

24.02.2021

$\Omega$  - zbiór zdarzeń elementarnych  
(czyli „wyników doświadczenia“)

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

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

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

Def. 1.1 Rodzina  $\mathcal{F}$  podzbiorów  $\Omega$

nazywamy  $\sigma$ -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  $(\Omega, \mathcal{F})$  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  $(\Omega, \mathcal{F})$  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

$\Omega$  - 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  $(\Omega, \mathcal{F}, P)$  — 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)  $\infty$  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: zastanów 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  
mierzniacz na obroty.

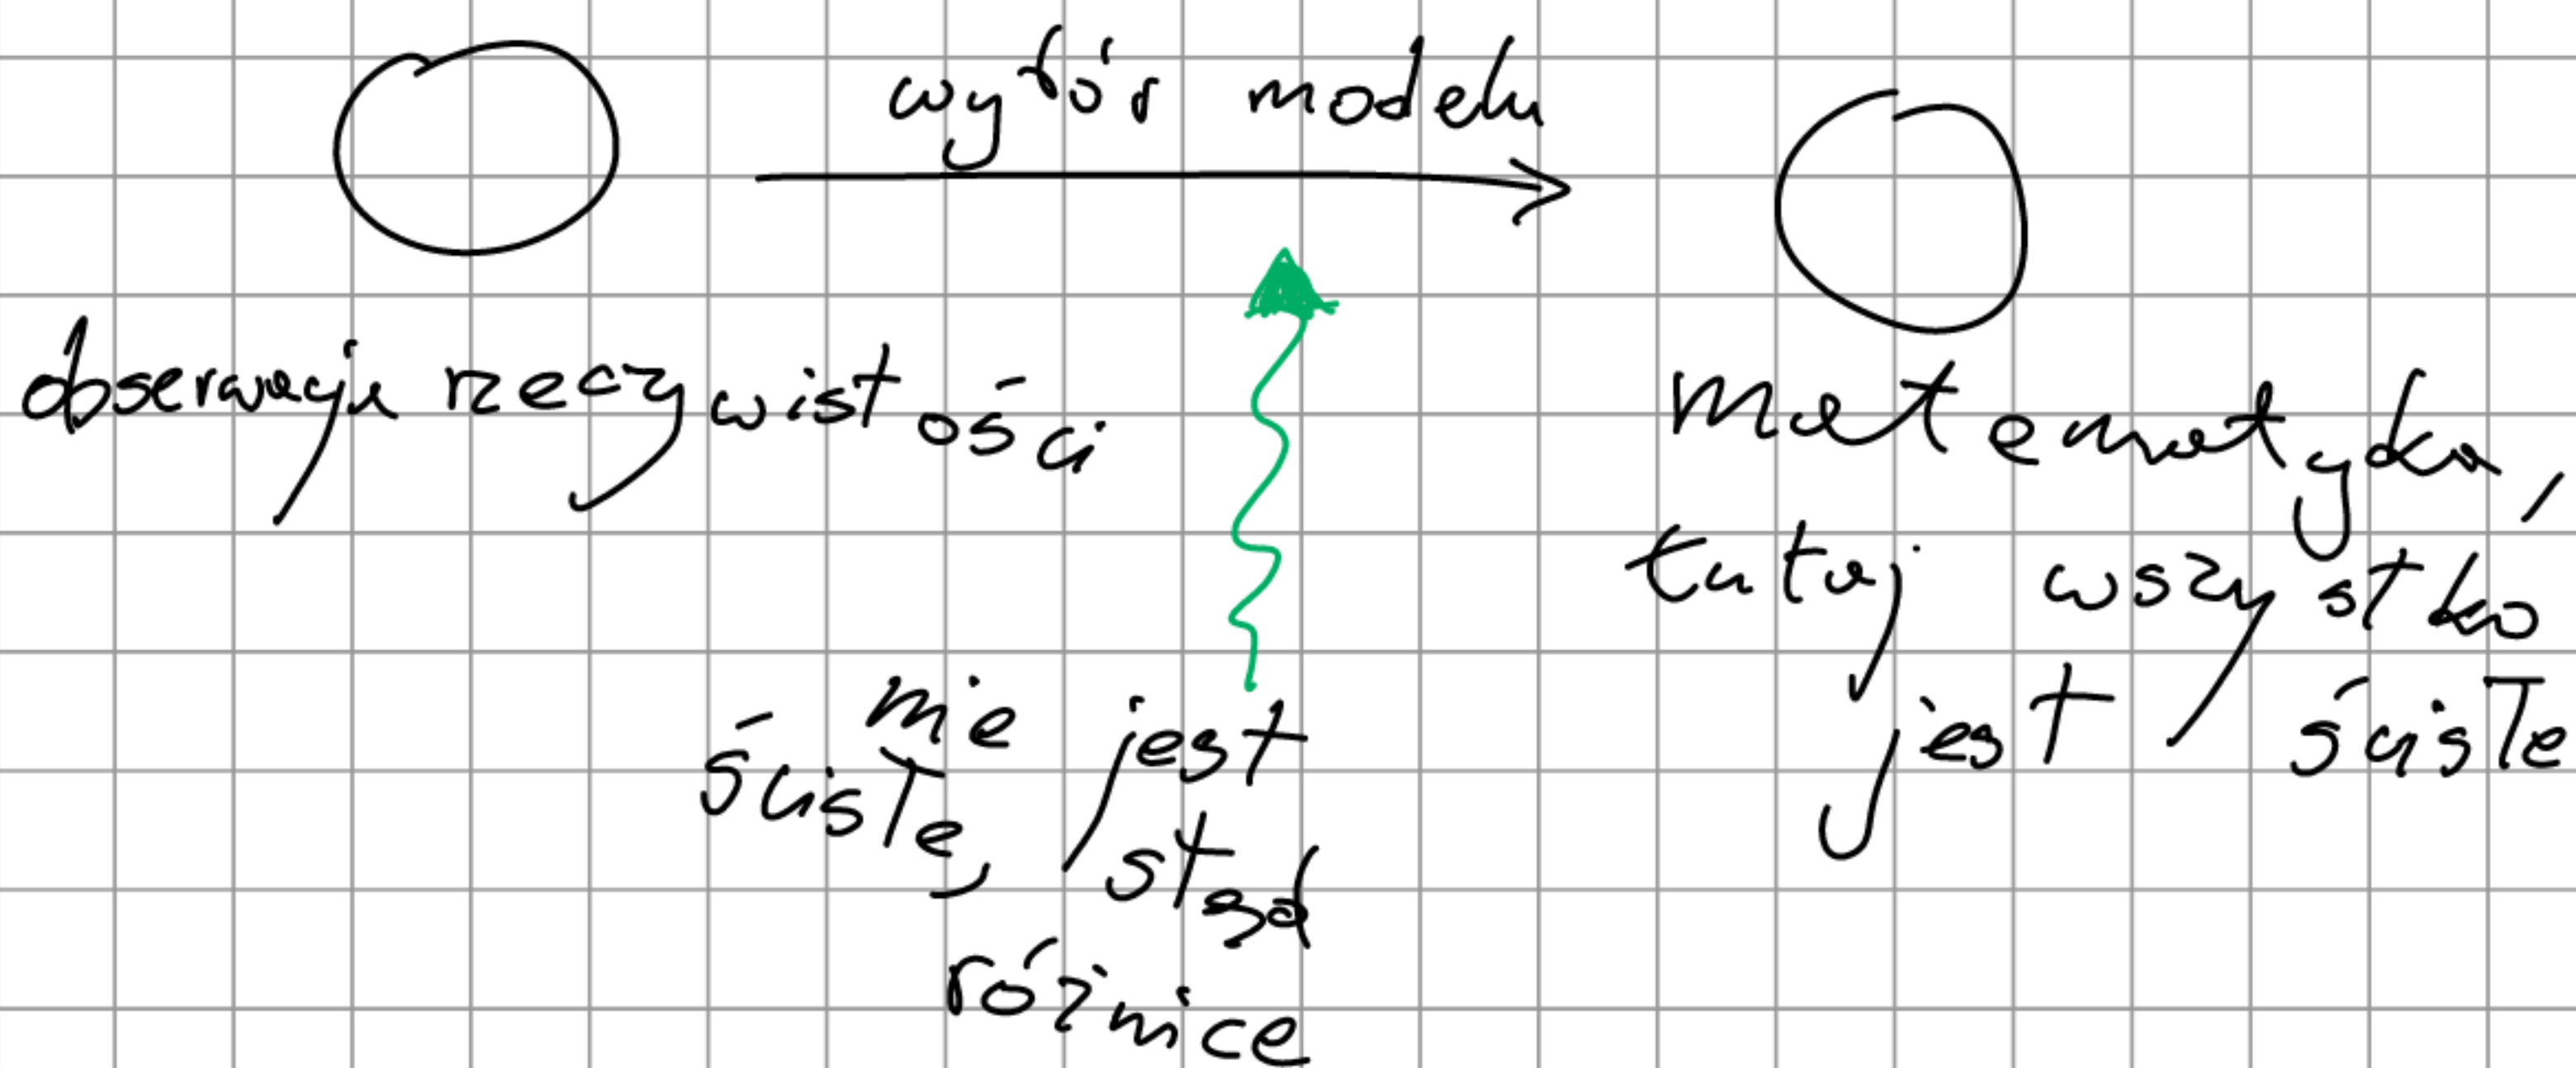


Możemy po prostu wylosować punkt z  
promienia okręgu, wyznaczyć on cięciwę.

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.  $(\Omega, \mathcal{F}, P)$  - 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  $(\Omega, \mathcal{F})$ .

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

jest rozbiciem zbiora  $\Omega$ ,

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



sumą rozłączną.

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



### Tw. 2.3 Wzór na p-stwo całkowite

$\{B_k\}_k^n$  - rozbicie  $\Omega$  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  $\mathcal{O}$   
 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. Jakże jest prawdopodobieństwo, 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:

