

# RACHUNEK PRAWDOPDOBOBIENSTWA I STATYSTYKA

OKNO - Ośrodek Kształcenia na Odległość  
Politechnika Warszawska

Krystyna Lipińska

Dominik Jagiełło

Rafał Maj

2010



# Spis treści

<b>1</b>	<b>Zdarzenia elementarne</b>	<b>9</b>
1.1	Elementy kombinatoryki . . . . .	10
1.2	Definicja prawdopodobieństwa . . . . .	13
1.3	Zadania do samodzielnego rozwiązania . . . . .	15
<b>2</b>	<b>Prawdopodobieństwo warunkowe i wzór Bayesa</b>	<b>17</b>
2.1	Prawdopodobieństwo warunkowe . . . . .	18
2.2	Prawdopodobieństwo całkowite i wzór Bayesa . . . . .	20
2.3	Zadania do samodzielnego rozwiązania . . . . .	22
<b>3</b>	<b>Zmienna losowa jednowymiarowa</b>	<b>23</b>
3.1	Zmienna losowa . . . . .	24
3.2	Rozkład prawdopodobieństwa zmiennej losowej . . . . .	27
3.3	Zadania do samodzielnego rozwiązania . . . . .	35
<b>4</b>	<b>Zmienne losowe dwuwymiarowe</b>	<b>37</b>
4.1	Zmienna losowa dwuwymiarowa . . . . .	38
4.2	Charakterystyki zmiennych losowych dwuwymiarowych . . . . .	43
4.3	Funkcje zmiennych losowych . . . . .	45
4.4	Twierdzenia graniczne . . . . .	49
4.5	Zadania do samodzielnego rozwiązania . . . . .	51
<b>5</b>	<b>Elementy statystyki opisowej</b>	<b>53</b>
5.1	Dane statystyczne . . . . .	54
5.2	Miary położenia, zróżnicowania, asymetrii . . . . .	55
5.3	Zadania do samodzielnego rozwiązania . . . . .	63
<b>6</b>	<b>Elementy statystyki matematycznej</b>	<b>65</b>
6.1	Pewne rozkłady stosowane w statystyce . . . . .	66
6.2	Estymacja . . . . .	67
6.3	Testowanie hipotez statystycznych . . . . .	69
6.4	Zadania do samodzielnego rozwiązania . . . . .	72

<b>7 Wybrane zagadnienia procesów stochastycznych</b>	<b>73</b>
7.1 Podstawowe definicje . . . . .	74

# Słowo wstępne

Celem przedmiotu Rachunek Prawdopodobieństwa i statystyka jest dostarczenie studentom aparatu pojęciowego niezbędnego w toku studiowania przedmiotów kierunkowych.

Materiał wykładów i ćwiczeń zawartych w podręczniku OKNA zawiera podstawowe elementy tych działów rachunku prawdopodobieństwa i statystyki, które mogą być użyteczne w przedmiotach specjalistycznych.

Student powinien opanować umiejętność odnajdywania w podręczniku odpowiednich metod i wzorów ułatwiających rozwiązanie problemów opisanych modelem matematycznym. Przystępując do samodzielnego opanowania materiału należy starać się zrozumieć rolę podanych definicji i wzorów ułatwiających rozwiązywanie zadań i ustalić relacje między nimi. Jest to bardzo przyjemny proces w wyniku którego można samodzielnie rozwiązać umieszczone na końcu rozdziału zadania uzyskując wynik zgodny z podaną odpowiedzią.

Zaliczenie przedmiotu polega na rozwiązaniu dwóch zestawów projektowych oraz zdaniu egzaminu. Egzamin polega na sprawdzeniu czy student opanował materiał objęty przedmiotem.

Studiując samodzielnie można korzystać z literatury uzupełniającej, pamiętając jednak że mogą występować różne metody i oznaczenia rozwiązywania zadań a nawet mogą występować różnice w definicjach.

Pomocą w opanowaniu systematycznym obowiązującego do egzaminu materiału są zajęcia stacjonarne na których wykładowca omawia trudniejsze zadania i wyjaśnia wątpliwości w postaci indywidualnych konsultacji.

Przedmiot jest realizowany w jednym półsemestrze.

Szczegóły dotyczące prowadzenia przedmiotu w danym semestrze będą podawane w witrynie przedmiotu.

Życzymy wytrwałości i satysfakcji z trudnych ale ciekawych studiów.

*Zespół prowadzących przedmiot RPiS*



# Wstęp

Podręcznik zawiera podstawowe elementy rachunku prawdopodobieństwa i statystyki matematycznej.

Rachunek prawdopodobieństwa zajmuje się badaniem i wykrywaniem prawidłowości w zjawiskach, na które działają czynniki losowe oraz budowaniem modeli matematycznych tych zjawisk.

Statystyka matematyczna zajmuje się natomiast metodami wnioskowania o całej zbiorowości danych na podstawie zbadania pewnej jej części zwanej próbką.

Czynniki losowe występują w wielu dziedzinach jak: teorii sterowania, miernictwie, kontroli jakości a także w organizacji i zarządzaniu w ekonomii.

W podręczniku umieszczone są definicje i twierdzenia bez dowodów. Wykorzystanie teorii ilustrowane jest przykładami. W zadaniach wymagających żmudnych obliczeń podawany jest jedynie algorytm ułatwiający uzyskanie wyniku oraz wynik końcowy. Ważny jest bowiem sposób uzyskania rozwiązania i interpretacja otrzymanego rezultatu.

**Uwaga** *Przy czytaniu podręcznika proszę zwrócić uwagę na fakt iż w większości rysunków osie  $Ox, Oy$  zostały w różny sposób skalibrowane, tzn. jedna jednostka na jednej osi może być innej długości od 1 jednostki na drugiej osi.*





# Wykład 1

## Zdarzenia elementarne

W tym wykładzie omówione są pojęcia z kombinatoryki, które są wykorzystywane w najprostszych przykładach prezentujących rozważany materiał. Następnie omówione są podstawowe pojęcia rachunku prawdopodobieństwa.

## 1.1 Elementy kombinatoryki

**Definicja 1.1.** Symbol  $n!$  dla  $n \in \mathbb{N}$  nazywamy *silnią*. Wyraża się on wzorem

$$n! = \begin{cases} 1 & \text{dla } n = 0 \vee n = 1 \\ 1 \cdot 2 \cdot \dots \cdot n & \text{dla } n \geq 2 \end{cases} \quad (1.1)$$

**Definicja 1.2.** *Symbolem Newtona* nazywamy wyrażenie

$$\binom{n}{k} = \frac{n!}{k!(n-k)!}, \quad \text{dla } n, k \in \mathbb{N}, k \leq n. \quad (1.2)$$

*Reguła mnożenia.* Jeżeli pewien wybór zależy od skończenie wielu decyzji, powiedzmy  $k$ , przy czym podejmując pierwszą decyzję mamy  $n_1$  możliwości, drugą  $n_2$  możliwości, ...,  $k$ -tą  $n_k$  możliwości, bo wybór ten może być zrobiony na

$$n = n_1 \cdot n_2 \cdot \dots \cdot n_k \quad (1.3)$$

możliwości.

**Przykład 1.3.** Na ile sposobów można podzielić 3 role męskie i 2 kobiece pomiędzy trzech aktorów i dwie aktorki?

*Rozwiązanie.* Role męskie możemy przydzielić na  $3!$  sposobów, role kobiece na  $2!$  sposobów, więc korzystając z reguły mnożenia wynika, że role te możemy przydzielić na

$$3! \cdot 2! = 6 \cdot 2 = 12$$

sposobów. □

**Przykład 1.4.** Ile nastąpi powitań, gdy jednocześnie spotka się 6 znajomych?

*Rozwiązanie.* Mamy  $n = 6, k = 2$ , czyli  $\binom{6}{2} = 15$  powitań. □

**Definicja 1.5.** *Permutacją bez powtórzeń* zbioru  $n$ -elementowego  $A = \{a_1, a_2, \dots, a_n\}$ , dla  $n \in \mathbb{N}$  nazywamy każdy  $n$ -wyrazowy ciąg utworzony ze wszystkich  $n$ -elementów zbioru  $A$ , czyli każde uporządkowanie elementów zbioru  $A$ .

**Stwierdzenie 1.6.** *Liczba wszystkich różnych permutacji bez powtórzeń zbioru  $n$ -elementowego jest równa*

$$P_n = n! \quad (1.4)$$

Permutacje wykorzystujemy, gdy:

- występują wszystkie elementy zbioru,
- kolejność elementów jest istotna.

**Przykład 1.7.** Na ile sposobów można ułożyć na półce 4 tomową encyklopedię?

*Rozwiązanie.* Rozmieszczamy wszystkie elementy i kolejność elementów ma znaczenie, zatem można to zrobić na  $4!$  sposobów.  $\square$

**Definicja 1.8.** *Permutacją  $n$ -wyrazową z powtórzeniami* zbioru  $k$ -elementowego  $A = \{a_1, a_2, \dots, a_k\}$ , w której element  $a_1$  występuje  $n_1$  razy, element  $a_2$  występuje  $n_2$  razy,  $\dots$ , element  $a_k$  występuje  $n_k$  razy, przy czym  $n_1 + n_2 + \dots + n_k = n$ , nazywamy każdy  $n$ -wyrazowy ciąg, w którym element  $a_i$  występuje  $n_i$  razy,  $i = 1, 2, \dots, k$ ,

**Stwierdzenie 1.9.** *Liczba wszystkich różnych  $n$ -wyrazowych permutacji z powtórzeniami ze zbioru  $k$ -elementowego jest równa*

$$P_n(n_1, n_2, \dots, n_k) = \frac{n!}{n_1! \cdot n_2! \cdot \dots \cdot n_k!},$$

gdzie  $n_i \in \mathbb{N}$ ,  $i = 1, 2, \dots, k$ ,  $n_i$  – liczba powtórzeń elementu  $a_i \in A$ ,  $n_1 + n_2 + \dots + n_k = n$ .

**Przykład 1.10.** Ile różnych liczb 6-cyfrowych można utworzyć z cyfr: 1, 1, 3, 3, 3, 5?

*Rozwiązanie.* Są to permutacje z powtórzeniami. Zatem korzystając ze wzoru otrzymujemy, że możemy utworzyć

$$P_6(2, 3, 1) = \frac{6!}{2! \cdot 3! \cdot 1!}$$

liczb.  $\square$

**Definicja 1.11.** *Waracją  $k$ -wyrazową z powtórzeniami* zbioru  $A$ ,  $n$ -elementowego, gdzie  $k \in \mathbb{N}$ , nazywamy każdy  $k$ -wyrazowy ciąg, którego wyrazami są elementy danego zbioru  $A$ .

**Stwierdzenie 1.12.** *Liczba wszystkich różnych  $k$ -wyrazowych wariacji z powtórzeniami zbioru  $n$ -elementowego jest równa*

$$W_n^k = n^k. \quad (1.5)$$

Waracje z powtórzeniami wykorzystujemy, gdy:

- kolejność elementów jest istotna,
- elementy mogą się powtarzać (losowanie ze zwracaniem),
- niekoniecznie wszystkie elementy zbioru są wykorzystane.

**Przykład 1.13.** Na ile sposobów można umieścić 11 piłeczek w czterech szufladach?

*Rozwiązanie.* Można to zrobić na  $W_4^{11} = 4^{11}$  sposobów.

**Definicja 1.14.** *Wariacją  $k$ -wyrazową bez powtórzeń* zbioru  $A$ ,  $n$ -elementowego, gdzie  $k \in \mathbb{N}$ , nazywamy każdy  $k$ -wyrazowy ciąg różnowartościowy, którego wyrazami są elementy danego zbioru  $A$ .

**Stwierdzenie 1.15.** Liczba wszystkich różnych  $k$ -wyrazowych wariacji bez powtórzeń zbioru  $n$ -elementowego jest równa

$$V_n^k = \frac{n!}{(n-k)!} = n(n-1)(n-2) \cdots (n-k+1). \quad (1.6)$$

Wariacje bez powtórzeń wykorzystujemy, gdy:

- kolejność elementów jest istotna,
- elementy nie mogą się powtarzać (losowanie bez zwracania),
- niekoniecznie wszystkie elementy zbioru są wykorzystane.

