

---

# Notatki z Rachunku Prawdopodobieństwa

2024-10-08 – 2025-01-21

## Spis treści

<b>Przedmowa</b>	<b>8</b>
<b>1 Trochę kombinatoryki</b>	<b>9</b>
1.1 Wariacja z powtórzeniami (funkcja)	9
1.2 Wariacja bez powtórzeń (funkcja różnowartościowa)	9
1.3 Permutacja bez powtórzeń (bijekcja, permutacja)	9
1.4 Kombinacje bez powtórzeń (podzbiór)	10
1.5 Kombinacja z powtórzeniami (krata)	10
1.6 Permutacje z powtórzeniami (podział zbioru)	10
1.7 Oznaczenia	10
<b>2 Wstęp do rachunku prawdopodobieństwa</b>	<b>11</b>
2.1 Zdarzenie elementarne	11
2.2 Przykłady zdarzeń elementarnych	11
2.3 Sigma-ciało zdarzeń losowych	12
2.4 Zbiory borelowskie	12
2.4.1 Zbiory borelowskie na prostej	13
2.5 Definicja prawdopodobieństwa (Kolmogorow, 1933)	13
2.6 Przestrzeń probabilistyczna	13
<b>3 Podstawowe pojęcia probabilistyczne</b>	<b>14</b>
<b>4 Różne miary probabilistyczne</b>	<b>20</b>
4.1 Przeliczalny zbiór zdarzeń elementarnych	20
4.1.1 Uwagi	21
4.2 Prawdopodobieństwo geometryczne	22
<b>5 Prawdopodobieństwo warunkowe</b>	<b>23</b>
5.1 Definicja	24
5.2 Rozbicie przestrzeni $\Omega$	26
5.3 Prawdopodobieństwo całkowite	26
5.3.1 Prawdopodobieństwo całkowite dla przeliczalnego rozbicia	27
5.4 Wzór Bayesa	28
<b>6 Niezależność zdarzeń</b>	<b>28</b>
6.1 Zdarzenia niezależne	28
6.2 Zdarzenie niezależne - definicja	29
6.3 Niezależność trzech zdarzeń	30

---

6.4	Niezależność $n$ zdarzeń . . . . .	30
6.5	Niezależność $\sigma$ -ciał . . . . .	32
6.6	Prawdopodobieństwo sumy niezależnych zdarzeń . . . . .	33
6.7	Nieskończony ciąg niezależnych zdarzeń . . . . .	33
<b>7</b>	<b>Schematy</b> . . . . .	<b>33</b>
7.1	Schemat ogólny . . . . .	33
7.2	Schemat Bernoulliego . . . . .	34
7.3	Granica górna ciągu zdarzeń . . . . .	34
7.4	Granica dolna ciągu zdarzeń . . . . .	34
7.4.1	Własności . . . . .	35
7.5	Lemat Borela-Cantellego . . . . .	35
<b>8</b>	<b>Zmienne losowe</b> . . . . .	<b>36</b>
8.1	Zmienna losowa - uwagi . . . . .	36
8.2	Zbiory borelowskie . . . . .	36
8.2.1	Przykłady zbiorów borelowskich . . . . .	36
8.2.2	Uwagi . . . . .	38
8.3	$\sigma$ -ciało generowane przez zmienną losową . . . . .	38
<b>9</b>	<b>Rozkład prawdopodobieństwa</b> . . . . .	<b>39</b>
9.1	Rozkład ciągły . . . . .	39
9.2	Rozkład dyskretny . . . . .	40
9.3	Dystrybuanta . . . . .	40
9.3.1	Dystrybuanta na $\mathbb{R}$ . . . . .	41
9.3.2	Własności dystrybuanty na $\mathbb{R}^n$ . . . . .	41
9.3.3	Rozkład zmiennej losowej $Y = \varphi(X)$ . . . . .	42
9.4	Wartość oczekiwana . . . . .	43
9.4.1	Przypadek dyskretny . . . . .	43
9.5	Wartość oczekiwana uogólniona . . . . .	43
9.6	Przypadek ciągły . . . . .	44
9.6.1	Wartość oczekiwana wektora losowego . . . . .	44
9.7	Własności wartości oczekiwanej . . . . .	44
9.8	Wariancja . . . . .	46
9.8.1	Własności wariancji . . . . .	47
9.8.2	Odchylenie standardowe . . . . .	48
9.8.3	Wyznaczanie wariancji i odchylenia standardowego . . . . .	48
9.9	Momenty zwykłe i absolutne . . . . .	49

---

---

9.10	Momenty centralne . . . . .	49
9.10.1	Interpretacja fizyczna . . . . .	49
9.11	Skośność i koncentracja rozkładu . . . . .	49
9.12	Mediana zmiennej losowej . . . . .	50
9.13	Moda zmiennej losowej . . . . .	50
<b>10</b>	<b>Przegląd wybranych dyskretnych rozkładów prawdopodobieństwa</b>	<b>51</b>
10.1	Rozkład jednopunktowy . . . . .	51
10.1.1	Wartość oczekiwana . . . . .	51
10.2	Rozkład dwupunktowy . . . . .	51
10.2.1	Rozkład zero-jedynkowy . . . . .	51
10.3	Rozkład dwumianowy . . . . .	52
10.3.1	Jak rozpoznać rozkład dwumianowy . . . . .	52
10.3.2	wartość oczekiwana . . . . .	53
10.3.3	Wariancja . . . . .	53
10.4	Rozkład Poissona . . . . .	54
10.4.1	Wartość oczekiwana . . . . .	54
10.4.2	Wariancja . . . . .	55
10.5	Związek rozkładu Bernoulliego i rozkładu Poissona . . . . .	55
10.6	Rozkład geometryczny . . . . .	56
10.6.1	Wartość oczekiwana . . . . .	56
10.6.2	Wariancja . . . . .	57
10.7	Rozkład ujemnie dwumianowy . . . . .	58
10.7.1	parametry . . . . .	58
10.8	Rozkład hipergeometryczny . . . . .	59
10.8.1	Interpretacja . . . . .	59
10.8.2	Parametry . . . . .	59
10.9	Tabela rozkładów dyskretnych i ich parametrów . . . . .	60
<b>11</b>	<b>Rozkłady ciągłe</b>	<b>61</b>
11.1	Rozkład jednostajny . . . . .	61
11.1.1	Dystrybuanta . . . . .	61
11.1.2	Wartość oczekiwana . . . . .	63
11.1.3	Drugi moment zwykły . . . . .	63
11.1.4	Wariancja . . . . .	63
11.1.5	Mediana . . . . .	63
11.1.6	Dominanta . . . . .	63

---

11.2	Rozkład wykładniczy . . . . .	63
11.2.1	Dystrybuanta . . . . .	64
11.2.2	Wartość oczekiwana . . . . .	65
11.2.3	Drugi moment zwykły . . . . .	65
11.2.4	Wariancja . . . . .	66
11.2.5	Zastosowania . . . . .	66
11.3	Rozkład gamma . . . . .	66
11.3.1	Dystrybuanta . . . . .	67
11.3.2	Wartość oczekiwana . . . . .	67
11.3.3	Drugi moment zwykły . . . . .	67
11.3.4	Wariancja . . . . .	68
11.4	Rozkład Cauchy'ego . . . . .	68
11.5	Rozkład normalny . . . . .	69
11.5.1	Uwagi . . . . .	69
11.5.2	Wartość oczekiwana . . . . .	70
11.5.3	Wariancja . . . . .	70
11.6	Rozkład normalny $N(0, 1)$ . . . . .	70
11.6.1	Standaryzacja rozkładu normalnego . . . . .	72
11.6.2	Zastosowania . . . . .	72
11.7	Tabela parametrów rozkładów ciągłych . . . . .	73
<b>12</b>	<b>Rozkłady dwuwymiarowe i wielowymiarowe</b>	<b>73</b>
12.1	Dwuwymiarowa zmienna losowa (przypomnienie) . . . . .	73
12.2	Moment zwykły mieszany . . . . .	74
12.2.1	Rozkład skokowy . . . . .	74
12.2.2	Rozkład ciągły . . . . .	74
12.3	Moment centralny mieszany rzędu $r + s$ . . . . .	74
12.3.1	Moment centralny mieszany dla rozkładu skokowego . . . . .	75
12.4	Moment centralny mieszany dla rozkładu ciągłego . . . . .	75
12.5	Kowariancja . . . . .	75
12.5.1	Własności . . . . .	75
12.5.2	Nierówność Höldera . . . . .	76
12.5.3	Uwagi i interpretacja . . . . .	77
12.6	Korelacja . . . . .	77
12.6.1	Własności . . . . .	78
12.7	Regresja . . . . .	78
12.7.1	Regresja II rodzaju $Y$ względem $X$ . . . . .	79
12.7.2	Regresja II rodzaju $X$ względem $Y$ . . . . .	79

---

12.8	Wariancja sumy zmiennych losowych . . . . .	80
12.8.1	Wniosek . . . . .	80
12.9	Macierz kowariancji . . . . .	80
12.10	Rozkład wielomianowy . . . . .	81
12.11	Rozkład normalny . . . . .	81
<b>13</b>	<b>Niezależne zmienne losowe</b>	<b>82</b>
13.1	Uwagi . . . . .	82
13.2	Własności . . . . .	83
13.3	Zmienne losowe o rozkładzie dyskretnym . . . . .	84
13.4	Zmienne losowe o rozkładzie ciągłym . . . . .	85
13.4.1	Własności . . . . .	86
13.5	Rozkład sumy niezależnych zmiennych losowych . . . . .	87
13.5.1	Rozkład sumy niezależnych zmiennych losowych o rozkładach ciągłych . . . . .	87
<b>14</b>	<b>Funkcja charakterystyczna</b>	<b>88</b>
14.1	Rozkład dyskretny . . . . .	89
14.2	Rozkład ciągły . . . . .	89
14.3	Własności funkcji charakterystycznej . . . . .	91
14.4	Własności funkcji charakterystycznej . . . . .	92
<b>15</b>	<b>Rozkład ciągły</b>	<b>92</b>
15.1	Związek gęstości zmiennej $X$ i zmiennej $g(X)$ . . . . .	92
<b>16</b>	<b>Nierówności związane z momentami.</b>	<b>95</b>
16.1	Nierówność Schwarz'a . . . . .	95
16.2	Nierówność Jensena . . . . .	96
16.3	Nierówność Höldera . . . . .	97
16.4	Nierówność Czebyszewa . . . . .	99
16.5	Nierówność Markowa . . . . .	99
16.6	Nierówność Czebyszewa-Bienaymé . . . . .	100
16.7	Nierówność Czebyszewa – wykładnicza . . . . .	100
<b>17</b>	<b>Rodzaje zbieżności zmiennych losowych</b>	<b>101</b>
17.1	Zbieżność «prawie na pewno» – własności . . . . .	101
17.2	Charakteryzacja zbieżności «prawie na pewno» . . . . .	102
17.2.1	Wniosek . . . . .	103
17.3	Zbieżność «prawie na pewno» i zbieżność w/g prawdopodobieństwa . . . . .	103
17.4	Zbieżność w/g $p$ -tego momentu i zbieżność w/g prawdopodobieństwa . . . . .	104

---

---

17.5 Twierdzenie Riesza . . . . .	105
<b>18 Twierdzenia graniczne</b>	<b>105</b>
18.1 Prawo wielkich liczb Bernoulliego . . . . .	105
18.1.1 Interpretacja . . . . .	106
18.2 Mocne prawo wielkich liczb Bernoulliego . . . . .	106
18.3 Prawo wielkich liczb . . . . .	107
18.4 Słabe prawo wielkich liczb Markowa . . . . .	108
18.5 Słabe prawo wielkich liczb Czebyszewa . . . . .	108
18.6 Twierdzenie Kołmogorowa, mocne prawo wielkich liczb Kołmogorowa . . . . .	109
18.7 Mocne prawo wielkich liczb Kołmogorowa . . . . .	109
<b>19 Lokalne twierdzenia graniczne</b>	<b>110</b>
19.1 Twierdzenie Poissona . . . . .	110
19.2 Twierdzenie Moivre'a-Laplace'a . . . . .	111
19.2.1 Wzory praktyczne . . . . .	111
19.3 Centralne Twierdzenie Graniczne Lindeberga-Lévy'ego – integralne . . . . .	111
19.4 Twierdzenie Moivre'a-Laplace'a – integralne . . . . .	114
<b>20 Warunkowa wartość oczekiwana</b>	<b>115</b>
20.1 Warunkowa wartość oczekiwana względem zdarzenia $A$ . . . . .	115
20.2 Warunkowa wartość oczekiwana względem $\sigma$ -ciała . . . . .	115
20.2.1 Własność 1 . . . . .	117
20.2.2 Własność 2 . . . . .	117
20.2.3 Własność 3 . . . . .	118
20.2.4 Własność 4 . . . . .	118
20.2.5 Własność 5 . . . . .	120
20.2.6 Własność 6 . . . . .	121
20.2.7 Własność 7 . . . . .	121
20.2.8 Własność 8 . . . . .	122
20.2.9 Własność 9 . . . . .	122
20.2.10 Własność 10 . . . . .	123
<b>21 Moment zatrzymania</b>	<b>124</b>
21.1 Filtracja . . . . .	124
21.2 Interpretacja i przykład . . . . .	124
21.3 Rodzina zmiennych losowych adaptowana do filtracji . . . . .	124
21.4 Moment stopu . . . . .	124

---

---

<b>22 Martyngały, nadmartyngały i podmartyngały</b>	<b>126</b>
22.1 Interpretacja . . . . .	126
22.2 Własności . . . . .	127
22.3 Ciąg prognozowalny . . . . .	127
22.4 Transformata martyngałowa . . . . .	127
22.4.1 Interpretacja . . . . .	128
22.5 Jak wygrać milion dolarów . . . . .	128
22.5.1 Strategia . . . . .	128
22.5.2 Analiza gry – Czy na pewno wygramy? . . . . .	129
22.5.3 Kiedy wygramy? . . . . .	130
22.5.4 Ile wygramy? . . . . .	130
22.5.5 Wnioski . . . . .	131

## Przedmowa

To są notatki z przedmiotu rachunek prawdopodobieństwa prowadzonego na kierunku IAD w 2024/2025 roku przez dr hab. Annę Kuczmaszewską, prof. PL. Treści obejmują 14 wykładów i dodatkowo zawierają twierdzenie z ćwiczeń w prostszej formie niż było na wykładzie.

Niektóre dowody, które istnieją w wykładach Pani Profesor nie zostały zanotowane ponieważ były pomijane na wykładach. W wykładach również zdarzały się niedoprecyzowania lub błędy i jeśli były zauważone, były poprawione, jednak to nie oznacza że treści notatek są bezbłędne (w tym gramatycznie).

Notatki znajdują się w **domenie publicznej** na warunkach licencji CC0 1.0 Universal<sup>1</sup>

---

<sup>1</sup><https://creativecommons.org/publicdomain/zero/1.0/deed.pl>

2024-10-08

## 1 Trochę kombinatoryki

### 1.1 Wariacja z powtórzeniami (funkcja)

Równoważne definicje:

**$k$ -elementową wariacją z powtórzeniami zbioru  $Y$**  nazywamy każdą funkcję  $f : \{1, 2, \dots, k\} \rightarrow Y$

**$k$ -elementową wariacją z powtórzeniami zbioru  $Y$**  (złożonego z  $n$  różnych elementów) nazywamy każde uporządkowanie zbioru złożonego z  $k$  elementów wybranych ze zbioru  $Y$ , przy czym wybrane elementy mogą się powtarzać.

**$k$ -elementową wariacją z powtórzeniami zbioru  $Y$**  (złożonego z  $n$  różnych elementów) nazywamy każdy wynik  $k$ -krotnego losowania ze zwracaniem ze zbioru  $Y$  uwzględniający kolejność wylosowanych elementów

### 1.2 Wariacja bez powtórzeń (funkcja różnowartościowa)

Równoważne definicje:

**$k$ -elementową wariacją bez powtórzeń zbioru  $Y$**  nazywamy każdą różnowartościową funkcję  $f : \{1, 2, 3, \dots, k\} \rightarrow Y$

**$k$ -elementową wariacją bez powtórzeń zbioru  $Y$**  (złożonego z  $n$ -różnych elementów) nazywamy każde uporządkowanie  $k$ -elementowego podzbioru zbioru  $Y$

**$k$ -elementową wariacją bez powtórzeń zbioru  $Y$**  (złożonego z  $n$  różnych elementów) nazywamy każdy wynik  $k$ -krotnego losowania bez zwracania ze zbioru  $Y$  uwzględniający kolejność wylosowanych elementów

### 1.3 Permutacja bez powtórzeń (bijekcja, permutacja)

Równoważne definicje:

**Permutacją  $n$ -elementowego zbioru** nazywamy każdą funkcję  $f$  odwzorowującą zbiór  $Y = \{y_1, y_2, \dots, y_n\}$  na zbiór  $Y$

$$f : \{y_1, y_2, \dots, y_n\} \xrightarrow{\text{na}} Y$$

**Permutacją  $n$ -elementowego zbioru  $Y$**  nazywamy każde uporządkowanie zbioru  $Y = \{y_1, y_2, \dots, y_n\}$

## 1.4 Kombinacje bez powtórzeń (podzbiór)

$k$ -elementową kombinacją bez powtórzeń zbioru  $Y$  (złożonego z  $n$ -różnych elementów) nazywamy każdy  $k$ -elementowy podzbiór zbioru  $Y$

### Achtung! 1

W przypadku kombinacji, w przeciwieństwie do wariacji i permutacji, nie jest istotna kolejność elementów, ważne są tylko elementy w zbiorze

## 1.5 Kombinacja z powtórzeniami (krata)

$k$ -elementową kombinacją z powtórzeniami z  $n$  nazywamy każde rozmieszczenie  $n$  nierozróżnialnych kul w  $k$  komórkach

## 1.6 Permutacje z powtórzeniami (podział zbioru)

$n$ -elementową permutacją z powtórzeniami nazywamy każde uporządkowanie zbioru  $n$ -elementowego, gdzie  $k$  różnych elementów powtarza się odpowiednio  $r_1, r_2, \dots, r_k$  razy

## 1.7 Oznaczenia

$\overline{V}_n^k$  liczba  $k$ -elementowych wariacji z powtórzeniami ze zbioru  $n$  różnych elementów

$V_n^k$  liczba  $k$ -elementowych wariacji bez powtórzeń ze zbioru  $n$  różnych elementów

$P_n$  liczba  $n$ -elementowych permutacji

$C_n^k$  liczba  $k$ -elementowych kombinacji ze zbioru  $n$  różnych elementów

$\overline{C}_n^k$  liczba  $k$ -elementowych kombinacji z powtórzeniami z  $n$

$\overline{P}_n(r_1, r_2, \dots, r_k)$  liczba podziałów zbioru  $n$ -elementowego na zbiory o liczebnościach  $r_1, r_2, \dots, r_k$

### Twierdzenie 1.1

1.  $\overline{V}_n^k = n^k$
2.  $V_n^k = \frac{n!}{(n-k)!}$
3.  $P_n = n!$
4.  $C_n^k = \binom{n}{k}$
5.  $\overline{C}_n^k = \binom{n+k-1}{k}$
6.  $\overline{P}_n(r_1, r_2, \dots, r_k) = \frac{n!}{r_1! r_2! \dots r_k!}$

**Twierdzenie 1.2**

Każdy ciąg  $k$ -elementowy można otrzymać wybierając  $k$ -elementowy podzbiór i ustawiając jego elementy w ciąg (permutując je mamy zatem)  $V_n^k = C_n^k \cdot P_n$

## 2 Wstęp do rachunku prawdopodobieństwa

### 2.1 Zdarzenie elementarne

Zdarzenie elementarne jest pojęciem, którego nie definiujemy. Uważamy je za pojęcie pierwotne.

**Przestrzeń zdarzeń elementarnych** Zbiór wszystkich zdarzeń elementarnych nazywamy przestrzenią zdarzeń elementarnych i oznaczamy symbolem  $\Omega$ .

### 2.2 Przykłady zdarzeń elementarnych

**Przykład 2.1**

Rzucamy monetą. Zdarzenia elementarne: wypadnięcie orła, wypadnięcie reszki.  
Zbiór zdarzeń elementarnych  $\Omega$  to  $\Omega = \{O, R\}$

**Przykład 2.2**

Rzucamy kostką do gry:  $\Omega = \{1, 2, 3, 4, 5, 6\}$

**Przykład 2.3**

Mamy odcinek  $OA$  o długości  $l$  na osi  $OX$ . Wybieramy punkt  $P$  o współrzędnej  $x$ .  
Zdarzeniem elementarnym jest «wylosowanie dowolnego punktu na odcinku  $OA$ ».  
Zbiór zdarzeń elementarnych  $\Omega$  składa się ze wszystkich punktów na odcinku  $OA$

$$\Omega = \{x \in \mathbb{R} : 0 \leq x \leq l\}$$

**Zdarzenie elementarne** Zdarzenia elementarne możemy traktować jako najprostsze nierozkładalne, elementarne wyniki doświadczenia losowego, charakteryzujące się tym, że każde powtórzenie tego doświadczenia kończy się jednym i tylko jednym z nich.

**Jednak nie jest to definicja.**

**Zdarzenie pewne** Zdarzeniem pewnym nazywamy całą przestrzeń zdarzeń elementarnych  $\Omega$

**Zdarzenie niemożliwe** Zdarzeniem niemożliwym nazywamy podzbiór pusty  $\emptyset$  przestrzeni  $\Omega$

**Zdarzenie przeciwne** Zdarzeniem przeciwnym do zdarzenia  $A$  nazywamy zdarzenie  $C$  składające się z tych zdarzeń elementarnych, które nie należą do zdarzenia  $A$ . Zdarzenie przeciwne do zdarzenia  $A$  oznaczamy symbolem

$$A' = \{\omega : (\omega \notin A)\}$$

### 2.3 Sigma-ciąto zdarzeń losowych

Rodziny  $\mathcal{F}$  podzbiorów zbioru  $\Omega$  spełniającą następujące warunki:

1.  $\Omega \in \mathcal{F}$

do rodziny  $\mathcal{F}$  należy zdarzenie pewne

2.  $\bigcap_{A \in \mathcal{F}} A' \in \mathcal{F}$

jeżeli zdarzenie  $A$  należy do rodziny  $\mathcal{F}$ , to zdarzenie przeciwne  $A'$  też należy do  $\mathcal{F}$

3.  $\bigcap_{A_1, A_2, \dots \in \mathcal{F}} \bigcup_{i=1}^{\infty} A_i \in \mathcal{F}$

jeżeli zdarzenia  $A_1, A_2, \dots$  należą do rodziny  $\mathcal{F}$ , to ich suma również należy do rodziny  $\mathcal{F}$

nazywamy  **$\sigma$ -ciątem zdarzeń losowych** (używa się również pojęcia borelowskie  $\sigma$ -ciąt zdarzeń lub niekiedy  $\sigma$ -algebra), a elementy tej rodziny nazywamy zdarzeniami losowymi

#### Achtung! 2

- Jeżeli przestrzeń zdarzeń elementarnych  $\Omega$  jest co najwyżej przeliczalna, to jako klasę  $\mathcal{F}$  (zbiór wszystkich zdarzeń losowych) przyjmuje się klasę wszystkich podzbiorów zbioru  $\Omega$
- Jeżeli  $\Omega$  jest przestrzenią zdarzeń elementarnych położoną w przestrzeni euklidesowej  $\mathbb{R}^n$ , to jako klasę  $\mathcal{F}$  zdarzeń losowych przyjmujemy klasę podzbiorów borelowskich przestrzeni  $\Omega$

### 2.4 Zbiory borelowskie

Klasę zbiorów borelowskich na przestrzeni topologicznej definiujemy jako klasę wszystkich zbiorów które można otrzymać ze zbiorów otwartych (tę samą klasę otrzymamy z przedziałów domkniętych) za pomocą skończonej lub przeliczalnej liczby działań teriomnogościowych (dodawanie, mnożenie, uzupełnianie zbiorów).

### 2.4.1 Zbiory borelowskie na prostej

W szczególności zbiorami borelowskimi na prostej są wszystkie przedziały postaci:

1.  $(a, b), \langle a, b \rangle, (a, b], \langle a, b)$
2.  $(-\infty, b), (-\infty, b], (a, +\infty), \langle a, +\infty)$
3. wszystkie zbiory jednopunktowe, przeliczalne, otwarte, domknięte
4. cała prosta  $(-\infty, \infty)$ , zbiór pusty

### 2.5 Definicja prawdopodobieństwa (Kolmogorow, 1933)

Niech

- $\Omega$  będzie zbiorem zdarzeń elementarnych
- $\mathcal{F}$  –  $\sigma$ -ciałem zdarzeń losowych

Prawdopodobieństwem  $P$  nazywamy funkcję określoną na  $\sigma$ -ciele  $\mathcal{F}$  przyjmującą wartości rzeczywiste

$$P : \mathcal{F} \rightarrow \mathbb{R}$$

i spełniającą następujące aksjomaty:

1. Dla każdego zdarzenia losowego  $A \in \mathcal{F}$  prawdopodobieństwo  $P(A)$  jest liczbą z przedziału  $\langle 0, 1 \rangle$  (to, że jest mniejsze od 1 można wyprowadzić z aksjomatów)

$$0 \leq P(A)$$

- 2) Prawdopodobieństwo zdarzenia pewnego  $\Omega$  jest równe jeden,

$$P(\Omega) = 1$$

- 3) Prawdopodobieństwo przeliczalnej sumy parami wykluczających się zdarzeń  $(A_i \cap A_j = \emptyset, i \neq j \text{ dla } A_i \in \mathcal{F}, i \in \mathbb{N})$  jest równe sumie prawdopodobieństw tych zdarzeń:

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

### 2.6 Przestrzeń probabilistyczna

Dokonyjemy pewnego doświadczenia losowego. Niech:

- $\Omega$  będzie zbiorem zdarzeń elementarnych w tym doświadczeniu

- $\mathcal{F}$  –  $\sigma$  - ciałem zdarzeń losowych w tym doświadczeniu
- $P$  - funkcja prawdopodobieństwa określona na  $\mathcal{F}$

**Przestrzenią probabilistyczną** (przestrzenią prawdopodobieństwa) nazywamy trójkę  $(\Omega, \mathcal{F}, P)$

2024-10-11:

### 3 Podstawowe pojęcia probabilistyczne

#### Twierdzenie 3.1

Jeżeli  $(\Omega, \mathcal{F}, P)$  jest przestrzenią probabilistyczną i  $A, B, A_1, A_2, \dots, A_n \in \mathcal{F}$ , to

1.  $P(\emptyset) = 0$
2. jeżeli  $A_1, A_2, \dots, A_n$  wykluczają się wzajemnie ( $A_i \cap A_j = \emptyset, i \neq j$ ), to

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

3.  $P(A') = 1 - P(A)$
4. Jeżeli  $A \subset B$ , to  $P(B \setminus A) = P(B) - P(A)$
5. Jeżeli  $A \subset B$ , to  $P(A) \leq P(B)$
6.  $P(A) \leq 1$
7.  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$

#### Dowód 3.1

Teza:  $P(\emptyset) = 0$

Na mocy pierwszego aksjomatu  $P(\emptyset) \geq 0$

Niech  $P(\emptyset) = a \geq 0$ . Wtedy mamy

$$a = P(\emptyset) = P\left(\bigcup_{n=1}^{\infty} \emptyset\right) = \sum_{n=1}^{\infty} P(\emptyset) = \sum_{n=1}^{\infty} a = \lim_{n \rightarrow \infty} \sum_{i=1}^n a = \lim_{n \rightarrow \infty} n \cdot a$$

Zbiór pusty wyrażamy w postaci przeliczalnej sumy zbiorów pustych (które są zbiorami parami rozłącznymi)

Otrzymujemy równanie  $a = \lim_{n \rightarrow \infty} n \cdot a$

Jedynym rozwiązaniem równania jest  $a = 0$ . CND

**Dowód 3.2**

Teza: jeżeli  $A_1, A_2, \dots, A_n$  wykluczają się wzajemnie ( $A_i \cap A_j = \emptyset, i \neq j$ ), to

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

Zdefiniujmy następująco ciąg zdarzeń losowych  $\{B_i, i \geq 1\}$

$$B_i = \begin{cases} A_i, & i = 1, 2, \dots, n \\ \emptyset, & i = n+1, n+2, \dots \end{cases}$$

Zdarzenia te są parami wykluczające, a zatem na mocy III aksjomatu i własności 1 mamy:

$$\begin{aligned} P\left(\bigcup_{i=1}^n A_i\right) &= P\left(\bigcup_{i=1}^n A_i \cup \bigcup_{i=n+1}^{\infty} A_i\right) \\ &= P\left(\bigcup_{i=1}^{\infty} B_i\right) \\ &\stackrel{\text{III aksjomat}}{=} \sum_{i=1}^{\infty} P(B_i) \\ &= \sum_{i=1}^n P(A_i) + \sum_{i=n+1}^{\infty} P(\emptyset) \\ &= \sum_{i=1}^n P(A_i) \end{aligned}$$

CND

**Dowód 3.3**

Teza:  $P(A') = 1 - P(A)$

Zauważmy, że dla dowolnego zdarzenia  $A$  mamy

$$A \cup A' = \Omega \quad A \cap A' = \emptyset$$

Na mocy aksjomatu II i własności 2 mamy:

$$1 = P(\Omega) = P(A \cup A') = P(A) + P(A')$$

Stąd  $P(A') = 1 - P(A)$ . **CND**

**Dowód 3.4**

Teza: Jeżeli  $A \subset B$ , to  $P(B \setminus A) = P(B) - P(A)$

Dla  $A \subset B$  mamy:

$$A \cup (B \setminus A) = B \quad \text{oraz} \quad A \cap (B \setminus A) = \emptyset$$

Wtedy na mocy własności 2:

$$P(A) + P(B \setminus A) = P(B)$$

Stąd

$$P(B \setminus A) = P(B) - P(A)$$

CND

**Dowód 3.5**

Teza: Jeżeli  $A \subset B$ , to  $P(A) \leq P(B)$

Na mocy aksjomatu I oraz własności 4 dla  $A \subset B$  mamy

$$0 \leq P(B \setminus A) = P(B) - P(A)$$

Stąd  $P(A) \leq P(B)$ . CND

**Dowód 3.6**

Teza:  $P(A) \leq 1$

Zauważmy, że  $A \subset \Omega$

Wtedy na mocy własności 5 i aksjomatu II mamy:

$$P(A) \leq P(\Omega) = 1$$

Stąd  $P(A) \leq 1$ . CND

**Dowód 3.7**

Teza:  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$

Korzystamy z następujących zależności:

$$A \cup B = A \cup (B \setminus A), \quad \text{i} \quad B = (B \setminus A) \cup (A \cap B)$$

Korzystając z własności 2 dostajemy układ dwóch zależności:

$$\begin{cases} P(A \cup B) = P(A) + P(B \setminus A) \\ P(B) = P(B \setminus A) + P(A \cap B) \end{cases}$$

Odejmując stronami dostajemy:

$$P(A \cup B) - P(B) = P(A) - P(A \cap B)$$

Stąd  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$ . CND

### Twierdzenie 3.2: Prawdopodobieństwo sumy trzech zdarzeń

Niech  $A, B, C \in \mathcal{F}$ .

$$\begin{aligned} P(A \cup B \cup C) &= P(A) + P(B) + P(C) - P(A \cap B) - P(A \cap C) \\ &\quad - P(B \cap C) + P(A \cap B \cap C) \end{aligned}$$

Dowód jak dla mocy sumy trzech zbiorów na mocy własności 7

### Twierdzenie 3.3: Wzór włączeń i wyłączeń

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

$$\begin{aligned} P(A_1 \cup A_2 \cup \dots \cup A_n) &= \sum_{i=1}^n P(A_i) \\ &\quad - \sum_{1 \leq i_1 < i_2 \leq n} P(A_{i_1} \cap A_{i_2}) \\ &\quad + \dots \\ &\quad + (-1)^{n+1} P(A_1 \cap A_2 \cap \dots \cap A_n) \end{aligned}$$

### Twierdzenie 3.4: o ciągłości miary

Niech  $(\Omega, \mathcal{F}, P)$  będzie przestrzenią probabilistyczną.