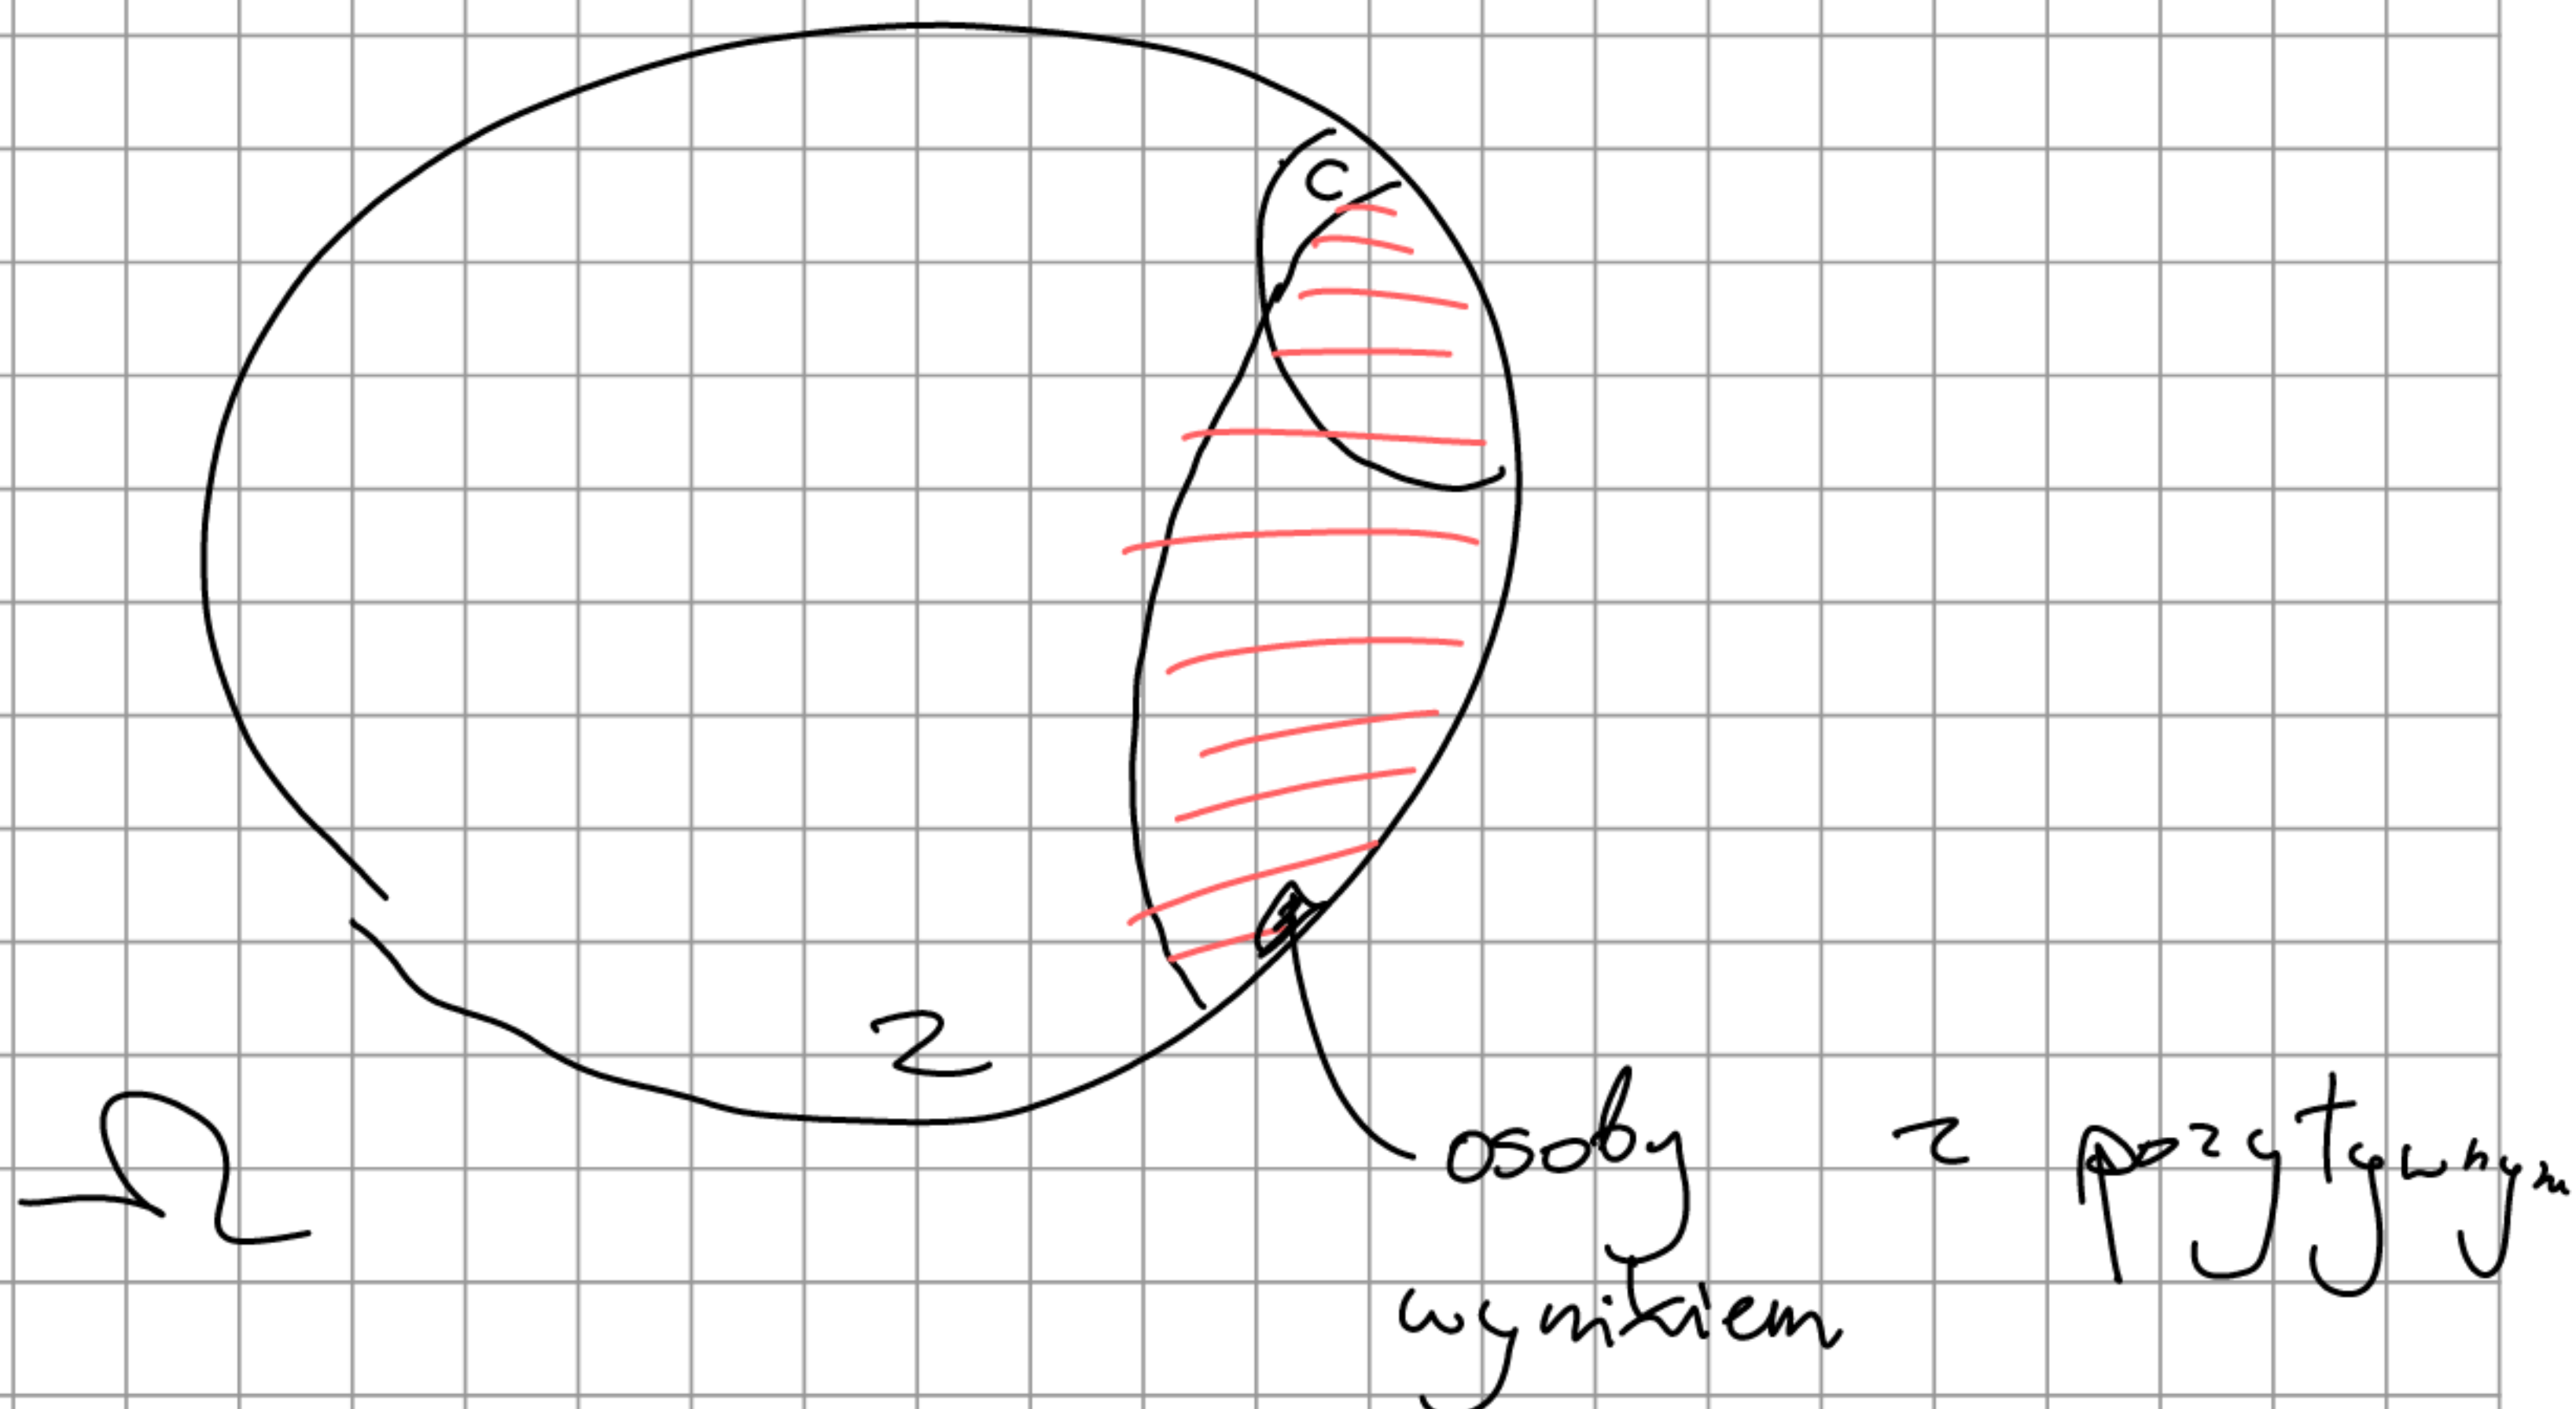
C - chora, Z - zdrowa.  $\Omega = C \cup Z$

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.  $(\Omega, \mathcal{F}, P)$  - 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' dniem 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 razem wypadła parzysta i oczek
- B - w drugim razem wypadła parzysta i liczbę oczek
- C - suma 1, oczek jest parzysta

Nówczas  $A, B, C$  są parami niezależne, ale  $ABC$  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  $(\Omega, \mathcal{F}, P)$  - p. prob.,

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

w  $\mathcal{F}$ . Mówimy, że te  $\sigma$ -cieto

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 rodzinie  $\{\mathcal{F}_i\}_{i \in I}$  jest niezależne, gdy każdy  $\mathcal{F}_i$  skończony

Podzbiór jest niezależny

Tw. 2.10  $\sigma$ -cięża  $\mathcal{F}_1, \dots, \mathcal{F}_n$

są niez.  $\Leftrightarrow$  dowolne zdarzenia

$A_1, \dots, A_n$  są niezależne.

Przykład Rzucamy 2 razy kostką.

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

składane się ze wszystkich podzbiórów  $\Omega$ ,

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

$\sigma$ -cięża


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

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

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

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

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



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

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

$\tilde{A}, \tilde{B}$  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  $\sigma$ -cieta  $\sigma(A_1), \dots, \sigma(A_n)$

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

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...  
(Bernoulli)

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

$(\Omega, \mathcal{F}, P)$ . 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.  $\infty$  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 gdać)

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



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

niezależne

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  $\omega \in \bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} A_n$ ? gdy  $\forall m \omega \in \bigcup_{n=m}^{\infty} A_n$ , czyli  $\omega$  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  $\infty$  wiele  
zbioreń  $A_n$ .

D-d.

$$1. \mathbb{P} \left[ \bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} A_n \right] \leq \mathbb{P} \left[ \bigcup_{n=M}^{\infty} A_n \right] \leq \\ \leq \sum_{n=M}^{\infty} \mathbb{P}[A_n] \xrightarrow{M \rightarrow \infty} 0 \\ (\text{z def. zbieżności szeregu})$$

2. Wystarczy, że

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

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

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  $\Omega$ ,  $A_i$  - w  $i$ -tym rzucie 6.

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

Z lematu B-C

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

infinity often

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

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

Przykład Urzasdnie, że jeżeli będziemy rzucać 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  $\infty$  wiele razy  
niesymetryczną monetą. Niech

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

Pokaż że z  $p$ -stwem 1

zachodzi jedynie skończenie  
wiele zdarzeń  $A_n$ .



Spacer losowy — z  $p$ -stwem

$p$  idziemy w prawo,  $1-p$

w lewo. Przykład mówi

o tym, że  $0$  odwiedimy skończenie

wiele razy.



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


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

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

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

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

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



z Lem. B-C

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

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

$\Downarrow$

$A_n$  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:

•  $\Omega$ : 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.  $X_1 + X_2, X_1 - X_2, X_1 \cdot X_2, X_1 \setminus X_2$  ( $X_2 \neq 0$ )

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  $\mu$  na  $(\mathbb{R}, \mathcal{B}_\sigma(\mathbb{R}))$


zdefiniowana wzorem

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

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

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

nazywamy rozkładem zmiennej losowej  $X$ .



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

p. prob.

17.03.2021

Co byto do tej pracy?