**Przykład 1.16.** Ile jest liczb czterocyfrowych utworzonych tylko z cyfr nieparzystych?

*Rozwiązanie.* Cyfr nieparzystych jest 5. Możemy je rozmieszczać na 4 pozycjach. Mamy zatem, że tych liczb jest  $V_5^4 = \frac{5!}{(5-4)!} = 120$ .  $\square$

**Definicja 1.17.** Kombinacją  $k$ -elementową bez powtórzeń zbioru  $A$ ,  $n$ -elementowego, gdzie  $k, n \in \mathbb{N}$ , nazywamy każdy podzbiór  $k$ -elementowy zbioru  $A$ , przy czym elementy nie mogą się powtarzać.

**Stwierdzenie 1.18.** Liczba wszystkich różnych kombinacji  $k$ -elementowych bez powtórzeń jest równa

$$C_n^k = \binom{n}{k}. \quad (1.7)$$

Kombinacje stosujemy wtedy, gdy kolejność elementów nie ma znaczenia.

**Przykład 1.19.** Na ile sposobów można wypełnić kupon DUŻEGO LOTKA?

*Rozwiązanie.* Są to kombinacje 6 elementowe ze zbioru 49 elementowego, czyli kupon można wypełnić na  $C_{49}^6 = \binom{49}{6}$  sposobów.  $\square$

## 1.2 Definicja prawdopodobieństwa

Niech  $\Omega$  będzie dowolnym zbiorem, którego elementy oznaczamy przez  $\omega$ . Zbiór ten będziemy nazywali *przestrzenią zdarzeń elementarnych*, a jego elementy zdarzeniami elementarnymi. Przestrzeń zdarzeń elementarnych jest pojęciem pierwotnym (nie definiowanym) w rachunku prawdopodobieństwa. W konkretnych przykładach będziemy  $\Omega$  utożsamiać ze zbiorem wszystkich możliwych wyników doświadczenia losowego. Ponieważ zdarzenia losowe będziemy rozumieli jako podzbiory zbioru wszystkich możliwych zdarzeń losowych w danym doświadczeniu, więc wygodnie jest wprowadzić następującą definicję.

**Definicja 1.20.** Rodzinę podzbiorów  $\mathcal{A}$  zbioru  $\Omega$  nazywamy algebrą zbiorów, jeżeli:

- (i)  $A, B \in \mathcal{A} \Rightarrow A \cup B \in \mathcal{A}$ ,
- (ii)  $A, B \in \mathcal{A} \Rightarrow A \cap B \in \mathcal{A}$ ,
- (iii)  $A \in \mathcal{A} \Rightarrow A' = (\Omega \setminus A) \in \mathcal{A}$ ,
- (iv)  $\Omega \in \mathcal{A}, \emptyset \in \mathcal{A}$ .

Jako *zdarzenia losowe* będziemy rozumieć podzbiory z pewnej algebry podzbiorów zbioru  $\Omega$ .

**Definicja 1.21.** Rzeczywistą funkcję  $P(A)$  określoną na algebrze  $\mathcal{A}$  podzbiorów zbioru  $\Omega$  nazywamy *prawdopodobieństwem*, jeżeli spełnia warunki

- (i)  $A \in \mathcal{A} \Rightarrow P(A) \geq 0$ ,
- (ii)  $A, B \in \mathcal{A}, A \cap B = \emptyset \Rightarrow P(A \cup B) = P(A) + P(B)$ ,
- (iii)  $P(\Omega) = 1, P(\emptyset) = 0$ .

Podstawowe własności prawdopodobieństwa są zamieszczone poniżej.

1. Jeżeli  $A \cap B = \emptyset, A, B \in \mathcal{A}$ , to  $P(A \cup B) = P(A) + P(B)$ .
2. Jeżeli  $A \subset B, A, B \in \mathcal{A}$ , to  $P(B \setminus A) = P(B) - P(A)$ .
3. Jeżeli  $A \subset B, A, B \in \mathcal{A}$ , to  $P(A) \leq P(B)$ .
4. Dla każdego  $A \in \mathcal{A}, 0 \leq P(A) \leq 1$ .
5. Jeżeli  $A, B \in \mathcal{A}$ , to  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$ .

Trójkę  $(\Omega, \mathcal{A}, P)$  nazywamy *przestrzenią probabilistyczną*.

Często użyteczna jest też klasyczna definicja prawdopodobieństwa.

**Definicja 1.22.** Jeżeli zbiór zdarzeń elementarnych  $\Omega$  jest skończony i każde zdarzenie elementarne ma tą samą szansę zaistnienia to prawdopodobieństwo zdarzenia  $A$  wyraża się wzorem

$$P(A) = \frac{|A|}{|\Omega|}, \quad (1.8)$$

gdzie  $|A|, |\Omega|$  oznacza licznosc zbioru.

Tak określone prawdopodobieństwo spełnia wszystkie aksjomaty z definicji 1.21.

**Przykład 1.23.** Partia odbiorników telewizyjnych składa się z 10 sztuk, z których 3 są wadliwe. Jakie jest prawdopodobieństwo zdarzenia polegającego na tym, że dwa wybrane losowo odbiorniki są wadliwe?

*Rozwiązanie.* Przez  $A$  oznaczymy zbiór odbiorników wadliwych. Zatem zdarzeń sprzyjających jest  $|A| = \binom{3}{2} = 3$  – wybieramy dwie sztuki wadliwe spośród trzech. Natomiast wszystkich zdarzeń  $|\Omega| = \binom{10}{2} = 45$  – wybieramy dwie sztuki spośród 10. Stąd

$$P(A) = \frac{3}{45} = \frac{1}{15} \approx 0,06.$$

□

**Przykład 1.24.** Egzaminator przygotował 30 pytań, wypisując na każdej kartce 4 pytania. Zdający umie odpowiedzieć poprawnie na połowę pytań. Jakie jest prawdopodobieństwo że zdający odpowie poprawnie na 4 pytania?

*Rozwiązanie.* Oznaczmy przez  $A$  zdarzenie polegające na wylosowaniu zestawu z pytaniami, na które zdający zna odpowiedź. Mamy  $|A| = \binom{15}{4}$  – losujemy 4 pytania z 15 „dobrych”, oraz  $|\Omega| = \binom{30}{4}$  – losujemy 4 pytania spośród wszystkich. Zatem

$$P(A) = \frac{\binom{15}{4}}{\binom{30}{4}} = \frac{13}{261} \approx 0,05,$$

czyli 5%.

□

**Przykład 1.25.** Spośród 100 studentów, 25 wybrało język angielski, 40 niemiecki, 20 rosyjski a 20 angielski i niemiecki. Jakie jest prawdopodobieństwo, że losowo wybrany student uczy się języka angielskiego lub niemieckiego?

*Rozwiązanie.* Oznaczmy przez  $A$  student uczy się języka angielskiego, przez  $B$  - niemieckiego. Mamy  $P(A) = \frac{25}{100}$ ,  $P(B) = \frac{40}{100}$ ,  $P(A \cap B) = \frac{20}{100}$ . Stąd

$$P(A \cup B) = P(A) + P(B) - P(A \cap B) = 0,25 + 0,4 - 0,2 = 0,45.$$

□

**Przykład 1.26.** W 30 osobowej grupie studentów jest 8 kobiet. Grupa otrzymała 6 biletów bezpłatnych do teatru, które losowano w grupie. Jakie jest prawdopodobieństwo, że wśród posiadaczy bezpłatnych biletów są dokładnie 3 kobiety?

*Rozwiązanie.*

$$P(A) = \frac{\binom{8}{3} \binom{22}{3}}{\binom{30}{6}} = 0,02.$$

□

### 1.3 Zadania do samodzielnego rozwiązania

**1.1.** Komisja złożona z 3 kobiet i 5 mężczyzn wybiera spośród siebie przewodniczącego. Jakie jest prawdopodobieństwo, że zostanie nim kobieta, przy założeniu, że wszyscy członkowie komisji mają takie same szanse? Odp.

$\frac{3}{8}$ .

**1.2.** Spośród pięciu piłek o różnej wielkości wybieramy dwie. Jakie jest prawdopodobieństwo, że wśród wylosowanych będzie najmniejsza, przy założeniu, że wszystkie piłki mają równe szanse być wybrane? Odp.  $\frac{2}{5}$ .

**1.3.** Znaleźć prawdopodobieństwo, że przy 5-krotnym rzucie kostką otrzymamy 5 różnych wyników? Odp.  $\frac{6!}{6^5}$ .

**1.4.** Jakie jest prawdopodobieństwo, że przy jednoczesnym rzucie trzema kostkami do gry wypadnie

a) 11,

b) 12.

Odp. a)  $\frac{27}{216}$ , b)  $\frac{25}{216}$ .

**1.5.** W urnie mamy 14 kul czarnych, 16 kul białych i dwie kule niebieskie. Obliczyć prawdopodobieństwo, że przy losowaniu jednej kuli

a) wylosowana kula będzie niebieska,

b) wylosowana kula będzie niebieska lub czarna.

Odp. a)  $\frac{1}{16}$ , b)  $\frac{1}{2}$ .

**1.6.** W skrzyni znajduje się 6 dobrych i 4 wadliwe elementy. Obliczyć prawdopodobieństw, że wśród 4 wybranych losowo elementów, nie będzie ani jednego wadliwego.

Odp.  $\frac{1}{14}$ .

**1.7.** Autobus zatrzymuje się na 10 przystankach. Jakie jest prawdopodobieństwo, że spośród 6 osób znajdujących się w autobusie, każda wysiadzie na innym przystanku?

Odp. 0, 1512.

**1.8.** W pudełku znajduje się 25 długopisów, z czego 5 jest zepsutych. Wybieramy losowo 3 długopisy. Obliczyć prawdopodobieństwo, że co najmniej dwa są dobre.

Odp.  $\frac{209}{230}$ .

**1.9.** Student umie odpowiedzieć na 20 spośród 25 pytań egzaminacyjnych. Na egzaminie losuje 3 pytania. Jakie jest prawdopodobieństwo, że uczeń odpowie na 2 pytania? Odp.

$\frac{209}{230}$ .

**1.10.** W sześciu szufladach umieszczamy sześć krawatów. Zakładając, że każde rozmieszczenie krawatów jest jednakowo prawdopodobne obliczyć prawdopodobieństwo zdarzenia, że co najmniej dwie szuflady będą puste. Odp.  $\frac{61}{81}$ .





## Wykład 2

# Prawdopodobieństwo warunkowe i wzór Bayesa

W tym wykładzie omówione są jedne z najważniejszych pojęć rachunku prawdopodobieństwa, mianowicie prawdopodobieństwo warunkowe oraz wzór Bayesa.

## 2.1 Prawdopodobieństwo warunkowe

Rozważmy dwa zdarzenia w tym samym skończonym zbiorze zdarzeń elementarnych.

**Definicja 2.1.** Prawdopodobieństwo warunkowe zdarzenia  $A$  pod warunkiem, że zaszło zdarzenie  $B$  wyliczamy ze wzoru

$$P(A|B) = \frac{P(A \cap B)}{P(B)}, \quad \text{jeżeli } P(B) > 0. \quad (2.1)$$

Analogicznie obliczamy prawdopodobieństwo warunkowe zdarzenie  $B$  pod warunkiem, że zaszło zdarzenie  $A$

$$P(B|A) = \frac{P(A \cap B)}{P(A)}, \quad \text{jeżeli } P(A) > 0. \quad (2.2)$$

Przekształcając powyższy wzór otrzymujemy wzór na *prawdopodobieństwo ilorazowe*

$$P(A \cap B) = P(A)P(B|A). \quad (2.3)$$

**Definicja 2.2.** Zdarzenia  $A$  i  $B$  nazywamy niezależnymi, jeżeli

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

**Twierdzenie 2.3.** Jeżeli niezależne są zdarzenia  $A$  oraz  $B$ , z tej samej rodziny zdarzeń, to niezależne są także zdarzenia

- a)  $A$  i  $B'$ ;
- b)  $A'$  i  $B$ ;
- c)  $A'$  i  $B'$ .

**Przykład 2.4.** Do windy na parterze sześciopiętrowego bloku wsiadło 4 pasażerów. Jakie jest prawdopodobieństwo, że każda z osób wysiadła na innym piętrze?

*Rozwiązanie.* Prawdopodobieństwo zdarzenia  $A_i, i = 1, 2, 3, 4$  wynoszą  $P(A_1) = \frac{6}{6}, P(A_2) = \frac{5}{6}, P(A_3) = \frac{4}{6}, P(A_4) = \frac{3}{6}$ . Zdarzenia te są niezależne, więc

$$P(A_1 \cap A_2 \cap A_3 \cap A_4) = P(A_1) \cdot P(A_2) \cdot P(A_3) \cdot P(A_4) \approx 0,28,$$

czyli 28%. □

**Przykład 2.5.** W pewnym przedsiębiorstwie 96% wyrobów jest dobrych. Na 100 dobrych wyrobów średnio 75 jest pierwszego gatunku. Znaleźć prawdopodobieństwo tego, że dobra sztuka wyprodukowana w tym przedsiębiorstwie jest pierwszego gatunku.