- Jeżeli  $\{A_n, n \geq 1\}$  jest wstępującą rodziną zdarzeń losowych

$$A_1 \subset A_2 \subset \dots \subset A_n \subset A_{n+1} \subset \dots$$

Oraz

$$\bigcup_{n=1}^{\infty} A_n = A$$

$$\text{To } P(A) = \lim_{n \rightarrow \infty} P(A_n)$$

2) i  $\{A_n, n \geq 1\}$  jest zstępującą rodziną zdarzeń losowych

$$A_1 \supset A_2 \supset \dots \supset A_n \supset A_{n+1} \supset \dots$$

Oraz

$$\bigcap_{n=1}^{\infty} A_n = A$$

$$\text{To } P(A) = \lim_{n \rightarrow \infty} P(A_n)$$

### Dowód 3.8: Dowód dla rodziny wstępującej

Niech

$$B_1 = A_1$$

$$B_2 = A_2 \setminus A_1$$

⋮

$$B_n = A_n \setminus A_{n-1}$$

⋮

Wtedy

1. zdarzenia  $B_i, i \geq 1$  wykluczają się

$$2. \bigcup_{i=1}^n B_i = \bigcup_{i=1}^n A_i = A_n$$

$$P(A_n) \stackrel{2.}{=} \sum_{i=1}^n P(B_i)$$

$$\bigcup_{i=1}^{\infty} B_i = A$$

$$\begin{aligned}
 P(A) &= P\left(\bigcup_{i=1}^{\infty} B_i\right) \\
 &\stackrel{\text{III aksjomat}}{=} \sum_{i=1}^{\infty} P(B_i) \\
 &= \lim_{n \rightarrow \infty} \sum_{i=1}^n P(B_i) \\
 &= \lim_{n \rightarrow \infty} P(A_n)
 \end{aligned}$$

**Dowód 3.9: Dowód dla rodziny zstępującej**

Rozważamy rodzinę zstępującą  $C_n, n \geq 1$   $C_n = A'_n$ . Wtedy

$$\bigcup_{n=1}^{\infty} C_n = \bigcup_{n=1}^{\infty} A'_n = \left(\bigcap_{n=1}^{\infty} A_n\right)' = A'$$

$$P(A') \stackrel{(i)}{=} \lim_{n \rightarrow \infty} P(C_n) = \lim_{n \rightarrow \infty} (1 - P(A_n))$$

Stąd mamy

$$1 - P(A) = 1 - \lim_{n \rightarrow \infty} P(A_n)$$

i ostatecznie

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

**Twierdzenie 3.5: o przedłużaniu miary**

Jeżeli  $P$  jest skończenie addytywną i nieujemną funkcją na pewnym ciele  $\mathcal{A}$  podzbiorów  $\Omega$ , przy czym  $P(\Omega) = 1$ , i spełniony jest

- warunek (i) z twierdzenia o ciągłości miary LUB
- warunek (ii) dla  $A = \emptyset$

to  $P$  przedłuża się jednoznacznie do prawdopodobieństwa na  $\sigma(\mathcal{A})$ , czyli  $\sigma$ -ciele generowanym przez  $\mathcal{A}$

## 4 Różne miary probabilistyczne

### 4.1 Przeliczalny zbiór zdarzeń elementarnych

- $\Omega$  - przeliczalny zbiór zdarzeń
- $\mathcal{F}$  - zbiór wszystkich podzbiorów zbioru  $\Omega$

Możemy podać kompletny, zgodny z intuicją i zdrowym rozsądkiem, opis wszystkich możliwych prawdopodobieństw.

#### Twierdzenie 4.1

Jeśli

- $\Omega = \{\omega_1, \omega_2, \dots\}$
- dla każdego  $i \in \mathbb{N}$  zbiór  $\{\omega_i\} \in \mathcal{F}$
- $P$  jest prawdopodobieństwem

to dla każdego  $A \subset \Omega$  mamy

$$P(A) = \sum_{i \in \{i: \omega_i \in A\}} p_i$$

gdzie  $p_i = P(\{\omega_i\})$

#### Przykład 4.1

Niech

- $\Omega = \{\omega_1, \omega_2, \dots\}$  oraz
- $\mathcal{F}$  - rodzina wszystkich podzbiorów  $\Omega$ .
- $P : \mathcal{F} \rightarrow \mathbb{R}$

•

$$p(\{\omega_1\}) = p_1$$

$$p(\{\omega_2\}) = p_2$$

⋮

$$p(\{\omega_n\}) = p_n$$

•

$$\sum_{i=1}^n p_i = 1$$

$$\bullet P(\Omega) = P\left(\bigcup_{i=1}^{\infty} \{\omega_i\}\right) = \sum_{i=1}^n p_i = 1$$

Weźmy zdarzenia losowe  $A_1, A_2, \dots$ , takie, że  $A_i \cap A_j = \emptyset$

$$A_i = \{\omega_{i_1}, \omega_{i_2}, \dots, \omega_{i_n}\}$$

$$A_j = \{\omega_{j_1}, \omega_{j_2}, \dots, \omega_{j_n}\}$$

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = P\left(\bigcup_{\substack{k:\omega_k \in A_j \\ j=1,2,\dots}} \{\omega_k\}\right) = \sum_{\substack{k:\omega_k \in A_j \\ j=1,2,\dots}} P(\{\omega_k\})$$

#### Dowód 4.1

Dowolne zdarzenie  $A \in \mathcal{F}$  wyraża się wzorem

$$A = \bigcup_{i \in \{i: \omega_i \in A\}} \{\omega_i\}$$

- spełniony jest warunek  $\{\omega_i\} \cap \{\omega_j\} = \emptyset$  gdy  $i \neq j$
- $A = \bigcup_{i \in \{i: \omega_i \in A\}} \{\omega_i\}$  jest skończony lub przeliczalny

Z III aksjomatu lub drugiej własności

$$\begin{aligned} P(A) &= P\left(\bigcup_{i \in \{i: \omega_i \in A\}} \{\omega_i\}\right) \\ &= \sum_{i \in \{i: \omega_i \in A\}} P(\{\omega_i\}) \\ &= \sum_{i \in \{i: \omega_i \in A\}} p_i \end{aligned}$$

#### 4.1.1 Uwagi

1. Prawdopodobieństwo jest jednoznacznie wyznaczone przez prawdopodobieństwo zdarzeń elementarnych
2.  $\sum_{i=1}^{\infty} p_i = 1 \implies$  na zbiorze przeliczalnym i nieskończonym prawdopodobieństwo nie może być rozłożone «równo»
3. Tylko w przypadku zbioru  $\Omega$  skończonego często mamy do czynienia z rozkładem równomiernym.

## 4.2 Prawdopodobieństwo geometryczne

Niech

- $\Omega \subset \mathbb{R}^n$
- $\mu$  - naturalna miara na  $\mathbb{R}^n$  (np. miara Lebesgue'a [lebega])

Wtedy możemy mówić o prawdopodobieństwie geometrycznym, a zadanie sprowadza się do znalezienia miary (długości, pola, objętości itd.) podzbiorów  $\mathbb{R}^n$ .

$$\Omega \subset \mathbb{R}^n, \quad \mu - \text{miara}$$

Każde zdarzenie elementarne (w tym przypadku każdy punkt zbioru  $\Omega \subset \mathbb{R}^n$ ) jest «jednakowo możliwe».

$$A \subset \Omega, \quad A \in \mathcal{F}, \quad A \text{ jest zdarzeniem losowym}$$

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

### Przykład 4.2

Pani X i pani Y umówiły się na spotkanie między godz. 16 a 17 w centrum miasta. Komunikacja w godzinach szczytu działa jak działa. Osoba, która przyjdzie pierwsza czeka na drugą 20 minut. Jaka jest szansa, że dojdzie do spotkania?

Rozwiązanie

Niech

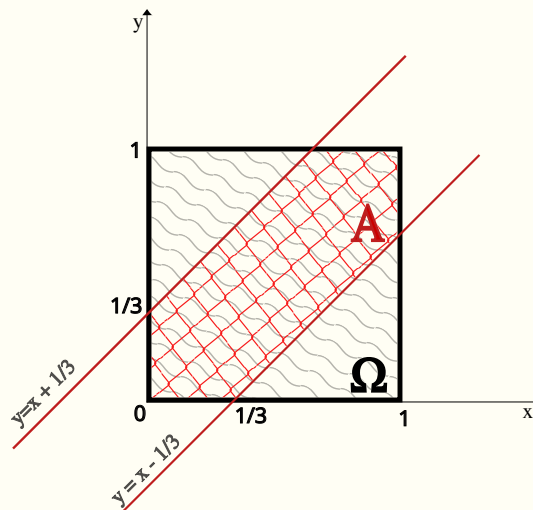
- $x$  – godzina przybycia na umówione miejsce p. X
- $y$  – godzina przybycia na umówione miejsce p. Y

Dla uproszczenia przyjmujemy, że panie spotkają się między godzinami 0.00 i 1.00. Zauważmy, że wtedy

$$x \in \langle 0; 1 \rangle \quad \text{i} \quad y \in \langle 0; 1 \rangle$$

Zbiór zdarzeń elementarnych  $\Omega$  możemy przedstawić następująco

$$\Omega = \{(x, y) : 0 \leq x, y \leq 1\} \subset \mathbb{R}^2$$



**Rysunek 1:** prawdopodobieństwo geometryczne

$A$  – zdarzenie polegające na tym, że panie spotkają się (panie spotkają się gdy różnica czasów ich pojawienia się w umówionym miejscu będzie mniejsza niż  $\frac{1}{3}$  godziny)

$$A = \{(x, y) : 0 \leq x, y \leq 1, |x - y| \leq \frac{1}{3}\}$$

$\mu$  – pole

$$P(A) = \frac{\mu(A)}{\mu(\Omega)} = \frac{1 - (\frac{2}{3})^2}{1} = \frac{5}{9}$$

2024-10-22

## 5 Prawdopodobieństwo warunkowe

Bardzo wiele zadań i problemów rachunku prawdopodobieństwa jest formułowanych w terminach prawdopodobieństwa warunkowego.

- firmy ubezpieczeniowe i pytania zadawane przy zawieraniu ubezpieczeń -> skutek: wysokość składki ubezpieczeniowej ustalana na podstawie prawdopodobieństwa przeżycia

**Przykład 5.1**

W jednej urnie są same białe kule, w drugiej same czarne. Wybieramy losowo urnę i wyciągamy z niej kolejno 2 kule. Niech  $A$  (odp.  $B$ ) oznacza zdarzenie, że pierwsza (odp. druga) kula jest biała. Wyznaczyć  $P(A)$ ,  $P(B)$ ,  $P(B|A)$

$P(A) = P(B) = \frac{1}{2}$  - bo wybór urny determinuje wybór koloru kuli

$P(B|A) = 1$  - bo jeżeli zaszło zdarzenie  $A$ , to druga będzie biała

**5.1 Definicja**

Niech  $(\Omega, \mathcal{F}, P)$  będzie przestrzenią probabilistyczną

Prawdopodobieństwem warunkowym zajścia zdarzenia  $A$  pod warunkiem zajścia zdarzenia  $B$ ,  $P(B) > 0$ , nazywamy liczbę

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

Uwaga: przy ustalonym  $B \in \mathcal{F}$  prawdopodobieństwo warunkowe  $P(A|B)$  jest zwykłym prawdopodobieństwem na  $(\Omega, \mathcal{F})$  oraz na  $(B, \mathcal{F}_B)$ , gdzie  $\mathcal{F}_B = \{A \cap B : A \in \mathcal{F}\}$

**Przykład 5.2**

Wybieramy jedną rodzinę spośród rodzin z dwójką dzieci. Obliczyć prawdopodobieństwo, że wybierzemy rodzinę z dwoma chłopcami, jeśli wiemy, że w tej rodzinie

- starsze dziecko jest chłopcem
- jest co najmniej jeden chłopiec

Rozwiązanie.

$$\Omega = \{(c, c), (c, d), (d, c), (d, d)\}$$

pierwszy element pary oznacza płeć starszego dziecka, drugi drugiego.

•

$$\begin{aligned} P(\{(c, c)\} | \{(c, c), (c, d)\}) &= \frac{P(\{(c, c)\} \cap \{(c, c), (c, d)\})}{P(\{(c, c), (c, d)\})} \\ &= \frac{P(\{(c, c)\})}{P(\{(c, c), (c, d)\})} \\ &= \frac{\frac{1}{4}}{\frac{1}{2}} = \frac{1}{2} \end{aligned}$$

$$\begin{aligned}
 P(\{(c,c)\}|\{(c,c), (c,d), (d,c)\}) &= \frac{P(\{(c,c)\} \cap \{(c,c), (c,d), (d,c)\})}{P(\{(c,c), (c,d), (d,c)\})} \\
 &= \frac{P(\{(c,c)\})}{P(\{(c,c), (c,d), (d,c)\})} \\
 &= \frac{\frac{1}{4}}{\frac{3}{4}} = \frac{1}{3}
 \end{aligned}$$

**Przykład 5.3**

Udowodnić, że dla dowolnych  $A, B \in \mathcal{F}$ , takich, że  $P(A) > 0, P(B) > 0$

$$P(A|B) > P(A) \iff P(B|A) > P(B)$$

Rozwiązanie

$$\begin{aligned}
 P(A|B) > P(A) &\iff \frac{P(A \cap B)}{P(B)} > P(A) \\
 &\iff P(A \cap B) > P(A) \cdot P(B) \\
 &\iff P(B|A) > P(B)
 \end{aligned}$$

Interpretacja: zajście zdarzenia  $B$  zwiększa szanse zajścia zdarzenia  $A$  wtw, gdy zajście zdarzenia  $A$  zwiększa szanse zajścia zdarzenia  $B$

**Zastosowanie ostatniego przykładu** Prawdopodobieństwo warunkowe, że brydżysta ma asa pik (zdarzenie  $A$ ), jeśli wiemy, że ma co najmniej 1 asa (zdarzenie  $B$ ) jest większe od prawdopodobieństwa, że brydżysta ma asa pik

$P(A|B) = 1 \geq P(B)$  ma co najmniej jednego asa gdy ma asa pik, zatem  $P(A|B) \geq P(A)$

**Twierdzenie 5.1**

Jeżeli zdarzenia  $A_1, A_2, \dots, A_n$  spełniają warunek

$$P(A_1 \cap A_2 \cap \dots \cap A_n) > 0$$

to

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1) \cdot P(A_2|A_1) \cdot \dots \cdot P(A_n|A_1 \cap A_2 \cap \dots \cap A_{n-1})$$

**Dowód 5.1**

$$P(A_1 \cap A_2 \cap \dots \cap A_n) > 0 \implies$$

wszystkie prawdopodobieństwa warunkowe są dobrze określone

$$\begin{aligned} P &= P(A_1) \cdot P(A_2|A_1) \cdot P(A_3|A_1 \cap A_2) \cdots P(A_n|A_1 \cap A_2 \cap \dots \cap A_{n-1}) \\ &= P(A_1) \cdot \frac{P(A_1 \cap A_2)}{P(A_1)} \cdot \frac{P(A_1 \cap A_2 \cap A_3)}{P(A_1 \cap A_2)} \cdots \frac{P(A_1 \cap A_2 \cap \dots \cap A_n)}{P(A_1 \cap A_2 \cap \dots \cap A_{n-1})} \\ &= P(A_1 \cap A_2 \cap \dots \cap A_n) \end{aligned}$$

**5.2 Rozbicie przestrzeni  $\Omega$** 

Rozbiciem przestrzeni  $\Omega$  nazywamy rodzinę zdarzeń  $\{A_i\}_{i \in I}$ , które wzajemnie się wykluczają

$$\bullet \bigcap_{\substack{i,j \in I \\ i \neq j}} A_i \cap A_j = \emptyset$$

a ich suma daje zdarzenie pewne

$$\bullet \bigcup_{i \in I} A_i = \Omega$$

**5.3 Prawdopodobieństwo całkowite**

Jeżeli zdarzenia  $\{A_1, A_2, \dots, A_n\}$  tworzą rozbicie przestrzeni  $\Omega$  i  $P(A_i) > 0$  dla  $i \in \{1, 2, \dots, n\}$ , to dla dowolnego zdarzenia  $B$

$$P(B) = \sum_{i=1}^n P(B|A_i) \cdot P(A_i)$$

**Dowód 5.2**

Dla  $i = \{1, 2, \dots, n\}$ :

- $P(A_i) > 0$
- $A_i \cap A_j = \emptyset, i \neq j$
- $\bigcup_{i=1}^n A_i = \Omega$

$$\begin{aligned}
 B &= B \cap \Omega \\
 &= B \cap (A_1 \cup A_2 \cup \dots \cup A_n) \\
 &= \underbrace{(B \cap A_1) \cup (B \cap A_2) \cup \dots \cup (B \cap A_n)}_{\text{suma zbiorów rozłącznych}}
 \end{aligned}$$

$$\begin{aligned}
 P(B) &= P((B \cap A_1) \cup (B \cap A_2) \cup \dots \cup (B \cap A_n)) \\
 &= \sum_{i=1}^n P(B \cap A_i) \\
 &= \sum_{i=1}^n P(B|A_i) \cdot P(A_i)
 \end{aligned}$$

### 5.3.1 Prawdopodobieństwo całkowite dla przeliczalnego rozbicia

Niech  $\{A_1, A_2, \dots, A_n, \dots\}$  – rozbicie przeliczalne przy czym  $\bigwedge_{i \in \mathbb{N}} P(A_i) > 0$ , to

$$P(B) = \sum_{i=1}^{\infty} P(B|A_i) \cdot P(A_i)$$

(dowód analogiczny jak powyżej)

#### Przykład 5.4

W loterii fantowej zorganizowanej na balu szansa wygranej w jednym losowaniu jest równa  $p$ , przegranej  $q$ , a z prawdopodobieństwem  $r$  wyciągany jest los «graj dalej». Wtedy wrzucamy go z powrotem do urny i losujemy jeszcze raz. Jakie jest prawdopodobieństwo wygranej?

Rozwiązanie. Wprowadzamy następujące oznaczenia:

- $A_1$  – wyciągnięto los «wygrana»,  $P(A_1) = p$
- $A_2$  – wyciągnięto los «przegrana»,  $P(A_2) = q$
- $A_3$  – wyciągnięto los «graj dalej»,  $P(A_3) = r$

gdzie  $p + q + r = 1$

Niech  $B$  oznacza wygraną. Mamy wtedy:

- $P(B|A_1) = 1$
- $P(B|A_2) = 0$
- $P(B|A_3) = P(B)$

Zakładamy, że loteria liczy tak dużo losów, że pierwsze losowania nie zmieniają prawdopodobieństw.

$$\begin{aligned} P(B) &= P(B|A_1) \cdot P(A_1) + P(B|A_2) \cdot P(A_2) + P(B|A_3) \cdot P(A_3) \\ &= 1 \cdot p + 0 \cdot q + P(B) \cdot r \end{aligned}$$

Stąd

$$P(B) \cdot (1 - r) = p \quad P(B) = \frac{p}{1 - r}$$

## 5.4 Wzór Bayesa

Jeżeli zdarzenia  $\{A_1, A_2, \dots, A_n\}$  tworzą rozbiecie przestrzeni  $\Omega$  i  $P(A_i) > 0$  dla  $i \in \{1, \dots, n\}$ , to dla dowolnego zdarzenia  $B$  takiego, że  $P(B) > 0$  mamy

$$P(A_i|B) = \frac{P(B|A_i) \cdot P(A_i)}{\sum_{i=1}^n P(B|A_i) \cdot P(A_i)}, \quad i \in \{1, \dots, n\}$$

### Dowód 5.3

$$\begin{aligned} P(A_i|B) &= \frac{P(A_i \cap B)}{P(B)} = \frac{P(B|A_i) \cdot P(A_i)}{\sum_{i=1}^n P(B|A_i) \cdot P(A_i)} \\ P(B|A_i) &= \frac{P(B \cap A_i)}{P(A_i)} \implies P(B \cap A_i) = P(B|A_i) \cdot P(A_i) \end{aligned}$$

## 6 Niezależność zdarzeń

### 6.1 Zdarzenia niezależne

Niezależność - jedno z podstawowych pojęć odróżniających rachunek prawdopodobieństwa od innych działów matematyki badających własności przestrzeni mierzalnych

Niech  $(\Omega, \mathcal{F}, P)$  będzie przestrzenią prawdopodobieństwa oraz niech  $A, B \in \mathcal{F}$

Naturalnym jest powiedzieć, że zdarzenie  $B$  **nie zależy od zdarzenia**  $A$ , gdy wiedza o tym, że zaszło zdarzenie  $A$  nie ma wpływu na prawdopodobieństwo zajścia zdarzenia  $B$

Założmy, że  $P(A) > 0$

$$P(B|A) = P(B) \quad P(A \cap B) = P(A) \cdot P(B)$$

## 6.2 Zdarzenie niezależne - definicja

**Zdarzenia niezależne** Zdarzenia  $A$  i  $B$  są niezależne (stochastycznie niezależne) gdy zachodzi warunek

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

- Zdarzenie niezależne i rozłączne ( $A \cap B = \emptyset$ ) to dwa różne pojęcia
- Zdarzenia rozłączne są niezależne wtw, gdy  $P(A) = 0 \vee P(B) = 0$
- Relacja niezależności jest symetryczna

### Przykład 6.1

Wybieramy jedną rodzinę spośród rodzin mających  $n$  dzieci. Niech:

- $A$  – zdarzenie, że w losowo wybranej rodzinie jest co najwyżej jedna dziewczynka
- $B$  – zdarzenie, że w rodzinie są dziewczynki i chłopcy

Czy zdarzenia  $A$  i  $B$  są niezależne

Rozwiązanie. Tworzymy przestrzeń probabilistyczną:

- $\Omega$  – zbiór  $n$  elementowych ciągów  $(a_1, a_2, \dots, a_n)$   $a_i \in \{\text{chłopiec, dziewczynka}\}$  uporządkowanych w/g starszeństwa
- $\mathcal{F}$  – zbiór wszystkich podzbiorów zbioru  $\Omega$
- $P$  – miara prawdopodobieństwa:

$$P(A) = \frac{\text{liczba elementów w zbiorze } A}{\text{liczba elementów zbioru } \Omega} \stackrel{\text{ozn.}}{=} \frac{n(A)}{n(\Omega)}$$

Mamy

- $n(\Omega) = 2^n$  ( $n$  elementowa wariacja z powtórzeniami z 2)
- $n(A) = n + 1$  (1 dziewczynka na kolejnych miejscach lub sami chłopcy)
- $n(B) = 2^n - 2$  (odejmujemy same dziewczynki i samych chłopców)

Zdarzenia są niezależne  $\iff P(A \cap B) = P(A) \cdot P(B)$

Mamy

$$P(A) = \frac{n+1}{2^n} \quad P(B) = \frac{2^n - 2}{2^n} \quad P(A) \cdot P(B) = \frac{(n+1)(2^n - 2)}{2^{2n}}$$

$$P(A \cap B) = \frac{n}{2^n} \quad \text{i} \quad P(A \cap B) = \frac{n}{2^n}$$

Warunek:

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

po przekształceniach:

$$n2^n - 2n + 2^n - 2 = n2^n, \quad 2^n = 2 + 2n, \quad 2^{n-1} = 1 + n$$

Mamy

$$2^{n-1} = 1 + n$$

Warunek jest spełniony tylko dla  $n = 3$

### 6.3 Niezależność trzech zdarzeń

Niech  $A, B, C \in \mathcal{F}$ .

Zdarzenia  $A, B, C$  są niezależne wtw, gdy

- $P(A \cap B) = P(A) \cdot P(B)$
- $P(A \cap C) = P(A) \cdot P(C)$
- $P(B \cap C) = P(B) \cdot P(C)$
- $P(A \cap B \cap C) = P(A) \cdot P(B) \cdot P(C)$

### 6.4 Niezależność $n$ zdarzeń

Niech  $A_1, A_2, \dots, A_n \in \mathcal{F}$ .

Zdarzenia  $A_1, A_2, \dots, A_n$  są niezależne wtw, gdy

$$P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_k}) = P(A_{i_1}) \cdot P(A_{i_2}) \cdot \dots \cdot P(A_{i_k})$$

dla

$$1 \leq i_1 < i_2 < \dots < i_k < n \quad \text{i} \quad k = 2, 3, \dots, n$$

#### Achtung! 3

Żeby wykazać, że zdarzenia  $A_1, A_2, \dots, A_n \in \mathcal{F}$  są niezależne należy sprawdzić  $2^n - n - 1$  równości

**Przykład 6.2**

Dla  $n \geq 3$  z niezależności zdarzeń parami nie wynika ich niezależność.

Niech  $\Omega = \{\omega_1, \omega_2, \omega_3, \omega_4\}$  i  $P(\{\omega_i\}) = \frac{1}{4}$

Dla  $A_1 = \{\omega_1, \omega_2\}$ ,  $A_2 = \{\omega_1, \omega_3\}$ ,  $A_3 = \{\omega_1, \omega_4\}$  mamy:

$$P(A_i) = \frac{1}{2}, P(A_i \cap A_j) = \frac{1}{4} \quad i \neq j$$

Mamy zatem niezależność parami:

$$P(A_i \cap A_j) = P(A_i) \cdot P(A_j) \quad i \neq j$$

Z drugiej strony:

$$P(A_1 \cap A_2 \cap A_3) = P(\{\omega_1\}) = \frac{1}{4} \neq \frac{1}{8} = P(A_1) \cdot P(A_2) \cdot P(A_3)$$

Zatem zdarzenia nie są niezależne.

**Twierdzenie 6.1**

Jeżeli  $A$  i  $B$  są zdarzeniami niezależnymi

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

to niezależne są również następujące zdarzenia:

- i)  $A$  i  $B'$
- ii)  $A'$  i  $B$
- iii)  $A'$  i  $B'$

**Dowód 6.1**

Rozwiązanie. Zakładamy, że  $A$  i  $B$  są zdarzeniami niezależnymi.