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

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

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

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

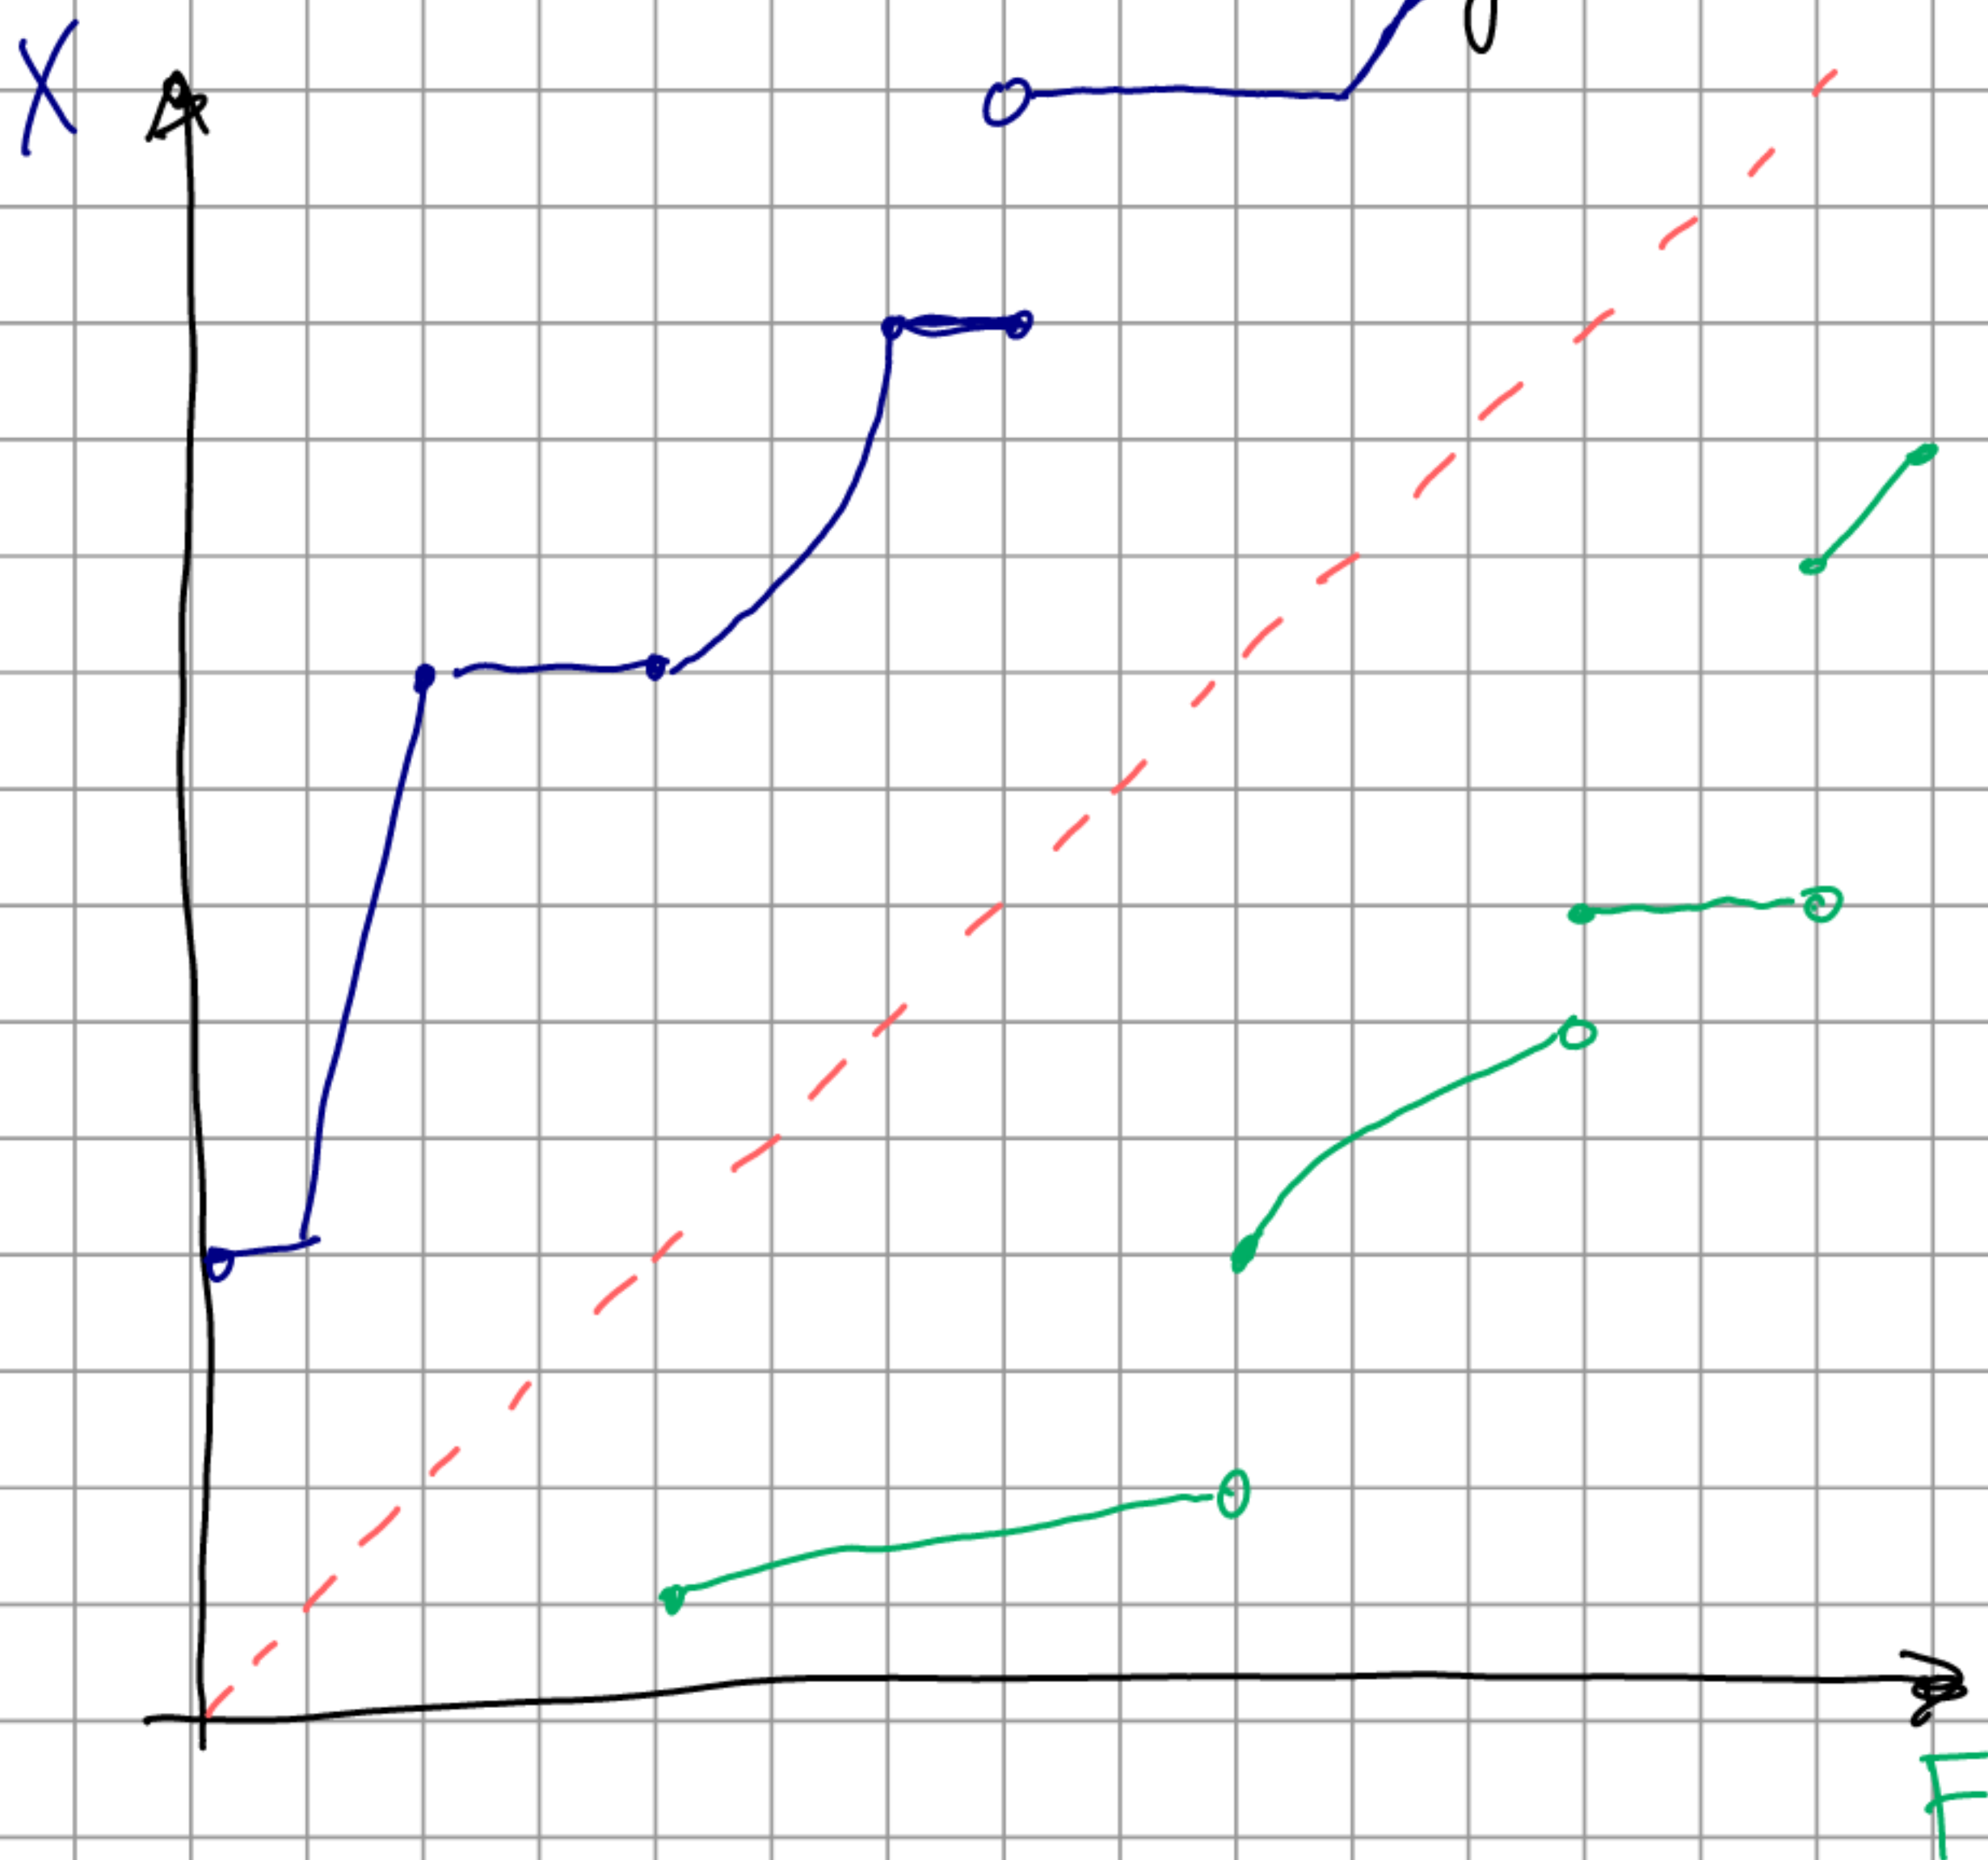
↖ bo  $F$  niemalejąca ↗

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

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  $\Omega$  nazywamy

$\pi$ -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  $\Omega$

nazywamy  $\lambda$ -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 $\pi$ -układach) Tw. Dynkina

Jeżeli  $\mathcal{L}$  jest  $\lambda$ -układem zawierającym  $\pi$ -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 spełniona przez

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

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

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

$\mathcal{L}$  jest  $\lambda$ -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  $\mu$  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 Tatwiej 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  $\mu$  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  $\lambda$  ( $\lambda > 0$ ):  $X \sim \text{Exp}(\lambda)$


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



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  $\mu$   
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  $(\Omega, \mathcal{F}, P)$ -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  $\mathbb{R}^d$ ,

$\mathcal{N}(m, A^{-1})$ :  $m$  - 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  $A$

Widoczne, 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  $X$

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

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

rodzina zmiennych losowych. Zmiennie te

są niezależne, jeżeli  $\sigma(X_i)$  ( $\sigma$ -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  $\sigma$ -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?

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



+ trochę naturzynie  
↓

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

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

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  $f$  nazywamy splotem  $f_1, f_2$ .

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

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

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

To jest splot

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

31.03.2021

Tw. z poprzedniego wykładu:

TW.4.12 Załóżmy, że  $X_1, X_2$  są nrl. zm. los.

o rozkładach ciągłych z gęstościami  $f_1, f_2$ .

Wówczas zmienna losowa  $X_1 + X_2$  ma

rozkład z gęstością

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

D-d. 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

▷

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

$z = x_1 + x_2$

=

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

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

$$= \int_B f_1 * f_2 dz$$

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

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

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

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



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  $(\Omega, \mathcal{F}, P)$ . 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 gracje 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  $n$   
rutzów. Wówczas oczekujemy, że gracz A  
wygra w przybliżeniu

$$\approx 1 \cdot \frac{n}{6} + 3 \cdot \frac{n}{6} + 5 \cdot \frac{n}{6} - 2 \cdot \frac{n}{6} - 4 \cdot \frac{n}{6} - 6 \cdot \frac{n}{6} = -\frac{n}{2}$$