*Rozwiązanie.* Oznaczmy przez  $A$  zdarzenie polegające na tym, że sztuka jest dobra, a przez  $B$  - że sztuka jest pierwszego gatunku. Mamy

$$P(A \cap B) = P(A) \cdot P(B|A) = 0,96 \cdot 0,75 = 0,72.$$

□

**Przykład 2.6.** Obliczyć prawdopodobieństwo, że losowo wybrany los loteryjny wygrywa największą stawkę, jeżeli wiadomo, że 25% losów przegrywa a 20% to losy wygrywające największą stawkę.

*Rozwiązanie.* Oznaczmy przez  $A$  zdarzenie, że los jest wygrywający (cokolwiek). Stąd  $P(A) = 1 - P(A') = 1 - \frac{25}{100} = \frac{3}{4}$ , natomiast przez  $B$  zdarzenie, że los wygrywa najwyższą stawkę. Stąd  $P(B|A) = \frac{20}{100}$ . Zatem

$$P(A \cap B) = P(A) \cdot P(B|A) = \frac{3}{4} \cdot \frac{1}{5} = 0,15.$$

□

**Przykład 2.7.** W pudełku zawierającym 15 rezystorów 3 są wybrakowane. Rezystory z pudełka wyjmujemy w sposób losowy. Obliczyć prawdopodobieństwo

- a) wyjęcia kolejno dwóch rezystorów dobrych,
- b) wyjęcia dwóch rezystorów, z których jeden jest dobry a drugi wybrakowany.

*Rozwiązanie.* Oznaczmy przez  $A_1$  zdarzenie, że pierwszy z wyjętych rezystorów jest dobry, zaś przez  $A_2$ , że drugi z wyjętych rezystorów jest dobry.

W przypadku a)  $P(A_1 \cap A_2) = P(A_1) \cdot P(A_2|A_1) = \frac{12}{15} \cdot \frac{11}{14} = \frac{22}{35} \approx 0,63$ .

Oznaczmy przez  $B_1$  zdarzenie, że pierwszy z wyjętych rezystorów jest wybrakowany, zaś przez  $B_2$ , że drugi z wyjętych rezystorów jest wybrakowany.

W przypadku b)  $P(A_1 \cap A_2) = P(A_1) \cdot P(B_2|A_1) = \frac{12}{15} \cdot \frac{3}{14} = \frac{6}{35} \approx 0,17$ . □

**Przykład 2.8.** Policja uzyskała informację, że terroryści podłożyli bomby w dwóch spośród 8 odlatujących samolotów. Jakie jest prawdopodobieństwo, że zostaną one znalezione już po przeszukaniu dwóch pierwszych samolotów.

*Rozwiązanie.* Oznaczmy przez  $A_1$  zdarzenie, że w pierwszym samolocie jest bomba, zaś przez  $A_2$  zdarzenie, że w drugim samolocie jest bomba. Stąd

$$P(A_1 \cap A_2) = P(A_1) \cdot P(A_2|A_1) = \frac{2}{8} \cdot \frac{1}{7} = \frac{1}{28} \approx 0,04.$$

□

## 2.2 Prawdopodobieństwo całkowite i wzór Bayesa

**Definicja 2.9.** Układ zdarzeń  $A_1, A_2, \dots, A_n$  nazywamy *zupełnym*, jeżeli zdarzenia te są parami niezależne (wykluczają się), tzn.  $A_i \cap A_j = \emptyset$  dla  $i \neq j$  oraz

$$A_1 \cup A_2 \cup \dots \cup A_n = \Omega. \quad (2.4)$$

**Twierdzenie 2.10.** Jeżeli zdarzenia  $A_1, A_2, \dots, A_n$  tworzą układ zupełny oraz  $P(A_i) > 0$ , dla  $i = 1, 2, \dots, n$ , to dla dowolnego zdarzenia  $B$

$$P(B) = \sum_{i=1}^n P(A_i) \cdot P(B|A_i). \quad (2.5)$$

**Przykład 2.11.** W jednej urnie mamy 3 kule białe i 4 czarne, a w drugiej 5 kul białych i 4 czarne. Rzucamy kostką do gry. Gdy wypadnie liczba podzielna przez 3, to losujemy z pierwszej urny, w przeciwnym przypadku z drugiej. Jakie jest prawdopodobieństwo wylosowania kuli białej?

*Rozwiązanie.* Oznaczmy przez  $B_1$  zdarzenie, że wypadła liczba podzielna przez 3, przez  $B_2$  zdarzenie, że wypadła liczba niepodzielna przez 3, przez  $A$  zdarzenie, że wylosowaliśmy kulę białą. Mamy

$$P(A) = P(A|B_1) \cdot P(B_1) + P(A|B_2) \cdot P(B_2) = \frac{1}{3} \cdot \frac{3}{7} + \frac{2}{3} \cdot \frac{5}{9} = \frac{97}{189} \approx 0,51.$$

□

**Przykład 2.12.** Trzy fabryki wytwarzają pewien towar, dla którego określona jest norma. Przy czym

**Fabryka 1** dostarcza na rynek 30% towaru w którym normę spełnia 80% towaru,

**Fabryka 2** dostarcza na rynek 40% towaru w którym normę spełnia 70% towaru,

**Fabryka 3** dostarcza na rynek 30% towaru w którym normę spełnia 60% towaru.

Obliczyć prawdopodobieństwo, że towar dostarczony na rynek spełnia normę.

*Rozwiązanie.* Oznaczmy przez  $B$  zdarzenie, że towar dostarczony na rynek spełnia normę. Mamy  $P(A_1) = 0,3$ ;  $P(B|A_1) = 0,8$ ;  $P(A_2) = 0,4$ ;  $P(B|A_2) = 0,7$ ;  $P(A_3) = 0,3$ ;  $P(B|A_3) = 0,6$ . Stąd prawdopodobieństwo spełnienia normy przez towar na rynku wynosi

$$P(B) = 0,3 \cdot 0,8 + 0,4 \cdot 0,7 + 0,3 \cdot 0,6 = 0,7.$$

□

**Twierdzenie 2.13.** Jeżeli  $P(B) > 0$  i spełnione są założenia Twierdzenia 2.10, to zachodzi wzór zwany wzorem Bayesa

$$P(A_j|B) = \frac{P(A_j) \cdot P(B|A_j)}{P(B)}.$$

**Przykład 2.14.** Korzystając z danych z Przykładu 2.12 obliczyć prawdopodobieństwo spełnienia normy przez towar wyprodukowany w fabryce 3.

*Rozwiązanie.* Mamy

$$P(A_3|B) = \frac{0,3 \cdot 0,6}{0,7} = 0,25.$$

□

### 2.3 Zadania do samodzielnego rozwiązania

**2.1.** Rzucamy dwukrotnie kostką do gry. Obliczyć prawdopodobieństwo, że suma oczek będzie większa od 9, jeżeli za pierwszym razem wypadło 6 oczek? Odp.  $\frac{1}{3}$ .

**2.2.** W skrzyni znajduje się 12 elementów, z czego 6 jest dobrych a 6 wadliwych. W sposób losowy, bez zwracania wybieramy dwa elementy. Oblicz prawdopodobieństwo wylosowania za drugim elementu wadliwego, pod warunkiem, że za pierwszym razem wybrano element dobry. Odp.  $\frac{6}{11}$ .

**2.3.** Na dworcu kolejowym znajdują się dwoje schodów ruchomych. Pierwsze są sprawne z prawdopodobieństwem  $\frac{1}{2}$ , natomiast drugie  $\frac{1}{3}$ . Prawdopodobieństwo, że działają pierwsze schody, gdy zepsute są drugie wynosi  $\frac{1}{2}$ .

- a) Jakie jest prawdopodobieństwo, że działają drugie schody, pod warunkiem, że nie działają pierwsze?
- b) Jakie jest prawdopodobieństwo, że działają przynajmniej jedne schody?

Odp. a)  $\frac{1}{3}$ , b)  $\frac{2}{3}$ .

**2.4.** Rzucamy dwiema symetrycznymi kostkami do gry. Oblicz prawdopodobieństwo otrzymania sumy oczek równej 3, jeżeli na pierwszej kostce wypadła 1. Odp.  $\frac{1}{6}$ .

**2.5.** Rozważmy rodziny z dwojgiem dzieci. Niech  $d$  oznacza dziewczynkę,  $c$  - chłopca. Zdarzeniami elementarnymi będą pary:  $(d,d)$ ,  $(d,c)$ ,  $(c,d)$ ,  $(c,c)$ , gdzie pierwsza litera w parze oznacza płeć starszego dziecka, druga zaś młodszego. Zakładając, że wszystkie zdarzenia są jednakowo prawdopodobne obliczyć prawdopodobieństwo, że w losowo wybranej rodzinie z dwojgiem dzieci, jest dwóch chłopców, pod warunkiem, że w tej rodzinie jest co najmniej jeden chłopiec. Odp.  $\frac{1}{3}$ .

**2.6.** Student dojeżdża na uczelnię rowerem średnio co drugi dzień, autobusem co trzeci dzień, a tramwajem co szósty. Jadąc rowerem, spóźnia się z prawdopodobieństwem raz na sześćdziesiąt razy jadąc autobusem - raz na dwadzieścia razy, a tramwajem raz na dziesięć razy. Oblicz prawdopodobieństwo, że student spóźni się na uczelnię. Odp.  $\frac{1}{24}$ .

**2.7.** Potrzeby świerkowych sadzonek dla nadleśnictwa pokrywa produkcja dwóch szkółek leśnych. Pierwsza szkółka pokrywa 75% zapotrzebowania, przy czym na 100 sadzonek z tej szkółki 80 jest pierwszej jakości. Druga szkółka pokrywa 25% zapotrzebowania, przy czym na 100 sadzonek z tej szkółki 60 jest pierwszej jakości. Obliczyć prawdopodobieństwo, że losowo wybrana sadzonka jest pierwszej jakości. Odp. 0,75.

## Wykład 3

# Zmienna losowa jednowymiarowa

W tym wykładzie omówione jest pojęcie zmiennej losowej, typy zmiennych losowych, parametry zmiennych losowych oraz przykłady rozkładów prawdopodobieństwa.

### 3.1 Zmienna losowa

**Definicja 3.1.** Zmienną losową nazywamy funkcję  $X$  przyporządkowującą zdarzeniu elementarnemu dokładnie jedną liczbę rzeczywistą, tj.  $X : \Omega \rightarrow \mathbb{R}$ , spełniającą warunek:

dla dowolnego  $a \in \mathbb{R}$  zbiór  $\{\omega \in \Omega : X(\omega) < a\}$  należy do zbioru zdarzeń losowych.

**Notacja.** Symbolu  $A := B$  będziemy używali do oznaczenia, że pewne oznaczenie jest równe z definicji. Należy go rozumieć następująco: Symbol (wyrażenie)  $A$  jest równy z definicji obiektowi  $B$ .

Zatem poniższe oznaczenia należy rozumieć następująco: zbiór stojący z prawej strony symbolu  $:=$  dla skrócenia zapisu będzie oznaczany przez symbol stojący z lewej strony tego znaku.

Będziemy korzystali z następującego zapisu

$$\begin{aligned} (X < a) &:= \{\omega \in \Omega : X(\omega) < a\}, \\ (X \leq a) &:= \{\omega \in \Omega : X(\omega) \leq a\}, \\ (X > a) &:= \{\omega \in \Omega : X(\omega) > a\}, \\ (X \geq a) &:= \{\omega \in \Omega : X(\omega) \geq a\}. \end{aligned}$$

Zmienne losowe pozwalają przedstawić wyniki doświadczeń losowych za pomocą liczb. Prawdopodobieństwo przyjęcia przez zmienną losową danych wartości można wyznaczyć za pomocą dystrybuanty.