Wtedy:

$$i) \quad A = A \cap \Omega = A \cap (B \cup B') = \underbrace{(A \cap B) \cup (A \cap B')}_{\text{suma zdarzeń rozłącznych}}$$

$$P(A) = P(A \cap B) + P(A \cap B') = P(A) \cdot P(B) + P(A \cap B')$$

$$P(A \cap B') = P(A) - P(A) \cdot P(B) = P(A)(1 - P(B)) = P(A) \cdot P(B')$$

Zdarzenia  $A$  i  $B'$  są niezależne

$$\text{ii) } B = B \cap \Omega = B \cap (A \cup A')$$

iii)

$$B' = B' \cap \Omega = B' \cap (A \cup A') = (A \cap B') \cup (A' \cap B')$$

$$P(B') = P(A \cap B') + P(A' \cap B') = P(A) \cdot P(B') + P(A' \cap B')$$

$$P(A' \cap B') = P(B') - P(A) \cdot P(B') = P(B')(1 - P(A)) = P(A')P(B')$$

### Twierdzenie 6.2: uogólnienie na $n$ zdarzeń

Przyjmujemy oznaczenia

$$\bullet A^0 = A \text{ i } A^1 = A'$$

Twierdzenie

Następujące warunki są równoważne:

- Zdarzenia  $A_1, A_2, \dots, A_n$  są niezależne
- Dla każdego ciągu  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ , gdy  $\varepsilon_i \in \{0, 1\}$ ,  $i \in \{1, 2, \dots, n\}$  zdarzenia  $B_1 = A_1^{\varepsilon_1}, B_2 = A_2^{\varepsilon_2}, \dots, B_n = A_n^{\varepsilon_n}$  są niezależne
- Dla każdego ciągu  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ , gdy  $\varepsilon_i \in \{0, 1\}$ ,  $i \in \{1, 2, \dots, n\}$  zachodzi równość  $P(A_1^{\varepsilon_1} \cap A_2^{\varepsilon_2} \cap \dots \cap A_n^{\varepsilon_n}) = P(A_1^{\varepsilon_1}) \cdot P(A_2^{\varepsilon_2}) \cdot \dots \cdot P(A_n^{\varepsilon_n})$

## 6.5 Niezależność $\sigma$ -ciał

Niech  $(\Omega, \mathcal{F}, P)$  – przestrzeń probabilistyczna

**Niezależność  $\sigma$ -ciał**  $\sigma$ -ciała  $\mathcal{F}_1, \mathcal{F}_2, \dots, \mathcal{F}_n$  ( $\mathcal{F}_j \subseteq \mathcal{F}$  dla każdego  $j \in \{1, 2, \dots, n\}$ ) są niezależne wtw, gdy

$$\bigwedge_{j \in \{1, 2, \dots, n\}} \bigwedge_{A_j \in \mathcal{F}_j} P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1) \cdot P(A_2) \cdot \dots \cdot P(A_n)$$

### Twierdzenie 6.3

Zdarzenia  $A_1, A_2, \dots, A_n$  są niezależne wtw, gdy  $\sigma(A_1), \sigma(A_2), \dots, \sigma(A_n)$  są niezależne, gdzie

$$\sigma(A_i) = \{A_i, A_i', \emptyset, \Omega\}$$

jest  $\sigma$ -ciałem generowanym przez  $A_i, i \in \{1, 2, \dots, n\}$

## 6.6 Prawdopodobieństwo sumy niezależnych zdarzeń

Niech  $A_1, A_2, \dots, A_n$  – zdarzenia niezależne

$$P\left(\bigcup_{i=1}^n A_i\right) = 1 - P\left(\bigcap_{i=1}^n A_i'\right) = 1 - \prod_{i=1}^n P(A_i') = 1 - \prod_{i=1}^n (1 - P(A_i))$$

## 6.7 Nieskończony ciąg niezależnych zdarzeń

Zdarzenia  $A_1, A_2, \dots$  nazywamy niezależnymi, gdy dla każdego  $n$  zdarzenia  $A_1, A_2, \dots, A_n$  są niezależne.

---

2024-10-29

## 7 Schematy

### 7.1 Schemat ogólny

Rozważamy sytuację gdy:

- dokonujemy  $n$  doświadczeń w sposób niezależny
- z  $j$ -tym doświadczeniem związana jest przestrzeń probabilistyczna  $(\Omega_j, \mathcal{F}_j, P_j)$  (z każdym doświadczeniem związana różna przestrzeń probabilistyczna)
- wynikiem  $n$  doświadczeń jest ciąg  $(\omega_1, \omega_2, \dots, \omega_n)$ , gdzie  $\omega_j$  - wynik  $j$ -tego doświadczenia

Konstruujemy nową przestrzeń  $(\Omega, \mathcal{F}, P)$

- $\Omega = \Omega_1 \times \Omega_2 \times \dots \times \Omega_n$
- $\mathcal{F} = \mathcal{F}_1 \otimes \mathcal{F}_2 \otimes \dots \otimes \mathcal{F}_n$  -  $\sigma$ -ciało produktowe, jest to  $\sigma$ -ciało generowane przez cylindry, tzn. zbiory postaci  $A_1 \times A_2 \times \dots \times A_n, A_i \in \mathcal{F}_i$
- $P = P_1 \otimes P_2 \otimes \dots \otimes P_n$  - miara produktowa, która jest rozszerzeniem na  $\sigma$ -ciało  $\mathcal{F}$  miary  $P(A_1 \times A_2 \times \dots \times A_n) = \prod_{i=1}^n P_i(A_i)$

## 7.2 Schemat Bernoulliego

Schemat Bernoulliego jest szczególnym przypadkiem wyżej opisanej sytuacji gdy

- dokonujemy niezależnie  $n$  razy pewnego doświadczenia
- każde doświadczenie kończy się jednym spośród dwóch możliwych wyników “sukces”, “porażka”
- znamy prawdopodobieństwo  $p$  “sukcesu” (a zatem i  $q$  “porażki”)
- poszczególne doświadczenia nazywamy próbami Bernoulliego

### Twierdzenie 7.1: Prawdopodobieństwo zajścia $k$ sukcesów

Prawdopodobieństwo zajścia dokładnie  $k$  sukcesów w schemacie Bernoulliego przy  $n$  próbach z prawdopodobieństwem sukcesu w pojedynczym doświadczeniu równym  $p$  wynosi

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

## 7.3 Granica górna ciągu zdarzeń

Granicą górną ciągu zdarzeń  $\{A_n, n \geq 1\}$  nazywamy zdarzenie

$$\limsup A_n := \bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} A_n$$

interpretacja:  $\omega \in \limsup A_n \iff \omega$  należy do nieskończenie wielu zdarzeń z ciągu  $\{A_n, n \geq 1\}$

### Dowód 7.1

$$\begin{aligned} \omega \in \limsup A_n &\iff \omega \in \bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} A_n \\ &\iff \bigwedge_{m \in \mathbb{N}_+} \bigvee_{n \geq m} \omega \in A_n \end{aligned}$$

## 7.4 Granica dolna ciągu zdarzeń

Granicą dolną ciągu zdarzeń  $\{a_n, n \geq 1\}$  nazywamy zdarzenie

$$\liminf A_n := \bigcup_{m=1}^{\infty} \bigcap_{n=m}^{\infty} A_n$$

interpretacja:  $\omega \in \liminf A_n \iff \omega$  należy do wszystkich zdarzeń z ciągu  $\{A_n, n \geq 1\}$ , poczynając od pewnego miejsca

**Dowód 7.2**

$$\begin{aligned} \omega \in \liminf A_n &\iff \omega \in \bigcup_{m=1}^{\infty} \bigcap_{n=m}^{\infty} A_n \\ &\iff \bigvee_{m \in \mathbb{N}_+} \bigwedge_{n \geq m} \omega \in A_n \end{aligned}$$

**7.4.1 Własności**

$$\begin{aligned} (\liminf A_n)' = \limsup(A_n') &\quad (\liminf A_n)' = \left( \bigcup_{m=1}^{\infty} \bigcap_{n=m}^{\infty} A_n \right)' \\ &= \bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} A_n' \\ &= \limsup A_n' \end{aligned}$$

$$\begin{aligned} (\limsup A_n)' = \liminf(A_n') &\quad (\limsup A_n)' = \left( \bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} A_n \right)' \\ &= \bigcup_{m=1}^{\infty} \bigcap_{n=m}^{\infty} A_n' \\ &= \liminf A_n' \end{aligned}$$

**7.5 Lemat Borela-Cantellego**

- ważne narzędzie do badania własności zachodzących z prawdopodobieństwem 1
- dostarcza informacji o prawdopodobieństwie zdarzeń typu “zaszło nieskończenie wiele zdarzeń  $A_n, n \geq 1$ ”

**Twierdzenie 7.2: Lemat Borela-Cantellego**

Niech  $\{A_n, n \geq 1\}$  będzie ciągiem zdarzeń losowych

i) Jeśli  $\sum_{n=1}^{\infty} P(A_n) < \infty$ , to  $P(\limsup_{n \rightarrow \infty} A_n) = 0$

ii) Jeżeli zdarzenia  $A_1, A_2, \dots$  są niezależne i  $\sum_{n=1}^{\infty} P(A_n) = \infty$ , to  $P(\limsup_{n \rightarrow \infty} A_n) = 1$

## 8 Zmienne losowe

Niech  $(\Omega, \mathcal{F}, P)$  – przestrzeń probabilistyczna

**Zmienna losowa** Odwzorowanie  $X : \Omega \rightarrow \mathbb{R}^n$  nazywamy **zmienną losową** o wartościach w  $\mathbb{R}^n$ , jeśli

$$\bigwedge_{A \in \mathcal{B}(\mathbb{R}^n)} X^{-1}(A) \in \mathcal{F}$$

gdzie

- $\mathcal{B}(\mathbb{R}^n)$  – wszystkie zbiory borelowskie na  $\mathbb{R}^n$
- $\underbrace{X^{-1}(A)}_{\text{przeciwobraz}} = \{\omega \in \Omega : X(\omega) \in A\}$

### 8.1 Zmienna losowa - uwagi

Inaczej:  $X$  jest zmienną losową, jeśli jest odwzorowaniem mierzalnym  $(\Omega, \mathcal{F})$  w  $(\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$

Powyższa definicja gwarantuje, że prawdopodobieństwo wszystkich zdarzeń związanych ze zmienną losową jest dobrze określone, czyli zdarzeń postaci  $X^{-1}(A)$ , gdzie  $A \in \mathcal{B}(\mathbb{R}^n)$

**Wektor losowy** Jeśli zmienna losowa odwzorowuje na przestrzeń euklidesową, to taką zmienną nazywamy wektorem losowym.

### 8.2 Zbiory borelowskie

**Zbiór borelowski** podzbiór przestrzeni topologicznej, który można uzyskać ze zbiorów otwartych tej przestrzeni (lub równoważnie, ze zbiorów domkniętych) za pomocą przeliczalnych sum, przekrojów bądź dopełnień.

**$\sigma$ -ciało borelowskie** Klasa zbiorów uzyskanych za pomocą tych operacji tworzy  $\sigma$ -ciało nazywamy  $\sigma$ -ciałem zbiorów borelowskich lub  $\sigma$ -ciałem borelowskim danej przestrzeni topologicznej

#### 8.2.1 Przykłady zbiorów borelowskich

- zbiór liczb wymiernych na prostej rzeczywistej uzyskany jako przeliczalna suma przeliczalnego iloczynu zbiorów otwartych
- pojedynczy punkt będący dopełnieniem sumy dwóch zbiorów otwartych np.  $(-\infty, 1) \cup (1, \infty)$
- rodzina zbiorów borelowskich na prostej jest generowana przez wszystkie przedziały otwarte (równoważnie: domknięte) o końcach wymiernych

- rodzina zbiorów borelowskich na płaszczyźnie jest generowana przez wszystkie prostokąty otwarte o wierzchołkach wymiernych (wystarczą prostokąty o bokach równoległych do osi współrzędnych)
- nie ma naturalnego przykładu podzbioru prostej rzeczywistej, który nie byłby borelowski (intuicyjnie wszystkie zbiory, które można opisać wzorem są borelowskie)
- istnieją konstrukcje zbiorów korzystające z pewnika wyboru, które dają zbiory nie należące do tej klasy, np. zbiór Vitaliego lub zbiór Bernsteina.

### Twierdzenie 8.1: Warunek równoważny

Jeżeli odwzorowanie  $X : \Omega \rightarrow \mathbb{R}^n$  spełnia następujący warunek

$$\bigwedge_{(t_1, t_2, \dots, t_n) \in \mathbb{R}^n} X^{-1}((-\infty, t_1) \times (-\infty, t_2) \times \dots \times (-\infty, t_n)) \in \mathcal{F}$$

to  $X$  jest zmienną losową (wektorem losowym) o wartościach w  $\mathbb{R}^n$

### Achtung! 4

Wystarczy zauważyć, że rodzina zbiorów

$$\{A \subset \mathbb{R}^n : X^{-1}(A) \in \mathcal{F}\}$$

jest  $\sigma$ -ciałem zawierającym wszystkie zbiory postaci

$$(-\infty, t_1) \times (-\infty, t_2) \times \dots \times (-\infty, t_n),$$

a więc wszystkie zbiory borelowskie

**Funkcja borelowska** Funkcją borelowską nazywamy taką funkcję

$$\varphi : \mathbb{R}^n \rightarrow \mathbb{R}^m$$

że przeciwobrazy zbiorów borelowskich w  $\mathbb{R}^m$  są zbiorami borelowskimi w  $\mathbb{R}^n$

### Twierdzenie 8.2

Niech

- $X : \Omega \rightarrow \mathbb{R}^n$  będzie zmienną losową
- $\varphi : \mathbb{R}^n \rightarrow \mathbb{R}^m$  – funkcją borelowską

Wtedy  $(\varphi \circ X)$  jest zmienną losową o wartościach w  $\mathbb{R}^m$

Wniosek: Złożenie wektora losowego z funkcją borelowską jest wektorem losowym.

### Dowód 8.1

Niech

- $B \in \mathcal{B}(\mathbb{R}^m)$ .
- $\varphi : \mathbb{R}^n \rightarrow \mathbb{R}^m$  jest funkcją borelowską.

Wtedy  $\varphi^{-1}(B) \in \mathcal{B}(\mathbb{R}^n)$

Oznaczmy  $C = \varphi^{-1}(B)$ . Widzimy, że  $C \in \mathcal{B}(\mathbb{R}^n)$

Ponieważ  $X$  jest zmienną losową, to  $X^{-1}(C) \in \mathcal{F}$

Mamy zatem

$$(\varphi \circ X)^{-1}(B) = X^{-1}(\varphi^{-1}(B)) = X^{-1}(C) \in \mathcal{F}$$

### 8.2.2 Uwagi

Na zmiennych losowych można wykonywać operacje, które są wykonywane na funkcjach mierzalnych i dalej pozostawać w klasie zmiennych losowych.

Każda funkcja

$$Y : \Omega \rightarrow \mathbb{R}^k$$

która jest zdefiniowana za pomocą funkcji elementarnych i działań przeliczalnych (w tym  $\lim$ ,  $\lim \sup$ ,  $\lim \inf$ ) na wektorach losowych  $X_1, X_2, \dots$  jest  $k$ -wymiarową zmienną losową.

### 8.3 $\sigma$ -ciało generowane przez zmienną losową

$\sigma$ -ciałem generowanym przez zmienną losową o wartościach w  $\mathbb{R}^n$  nazywamy najmniejsze  $\sigma$ -ciało podzbiorów  $\Omega$ , względem którego  $X$  jest mierzalna.

#### Achtung! 5

Najmniejsze podzbiorów  $\Omega$ , względem którego  $X$  jest mierzalna jest częścią wspólną wszystkich  $\sigma$ -ciał, względem których  $X$  jest mierzalna.

**Twierdzenie 8.3**

$$\sigma(X) = \{X^{-1}(B) : B \in \mathcal{B}(\mathbb{R}^n)\}$$

**9 Rozkład prawdopodobieństwa**

**Rozkładem prawdopodobieństwa na  $\mathbb{R}^n$**  nazywamy każdą miarę probabilistyczną  $\mu : \mathcal{B}(\mathbb{R}^n) \rightarrow \mathbb{R}$  spełniającą warunki

- I.  $\bigwedge_{B \in \mathcal{B}(\mathbb{R}^n)} \mu(B) \geq 0$
- II.  $\mu(\mathbb{R}^n) = 1$
- III.  $\bigwedge_{\substack{B_1, B_2, \dots \in \mathcal{B}(\mathbb{R}^n) \\ B_i \cap B_j = \emptyset}} \mu\left(\bigcup_{i=1}^{\infty} B_i\right) = \sum_{i=1}^{\infty} \mu(B_i)$

Rozkładem prawdopodobieństwa zmiennej losowej  $X$  o wartościach w  $\mathbb{R}^n$  nazywamy rozkład  $\mu_X$  określony na  $\mathcal{B}(\mathbb{R}^n)$  w następujący sposób

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

**9.1 Rozkład ciągły**

**Gęstość rozkładu** Jeżeli  $\mu$  jest rozkładem prawdopodobieństwa na  $\mathbb{R}^n$  i dla pewnej funkcji  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  całkownej w sensie Lebesgue'a mamy

$$\mu(A) = \int_A f(x) dx, \quad A \in \mathcal{B}(\mathbb{R}^n)$$

to  $f$  nazywamy gęstością rozkładu  $\mu$

**Rozkład ciągły** Rozkład, który ma gęstość nazywamy rozkładem ciągłym.

**Twierdzenie 9.1**

Niech  $f$  będzie gęstością prawdopodobieństwa rozkładu  $\mu$  na  $\mathbb{R}^n$ .

Wtedy

- 1)  $\int_{\mathbb{R}^n} f(\mathbf{x}) d\mathbf{x} = 1$
- 2)  $f \geq 0$  prawie wszędzie (poza zbiorem miary Lebesgue'a zero)
- 3) Gęstość jest wyznaczona jednoznacznie z dokładnością do zbiorów miary Lebesgue'a 0.

Każda funkcja, spełniająca warunki 1 i 2 jest gęstością prawdopodobieństwa jakiegoś rozkładu.

## 9.2 Rozkład dyskretny

Rozkład  $\mu$  na  $\mathbb{R}^n$  nazywamy dyskretnym, jeżeli istnieje co najwyżej przeliczalny zbiór  $S \subset \mathbb{R}^n$ , dla którego  $\mu(S) = 1$ .

Niech

- $S = \{s_i, i \in I\}$
- $p_i = \mu(\{s_i\})$  dla  $i \in I$
- $I$  jest przeliczalnym zbiorem wskaźników, tzn.  $I_A(s_i) = \begin{cases} 0, & s_i \notin A \\ 1, & s_i \in A \end{cases}$

Wtedy

$$\mu(A) = \mu(A \cap S) = \sum_{i \in I} p_i I_A(s_i), \quad \forall A \in \mathcal{B}(\mathbb{R}^n)$$

Zbiór  $((s_i, p_i), i \in I)$  jednoznacznie wyznacza rozkład  $\mu$

## 9.3 Dystrybuanta

Dystrybuantą rozkładu prawdopodobieństwa  $\mu$  na  $\mathbb{R}^n$  nazywamy funkcję

$$F_\mu : \mathbb{R}^n \rightarrow \mathbb{R}$$

określoną zależnością

$$F_\mu(t_1, t_2, \dots, t_n) = \mu((-\infty, t_1] \times (-\infty, t_2] \times \dots \times (-\infty, t_n])$$

Jeżeli  $\mu_X$  jest rozkładem zmiennej losowej  $X = (X_1, X_2, \dots, X_n)$  o wartościach w  $\mathbb{R}^n$ , dystrybuantę  $F_{\mu_X}$  nazywamy dystrybuantą zmiennej losowej  $X$  i oznaczamy przez  $F_X$ . Wtedy

$$\begin{aligned} F_X(t_1, t_2, \dots, t_n) &= P(X_1 \leq t_1, X_2 \leq t_2, \dots, X_n \leq t_n) \\ &= P[\omega \in \Omega : X_1(\omega) \leq t_1, X_2(\omega) \leq t_2, \dots, X_n(\omega) \leq t_n] \end{aligned}$$

### 9.3.1 Dystrybuanta na $\mathbb{R}$

Dystrybuanta zmiennej losowej  $X$  o wartościach w  $\mathbb{R}^1$ .

$$F_X : \mathbb{R} \rightarrow \mathbb{R} \quad F_X(t) = P(X \leq t)$$

Własności dystrybuanty na  $\mathbb{R}^1$ :

- 1)  $F_X$  jest funkcją niemalejącą:

$$\bigwedge_{t_1 < t_2} F_X(t_1) \leq F_X(t_2)$$

- 2)

$$\lim_{t \rightarrow \infty} F_X(t) = 1 \quad \lim_{t \rightarrow -\infty} F_X(t) = 0$$

- 3)  $F_X$  jest funkcją prawostronnie ciągłą:

$$\bigwedge_{t_0 \in \mathbb{R}} \lim_{t \rightarrow t_0^+} F_X(t) = F_X(t_0)$$

#### Twierdzenie 9.2

Jeżeli funkcja  $F : \mathbb{R} \rightarrow \mathbb{R}$  spełnia warunki (1), (2) i (3), to jest to dystrybuanta pewnego rozkładu

### 9.3.2 Własności dystrybuanty na $\mathbb{R}^n$

Dystrybuanta  $F$  zmiennej losowej  $X$  (wektora losowego) na  $\mathbb{R}^n$  ma następujące własności:

- 1)  $F_X$  jest funkcją niemalejącą względem każdego argumentu  
2)

$$F_X(t_1, t_2, \dots, t_n) \rightarrow 0, \text{ jeśli } \inf_{i \in \{1, \dots, n\}} t_i \rightarrow -\infty$$

(przynajmniej jeden z argumentów dąży do  $-\infty$ )

$$F_X(t_1, t_2, \dots, t_n) \rightarrow 1, \text{ jeśli } \inf_{i \in \{1, \dots, n\}} t_i \rightarrow \infty$$

(każdy z argumentów dąży do  $\infty$ )

- 3)  $F_X$  jest funkcją prawostronnie ciągłą ze względu na każdy z argumentów

**9.3.3 Rozkład zmiennej losowej  $Y = \varphi(X)$** 

- $X$  - zmienna losowa o ciągłym rozkładzie
- $\varphi$  - funkcja klasy  $C^1$

Wtedy zmienna losowa  $Y = \varphi(X)$  jest zmienną losową o ciągłym rozkładzie.

**Twierdzenie 9.3**

Jeżeli zmienna losowa  $X$  ma rozkład ciągły o gęstości  $f$  i  $X(\Omega) \subset (a, b)$ , funkcja  $\varphi : (a, b) \rightarrow \mathbb{R}$  jest klasy  $C^1$  oraz  $\bigwedge_{x \in (a,b)} \varphi'(x) \neq 0$ , to zmienna losowa  $Y = \varphi(X)$  ma rozkład ciągły o gęstości

$$f_Y(y) = f(\varphi^{-1}(y)) \cdot |(\varphi^{-1}(y))'| \cdot I_{\varphi((a,b))}(y)$$

**Przykład 9.1**

$X$  ma rozkład jednostajny  $U([0, 2])$ , tzn. ma gęstość  $f_X(t) = \begin{cases} 0, & t \notin [0, 2] \\ \frac{1}{2}, & t \in [0, 2] \end{cases}$

$$y = 2x + 5$$

$$y - 5 = 2x$$

$$\varphi : \mathbb{R} \rightarrow \mathbb{R} \quad \varphi(x) = 2x + 5$$

$$x = \frac{y - 5}{2}$$

$$x = \varphi^{-1}(y) = \frac{y - 5}{2}$$

$$(\varphi^{-1}(y))' = \left(\frac{y - 5}{2}\right)' = \frac{1}{2}$$

$$f_Y(y) = f_X(\varphi^{-1}(y)) \cdot |(\varphi^{-1}(y))'| \cdot I_{[5;9]}(y)$$

$$= \begin{cases} \frac{1}{2} \cdot \frac{1}{2}, & y \in [5; 9] \\ 0, & y \notin [5; 9] \end{cases}$$

$$= \begin{cases} \frac{1}{4}, & y \in [5; 9] \\ 0, & y \notin [5; 9] \end{cases}$$

## 9.4 Wartość oczekiwana

### 9.4.1 Przypadek dyskretny

Niech

- $(\Omega, \mathcal{F}, P)$  – przestrzeń probabilistyczna
- Zmienna losowa  $X$  o wartościach w  $\mathbb{R}$  ma rozkład dyskretny  $\{(x_i, p_i) : i \in I\}$ , gdzie  $I$  jest co najwyżej przeliczalnym
- $\sum_{i \in I} |x_i| p_i < \infty$ , gdzie  $p_i = P[X = x_i]$

Wartością oczekiwaną zmiennej losowej  $X$  nazywamy liczbę

$$EX = \sum_{i \in I} x_i p_i = \sum_{i \in I} x_i P[X = x_i]$$

#### Achtung! 6

Jeżeli  $I$  jest zbiorem skończonym, to powyższa definicja pokrywa się z definicją całki z funkcji prostej przyjmującej wartości  $x_i$  na zbiorach

$$A_i = \{\omega \in \Omega : X(\omega) = x_i\}$$

względem miary  $P$

Mamy

$$X(\omega) = \sum_{i \in I} x_i I_{A_i}(\omega)$$

oraz

$$\int_{\Omega} X(\omega) dP(\omega) = \sum_{i \in I} x_i P(A_i) = \sum_{i \in I} x_i P(X = x_i)$$

## 9.5 Wartość oczekiwana uogólniona

Zmienna losowa  $X$  o wartościach w  $\mathbb{R}$  ma wartość oczekiwaną  $EX$ , jeżeli jest całkowna, czyli

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

Wtedy wartością oczekiwaną zmiennej losowej  $X$  nazywamy liczbę

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

**Achtung! 7**

Jeżeli zmienna losowa nie jest całkowalna, to nie ma wartości oczekiwanej (wartość oczekiwana nie istnieje)

**9.6 Przypadek ciągły**

Jeżeli zmienna losowa  $X$  ma rozkład typu ciągłego o funkcji gęstości  $f$ , to

$$EX = \int_{-\infty}^{\infty} xf(x)dx$$

pod warunkiem, że  $\int_{-\infty}^{\infty} |x|f(x)dx < \infty$

**9.6.1 Wartość oczekiwana wektora losowego**

Wartością oczekiwaną zmiennej losowej (wektora losowego)  $X = (X_1, X_2, \dots, X_n)$  o wartościach w  $\mathbb{R}^n$  nazywamy wektor

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

o ile wszystkie współrzędne wektora  $X$  mają wartości oczekiwane.

**9.7 Własności wartości oczekiwanej**

Niech  $X, Y$  i  $\{X_n : n \geq 1\}$  będą zmiennymi losowymi o wartościach oczekiwanych odpowiednio równych  $EX, EY$  i  $\{EX_n, n \geq 1\}$ .

Wtedy:

1. Jeżeli  $X \geq 0$ , to  $EX \geq 0$
2.  $|EX| \leq E|X|$
3.  $E(aX + b) = aEX + b$
4. Jeżeli  $X_n \geq 0$ , to  $E(\liminf_{n \rightarrow \infty} X_n) \leq \liminf_{n \rightarrow \infty} EX_n$

5. Jeżeli  $\{X_n, n \geq 1\}$  jest niemalejącym ciągiem nieujemnych zmiennych losowych, to  $E\left(\lim_{n \rightarrow \infty} X_n\right) = \lim_{n \rightarrow \infty} EX_n$  (tw. Lebesgue'a o zbieżności monotonicznej)
6. Jeżeli  $\{X_n, n \geq 1\}$  jest ciągiem zmiennych losowych takich, że

$$|X_n| \leq Z$$

dla pewnej całkowlanej zmiennej losowej  $Z$ , to

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

(tw. Lebesgue'a o zbieżności zmajoryzowanej)

### Przykład 9.2: rozkład dyskretny

$$X : \{(x_i, p_i) : i \in I\}$$

$$P[X = -1] = P[X = 1] = \frac{1}{4} \text{ oraz } P[X = 0] = \frac{1}{2}$$

$$\left\{(-1, \frac{1}{4}), (0, \frac{1}{2}), (1, \frac{1}{4})\right\}$$

$$EX = -1 \cdot \frac{1}{4} + 0 \cdot \frac{1}{2} + 1 \cdot \frac{1}{4} = 0$$

$$Y = 2X + 5$$

$p_i$	$Y$
$\frac{1}{4}$	3
$\frac{1}{2}$	5
$\frac{1}{4}$	7

$$EY = 3 \cdot \frac{1}{4} + 5 \cdot \frac{1}{2} + 7 \cdot \frac{1}{4} = 5$$

$$EY = E(2X + 5) = 2 \cdot EX + 5 = 2 \cdot 0 + 5 = 5$$

$$P[Y = 3] = P[2X + 5 = 3] = P[X = -1] = \frac{1}{4}$$

**Przykład 9.3: rozkład ciągły**

$$f(x) = \begin{cases} 0, & x < 0 \\ \frac{1}{2}, & 0 \leq x \leq 2 \\ 0, & x > 2 \end{cases}$$

$$EX = \int_{-\infty}^{\infty} xf(x)dx = \int_{-\infty}^0 \underbrace{xf(x)}_0 dx + \int_0^2 \underbrace{xf(x)}_{\frac{1}{2}} dx + \int_2^{\infty} \underbrace{xf(x)}_0 dx = \dots = 1$$

**Twierdzenie 9.4**

Niech

- $\varphi : \mathbb{R}^n \rightarrow \mathbb{R}$  będzie funkcją borelowską
- $X$  – zmienna losowa typu ciągłego o wartościach w  $\mathbb{R}^n$

Wtedy

$$E_{\varphi}(X) = \int_{\mathbb{R}^n} \varphi(x)f(x)dx$$

gdzie  $f(x)$  jest funkcją gęstości prawdopodobieństwa i  $x = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$

**Twierdzenie 9.5**

Jeżeli zmienna losowa  $X$  ma rozkład dyskretny  $\{(x_i, p_i), i \in I\}$ , to wartość oczekiwana zmiennej losowej  $Y = \varphi(X)$  istnieje wtw, gdy zbieżny jest szereg

$$\sum_{i \in I} |\varphi(x_i)|p_i < \infty$$

i wyraża się wzorem

$$E_{\varphi}(X) = \sum_{i \in I} \varphi(x_i)p_i$$

**9.8 Wariancja**

Wariancja jest miarą rozrzutu wartości zmiennej wokół wartości średniej (wartości oczekiwanej)

Niech  $X$  będzie zmienną losową o wartościach rzeczywistych.