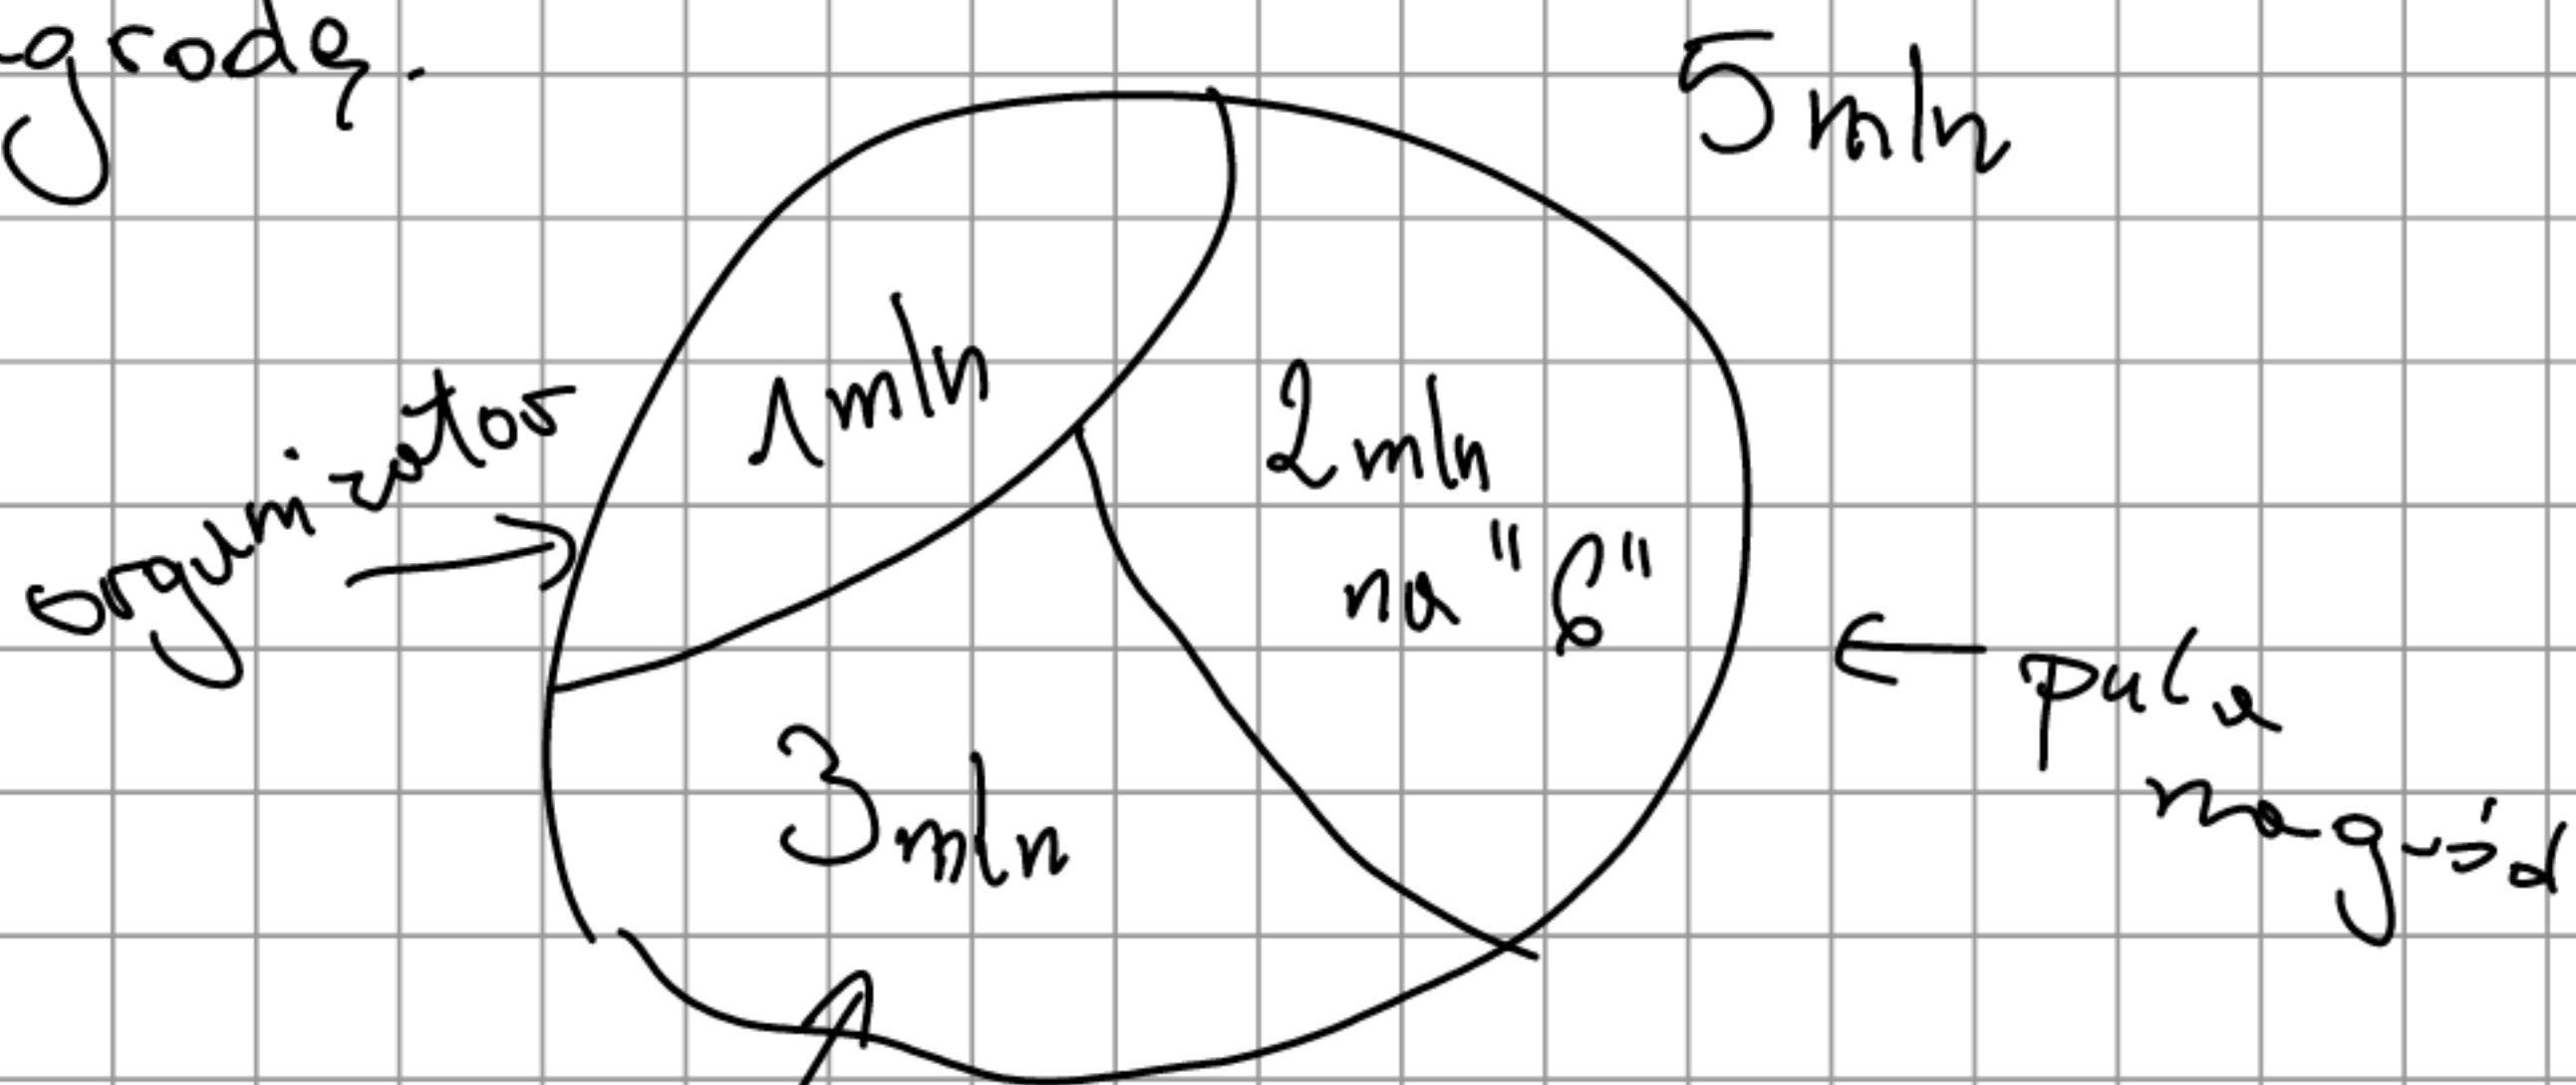
Formalnie: Niech  $X$  oznacza wygraną gracza A

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.


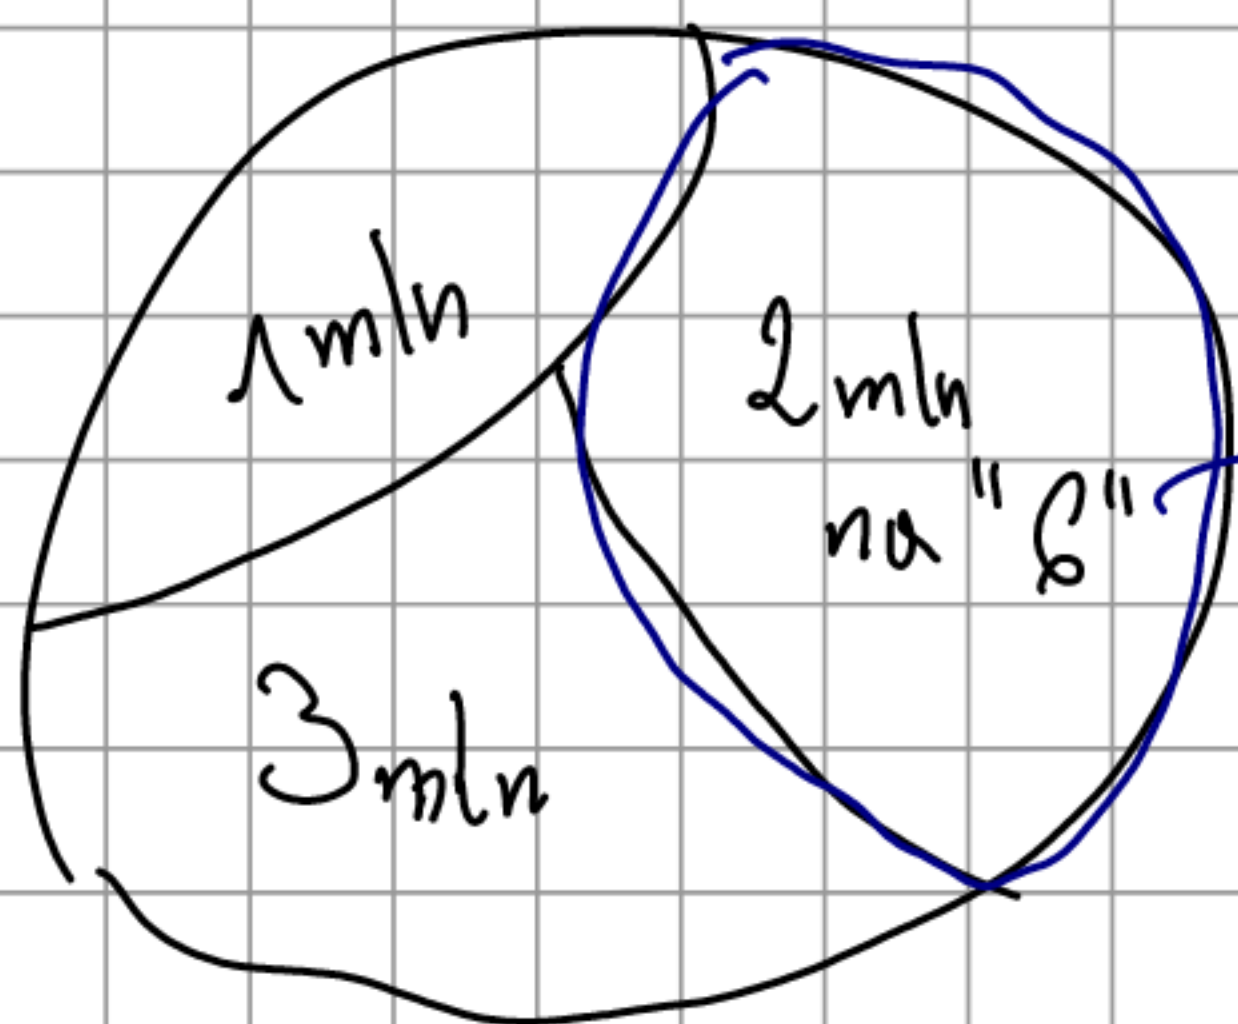
Jeśli skreśliśmy liczby wylosowane przez maszynę losującą, to dostajemy nagrodę.



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  $\omega$ , to

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

Przykład Kupujemy  $k$  losów w loterii, w której

jest  $M$  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  $\sigma$  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  $\mu$ .

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.

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

wynikie z kroku 1 i liniowości  
wartości oczekiwanej.

Krok 3.

Załóżmy, że  $f \geq 0$ . Wtedy można

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

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



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


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

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



Pod A mamy B lub C.

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



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

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

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

$$\sim 235$$

$\log 52 + \gamma$  stała  
eulera

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

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

nazywamy wariancją zmienną losową  $X$ .

Pierwiastek z wariancji nazywamy

odchyleniem standardowym

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

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

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

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

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

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

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

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

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

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

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

Jeżeli  $X$  ma rozkład dyskretny

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

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

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

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

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

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

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

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

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

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

↑  
niezależność

Przykład Żeńimy, 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

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

Przykład Niech  $\sigma$  będzie losową permutacją

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

punktów stałych  $\sigma$ . 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  $\mathbb{E} X \cdot Y = \mathbb{E} X \cdot \mathbb{E} Y$ ,

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

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

$$= \mathbb{E} X Y - \mathbb{E} X \mathbb{E} Y$$

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

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  
koszt 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

$\Rightarrow$

$$P[|X_n - X| < \epsilon] \leq \frac{E|X_n - X|^p}{\epsilon^p} \rightarrow 0$$

$\Leftarrow X_n = n^{1/p} \cdot \mathbb{1}_{[0,1/n]}$ ,  $X_n \xrightarrow{P} 0$ ,  $X_n \not\xrightarrow{L^p} 0$

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  $\varepsilon = 2^{-k}$ .

$$P[|X_n - X| \geq 2^{-k}] \leq 2^{-k} \quad (\text{dla dużych } n).$$

$n \geq n_k$

Możemy założyć, że  $\{n_k\}$  jest rosnący.

$$\text{Mamy } \sum_{k=1}^{\infty} P[|X_{n_k} - X| \geq 2^{-k}] \leq \sum_{k=1}^{\infty} 2^{-k} < \infty$$