**Definicja 3.2.** *Dystrybuantą* zmiennej losowej nazywamy funkcję  $F$  określoną następująco

$$F(x) = P(X \leq x). \quad (3.1)$$

Dystrybuanta zmiennej losowej ma następujące własności

1. Jest funkcją niemalejącą, prawostronnie ciągłą.
2.  $\lim_{x \rightarrow -\infty} F(x) = 0$  oraz  $\lim_{x \rightarrow \infty} F(x) = 1$ .
3.  $0 \leq F(x) \leq 1$  dla każdego  $x$ .
4. Dla każdego przedziału  $\langle a, b \rangle$  mamy  $P(a \leq x \leq b) = F(b) - F(a-)$ , gdzie  $F(a-) = \lim_{x \rightarrow a^-} F(x)$  oznacza granicę lewostronną funkcji  $F$  w punkcie  $a$ .
5.  $P(xb) = 1 - F(b)$ .

Dalej zostaną podane typy zmiennych losowych: zmienną losową skokową (dyskretną) i zmienną losową ciągłą.

#### Zmienna losowa skokowa (dyskretna)

Zmienna losowa skokowa  $X$ , jest to zmienna losowa, której zbiór wartości jest zbiorem skończonym lub przeliczalnym (tnz. jest równoliczny ze zbiorem liczb naturalnych  $\mathbb{N}$ ), czyli



przyjmuje wartości pewnego ciągu  $x$  skończonego lub nieskończonego z prawdopodobieństwem  $p$ , czyli jest określona funkcja prawdopodobieństwa

$$p_k = P(X = x_k), \quad p_k > 0, \quad \sum_k p_k = 1. \quad (3.2)$$

Zależność tę można przedstawić za pomocą tabeli

$x_k$	$x_1$	$x_2$	$\cdots$	$x_n$
$p_k$	$p_1$	$p_2$	$\cdots$	$p_n$

**Przykład 3.3.** Zmienna losowa  $X$  dyskretna ma funkcję prawdopodobieństwa określoną tabelą

$x_i$	-1	0	2
$p_i$	$\frac{1}{2}$	$\frac{1}{6}$	$\frac{1}{3}$

Wyznaczyć dystrybuantę zmiennej losowej  $X$ .

*Rozwiązanie.* Dystrybuanta zmiennej losowej  $X$  jest funkcją  $F(x) = P(X \leq x)$ . Wtedy

$$\begin{aligned} F(-2) &= P(X \leq -2) = 0 \\ F(-1) &= P(X \leq -1) = \frac{1}{2} \\ F(-0,5) &= P(X \leq -0,5) = \frac{1}{2} \\ F(0) &= P(X \leq 0) = P(-1) + P(0) = \frac{1}{2} + \frac{1}{6} = \frac{2}{3} \\ F(1) &= P(X \leq 1) = P(-1) + P(0) = \frac{1}{2} + \frac{1}{6} = \frac{2}{3} \\ F(3) &= P(X \leq 3) = P(-1) + P(0) + P(2) = \frac{1}{2} + \frac{1}{6} + \frac{1}{3} = 1 \end{aligned}$$

Zatem

$$F(x) = \begin{cases} 0 & \text{dla } x < -1 \\ \frac{1}{2} & \text{dla } -1 \leq x < 0 \\ \frac{2}{3} & \text{dla } 0 \leq x < 2 \\ 1 & \text{dla } x > 2 \end{cases}$$


□

### Zmienna losowa ciągła

Zmienna losowa  $X$  ciągła, jest to zmienna losowa zdefiniowana za pomocą funkcji  $f(x)$  zwanej *gęstością prawdopodobieństwa zmiennej  $X$*  w postaci

$$P(a < X < b) = \int_a^b f(x) dx. \quad (3.3)$$

Gęstość prawdopodobieństwa spełnia warunki



Rysunek 3.1: Dystrybuanta zmiennej losowej z Przykładu 3.3

1.  $f(x) > 0$ , czyli jest funkcją nieujemną,
2.  $\int_{-\infty}^{\infty} f(x)dx = 1$ .

Dystrybuanta zmiennej losowej ciągłej może być przedstawiona w postaci

$$F(x) = \int_{-\infty}^x f(t)dt, \quad (3.4)$$

więc jest funkcją górnej granicy całkowania.

	zmienna losowa skokowa	zmienna losowa ciągła
wartość oczekiwana	$E(X) = \sum_{k=1}^n x_k \cdot p_k$	$E(X) = \int_{-\infty}^{\infty} x f(x) dx$
wariancja	$\sigma^2(X) = \sum_{k=1}^n (x_k - E(X))^2 \cdot p_k$	$\sigma^2(X) = \int_{-\infty}^{\infty} (x - E(x))^2 f(x) dx$
odchylenie standardowe	$\sigma = \sqrt{\sigma^2(X)}$	$\sigma = \sqrt{\sigma^2(X)}$

Tablica 3.1: Parametry zmiennych losowych.

### 3.2 Rozkład prawdopodobieństwa zmiennej losowej

Mówimy, że znamy rozkład prawdopodobieństwa zmiennej losowej, jeżeli jest znana

- dystrybuanta zmiennej losowej,
- funkcja prawdopodobieństwa, gdy zmienna jest skokowa, lub
- funkcja gęstości, jeżeli zmienna losowa jest ciągła.

#### Parametry rozkładów

Zmienne losowe i ich rozkłady jednowymiarowe nie zawsze są wystarczające lub wygodne do opisanie bardziej złożonych problemów. Przy analizie danych uzyskanych w wyniku przeprowadzonych obserwacji istotną rolę odgrywają parametry rozkładów zmiennych losowych takie jak wartość oczekiwana  $E(X)$ , wariancja  $\sigma^2(X)$ , odchylenie standardowe  $\sigma(X)$ . Wariancja jest miarą rozproszenia zmiennej losowej dookoła jej wartości oczekiwanej, także miarą rozproszenia jest odchylenie standardowe  $\sigma$ .

Definicje parametrów umieścimy w zestawieniu

Obliczanie wariancji upraszcza wzór

$$\sigma^2(X) = E(X^2) - [E(X)]^2. \quad (3.5)$$

Teraz podamy podstawowe własności parametrów.

1.  $E(aX) = aE(X)$ , gdzie  $a$  jest stałą.
2. Jeżeli istnieją wartości oczekiwane zmiennych losowych  $X$  i  $Y$ , to

$$E(X + Y) = E(X) + E(Y).$$

3.  $E(XY) = E(X)E(Y)$ , jeżeli zmienne losowe  $X$  i  $Y$  są niezależne.
4.  $E(a) = a$ , gdzie  $a$  jest stałą.
5.  $\sigma^2(aX) = a\sigma^2(X)$ .
6.  $\sigma^2(X + Y) = \sigma^2(X) + \sigma^2(Y)$ .

7.  $\sigma^2(a) = 0$ , gdzie  $a$  jest stałą.

**Przykład 3.4.** Zmienna losowa ma rozkład określony tabelą

$x_k$	0	1	2	3
$p_k$	0,25	0,2	0,15	0,4

Wyznaczyć: dystrybuantę rozkładu,  $P(X < 3)$ ,  $E(X)$ ,  $D^2(X)$ ,  $\sigma$ .


*Rozwiązanie.* Mamy  $P(X \leq 3) = P(X = 0) + P(X = 1) + P(X = 2) + P(X = 3) = 0,25 + 0,2 + 0,15 + 0,4 = 1,0$ .  $E(X) = 0 \cdot 0,25 + 1 \cdot 0,2 + 2 \cdot 0,15 + 3 \cdot 0,4 = 1,70$ ,  $[E(X)]^2 = 2,89$ ,

$E(X^2) = 0^2 \cdot 0,25 + 1^2 \cdot 0,2 + 2^2 \cdot 0,15 + 3^2 \cdot 0,4 = 4,4$ .

$\sigma^2(X) = E(X^2) - [E(X)]^2 = 4,4 - 2,89 = 1,51$ .  $\sigma = \sqrt{1,51} \approx 1,23$ .

$$F(x) = \begin{cases} 0 & x \in (-\infty, 0) \\ 0,25 & x \in \langle 0, 1) \\ 0,45 & x \in \langle 1, 2) \\ 0,60 & x \in \langle 2, 3) \\ 1 & x \in \langle 3, \infty) \end{cases}$$

Wykres dystrybuanty natomiast histogram □




Rysunek 3.2: Dystrybuanta zmiennej losowej z Przykładu 3.4

## Rozkłady zmiennej skokowej

### Rozkład zero-jedynkowy

Zmienna losowa  $X$  ma rozkład zerojedynkowy z parametrem  $p$ , jeżeli jej funkcja prawdopodobieństwa wyraża się równościami

$$P(X = 1) = p, P(X = 0) = 1 - p = q. \quad (3.6)$$



Rysunek 3.3: Histogram zmiennej losowej z Przykładu 3.4

Wartość oczekiwana tej zmiennej  $E(X) = p$ , wariancja  $\sigma^2(X) = pq$ .

### Rozkład dwumianowy (Bernoulliego)

Jeżeli pewne doświadczenie losowe składa się z serii  $n$  prób, przy czym kolejne próby są niezależne oraz w każdej próbie możliwe są dwa wyniki: **sukces** z prawdopodobieństwem  $p$ , oraz **porażka** z prawdopodobieństwem  $q = 1 - p$ , to takie doświadczenie nazywamy *schematem Bernoulliego* z parametrami  $n$  i  $p$ . Prawdopodobieństwo tego, że w serii  $n$ -prób uzyskamy  $k$  sukcesów i  $n - k$  porażek wyraża się wzorem

$$P(X_n = k) = \binom{n}{k} p^k (1 - p)^{n-k}, \quad k = 0, 1, 2, \dots, n. \quad (3.7)$$

Wartość oczekiwana tej zmiennej wynosi  $E(X) = p$ , natomiast wariancja  $\sigma^2(X) = pq$ .

Przy stosowaniu rozkładu dwumianowego należy zwracać uwagę na rodzaj warunków wynikających ze zdarzenia. Są to sformułowania „dokładnie ...”, „co najmniej ...”, „co najwyżej ...”.

**Przykład 3.5.** W hali fabrycznej pracuje 5 maszyn. Każda z nich psuje się z prawdopodobieństwem  $p = \frac{1}{3}$  niezależnie od siebie. Wyznaczyć prawdopodobieństwa

- zepsuła się jedna maszyna, tj.  $P(X = 1)$ ,
- żadna maszyna się niepopsuła, tj.  $P(X = 0)$ ,
- zepsuły się trzy maszyny, tj.  $P(X = 3)$ ,
- zepsuła się co najmniej jedna maszyna, tj.  $P(X \geq 1)$ ,
- zepsuła się co najwyżej jedna maszyna, tj.  $P(X \leq 1)$ ,
- zepsuło się więcej niż jedna maszyna, tj.  $P(X > 1)$ .

*Rozwiązanie.* a)  $P(X = 1) = \binom{5}{1} \left(\frac{1}{3}\right)^1 \left(\frac{2}{3}\right)^4 = \frac{80}{243} \approx 0,329$

b)  $P(X = 0) = \binom{5}{0} \left(\frac{1}{3}\right)^0 \left(\frac{2}{3}\right)^5 = \frac{32}{243} \approx 0,132$

- c)  $P(X = 3) = \binom{5}{3} \left(\frac{1}{3}\right)^3 \left(\frac{2}{3}\right)^2 = \frac{40}{243} \approx 0,167$   
 d)  $P(X \geq 1) = 1 - P(X < 1) = P(X = 0) = 0,868$   
 e)  $P(X \leq 1) = P(X = 0) + P(X = 1) = 0,461$   
 f)  $P(X > 1) = 1 - P(X \leq 1) = 0,539$

□

**Przykład 3.6.** Środek owadobójczy zabija przeciętnie 90% owadów. Środek ten zastosowano na 10 owadach. Obliczyć prawdopodobieństwo, że co najwyżej dwa osobniki przeżyją.

*Rozwiązanie.* Oznaczmy przez  $A$  zdarzenie, że owad przeżyje. Mamy więc  $p = 0,1, q = 0,9, n = 10$ .

$$\begin{aligned} P(X \leq 2) &= P(X = 0) + P(X = 1) + P(X = 2) = \\ &= \binom{10}{0} (0,1)^0 (0,9)^{10} + \binom{10}{1} (0,1)^1 (0,9)^9 + \binom{10}{2} (0,1)^2 (0,9)^8 = \\ &= 0,929. \end{aligned}$$

□

### Rozkład Poissona

Zmienna skokowa  $X$  ma rozkład Poissona, jeżeli

$$P(X = k) = \frac{e^{-\lambda} \lambda^k}{k!}, \quad \text{dla } k = 0, 1, 2, \dots \quad (3.8)$$

Wiele występujących w praktyce rozkładów może być aproksymowane rozkładem Poissona.