Jeżeli  $E(X - EX)^2 < \infty$ , to liczbę tę nazywamy **wariancją** zmiennej losowej  $X$  i oznaczamy symbolem

$D^2(X)$  lub  $\text{Var}(X)$

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

### Achtung! 8

Warunkiem koniecznym istnienia wariancji jest istnienie wartości oczekiwanej  $EX$  zmiennej losowej  $X$

### 9.8.1 Własności wariancji

Jeżeli  $X$  jest zmienną losową, dla której  $EX^2 < \infty$ , to istnieje wariancja  $D^2(X)$  oraz

- 1)  $D^2(X) = E(X^2) - (EX)^2$
- 2)  $D^2(X) \geq 0$
- 3)  $\bigwedge_{c \in \mathbb{R}} D^2(cX) = c^2 D^2(X)$
- 4)  $\bigwedge_{x \in \mathbb{R}} D^2(X + a) = D^2(X)$
- 5)  $D^2(X) = 0 \iff \bigvee_{c \in \mathbb{R}} P(X = c) = 1$

### Dowód 9.1

- 1) Na mocy założenia  $EX^2 < \infty$  i nierówności

$$|t| < t^2 + 1$$

mamy

$$|EX| \leq E|X| < EX^2 + 1 < \infty$$

Zatem wartość oczekiwana istnieje i spełniony jest warunek konieczny istnienia wariancji

$$\begin{aligned} D^2(X) &= E(X - EX)^2 \\ &= E(X^2 - 2XEX + (EX)^2) \\ &= EX^2 - 2(EX)^2 + (EX)^2 \\ &= EX^2 - (EX)^2 < \infty \end{aligned}$$

co dowodzi istnienia wariancji i prawdziwości (1)

2)

$$(X - EX)^2 \geq 0 \implies E(X - EX)^2 \geq 0 \iff D^2(X) \geq 0$$

3)

$$\begin{aligned} D^2(cX) &= E(cX - E(cX))^2 \\ &= E(cx - cEX)^2 \\ &= E(c^2(X - EX)^2) \\ &= c^2 E(X - EX)^2 \end{aligned}$$

4)

$$\begin{aligned} D^2(X + a) &= E(X + a - E(X + a))^2 \\ &= E(X + a - EX - a)^2 \\ &= E(X - EX)^2 \\ &= D^2(X) \end{aligned}$$

5)

$$\begin{aligned} D^2(X) = 0 &\iff E(X - EX)^2 = 0 \\ &\iff P(X - EX = 0) = 1 \\ &\iff P(X = EX) = 1 \end{aligned}$$

Wtedy  $c = EX$  i mamy

$$P(X = c) = 1$$

### 9.8.2 Odchylenie standardowe

**Odchyleniem standardowym zmiennej  $X$  o wariancji  $D^2(X)$**  nazywamy liczbę  $D(X) = \sigma_X$  zdefiniowaną następująco:

$$D(X) = \sigma_X = \sqrt{D^2(X)}$$

### 9.8.3 Wyznaczanie wariancji i odchylenia standardowego

- dla rozkładu dyskretnego  $\{(x_i, p_i), i \in I\}$ :

$$D^2(X) = \sum_{i \in I} (x_i - EX)^2 p_i = \sum_{i \in I} x_i^2 p_i - \left( \sum_{i \in I} x_i p_i \right)^2,$$

- dla rozkładu ciągłego (jednowymiarowego) z funkcją gęstości  $f$

$$D^2(X) = \int_{-\infty}^{\infty} (x - EX)^2 f(x) dx = \int_{-\infty}^{\infty} x^2 f(x) dx - \left( \int_{-\infty}^{\infty} x f(x) dx \right)^2$$

## 9.9 Momenty zwykłe i absolutne

**Momentem zwykłym rzędu  $r > 0$  zmiennej  $X$**  nazywamy liczbę

$$EX^r$$

**Momentem absolutnym rzędu  $r > 0$  zmiennej  $X$**  nazywamy liczbę

$$E|X|^r$$

pod warunkiem, że wartości oczekiwane istnieją.

## 9.10 Momenty centralne

- $E(X - EX)^r$  – moment zwykły centralny rzędu  $r > 0$
- $E|X - EX|^r$  – moment absolutny centralny rzędu  $r > 0$

### 9.10.1 Interpretacja fizyczna

- Rozkład prawdopodobieństwa - rozkład masy jednostkowej (rozkład dyskretny), zwykła gęstość (gęstość rozkładu ciągłego)
- Wartość oczekiwana  $EX$  – położenie środka ciężkości
- Wariancja  $D^2(X)$  – moment bezwładności względem środka masy
- Momenty wyższych rzędów – wykorzystywane w statystyce do mierzenia:
  - asymetrii rozkładu (skośności)
  - stopnia koncentracji rozkładu wokół średniej (kurtoza)

## 9.11 Skośność i koncentracja rozkładu

- współczynnik asymetrii (skośność):

$$\alpha_3 = \frac{E(X - EX)^3}{(D^2(X))^{\frac{3}{2}}} = \frac{E(X - EX)^3}{\sigma_X^3}$$

- współczynnik spłaszczenia (kurtoza):

$$\alpha_4 = \frac{E(X - EX)^4}{(D^2(X))^2} = \frac{E(X - EX)^4}{\sigma_X^4}$$

## 9.12 Mediana zmiennej losowej

Medianą zmiennej losowej  $X$  nazywamy liczbę oznaczaną symbolem  $Me$  zdefiniowaną następującym wzorem

$$P[X \leq Me] \geq \frac{1}{2} \quad \text{i} \quad P[X \geq Me] \geq \frac{1}{2}$$

Dla rozkładu zmiennej losowej typu ciągłego o gęstości  $f(x)$  medianę wyznaczamy ze wzoru

$$\int_{-\infty}^{Me} f(x) dx = \frac{1}{2} \quad \text{lub} \quad \int_{Me}^{\infty} f(x) dx = \frac{1}{2}$$

Widać, że jak zsumujemy lewą i prawą całkę, to dostaniemy  $\int_{-\infty}^{\infty} f(x) dx = 1$

### Achtung! 9

- Mediana istnieje dla każdej zmiennej losowej, ale może nie być wyznaczona w sposób jednoznaczny
- Mediana jest jednym z parametrów służącym do charakteryzowania położenia środka rozkładu zmiennej losowej

## 9.13 Moda zmiennej losowej

**Modą (dominantą)  $M_o$  zmiennej losowej typu skokowego** nazywamy tę wartość zmiennej losowej  $X$ , która przyjmuje ona z największym prawdopodobieństwem, pod warunkiem, że nie jest to jej wartość najmniejsza ani największa

**Modą (dominantą)  $M_o$  zmiennej losowej typu ciągłego** nazywamy odciętą ekstremum maximum gęstości  $f$  zmiennej losowej

### Achtung! 10

- Istnieją rozkłady prawdopodobieństwa, które nie mają mody
- Istnieją rozkłady prawdopodobieństwa, które mają więcej niż jedną modę – nazywamy je rozkładami wielomodalnymi

2024-11-12

## 10 Przegląd wybranych dyskretnych rozkładów prawdopodobieństwa

### 10.1 Rozkład jednopunktowy

Zmienna losowa  $X$  ma rozkład **jednopunktowy**, jeżeli istnieje stała  $c \in \mathbb{R}$ , dla której  $P[X = c] = 1$

#### 10.1.1 Wartość oczekiwana

Wtedy  $EX = c \cdot 1 = c$ , oraz moment rzędu drugiego  $E(X^2) = c^2$

Wariancja  $D^2(X) = EX^2 - (EX)^2 = 0$ , oraz mediana  $Me = c$

Dystrybuanta tej zmiennej losowej dana jest wzorem

$$F(x) = \begin{cases} 0, & x < c \\ 1, & c \leq x \end{cases}$$

### 10.2 Rozkład dwupunktowy

Zmienna losowa  $X$  ma rozkład dwupunktowy, gdy istnieją stałe  $c_1, c_2 \in \mathbb{R}$  dla których

$$P[X = c_1] = p_1 \quad P[X = c_2] = p_2$$

$$0 < p_1 < 1 \quad 0 < p_2 < 1 \quad p_1 + p_2 = 1$$

#### 10.2.1 Rozkład zero-jedynkowy

Szczególny przypadek rozkładu dwupunktowego

W przypadku, gdy  $c_1 = 0, c_2 = 1$

oraz  $p_1 = q, p_2 = p$

rozkład ten przyjmuje postać

$$P[X = 1] = p, \quad P[X = 0] = q = 1 - p$$

**Wartość oczekiwana**

$$EX = 1 \cdot p + 0 \cdot q = p$$

$$EX^2 = 1^2 \cdot p + 0^2 \cdot q = p$$

$$D^2(X) = p - p^2 = pq$$

**Dystrybuanta**

$$F(x) = \begin{cases} 0, & x < 0 \\ q, & 0 \leq x < 1 \\ 1, & 1 \leq x \end{cases}$$

**10.3 Rozkład dwumianowy**

Zmienna losowa  $X$  ma rozkład dwumianowy ( $\mathcal{B}(n, p)$ ) (zwany także rozkładem Bernoulliego), jeżeli jej funkcja prawdopodobieństwa ma następującą postać:

$$P[X = k] = \binom{n}{k} p^k q^{n-k}, \quad k \in \{0, 1, \dots, n\}$$

gdzie  $n$  jest pewną liczbą naturalną,  $0 < p < 1$ ,  $q = 1 - p$

$$(x_k, p_k)_{k \in \{0, 1, \dots, n\}}, \text{ gdzie } x_k = k, p_k = \binom{n}{k} p^k q^{n-k}$$

**10.3.1 Jak rozpoznać rozkład dwumianowy**

Dokonujemy  $n$  niezależnych doświadczeń losowych:

- zbiór zdarzeń elementarnych w każdym z tych doświadczeń jest dwuelementowy  $\Omega = \{\omega_1, \omega_2\}$
- wyróżniamy jedno z tych zdarzeń elementarnych i nazywamy je “sukcesem”, a drugie “porażką”
- prawdopodobieństwo “sukcesu” w każdym doświadczeniu jest jednakowe i wynosi  $p$
- zmienna losowa  $X$  wyraża liczbę sukcesów w ciągu  $n$  niezależnych doświadczeń losowych

**10.3.2 wartość oczekiwana**

$$\begin{aligned}
EX &= \sum_{k=0}^n k \binom{n}{k} p^k q^{n-k} \\
&= \sum_{k=1}^n k \cdot \frac{n!}{k! \cdot (n-k)!} p^k q^{n-k} \\
&= np \sum_{k=1}^n \frac{(n-1)!}{(k-1)! (n-k)!} p^{k-1} q^{n-k} \text{ | podstawiamy } i = k-1 \\
&= np \cdot \sum_{i=0}^{n-1} \frac{(n-1)!}{i! \cdot (n-1-i)!} p^i q^{n-1-i} \\
&= np(p+q)^{n-1} \\
&= np
\end{aligned}$$

**10.3.3 Wariancja**

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

$$\begin{aligned}
E(X^2) &= \sum_{k=0}^n k^2 \binom{n}{k} p^k q^{n-k} \\
&= \sum_{k=1}^n \binom{n}{k} k^2 p^k q^{n-k} \\
&= \sum_{k=1}^n k \frac{n!}{(k-1)! \cdot (n-k)!} p^k q^{n-k} \\
&\stackrel{\text{niech } i:=k-1}{=} \sum_{i=0}^{n-1} (i+1) \frac{n!}{i! (n-1-i)!} p^{i+1} q^{n-1-i} \\
&= \sum_{i=0}^n i \cdot \frac{n!}{i! (n-1-i)!} p^{i+1} q^{n-1-i} + \sum_{i=0}^n \frac{n!}{i! (n-1-i)!} p^{i+1} q^{n-1-i} \\
&= np \sum_{i=0}^{n-1} i \frac{(n-1)!}{i! (n-1-i)!} p^i q^{n-1-i} + np \sum_{i=0}^{n-1} \frac{(n-1)!}{i! (n-1-i)!} p^i q^{n-1-i} \\
&= np \sum_{i=0}^{n-1} i \binom{n-1}{i} p^i q^{n-1-i} + np \sum_{i=0}^{n-1} \binom{n-1}{i} p^i q^{n-1-i} \\
&= np(n-1)p + np(p+q)^{n-1} \\
&= n^2 p^2 - np^2 + np
\end{aligned}$$

$$E(X^2) = n^2 p^2 - np^2 + np$$

$$\begin{aligned}
 D^2(X) &= E(X^2) - (EX)^2 \\
 &= n^2 p^2 - np^2 + np - (np)^2 \\
 &= np - np^2 \\
 &= np(1 - p) = npq
 \end{aligned}$$

## 10.4 Rozkład Poissona<sup>2</sup>

Zmienna losowa  $X$  ma rozkład Poissona  $\mathcal{P}(\lambda)$ , jeżeli jej funkcja prawdopodobieństwa, jeżeli jej funkcja prawdopodobieństwa jest następująca

$$P[X = k] = e^{-\lambda} \frac{\lambda^k}{k!}, \quad k \in \{0, 1, \dots\}$$

gdzie  $\lambda > 0$

$$\sum_{k=0}^{\infty} \frac{\lambda^k}{k!} = e^{\lambda}, \quad \text{zatem} \quad \sum_{k=0}^{\infty} P[X = k] = 1$$

$$\begin{aligned}
 \sum_{k=0}^{\infty} P[X = k] &= \sum_{k=0}^{\infty} e^{-\lambda} \frac{\lambda^k}{k!} \\
 &= e^{-\lambda} \sum_{k=0}^{\infty} \frac{\lambda^k}{k!} \\
 &= e^{-\lambda} e^{\lambda} \\
 &= 1
 \end{aligned}$$

### 10.4.1 Wartość oczekiwana

$$\begin{aligned}
 EX &= \sum_{k=0}^{\infty} k \cdot e^{-\lambda} \frac{\lambda^k}{k!} \\
 &= e^{-\lambda} \lambda \sum_{k=1}^{\infty} \frac{\lambda^{k-1}}{(k-1)!} \quad \text{niech } i := k - 1 \\
 &= e^{-\lambda} \lambda \sum_{i=0}^{\infty} \frac{\lambda^i}{i!} \\
 &= e^{-\lambda} \lambda e^{\lambda} \\
 &= \lambda
 \end{aligned}$$

---

<sup>2</sup>/ptasona/

**10.4.2 Wariancja**

$$\begin{aligned}
E(X^2) &= \sum_{k=0}^{\infty} k^2 \cdot e^{-\lambda} \frac{\lambda^k}{k!} \\
&= \lambda e^{-\lambda} \sum_{k=1}^{\infty} k(k-1+1) \frac{\lambda^{k-1}}{k!} \\
&= \lambda e^{-\lambda} \sum_{k=1}^{\infty} k(k-1) \frac{\lambda^{k-1}}{k!} + \lambda e^{-\lambda} \sum_{k=1}^{\infty} k \frac{\lambda^{k-1}}{k!} \\
&= \lambda e^{-\lambda} \sum_{k=1}^{\infty} (k-1) \frac{\lambda^{k-1}}{(k-1)!} + \underbrace{\lambda e^{-\lambda} \sum_{k=1}^{\infty} \frac{\lambda^{k-1}}{(k-1)!}}_{\lambda} \\
&= e^{-\lambda} \lambda \sum_{k=2}^{\infty} (k-1) \cdot \frac{\lambda^{k-1}}{(k-1)!} + \lambda \\
&= e^{-\lambda} \lambda \sum_{k=2}^{\infty} \frac{\lambda^{k-1}}{(k-2)!} + \lambda \\
&= e^{-\lambda} \lambda^2 \sum_{k=2}^{\infty} \frac{\lambda^{k-2}}{(k-2)!} + \lambda \\
&= e^{-\lambda} \lambda^2 \sum_{j=0}^{\infty} \frac{\lambda^j}{(j)!} + \lambda \\
&= e^{-\lambda} \lambda^2 e^{\lambda} + \lambda \\
&= \lambda^2 + \lambda
\end{aligned}$$

Zatem

$$D^2(X) = \underbrace{\lambda^2 + \lambda}_{E(X^2)} - \underbrace{\lambda^2}_{(EX)^2} = \lambda$$

**10.5 Związek rozkładu Bernoulliego i rozkładu Poissona**

Jeżeli zmienna losowa  $X_n$  ma rozkład dwumianowy  $\mathcal{B}(n, p_n)$ :

$$P[X_n = k] = \binom{n}{k} p_n^k q_n^{n-k}, \quad k \in \{0, 1, \dots, n\}$$

przy czym  $\lim_{n \rightarrow \infty} np_n = \lambda < \infty$

$$\lim_{n \rightarrow \infty} P[X_n = k] = e^{-\lambda} \frac{\lambda^k}{k!}$$

Twierdzenie to, dla dostatecznie dużej liczby doświadczeń, pozwala traktować rozkład Bernoulliego jako rozkład w przybliżeniu Poissona z parametrem  $\lambda = np$

$$P[X_n = k] \approx e^{-\lambda} \frac{\lambda^k}{k!}$$

## 10.6 Rozkład geometryczny

Zmienna losowa  $X$  ma rozkład geometryczny, jeżeli jej funkcja prawdopodobieństwa jest następująca

$$P[X = k] = (1 - p)^{k-1} p \quad k \in \mathbb{N}_+$$

gdzie  $0 < p < 1$  i  $q = 1 - p$

### Achtung! 11

- Jest to rozkład czasu oczekiwania na pierwszy sukces w ciągu doświadczeń Bernoulliego
- ma własność “braku pamięci”
- jego odpowiednikiem ciągłym jest rozkład wykładniczy

### 10.6.1 Wartość oczekiwana

$$\begin{aligned} EX &= \sum_{k=1}^{\infty} k \cdot P[X = k] \\ &= \sum_{k=1}^{\infty} k \cdot (1 - p)^{k-1} p \\ &= \sum_{k=1}^{\infty} k \cdot q^{k-1} p \\ &= p \sum_{k=1}^{\infty} k \cdot q^{k-1} \end{aligned}$$

$$p(1 + q + q^2 + \dots) = \frac{p}{1 - q} \quad \text{różniczkujemy po } q$$

$$p + 2pq + 3pq^2 + \dots = \frac{p}{(1 - q)^2} = \frac{p}{p^2} = \frac{1}{p}$$

Zatem

$$EX = \sum_{k=1}^{\infty} kq^{k-1}p = p + 2pq + 3pq^2 + \dots = \frac{1}{p}$$

### 10.6.2 Wariancja

$$\begin{aligned} EX^2 &= \sum_{k=1}^{\infty} k^2 P[X = k] \\ &= \sum_{k=1}^{\infty} k^2 (1-p)^{k-1} p \\ &= \sum_{k=1}^{\infty} k^2 q^{k-1} p \end{aligned}$$

$$p + pq + 3pq^2 + \dots = \frac{p}{(1-q)^2} \quad \text{mnożymy obustronnie przez } q$$

$$pq + 2pq^2 + 3pq^3 + \dots = \frac{pq}{(1-q)^2} \quad \text{różniczkujemy po } q$$

$$p + 2^2pq + 3^2pq^2 + \dots = \frac{p(1-q)^2 + 2(1-q)pq}{(1-q)^4} = \frac{p(1-q^2)}{(1-q)^4}$$

Zatem

$$EX^2 = \frac{p(1-q^2)}{p^4} = \frac{1-q^2}{p^3}$$

Na końcu mamy wariancję

$$\begin{aligned} D^2(X) &= E(X^2) - (EX)^2 \\ &= \frac{1-q^2}{p^3} - \frac{1}{p^2} \\ &= \frac{1-p}{p^2} \\ &= \frac{q}{p^2} \end{aligned}$$

**Achtung! 12**

Czasami rozkład geometryczny jest definiowany następująco:

$$P[X = k] = (1 - p)^k p, \quad k \in \mathbb{N}$$

gdzie  $p \in (0, 1)$  i  $q = 1 - p$

$$EX = \frac{1}{p} - 1 = \frac{q}{p}$$

**10.7 Rozkład ujemnie dwumianowy**

Zmienna losowa  $X$  ma rozkład ujemnie dwumianowy, jeżeli jej funkcja prawdopodobieństwa jest następująca

$$P[X = k] = \binom{r + k - 1}{k} (1 - p)^k p^r, \quad k \in \mathbb{N}$$

gdzie  $p \in (0, 1)$  i  $r > 0$

Nazwa rozkładu nawiązuje do zależności

$$\begin{aligned} \binom{r + k - 1}{k} &= (-1)^k \binom{-r}{k} \\ &= (-1)^k \cdot \frac{r(r-1) \dots (r-k+1)}{k!} \end{aligned}$$

**Achtung! 13**

- Jeżeli  $r$  jest liczbą całkowitą, to wyraża ona czas oczekiwania na  $m$ -ty sukces w ciągu prób Bernoulliego - **rozkład Pascala**
- $X$  - liczba porażek poprzedzających  $r$ -ty sukces - **rozkład Pascala**
- Dla  $r = 1$  otrzymujemy **rozkład geometryczny**

**10.7.1 parametry**

- Wartość oczekiwana:

$$EX = \frac{r(1-p)}{p} = \frac{rq}{p}$$

- Wariancja

$$D^2(X) = \frac{r(1-p)}{p^2} = \frac{rq}{p^2}$$

## 10.8 Rozkład hipergeometryczny

Zmienna losowa  $X$  ma rozkład hipergeometryczny, jeżeli jej funkcja prawdopodobieństwa jest następująca

$$P[X = k] = \frac{\binom{n}{k} \binom{m-n}{r-k}}{\binom{m}{r}}$$

gdzie  $\max(0, n + r - m) \leq k \leq \min(n, r)$

$$\begin{array}{ll} \binom{n}{k} & 0 \leq k \leq n \\ \binom{m-n}{r-k} & 0 \leq r-k \leq m-n \implies n-m+r \leq k \leq r \\ \binom{m}{r} & 0 \leq r \leq m \end{array}$$

Zatem  $\max(0, n - m + r) \leq k \leq \min(n, r)$

### 10.8.1 Interpretacja

Z populacji  $m$  elementów, gdzie  $n$  są wyróżnione wybieramy  $r$  elementów, przy czym chcemy żeby  $k$  były wyróżnione. Zmienna  $X$  wyraża liczbę wyróżnionych elementów w próbie

$$|\Omega| = \binom{m}{r} \quad |A_k| = \binom{n}{k} \binom{m-n}{r-k}$$

Zatem  $P[X = k] = P(A_k) = \frac{|A_k|}{|\Omega|} = \frac{\binom{n}{k} \binom{m-n}{r-k}}{\binom{m}{r}}$

### 10.8.2 Parametry

$$0 \leq n \leq m \quad 0 \leq r \leq m$$

- wartość oczekiwana:

$$EX = \frac{nr}{m}$$

- wariancja:

$$D^2(X) = \frac{nr(m-r)(m-n)}{m^2(m-1)}$$

### 10.9 Tabela rozkładów dyskretnych i ich parametrów

Nazwa	Wzór	$EX$	$D^2(X)$
Rozkład jednopunktowy	$P[X = c] = 1$	$c$	$0$
Rozkład dwupunktowy	$P[X = c_1] = p_1$ $P[X = c_2] = p_2$ $p_1 + p_2 = 1$	$p_1c_1 + p_2c_2$	$p_1p_2(c_1 - c_2)^2$
Rozkład zero-jedynkowy	$P[X = 0] = 1 - p$ $P[X = 1] = p$	$p$	$p - p^2$
Rozkład dwumianowy $\mathcal{B}(n, p)$	$P[X = k] = \binom{n}{k} p^k (1 - p)^{n-k}$	$np$	$np(1 - p)$
Rozkład Poissona $\text{Pois}(\lambda)$	$P[X = k] = e^{-\lambda} \frac{\lambda^k}{k!}$	$\lambda$	$\lambda$
Rozkład geometryczny	$P[X = k] = (1 - p)^{k-1} p$	$\frac{1}{p}$	$\frac{1-p}{p^2}$
Rozkład ujemnie dwumianowy	$P[X = k] = \binom{r+k-1}{k} (1 - p)^k p^r$	$\frac{r(1-p)}{p}$	$\frac{r(1-p)}{p^2}$
Rozkład hipergeometryczny	$P[X = k] = \frac{\binom{n}{k} \binom{m-n}{r-k}}{\binom{m}{r}}$	$\frac{nr}{m}$	$\frac{nr(m-r)(m-n)}{m^2(m-1)}$


2024-11-19

## 11 Rozkłady ciągłe

### 11.1 Rozkład jednostajny

Zmienna  $X$  ma rozkład jednostajny (prostokątny/równomierny) w przedziale skończonym  $\langle a, b \rangle$  (lub  $(a, b)$ ,  $[a, b)$ ,  $(a, b]$ ), jeżeli ma gęstość  $f(x)$  określoną wzorem

$$f(x) = \begin{cases} 0, & x < a \\ \frac{1}{b-a}, & a \leq x \leq b \\ 0, & b < x \end{cases}$$



**Rysunek 2:** Wykres funkcji gęstości<sup>3</sup>

dla  $(a, b)$  gęstość rozkładu jednostajnego ma postać  $f(x) = \begin{cases} 0, & x \leq a \\ \frac{1}{b-a}, & a < x < b \\ 0, & x \leq b \end{cases}$

#### 11.1.1 Dystrybuanta

Dla  $a \leq x < b$  mamy

<sup>3</sup><https://www.desmos.com/calculator/1hj8epygth>

$$\begin{aligned}
 F(x) &= \int_{-\infty}^x f(x)dx \\
 &= \int_{-\infty}^a f(x)dx + \int_a^x f(x)dx \\
 &= 0 + x \cdot \frac{1}{b-a} \\
 &= \frac{x}{b-a} \Big|_a^x \\
 &= \frac{x-a}{b-a}
 \end{aligned}$$


Dla  $x < a$ :

$$F(x) = \int_{-\infty}^x f(x)dx = 0$$

Dla  $b < x$ :

$$F(x) = \int_{-\infty}^x f(x)dx = \dots = 1$$

Zatem ostatecznie 
$$F(x) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x < b \\ 1, & b \leq x \end{cases}$$



**Rysunek 3:** Wykres dystrybuanty<sup>4</sup>

<sup>4</sup><https://www.desmos.com/calculator/1hj8epygtb>

**11.1.2 Wartość oczekiwana**

$$\begin{aligned} EX &= \int_{-\infty}^{\infty} xf(x)dx \\ &= \int_a^b \frac{x}{b-a} dx \\ &= \frac{x^2}{2(b-a)} \Big|_a^b \\ &= \frac{a+b}{2} \end{aligned}$$

**11.1.3 Drugi moment zwykły**

$$\begin{aligned} E(X^2) &= \int_{-\infty}^{\infty} x^2 f(x) dx \\ &= \int_a^b \frac{x^2}{b-a} dx \\ &= \frac{x^3}{3(b-a)} \Big|_a^b \\ &= \frac{a^2 + ab + b^2}{3} \end{aligned}$$

**11.1.4 Wariancja**

$$D^2(X) = E(X^2) - (EX)^2 = \frac{a^2 + ab + b^2}{3} - \left(\frac{a+b}{2}\right)^2 = \frac{(b-a)^2}{12}$$

**11.1.5 Mediana**

$$\text{Me} = \frac{a+b}{2}$$


**11.1.6 Dominanta**

Rozkład jednostajnie ciągły nie ma dominanty.

**11.2 Rozkład wykładniczy**

Zmienna  $X$  ma rozkład wykładniczy z parametrem  $\lambda > 0$ , jeżeli ma gęstość prawdopodobieństwa  $f(x)$  określoną wzorem

$$f(x) = \begin{cases} 0, & x \leq 0 \\ \lambda e^{-\lambda x}, & 0 < x \end{cases}$$




**Rysunek 4:** Wykres funkcji gęstości<sup>5</sup>

### 11.2.1 Dystrybuanta

$$F(x) = \int_{-\infty}^x f(x)dx = \begin{cases} \int_{-\infty}^x 0dx, & x < 0 \\ \int_0^x \lambda x^{-\lambda x} dx, & 0 \leq x \end{cases} = \begin{cases} 0, & x < 0 \\ -e^{-\lambda x} \Big|_0^x, & 0 \leq x \end{cases} = \begin{cases} 0, & x < 0 \\ 1 - e^{-\lambda x}, & 0 \leq x \end{cases}$$

<sup>5</sup><https://www.desmos.com/calculator/nyv0n0b128>



Rysunek 5: Wykres dystrybuanty<sup>6</sup>

### 11.2.2 Wartość oczekiwana

$$\begin{aligned}
 EX &= \int_{-\infty}^{\infty} x f(x) dx \\
 &= \int_0^{\infty} \lambda x e^{-\lambda x} dx \\
 &= -x e^{-\lambda x} \Big|_0^{\infty} + \int_0^{\infty} e^{-\lambda x} dx \\
 &= -\frac{e^{-\lambda x}}{\lambda} \Big|_0^{\infty} \\
 &= \frac{1}{\lambda}
 \end{aligned}$$

### 11.2.3 Drugi moment zwykły

$$\begin{aligned}
 E(X^2) &= \int_{-\infty}^{\infty} x^2 f(x) dx \\
 &= \int_0^{\infty} \lambda x^2 e^{-\lambda x} dx \\
 &= -x^2 e^{-\lambda x} \Big|_0^{\infty} + \frac{2}{\lambda} \int_0^{\infty} \lambda x e^{-\lambda x} dx \\
 &= \frac{2}{\lambda^2}
 \end{aligned}$$

<sup>6</sup><https://www.desmos.com/calculator/nyv0n0b128>

### 11.2.4 Wariancja

$$D^2(X) = E(X^2) - (EX)^2 = \frac{2}{\lambda^2} - \frac{1}{\lambda^2} = \frac{1}{\lambda^2}$$

### 11.2.5 Zastosowania

Rozkład wykładniczy ma zastosowanie do pewnych zagadnień praktycznych

- czas świecenia żarówki,
- czas niezawodnego działania urządzeń elektrycznych można traktować jako zmienną losową o rozkładzie wykładniczym.