\* 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

$$\mathbb{E}X_1^2 = \int_{-1}^1 x^2 \frac{dx}{2} = \frac{1}{2} \cdot \frac{1}{3} x^3 \Big|_{-1}^1 = \frac{1}{3}.$$

$$\text{Var} X_1^2 \leq \mathbb{E}X_1^4 \leq 1.$$

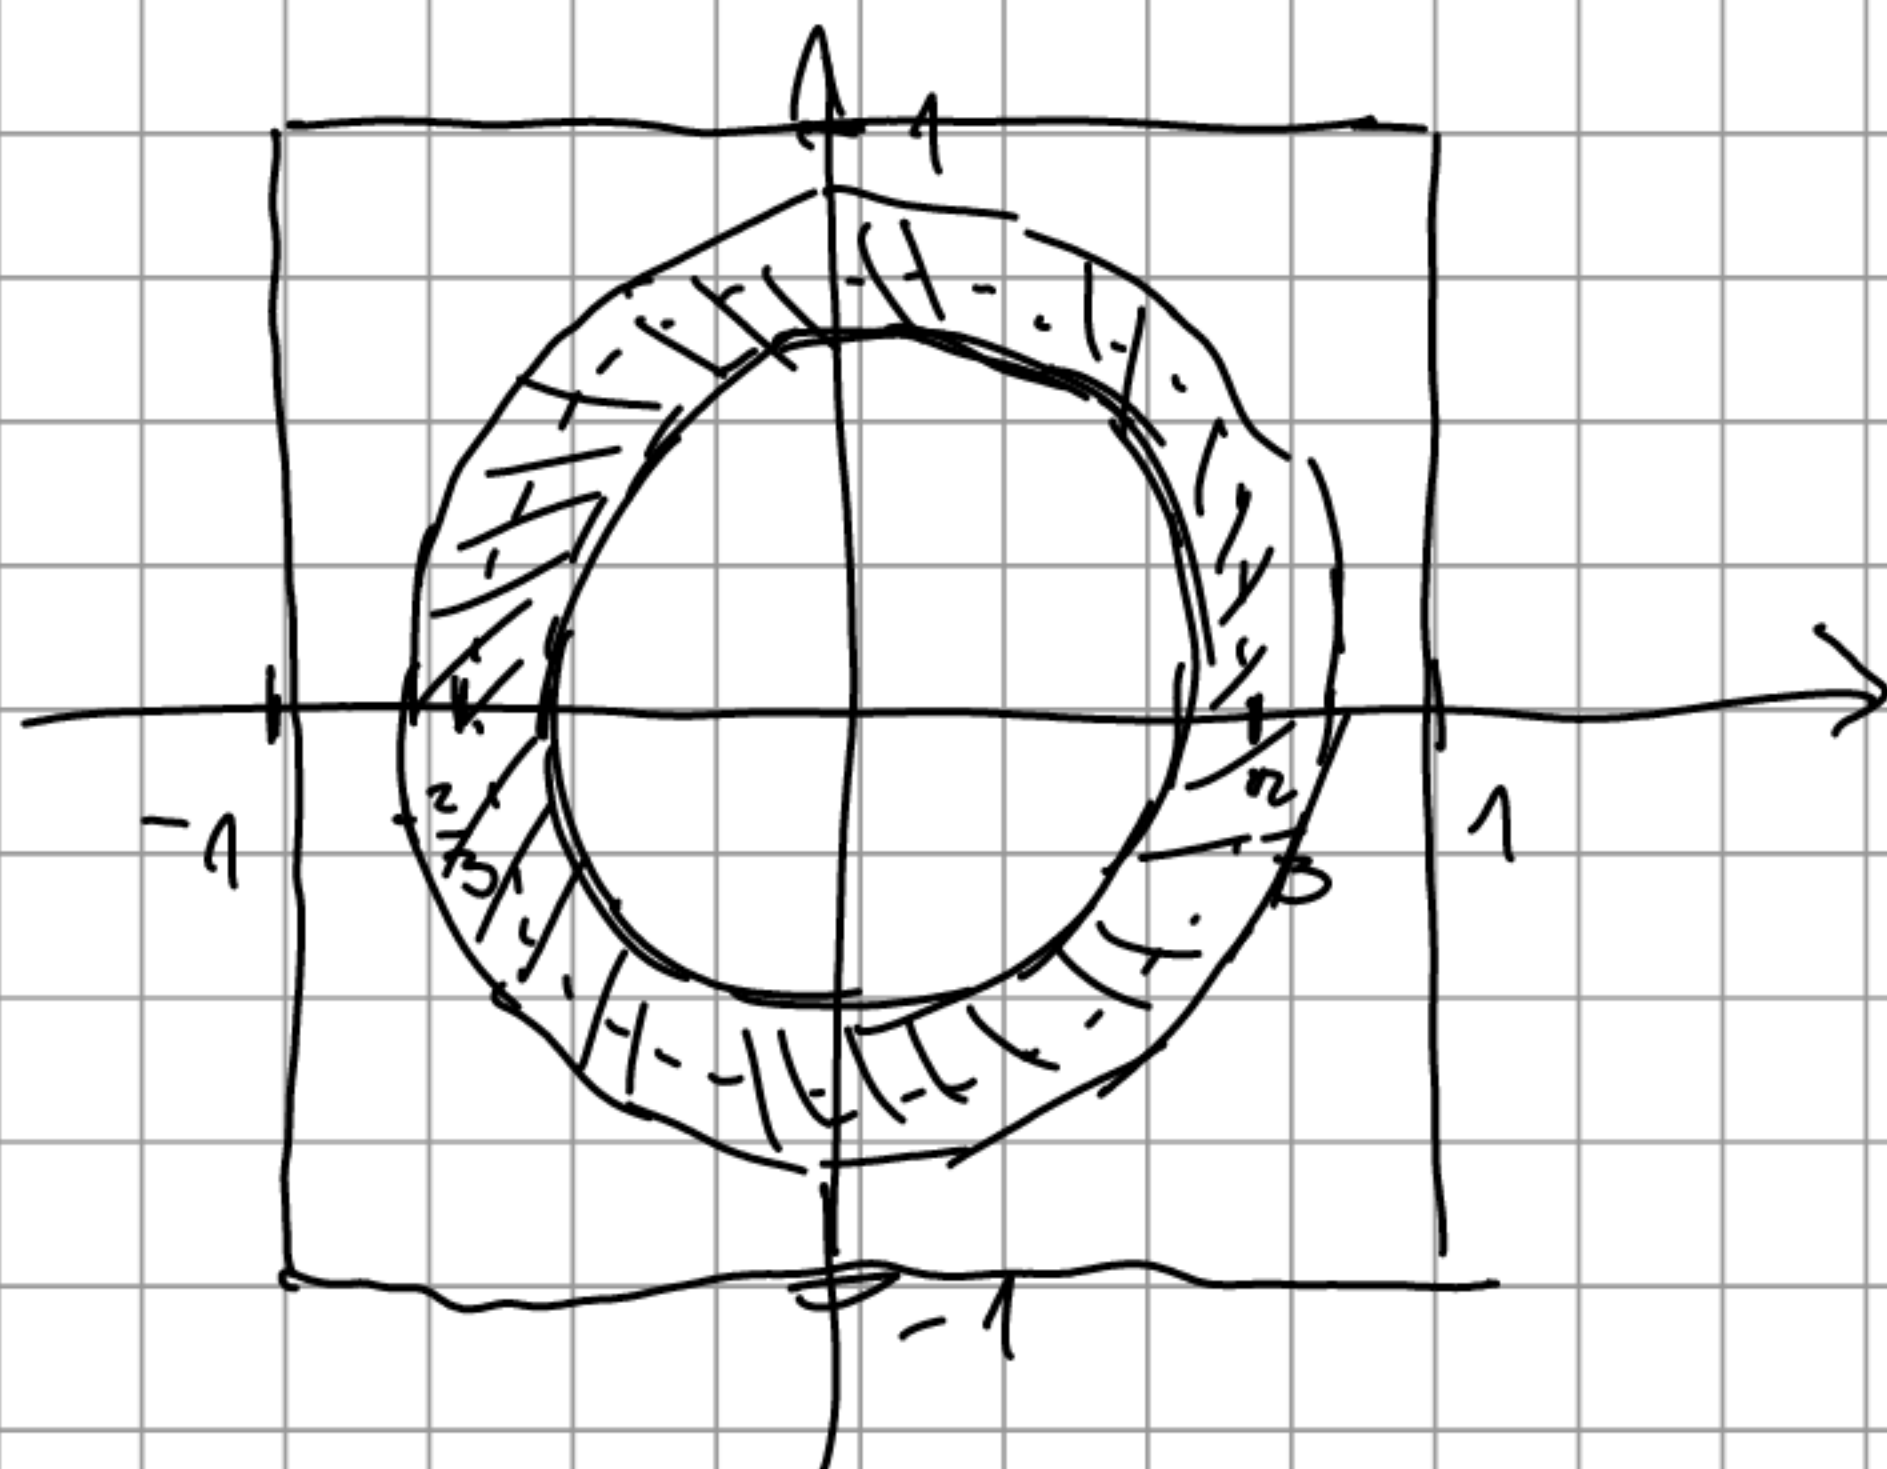


Ze SPWL mamy

$$\frac{X_1^2 + \dots + X_n^2}{n} \xrightarrow{P} \frac{1}{3}$$

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 pierścień 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:  $\frac{X_1 + \dots + X_n}{n}$   ~~$\mathbb{E}X_1$~~  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  $\pm 1$ , 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  $\sigma$ -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  $\sigma$ -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  $n$ .

$$\mathcal{F}_{n,\infty} \supseteq \mathcal{F}_{n+1,\infty}$$

$\mathcal{F}_\infty$  - wiedza o „nieskończenie

odległej” przyszłości.

Przykład. Rzucamy kostką.

"6 wypadnie  $\infty$  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  $\sigma$ -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  $n$

$$A = \bigcap_{k > n} \bigcup_{i \geq k} A_i \in \mathcal{F}_{n, \infty}$$

$\left( \begin{array}{l} A_i = \{2\} \text{ w } i\text{-tym rzucie wypadła } 6 \end{array} \right)$   
 $\left( \begin{array}{l} \bigcup_{i \geq k} A_i = \{2\} \text{ w rzutach } k, k+1, k+2, \dots \text{ wypadła} \\ \text{co najmniej jedna } 6 \end{array} \right)$   
 $\left( \begin{array}{l} A = \{2\} \text{ wypadło } \infty \text{ wiele } 6 \end{array} \right)$

- zdarzenie

$A = \{\omega: \text{ciąg } \{X_n(\omega)\} \text{ jest zbieżny}\}$   
 należy do  $\sigma$ -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  $\sigma$ -ciała ogólnego

• zdanie

$$\left\{ \limsup_{n \rightarrow \infty} (X_1 + \dots + X_n) > 0 \right\}$$

nie należy do  $\sigma$ -cieta

ogonowego, ponieważ pierwsze składniki mają wpływ na granicę.

Tw. 7.3 (Prawo 0-1 Kolmogorowa)

Jeżeli  $\sigma$ -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  $\pi$ -aktua, to

$\sigma$ -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  $\lambda$ -ciałem

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

- 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

$$P[B \cap A_2 \cap \dots \cap A_n] \xrightarrow{k \rightarrow \infty} P[B_k \cap A_2 \cap \dots \cap A_n] = \\ = P[B]P[A_2] \dots P[A_n] \xrightarrow{k \rightarrow \infty} P[B]P[A_2] \dots P[A_n]$$

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  $\pi$ -układem.

Rodziny  $\sigma(\mathcal{F}_1, \dots, \mathcal{F}_n)$  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  $\pi$ -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 niezależnymi 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  $\infty$  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.



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



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.  $\{X_n\}_n$

rozkładzie  $g$  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:

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

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

z MPWL

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

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

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-o. 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  $\{|X_n| > n\}$ .

lemmat 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

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

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

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

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-ś. 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 ciągłem 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. "⇐" Żut. że te 3 szeregi są

zbieżne.

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

i tw. Kotmogorowe o dwóch



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

2. Korzystamy z lematu Borela-Cantali ego.

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:  $\forall \epsilon > 0 \exists n$  dla dużych  $n$   $|S_n| < \epsilon \cdot n$

• 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  
 żmudne, 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. 9.1

Niech  $\{X_n\}$  będzie

ciągiem niezależ. zm. los. t.ż.  $P[X_n = 1] =$

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

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.

D-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  $n = 2m$  (głównia 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  $\mu_n$  zbieżny do miary  $\mu$ ?

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  $\mu_n$  będzie ciągiem miar prob. na  $\mathcal{B}_0(\mathbb{R})$ . Mówimy, że  $\mu_n$  zbiegają słabo do miary prob.  $\mu$  ( $\mu_n \Rightarrow \mu$ ) 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  $\mu_n, \mu$  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. z.  $\mu(\partial A) = 0$

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

↑  
breg  $A$

19.05.2021

D-d. tw. 9.3

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

Dla  $\varepsilon > 0$  oznaczymy przez

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

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

i weźmy  $\varepsilon > 0$  taki, że

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

Taki  $\varepsilon$  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

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

∴ dowolności  $\delta$  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

$F_\varepsilon$ . Patrzymy na  $\partial F_\varepsilon$  - są to zbiory

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

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

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


$\sum_{\varepsilon > 0} \mu(\partial F_\varepsilon) \leftarrow$  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  $\mu, \nu$  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  $\Pi$ - $\lambda$  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  $\Pi$ -układem,  $\mathcal{L}$  jest  $\lambda$ -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 pokazujemy  $\nu(F) \leq \mu(F)$

co daje równość obu miar

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

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



TW. 9.5 Niech  $\{\mu_n\}_{n=1}^{\infty}$ ,  $\mu$  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 pstwem  $\frac{1}{2}$ .