Jeżeli liczba doświadczeń  $n$  jest duża a prawdopodobieństwo  $p$  małe, to obliczenie  $k$  sukcesów jest bardzo utrudnione przy zastosowaniu rozkładu dwumianowego Bernullego. Można wówczas przyjąć  $\lambda = np$  i zastosować wzór graniczny przy  $n \rightarrow \infty$ . Otrzymujemy wówczas wzór przybliżony

$$P(X = k) \approx \frac{(np)^k e^{-np}}{k!}. \quad (3.9)$$

**Przykład 3.7.** Daltonizm stwierdza się o 1% mężczyzn. Obliczyć prawdopodobieństwo, że w próbie liczącej  $n = 100$  mężczyzn

- a) nie będzie ani jednego daltonisty,  
 b) będzie co najmniej trzech.

*Rozwiązanie.* Mamy  $n = 100, p = 0,01$ .

a)  $P(X = 0) = \frac{1}{0!} e^{-1} = 0,37,$

b)  $P(X \geq 3) = 1 - P(X < 3) = 1 - [P(X = 0) + P(X = 1) + P(X = 2)].$

$P(X = 1) = \frac{1}{1!} e^{-1} = 0,37. P(X = 2) = \frac{1}{2!} e^{-1} = 0,18. \text{ Stąd}$

$$P(X \geq 3) = 1 - [0,37 + 0,37 + 0,18] = 0,08.$$

□

## Rozkłady zmiennej losowej ciągłej

### Rozkład normalny


Rozkład normalny jest rozkładem o funkcji gęstości prawdopodobieństwa

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad (3.10)$$

gdzie  $\mu = E(X)$  jest wartością oczekiwaną a  $\sigma$  odchyleniem standardowym. Symbolicznie zapisujemy ten rozkład jako  $N(\mu, \sigma)$ . Szczególnym przypadkiem jest rozkład  $N(0, 1)$  o gęstości

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

której wykres przedstawia poniższy rysunek



Rysunek 3.4: Gęstość rozkładu normalnego  $N(0, 1)$ .

Dystrybuanta tego rozkładu jest równa


$$F(x) = P(X < x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt = \Phi(x). \quad (3.11)$$

**Przykład 3.8.** Dla rozkładu  $N(0, 1)$  obliczyć

- a)  $P(X < -2)$ ,
- b)  $P(-1 \leq X \leq 2)$ ,
- c)  $P(X > 6)$ .

*Rozwiązanie.* Mamy a)

$$\begin{aligned} P(X < -2) &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{-2} e^{-\frac{t^2}{2}} dt = \Phi(-2) = \\ &= 1 - \Phi(2) = 1 - 0,97725 = 0,02275. \end{aligned}$$



Rysunek 3.5: Przykład 3.8 a) i b)

b)

$$\begin{aligned} P(-1 \leq X \leq 3) &= F(3) - F(-1) = \Phi(3) - (1 - \Phi(-1)) = \\ &= \Phi(3) + \Phi(1) - 1 = 0,9987 + 0,8413 - 1 \approx \\ &\approx 0,84. \end{aligned}$$


c)

$$P(X > 6) = 1 - P(X \leq 6) = 1 - F(6) = 1 - \Phi(6) \approx 1 - 1 \approx 0.$$

□

**Uwaga 3.9.** W podpunkcie c) powyższego zadania przyjęliśmy, że  $\Phi(6) \approx 1$ , co jak spojrzymy do tablic rozkładu normalnego popełniamy mały błąd, gdyż już dla wartości 5 ta różnica między prawdziwą wartością a 1 jest bardzo niewielka (w praktyce zaniedbywalna). Widoczne jest to też na ostatnim rysunku.





Rysunek 3.6: Przykład 3.8 c)

W praktyce występują jednak najczęściej rozkłady  $N(m, \sigma)$ , gdzie  $m \neq 0$  i  $\sigma \neq 1$ . Wówczas wprowadzamy *zmienną standaryzowaną*

$$Y = \frac{X - m}{\sigma}, \quad (3.12)$$

która ma już rozkład  $N(0, 1)$ , co umożliwi nam skorzystanie z funkcji  $\Phi(x)$ .

**Przykład 3.10.** Wydajność pracy jest mierzona liczbą detali wykonanych przez pracownika na danym stanowisku. Liczba detali dana jest zmienną losową  $X$  dla  $N(8, 2)$ . Obliczyć  $P(X < 5)$ .

*Rozwiązanie.* Mamy  $Y = \frac{X-8}{2}$ , czyli

$$\begin{aligned} P(X < 5) &= P\left(\frac{X - 8}{2} < \frac{5 - 8}{2}\right) = P(Y < -1,5) = F(-1,5) = \Phi(-1,5) = \\ &= 1 - 0,93319 = 0,6681 \end{aligned}$$

□

### Pewne własności rozkładu normalnego

1. Jeżeli zmienna  $X$  ma rozkład normalny  $N(m, \sigma)$ , to zmienna losowa  $Y = aX + b$  ma rozkład  $N(am + b, |a|\sigma)$ .
2. Jeżeli zmienne losowe  $X$  i  $Y$  mają niezależne rozkłady  $N(m_1, \sigma_1), N(m_2, \sigma_2)$ , to zmienna losowa  $Z = X + Y$  ma rozkład  $N(m_1 + m_2, \sqrt{\sigma_1^2 + \sigma_2^2})$ .

**Przykład 3.11.** Urządzenie złożone z dwóch bloków pracuje w ten sposób, że najpierw włączony jest pierwszy blok, a w chwili awarii tego bloku włącza się drugi blok. Czas bezawaryjnej pracy bloków są zmiennymi losowymi o rozkładach  $N(60; 4)$  i  $N(80; 3)$  odpowiednio. Obliczyć prawdopodobieństwo, że urządzenie będzie pracować co najmniej 150 godzin.

*Rozwiązanie.*  $Z = X + Y$ , zatem  $Z$  ma rozkład  $N(60 + 80, \sqrt{4^2 + 3^2}) = N(140, 5)$ .

$$\begin{aligned} P(Z \geq 150) &= P\left(\frac{Z - 140}{5} \geq \frac{150 - 140}{5}\right) = P(R \geq 2) = 1 - P(R < 2) = \\ &= 1 - \Phi(2) = 1 - 0,97725 \approx 0,022. \end{aligned}$$

Czyli około 2,2%.

□

### 3.3 Zadania do samodzielnego rozwiązania

3.1. Zmienna losowa skokowa  $X$  ma funkcję prawdopodobieństwa:

$x_i$	-1	1	4
$p_i$	0,5	0,4	0,1

Wyznaczyć dystrybuantę zmiennej losowej  $X$  i narysować jej wykres.

$$\text{Odp. } F(x) = \begin{cases} 0 & x \leq -1 \\ 0,5 & -1 < x \leq 1 \\ 0,9 & 1 < x \leq 4 \\ 1 & x > 4 \end{cases}$$

3.2. Zmienna losowa ciągła  $X$  ma gęstość

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

Wyznaczyć dystrybuantę zmiennej  $X$ .

$$\text{Odp. } F(x) = \begin{cases} 0 & x \leq -1 \\ \frac{1}{2}(x+1) & -1 < x \leq 0 \\ \frac{1}{2}(x^2+1) & 0 < x \leq 1 \\ 1 & x > 1 \end{cases}$$

3.3. Dystrybuanta zmiennej losowej ciągłej dana jest wzorem

$$F(x) = \begin{cases} 0 & x \leq 0 \\ \frac{1}{16}x^2 & 0 < x \leq 4 \\ 1 & x > 4 \end{cases}$$

Wyznaczyć funkcję gęstości zmiennej  $X$  oraz wyznaczyć wartość oczekiwaną i wariancję zmiennej  $X$ .

$$\text{Odp. } f(x) = \begin{cases} 0 & x \leq 0 \\ \frac{1}{8}x & 0 < x \leq 4 \\ 0 & x > 4 \end{cases}, E(X) = \frac{8}{3}, \sigma^2(X) = \frac{8}{9}.$$

3.4. Gęstością zmiennej losowej  $X$  jest funkcja

$$f(x) = \begin{cases} 0 & x \leq 1 \\ \frac{1}{2} & 1 < x \leq 3 \\ 0 & x > 3 \end{cases}$$

Wyznaczyć dystrybuantę zmiennej losowej  $X$  oraz wyznaczyć  $P(X > 2)$ .

$$\text{Odp. } F(x) = \begin{cases} 0 & x \leq 1 \\ \frac{1}{2}x - \frac{1}{2} & 1 < x \leq 3 \\ 1 & x > 3 \end{cases}, P(X > 2) = \frac{1}{2}.$$

**3.5.** Zmienna losowa  $X$  przyjmuje wartości 0, 1, 2, 3 z prawdopodobieństwami odpowiednio równymi 0, 1; 0, 1; 0, 2; 0, 6. Obliczyć wartość oczekiwaną i wariancję zmiennej  $X$ .

Odp.  $E(X) = 2,3, \sigma^2(X) = 1,01$ .

**3.6.** Zmienna losowa  $X$  ma rozkład normalny  $N(1, 5; 2)$ . Obliczyć prawdopodobieństwo:

a)  $P(X < -2, 5)$

b)  $P(X > -0, 5)$ ,

c)  $P(0, 5 < X < 2)$ .

Odp. a) 0,02275, b) 0,8413, c) 0,2902.

**3.7.** Masa gruszek odmiany klops ma rozkład normalny  $N(160, 30)$ . Oblicz prawdopodobieństwo, że gruszka tego gatunku waży od 130 do 160 gramów.

Odp. 0,3413.

**3.8.** W populacji studentów uczęszczających na zajęcia ze statystyki dokonano pomiaru wzrostu mężczyzn. W wyniku badania stwierdzono, że zmienna losowa  $X$  wyrażająca wzrost studenta ma rozkład normalny  $N(178, 10)$ . Oblicz prawdopodobieństwo, że

a) wzrost studenta jest mniejszy niż 188 cm,

b) wzrost studenta jest większy niż 172,

c) wzrost studenta jest większy niż 200 cm,

d) wzrost studenta należy do przedziału (166 cm, 186 cm).

Odp. a) 0,8413, b) 0,7257, c) 0,0139, d) 0,673.

## Wykład 4

# Zmienne losowe dwuwymiarowe

Omówione są zmienne losowe dwuwymiarowe, ich parametry. Następnie funkcje zmiennych losowych oraz twierdzenia graniczne.

## 4.1 Zmienna losowa dwuwymiarowa

Rozkład dwuwymiarowej zmiennej losowej  $Z = (X, Y)$  jest rozkładem dwóch zmiennych losowych  $X$  i  $Y$ .

W przypadku, gdy zmienne losowe  $X$  i  $Y$  są dyskretne, możemy ich rozkład opisać łączną funkcją prawdopodobieństwa

$$P(X = x, Y = y) = P(x, y), \quad (4.1)$$

która daje prawdopodobieństwo tego, że zmienna losowa  $X$  osiąga wartość  $x$  i jednocześnie zmienna losowa  $Y$  osiąga wartość  $y$ . Łączne prawdopodobieństwo  $P(x, y)$  możemy podać w postaci tzw. tablicy korelacyjnej. Przy założeniu, że różnych wartości zmiennej  $X$  jest  $r$  a różnych wartości zmiennej  $Y$  jest  $s$ , ta tablica obejmuje  $r \cdot s$  łącznych prawdopodobieństw możliwych kombinacji wartości  $x$  i  $y$ .