### 11.3 Rozkład gamma

Zmienna  $X$  ma rozkład gamma z parametrami  $b, p > 0$   $\Gamma(b, p)$ , jeżeli jej gęstość prawdopodobieństwa dana jest wzorem:

$$f(x) = \begin{cases} 0, & x \leq 0 \\ \frac{b^p}{\Gamma(p)} x^{p-1} e^{-bx}, & 0 < x \end{cases}$$

gdzie

- $\Gamma(p) = \int_0^{\infty} x^{p-1} e^{-x} dx$
- $p$  – parametr kształtu
- $b$  – parametr skali



**Rysunek 6:** Wykres funkcji gęstości <sup>7</sup>

**Achtung! 14**

- Funkcja  $\Gamma(p)$  jest uogólnieniem znanego pojęcia funkcji silnia:  $n \mapsto n!$
- $\Gamma(p+1) = p\Gamma(p)$ , bo np. odpowiednio  $(n+1)! = n \cdot n!$
- $\int_0^\infty x^{p-1} e^{-bx} dx = \frac{\Gamma(p)}{b^p}$

**11.3.1 Dystrybuanta**

Nie wyliczymy jej dla wszystkich parametrów

**11.3.2 Wartość oczekiwana**

$$\begin{aligned}
 EX &= \int_{-\infty}^{\infty} x f(x) dx \\
 &= \int_0^{\infty} \frac{b^p}{\Gamma(p)} x^p e^{-bx} dx \\
 &= \frac{\Gamma(p+1)}{b \cdot \Gamma(p)} \int_0^{\infty} \underbrace{\frac{b^{p+1}}{\Gamma(p+1)} x^p e^{-bx}}_{\text{gęstość rozkładu } \Gamma(b, p+1)} dx \\
 &= \frac{p \cdot \Gamma(p)}{b \cdot \Gamma(p)} \cdot 1 \\
 &= \frac{p}{b}
 \end{aligned}$$

**11.3.3 Drugi moment zwykły**

$$\begin{aligned}
 E(X^2) &= \int_{-\infty}^{\infty} x^2 f(x) dx \\
 &= \int_0^{\infty} \frac{b^p}{\Gamma(p)} x^{p+1} e^{-bx} dx \\
 &= \frac{\Gamma(p+2)}{b^2 \cdot \Gamma(p)} \int_0^{\infty} \underbrace{\frac{b^{p+2}}{\Gamma(p+2)} x^{p+1} e^{-bx}}_{\text{gęstość rozkładu } \Gamma(b, p+2)} dx \\
 &= \frac{(p+1)p \cdot \Gamma(p)}{b^2 \cdot \Gamma(p)} \cdot 1 \\
 &= \frac{p^2 + p}{b^2}
 \end{aligned}$$

<sup>7</sup><https://www.desmos.com/calculator/pnccznwdt>


### 11.3.4 Wariancja

$$D^2(X) = E(X^2) - (EX)^2 = \frac{p^2 + p}{b^2} - \frac{p^2}{b^2} = \frac{p}{b^2}$$

### 11.4 Rozkład Cauchy'ego

Zmienna  $X$  ma rozkład Cauchy'ego z parametrami  $a > 0, m \in \mathbb{R}$ , jeśli funkcja gęstości dana jest wzorem

$$f(x) = \frac{1}{\pi(a^2 + (x - m)^2)}$$



**Rysunek 7:** Wykres funkcji gęstości <sup>8</sup>

- Postać standardowa - gdy  $a = 1, m = 0$

$$f(x) = \frac{1}{\pi(1 + x^2)}$$


- Momenty: wartość oczekiwana, wariancja i momenty wyższych rzędów nie istnieją

<sup>8</sup><https://www.desmos.com/calculator/k7em2gm1st>

## 11.5 Rozkład normalny

Zmienna losowa  $X$  ma rozkład normalny  $N(\mu, \sigma)$  z parametrami  $\mu \in \mathbb{R}$  i  $\sigma \in \mathbb{R}_+$ , jeżeli ma gęstość prawdopodobieństwa  $f(x)$  określoną wzorem

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



**Rysunek 8:** Wykres funkcji gęstości<sup>9</sup>

### 11.5.1 Uwagi

- Badając tę funkcję metodami rachunku różniczkowego mamy:
  - 1) funkcja  $f(x)$  osiąga maksimum w punkcie  $x = \mu$
  - 2) oś  $x$  jest asymptotą funkcji  $f(x)$  gdy  $x$  dąży do  $-\infty$  lub  $+\infty$
  - 3)  $f(x)$  posiada punkty przegięcia w punktach:  $x = \mu - \sigma$  i  $x = \mu + \sigma$
  - 4) krzywa  $f(x)$  jest symetryczna względem prostej  $x = \mu$
- Badając krzywe  $f(x)$  przy różnych wartościach parametru  $\sigma$  stwierdzamy, że im  $\sigma$  jest większe tym krzywa jest bardziej spłaszczona
- Parametr  $\sigma$  jest miarą rozproszenia (odchyleniem standardowym) wartości zmiennej losowej  $X$  wokół wartości  $x = \mu$  (wartości średniej)

<sup>9</sup><https://www.desmos.com/calculator/ykoq0sgvgl>

- Obliczając parametry tego rozkładu skorzystamy z następującego wzoru

$$\int_{-\infty}^{\infty} e^{-\frac{1}{2}x^2} dx = \sqrt{2\pi}$$

### 11.5.2 Wartość oczekiwana

Niech  $z = \frac{x-\mu}{\sigma}$ ,  $dx = \sigma dz$ ,  $\begin{cases} x = -\infty & \Rightarrow z = -\infty \\ x = \infty & \Rightarrow z = \infty \end{cases}$

$$\begin{aligned} EX &= \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\infty} x e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx \\ &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} (\sigma z + \mu) e^{-\frac{z^2}{2}} dz \\ &= \frac{\sigma}{\sqrt{2\pi}} \int_{-\infty}^{\infty} z e^{-\frac{z^2}{2}} dz + \mu \cdot \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{z^2}{2}} dz \\ &= 0 + \mu \cdot 1 \\ &= \mu \end{aligned}$$

### 11.5.3 Wariancja

Podstawiamy  $z = \frac{x-\mu}{\sigma}$  jak poprzednio

$$\begin{aligned} D^2(X) &= E(\bar{X} - \mu)^2 \\ &= \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{\infty} (x - \mu)^2 e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx \\ &= \frac{\sigma^2}{\sqrt{2\pi}} \int_{-\infty}^{\infty} z^2 e^{-\frac{z^2}{2}} dz \end{aligned}$$


Całkujemy przez części  $\left| \begin{array}{ll} u = z & u' = 1 \\ v' = z e^{-\frac{z^2}{2}} & v = -e^{-\frac{z^2}{2}} \end{array} \right|$

$$\begin{aligned} &= \frac{\sigma^2}{\sqrt{2\pi}} \left( \left[ -z e^{-\frac{z^2}{2}} \right]_{-\infty}^{+\infty} + \int_{-\infty}^{\infty} e^{-\frac{1}{2}z^2} dz \right) \\ &= \frac{\sigma^2}{\sqrt{2\pi}} (0 + \sqrt{2\pi}) = \sigma^2 \end{aligned}$$

### 11.6 Rozkład normalny $N(0, 1)$

Dla  $\mu = 0$  i  $\sigma = 1$  to funkcja gęstości jest oznaczana symbolem  $\varphi(x)$ :


$$\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$$



**Rysunek 9:** Wykres funkcji gęstości <sup>10</sup>

Dystrybuanta rozkładu  $N(0, 1)$  ma postać

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{x^2}{2}} dx$$



**Rysunek 10:** Wykres dystrybuanty <sup>11</sup>

<sup>10</sup><https://www.desmos.com/calculator/ykoq0sgvgl>

Funkcja  $\Phi(x)$  jest stabelaryzowana

Ponadto funkcja  $\Phi(x)$  spełnia następujący warunek

$$\Phi(-x) = 1 - \Phi(x)$$

### 11.6.1 Standaryzacja rozkładu normalnego

$X$  ma rozkład  $N(\mu, \sigma) \Rightarrow Y = \frac{X-\mu}{\sigma}$  ma rozkład  $N(0, 1)$

Zatem dla dowolnych liczb rzeczywistych  $a$  i  $b$  takich, że  $a < b$  mamy

$$\begin{aligned} P[a < x < b] &= P\left[\frac{a-\mu}{\sigma} < Y < \frac{b-\mu}{\sigma}\right] \\ &= \Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right) \end{aligned}$$

Możemy zatem od dowolnego rozkładu normalnego  $N(\mu, \sigma)$  przejść do rozkładu normalnego  $N(0, 1)$

### 11.6.2 Zastosowania

- rozkład normalny odgrywa ważną rolę w zastosowaniach,
- wiele spotykanych na codzień wielkości (zmiennych losowych) ma rozkład normalny lub bardzo zbliżony do normalnego.

---

<sup>11</sup><https://www.desmos.com/calculator/ykoq0sgvgl>

**11.7 Tabela parametrów rozkładów ciągłych**

Nazwa	$f(x)$	$F(x)$	$EX$	$E(X^2)$	$D^2(X)$
Jednostajny $U(a, b)$	$\begin{cases} 0, & x < a \\ \frac{1}{b-a}, & a \leq x \leq b \\ 0, & b < x \end{cases}$	$\begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x < b \\ 1, & b \leq x \end{cases}$	$\frac{a+b}{2}$	$\frac{a^2+ab+b^2}{3}$	$\frac{(b-a)^2}{12}$
Wykładniczy $\text{Exp}(\lambda)$	$\begin{cases} 0, & x \leq 0 \\ \lambda e^{-\lambda x}, & 0 < x \end{cases}$	$\begin{cases} 0, & x < 0 \\ 1 - e^{-\lambda x}, & 0 \leq x \end{cases}$	$\frac{1}{\lambda}$	$\frac{2}{\lambda^2}$	$\frac{1}{\lambda^2}$
Gamma $\Gamma(b, p)$	$\begin{cases} 0, & x \leq 0 \\ \frac{b^p}{\Gamma(p)} x^{p-1} e^{-bx}, & 0 < x \end{cases}$	-	$\frac{p}{b}$	$\frac{p^2+p}{b^2}$	$\frac{p}{b^2}$
Cauchy'ego	$\frac{1}{\pi(a^2 + (x-m)^2)}$	-	-	-	-
Normalny $N(\mu, \sigma)$	$\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$	-	$\mu$	$\mu^2 + \sigma^2$	$\sigma^2$
Normalny $N(0, 1)$	$\varphi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$	$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{x^2}{2}} dx$	0	1	1

2024-11-26

**12 Rozkłady dwuwymiarowe i wielowymiarowe****12.1 Dwuwymiarowa zmienna losowa (przypomnienie)**

Niech

- $(\Omega, \mathcal{F}, P)$  – przestrzeń probabilistyczna
- $(X, Y)$  – dwuwymiarowy wektor losowy (dwuwymiarowa zmienna losowa)

$$(X, Y) : \Omega \rightarrow \mathbb{R} \times \mathbb{R}$$

$$\text{i } \bigcap_{t_1, t_2 \in \mathbb{R}} \{\omega \in \Omega : X(\omega) < t_1, Y(\omega) < t_2\} \in \mathcal{F}$$

## 12.2 Moment zwykły mieszany

**Momentem zwykłym mieszanym**  $m_{r,s}$  rzędu  $r + s$  zmiennej losowej  $(X, Y)$  nazywamy wartość oczekiwaną iloczynu  $X^r \cdot Y^s$  (o ile istnieje)

$$m_{r,s} = E(X^r \cdot Y^s) \quad \text{dla } r, s \in \mathbb{N}$$

### 12.2.1 Rozkład skokowy

Niech  $(X, Y)$  – zmienna typu skokowego o rozkładzie prawdopodobieństwa

$$p_{ij} = P[X = x_i, Y = y_j] \quad i, j \in \mathbb{N}_+$$

$$m_{r,s} = \sum_i \sum_j x_i^r \cdot y_j^s \cdot p_{ij} \quad \text{o ile} \quad \sum_i \sum_j |x_i|^r \cdot |y_j|^s \cdot p_{ij} < \infty$$

### 12.2.2 Rozkład ciągły

Niech  $(X, Y)$  – zmienna typu ciągłego o rozkładzie prawdopodobieństwa danym za pomocą funkcji gęstości:  $f(x, y)$

$$m_{r,s} = \iint_{\mathbb{R}^2} x^r \cdot y^s \cdot f(x, y) \, dx \, dy \quad \text{o ile} \quad \iint_{\mathbb{R}^2} |x|^r \cdot |y|^s \cdot f(x, y) \, dx \, dy < \infty$$

W szczególnym przypadku

- dla  $r = 0$ :  $m_{0,s} = EY^s$
- dla  $s = 0$ :  $m_{r,0} = EX^r$

## 12.3 Moment centralny mieszany rzędu $r + s$

Momentem centralnym mieszanym  $\mu_{r,s}$  rzędu  $r + s$  zmiennej losowej  $(X, Y)$  nazywamy wartość oczekiwaną iloczynu  $(X - EX)^r \cdot (Y - EY)^s$  (o ile istnieje):

$$\mu_{r,s} = E[(X - EX)^r \cdot (Y - EY)^s]$$

dla  $r, s \in \mathbb{N}$

### 12.3.1 Moment centralny mieszany dla rozkładu skokowego

Niech  $(X, Y)$  – zmienna typu skokowego o rozkładzie

$$p_{ij} = P[X = x_i, Y = y_j] \quad i, j \in \mathbb{N}_+$$

$$\mu_{r,s} = \sum_i \sum_j (x_i - EX)^r \cdot (y_j - EY)^s \cdot p_{ij} \quad \text{o ile} \quad \sum_i \sum_j |x_i - EX|^r \cdot |y_j - EY|^s \cdot p_{ij} < \infty$$

### 12.4 Moment centralny mieszany dla rozkładu ciągłego

Niech  $(X, Y)$  – zmienna losowa typu ciągłego o gęstości prawdopodobieństwa  $f(x, y)$

$$\mu_{r,s} = \iint_{\mathbb{R}^2} (x - EX)^r \cdot (y - EY)^s \cdot f(x, y) \, dx \, dy \quad \text{o ile} \quad \iint_{\mathbb{R}^2} |x - EX|^r \cdot |y - EY|^s \cdot f(x, y) \, dx \, dy < \infty$$

W szczególnym przypadku

- dla  $r = 2, s = 0$ :  $\mu_{20} = E(X - EX)^2 = D^2(X)$
- dla  $r = 0, s = 2$ :  $\mu_{02} = E(Y - EY)^2 = D^2(Y)$

### 12.5 Kowariancja

Kowariancją całkwalnych zmiennych losowych  $X, Y$  spełniających warunek

$$E|X \cdot Y| < \infty$$

nazywamy moment centralny mieszany rzędu  $1 + 1$

#### Achtung! 15

Kowariancja zawsze jest dla dwóch zmiennych losowych.

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

#### 12.5.1 Własności

- $\text{cov}(X, Y) = E(XY) - EX \cdot EY$
- $|\text{cov}(X, Y)| \leq \sqrt{D^2(X) \cdot D^2(Y)}$

**Dowód 12.1**

1) Zauważmy, że

$$\begin{aligned}\operatorname{cov}(X, Y) &= E[(X - EX)(Y - EY)] \\ &= E(XY - XEY - YEX + EX \cdot EY) \\ &= E(XY) - EY \cdot EX - EX \cdot EY + EX \cdot EY \\ &= E(XY) - EX \cdot EY\end{aligned}$$

Czyli  $\mu_{11} = m_{11} - m_{10} \cdot m_{01}$

2) Na mocy nierówności Höldera dla

$$\tilde{X} = X - EX, \quad \tilde{Y} = Y - EY$$

mamy

$$E(\tilde{X}\tilde{Y}) \leq \sqrt{E(\tilde{X}^2)E(\tilde{Y}^2)}$$

Zatem

$$|E((X - EX) \cdot (Y - EY))| \leq \sqrt{D^2(X) \cdot D^2(Y)}$$

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

**12.5.2 Nierówność Höldera**

Niech

- $p > 1$
- $q > 1$
- $\frac{1}{p} + \frac{1}{q} = 1$

Wtedy

$$E|X \cdot Y| \leq [E(|X|^p)]^{\frac{1}{p}} [E(|Y|^q)]^{\frac{1}{q}}$$

Czyli

- dla przypadku dyskretnego:

$$\sum_i a_i b_i \leq \left( \sum_i a_i^p \right)^{\frac{1}{p}} \cdot \left( \sum_i b_i^q \right)^{\frac{1}{q}}$$

- dla przypadku ciągłego:

$$\int f(x)g(x)dx \leq \left( \int (f(x))^p dx \right)^{\frac{1}{p}} \left( \int (g(x))^q dx \right)^{\frac{1}{q}}$$

### 12.5.3 Uwagi i interpretacja

- Z zależności 2. wynika, że kowariancja istnieje gdy istnieją odpowiednio wariancje  $D^2(X)$  i  $D^2(Y)$ .
- Kowariancja  $\text{cov}(X, Y)$  jest wartością średnią (oczekiwaną) iloczynu odchyleń obu zmiennych od ich wartości oczekiwanych
- może być traktowana jako pewna miara “zgodności” dwu zmiennych losowych:
  - im większa kowariancja tym większa “zgodność” zmiennych (równocześnie przyjmują wartości “duże” i równocześnie przyjmują wartości “małe”)

### 12.6 Korelacja

Niech  $(X, Y)$  – dwuwymiarowa zmienna losowa taka, że

- $0 < D^2(X) < \infty$  oraz  $0 < D^2(Y) < \infty$

Dwie zmienne losowe  $X, Y$  nazywamy **nieskorelowanymi** wtw, gdy

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

**Współczynnikiem korelacji**  $\rho_{XY}$  zmiennych losowych  $X, Y$  nazywamy wyrażenie

$$\begin{aligned} \rho_{XY} &= \frac{E[(X - EX)(Y - EY)]}{\sqrt{D^2(X) \cdot D^2(Y)}} \\ &= \frac{\text{cov}(X, Y)}{\sqrt{D^2(X) \cdot D^2(Y)}} \end{aligned}$$

- Jeżeli  $\rho_{X,Y} = 0$ , to zmienne losowe są nieskorelowane
- Jeżeli  $\rho_{X,Y} > 0$ , to zmienne losowe są dodatnio skorelowane
- Jeżeli  $\rho_{X,Y} < 0$ , to zmienne losowe są ujemnie skorelowane

### 12.6.1 Własności

1. Dla dowolnego wektora losowego  $(X, Y)$  o skończonych dodatnich wariancjach  $0 < D^2(X) < \infty, 0 < D^2(Y) < \infty$  zachodzi warunek

$$-1 \leq \rho_{XY} \leq 1$$

#### Dowód 12.2

Z własności 2 mamy

$$\begin{aligned} |\operatorname{cov}(X, Y)| \leq \sqrt{D^2(X) \cdot D^2(Y)} &\iff \left| \frac{\operatorname{cov}(X, Y)}{\sqrt{D^2(X) \cdot D^2(Y)}} \right| \leq 1 \\ &\iff |\rho_{XY}| \leq 1 \end{aligned}$$

2. Niech  $X, Y$  będą dowolnymi zmiennymi losowymi, dla których istnieje współczynnik korelacji  $\rho_{XY}$ .

Warunkiem koniecznym i dostatecznym na to, by zmienne losowe  $X, Y$  były z prawdopodobieństwem 1 związane zależnością liniową, tzn.  $P[\omega \in \Omega : Y(\omega) = aX(\omega) + b] = 1$  dla  $a \neq 0$ , jest

$$\rho_{XY}^2 = 1$$

### 12.7 Regresja

Niech  $(X, Y)$  – dwuwymiarowa zmienna losowa, dla której istnieje kowariancja  $\operatorname{cov}(X, Y)$

Szukamy funkcji wyrażającej zależność jednej zmiennej od drugiej.

Najprostszą zależnością, najwygodniejszą do dalszych badań jest **zależność liniowa**.

Dlatego często, ze świadomością popełnienia pewnych błędów, przyjmujemy, że zależność pomiędzy badanymi zmiennymi jest liniowa i szukamy prostej, która najlepiej wyraża jedną zmienną jako **funkcję liniową** drugiej zmiennej – szukamy prostej regresji lub inaczej regresji II rodzaju.

**12.7.1 Regresja II rodzaju  $Y$  względem  $X$** 

Prostą regresji (regresją II rodzaju) zmiennej  $Y$  względem zmiennej  $X$  nazywamy prostą

$$y = \alpha x + \beta$$

gdzie  $\alpha$  i  $\beta$  są liczbami, dla których spełniona jest zależność

$$E((Y - \alpha X - \beta)^2) = \min$$

Warunek ten jest spełniony gdy

$$\alpha = \rho \frac{\sigma_Y}{\sigma_X}, \quad \beta = EY - \rho \frac{\sigma_Y}{\sigma_X} \cdot EX$$

Prosta regresji zmiennej  $Y$  względem zmiennej  $X$  ma postać

$$y - EY = \rho \frac{\sigma_Y}{\sigma_X} (x - EX)$$

**12.7.2 Regresja II rodzaju  $X$  względem  $Y$** 

Prostą regresji (regresją II rodzaju) zmiennej  $X$  względem zmiennej  $Y$  nazywamy prostą

$$x = \gamma y + \delta$$

gdzie  $\gamma$  i  $\delta$  są liczbami, dla których spełniona jest zależność

$$E((X - \gamma Y - \delta)^2) = \min$$

Warunek ten jest spełniony gdy

$$\gamma = \rho \frac{\sigma_X}{\sigma_Y}, \quad \delta = EX - \rho \frac{\sigma_X}{\sigma_Y} \cdot EY$$

Prosta regresji zmiennej  $Y$  względem zmiennej  $X$  ma postać

$$x - EX = \rho \frac{\sigma_X}{\sigma_Y} (y - EY)$$

## 12.8 Wariancja sumy zmiennych losowych

Jeżeli zmienne losowe  $X_1, X_2, \dots, X_n$  mają wariancje ( $\sigma_i^2 = D^2(X_i) < \infty, i \in \{1, 2, \dots, n\}$ ), to istnieje wariancja sumy  $X_1 + X_2 + \dots + X_n$  i

$$D^2(X_1 + X_2 + \dots + X_n) = \sum_{i=1}^n D^2(X_i) + 2 \sum_{1 \leq i < j \leq n} \text{cov}(X_i, X_j)$$

### Dowód 12.3

$$\begin{aligned} D^2(X_1 + X_2 + \dots + X_n) &= E[(X_1 + X_2 + \dots + X_n)^2] - [E(X_1 + X_2 + \dots + X_n)]^2 \\ &= \sum_{i=1}^n E(X_i^2) + 2 \sum_{j=2}^n \sum_{i=1}^{j-1} E(X_i X_j) - \sum_{i=1}^n (EX_i)^2 - 2 \sum_{j=2}^n \sum_{i=1}^{j-1} EX_i \cdot EX_j \\ &= \sum_{i=1}^n [E(X_i)^2 - (EX_i)^2] + 2 \sum_{j=1}^n \sum_{i=1}^{j-1} [E(X_i X_j) - EX_i \cdot EX_j] \\ &= \sum_{i=1}^n D^2(X_i) + 2 \sum_{j=2}^n \sum_{i=1}^{j-1} \text{cov}(X_i, X_j) \end{aligned}$$

### 12.8.1 Wniosek

jeżeli zmienne losowe  $X_1, X_2, \dots, X_n$  mają wariancje ( $\sigma_i^2 = D^2(X_i) < \infty, i \in \{1, 2, \dots, n\}$ ) i są parami nieskorelowane, to

$$D^2(X_1 + X_2 + \dots + X_n) = \sum_{i=1}^n D^2(X_i)$$

## 12.9 Macierz kowariancji

Dla wektora losowego  $X = (X_1, X_2, \dots, X_n)$  odpowiednikiem wariancji jest macierz kowariancji.

Jeżeli  $D^2(X_i) < \infty$  dla każdego  $i \in \{1, 2, \dots, n\}$ , to macierz

$$\begin{aligned}
 Q_X &= \left[ \text{cov}(X_i, X_j) \right]_{i,j \in \{1,2,\dots,n\}} \\
 &= \begin{bmatrix} D^2(X_1) & \text{cov}(X_1, X_2) & \cdots & \text{cov}(X_1, X_n) \\ \text{cov}(X_2, X_1) & D^2(X_2) & \cdots & \text{cov}(X_2, X_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(X_n, X_1) & \text{cov}(X_n, X_2) & \cdots & D^2(X_n) \end{bmatrix}
 \end{aligned}$$

nazywamy macierzą kowariancji wektora losowego  $X = (X_1, X_2, \dots, X_n)$

## 12.10 Rozkład wielomianowy

**Rozkład wielomianowy** jest uogólnieniem rozkładu dwumianowego i opisuje rozkład wyników przy  $n$ -krotnym powtórzeniu doświadczenia o  $k$  możliwych wynikach

Oznaczamy

- $X_i$  – liczba wyników  $i$ -tego typu w serii  $n$  doświadczeń.

$$\begin{aligned}
 P(X_1 = n_1, X_2 = n_2, \dots, X_k = n_k) &= \frac{n!}{n_1! n_2! \dots n_k!} p_1^{n_1} p_2^{n_2} \cdots p_k^{n_k} \\
 &= \binom{n}{n_1, n_2, \dots, n_k} p_1^{n_1} p_2^{n_2} \cdots p_k^{n_k}
 \end{aligned}$$

Dla takich  $p$  i  $n$ , że

$$\bigwedge_{i \in \{1..k\}} p_i \in (0, 1) \quad \sum_{i=1}^k p_i = 1 \quad \sum_{i=1}^k n_i = n$$

### Achtung! 16

- Zmienna losowa  $X_i$  ma rozkład  $\mathcal{B}(n, p_i)$
- $\text{cov}(X_i, X_j) = -p_i p_j, i \neq j$

## 12.11 Rozkład normalny

Niech

- $X : \Omega \rightarrow \mathbb{R}^n$

- $X = (X_1, X_2, \dots, X_n)$  – zmienna losowa ciągła określona na przestrzeni probabilistycznej  $(\Omega, \mathcal{F}, P)$

Mówimy, że zmienna losowa  $X = (X_1, X_2, \dots, X_n)$  ma rozkład normalny z parametrami  $m, C$ , gdzie  $m \in \mathbb{R}^n$  i  $C$  jest macierzą symetryczną, dodatnio określoną stopnia  $n$ , jeżeli jej funkcja gęstości prawdopodobieństwa określona jest wzorem

$$f_X(\underbrace{x_1, x_2, \dots, x_n}_{\mathbf{x}}) = \frac{1}{(2\pi)^{\frac{n}{2}} \sqrt{\det C}} \cdot \exp\left(-\frac{1}{2} [(\mathbf{x} - m) \times C^{-1} \times (\mathbf{x} - m)^T]\right)$$

---

2024-12-03

### 13 Niezależne zmienne losowe

- $(\Omega, \mathcal{F}, P)$  – przestrzeń probabilistyczna
- $X_i, i \in \{1..n\}$  – zmienne losowe określone na  $(\Omega, \mathcal{F}, P)$

Zmienne losowe  $X_1, X_2, \dots, X_n$  są niezależne, jeśli dla dowolnego wyboru zbiorów borelowskich

$$B_1, B_2, \dots, B_n \in \mathcal{B}(\mathbb{R})$$

zachodzi równość:

$$P[X_1 \in B_1, X_2 \in B_2, \dots, X_n \in B_n] = P[X_1 \in B_1] \cdot P[X_2 \in B_2] \cdots P[X_n \in B_n]$$

#### 13.1 Uwagi

- rozkład łączny – gęstość dla całego wektora  $(X_1, X_2, \dots, X_n)$ , rozkład brzegowy – rozkład poszczególnych zmiennych  $X_i$  wektora  $(X_1, X_2, \dots, X_n)$
- łączny rozkład niezależnych zmiennych losowych jest wyznaczony przez rozkłady brzegowe:

$$P[X_1 \in B_1, X_2 \in B_2, \dots, X_n \in B_n] = P[X_1 \in B_1] \cdot P[X_2 \in B_2] \cdots P[X_n \in B_n]$$

- Definicja równoważna:

Zmienne losowe są niezależne wtw, gdy niezależne są  $\sigma$ -ciąta generowane przez te zmienne losowe.

**Twierdzenie 13.1**

Dla zmiennych losowych  $X_1, X_2, \dots, X_n$  o wartościach w  $\mathbb{R}$  następujące warunki są równoważne:

- 1) zmienne losowe są niezależne
- 2)  $F_{X_1, X_2, \dots, X_n}(t_1, t_2, \dots, t_n) = F_{X_1}(t_1) \cdot F_{X_2}(t_2) \cdots F_{X_n}(t_n)$

**13.2 Własności**

Założmy, że zmienne losowe  $X_1, X_2, \dots, X_n$  są niezależne, a funkcje  $\varphi_j : \mathbb{R} \rightarrow \mathbb{R}$  dla  $j \in \{1..n\}$  są mierzalne względem  $\sigma$ -ciała zbiorów borelowskich (są funkcjami borelowskimi).

Wtedy zmienne losowe

$$Y_j = \varphi_j(X_j)$$

są też niezależne.