$S_n = X_1 + \dots + X_n$ . 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  $\varepsilon$ , 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  $\delta_a$  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  $S_n/n \xrightarrow{d} N(0,1)$



26.05.2021 Przypomnienie:

Ciąg miar  $\{\mu_n\}$  zbiega słabo do

miary  $\mu$  jeżeli  $(\mu_n \Rightarrow \mu)$

$$\forall f \in C(\mathbb{R}) \quad \int_{\mathbb{R}} f(x) d\mu_n(x) \rightarrow \int_{\mathbb{R}} f(x) d\mu(x)$$

ciąg i  
ograniczone

$$(X_n \xrightarrow{d} X)$$

Ciąg zm. los.  $\{X_n\}$  zb. wg rozkładu

do zm. los.  $X$  jeżeli  $\mu_{X_n} \Rightarrow \mu_X, \tau_n$

$$\forall f \in C(\mathbb{R}) \quad \mathbb{E} f(X_n) \rightarrow \mathbb{E} f(X)$$

lemmat 9.7  $\{X_n\}, \{Y_n\}$  - ciągi zm. los.

Wtedy:

• jeżeli  $X_n \xrightarrow{P} X$ , to  $X_n \xrightarrow{d} X$







• jeżeli  $X_n \xrightarrow{d} X$  i  $P[X=c]=1$ , to

$$X_n \xrightarrow{P} c$$

• jeżeli  $X_n \xrightarrow{d} X$ , to  $aX_n + b \xrightarrow{d} aX + b$ ,

dla  $a, b \in \mathbb{R}$

• jeżeli  $X_n \xrightarrow{d} X$  i  $Y_n \xrightarrow{d} c$ , to  $X_n + Y_n \xrightarrow{d} X + c$   
oraz  $X_n Y_n \xrightarrow{d} cX$



Przykład. Zbieżność wg rozkładu nie implikuje zb. wg p-stwa.

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

$$X_k = \begin{cases} \mathbb{1}_{[0, \frac{1}{2}]} & \text{gdy } k \text{ nieparzyste} \\ \mathbb{1}_{[\frac{1}{2}, 1]} & \text{gdy } k \text{ parzyste} \end{cases}$$

$X_k$  ma rozkład  $\frac{1}{2}\delta_0 + \frac{1}{2}\delta_1$ , więc

$\mu_{X_n} \Rightarrow \frac{1}{2}\delta_0 + \frac{1}{2}\delta_1$ , ale nie

ma zb. wg. p-stwa.

b)  $Y \sim \mathcal{N}(0,1)$ ,  $X_n = (-1)^n Y$

Tw. 9.8 (Skorochoła)

Zet. że  $\{X_n\}$  jest ciągiem zm. los.

określonych na  $(\Omega, \mathcal{F}, \mathbb{P})$  i t. że

$X_n \xrightarrow{d} X$  dla pewnej zm. los  $X$ . Istnieje

zm. los  $\{X'_n\}$  oraz  $X'$  określone na

$(0,1), \mathcal{B}_w(0,1), \lambda$ ) t. że  $X_n \stackrel{d}{=} X'_n, X \stackrel{d}{=} X'$

(a więc w szczególności  $X'_n \xrightarrow{d} X'$ ) oraz

$X'_n \rightarrow X'$  p.n.

Def. 9.9 Dystrybucja atomna to

funkcja  $F$  spełniająca warunki:

•  $F$  jest niemalejąca

•  $0 \leq F(t) \leq 1$

•  $F$  jest prawostronnie ciągła

•  $\lim_{t \rightarrow \infty} F(t) - \lim_{t \rightarrow -\infty} F(t)$

$= P \leq 1$ .

Rozważmy rodzinę dystrybucyj atomowych  $\{F_n\}$   
zbieżnych do  $F$  (czyli  $F_n(x) \rightarrow F(x)$   
dla każdego  $x$  - punkta ciągłości  $F$ )

Tw. 9.10 (Hollera o wyborze)

Każdy ciąg dystrybucyj zawiera podciąg  
steżo zbieżny do dystrybucyj atomowej:

$\{F_n\}$  dystrybucyj,  $\exists \{n_k\}$  t.j.  $F_{n_k} \rightarrow F$  dystrybucyj atomowej.

D-d. Idea: chcemy wybrać  $\{F_{n_k}\}$  który  
będzie zbieżny punktowo we wszystkich  
liczbach wymiernych.

**krok 1** Ustawmy  $n$ . wymierne w ciągu  $w_1, w_2, w_3, \dots$   
Ciąg  $\{F_n(w_1)\}$  jest ograniczony (bo  $F_n \in [0,1]$ )  
Z tw. Bolzano - Weierstrassa ten ciąg

zawiera podciąg zbieżny  $F_{n_{1k}}$ :

$$\lim_{k \rightarrow \infty} F_{n_{1k}}(w_1) =: F_0(w_1)$$

Krok 2

Ciąg  $\{F_{1,k}(w_2)\}_k$  jest ograniczony, więc

zawiera podciąg zbieżny  $\{F_{2,n}(w_2)\}$

$$\lim_{n \rightarrow \infty} F_{2,n}(w_2) =: F_0(w_2)$$

Krok 3

Analogicznie do poprzednich

$$\lim_{n \rightarrow \infty} F_{3,n}(w_3) =: F_0(w_3)$$

⋮

$$\begin{array}{ccccccc} F_{1,1}(w_1) & F_{1,2}(w_1) & F_{1,3}(w_1) & \dots & \rightarrow & F_0(w_1) \\ F_{2,1}(w_2) & F_{2,2}(w_2) & F_{2,3}(w_2) & \dots & \rightarrow & F_0(w_2) \\ F_{3,1}(w_3) & F_{3,2}(w_3) & F_{3,3}(w_3) & \dots & \rightarrow & F_0(w_3) \\ \vdots & \vdots & \vdots & & & \vdots \end{array}$$

Wybieramy podciąg  $\{F_{n,k,k}\}$  - podciąg  
dystrybuent, który spełnia

$$\lim_{k \rightarrow \infty} F_{n,k,k}(w) = F_0(w) \quad \forall w \in \mathbb{Q}$$

Definiujemy  $F_0$  na  $\mathbb{R}$ :

$$F_0(t) = \inf \{ F_0(w) : t < w, w \in \mathbb{Q} \}$$

Przykład.  $F_n(x) = \begin{cases} 0 & x < n \\ 1 & x \geq n \end{cases}$

Zauważmy, że  $F_n(x) \rightarrow 0$  gdy  $n \rightarrow \infty$ ,

wiec  $\{F_n\}$  zb. słabo do dystrybucyj

$\mu$ -Tomnej  $F \equiv 0$  ( $\delta_n \Rightarrow 0$ )

Przykład  $F_n(x) = \begin{cases} 0 & x < -n \\ 1 & x \geq n \end{cases}$

$\{F_n\}$  zbiega do  $F \equiv 1$  - dyst.  $\mu$ -Tomna.

Problem: Znaleźć warunki, przy których dystrybucja graniczna jest prawdziwą dystrybucją.

Def. 3.11 Rodzina  $\{\mu_t\}_{t \in T}$  rozkładów  $p$ -stopnia na  $(\mathbb{R}, \mathcal{B}_p(\mathbb{R}))$  nazywana jest ciasną (jedrną, ang. tight), jeżeli

dla każdego  $\varepsilon > 0$  istnieje zbiór  
zawarty w  $t$ -ie

$$\mu_t(K) > 1 - \varepsilon, \quad \forall t \in T$$
$$(\mu_t(K^c) < \varepsilon)$$

(np.  $K = [-N, N]$  dla pewnego "dużego"  $N$ )

Przykład. Niech  $\{X_t\}_{t \in T}$  będzie rodziną

zm. los.  $t$ -ie istnieje  $\delta > 0$ :

$$\sup_{t \in T} \mathbb{E} |X_t|^\delta = M < \infty$$


Wtedy rodzina  $\{\mu_{X_t}\}_{t \in T}$  jest ciasna.

Wstawmy  $\varepsilon > 0$ . Wtedy dla  $t \in T$

$$\begin{aligned} \mu_t([-n, n]^c) &= \mathbb{P}[|X_t| > n] \leq \mathbb{P}[|X_t|^\delta > n^\delta] \leq \\ &\leq \frac{\mathbb{E} |X_t|^\delta}{n^\delta} \leq \frac{M}{n^\delta} < \varepsilon \quad \text{dla dużych } n. \end{aligned}$$

Tw. 9.12 (Prohorowa)

Rodzina rozkładów  $p$ -stwa jest ciasna



z każdego ciągu elem. tej rodziny można  
wybrać podciąg słabo zbieżny do pewnego  
rozkładu  $p$ -stwa.

D-d. " $\Rightarrow$ " Łat.  $\{F_t\}_{t \in T}$  jest ciasna.

Z tw. Hellyego istnieje  $\{F_{n_k}\}$  do pewnej atomnej dystrybucyjności  $F$ . Pokazamy, że  $F$  jest dystrybucyjną. Wybierzmy  $\varepsilon > 0$ .

Z ciasności wynika, że istnieje  $M$  t.ze

$$\mu_{n_k}([-M, M]) > 1 - \varepsilon. \text{ Możemy założyć,}$$

że  $M, -M$  są pkt. ciągłości  $F$  oraz  $F_{n_k}$

dla każdego  $k$ . Wówczas

$$F_{n_k}(M) - F_{n_k}(-M) = \mu_{n_k}([-M, M]) > 1 - \varepsilon$$

$$\downarrow k \rightarrow \infty$$

$$F(M) - F(-M)$$

Pokazaliśmy, że  $\forall \varepsilon > 0 \exists M_\varepsilon (F(M_\varepsilon) - F(-M_\varepsilon)) < 1 - \varepsilon$

Łatem  $\lim_{M_\varepsilon \rightarrow \infty} F(M_\varepsilon) - F(-M_\varepsilon) = 1.$

Łatem  $F$  jest prawdziwą dystrybucyjną.

" $\Leftarrow$ " ćwiczenie. ■

---



$\{a_n\}_{n \in \mathbb{N}} \rightsquigarrow$  funkcja tworząca  $F(x) = \sum_{n=0}^{\infty} a_n x^n$

$\{X_n\}_{n \in \mathbb{N}} \rightsquigarrow$  funkcje charakterystyczne } Centralne  
(transformata Fouriera) } tw. granicznych

Def. 10.1 Funkcja charakterystyczna zmiennej

losowej  $X$  nazywamy funkcję  $\varphi_X: \mathbb{R} \rightarrow \mathbb{C}$

zdefiniowaną wzorem

$$\varphi_X(t) = \mathbb{E} e^{itX} = \mathbb{E} [\cos(tX) + i \sin(tX)]$$

$$= \mathbb{E} \cos tX + i \mathbb{E} \sin tX$$

$$\int_{\mathbb{R}} e^{its} d\mu_X(s)$$

$$\left[ \hat{f}(x) = \int_{\mathbb{R}} e^{itx} f(x) dx \right]$$

Przykład.

1)  $X = a$  p.w.,  $\varphi_X(t) = \mathbb{E} e^{itX} = \mathbb{E} e^{ita} = e^{ita}$

2)  $X \sim U(0,1)$ ,  $\varphi_X(t) = \int_0^1 e^{its} ds = \int_0^1 \cos ts ds$

$$+ i \int_0^1 \sin ts ds = \frac{\sin ts}{t} \Big|_0^1 - i \frac{\cos ts}{t} \Big|_0^1 =$$

$$= \frac{\sin t}{t} - \frac{i \cos t}{t} + \frac{i}{t} = \frac{1}{it} (i \sin t + \cos t - 1) = \frac{e^{it} - 1}{it}$$

(albo  $t=0$  to nie działa, ale Tetwo wprost policzyć  $t_0$  całką)

3)  $X \sim N(0,1)$ , wtedy  $\varphi_X(t) = e^{-\frac{t^2}{2}}$ . Jak to policzyć?

1) Metoda z analizy zespolonej

$$\begin{aligned} 2) \varphi(t) &= \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} e^{itx} e^{-\frac{x^2}{2}} dx = \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} \cos(tx) e^{-\frac{x^2}{2}} dx \\ &+ \frac{i}{\sqrt{2\pi}} \int_{\mathbb{R}} \sin(tx) e^{-\frac{x^2}{2}} dx = \frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} \cos(tx) e^{-\frac{x^2}{2}} dx \end{aligned}$$

funkcja nieparzysta

Różniczkujemy po  $t$ :

$$\begin{aligned} \varphi'(t) &= -\frac{1}{\sqrt{2\pi}} \int_{\mathbb{R}} \sin tx \cdot x \cdot e^{-\frac{x^2}{2}} dx \\ &= \frac{1}{\sqrt{2\pi}} \sin tx e^{-\frac{x^2}{2}} \Big|_{-\infty}^{+\infty} - \frac{t}{\sqrt{2\pi}} \int_{\mathbb{R}} \cos(tx) e^{-\frac{x^2}{2}} dx \\ &= -t \varphi(t) \end{aligned}$$

otrymaliśmy równanie  $\varphi' = -t\varphi$ ,  $\varphi(0) = 1$ .

$$\frac{d\varphi}{dt} = -t\varphi \rightarrow \int \frac{d\varphi}{\varphi} = -\int t dt \rightarrow \log|\varphi| = -\frac{t^2}{2} + C$$

$$\varphi = C \cdot e^{-\frac{t^2}{2}}, \quad C = 1.$$

Podsumowując:

•  $\mathcal{D}_a \rightarrow e^{ita}$

•  $\mathcal{U}(0,1) \rightarrow \frac{e^{it} - 1}{it}$

•  $\mathcal{N}(0,1) \rightarrow e^{-\frac{t^2}{2}}$

Tw. 10.2 Niech  $\varphi_X$  będzie f. char. zm. los.  $X$ .