$x$	$y$				suma
	$y_1$	$y_2$	$\dots$	$y_s$	
$x_1$	$P(x_1, y_1)$	$P(x_1, y_2)$	$\dots$	$P(x_1, y_s)$	$P_1(x_1)$
$x_2$	$P(x_2, y_1)$	$P(x_2, y_2)$	$\dots$	$P(x_2, y_s)$	$P_1(x_2)$
$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
$x_r$	$P(x_r, y_1)$	$P(x_r, y_2)$	$\dots$	$P(x_r, y_s)$	$P_1(x_r)$
suma	$P_2(y_1)$	$P_2(y_2)$	$\dots$	$P_2(y_s)$	1

Poziome sumy tych prawdopodobieństw w tej tablicy są wartościami brzegowej funkcji prawdopodobieństwa  $P_1(x)$ , która podaje prawdopodobieństwa, że zmienna losowa  $X$  osiąga wartość  $x$  bez względu na wartości zmiennej  $Y$ . Podobnie pionowe sumy tych prawdopodobieństw dają wartości brzegowej funkcji prawdopodobieństwa  $P_2(y)$ . Mamy zatem

$$\sum_y P(x, y) = P_1(x), \quad \sum_x P(x, y) = P_2(y), \quad (4.2)$$

oraz

$$\sum_x \sum_y P(x, y) = \sum_x P_1(x) = \sum_y P_2(y) = 1. \quad (4.3)$$

Rozkład dwóch dyskretnych lub ciągłych zmiennych losowych można opisać łączną dystrybucją

$$F(x, y) = P(X \leq x, Y \leq y), \quad (4.4)$$

która podaje prawdopodobieństwo, że zmienna  $X$  osiągnie wartość mniejsze niż  $x$  a jednocześnie zmienna  $Y$  osiągnie wartość mniejszą od  $y$ . Łączna dystrybuanta spełnia warunki

$$F(-\infty, y) = F(-\infty, x) = F(-\infty, -\infty) = 0, \quad F(\infty, \infty) = 1. \quad (4.5)$$

Prawdopodobieństwo, że ciągła zmienna losowa  $X$  osiągnie wartość z przedziału  $\langle x_1, x_2 \rangle$  i jednocześnie ciągła zmienna losowa  $Y$  osiągnie wartość z przedziału  $\langle y_1, y_2 \rangle$  jest równa

$$P(x_1 \leq X \leq x_2, y_1 \leq Y \leq y_2) = F(x_2, y_2) - F(x_1, y_2) - F(x_2, y_1) + F(x_1, y_1). \quad (4.6)$$

Możemy także otrzymać dystrybuanty zmiennych losowych brzegowych kładąc

$$F_1(x) = F(x, \infty), \quad F_2(x) = F(\infty, y). \quad (4.7)$$

Rozkład dwuwymiarowej zmiennej losowej ciągłej możemy także opisać za pomocą łącznej gęstości prawdopodobieństwa  $f(x, y)$ . Dwuwymiarowa gęstość prawdopodobieństwa jest tak samo jak jednowymiarowa funkcją nieujemną i spełnia warunek

$$\int_{-\infty}^{\infty} \left[ \int_{-\infty}^{\infty} f(x, y) dx \right] dy = 1. \quad (4.8)$$

Brzegowe gęstości prawdopodobieństwa

$$f_1(x) = \int_{-\infty}^{\infty} f(x, y) dy,$$

$$f_2(y) = \int_{-\infty}^{\infty} f(x, y) dx.$$

Łączna dystrybuanta dwuwymiarowej zmiennej losowej możemy otrzymać z łącznej gęstości i na odwrót

$$F(x, y) = \int_{-\infty}^y \left[ \int_{-\infty}^x f(t, u) dt \right] du, \quad (4.9)$$

$$f(x, y) = \frac{\partial^2 F(x, y)}{\partial x \partial y}. \quad (4.10)$$

Kolejnym typem rozkładów (oprócz łącznego i brzegowego) są rozkłady warunkowe. Rozkładem warunkowym zmiennej losowej  $X$  względem  $y$  rozumiemy rozkład tej zmiennej przy założeniu, że zmienna  $Y$  przyjmuje wartość  $y$  i analogicznie rozkładem warunkowym zmiennej  $X$  względem  $x$  rozumiemy rozkład tej zmiennej przy założeniu, że zmienna  $X$  przyjmuje wartość  $x$ . Rozkład warunkowy jest zdefiniowany jako iloraz łącznego i brzegowego rozkładu.

Dla dwóch zmiennych losowych dyskretnych  $X$  i  $Y$  funkcje prawdopodobieństwa są dane

$$P(x|y) = \frac{P(x, y)}{P_2(y)}, \quad P_2(y) \neq 0, \quad (4.11)$$

$$P(y|x) = \frac{P(x, y)}{P_1(x)}, \quad P_1(x) \neq 0, \quad (4.12)$$

dystrybuanty warunkowe

$$F(x|y) = \frac{\sum_{t < x} P(t, y)}{P_2(y)}, \quad P_2(y) \neq 0, \quad (4.13)$$

$$F(y|x) = \frac{\sum_{u < y} P(x, u)}{P_1(x)}, \quad P_1(x) \neq 0. \quad (4.14)$$

Dla zmiennych losowych ciągłych  $X$  i  $Y$  gęstości warunkowe są określone wzorami

$$f(x|y) = \frac{f(x, y)}{f_2(y)}, \quad f_2(y) \neq 0, \quad (4.15)$$

$$f(y|x) = \frac{f(x, y)}{f_1(x)}, \quad f_1(x) \neq 0 \quad (4.16)$$

i warunkowe dystrybuanty

$$F(x, y) = \frac{\int_{-\infty}^x f(t, y) dt}{f_2(y)}, \quad f_2(y) \neq 0, \quad (4.17)$$

$$F(y|x) = \frac{\int_{-\infty}^y f(x, t) dt}{f_1(x)}, \quad f_1(x) \neq 0. \quad (4.18)$$

**Definicja 4.1.** Mówimy, że dwie zmienne losowe  $X$  oraz  $Y$  są niezależne, jeżeli dla wszystkich  $i, j$  zachodzi równość

$$P(X = x_i, Y = y_j) = P(X = x_i) \cdot P(Y = y_j). \quad (4.19)$$

Czyli zmienne losowe  $X$  i  $Y$  są niezależne, jeżeli rozkład jednej zmiennej nie zależy od wartości drugiej zmiennej. Ponadto prawdziwe są twierdzenia, że zmienne losowe  $X$  oraz  $Y$  są niezależne wtedy i tylko wtedy, gdy zachodzi jedna z poniższych równości

$$P(x, y) = P_1(x) \cdot P_2(y), \quad (4.20)$$

$$F(x, y) = F_1(x) \cdot F_2(y), \quad (4.21)$$

$$f(x, y) = f_1(x) \cdot f_2(y). \quad (4.22)$$

**Przykład 4.2.** Dana jest dwuwymiarowa zmienna losowa  $Z = (X, Y)$  dyskretna, której wartości prawdopodobieństw podane są w poniższej tabelicy

		$y$	
		1	2
$x$	-1	$\frac{3}{16}$	$\frac{5}{16}$
	0	$\frac{3}{32}$	$\frac{5}{32}$
	1	$\frac{3}{32}$	$\frac{5}{32}$



- a) Wyznaczyć rozkłady brzegowe zmiennych losowych  $X$  i  $Y$ .
- b) Wyznaczyć prawdopodobieństwa warunkowe tych zmiennych.
- c) Wykazać, że zmienne są niezależne.

*Rozwiązanie.* Mamy a)

$$P_2(1) = \frac{3}{16} + \frac{3}{32} + \frac{3}{32} = \frac{3}{8}, \quad P_2(2) = \frac{5}{8}, \quad P_1(-1) = \frac{3}{16} + \frac{5}{16} = \frac{1}{2},$$

$$P_1(0) = \frac{1}{4}, \quad P_1(1) = \frac{1}{4}.$$

- b) Korzystając ze wzorów (4.11) oraz (4.12) otrzymujemy

$$P(X = -1|Y = 1) = \frac{P(X = -1, Y = 1)}{P_2(1)} = \frac{\frac{3}{16}}{\frac{3}{8}} = \frac{1}{2},$$

$$P(X = -1|Y = 2) = \frac{\frac{5}{16}}{\frac{5}{8}} = \frac{1}{2},$$

$$P(X = 0|Y = 1) = \frac{\frac{3}{32}}{\frac{3}{8}} = \frac{1}{4},$$

$$P(X = 0|Y = 2) = \frac{\frac{5}{32}}{\frac{5}{8}} = \frac{1}{4},$$

$$P(X = 1|Y = 1) = \frac{\frac{3}{32}}{\frac{3}{8}} = \frac{1}{4},$$

$$P(X = 1|Y = 2) = \frac{\frac{5}{32}}{\frac{5}{8}} = \frac{1}{4}.$$

$$P(Y = 1|X = -1) = \frac{P(X = -1, Y = 1)}{P_1(-1)} = \frac{\frac{3}{16}}{\frac{1}{2}} = \frac{3}{8},$$

$$P(Y = 2|X = 0) = \frac{\frac{3}{32}}{\frac{1}{4}} = \frac{3}{8},$$

$$P(Y = 1|X = 1) = \frac{\frac{3}{32}}{\frac{1}{4}} = \frac{3}{8},$$

$$P(Y = 2|X = -1) = \frac{\frac{5}{16}}{\frac{1}{2}} = \frac{5}{8},$$

$$P(Y = 2|X = 0) = \frac{\frac{5}{32}}{\frac{1}{4}} = \frac{5}{8},$$

$$P(Y = 2|X = 1) = \frac{\frac{5}{32}}{\frac{1}{4}} = \frac{5}{8}.$$

c) Mamy

$$P_1(-1) \cdot P_2(1) = \frac{1}{2} \cdot \frac{3}{8} = \frac{3}{16} = P(X = -1, Y = 1),$$

$$P_1(-1) \cdot P_2(2) = \frac{1}{2} \cdot \frac{5}{8} = \frac{5}{16},$$

itd.

co dowodzi, że zmienne te są niezależne.

□

## 4.2 Charakterystyki zmiennych losowych dwuwymiarowych

Brzegowe charakterystyki, które informują nas o własnościach zmiennych brzegowych  $X$  i  $Y$  dane są wzorami dla dyskretnej zmiennej losowej

$$E(X) = \sum_x x P_1(x), \quad (4.23)$$

$$\sigma^2(X) = \sum_x (x - E(X))^2 \cdot P_1(X), \quad (4.24)$$

a dla zmiennej ciągłej

$$E(X) = \int_{-\infty}^{\infty} x f_1(x) dx, \quad (4.25)$$

$$\sigma^2(X) = \int_{-\infty}^{\infty} (x - E(X))^2 \cdot f_1(x) dx. \quad (4.26)$$

Analogicznie definiuje się te charakterystyki dla zmiennej  $Y$ .

Charakterystyki zmiennych warunkowych definiujemy wzorami

$$E(X|y) = \begin{cases} \sum_x x P(x|y), \\ \int_{-\infty}^{\infty} x f(x|y) dx, \end{cases} \quad (4.27)$$

$$\sigma^2(X|y) = \begin{cases} \sum_x (x - E(X|y))^2 \cdot P(x|y), \\ \int_{-\infty}^{\infty} (x - E(X|y))^2 \cdot f(x|y) dx. \end{cases} \quad (4.28)$$

Analogicznie definiujemy  $E(Y|x)$ ,  $\sigma^2(Y|x)$ .

Charakterystyki, które dostarczają nam informację o zależnościach między zmiennymi  $X$  i  $Y$ . Do tych charakterystyk należy kowariancja  $C(X, Y)$  oraz współczynnik korelacji  $\varrho(X, Y)$ .

Kowariancja jest zdefiniowana jako wartość oczekiwana iloczynu odchyłeń zmiennych  $X$  i  $Y$  od ich wartości oczekiwanych

$$C(X, Y) = E[(X - E(X)) \cdot (Y - E(Y))]. \quad (4.29)$$

Przy obliczeniach wygodnie jest skorzystać ze wzoru

$$C(X, Y) = E(XY) - E(X)E(Y). \quad (4.30)$$

Kowariancja może osiągać wartości ze zbioru  $(-\infty, \infty)$  i pomaga nam stwierdzić o istnieniu lub jego braku między zmiennymi.

Użyteczniejszą charakterystyką jest współczynnik korelacji liniowej  $\varrho(X, Y)$  dany wzorem

$$\varrho(X, Y) = \frac{C(X, Y)}{\sigma(X) \cdot \sigma(Y)}. \quad (4.31)$$

Przyjmuje wartości z przedziału  $\langle -1, 1 \rangle$ . Jeżeli jego wartość jest równa  $\pm 1$ , to wtedy między zmiennymi  $X$  i  $Y$  mamy zależność liniową, natomiast gdy jest równa 0, to nie ma zależności liniowej między tymi zmiennymi losowymi.

**Przykład 4.3.** Zmienna losowa  $Z = (X, Y)$  ma gęstość prawdopodobieństwa zadaną wzorem

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

Wyznaczyć

- brzegowe wartości oczekiwane i wariancje;
- $E(X|y), \sigma^2(X|y)$ ;
- $C(X, Y), \varrho(X, Y)$ .