**Dowód 13.1**

- $\varphi_j$  są funkcjami borelowskimi, stąd dla dowolnych zbiorów borelowskich  $B_j \in \mathcal{B}(\mathbb{R})$  dla  $j \in \{1..n\}$ , zbiory

$$\varphi_j^{-1}(B_j), \quad j \in \{1..n\}$$

też są zbiorami borelowskimi

Mamy zatem:

$$\begin{aligned} & P[Y_1 \in B_1, Y_2 \in B_2, \dots, Y_n \in B_n] \\ &= P[X_1 \in \varphi_1^{-1}(B_1), X_2 \in \varphi_2^{-1}(B_2), \dots, X_n \in \varphi_n^{-1}(B_n)] \\ &= P[X_1 \in \varphi_1^{-1}(B_1)] \cdot P[X_2 \in \varphi_2^{-1}(B_2)] \cdots P[X_n \in \varphi_n^{-1}(B_n)] \\ &= P[Y_1 \in B_1] \cdot P[Y_2 \in B_2] \cdots P[Y_n \in B_n] \end{aligned}$$

co kończy dowód

### 13.3 Zmienne losowe o rozkładzie dyskretnym

#### Twierdzenie 13.2

Zmienne losowe  $X_1, X_2, \dots, X_n$  o rozkładach dyskretnych są niezależne wtw, gdy dla każdego ciągu

$$x_1, x_2, \dots, x_n$$

gdzie

- $x_i \in S_{X_i}$  dla  $i \in \{1..n\}$
- $S_{X_i}$  – zbiór wartości zmiennej  $X_i$

spełniony jest warunek

$$\begin{aligned} P[X_1 = x_1, X_2 = x_2, \dots, X_n = x_n] \\ = P[X_1 = x_1] \cdot P[X_2 = x_2] \cdots P[X_n = x_n] \end{aligned}$$

#### Dowód 13.2

1.  $\implies$  Oczywiste z definicji:

$$B_1 = \{x_1\}, B_2 = \{x_2\}, \dots, B_n = \{x_n\},$$

2.  $\longleftarrow$  Skorzystamy z warunku niezależności dla dystrybuant.

$$\begin{aligned}
& F_{X_1, X_2, \dots, X_n}(t_1, t_2, \dots, t_n) \\
&= \sum_{\substack{y_j^{(i)} \leq t_i \\ y_j^{(i)} \in S_{X_i} \\ i \in \{1..n\}}} P[X_1 = y_j^{(1)}, X_2 = y_j^{(2)}, \dots, X_n = y_j^{(n)}] \\
&= \sum_{\substack{y_j^{(i)} \leq t_i \\ y_j^{(i)} \in S_{X_i} \\ i \in \{1..n\}}} P[X_1 = y_j^{(1)}] \cdot P[X_2 = y_j^{(2)}] \cdots P[X_n = y_j^{(n)}] \\
&= \sum_{i=1}^n \sum_{\substack{y_j^{(i)} \leq t_i \\ y_j^{(i)} \in S_{X_i}}} P[X_1 = y_j^{(1)}] \cdot P[X_2 = y_j^{(2)}] \cdots P[X_n = y_j^{(n)}] \\
&= \left[ \sum_{\substack{y_j^{(1)} \leq t_1 \\ y_j^{(1)} \in S_{X_1}}} P[X_1 = y_j^{(1)}] \right] \cdot \left[ \sum_{\substack{y_j^{(2)} \leq t_2 \\ y_j^{(2)} \in S_{X_2}}} P[X_2 = y_j^{(2)}] \right] \cdots \left[ \sum_{\substack{y_j^{(n)} \leq t_n \\ y_j^{(n)} \in S_{X_n}}} P[X_n = y_j^{(n)}] \right] \\
&= F_{X_1}(t_1) \cdot F_{X_2}(t_2) \cdots F_{X_n}(t_n)
\end{aligned}$$

### 13.4 Zmienne losowe o rozkładzie ciągłym

#### Twierdzenie 13.3

Zmienne losowe  $X_1, X_2, \dots, X_n$  o rozkładach ciągłych danych za pomocą funkcji gęstości

$$f_1, f_2, \dots, f_n$$

i rozkładzie łącznym o funkcji gęstości  $f_{X_1, X_2, \dots, X_n}$  są niezależne wtw, gdy

$$f_{X_1, X_2, \dots, X_n}(t_1, t_2, \dots, t_n) = f_1(t_1) \cdot f_2(t_2) \cdots f_n(t_n)$$

#### Dowód 13.3

1.  $\implies$  Zakładamy, że zmienne są niezależne. Wtedy:

$$\underbrace{F_{X_1, X_2, \dots, X_n}(t_1, t_2, \dots, t_n)}_L = \underbrace{F_{X_1}(t_1) \cdot F_{X_2}(t_2) \cdots F_{X_n}(t_n)}_P$$

$$\begin{aligned}
 P &= \int_{-\infty}^{t_1} f_1(x_1) dx_1 \cdot \int_{-\infty}^{t_2} f_2(x_2) dx_2 \cdots \int_{-\infty}^{t_n} f_n(x_n) dx_n \\
 &= \int_{-\infty}^{t_1} \int_{-\infty}^{t_2} \cdots \int_{-\infty}^{t_n} f_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n) dx_1 dx_2 \cdots dx_n \\
 L &= \int_{-\infty}^{t_1} \int_{-\infty}^{t_2} \cdots \int_{-\infty}^{t_n} f_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n) dx_1 dx_2 \cdots dx_n
 \end{aligned}$$

Ostatecznie

$$f_1(x_1) \cdot f_2(x_2) \cdots f_n(x_n) = f_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n)$$

2.  $\Leftarrow$  Zakładamy, że

$$f_1(x_1) \cdot f_2(x_2) \cdots f_n(x_n) = f_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n)$$

Wtedy

$$\begin{aligned}
 &F_{X_1, X_2, \dots, X_n}(t_1, t_2, \dots, t_n) \\
 &= \int_{-\infty}^{t_1} \int_{-\infty}^{t_2} \cdots \int_{-\infty}^{t_n} f_{X_1, X_2, \dots, X_n}(x_1, x_2, \dots, x_n) dx_1 dx_2 \cdots dx_n \\
 &= \int_{-\infty}^{t_1} \int_{-\infty}^{t_2} \cdots \int_{-\infty}^{t_n} f_1(x_1) \cdot f_2(x_2) \cdots f_n(x_n) dx_1 dx_2 \cdots dx_n \\
 &= \int_{-\infty}^{t_1} f_1(x_1) dx_1 \cdot \int_{-\infty}^{t_2} f_2(x_2) dx_2 \cdots \int_{-\infty}^{t_n} f_n(x_n) dx_n \\
 &= F_{X_1}(t_1) \cdot F_{X_2}(t_2) \cdots F_{X_n}(t_n)
 \end{aligned}$$

Co dowodzi niezależności zmiennych

### 13.4.1 Własności

#### Twierdzenie 13.4

Założmy, że

- zmienne losowe  $\overbrace{X_1, X_2, \dots, X_n}^n, \overbrace{X_{n+1}, \dots, X_{n+m}}^m$  są niezależne
- funkcje  $\varphi : \mathbb{R}^n \rightarrow \mathbb{R}$  oraz  $\psi : \mathbb{R}^m \rightarrow \mathbb{R}$

Wtedy zmienne losowe

$$Y_1 = \varphi(X_1, X_2, \dots, X_n) \quad \text{oraz} \quad Y_2 = \psi(X_{n+1}, X_{n+2}, \dots, X_{n+m})$$

są niezależne

### Twierdzenie 13.5

Jeżeli  $X_1, X_2, \dots, X_n$  są niezależnymi zmiennymi losowymi, które mają wartości oczekiwane  $EX_1, EX_2, \dots, EX_n$ , to istnieje wartość oczekiwana ich iloczynu  $X_1 \cdot X_2 \cdots X_n$  i zachodzi warunek

$$E(X_1 \cdot X_2 \cdots X_n) = EX_1 \cdot EX_2 \cdots EX_n$$

### Twierdzenie 13.6

Jeżeli  $X_1, X_2, \dots, X_n$  są niezależnymi zmiennymi losowymi posiadającymi wariancje  $D^2(X_i)$  dla  $i \in \{1..n\}$ , to istnieje wariancja ich sumy i mamy

$$D^2\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n D^2(X_i)$$

### Twierdzenie 13.7

Jeśli  $X, Y$  są niezależne, to  $X, Y$  są nieskorelowane.

Ale w inną stronę warunek może nie zachodzić

## 13.5 Rozkład sumy niezależnych zmiennych losowych

Jeżeli zmienne losowe  $X, Y$  są niezależne, to rozkład ich sumy  $X + Y$  nazywamy splotem rozkładów zmiennej losowej  $X$  i zmiennej  $Y$

$$\mathcal{L}(X + Y) = \mathcal{L}(X) * \mathcal{L}(Y)$$

### 13.5.1 Rozkład sumy niezależnych zmiennych losowych o rozkładach ciągłych

Niech

- $X, Y$  – niezależne zmienne losowe typu ciągłego
- $f$  – funkcja gęstości zmiennej  $X$

- $g$  – funkcja gęstości zmiennej  $Y$

Wyznaczamy dystrybuantę zmiennej losowej  $Z = X + Y$ :

$$\begin{aligned} F_Z(t) &= P[Z \leq t] \\ &= P[X + Y \leq t] \\ &= \iint_{x+y \leq t} f(x, y) \, dx dy \\ &= \iint_{x+y \leq t} f(x)g(y) \, dx dy \end{aligned}$$

stosujemy podstawienie  $x + y = z$  oraz  $y = u$ .

Stąd

- $x = z - u$  oraz  $y = u$
- $\frac{\partial x}{\partial z} = 1$  oraz  $\frac{\partial x}{\partial u} = -1$
- $\frac{\partial y}{\partial z} = 0$  oraz  $\frac{\partial y}{\partial u} = 1$
- $\begin{vmatrix} 1 & -1 \\ 0 & 1 \end{vmatrix} = 1$
- $z \leq t, u \in \mathbb{R}$

$$\begin{aligned} F_Z(t) &= \iint_{x+y \leq t} f(x)g(y) \, dx dy \\ &= \int_{-\infty}^t \left[ \int_{\mathbb{R}} f(z-u)g(u) \, du \right] dz \end{aligned}$$

Z drugiej strony:

$$F_Z(t) = \int_{-\infty}^t h(z) \, dz, \quad h - \text{funkcja gęstości zmiennej } Z$$

Stąd

$$h(z) = (f * g)(z) = \int_{\mathbb{R}} f(z-u)g(u) \, du$$

## 14 Funkcja charakterystyczna

Niech

- $X$  – zmienna losowa określona na przestrzeni  $(\Omega, \mathcal{F}, P)$

Funkcja

$$\varphi : \mathbb{R} \rightarrow \mathbb{C}$$

jest funkcją charakterystyczną zmiennej losowej  $X$ , jeśli dla  $t \in \mathbb{R}$

$$\begin{aligned} \varphi(t) &= E e^{itX(\omega)} \\ &\stackrel{\text{def}}{=} E \cos[tX(\omega)] + i E \sin[tX(\omega)] \\ &= \int_{\Omega} e^{itX(\omega)} P(d\omega) \end{aligned}$$

### 14.1 Rozkład dyskretny

Niech

- $X$  – zmienna losowa o rozkładzie dyskretnym
- $\{x_k, k \in \{1..\}\}$  – zbiór wartości zmiennej  $X$
- $p_k = P[X = x_k]$

Funkcja charakterystyczna ma postać

$$\varphi(t) = \sum_{k=1}^{\infty} e^{itx_k} p_k$$

#### Przykład 14.1

Funkcja charakterystyczna rozkładu «zero-jedynkowego».

$$P[X = 0] = 1 - p = q \quad P[X = 1] = p$$

$$\varphi(t) = E e^{itX} = p e^{it} + q e^{it \cdot 0} = p e^{it} + q$$

### 14.2 Rozkład ciągły

Niech

- $X$  – zmienna losowa o rozkładzie ciągłym
- $f$  – funkcja gęstości zmiennej  $X$

Funkcja charakterystyczna jest równa

$$\varphi(t) = \int_{-\infty}^{\infty} e^{itx} f(x) dx$$

### Przykład 14.2

Funkcja charakterystyczna rozkładu ciągłego o funkcji gęstości  $f(x) = \frac{1}{2}e^{-|x|}$

$$\begin{aligned} \varphi(t) &= Ee^{itX} \\ &= \int_{-\infty}^{+\infty} e^{itx} \frac{1}{2} e^{-|x|} dx \\ &= \frac{1}{2} \int_{-\infty}^{+\infty} \cos(tx) e^{-|x|} dx + \frac{1}{2} i \int_{-\infty}^{+\infty} \sin(tx) e^{-|x|} dx \\ &= \frac{1}{2} \int_{-\infty}^{+\infty} \cos(tx) e^{-|x|} dx \\ &= 2 \cdot \frac{1}{2} \int_0^{+\infty} \cos(tx) e^{-x} dx \end{aligned}$$

$$\begin{aligned} \frac{1}{2} \int_0^{+\infty} \cos(tx) e^{-x} dx &= \left| \begin{array}{ll} u = \cos(tx) & u' = -t \sin(tx) \\ v' = e^{-x} & v = -e^{-x} \end{array} \right| \\ &= -e^{-x} \cos tx \Big|_0^{\infty} - t \int_0^{+\infty} e^{-x} \sin(tx) dx \\ &= 1 - t \int_0^{\infty} e^{-x} \sin(tx) dx \\ &= \left| \begin{array}{ll} u = \sin(tx) & u' = t \cos(tx) \\ v' = e^{-x} & v = -e^{-x} \end{array} \right| \\ &= 1 - t \left( -e^{-x} \sin(tx) \Big|_0^{\infty} + t \int_0^{+\infty} e^{-x} \cos(tx) dx \right) \\ &= 1 - t(0 + t \int_0^{+\infty} e^{-x} \cos(tx) dx) \\ &= 1 - t^2 \int_0^{+\infty} e^{-x} \cos(tx) dx \\ (1 + t^2) \int_0^{+\infty} \cos(tx) e^{-x} dx &= 1 \end{aligned}$$

$$\int_0^{+\infty} \cos(tx) e^{-x} dx = \frac{1}{1 + t^2}$$

Stąd

$$\varphi(t) = \frac{1}{1+t^2}$$

### 14.3 Własności funkcji charakterystycznej

Funkcja charakterystyczna zmiennej losowej  $X$  ma następujące własności

- 1)  $|\varphi_X(t)| \leq \varphi_X(0) = 1$
- 2)  $\varphi_X(-t) = \overline{\varphi_X(t)} = \varphi_{-X}(t)$
- 3)  $\varphi_{aX+b}(t) = e^{itb} \varphi_X(at)$
- 4) Jeżeli  $X, Y$  są niezależne, to

$$\varphi_{aX+bY} = \varphi_X(at) \cdot \varphi_Y(bt) \quad \forall a, b \in \mathbb{R}$$

#### Dowód 14.1

$$\varphi_X(0) = Ee^{i0 \cdot X} = 1$$

Stąd

$$|\varphi_X(t)| = |Ee^{itX}| \leq E|e^{itX}| = E\sqrt{\cos^2(tX) + \sin^2(tX)} = 1$$

#### Dowód 14.2

$$\frac{\varphi_X(-t)}{E \cos(tX) + iE \sin(tX)} = \frac{E \cos(-tX) + iE \sin(-tX)}{E \cos(tX) + iE \sin(tX)} = \frac{E \cos(tX) - iE \sin(tX)}{E \cos(tX) + iE \sin(tX)} = \overline{\varphi_X(t)}$$

Ponadto

$$\varphi_X(-t) = Ee^{-itX} = Ee^{it(-X)} = \varphi_{-X}(t)$$

#### Dowód 14.3

$$\varphi_{aX+b}(t) = Ee^{it(aX+b)} = E(e^{it(aX)} \cdot e^{itb}) = e^{itb} Ee^{i(ta)X} = e^{itb} \varphi_X(at)$$

#### Dowód 14.4

$X, Y$  są niezależne  $\implies e^{it(aX)}, e^{it(bY)}$  są niezależne

$$\begin{aligned} \varphi_{aX+bY} &= Ee^{it(aX+bY)} \\ &= E(e^{it(aX)} \cdot e^{it(bY)}) \\ &= Ee^{i(ta)X} \cdot Ee^{i(tb)Y} \\ &= \varphi_X(at) \cdot \varphi_Y(bt) \end{aligned}$$

## 14.4 Własności funkcji charakterystycznej

- Każda funkcja charakterystyczna jest funkcją jednostajnie ciągłą na  $\mathbb{R}$
- Funkcja charakterystyczna zmiennej  $X$  jest rzeczywista wtw, gdy rozkład zmiennej losowej jest symetryczny

Uwaga: Rozkład jest symetryczny, gdy:

- $P[X = a] = P[X = -a], a \in \mathbb{R}, X$  ma rozkład dyskretny
- $f(-x) = f(x), X$  ma rozkład ciągły
- Jeżeli  $E|X^n| < \infty, n \in \mathbb{N}$ , to  $n$ -ta pochodna funkcji charakterystycznej  $\varphi_X^{(n)}$  istnieje i jest jednostajnie ciągła, a ponadto

$$\varphi_X^{(n)}(0) = i^n E(X^n)$$

- Zmienne losowe o różnych rozkładach mają różne funkcje charakterystyczne
- Funkcja  $\varphi : \mathbb{R} \rightarrow \mathbb{C}$  jest funkcją charakterystyczną pewnego rozkładu prawdopodobieństwa na  $\mathbb{R}$  wtw, gdy jest:
  - ciągła
  - dodatnio określona (tzn.  $\bigwedge_{x \in \mathbb{R}} \varphi(x) \neq 0$ )
  - $\varphi(0) = 1$

2024-12-09 (ćwiczenia)

## 15 Rozkład ciągły

### 15.1 Związek gęstości zmiennej $X$ i zmiennej $g(X)$

Jeżeli

- $X$  jest zmienną losową ciągłą o gęstości  $f$  skoncentrowanej na przedziale  $(a, b)$
- $y = g(x)$  jest funkcją ściśle monotoniczną klasy  $C^{(1)}$  o pochodnej  $g'(x) \neq 0$  w tym przedziale
- $x = h(y)$  jest funkcją odwrotną do  $y = g(x)$ ,

to gęstość  $k$  zmiennej  $Y = g(X)$  jest postaci

$$k(y) = \begin{cases} f[h(y)] \cdot h'(y), & c < y < d \\ 0, & \text{poza} \end{cases}$$

gdzie

- $c = \min(c_1, d_1)$  oraz  $d = \max(c_1, d_1)$
- $c_1 = \lim_{x \rightarrow a^+} g(x)$  oraz  $d_1 = \lim_{x \rightarrow b^-} g(x)$

### Przykład 15.1

Zmienna losowa  $X$  ma gęstość prawdopodobieństwa  $f(x) = \alpha(1-x)I_{(0,1)}$ . Wyznaczyć parametr  $\alpha$ . Wyznaczyć funkcję gęstości i dystrybuantę zmiennej losowej  $Y = e^X$

Gęstość w postaci jawnej:

$$f(x) = \begin{cases} \alpha(1-x), & 0 < x < 1 \\ 0, & \text{poza} \end{cases}$$

Dla gęstości musi być spełniony warunek  $\int_{-\infty}^{+\infty} f(x) dx = 1$

$$\begin{aligned} \int_{-\infty}^{+\infty} f(x) dx &= \int_0^1 \alpha(1-x) dx \\ &= \left[ \alpha x - \frac{\alpha x^2}{2} \right]_0^1 \\ &= \alpha - \frac{\alpha}{2} \\ &= \frac{\alpha}{2} = 1 \implies \alpha = 2 \end{aligned}$$

Zatem gęstość ma postać

$$f(x) = \begin{cases} 2 - 2x, & 0 < x < 1 \\ 0, & \text{poza} \end{cases}$$

Oraz dystrybuanta:

$$F(x) = \begin{cases} 0, & x \leq 0 \\ 2x - x^2, & 0 < x < 1 \\ 1, & 1 \leq x \end{cases}$$

Wyznamy gęstość zmiennej  $Y = e^X$  na dwa sposoby:

(1) Wyznamy dystrybuantę i zrózniczkujemy

$$\begin{aligned}
 F_X(t) &= P[Y \leq t] = P[e^X \leq t] \\
 &= \begin{cases} 0, & t \leq 0 \\ P[X \leq \ln t], & 0 < t \end{cases} \\
 &= \begin{cases} 0, & t \leq 0 \\ F_X(\ln t), & 0 < t \end{cases} \\
 &= \begin{cases} 0, & t \leq 0 \\ 0, & \ln t \leq 0 \\ 2 \ln t - \ln^2 t, & 0 < \ln t < 1 \\ 1, & 1 \leq \ln t \end{cases} \\
 &= \begin{cases} 0, & t \leq 1 \\ 2 \ln t - \ln^2 t, & 1 < t < e \\ 1, & e \leq t \end{cases}
 \end{aligned}$$

Teraz zrózniczkujac dostajemy gęstość

$$f_X(t) = \begin{cases} 0, & t \leq 1 \\ \frac{2}{t} - 2 \cdot \frac{\ln t}{t}, & 1 < t < e \\ 0, & e \leq t \end{cases}$$

(1) Wykorzystujac twierdzenie

- $(0; 1) = (0; 1)$
- $a = 0 \quad b = 1$
- $y = e^x, x \in (0; 1)$
- $\ln y = x$
- $g(x) = e^x \quad h(y) = \ln y$

Wyznamy  $c, d$

$$c_1 = \lim_{x \rightarrow a^+} g(x) = \lim_{x \rightarrow 0^+} g(x) = 1$$

$$d_1 = \lim_{x \rightarrow b^-} g(x) = \lim_{x \rightarrow 1^-} g(x) = e$$

$$c = \min(c_1, d_1) = \min(1, e) = 1$$

$$d = \max(c_1, d_1) = \max(1, e) = e$$

Ostatecznie mamy gęstość

$$k(y) = \begin{cases} (2 - 2 \ln y) \cdot \left| \frac{1}{y} \right|, & 1 < y < e \\ 0, & \text{poza} \end{cases}$$

$$= \begin{cases} \frac{2}{y} - \frac{2 \ln y}{y}, & 1 < y < e \\ 0, & \text{poza} \end{cases}$$

Co się zgadza z ręcznie obliczoną gęstością.

2024-12-10

## 16 Nierówności związane z momentami.

### 16.1 Nierówność Schwarz

Jeżeli zmienne losowe  $X, Y$  mają skończone wariancje tzn.  $E(X^2) < \infty, E(Y^2) < \infty$ , to

$$(E|XY|)^2 \leq E(X^2) \cdot E(Y^2)$$

#### Dowód 16.1

Założmy, że  $EX^2 > 0$  i  $EY^2 > 0$ .

Zauważmy ponadto, że

$$(|a| - |b|)^2 \geq 0 \iff a^2 - 2|a||b| + b^2 \geq 0$$

Stąd

$$2|a \cdot b| = 2|a| \cdot |b| \leq a^2 + b^2$$

Podstawmy  $a = \bar{X} = \frac{X}{\sqrt{E(X^2)}}$  i  $b = \bar{Y} = \frac{Y}{\sqrt{E(Y^2)}}$

Wtedy

$$2|\bar{X}||\bar{Y}| \leq \bar{X}^2 + \bar{Y}^2$$

Zatem

$$2E|\bar{X}\bar{Y}| \leq E(\bar{X}^2) + E(\bar{Y}^2)$$

$$2E \frac{|X \cdot Y|}{\sqrt{E(X^2)}\sqrt{E(Y^2)}} \leq 1 + 1 = 2$$

$$E|X \cdot Y| \leq \sqrt{E(X^2) \cdot E(Y^2)}$$

Ostatecznie:

$$(E|XY|)^2 \leq E(X^2) \cdot E(Y^2)$$

## 16.2 Nierówność Jensena

Niech  $X$  będzie zmienną losową taką, że  $E|X| < \infty$  i niech  $g$  będzie funkcją wypukłą, taką, że  $E|g(X)| < \infty$ . Wtedy

$$g(EX) \leq Eg(X)$$

### Achtung! 17

Dla funkcji wypukłej jej styczna w dowolnym punkcie zawsze jest nie większa niż sama funkcja.

### Przykład 16.1

$$g(x) = x^2 \quad \underbrace{(EX)^2}_{g(EX)} \leq \underbrace{E(X^2)}_{E(g(X))}$$

$$g(x) = e^x \quad E(e^X) \geq e^{EX}$$

**Dowód 16.2**

- Ponieważ funkcja  $g$  jest wypukła, tzn., że w każdym punkcie jej wykres ma prostą podpierającą (wykres funkcji leży nad styczną do wykresu w dowolnym punkcie).
- Wybieramy punkt  $(x_0, g(x_0))$  na krzywej  $y = g(x)$  i prowadzimy prostą podpierającą (styczną):

$$y - g(x_0) = \lambda(x_0)(x - x_0)$$

gdzie  $\lambda(x_0)$  – współczynnik kierunkowy prostej

lub inaczej  $y = g(x_0) + (x - x_0)\lambda(x_0)$

Z wypukłości funkcji  $g$  wynika warunek  $g(x) \geq y$

Mamy zatem

$$g(x) \geq g(x_0) + (x - x_0)\lambda(x_0)$$

Dokonyjemy podstawienia:  $x_0 = EX$ ,  $x = \overbrace{X}^{\text{zmienna losowa}}$

Mamy:

$$g(X) \geq g(EX) + (X - EX)\lambda(EX)$$

$$Eg(X) \geq E[g(EX) + (X - EX)\lambda(EX)]$$

$$Eg(X) \geq \underbrace{Eg(EX)}_{\text{wartość oczekiwana liczby}} + E(X - EX) \cdot \lambda(EX)$$

$$Eg(X) \geq g(EX) + \lambda(EX) \underbrace{E(X - EX)}_{=EX-EX=0}$$

Stąd otrzymujemy

$$Eg(X) \geq g(EX)$$

**16.3 Nierówność Höldera**

Niech

- $p > 1, q > 1$
- $\frac{1}{p} + \frac{1}{q} = 1$
- $X, Y$  będą zmiennymi losowymi takimi, że  $E(|X|^p) < \infty, E(|Y|^q) < \infty$ .

Wtedy  $E|X \cdot Y| < \infty$  oraz

$$E|X \cdot Y| \leq (E|X|^p)^{\frac{1}{p}} \cdot (E|Y|^q)^{\frac{1}{q}}$$

**Dowód 16.3**

Jeden z warunków na funkcję wypukłą mówi, że

$$f \text{ jest wypukła} \iff f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y)$$

gdzie  $\lambda \in (0, 1)$

Dla funkcji wklęsłej mamy warunek ze znakiem przeciwnym.

Zatem prawdziwa jest nierówność:

$$\log(\lambda x + (1 - \lambda)y) \geq \lambda \log x + (1 - \lambda) \log y$$

$$\log(\lambda x + (1 - \lambda)y) \geq \log x^\lambda + \log y^{1-\lambda}$$

$$\log(\lambda x + (1 - \lambda)y) \geq \log(x^\lambda \cdot y^{1-\lambda})$$

Stąd otrzymujemy:

$$x^\lambda \cdot y^{1-\lambda} \leq \lambda x + (1 - \lambda)y$$

Podstawiamy:  $\lambda := \frac{1}{p}$ ,  $1 - \lambda := \frac{1}{q}$   
oraz  $x := w^p$  i  $y := z^q$

$$(w^p)^{\frac{1}{p}} \cdot (z^q)^{\frac{1}{q}} \leq \frac{1}{p} \cdot w^p + \frac{1}{q} z^q$$

$$w \cdot z \leq \frac{w^p}{p} + \frac{z^q}{q} \text{ - nierówność Younga}$$

Niech teraz  $\bar{X} := \frac{|X|}{(E|X|^p)^{\frac{1}{p}}}$  oraz  $\bar{Y} := \frac{|Y|}{(E|Y|^q)^{\frac{1}{q}}}$

$$\bar{X} \cdot \bar{Y} \leq \frac{\bar{X}^p}{p} + \frac{\bar{Y}^q}{q}$$

$$\frac{|X|}{(E|X|^p)^{\frac{1}{p}}} \cdot \frac{|Y|}{(E|Y|^q)^{\frac{1}{q}}} \leq \frac{|X|^p}{p(E|X|^p)} \cdot \frac{|Y|}{q(E|Y|^q)}$$

$$\frac{E|X \cdot Y|}{(E|X|^p)^{\frac{1}{p}} \cdot (E|Y|^q)^{\frac{1}{q}}} \leq \frac{1}{p} + \frac{1}{q} = 1$$

$$E|X \cdot Y| \leq (E|X|^p)^{\frac{1}{p}} \cdot (E|Y|^q)^{\frac{1}{q}}$$

### 16.4 Nierówność Czebyszewa

Niech  $X \geq 0$  będzie zmienną losową o wartości oczekiwanej  $EX$ .