Wtedy:

1)  $\varphi_X(0) = 1$

2)  $|\varphi_X(t)| \leq 1$

3)  $\varphi_X(t) = \overline{\varphi_X(-t)}$  ( $\mathbb{E} e^{itX} = \mathbb{E} \overline{e^{-itX}} = \overline{\mathbb{E} e^{-itX}} = \overline{\varphi(-t)}$ )

4)  $\varphi_X(t)$  jest rzeczywist  $\Leftrightarrow$  rozkład  $X$  jest symetryczny

5)  $\varphi_X$  jest jednostajnie ciągłe.

6)  $\varphi_{aX+b}(t) = e^{itb} \varphi_X(at)$

D-d 5)  $\forall \epsilon > 0 \exists \delta > 0 \forall x, y \ |x-y| < \delta \Rightarrow |\varphi_X(x) - \varphi_X(y)| < \epsilon$

$$|\varphi_X(t+h) - \varphi_X(t)| = |\mathbb{E} e^{i(t+h)X} - \mathbb{E} e^{itX}| = |\mathbb{E}[e^{itX}(e^{ihX} - 1)]|$$

$$\leq \mathbb{E} |e^{ihX} - 1| \rightarrow 0 \text{ gdy } h \rightarrow 0.$$

$$6) \varphi_{aX+b}(t) = \int e^{it(ax+b)} = e^{itb} \int e^{i(at)x} = e^{itb} \varphi_X(at)$$

9.08.2021 Chcemy badać wagi zm. los.  $\{X_n\}$ .

iid. i ich sumy  $X_1 + \dots + X_n = S_n$ .

Pytamy, czy  $S_n$  zbiega (po odpowiednim  
znormalizowaniu) i w jakim sensie?

### Tw. 10.3 (Bochnera)

Funkcja  $\varphi$  jest f. char. pewnego rozkładu

p-stwa wtedy i tylko wtedy, gdy  $\varphi$   
jest ciągła,  $\varphi(0) = 1$  i jest dodatnio  
określona, tzn. dla każdego ciągu  $t_1, \dots, t_n$

oraz  $z_1, \dots, z_n \in \mathbb{C}$  zachodzi

$$\sum_{k, j \leq n} \varphi(t_k - t_j) z_k \bar{z}_j \geq 0$$

D-d. " $\Rightarrow$ "

$$\sum_{k, j \leq n} \varphi(t_k - t_j) z_k \bar{z}_j = \sum_{k, j} \mathbb{E} \left[ e^{i(t_k - t_j) X} z_k \bar{z}_j \right]$$
$$= \mathbb{E} \left[ \sum_{k, j} e^{it_k X} z_k \overline{e^{it_j X} z_j} \right] = \mathbb{E} \left[ \sum_k e^{it_k X} z_k \overline{\left( \sum_j e^{it_j X} z_j \right)} \right]$$
$$= \mathbb{E} \left[ \left| \sum_k e^{it_k X} z_k \right|^2 \right] \geq 0 \quad (z \bar{z} = |z|^2)$$

Tw. 10.4 Załóżmy, że  $X$  jest zm. los. taką,  
że  $E|X_k|^k < \infty$  dla pewnej liczby naturalnej  
 $k$ . Wtedy f. char.  $\varphi_X$  ma  $k$ -tą ciągłą  
pochodną oraz

$$\varphi_X^{(k)}(t) = i^k E[e^{itX} X^k].$$

W szczególności

$$\varphi_X^{(k)}(0) = i^k E[X^k].$$

Ponadto

$$\varphi_X(t) = 1 + \sum_{k=1}^n \frac{(it)^k}{k!} \cdot E[X^k] + o(|t|^n)$$

gdzie ostatni składnik spełnia

$$\lim_{t \rightarrow 0} \frac{o(|t|^n)}{|t|^n} = 0.$$

"Dowód"  $\varphi_X(t) = E e^{itX}$ . Jak różniczkować  $\varphi_X$ ?

Krok. 1 Należy pokazać, że  $\varphi_X'(t) = E[(e^{itX})']$

Krok. 2  $\varphi_X'(t) = E[iX e^{itX}]$

Dowód kroku 1.

Dla  $k=1$  mamy

$$\frac{\varphi_X(t+h) - \varphi_X(t)}{h} = \mathbb{E} \left[ \frac{e^{i(t+h)X} - e^{itX}}{h} \right] = \mathbb{E} \left[ e^{itX} \frac{e^{ihX} - 1}{h} \right].$$

Zauważmy, że  $\lim_{h \rightarrow 0} \frac{e^{ihX} - 1}{h} = iX$  (pochodna  $e^{itX}$ )

Chcemy użyć tw. Lebesgue'a. W tym celu piszemy

$$\left| e^{itX} \cdot \frac{e^{ihX} - 1}{h} \right| \leq \frac{|\cos(hX) - 1|}{|h|} + \frac{|\sin(hX)|}{|h|}$$

$$= |X| \cdot \left( \underbrace{\sin \frac{hX}{2} \cdot \frac{\sin \left( \frac{hX}{2} \right)}{h|X|/2}}_{\leq 1} + \underbrace{\frac{|\sin hX|}{|h||X|}}_{\leq 1} \right) \leq 2|X|$$

Z zał.  $\mathbb{E}|X| < \infty$  możemy odwołać się do

tw. Lebesgue'a i stąd

$$\begin{aligned} \varphi_X'(t) &= \lim_{h \rightarrow 0} \frac{\varphi_X(t+h) - \varphi_X(t)}{h} = \mathbb{E} \left[ e^{itX} \cdot \lim_{h \rightarrow 0} \frac{e^{ihX} - 1}{h} \right] \\ &= i \mathbb{E} [e^{itX} \cdot X] \end{aligned}$$

TW. 10.5 Jeżeli  $X, Y$  są niezależnymi zm. los. to

$$\varphi_{X+Y}(t) = \varphi_X(t)\varphi_Y(t)$$

D-o.  $\varphi_{X+Y}(t) = \mathbb{E} e^{it(X+Y)} = \mathbb{E} e^{itX} \mathbb{E} e^{itY} = \varphi_X(t)\varphi_Y(t)$ .

TW. 10.6 (o jednoznaczności)

Jeżeli rozkłady  $\mu$  i  $\nu$  na  $\mathbb{R}$  mają

równe funkcje charakterystyczne

$$\varphi_\mu(t) = \varphi_\nu(t), \quad t \in \mathbb{R}$$

to  $\mu = \nu$ .

D-o. Pokażemy, że  $\forall f \in C(\mathbb{R})$   $\left. \begin{array}{l} \int_{\mathbb{R}} f d\mu = \int_{\mathbb{R}} f d\nu \end{array} \right\} \Rightarrow \mu = \nu$

---

Narzędzie: tw. Weierstrassa: jeżeli  $f$  jest funkcją ciągłą i okresową na  $\mathbb{R}$

(o okr.  $T$ ,  $f(x+T) = f(x)$ ) to możemy  $f$

przybliżyć ciągiem wiel. tryg. o tym samym

okresie co  $f$ .



$$f_n(x) = \sum_{k=0}^n \left( a_k \sin \frac{2\pi kx}{T} + b_k \cos \frac{2\pi kx}{T} \right)$$

$$f_n \implies f$$

Wiemy:  $\varphi_\mu(t) = \varphi_\nu(t)$ , czyli

$$\int_{\mathbb{R}} e^{itx} d\mu(x) = \int_{\mathbb{R}} e^{itx} d\nu(x)$$

$$\sin tx = \frac{e^{itx} - e^{-itx}}{2i}$$

$$\int_{\mathbb{R}} \sin tx d\mu(x) = \int_{\mathbb{R}} \sin tx d\nu(x)$$

$$\int_{\mathbb{R}} \cos tx d\mu(x) = \int_{\mathbb{R}} \cos tx d\nu(x)$$

Zatem również

$$\int f_n(x) d\mu(x) = \int f_n(x) d\nu(x) \quad \text{dla każdego}$$

wiel. tryg.  $f_n$

Z tw. Weierstrassa mamy również


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

dla każdej  $f$  ciągłej i okresowej.

Niech  $f \in C(\mathbb{R})$ . Istnieje ciąg  $\{f_n\}$  funkcji ciągłych i okresowych.

$$1) f(x) = f_n(x) \text{ dla } x \in [-n, n]$$

$$2) \sup |f_n(x)| \leq \sup |f(x)|$$



$$\left| \int_{\mathbb{R}} f(x) d\mu(x) - \int_{\mathbb{R}} f(x) d\nu(x) \right| \leq \int_{\mathbb{R}} |f(x) - f_n(x)| d\mu(x) + \left| \int_{\mathbb{R}} f(x) d\mu(x) - \int_{\mathbb{R}} f_n(x) d\mu(x) \right| + \int_{\mathbb{R}} |f(x) - f_n(x)| d\nu(x)$$

$$\leq 2 \sup_{x \in \mathbb{R}} |f(x)| \left( \mu((-n, n)^c) + \nu((-n, n)^c) \right) \rightarrow 0$$

Przykład Jeżeli  $X_1, X_2$  są niezależne i mają rozkłady  $\mathcal{N}(m_1, \sigma_1^2), \mathcal{N}(m_2, \sigma_2^2)$ , to  $X_1 + X_2$  ma rozkład  $\mathcal{N}(m_1 + m_2, \sigma_1^2 + \sigma_2^2)$ .

Istotnie, możemy napisać  $X_j = m_j + \sigma_j Y_j$ , gdzie  $Y_j$  ma rozkład  $\mathcal{N}(0, 1)$ . Możemy

obliczyć  $\varphi_{X_j}$ :

$$\varphi_{X_j}(t) = \varphi_{m_j + \sigma_j Y_j}(t) = e^{im_j t} \varphi_{Y_j}(\sigma_j t) = e^{im_j t} e^{-\frac{\sigma_j^2 t^2}{2}}$$

zatem

$$\varphi_{X_1 + X_2}(t) = \varphi_{X_1}(t) \varphi_{X_2}(t) = e^{im_1 t} e^{-\frac{\sigma_1^2 t^2}{2}} \cdot e^{im_2 t} e^{-\frac{\sigma_2^2 t^2}{2}} = e^{i(m_1 + m_2)t} e^{-\frac{(\sigma_1^2 + \sigma_2^2)t^2}{2}}$$

Powyższa funkcja jest f. char.  $\mathcal{N}(m_1 + m_2, \sigma_1^2 + \sigma_2^2)$ .

Z tw. o jednoznaczności wynika więc, że

$X_1 + X_2$  ma taki rozkład.

## TW. 10.7 (Levy, Cramer)

Niech  $\mu_n$  będą rozkładami na  $\mathbb{R}$ . Wówczas

1. Jeżeli  $\mu_n \Rightarrow \mu$ , to dla każdego  $t$

$$\varphi_{\mu_n}(t) \rightarrow \varphi_{\mu}(t).$$

2. Jeżeli  $\varphi_{\mu_n}(t) \rightarrow \varphi(t)$  dla pewnej funkcji

$\varphi$  ciągłej w  $0$ , to  $\varphi$  jest funkcją

char. pewnego  $\mu$  t.je  $\mu_n \Rightarrow \mu$ .

D-o.

$$1. \varphi_{\mu_n}(t) = \int_{\mathbb{R}} \cos(tx) d\mu_n(x) + i \int_{\mathbb{R}} \sin(tx) d\mu_n(x)$$

$$\longrightarrow \int_{\mathbb{R}} \cos(tx) d\mu(x) + i \int_{\mathbb{R}} \sin(tx) d\mu(x) = \varphi_{\mu}(t)$$

2. Krok 1. Pokażemy, że jeżeli  $\varphi_{\mu_n} \rightarrow \varphi$  i

$\varphi$  jest ciągła w  $0$ , to rodzina miar  $\{\mu_n\}$

jest ciasna.

Ustalmy  $x \in \mathbb{R}$ ,  $\mu > 0$  i zauważmy

$$\int_{-\mu}^{\mu} (1 - e^{itx}) dt = 2\mu - \int_{-\mu}^{\mu} \cos(tx) dt = 2\mu - \frac{2\sin(\mu x)}{x}$$

Podzielmy obie strony przez  $n$  i scałkujemy

po  $x$  względem miary  $\mu_n$ . Wtedy

$$\frac{1}{n} \int_{-n}^n (1 - \varphi_n(t)) dt = 2 \int_{\mathbb{R}} \left(1 - \frac{\sin nx}{nx}\right) d\mu_n(x)$$

$$\geq 2 \int_{\{ |x| > \frac{2}{n} \}} \left(1 - \frac{1}{n|x|}\right) d\mu_n(x) \geq \mu_n(\{ |x| > \frac{2}{n} \}).$$

Wstajemy  $\varepsilon > 0$ . Z ciągłości  $\varphi(t)$  w  $0$  istnieje  
male  $n$  t. ie

$$\frac{1}{n} \int_{-n}^n (1 - \varphi(t)) dt < 2\varepsilon.$$

Ze zbieżności  $\varphi_n(t) \rightarrow \varphi(t)$  wynika, że

dla dużych  $n$

$$\frac{1}{n} \int_{-n}^n (1 - \varphi_n(t)) dt < 3\varepsilon.$$

Zatem  $\mu_n(\{ |x| > \frac{2}{n} \}) < 3\varepsilon$

a to implikuje cięsnosć  $\mu_n$ .

Krok 2. Chcemy pokazać, że istnieje  $\mu$   
t. że  $\mu_n \Rightarrow \mu$  oraz  $\varphi_\mu = \varphi$ . Z tw. Prochorowa

ciąg  $\{\mu_n\}$  zawiera podciąg  $\{\mu_{n_k}\}$  słabo  
zbieżny  $\mu_{n_k} \Rightarrow \mu$ . Ponieważ  $\mu_{n_k} \Rightarrow \mu$

to z pkt. 1  $\varphi_{n_k}(t) \rightarrow \varphi_\mu(t)$ , a zatem  
 $\varphi_\mu = \varphi$ .