*Rozwiązanie.* Najpierw wyznaczmy gęstości brzegowe

oraz warunkową gęstość prawdopodobieństwa zmiennej losowej  $X$ , jeżeli zmienna  $Y$  przyjmuje wartość  $y$

$$f(x|y) = \frac{2}{2y} = \frac{1}{y} \quad \text{dla } 0 < x < y, 0 < y < 1.$$

Poza wartościami wyróżnionymi te gęstości są zerowe.

a) Mamy

$$E(X) = \int_0^1 2x(1-x)dx = \frac{1}{3}, \quad E(Y) = \int_0^1 2y^2 dy = \frac{2}{3},$$

$$\sigma^2(X) = \int_0^1 2x^2(1-x)dx - \left(\frac{1}{3}\right)^2 = \frac{1}{18}, \quad \sigma^2(Y) = \int_0^1 2y^3 dy - \left(\frac{2}{3}\right)^2 = \frac{1}{18}.$$

b) Korzystając ze wzorów wcześniej podanych otrzymujemy

$$E(X|y) = \int_0^y \frac{x}{y} dx = \frac{y}{2}, \quad \sigma^2(X|y) = \int_0^y \left(x - \frac{y}{2}\right)^2 \frac{1}{y} dx = \frac{y^2}{12}.$$

c) Korzystając ze wzorów na kowariancję i współczynnik korelacji otrzymujemy

$$C(X, Y) = \int_0^1 \left[ \int_0^y 2xy dx \right] dy - \left(\frac{2}{3}\right)^2 = \frac{1}{36}$$

$$\varrho(X, Y) = \frac{\frac{1}{36}}{\sqrt{\frac{1}{18} \cdot \frac{1}{18}}} = \frac{1}{2}.$$

□

### 4.3 Funkcje zmiennych losowych

#### Funkcje jednej zmiennej losowej

W niektórych zagadnieniach spotykamy się z sytuacją, że znamy rozkład prawdopodobieństwa zmiennej losowej  $X$  a interesuje nas rozkład zmiennej losowej  $Y$ , która jest funkcją zmiennej losowej  $X$

$$Y = y(X). \quad (4.32)$$

Jeżeli funkcja  $y(x)$  w zbiorze możliwych wartości zmiennej  $X$  jest ściśle monotoniczna, tzn. jeżeli ma funkcję odwrotną  $x = y^{-1}(y) = x(y)$ , to istnieje między zmiennymi  $X$  i  $Y$  wzajemnie jednoznaczna odpowiedniość i łatwo wyznaczyć rozkład prawdopodobieństwa zmiennej  $Y$ .

Jeżeli funkcja  $y(x)$  jest rosnąca, to dystrybuanta zmiennej losowej  $Y$  zadana jest wzorem

$$G(y) = P(Y < y) = P(X \leq x(y)) = F(x(y)), \quad (4.33)$$

jeżeli natomiast funkcja  $y(x)$  jest malejąca, to dystrybuanta zmiennej  $Y$  dana jest wzorem

$$G(y) = P(Y \leq y) = P(X \geq x(y)) = 1 - F(x(y)). \quad (4.34)$$

Jeżeli zmienna losowa  $X$  jest zmienną ciągłą o gęstości  $f(x)$  oraz jeżeli funkcja  $x(y)$  ma we wszystkich punktach wewnętrznych przedziału możliwych wartości ciągłą pochodną, to wtedy gęstość prawdopodobieństwa  $g(y)$  zmiennej losowej  $Y$  dla rosnącej  $y(x)$  dana jest wzorem

$$g(y) = \frac{dG(y)}{dy} = f(x(y)) \cdot x'(y) \quad (4.35)$$

a dla malejącej  $y(x)$

$$g(y) \frac{dG(y)}{dy} = -f(x(y)) \cdot x'(y). \quad (4.36)$$

Jeżeli funkcja  $y(x)$  w obszarze możliwych wartości zmiennej losowej  $X$  nie jest ściśle monotoniczna, to wtedy nie istnieje związek pomiędzy zmiennymi losowymi  $X$  i  $Y$  wzajemnie jednoznaczny związek.

#### Funkcje dwóch ciągłych zmiennych losowych

Jeżeli znamy łączną gęstość prawdopodobieństwa  $f(x_1, x_2)$  zmiennych losowych  $X_1, X_2$  a interesuje nas rozkład zmiennej losowej  $Y$ , która jest funkcją tych dwóch zmiennych losowych

$$Y = y(X_1, X_2). \quad (4.37)$$

Dystrybuanta zmiennej losowej  $Y$

$$G(y) = P(Y \leq y) = P(y(x_1, x_2) \leq y) \quad (4.38)$$

uzyskujemy całkując gęstość prawdopodobieństwa  $f(x_1, x_2)$  po zbiorze  $S$  takim, że  $y(x_1, x_2) < y$

$$G(y) = \iint_S f(x_1, x_2) dx_1 dx_2. \quad (4.39)$$

Różniczkując dystrybuantę  $G(y)$  otrzymujemy gęstość prawdopodobieństwa zmiennej  $Y$

$$g(y) = \frac{dG(y)}{dy}. \quad (4.40)$$

**Przykład 4.4.** Zmienna losowa dyskretna  $X$  dana jest

$$\begin{array}{c|c|c|c} x_i & -1 & 0 & 1 \\ \hline p_i & \frac{1}{6} & \frac{1}{3} & \frac{1}{2} \end{array}$$

Wyznaczyć zmienną losową  $Y = X^2$ .

*Rozwiązanie.* Mamy

$$\begin{array}{c|c|c|c} y_i & (-1)^2 & 0^2 & 1^2 \\ \hline p_i & \frac{1}{6} & \frac{1}{3} & \frac{1}{2} \end{array} \quad \text{tj.} \quad \begin{array}{c|c} y_i & 0 & 1 \\ \hline p_i & \frac{1}{3} & \frac{1}{6} + \frac{1}{2} = \frac{2}{3} \end{array}.$$

□

**Przykład 4.5.** Pomiędzy zmiennymi losowymi  $X$  i  $Y$  jest zależność

$$Y = 2X + 3.$$

$X$  jest ciągłą zmienną losową o dystrybuancie  $F(x)$ . Wyznaczyć gęstość prawdopodobieństwa  $g(y)$ ?

*Rozwiązanie.* Dystrybuanta zmiennej losowej  $Y$  dana jest

$$G(y) = P(Y < y) = P(2X + 3 < y) = P\left(X < \frac{y-3}{2}\right) = F\left(\frac{y-3}{2}\right).$$

Różniczkując dystrybuantę  $G(y)$  otrzymujemy gęstość prawdopodobieństwa zmiennej losowej  $Y$

$$g(y) = \frac{dG(y)}{dy} = \frac{1}{2} f\left(\frac{y-3}{2}\right),$$

gdzie  $f = \frac{d}{dx} F(x)$ .

□

**Przykład 4.6.** Wyznaczyć funkcję prawdopodobieństwa zmiennej losowej  $Y$ , jeżeli

$$P(X) = \begin{cases} \frac{1}{3} & \text{dla } x = 1, 2, 3, \\ 0 & \text{poza.} \end{cases}$$

oraz  $Y = 2X + 1$ .

*Rozwiązanie.* Mamy  $y(x) = 2x + 1$ , więc

$$P(y) = \begin{cases} \frac{1}{3} & \text{dla } y = 3, 5, 7, \\ 0 & \text{poza.} \end{cases}$$

□

**Przykład 4.7.** Zmienna losowa  $Y$  jest funkcją ciągłej zmiennej losowej  $X$ . Wyznaczyć gęstość prawdopodobieństwa  $g(y)$ , jeżeli gęstość zmiennej losowej  $X$  dana jest

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

oraz  $Y = X^3$ .

*Rozwiązanie.* Mamy  $y(x) = x^3$  dla  $0 < x < 1$ . W tym przedziale funkcja  $y(x)$  jest rosnąca a funkcją do niej odwrotną jest  $x(y) = \frac{1}{2}y^{\frac{1}{3}}$  dla  $0 < y < 8$ . Na mocy wzoru (4.35) otrzymujemy

$$g(y) = \begin{cases} 2 \cdot \frac{1}{2}y^{\frac{1}{3}} \cdot \frac{1}{6}y^{-\frac{2}{3}} = \frac{1}{6}y^{-\frac{1}{3}} & \text{dla } 0 < y < 8, \\ 0 & \text{poza.} \end{cases}$$

□

**Przykład 4.8.** Niech  $X$  będzie zmienną losową o wartości oczekiwanej  $E(X) = -1$  i wariancji  $\sigma^2(X) = 4$ . Rozważmy zmienną losową

$$Y = 2 - 3X.$$

Wyznaczyć wartość średnią, wariancję zmiennej  $Y$  oraz kowariancję i współczynnik korelacji zmiennych  $X, Y$ .

*Rozwiązanie.* Z własności wartości oczekiwanej i wariancji otrzymujemy

$$\begin{aligned} E(Y) &= E(2 - 3X) = E(2) - 3E(X) = 2 - 3 \cdot (-1) = 5, \\ \sigma^2(Y) &= \sigma^2(2 - 3X) = \sigma^2(2) + \sigma^2(-3X) = 0 + (-3)^2 D(X) = 9 \cdot 4 = 36 \end{aligned}$$

korzystając ponadto z definicji kowariancji otrzymujemy

$$\begin{aligned} C(X, Y) &= E[XY] - E(X)E(Y) = E(X(2 - 3X)) - E(X)E(Y) = \\ &= 2E(X) - 3E(X^2) + 5 \end{aligned}$$

a ponieważ

$$E(X^2) = \sigma^2(X) + (E(X))^2 = 4 + (-1)^2 = 5,$$

więc

$$C(X, Y) = 2 \cdot (-1) - 3 \cdot 5 + 5 = -12$$

oraz współczynnik korelacji

$$\rho(X, Y) = \frac{-12}{\sqrt{4 \cdot 36}} = -1,$$

co oznacza, że między zmiennymi losowymi  $X$  i  $Y$  mamy zależność liniową (tak przecież została określona zmienna  $Y$ ), czego się należało spodziewać.

□



## 4.4 Twierdzenia graniczne

Do tej pory zajmowaliśmy się zmienną losową o rozkładzie teoretycznym, któremu przypisawaliśmy teoretyczne charakterystyki. Jeżeli jednak powtórzmy niezależnie pewne doświadczenie losowe, możemy z obserwowanych wartości rozkład względnych częstości i informacje o tym rozkładzie sprowadzić znowu do charakterystyk. Ten rozkład, ewentualnie jego charakterystyki nazwiemy dla odróżnienia od poprzednich empirycznym rozkładem, ewentualnie empirycznymi charakterystykami.

Przy zachowaniu pewnych warunków możemy oczekiwać, że rozkład empiryczny (ewentualnie jego charakterystyki) będzie się zbliżało do rozkładu teoretycznego (ewentualnie teoretycznych charakterystyk), tym bardziej im więcej będzie realizowanych doświadczeń. Musimy jednak uświadomić sobie, że zbieżność wartości empirycznych do wartości teoretycznych nie ma charakteru zbieżności matematycznej ale zbieżności w sensie prawdopodobieństwa.

**Definicja 4.9.** Mówimy, że ciąg zmiennych losowych  $X_1, X_2, \dots, X_n, \dots$  jest zbieżny do zmiennej  $X$  według prawdopodobieństwa 1, jeżeli

$$\bigwedge_{\varepsilon > 0} \lim_{n \rightarrow \infty} P(|X_n - X| < \varepsilon) = 1.$$

Podamy teraz kilka twierdzeń dotyczących własności granicznych sum zmiennych losowych. Prawa wielkich liczb

**Twierdzenie 4.10** (Bernoullego). *Niech  $X_n, n = 1, 2, \dots$  będzie ciągiem zmiennych losowych o rozkładzie Bernoullego z parametrami  $n, p$ , gdzie  $0 < p < 1$ . Dla dowolnego  $\varepsilon > 0$  zachodzi*

$$\lim_{n \rightarrow \infty} P \left[ \left| \frac{X_n}{n} - p \right| < \varepsilon \right] = 1.$$

**Twierdzenie 4.11.** *Niech  $X_1, X_2, \dots$  będą parami niezależnymi zmiennymi losowymi takimi, że*

$$E(X_i) = a, \quad D(X_i) < c \quad i = 1, 2, \dots$$

gdzie  $|a| < \infty, c < \infty$ . Wtedy dla dowolnego  $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P \left[ \left| \frac{1}{n} \sum_{i=1}^n X_i - a \right| < \varepsilon \right] = 1.$$

oraz centralne twierdzenie graniczne Lindeberga-Levy'ego

**Twierdzenie 4.12** (Lindeberga-Levy'ego). *Niech  $X_1, X_2, \dots$  będzie ciągiem niezależnych zmiennych losowych o jednakowym rozkładzie z wartością oczekiwaną  $E(X_k) = \mu$  oraz odchyleniem standardowym  $\sigma(X_k) = \sigma, k = 1, 2, \dots$ . Wtedy*

$$\lim_{n \rightarrow \infty} P \left( a < \frac{S_n - E(X_n)}{\sigma} \leq b \right) = \Phi(b) - \Phi(a), \quad (4.41)$$

gdzie  $S_n = \sum_{k=1}^n X_k$  oraz  $\Phi$  oznacza dystrybuantę rozkładu  $N(0, 1)$ .