Wtedy dla każdego  $\varepsilon > 0$  prawdziwa jest nierówność:

$$P[X \geq \varepsilon] \leq \frac{EX}{\varepsilon}$$

#### Dowód 16.4

$$EX = E(XI[X < \varepsilon] + XI[X \geq \varepsilon])$$

gdzie  $I$  jest identyfkatorem:

$$I[X \geq \varepsilon] = \begin{cases} 1, & X \geq \varepsilon \\ 0, & X < \varepsilon \end{cases} \quad \begin{aligned} E(I[X \geq \varepsilon]) \\ &= 1 \cdot P[X \geq \varepsilon] + 0 \cdot P[X < \varepsilon] \\ &= P[X \geq \varepsilon] \end{aligned}$$

$$\begin{aligned} EX &= E(XI[X < \varepsilon] + XI[X \geq \varepsilon]) \\ &= E(XI[X < \varepsilon]) + E(XI[X \geq \varepsilon]) \\ &\geq E(XI[X \geq \varepsilon]) \\ &\geq E(\varepsilon I[X \geq \varepsilon]) \\ &= \varepsilon P[X \geq \varepsilon] \end{aligned}$$

Ostatecznie

$$P[X \geq \varepsilon] \leq \frac{EX}{\varepsilon}$$

### 16.5 Nierówność Markowa

Niech  $p > 0$ . Wtedy dla zmiennej losowej  $X$  takiej, że  $E|X|^p < \infty$  mamy:

$$P[|X| \geq \varepsilon] \leq \frac{E|X|^p}{\varepsilon^p} \quad \text{dla dowolnego } \varepsilon > 0$$

**Dowód 16.5**

Wprowadzamy oznaczenie  $Y := |X|^p$ .

$$\begin{aligned}P[|X| \geq \varepsilon] &= P[|X|^p \geq \varepsilon^p] \\&= P[Y \geq \varepsilon^p] \\&\leq \frac{EY}{\varepsilon^p} \\&= \frac{E|X|^p}{\varepsilon^p}\end{aligned}$$

**16.6 Nierówność Czebyszewa-Bienaymé**

Niech  $X$  będzie zmienną losową o skończonej wariancji  $D^2(X) < \infty$ . Wtedy dla dowolnego  $\varepsilon > 0$  mamy

$$P[|X - EX| \geq \varepsilon] \leq \frac{D^2(X)}{\varepsilon^2}$$

**Dowód 16.6**

Wprowadzamy oznaczenie  $Y := |X - EX|^2$

$$\begin{aligned}P[|X - EX| \geq \varepsilon] &= P[|X - EX|^2 \geq \varepsilon^2] \\&= P[Y \geq \varepsilon^2] \\&\leq \frac{EY}{\varepsilon^2} \\&= \frac{E|X - EX|^2}{\varepsilon^2} \\&= \frac{D^2(X)}{\varepsilon^2}\end{aligned}$$

**16.7 Nierówność Czebyszewa - wykładnicza**

Jeśli  $Ee^{pX} < \infty$  dla pewnej zmiennej losowej  $X$  i  $p > 0$ , to dla  $\lambda \in [0, p]$  mamy:

$$P[X \geq \varepsilon] \leq \frac{Ee^{\lambda X}}{e^{\lambda \varepsilon}}$$

dla dowolnego  $\varepsilon > 0$

### Dowód 16.7

Wprowadzamy oznaczenie:  $Y := e^{\lambda X}$

$$\begin{aligned} P[X \geq \varepsilon] &= P[e^{\lambda X} \geq e^{\lambda \varepsilon}] \\ &= P[Y \geq e^{\lambda \varepsilon}] \\ &\leq \frac{EY}{e^{\lambda \varepsilon}} \\ &= \frac{Ee^{\lambda X}}{e^{\lambda \varepsilon}} \end{aligned}$$

## 17 Rodzaje zbieżności zmiennych losowych

Ciąg zmiennych losowych  $\{X_n, n \geq 1\}$  jest zbieżny do zmiennej losowej  $X$

1) **prawie na pewno**, jeśli

$$P[\omega : \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)] = 1 \quad (X_n \xrightarrow{\text{p.n.}} X)$$

2) **według prawdopodobieństwa** (według miary probabilistycznej), jeśli dla każdego  $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P[\omega : |X_n(\omega) - X(\omega)| > \varepsilon] = 0 \quad (X_n \xrightarrow{\text{p}} X)$$

3) **według  $p$ -tego momentu** (w  $L^p$ ),  $0 < p < \infty$ , jeśli  $E|X| < \infty$ ,  $E|X_n|^p < \infty$  dla  $n \geq 1$  oraz

$$\lim_{n \rightarrow \infty} E|X_n - X|^p = 0 \quad (X_n \xrightarrow{L^p} X)$$

### Achtung! 18

Każda z tych zbieżności ma swój odpowiednik w analizie:

- 1) zbieżność prawie wszędzie
- 2) zbieżność według miary
- 3) zbieżność w  $L^p$

### 17.1 Zbieżność «prawie na pewno» – własności

Jeśli  $X_n \xrightarrow{\text{p.n.}} X$  oraz  $Y_n \xrightarrow{\text{p.n.}} Y$ , to

$$1) \bigwedge_{a,b \in \mathbb{R}} aX_n + bY_n \xrightarrow{\text{p.n.}} aX + bY$$

$$2) X_n \cdot Y_n \xrightarrow{\text{p.n.}} X \cdot Y$$

3) jeśli  $P[X \neq 0] = 1$ , to

$$I[X_n \neq 0] \cdot \frac{1}{X_n} \xrightarrow{\text{p.n.}} \frac{1}{X}$$

## 17.2 Charakteryzacja zbieżności «prawie na pewno»

Niech  $\{X_n, n \geq 1\}$  będzie ciągiem zmiennych losowych, a  $X$  zmienną losową.

Następujące warunki są równoważne:

$$1) X_n \xrightarrow{\text{p.n.}} X$$

2) dla każdego  $\varepsilon > 0$

$$\lim_{N \rightarrow \infty} P\left[\bigcap_{n=N}^{\infty} \{|X_n - X| \leq \varepsilon\}\right] = 1$$

3) dla każdego  $\varepsilon > 0$

$$\lim_{N \rightarrow \infty} P\left[\bigcup_{n=N}^{\infty} \{|X_n - X| > \varepsilon\}\right] = 0$$

### Dowód 17.1

Równoważność warunków (2) i (3) jest oczywista<sup>a</sup>. Wystarczy zatem pokazać, że równoważne są warunki (1) i (2).

$$\begin{aligned} X_n \xrightarrow{\text{p.n.}} X &\iff P[\omega : \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega) = 1] \\ &\iff \bigwedge_{\varepsilon > 0} P[\omega : \bigvee_N \bigwedge_{n \geq N} |X_n(\omega) - X(\omega)| \leq \varepsilon] = 1 \\ &\iff \bigwedge_{\varepsilon > 0} P[\omega : \bigcup_{N=1}^{\infty} \bigcap_{n=N}^{\infty} \{|X_n(\omega) - X(\omega)| \leq \varepsilon\}] = 1 \end{aligned}$$

Wprowadzamy oznaczenie:

$$B_N = \bigcap_{n=N}^{\infty} \{|X_n(\omega) - X(\omega)| \leq \varepsilon\}$$

Ciąg  $\{B_N, N \geq 1\}$  tworzy ciąg wstępujący, więc na mocy twierdzenia o ciągłości miary mamy

$$\bigwedge_{\varepsilon > 0} P\left[\bigcup_{N=1}^{\infty} B_N\right] = 1 \iff \bigwedge_{\varepsilon > 0} \lim_{N \rightarrow \infty} P[B_N] = 1$$

$$\iff \bigwedge_{\varepsilon > 0} P\left[\omega : \bigcap_{n=N}^{\infty} \{|X_n(\omega) - X(\omega)| \leq \varepsilon\}\right] = 1 \quad \text{CND}$$

$$P\left[\bigcup_{n=N}^{\infty} \{|X_n - X| > \varepsilon\}\right]' = \bigcap_{n=N}^{\infty} \{|X_n - X| \leq \varepsilon\}$$

### 17.2.1 Wniosek

Jeżeli dla każdego  $\varepsilon > 0$  mamy

$$\sum_{n=1}^{\infty} P[|X_n - X| > \varepsilon] < \infty \quad \text{to} \quad X_n \xrightarrow{\text{p.n.}} X$$

#### Dowód 17.2

Zauważmy, że

$$P\left[\bigcup_{n=N}^{\infty} \{|X_n - X| > \varepsilon\}\right] \leq \sum_{n=N}^{\infty} P[|X_n - X| > \varepsilon]$$

Wtedy

$$\lim_{N \rightarrow \infty} P\left[\bigcup_{n=N}^{\infty} \{|X_n - X| > \varepsilon\}\right]$$

$$\leq \lim_{N \rightarrow \infty} \sum_{n=N}^{\infty} P[|X_n - X| > \varepsilon] \rightarrow 0 \quad \text{jako reszta szeregu zbieżnego}$$

### 17.3 Zbieżność «prawie na pewno» i zbieżność w/g prawdopodobieństwa

Zbieżność prawie na pewno implikuje zbieżność według prawdopodobieństwa:

$$X_n \xrightarrow{\text{p.n.}} X \implies X_n \xrightarrow{P} X$$

**Dowód 17.3**

Niech  $\varepsilon > 0$ . Zauważmy, że

$$P \left[ \bigcap_{k=n}^{\infty} \{|X_k - X| \leq \varepsilon\} \right] \leq P[|X_n - X| \leq \varepsilon]$$

oraz

$$P[|X_n - X| > \varepsilon] = 1 - P[|X_n - X| \leq \varepsilon] \leq 1 - P \left[ \bigcap_{k=n}^{\infty} \{|X_k - X| \leq \varepsilon\} \right]$$

Stąd mamy:

$$0 \leq \lim_{n \rightarrow \infty} P[|X_n - X| > \varepsilon] \leq 1 - \underbrace{\lim_{n \rightarrow \infty} P \left[ \bigcap_{k=n}^{\infty} \{|X_k - X| \leq \varepsilon\} \right]}_{=1 \text{ bo } X_n \xrightarrow{p.n.} X} = 1 - 1 = 0$$

Na mocy twierdzenia o trzech ciągach mamy:

$$\lim_{n \rightarrow \infty} P[|X_n - X| > \varepsilon] = 0$$

**17.4 Zbieżność w/g p-tego momentu i zbieżność w/g prawdopodobieństwa**

Zbieżność w/g p-tego momentu implikuje zbieżność według prawdopodobieństwa:

$$X_n \xrightarrow{L^p} X \implies X_n \xrightarrow{p} X$$

**Dowód 17.4**

Niech  $\varepsilon > 0$ . Zauważmy, że na mocy nierówności Markowa mamy:

$$\lim_{n \rightarrow \infty} P[|X_n - X| > \varepsilon] \leq \lim_{n \rightarrow \infty} \frac{E|X_n - X|^p}{\varepsilon^p} \underbrace{=}_{X_n \xrightarrow{L^p} X} 0$$

## 17.5 Twierdzenie Riesz<sup>12</sup>

Jeżeli  $X_n \xrightarrow{p} X$ , to istnieje podciąg  $\{X_{n_k}, k \geq 1\}$  taki, że

$$X_{n_k} \xrightarrow{p.n.} X$$


---

2024-12-17

## 18 Twierdzenia graniczne

**Twierdzenia graniczne** formułują warunki, przy których dla ciągu zmiennych losowych  $\{X_n, n \geq 1\}$  istnieje asymptotyczny rozkład i określają postać tego rozkładu.

- **Prawa wielkich liczb** – zbieżność do rozkładu jednopunktowego
- **Lokalne twierdzenia graniczne** – zbieżność funkcji gęstości lub rozkładu prawdopodobieństwa
- **Integralne twierdzenia graniczne** – zbieżność dystrybuant

### 18.1 Prawo wielkich liczb Bernoulliego

Spostrzeżenie: Przy wielokrotnym rzucie monetą symetryczną częstość wystąpienia orła stabilizuje się w końcu w pobliżu  $\frac{1}{2}$ .

Jakob Bernoulli w książce *Ars Conjectandi* (1713 r).

Z prawdopodobieństwem dowolnie bliskim 1 można się spodziewać, iż przy dostatecznie wielkiej liczbie prób częstość danego zdarzenia losowego będzie się dowolnie mało różniła od jego prawdopodobieństwa

W dzisiejszych czasach:

Jeśli  $S_n$  oznacza liczbę sukcesów w schemacie  $n$  niezależnych prób Bernoulliego, gdzie prawdopodobieństwo sukcesu w pojedynczej próbie jest równe  $p$ , to

$$\bigwedge_{\varepsilon > 0} \lim_{n \rightarrow \infty} P\left[\left|\frac{S_n}{n} - p\right| \leq \varepsilon\right] = 1$$

---

<sup>12</sup>/Risa/

**Dowód 18.1**

$$P\left[\left|\frac{S_n}{n} - p\right| > \varepsilon\right] \leq \frac{E\left(\frac{S_n}{n} - p\right)^2}{\varepsilon^2} = \frac{E(S_n - np)^2}{n^2\varepsilon^2} = \frac{npq}{n^2\varepsilon^2} = \frac{pq}{n\varepsilon^2} \xrightarrow{n \rightarrow \infty} 0$$

Zatem

$$\lim_{n \rightarrow \infty} P\left[\left|\frac{S_n}{n} - p\right| \leq \varepsilon\right] = 1$$

Jako granica prawdopodobieństwa zdarzenia przeciwnego

**18.1.1 Interpretacja**

- Sens tego twierdzenia polega na tym, że wprowadzone przez nas określenie prawdopodobieństwa odpowiada intuicyjnemu rozumieniu prawdopodobieństwa jako granicy częstości pojawiania się zdarzenia.
- $\frac{S_n}{n}$  – można rozpatrywać jako częstość pojawiania się zdarzenia  $A$  – sukcesu, dla którego  $P(A) = p$ .
- Twierdzenie mówi, że w sensie zbieżności słabej (w/g prawdopodobieństwa)  $\frac{S_n}{n}$  zbliża się nieograniczenie do  $p$ .

**18.2 Mocne prawo wielkich liczb Bernoulliego**

Przy założeniach z twierdzenia poprzedniego

$$\frac{S_n}{n} \xrightarrow[n \rightarrow \infty]{\text{p.n.}} p$$

**Dowód 18.2**

W dowodzie korzystać będziemy z lematu Borela-Cantelliego i następującej nierówności Bernsteina:

$$P\left[\left|\frac{S_n}{n} - p\right| > \varepsilon\right] \leq 2e^{-\frac{n\varepsilon^2}{4}}$$

$$\sum_{n=1}^{\infty} P\left[\left|\frac{S_n}{n} - p\right| > \varepsilon\right] \leq 2 \sum_{n=1}^{\infty} e^{-\frac{n\varepsilon^2}{4}} < \infty$$

Skoro

$$\sum_{n=1}^{\infty} P\left[\left|\frac{S_n}{n} - p\right| > \varepsilon\right] < \infty$$

To na mocy lematu Borela-Cantelliego mamy

$$P\left[\bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} \left\{\left|\frac{S_n}{n} - p\right| > \varepsilon\right\}\right] = 0$$

Na podstawie warunku równoważnego zbieżności prawie na pewno i tw. o ciągłości miary mamy

$$\begin{aligned} & \lim_{m \rightarrow \infty} P\left[\bigcup_{n=m}^{\infty} \left\{\left|\frac{S_n}{n} - p\right| > \varepsilon\right\}\right] \\ &= P\left[\bigcap_{m=1}^{\infty} \bigcup_{n=m}^{\infty} \left\{\left|\frac{S_n}{n} - p\right| > \varepsilon\right\}\right] = 0 \end{aligned}$$

### 18.3 Prawo wielkich liczb

Niech

- $\{X_n, n \geq 1\}$  będzie ciągiem zmiennych losowych o wartościach oczekiwanych  $EX_n, n \geq 1$
- $S_n = X_1 + X_2 + \dots + X_n$

Mówimy, że ciąg  $\{X_n, n \geq 1\}$  spełnia **mocne prawo wielkich liczb**, jeżeli

$$\frac{S_n - ES_n}{n} \xrightarrow[n \rightarrow \infty]{\text{p.n.}} 0$$

Mówimy, że ciąg  $\{X_n, n \geq 1\}$  spełnia **ślabe prawo wielkich liczb**, jeżeli

$$\frac{S_n - ES_n}{n} \xrightarrow[n \rightarrow \infty]{\text{p.}} 0$$

Problem prawa wielkich liczb można uogólnić i rozważać problem zbieżności

$$\frac{S_n - a_n}{b_n}$$

gdzie  $\{a_n, n \geq 1\}$  jest dowolnym ciągiem liczb rzeczywistych, a  $\{b_n, n \geq 1\}$  jest ciągiem liczb rzeczywistych dodatnich rozbieżnym do  $+\infty$ .

Historycznie rzecz biorąc pierwszym słabym prawem wielkich liczb było prawo wielkich liczb Bernoulliego.

### 18.4 Stałe prawo wielkich liczb Markowa

Jeżeli  $\{X_n, n \geq 1\}$  jest ciągiem zmiennych losowych takich, że

$$\lim_{n \rightarrow \infty} \frac{D^2(S_n)}{n^2} = 0$$

to dla każdego  $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P \left[ \omega : \left| \frac{1}{n} \sum_{k=1}^n (X_k(\omega) - EX_k) \right| < \varepsilon \right] = 1$$

#### Dowód 18.3

Niech  $Y_n = \frac{1}{n} \sum_{k=1}^n X_k$ . Z założenia mamy, że

$$\lim_{n \rightarrow \infty} D^2(Y_n) = \lim_{n \rightarrow \infty} \frac{D^2(S_n)}{n^2} = 0$$

Na mocy nierówności Czebyszewa mamy

$$\begin{aligned} 1 &\geq P \left[ \omega : \left| \frac{1}{n} \sum_{k=1}^n (X_k(\omega) - EX_k) \right| < \varepsilon \right] = P[\omega : |Y_n(\omega) - EY_n| < \varepsilon] \\ &= 1 - P[\omega : |Y_n(\omega) - EY_n| \geq \varepsilon] \\ &\geq 1 - \frac{1}{\varepsilon^2} D^2(Y_n) \xrightarrow{n \rightarrow \infty} 1 \end{aligned}$$

### 18.5 Stałe prawo wielkich liczb Czebyszewa

Niech  $\{X_n, n \geq 1\}$  będzie ciągiem zmiennych losowych parami nieskorelowanych, o wspólnie ograniczonych wariancjach. Wtedy dla każdego  $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P \left[ \omega : \left| \frac{1}{n} \sum_{k=1}^n (X_k(\omega) - EX_k) \right| < \varepsilon \right] = 1$$

**Dowód 18.4**

$$\begin{aligned}
1 &\geq \lim_{n \rightarrow \infty} P \left[ \omega : \left| \frac{1}{n} \sum_{k=1}^n (X_k(\omega) - EX_k) \right| < \varepsilon \right] \\
&= 1 - \lim_{n \rightarrow \infty} P \left[ \omega : \left| \frac{1}{n} \sum_{k=1}^n (X_k(\omega) - EX_k) \right| \geq \varepsilon \right] \\
&\geq 1 - \frac{D^2(\sum_{k=1}^n X_k)}{n^2 \varepsilon^2} \\
&= 1 - \frac{\sum_{k=1}^n D^2(X_k)}{n^2 \varepsilon^2} \\
&\geq 1 - \frac{nC}{n^2 \varepsilon^2} \rightarrow_{n \rightarrow \infty} 1
\end{aligned}$$

**Achtung! 19**

Twierdzenia Markowa, Bernoulliego oraz Czebyszewa wymagają by zmienne losowe  $\{X_n, n \geq 1\}$  miały skończone wariancje.

**18.6 Twierdzenie Kołmogorowa, mocne prawo wielkich liczb Kołmogorowa**

Niech  $\{X_n, n \geq 1\}$  będzie ciągiem niezależnych zmiennych losowych takich, że  $D^2(X_n) < \infty, n \in \{1, 2, \dots\}$  i niech  $\{b_n, n \geq 1\}$  będzie ciągiem rosnącym liczb dodatnich, takim, że

$$\lim_{n \rightarrow \infty} b_n = \infty \quad \text{oraz} \quad \sum_{n=1}^{\infty} \frac{D^2(X_n)}{b_n^2} < \infty$$

Wtedy

$$\lim_{n \rightarrow \infty} \frac{S_n - ES_n}{b_n} = 0 \quad \text{p.n.}$$

W szczególności, jeżeli

$$\sum_{n=1}^{\infty} \frac{D^2(X_n)}{n^2} < \infty$$

to  $\{X_n, n \geq 1\}$  spełnia mocne prawo wielkich liczb.

**18.7 Mocne prawo wielkich liczb Kołmogorowa**

Jeżeli  $\{X_n, n \geq 1\}$  jest ciągiem niezależnych zmiennych losowych o jednakowym rozkładzie i  $E|X_1| < \infty$ , to  $\{X_n, n \geq 1\}$  spełnia **mocne prawo wielkich liczb**, czyli

$$\lim_{n \rightarrow \infty} \frac{S_n}{n} = EX_1 \quad \text{p.n.}$$

## 19 Lokalne twierdzenia graniczne

Lokalne twierdzenia graniczne dotyczą granicznego zachowania się ciągów rozkładów zmiennych losowych wyrażonych za pomocą:

- funkcji prawdopodobieństwa  $p_i = P[X = x_i]$  (dla rozkładów dyskretnych)
- funkcji gęstości  $f(x)$  (dla rozkładów ciągłych)

### 19.1 Twierdzenie Poissona

Jeśli  $X_n \sim \mathcal{B}(n, p_n)$  dla  $n \in \mathbb{N}$  i spełnione są warunki:

$$p_n \rightarrow 0 \quad np_n \rightarrow \lambda > 0, \quad \text{gdy } n \rightarrow \infty$$

to

$$\binom{n}{k} p_n^k (1 - p_n)^{n-k} \rightarrow \frac{\lambda^k}{k!} \cdot e^{-\lambda}, \quad \text{gdy } n \rightarrow \infty$$

#### Dowód 19.1

Niech  $\lambda_n = n \cdot p_n$ ,  $\lambda_n \rightarrow_{n \rightarrow \infty} \lambda$ ,  $p_n = \frac{\lambda_n}{n}$

$$\begin{aligned} \binom{n}{k} p_n^k (1 - p_n)^{n-k} &= \frac{n!}{k!(n-k)!} \cdot p_n^k (1 - p_n)^{n-k} \\ &= \frac{n(n-1)(n-2) \dots (n-k+1)}{k!} \left(\frac{\lambda_n}{n}\right)^k \left(1 - \frac{\lambda_n}{n}\right)^{n-k} \\ &= \frac{n}{n} \cdot \frac{n-1}{n} \cdot \frac{n-2}{n} \dots \frac{n-k+1}{n} \cdot \frac{\lambda_n^k}{k!} \left(1 - \frac{\lambda_n}{n}\right)^n \cdot \left(1 - \frac{\lambda_n}{n}\right)^{-k} \\ &= \frac{n-1}{n} \cdot \frac{n-2}{n} \dots \frac{n-k+1}{n} \cdot \frac{\lambda_n^k}{k!} \left(1 - \frac{\lambda_n}{n}\right)^{-\frac{n}{\lambda_n}(-\lambda_n)} \cdot \left(1 - \frac{\lambda_n}{n}\right)^{-k} \\ &\rightarrow_{n \rightarrow \infty} \frac{\lambda^k}{k!} e^{-\lambda} \end{aligned}$$

## 19.2 Twierdzenie Moivre'a-Laplace'a

Niech  $S_n$  ma rozkład dwumianowy  $\mathcal{B}(n, p)$ , a  $Y_n = \frac{S_n - np}{\sqrt{np(1-p)}}$   
 Odejmujemy  $ES_n$  i dzielimy przez  $D^2(S_n)$

Wtedy

$$\lim_{n \rightarrow \infty} \sqrt{np(1-p)} P \left[ Y_n = \frac{k - np}{\sqrt{np(1-p)}} \right] = \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}}$$

gdzie

$$y = \lim_{n \rightarrow \infty} \frac{k - np}{\sqrt{np(1-p)}} \quad \text{i gdy } 0 \leq k \leq n \wedge n \rightarrow \infty$$

### 19.2.1 Wzory praktyczne

W szczególności dla dostatecznie dużych  $n$  mamy wzór przybliżony:

$$\begin{aligned} P[S_n = k] &\approx \frac{1}{\sqrt{np(1-p)}} \cdot \varphi \left( \frac{k - np}{\sqrt{np(1-p)}} \right) \\ &= \frac{1}{\sqrt{2\pi \cdot np(1-p)}} e^{-\frac{(k - np)^2}{2np(1-p)}} \end{aligned}$$

## 19.3 Centralne Twierdzenie Graniczne Lindeberga-Lévy'ego – integralne

Niech  $\{X_n, n \geq 1\}$  będzie ciągiem:

- niezależnych zmiennych losowych
- o jednakowych rozkładach
- z wartością oczekiwaną  $EX_1 = m$
- ze skończoną wariancją  $D^2(X_1) = \sigma^2 < \infty$

Wtedy dla dowolnej liczby  $t \in \mathbb{R}$

$$\lim_{n \rightarrow \infty} P \left[ \frac{\sum_{i=1}^n X_i - n \cdot m}{\sigma \sqrt{n}} \leq t \right] = \Phi(t)$$

gdzie  $\Phi(t)$  jest dystrybuantą rozkładu  $N(0, 1)$

**Dowód 19.2**

Bez utraty ogólności możemy założyć, że  $EX_i = m = 0$ .

W przeciwnym przypadku rozważamy zmienne losowe

$$Y_n = X_n - m \quad (\text{wtedy } \sum_{i=1}^n X_i - n \cdot m = \sum_{i=1}^n Y_i)$$

Niech  $\varphi(t) = Ee^{itX_1}$

Wiemy, że jeśli  $E|X|^n < \infty$ , to  $\varphi_X^{(n)}(0) = i^n EX^n$

Zatem

$$\varphi'(0) = iEX_1 = 0, \quad \varphi'' = i^2 EX_1^2 = -EX_1^2 = -D^2(X_1) = -\sigma^2$$

oraz

$$\varphi(0) = 1$$

Z rozwinięcia Taylora drugiego rzędu mamy

$$\varphi(t) = \varphi(0) + \frac{\varphi'(0)}{1!}t + \frac{\varphi''(0)}{2!} + o(t^2)$$

Zatem

$$\varphi(t) = 1 + 0 - \frac{\sigma^2}{2}t^2 + o(t^2)$$

Wyznaczamy teraz funkcję charakterystyczną zmiennej

$$\frac{\sum_{i=1}^n X_i - n \cdot m}{\sigma\sqrt{n}} = \frac{\sum_{i=1}^n X_i}{\sigma\sqrt{n}} \quad \text{bo umówiliśmy się, że } m = 0$$

$$\begin{aligned}
E e^{it \cdot \frac{\sum_{i=1}^n X_i}{\sigma\sqrt{n}}} &= E e^{i \frac{t}{\sigma\sqrt{n}} \sum_{i=1}^n X_i} \\
&= E \left( e^{i \frac{t}{\sigma\sqrt{n}} X_1} \cdot e^{i \frac{t}{\sigma\sqrt{n}} X_2} \dots e^{i \frac{t}{\sigma\sqrt{n}} X_n} \right) \\
&\stackrel{\text{z niezależności}}{=} E \left( e^{i \frac{t}{\sigma\sqrt{n}} X_1} \right) \cdot E \left( e^{i \frac{t}{\sigma\sqrt{n}} X_2} \right) \dots E \left( e^{i \frac{t}{\sigma\sqrt{n}} X_n} \right) \\
&= \prod_{i=1}^n \varphi_{X_i} \left( \frac{t}{\sigma\sqrt{n}} \right) \\
&\stackrel{\text{jednakowe rozkłady}}{=} \prod_{i=1}^n \varphi \left( \frac{t}{\sigma\sqrt{n}} \right) \\
&= \left( \varphi \left( \frac{t}{\sigma\sqrt{n}} \right) \right)^n \\
&\stackrel{\text{z rozwinięcia Taylora}}{=} \left( 1 - \frac{\sigma^2}{2} \left( \frac{t}{\sigma\sqrt{n}} \right)^2 + o \left( \left( \frac{t}{\sigma\sqrt{n}} \right)^2 \right) \right)^n \\
&= \left( 1 - \frac{t^2}{2n} + o \left( \frac{t^2}{\sigma n} \right) \right)^n \\
&= \left[ \left( 1 - \frac{t^2}{2n} + o \left( \frac{t^2}{\sigma^2 n} \right) \right)^{-\frac{2n}{t^2}} \right]^{-\frac{t^2}{2}} \rightarrow_{n \rightarrow \infty} e^{-\frac{t^2}{2}}
\end{aligned}$$

Otrzymaliśmy postać funkcji charakterystycznej zmiennej losowej

$$Z_n = \frac{\sum_{i=1}^n X_i}{\sigma\sqrt{n}}$$

$$\varphi_{Z_n}(t) \rightarrow_{n \rightarrow \infty} e^{-\frac{t^2}{2}}$$

Rozważmy teraz zmienną losową  $X$  o rozkładzie  $N(0, 1)$ . Wyznaczamy jej funkcję charakterystyczną

$$\begin{aligned}
\varphi_X(t) &= Ee^{itX} = \int_{-\infty}^{+\infty} e^{itx} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx \\
&= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{itx} e^{-\frac{x^2}{2}} dx \\
&= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{-\frac{x^2}{2} + itx} dx \\
&= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{-\frac{x^2 - 2itx}{2}} dx \\
&= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{-\frac{x^2 - 2itx - t^2}{2}} \cdot e^{\frac{t^2}{2}} dx \\
&= e^{-\frac{t^2}{2}} \frac{1}{\sqrt{2\pi}} \underbrace{\int_{-\infty}^{+\infty} e^{-\frac{(x-it)^2}{2}} dx}_{\sqrt{2\pi}} \\
&= e^{-\frac{t^2}{2}}
\end{aligned}$$

Mamy zatem postać funkcji rozkładu normalnego  $N(0, 1)$ , tj.

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

co dowodzi, że rozkładem granicznym zmiennej losowej

$$\frac{\sum_{i=1}^n X_i - n \cdot m}{\sigma \sqrt{n}}$$

jest rozkład normalny standaryzowany  $N(0, 1)$

## 19.4 Twierdzenie Moivre'a-Laplace'a – integralne

Twierdzenie Moivre'a-Laplace'a jest wnioskiem z Centralnego Twierdzenia Granicznego Lindeberga-Levy'ego

Niech  $S_n$  będzie liczbą sukcesów w  $n$  próbach Bernoulliego z prawdopodobieństwem sukcesu  $p$ .