Porostaje  $\mu_n \Rightarrow \mu$ . Zał. nie wprost, że

$\mu_n \not\Rightarrow \mu$ , tzn.  $\mu_n$  zawiera podciąg  $\{\mu_{m_k}\}$   
nie zbieżny do  $\mu$ . Ten podciąg  $\{\mu_{m_k}\}$

jest ciśny, z tw. Prochorowa zawiera

podciąg zbieżny  $\{\mu_{m'_k}\}$  do pewnej

miary  $\mu_0$ . Z pkt. 1  $\varphi_\mu(t) \leftarrow \varphi_{\mu_{m'_k}}(t) \rightarrow \varphi_{\mu_0}(t)$

Z tw. o jednoznaczności  $\mu = \mu_0$ .

## TW. M.1 (Centralne twierdzenie graniczne)

Niech  $(X_n)_{n=1}^{\infty}$  będzie ciągiem niezależnych zmiennych losowych o takim samym rozkładzie i takim, że  $\mathbb{E}X_1 = m$ ,  $\text{Var} X_1 = \sigma^2$ . Wówczas

$$\frac{X_1 + \dots + X_n - nm}{\sqrt{n} \sigma} \xrightarrow{d} \mathcal{N}(0, 1)$$

D-d. Dla uproszczonej notacji  $Y_j = X_j - m$ .

Wtedy  $\mathbb{E}Y_j = 0$ ,  $\text{Var} Y_j = \sigma^2$ . Zmienna losowa

$Y = Y_1$  ma pierwszy i drugi moment,

zatem funkcja  $\varphi_Y$  jest dwukrotnie różniczkowalna w 0.

$$\varphi_Y(0) = 1$$

$$\varphi_Y'(0) = 0$$

$$\varphi_Y''(0) = -\mathbb{E}Y^2 = -\text{Var} Y = -\sigma^2$$

Zatem z tw. 10.4 w otoczeniu 0

$$\varphi_Y(t) = \varphi_Y(0) + \varphi_Y'(0)ot + \varphi_Y'' \cdot \frac{t^2}{2} + o(t^2) = 1 - \frac{t^2 \sigma^2}{2} + h(t)$$

gdzie  $\frac{h(t)}{t^2} \xrightarrow{t \rightarrow 0} 0$ . Funkcja  $h$  może być zespolona. Poniżej przydatną będzie następująca obserwacja: jeżeli  $\{c_n\}$  jest ciągiem lubz zespolonych t. ie  $c_n \rightarrow c \in \mathbb{C}$ , to

$$\lim_{n \rightarrow \infty} \left(1 + \frac{c_n}{n}\right)^n = e^c.$$

Notujemy t. Mamy

$$\begin{aligned} \varphi_{\frac{X_1 + \dots + X_n - nm}{\sqrt{n}\sigma}}(t) &= \varphi_{\frac{Y_1 + \dots + Y_n}{\sqrt{n}\sigma}}(t) = \left(\varphi_{\frac{Y_1}{\sigma}}(t)\right)^n \\ &= \left(\varphi_Y\left(\frac{t}{\sqrt{n}\sigma}\right)\right)^n = \left(1 - \frac{\sigma^2}{2} \cdot \left(\frac{t}{\sqrt{n}\sigma}\right)^2 + h\left(\frac{t}{\sqrt{n}\sigma}\right)\right)^n \\ &= \left(1 - \frac{t^2}{2n^2} + h\left(\frac{t}{\sqrt{n}\sigma}\right)\right)^n \end{aligned}$$

Wzimy  $c_n = n\left(-\frac{t^2}{2n^2} + h\left(\frac{t}{\sqrt{n}\sigma}\right)\right)$ .

Wówczas  $c_n \rightarrow -\frac{t^2}{2}$ , a więc

$$\varphi_{\frac{X_1 + \dots + X_n - nm}{\sqrt{n}\sigma}}(t) \xrightarrow{n \rightarrow \infty} e^{-\frac{t^2}{2}}.$$

Funkcja  $e^{-\frac{t^2}{2}}$  jest funkcją charakterystyczną



zm. los. o rozkładzie  $N(0,1)$ . Z tw.

Lévy'ego - Craméra wnioskujemy tezę.



16.06.2021

Zadanie Na podstawie losowej próby szacujemy procent dorosłych, którzy potrafia pisać i czytać. Wiadomo na pewno, że jest to powyżej 90% dorosłej populacji. Chcemy, aby błąd był mniejszy niż 0.01 z prawdopodobieństwem 0.9. Ile osób musi liczyć próba?

CTG:  $\{X_n\}$  i.i.d.,  $\mathbb{E}X_n < \infty$ ,  $\text{Var} X_n < \infty$ .

$$\frac{X_1 + \dots + X_n - nm}{\sqrt{n} \sigma} = \frac{S_n - \mathbb{E}S_n}{\sqrt{\text{Var} S_n}} \xrightarrow{d} \mathcal{N}(0, 1)$$

Rozwiązanie zadania

Chcemy znaleźć  $p \approx \frac{\text{osoby, które potrafią pisać}}{\text{wielkość próbki}}$   
 $n$ -l. testowanych osób

$X_i = \begin{cases} 1 & \text{i-te osoba czyta} \\ 0 & \text{w p.w.} \end{cases}$

$S_n = X_1 + \dots + X_n$  - l. osób, każde czytają

$$P \approx \frac{S_n}{n}, P\left[\left|\frac{S_n}{n} - p\right| \leq 0,01\right] \geq \frac{9}{10}$$

$S_n$  ma rozkład  $\text{Bin}(n, p)$

$EX_1 = p, \text{Var} X_1 = p(1-p)$ . Chcemy

skorzystać z CTG.

$$P\left[\left|\frac{S_n - np}{\sqrt{np(1-p)}}\right| \leq \frac{0,01\sqrt{n}}{\sqrt{p(1-p)}}\right] \geq \frac{9}{10}$$

Z CTG  $\sim \mathcal{N}(0,1)$

tu się też generuje pewien błąd

Szukamy  $x_0$  t.że

$$\frac{9}{10} \leq P\left[|\varphi| \leq x_0\right] = \int_{-x_0}^{x_0} \varphi(x) dx = \Phi(x_0) - \Phi(-x_0)$$

$\varphi \sim \mathcal{N}(0,1)$

$$= \Phi(x_0) - 1 + \Phi(x_0) = 2\Phi(x_0) - 1$$

Gdyż  $\Phi(x_0) \geq 0,95 \Rightarrow x_0 \geq 1,65$

$$\text{Zatem } \frac{\sqrt{n}}{100\sqrt{p(1-p)}} \geq 1.65$$

$$\sqrt{n} \geq 165\sqrt{p(1-p)}$$

Wiemy, że  $p \geq 0.9$ . Wtedy  $p(1-p) \leq 0.09$ .

$$\text{Czyli } \sqrt{n} \geq 0.3 \cdot 165 = 49.5$$

$$\text{Zatem } n \geq 49.5^2 = 2450.25$$

$$\text{Czyli } n \geq 2451.$$

### Tw. 11.2 (Berry-Essen)

Jeżeli  $\{X_n\}$  i.i.d.,  $\mathbb{E}X_1^3$ ,  $\mathbb{E}X_1 = 0$ ,

$\sigma^2 = \text{Var } X_1$ , to

$$\sup_{t \in \mathbb{R}} \left| \mathbb{P} \left[ \frac{X_1 + \dots + X_n}{\sqrt{n}\sigma} < t \right] - \Phi(t) \right| \leq \frac{C \cdot \mathbb{E}|X_1|^3}{\sigma^3 \sqrt{n}}$$

gdzie  $\Phi(t)$  jest dystrybucją rozkładu

normalnego  $\mathcal{N}(0,1)$ , a  $C$  jest

ustaloną stałą (niezależną od rozkładu  $X_1$ )

Przykład Niech  $U_n$  będzie ciągiem Bernoulliego,  
 tj.  $P[U_n = \pm 1] = 1/2$ . Wówczas dla powyższych  
 wartości  $n$ :

$$\left| P\left[\frac{U_1 + \dots + U_n}{\sqrt{n \operatorname{Var} U_n}} < 0\right] - \Phi(0) \right| = \left| P[U_1 + \dots + U_n < 0] - \frac{1}{2} \right|$$

$$= \left| \frac{1}{2} P[U_1 + \dots + U_n < 0] + \frac{1}{2} P[U_1 + \dots + U_n > 0] - \frac{1}{2} \right|$$

$$= \left| \frac{1}{2} (1 - P[U_1 + \dots + U_n = 0]) - \frac{1}{2} \right|$$

$$= \frac{1}{2} P[U_1 + \dots + U_n = 0]$$

$$= \frac{1}{2} \cdot \frac{\binom{n}{n/2}}{2^n} \stackrel{\text{stirling}}{\sim} \frac{1}{2} \frac{1}{\sqrt{\pi n/2}} = \frac{1}{\sqrt{2\pi} \cdot \sqrt{n}}$$

### Tw. M.3 (Lindeberg - Feller)

Niech  $\{X_{n,k}\}$  będzie schematem serii

spatniejącym:

- $E X_{n,k} = 0$  dla  $n \geq 1, k \leq n$

- $\lim_{n \rightarrow \infty} s_n^2 = \sigma^2 > 0$ , gdzie  $s_n^2 := \operatorname{Var} \sum_{k=1}^n X_{n,k} = \sum \operatorname{Var} X_{n,k}$

• (warunek Lindeberga) dla każdego  $\epsilon > 0$

$$\lim_{n \rightarrow \infty} \sum_{k=1}^n \mathbb{E} \left[ X_{n,k}^2 \mathbb{1}_{\{|X_{n,k}| > \epsilon\}} \right] = 0$$

Wówczas  $\sum_{k=1}^n X_{n,k} \xrightarrow{d} \mathcal{N}(0, \sigma^2)$

Przykład liczba cykli w losowej permutacji:

$$\begin{pmatrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 \\ 3 & 9 & 6 & 8 & 2 & 1 & 5 & 4 & 7 \end{pmatrix} = (136)(2975)(48)$$

Problem: losujemy permutację  $\pi_n \in S_n$ .

$C_n$  - l. cykli tej permutacji.

Cel:  $\frac{C_n - \log n}{\sqrt{\log n}} \xrightarrow{d} \mathcal{N}(0, 1)$

Definiujemy  $Z_{n,k} = \begin{cases} 1 & \text{jeżeli po } k\text{-tej} \\ & \text{liczbie w rozk.} \\ & \text{na cykle pojawił się ")}" \\ 0 & \text{w p.w.} \end{cases}$

Zauważmy, że  $C_n = \sum_{k=1}^n Z_{n,k}$

hmat: dla ustalonego  $n$   $Z_{n,k}$  są n.z.l.

$$\text{oraz } \mathbb{P}[Z_{n,k} = 1] = \frac{1}{n-k+1}.$$

Sprawdźmy warunki Lindeberga.

Zdef.  $Y_{n,k} = Z_{n, n-k+1}$ . Znowu  $Y_{n,k}$  są n.z.l.

$$\text{oraz } \mathbb{P}[Y_{n,k} = 1] = \frac{1}{k}.$$

$$\mathbb{E} Y_{n,k} = \frac{1}{k}, \quad \text{Var } Y_{n,k} = \frac{1}{k} - \frac{1}{k^2}$$

$$\mathbb{E} C_n = \sum_{k=1}^n \mathbb{E} Y_{n,k} = \sum_{k=1}^n \frac{1}{k} \sim \log n$$

$$\text{Var } C_n \sim \log n$$

Niech  $X_{n,k} = \frac{Y_{n,k} - \frac{1}{k}}{\sqrt{\log n}}$ .  $\{X_{n,k}\}$  - schemat serii.

$$1) \mathbb{E} X_{n,k} = 0$$

$$2) S_n^2 = \sum_{k=1}^n \text{Var } X_{n,k} = \sum_{k=1}^n \text{Var} \left( \frac{Y_{n,k}}{\sqrt{\log n}} \right) = \frac{1}{\log n} \sum_{k=1}^n \left( \frac{1}{k} - \frac{1}{k^2} \right)$$

$$\longrightarrow 1 = \sigma^2$$

$$3) \sum_{k=1}^n \mathbb{E} \left[ X_{n,k}^2 \mathbb{1}_{\{|X_{n,k}| > r\}} \right]$$

$$= \sum \mathbb{E} \left[ X_{n,k}^2 \mathbb{1}_{\left\{ \frac{Y_{n,k} - \frac{1}{k}}{\sqrt{\log n}} > r \right\}} \right] \xrightarrow{n \rightarrow \infty} 0$$

$\frac{2}{\sqrt{\log n}} > r$   
 $\rightarrow 0$  dla dużych  $n$   
 ten zbiór pusty

$\mathcal{L}$  CTG L-F  $\sum_{k=1}^n X_{n,k} \xrightarrow{d} \mathcal{N}(0, 1)$

Czyli

$$\frac{C_n - \log n}{\sqrt{\log n}} + \frac{\log n - \sum \frac{1}{k}}{\sqrt{\log n}} = \frac{\sum Y_{n,k} - \sum \frac{1}{k}}{\sqrt{\log n}}$$

$\downarrow^d \mathcal{N}(0, 1)$

$\downarrow 0$

$\xrightarrow{d} \mathcal{N}(0, 1)$

KONIEC