Wtedy dla dowolnych  $x \in \mathbb{R}$

$$P \left[ \frac{S_n - np}{\sqrt{np(1-p)}} \leq x \right] \xrightarrow{n \rightarrow \infty} P(Y \leq x) = \Phi(x)$$

gdzie  $\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt$  to dystrybuanta standaryzowanego rozkładu normalnego  $N(0, 1)$

**Dowód 19.3**

Niech  $S_n = X_1 + X_2 + \dots + X_n$

gdzie zmienne losowe  $\{X_n, n \geq 1\}$  są:

- niezależne
- mają jednakowy rozkład:  $P[X_i = 1] = p$  i  $P[X_i = 0] = 1 - p$

Wtedy

$$EX_1 = p = m \quad \text{i} \quad D^2(X_1) = p(1 - p) = \sigma^2$$

Zatem na mocy Centralnego Twierdzenia Granicznego Lindeberga-Levy'ego mamy

$$P \left[ \frac{S_n - np}{\sqrt{np(1-p)}} \leq x \right] = P \left[ \frac{S_n - nm}{\sigma\sqrt{n}} \leq x \right] \xrightarrow{n \rightarrow \infty} \Phi(x)$$

2025-01-07

## 20 Warunkowa wartość oczekiwana

### 20.1 Warunkowa wartość oczekiwana względem zdarzenia $A$

- $(\Omega, \mathcal{F}, P)$  – dana przestrzeń probabilistyczna
- $A \in \mathcal{F}, P(A) > 0$
- $P_A$  – prawdopodobieństwo warunkowe względem  $A$
- $X$  – całkowalna zmienna losowa określona na  $(\Omega, \mathcal{F}, P)$

**Warunkową wartością oczekiwaną** zmiennej losowej  $X$  pod warunkiem zdarzenia losowego  $A$  nazywamy liczbę  $E(X|A)$ :

$$E(X|A) = \int_{\Omega} X(\omega) dP_A$$

Jednak znacznie poręczniejszy w użyciu jest następujący, równoważny wzór:

$$E(X|A) = \frac{1}{P(A)} \int_A X(\omega) dP$$

### 20.2 Warunkowa wartość oczekiwana względem $\sigma$ -ciała

- $(\Omega, \mathcal{F}, P)$  – dana przestrzeń probabilistyczna

Niech  $X$  będzie zmienną losową na  $(\Omega, \mathcal{F}, P)$  i niech  $\mathcal{A}$  będzie  $\sigma$ -ciałem zawartym w  $\sigma$ -ciele  $\mathcal{F}$

**Warunkową wartością oczekiwaną** zmiennej losowej  $X$  pod warunkiem  $\sigma$ -ciała  $\mathcal{A}$  nazywamy **zmienną losową**  $E(X|\mathcal{A})$  spełniającą warunki:

1.  $E(X|\mathcal{A})$  jest funkcją  $\mathcal{A}$ -mierzalną
2. dla dowolnego  $A \in \mathcal{A}$

$$\int_A X dP = \int_A E(X|\mathcal{A}) dP$$

### Twierdzenie 20.1

Dla dowolnej zmiennej losowej całkowlanej na przestrzeni  $(\Omega, \mathcal{F}, P)$  i dowolnego  $\sigma$ -ciała  $\mathcal{A}$ ,  $\mathcal{A} \subset \mathcal{F}$  istnieje warunkowa wartość oczekiwana  $E(X|\mathcal{A})$ .

Ponadto  $E(X|\mathcal{A})$  jest wyznaczona jednoznacznie z dokładnością do zbioru miary zero

### Dowód 20.1

Dowód jednoznaczności.

Założmy, że  $Y_1, Y_2$  spełniają warunki 1) i 2) oraz

$$Y_1 \neq Y_2$$

Zauważmy, że zdarzenie  $\{Y_1 > Y_2\} \in \mathcal{A}$ , bo  $Y_1$  i  $Y_2$  są  $\mathcal{A}$ -mierzalne

Zatem

$$\int_{Y_1 > Y_2} Y_1 dP = \int_{Y_1 > Y_2} X dP = \int_{Y_1 > Y_2} Y_2 dP$$

Stąd

$$\int_{Y_1 > Y_2} (Y_1 - Y_2) dP = 0$$

$Y_1 - Y_2 > 0$ , zatem miara zbioru  $\{Y_1 > Y_2\}$  musi być równa zero:

$$P[Y_1 > Y_2] = 0$$

To samo rozumowanie zastosowane do  $\{Y_2 > Y_1\}$  pokazuje ostatecznie, że

$$P[Y_1 \neq Y_2] = 0$$

**20.2.1 Własność 1**

Jeśli  $A = \{\emptyset, \Omega\}$ , to

$$E(X|\mathcal{A}) = EX \quad \text{p.n.}$$

**Dowód 20.2**

$A = \{\emptyset, \Omega\}$  – jest  $\sigma$ -ciałem atomowym.

Wtedy każda zmienna losowa  $X$ ,  $\mathcal{A}$ -mierzalna jest postaci:

$$X = a_1 I_{\emptyset} + a_2 I_{\Omega} = a_2$$

Zatem

$$\int_{\Omega} E(X|\mathcal{A}) = \int_{\Omega} E(a_2|\mathcal{A}) = \int_{\Omega} a_2 dP$$

Stąd

$$\int_{\Omega} (E(X|\mathcal{A}) - a_2) dP = 0$$

co oznacza, że

$$E(X|\mathcal{A}) = a_2 \quad \text{p.n.}$$

Ponadto mamy:

$$\int_{\Omega} E(X|\mathcal{A}) dP = \underbrace{\int_{\Omega} X dP}_{EX} = \int_{\Omega} a_2 dP = a_2$$

Stąd

$$EX = a_2$$

co dowodzi ostatecznie, że

$$E(X|\mathcal{A}) = EX \quad \text{p.n.}$$

**20.2.2 Własność 2**

Jeśli  $X$  jest  $\mathcal{A}$ -mierzalna, to

$$E(X|\mathcal{A}) = X \quad \text{p.n.}$$

**Dowód 20.3**

Z definicji, dla dowolnego  $A \in \mathcal{A}$  mamy:

$$\int_A E(X|\mathcal{A})dP = \int_A XdP \iff \int_A E(X|\mathcal{A})dP - \int_A XdP$$

$$\int_A (E(X|\mathcal{A}) - X) dP = 0 \iff E(X|\mathcal{A}) - X = 0 \quad \text{p.n.}$$

$$E(X|\mathcal{A}) = X \quad \text{p.n.}$$

**20.2.3 Własność 3**

Jeśli  $X \geq 0$ , to

$$E(X|\mathcal{A}) \geq 0 \quad \text{p.n.}$$

**Dowód 20.4**

Niech  $\varepsilon > 0$ . Wprowadzamy oznaczenie

$$A_\varepsilon = \{\omega : E(X|\mathcal{A}) < -\varepsilon\}$$

$A_\varepsilon \in \mathcal{A}$  zatem

$$\bigwedge_{\varepsilon > 0} 0 \leq \int_{A_\varepsilon} XdP = \int_{A_\varepsilon} E(X|\mathcal{A})dP \leq -\varepsilon P[A_\varepsilon] \leq 0$$

co dowodzi, że  $\int_{A_\varepsilon} XdP = 0$  i stąd, (bo  $X \geq 0$ ),

$$A[A_\varepsilon] = 0 \iff P[\omega : E(X|\mathcal{A}) < -\varepsilon] = 0$$

$$\iff E(X|\mathcal{A}) \geq 0 \quad \text{p.n.}$$

**20.2.4 Własność 4**

$$|E(X|\mathcal{A})| \leq E(|X| | \mathcal{A}) \quad \text{p.n.}$$

**Dowód 20.5**

Zauważmy, że

$$X \geq Y \implies E(X|\mathcal{A}) \geq E(Y|\mathcal{A}) \quad \text{p.n.}$$

Rzeczywiście, jeżeli  $X \geq Y$ , to  $Z = X - Y \geq 0$ .

Wtedy na mocy Własności 3,  $E(Z|\mathcal{A}) \geq 0$  p.n.

$$\begin{aligned} \bigwedge_{A \in \mathcal{A}} 0 &\leq \int_A E(Z|\mathcal{A}) dP = \int_A Z dP \\ &= \int_A (X - Y) dP \\ &= \int_A X dP - \int_A Y dP \\ &= \int_A E(X|\mathcal{A}) dP - \int_A E(Y|\mathcal{A}) dP \\ &= \int_A (E(X|\mathcal{A}) - E(Y|\mathcal{A})) dP \end{aligned}$$

$$\implies E(X|\mathcal{A}) - E(Y|\mathcal{A}) \geq 0 \quad \text{p.n.} \iff E(X|\mathcal{A}) \geq E(Y|\mathcal{A}) \quad \text{p.n.}$$

Korzystając z powyższego faktu i nierówności

$$-|X| \leq X \leq |X|$$

mamy

$$E(-|X| | \mathcal{A}) \leq E(X|\mathcal{A}) \leq E(|X| | \mathcal{A}) \quad \text{p.n.}$$

Ponadto dla każdego  $A \in \mathcal{A}$  mamy

$$\int_A E(-|X| | \mathcal{A}) dP = \int_A (-|X|) dP = \int_A E(|X| | \mathcal{A}) dP$$

Stąd

$$\begin{aligned} \int_A [E(-|X| | \mathcal{A}) + E(|X| | \mathcal{A})] dP &= 0 \quad \text{p.n.} \\ \implies E(-|X| | \mathcal{A}) + E(|X| | \mathcal{A}) &= 0 \quad \text{p.n.} \\ \iff E(-|X| | \mathcal{A}) &= -E(|X| | \mathcal{A}) \quad \text{p.n.} \end{aligned}$$

Łącząc zatem dwie zależności:

$$E(-|X| | \mathcal{A}) \leq E(X|\mathcal{A}) \leq E(|X| | \mathcal{A}) \quad \text{p.n.}$$

i

$$E(-|X| | \mathcal{A}) = -E(|X| | \mathcal{A}) \quad \text{p.n.}$$

dostajemy

$$-E(|X| | \mathcal{A}) \leq E(X|\mathcal{A}) \leq E(|X| | \mathcal{A}) \quad \text{p.n.}$$

co jest równoważne

$$|E(X|\mathcal{A})| \leq E(|X| | \mathcal{A}) \quad \text{p.n.}$$

### 20.2.5 Własność 5

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

$$E((aX + bY) | \mathcal{A}) = aE(X|\mathcal{A}) + bE(Y|\mathcal{A}) \quad \text{p.n.}$$

#### Dowód 20.6

$$\begin{aligned} \bigwedge_{A \in \mathcal{A}} \int_A E((aX + bY) | \mathcal{A}) dP &= \int_A (aX + bY) dP \\ &= a \int_A X dP + b \int_A Y dP \\ &= a \int_A E(X|\mathcal{A}) dP + b \int_A E(Y|\mathcal{A}) dP \\ &= \int_A (aE(X|\mathcal{A}) + bE(Y|\mathcal{A})) dP \end{aligned}$$

Mamy zatem

$$\begin{aligned} \int_A E((aX + bY)|\mathcal{A}) dP &= \int_A (aE(X|\mathcal{A}) + bE(Y|\mathcal{A})) dP \\ \implies E((aX + bY)|\mathcal{A}) &= aE(X|\mathcal{A}) + bE(Y|\mathcal{A}) \quad \text{p.n.} \end{aligned}$$

2025-01-14

**20.2.6 Własność 6**

Jeżeli  $X_1 \leq X_2 \leq \dots$  jest niemalejącym ciągiem zmiennych losowych zbieżnych do zmiennej losowej  $X$  ( $X_n \nearrow X$ ), to

$$E(X_n|\mathcal{A}) \nearrow_{n \rightarrow \infty} E(X|\mathcal{A}) \quad \text{p.n.}$$

**Dowód 20.7**

Jeżeli  $X_1 \leq X_2 \leq \dots$ , to  $E(X_1|\mathcal{A}) \leq E(X_2|\mathcal{A}) \leq \dots$

Zatem na mocy tw. Lebesguea o monotonicznej zbieżności granica  $\lim_{n \rightarrow \infty} E(X_n|\mathcal{A})$  istnieje i jest funkcją  $\mathcal{A}$ -mierzalną oraz

$E(X|\mathcal{A}) = E(\lim_{n \rightarrow \infty} X_n|\mathcal{A})$  jest również  $\mathcal{A}$ -mierzalną

$$\begin{aligned} \bigwedge_{A \in \mathcal{A}} \int_A \lim_{n \rightarrow \infty} E(X_n|\mathcal{A}) dP &= \lim_{n \rightarrow \infty} \int_A E(X_n|\mathcal{A}) dP \\ &= \lim_{n \rightarrow \infty} \int_A X_n dP \\ &= \int_A \lim_{n \rightarrow \infty} X_n dP \\ &= \int_A E(\lim_{n \rightarrow \infty} X_n|\mathcal{A}) dP \\ &= \int_A E(X|\mathcal{A}) dP \\ \Leftrightarrow \lim_{n \rightarrow \infty} \int_A E(X_n|\mathcal{A}) dP &= \int_A E(X|\mathcal{A}) dP \quad \text{p.n.} \end{aligned}$$

**20.2.7 Własność 7**

Jeśli  $\mathcal{A}_1 \subset \mathcal{A}_2$ , to

$$E(X|\mathcal{A}_1) = E(E(X|\mathcal{A}_2)|\mathcal{A}_1) = E(E(X|\mathcal{A}_1)|\mathcal{A}_2)$$

**Dowód 20.8**

$E(X|\mathcal{A}_1)$  jest zmienną losową  $\mathcal{A}_1$ -mierzalną, zatem  $E(X|\mathcal{A}_1)$  jest również zmienną losową  $\mathcal{A}_2$ -mierzalną, bo  $\mathcal{A}_1 \subset \mathcal{A}_2$ .

Stąd

$$E(E(X|\mathcal{A}_1)|\mathcal{A}_2) = E(X|\mathcal{A}_1) \quad \text{p.n.}$$

Ponadto  $E(E(X|\mathcal{A}_2)|\mathcal{A}_1)$  jest zmienną losową  $\mathcal{A}_1$ -mierzalną.

Zatem

$$\begin{aligned} \bigwedge_{A \in \mathcal{A}_1} \int_A E(E(X|\mathcal{A}_2)|\mathcal{A}_1) dP &= \int_A E(X|\mathcal{A}_2) dP \\ &\stackrel{\text{p.n.}}{=} \int_A X dP \\ &= \int_A E(X|\mathcal{A}_1) dP \end{aligned}$$

Zatem

$$E(E(X|\mathcal{A}_2)|\mathcal{A}_1) = E(X|\mathcal{A}_1) \quad \text{p.n.}$$

### 20.2.8 Własność 8

$$EX = E(E(X|\mathcal{A}))$$

#### Dowód 20.9

$$E(E(X|\mathcal{A})) = \int_{\Omega} E(X|\mathcal{A}) dP = \int_{\Omega} X dP = EX$$

### 20.2.9 Własność 9

Jeżeli zmienna losowa  $X$  jest niezależna od  $\sigma$ -ciała, to

$$E(X|\mathcal{A}) = EX \quad \text{p.n.}$$

#### Dowód 20.10

- $EX$  jest stałą, jest więc funkcją  $\mathcal{A}$ -mierzalną
- Niech  $A \in \mathcal{A}$   
 $X$  jest niezależna od  $\sigma$ -ciała  $\mathcal{A}$ ,  
zatem zmienne losowe  $X$  i  $I_A$  są niezależne

Stąd dla dowolnego  $A \in \mathcal{A}$  mamy

$$\begin{aligned}
 \int_A E(X|\mathcal{A}) dP &= \int_A X dP \\
 &= \int_{\Omega} X I_A dP \\
 &= E(X \cdot I_A) \\
 &= EX \cdot EI_A \\
 &= EX \cdot \int_{\Omega} I_A dP \\
 &= \int_{\Omega} EX \cdot I_A dP \\
 &= \int_A EX dP
 \end{aligned}$$

czyli

$$E(X|\mathcal{A}) = EX \quad \text{p.n.}$$

### 20.2.10 Własność 10

Jeżeli  $Y$  jest ograniczoną zmienną losową  $\mathcal{A}$ -mierzalną, to

$$E(X \cdot Y | \mathcal{A}) = Y E(X|\mathcal{A}) \quad \text{p.n.}$$

$Y E(X|\mathcal{A})$  jest  $\mathcal{A}$ -mierzalna

#### Twierdzenie 20.2

Niech

- $\{A_i : i \in \mathbf{I}\}$  jest rozbiciem  $\Omega$ , tzn.
  - $\Omega = \bigcup_{i \in \mathbf{I}} A_i$ ,
  - $A_i \cap A_j = \emptyset, i \neq j$
- $\mathcal{G} = \sigma(\{A_i, i \in \mathbf{I}\})$

Wtedy

$$E(X|\mathcal{G}) = \sum_{i \in \mathbf{I}} E(X|A_i) \cdot I_{A_i}$$

## 21 Moment zatrzymania

### 21.1 Filtracja

- Niech  $(\Omega, \mathcal{F}, P)$  będzie przestrzenią probabilistyczną – modelem doświadczenia losowego
- Martyngały – narzędzie do analizy zjawisk rozwijających się w czasie.
- W tym celu musimy wzbogacić model doświadczenia losowego o niemalejącą rodzinę  $\sigma$ -ciał  $\mathcal{F}_t, t \in T$
- $T$  – zbiór indeksów

**Filtracją** nazywamy niemalejącą rodzinę  $\sigma$ -ciał  $\{\mathcal{F}_t, t \in T\}$ ,  $\mathcal{F}_t \subset \mathcal{F}$ , dla  $t \in T$

### 21.2 Interpretacja i przykład

Każde takie  $\sigma$ -ciało  $\mathcal{F}_t$  interpretujemy jako rodzinę zdarzeń, o których wiemy, czy zaszły, czy też nie zaszły do chwili  $t$

$$T = \mathbb{N}, \quad \mathcal{F}_1 \subset \mathcal{F}_2 \subset \dots$$

### 21.3 Rodzina zmiennych losowych adaptowana do filtracji

**Rodzina zmiennych losowych**  $\{X_t, t \in T\}$  jest **adaptowana** do filtracji  $\{\mathcal{F}_t, t \in T\}$ , jeżeli zmienne losowe  $X_t$  są  $\mathcal{F}_t$ -mieralne dla  $t \in T$

W szczególności rodzina zmiennych losowych  $\{X_t, t \in T\}$  jest adaptowana do naturalnej filtracji  $\{\mathcal{F}_t, t \in T\}$ , gdzie

$$\mathcal{F}_t = \sigma(\{X_s, s \leq t\}), \quad t \in T$$

### 21.4 Moment stopu

**Momentem stopu** względem filtracji  $\{\mathcal{F}_t, t \in T\}$  nazywamy zmienną losową  $\tau$ :

$$\tau : \Omega \rightarrow T \cup \{+\infty\}$$

spełniającą warunek

$$\bigwedge_{t \in T} \{\omega : \tau(\omega) \leq t\} \in \mathcal{F}_t$$

Moment stopu nazywa się czasem momentem Markowa lub momentem zatrzymania (ang.: stopping time)

### Przykład 21.1

- Rozważamy grę, w której 2 graczy  $A, B$  rzuca monetą.
- Jeśli wypadnie «orzeł», gracz  $A$  wygrywa od gracza  $B$  złotówkę, w przeciwnym razie gracz  $B$  wygrywa złotówkę
- Gra toczy się tak długo, jak długo obaj gracze mają pieniądze.
- Zakładamy, że gracz  $A$  postanawia wycofać się, gdy po raz pierwszy wygra 7 złotych
- Notuje więc swoje kolejne wygrane – są one zmiennymi losowymi

$$\xi_1, \xi_2, \dots,$$

o wartościach ze zbioru  $\{-1, 1\}$

- Łączna wygrana w chwili  $n$  to:

$$X_n = \sum_{i=1}^n \xi_i, \quad n = 1, 2, \dots$$

- przyjmujemy, że  $X_0 \equiv 0$
- Chwila wycofania się z gry gracza  $A$  jest zmienną losową, którą definiujemy następująco:

$$\tau_7 = \inf\{n : X_n = 7\}$$

- Zmienna losowa  $\tau_7$  jest **czasem zatrzymania**
- Zauważmy, że gracz  $A$  może nie doczekać się chwili gdy wygra 7 zł. (gdy np. moneta jest niesymetryczna lub gracz  $A$  ma ograniczony kapitał)

Oznacza to, że  $P[\tau_7 = +\infty] > 0$ . Zatem

$$\tau_7 : \Omega \rightarrow \mathbb{R} \cup \{+\infty\}$$

–  $\tau_7$  jest zmienną losową niewłaściwą.

- Ponadto w każdej chwili wiadomo, czy moment  $\tau_7$  już nastąpił, czy też nie, zatem wiemy, czy zdarzenie  $\{\tau_7 \leq t\}$  już nastąpiło, co oznacza, że

$$\{\tau_7 < t\} \in \mathcal{F}_t$$

- $\tau_7$  jest zatem czasem zatrzymania

## 22 Martyngały, nadmartyngały i podmartyngały

Niech

- $(\Omega, \mathcal{F}, P)$  – przestrzeń probabilistyczna
- $\{\mathcal{F}_t, t \in T\}$  – filtracja
- $\{X_t, t \in T\}$  – adaptowana rodzina zmiennych losowych

**Martyngał** Rodzinę  $(X_t, \mathcal{F}_t)_{t \in T}$ , gdzie zmienne losowe  $X_t$  są całkowalne dla  $t \in T$ , jest

- **martyngałem**, jeżeli dla  $s, t \in T$  i  $s \leq t$

$$E(X_t | \mathcal{F}_s) = X_s \quad \text{p.n.}$$

- **nadmartyngałem**, jeżeli dla  $s, t \in T$  i  $s \leq t$

$$E(X_t | \mathcal{F}_s) \leq X_s \quad \text{p.n.}$$

- **podmartyngałem**, jeżeli dla  $s, t \in T$  i  $s \leq t$

$$E(X_t | \mathcal{F}_s) \geq X_s \quad \text{p.n.}$$

### 22.1 Interpretacja

- Martyngał jest modelem gry sprawiedliwej w takim sensie, że:
  - średnia wygranej w chwili  $t$ , gdy znamy przebieg gry do chwili  $s$ ,  $E(X_t | \mathcal{F}_s)$  (zdarzenia, o których wiemy, czy zaszły, czy nie, jeżeli obserwujemy grę do chwili  $s$  tworzą  $\sigma$ -ciało  $\mathcal{F}_s$ ) jest równa  $X_s$ , czyli wygranej w chwili  $s$ .
- Nadmartyngał jest modelem gry niekorzystnej dla gracza.
- Podmartyngał jest modelem gry korzystnej dla gracza

## 22.2 Własności

Dla martyngału:

$$s, t \in T, s \leq t \text{ i } A \in \mathcal{F}_s$$

$$\int_A X_t dP = \int_A X_s dP$$

### Dowód 22.1

Dla martyngału mamy warunek  $E(X_t | \mathcal{F}_s) = X_s$

$$\bigwedge_{A \in \mathcal{F}_s} \int_A X_t dP = \int_A E(X_t | \mathcal{F}_s) dP = \int_A X_s dP$$

Jeśli  $T = \mathbb{N}$ , to warunek równoważny przyjmuje postać

$$E(X_{n+1} | \mathcal{F}_n) = X_n \quad n = 1, 2, \dots \quad \text{p.n.}$$

lub

$$E((X_{n+1} - X_n) | \mathcal{F}_n) = 0 \quad n = 1, 2, \dots \quad \text{p.n.}$$

## 22.3 Ciąg prognozowalny

Niech  $(X_n, \mathcal{F}_n)_{n=1}^{\infty}$  będzie martyngałem i  $\mathcal{F}_{-1} = \{\emptyset, \Omega\}$

Ciąg zmiennych losowych  $\{V_n, n \geq 0\}$  nazywamy ciągiem prognozowalnym, jeżeli zmienna losowa  $V_n$  jest  $\mathcal{F}_{n-1}$ -mierzalna dla  $n = 0, 1, 2, \dots$

## 22.4 Transformata martyngałowa

- Niech  $(X_n, \mathcal{F}_n)_{n=1}^{\infty}$  będzie martyngałem i  $\mathcal{F}_{-1} = \{\emptyset, \Omega\}$
- $\{V_n, n \geq 0\}$  – ciąg prognozowalny

Jeżeli założymy dodatkowo, że  $V_n, n \geq 0$  są ograniczone i zdefiniujemy

$$Z_n = V_0 X_0 + V_1 (X_1 - X_0) + \dots + V_n (X_n - X_{n-1})$$

to  $(Z_n, \mathcal{F}_n, n \geq 0)$  jest martyngałem.

$$\begin{aligned} E((Z_n - Z_{n-1})|\mathcal{F}_{n-1}) &= E(V_n(X_n - X_{n-1})|\mathcal{F}_{n-1}) \\ &\stackrel{\text{własność 10}}{=} V_n E((X_n - X_{n-1})|\mathcal{F}_{n-1}) \\ &= 0 \end{aligned}$$

**Transformatą martingalową** nazywamy ciąg  $\{Z_n, n \geq 1\}$

### 22.4.1 Interpretacja

- Niech  $X_n, n \geq 1$  oznacza łączną wygraną gracza  $A$  do chwili  $n$ .
- Grę obserwuje gracz  $C$ , który stawia na gracza  $A$  w  $n$ -tej partii  $V_n$  złotych (jego decyzja o wysokości stawki zależy od historii gry do chwili  $n - 1$ , stąd warunek, że  $V_n$  jest **ciągami prognozowalnym**) i wygrywa

$$V_n(X_n - X_{n-1}) \text{ złotych}$$

- $Z_n = V_0 X_0 + V_1(X_1 - X_0) + \dots + V_n(X_n - X_{n-1})$  - wygrana gracza  $C$

Gracz  $C$  uważa, że wygra, choć jego wygrana i wygrana gracza  $A$  tworzą martingał.

2025-01-21

## 22.5 Jak wygrać milion dolarów

### 22.5.1 Strategia

Dla uproszczenia zakładamy, że chcemy wygrać 1 zł.

- Niech  $\{Y_n, n \geq 1\}$  będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie

$$P[Y_n = 1] = p = 1 - P[Y_n = -1]$$

- Jeżeli  $Y_n = 1$ , to uznajemy, że w  $n$ -tej kolejce wygraliśmy.
- Rozważamy grę z następującym sposobem obstawiania:  
najpierw stawiamy 1 zł, a potem
  - podwajamy stawkę, gdy przegrywamy
  - wycofujemy się z gry, gdy po raz pierwszy wygramy

- Stawka w grze

$$W_1 = 1, \quad W_n = \begin{cases} 2^{n-1}, & \text{gdy } Y_i = -1 \quad \forall i \in \{1, \dots, n-1\}, \quad n \geq 2 \\ 0, & \text{w pozostałych przypadkach} \end{cases}$$

- $W_n, n \geq 1$  jest ciągiem prognozowalnym
- $S_n = \sum_{i=1}^n Y_i$  jest martyngałem gdy  $p = \frac{1}{2}$
- zgromadzony kapitał w grze (wygrana) – transformata:

$$X_n = \sum_{k=1}^n W_k Y_k = \sum_{k=1}^n W_k (S_k - S_{k-1}) = X_{n-1} + W_n X_n$$

- $X_n = \sum_{k=1}^n W_k Y_k = \sum_{k=1}^n W_k (S_k - S_{k-1}) = X_{n-1} + W_n X_n$
- $X_n$  - martyngał dla  $p = \frac{1}{2}$
- Gdy  $\bigwedge_{i \in \{1, 2, \dots, n\}} Y_i = -1$ , to gracz przegrał

$$X_n = - \sum_{i=1}^n W^{i-1} = -(1 + 2 + 2^2 + \dots + 2^n) = -(2^n - 1)$$

- Gdy  $Y_{n+1} = 1$ , to

$$X_{n+1} = X_n + W_{n+1} \cdot 1 = -(2^n - 1) + 2^n = 1$$

- W tym momencie kończymy grę (wygraliśmy)

### 22.5.2 Analiza gry – Czy na pewno wygramy?

Niech

$$\tau = \inf\{n \geq 1, X_n = 1\} \quad \text{– moment stopu}$$

Dla  $p = \frac{1}{2}$  mamy

$$P[\tau = n] = \frac{1}{2^n}$$

$$\begin{aligned}
 P[\tau < \infty] &= P\left[\bigcup_{i=1}^{\infty}\{\tau = n\}\right] \\
 &= \sum_{i=1}^{\infty} P[\tau = n] \\
 &= \sum_{i=1}^{\infty} \frac{1}{2^n} \\
 &= 1
 \end{aligned}$$

Z prawdopodobieństwem równym 1 wygramy.

### 22.5.3 Kiedy wygramy?

$$\begin{aligned}
 E_{\tau} &= \sum_{n=1}^{\infty} nP[\tau = n] \\
 &= \sum_{n=1}^{\infty} n \frac{1}{2^n} \\
 &= \frac{1}{2} \sum_{n=1}^{\infty} n \frac{1}{2^{n-1}} \\
 &= \frac{1}{2} \frac{1}{(1 - \frac{1}{2})^2} \\
 &= 2
 \end{aligned}$$

Przeciętnie, powinniśmy wygrać już w drugiej rundzie obstawiania.

Korzystamy ze wzoru

$$1 + 2p + 3p^2 + \dots = \frac{1}{(1-p)^2}$$

### 22.5.4 Ile wygramy?

Wiemy, że

- $\tau$  – moment wygranej
- $X_{\tau} \equiv 1$  – wielkość wygranej w chwili  $\tau$
- Przeciętna wielkości wygranej:

$$EX_{\tau} = 1 \cdot P[X_{\tau} = 1] = 1$$

**22.5.5 Wnioski**

- W grze sprawiedliwej istnieje strategia gry, w której
  - w skończonym czasie
  - z prawdopodobieństwem 1

gracz wygrywa 1 zł

- Choć średni czas oczekiwania  $\tau$  na wygraną jest równy 2, nie jest jednak z góry ograniczony.
- Dlatego pewnym wygranej można być tylko w przypadku, gdy mamy nieograniczony kapitał