Szczególnym przypadkiem powyższego twierdzenia jest

**Twierdzenie 4.13** (Moiver'a-Laplace'a). *Niech  $X_k$ ,  $k = 1, 2, 3, \dots$  będzie ciągiem niezależnych zmiennych losowych o jednakowym rozkładzie postaci*

$$P(X_k = 1) = 1 - P(X_k = 0) = p$$

,  $k = 1, 2, 3, \dots$ . Wtedy

$$\lim_{n \rightarrow \infty} P \left( a < \frac{S_n - np}{\sqrt{np(1-p)}} \leq b \right) = \Phi(b) - \Phi(a). \quad (4.42)$$

## 4.5 Zadania do samodzielnego rozwiązania

4.1. Zmienna losowa  $X$  dana jest jak w Przykładzie 4.4. Wyznaczyć zmienną losową  $Y = X^3$ .

Odp. Zmienna  $Y$  ma taki sam rozkład jak zmienna  $X$ .

4.2. Zmienna losowa dyskretna  $X$  ma rozkład prawdopodobieństwa

$$\begin{array}{c|c|c|c} x_i & -2 & 0 & 2 \\ \hline p_i & \frac{1}{6} & \frac{1}{3} & \frac{1}{2} \end{array}.$$

Wyznaczyć zmienną losową  $Y = X^3 - 2$ .

Odp.  $\begin{array}{c|c|c|c} x_i & -10 & -2 & 6 \\ \hline p_i & \frac{1}{6} & \frac{1}{3} & \frac{1}{2} \end{array}$



## Wykład 5

# Elementy statystyki opisowej

Statystyka opisowa zajmuje się opracowaniem danych statystycznych bez posługiwania się rachunkiem prawdopodobieństwa. Pozwala przedstawić dane w sposób uporządkowany, dający możliwość ich analizy.

*Populacją statystyczną* nazywamy zbiór wszystkich możliwych elementów (jednostek), które podlegają badaniu. Przykładem populacji są np. wszystkie elementy wyprodukowane przez daną maszynę, mieszkańcy Polski, mieszkańcy Warszawy itp.

Ponieważ często populacja jest zbyt duża aby można było przeprowadzić badanie całej populacji (np. ze względu na koszty, lub czas potrzebny do realizacji), więc wybiera się podzbiór (próbę) z populacji, która powinna być reprezentatywna dla całej populacji, tzn. aby badanie przeprowadzone na części populacji można było odnieść do wszystkich elementów populacji.

*Próba* (próba losowa) jest podzbiorem elementów (jednostek) populacji.

Jednostki statystyczne charakteryzują się pewnymi właściwościami, które określa się mianem *cech statystycznych*. Cechy statystyczne ogólnie dzieli się na

1. *Cechy niemierzalne* (jakościowe). Są to na ogół określane słownie np. płeć, rozmieszczenie przestrzenne czy geograficzne.
2. *Cechy mierzalne* (ilościowe). Są to właściwości, które można zmierzyć i wyrazić za pomocą jednostek fizycznych, np. waga, wysokość, długość, ilość itp. Ze względu na przyjmowane wartości cechy mierzalne dzielimy na:
  - (a) *dyskretne* (skokowe), to takie, które przyjmują skończony lub przeliczalny zbiór wartości na danej skali liczbowej, przy czym jest to na ogół zbiór liczb naturalnych (np. liczba dzieci w rodzinie, ilość wyprodukowanych elementów przez fabrykę itp.).
  - (b) *ciągłe*, to takie, które mogą przyjąć każdą wartość z określonego przedziału liczbowego  $\langle a, b \rangle$ .

## 5.1 Dane statystyczne

Materiał otrzymany w wyniku przeprowadzonej obserwacji statystycznej należy odpowiednio usystematyzować i pogrupować w postaci tzw. szeregów statystycznych.

*Szeregiem statystycznym* nazywamy ciąg wielkości statystycznych uporządkowany według określonych kryteriów.

Ze względu na kryteria uporządkowania szeregi statystyczne dzielimy na

**Szeregi szczegółowe** są to uporządkowane ciągi wartości badanej cechy statystycznej.

Taki sposób prezentacji danych statystycznych jest stosowany na ogół w przypadku, gdy przedmiotem badania jest niewielka liczba jednostek. Załóżmy, że zmienna  $X$  przyjmuje wartości  $x_1, x_2, \dots, x_n$ . Wartości tej cechy możemy uporządkować rosnąco

$$x_1 \leq x_2 \leq \dots \leq x_n \quad (5.1)$$

lub malejąco

$$x_1 \geq x_2 \geq \dots \geq x_n. \quad (5.2)$$

**Szereg rozdzielczy** stanowi zbiorowość statystyczną podzieloną na części (klasy) według określonej cechy jakościowej lub ilościowej z podaniem liczebności każdej z wyodrębnionych klas. W przypadku szeregów rozdzielczych cechy ilościowej jej warianty można określić

- *punktowo*, wtedy szereg ma postać

$i$	$x_i$	$n_i$	$n_i^{sk}$
1	$x_1$	$n_1$	$n_1^{sk}$
2	$x_2$	$n_2$	$n_2^{sk}$
3	$x_3$	$n_3$	$n_3^{sk}$
...	...	...	...
$k$	$x_k$	$n_k$	$n_k^{sk}$
$\sum$		$n$	

gdzie  $x_i$  jest  $i$ -tą wartością badanej cechy oraz  $n_i$  jest liczebnością cechy  $x_i$  w badanej próbie a  $n_i^{sk}$  są liczebnościami skumulowanymi, tj.  $n_i^{sk} = n_1 + n_2 + \dots + n_i$ .

- *przedziałowo*, wtedy szeregu ma postać

$i$	$x_{0,i}$	$x_{1,i}$	$\dot{x}_i$	$n_i$	$n_i^{sk}$
1	$x_{0,1}$	$x_{1,1}$	$\dot{x}_1$	$n_1$	$n_1^{sk}$
2	$x_{0,2}$	$x_{1,2}$	$\dot{x}_2$	$n_2$	$n_2^{sk}$
...	...	...	...	...	...
$k$	$x_{0,k}$	$x_{1,k}$	$\dot{x}_k$	$n_k$	$n_k^{sk}$
$\sum$				$n$	

gdzie  $x_{0,i}$  jest początkiem  $i$ -tego przedziału,  $x_{1,i}$  jest końcem  $i$ -tego przedziału,  $\dot{x}_i$  - jest reprezentantem  $i$ -tego przedziału oraz  $n_i$  liczebnością  $i$ -tego przedziału a  $n_i^{sk}$  jak poprzednio liczebnościami skumulowanymi.

## 5.2 Miary położenia, zróżnicowania, asymetrii

### Miary położenia (tendencji centralnej)

Miary tendencji centralnej służą do wyznaczenia wartości cechy, wokół której skupiają się dane. Czyli można taką wartość cechy mierzalnej uważać za „typowego reprezentanta” naszych danych. Do najczęściej używanych miar tendencji centralnej należą: średnia arytmetyczna, mediana i dominanta. Przyjmujemy oznaczenia  $n$  jest to liczba elementów w próbie,  $k$  jest to liczba klas (przedziałów) w szeregu rozdzielczym.

Średnia arytmetyczna dla poszczególnych szeregów wyraża się wzorami

- szczegółowego

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad (5.3)$$

- rozdzielczego punktowego

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k x_i \cdot n_i, \quad (5.4)$$

- rozdzielczego przedziałowego

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k \dot{x}_i \cdot n_i. \quad (5.5)$$

Mediana jest to element środkowy w uporządkowanej próbie (zbiorności) cechy  $X$ . Obliczamy ją ze wzorów

- dla szeregu szczegółowego

$$\text{Me} = \begin{cases} x_{\frac{n+1}{2}} & \text{dla } n \text{ nieparzystego,} \\ \frac{1}{2} (x_{\frac{n}{2}} + x_{\frac{n}{2}+1}) & \text{dla } n \text{ parzystego,} \end{cases} \quad (5.6)$$

- dla szeregu rozdzielczego punktowego, określamy pozycję mediany tak jak dla szeregu szczegółowego i odczytujemy w którym przedziale dana pozycja się znajduje. Wartość tego przedziału przyjmujemy za medianę.
- dla szeregu rozdzielczego przedziałowego, wyznaczamy pozycję mediany ze wzoru  $\frac{n}{2}$  i patrzymy w którym przedziale znajduje się mediana. Następnie wartość mediany liczymy ze wzoru

$$M = x_{0m} + \frac{\frac{1}{2}n - \sum_{i=1}^{m-1} n_i}{n_m} h_m, \quad (5.7)$$

gdzie  $x_{0m}$  - dolna granica przedziału mediany;  $\frac{n}{2}$  - pozycja mediany;  $\sum_{i=1}^{m-1} n_i$  - liczność wszystkich przedziałów poprzedzających przedział mediany (bez liczebności klasy

mediany);  $n_m$  - liczność przedziału mediany;  $h_m$  - długość przedziału mediany;  $m$  - numer przedziału mediany.

*Dominanta.* Oznaczamy ją przez  $D$ . Definiuje się ją dla

- szereg rozdzielczy punktowy - jest to jest to ta cecha, która występuje najczęściej. Jeżeli najczęściej występującą cechą jest  $x_d$ , to  $D = x_d$ .
- szereg rozdzielczy przedziałowy - najpierw wyznaczamy klasę najliczniejszą a następnie dominantę wyliczamy ze wzoru

$$D = x_{0d} + \frac{n_d - n_{d-1}}{(n_d - n_{d-1}) + (n_d - n_{d+1})} h_d, \quad (5.8)$$

gdzie  $x_{0d}$  - dolna granica przedziału dominanty;  $n_d$  - liczebność przedziału dominanty;  $n_{d-1}$  - liczebność przedziału poprzedzającego przedział dominanty;  $n_{d+1}$  - liczebność przedziału następnego po przedziale dominanty;  $h_d$  - rozpiętość przedziału dominanty.

*Kwartyłe.* Definiujemy je jako wartości cechy badanej zbiorowości, przedstawionej w postaci szeregu statystycznego, które dzielą zbiorowość na określone części pod względem liczby jednostek. *Kwartył pierwszy*  $Q_1$  - dzieli zbiorowość na dwie różne części w ten sposób, że 25% jednostek zbiorowości ma wartości cechy niższe bądź równe kwartyłowi pierwszemu  $Q_1$ , 75% równe bądź wyższe od tego kwartyła. *Kwartył drugi* - to jest modalna. *Kwartył trzeci*  $Q_3$  - dzieli zbiorowość na dwie części w ten sposób, że 75% jednostek ma wartości cechy niższe bądź równe  $Q_3$ , a 25% równe bądź wyższe od tego kwartyła.

W przypadku szeregów szczegółowych kwartyłe pierwszy i trzeci wyznacza się analogicznie jak medianę. Można bowiem przyjąć, że zbiorowość podzielimy na dwie części: pierwszą, której jednostki przyjmują wartości mniejsze od mediany oraz drugą w której przyjmują wartości większe od mediany.

W szeregach rozdzielczych wyznaczenie kwartyli poprzedza ustalenie ich pozycji według wzorów

$$N_{Q_1} = \frac{n}{4}, \quad (5.9)$$

$$N_{Q_3} = \frac{3n}{4}. \quad (5.10)$$

Do szeregów rozdzielczych przedziałowych stosujemy wzory

$$Q_1 = x_{0m} + \frac{N_{Q_1} - \sum_{i=1}^{m-1} n_i}{n_m} \cdot h_m, \quad (5.11)$$

$$Q_3 = x_{0m} + \frac{N_{Q_3} - \sum_{i=1}^{m-1} n_i}{n_m} \cdot h_m, \quad (5.12)$$



gdzie  $m$  - numer przedziału (klasy), w którym występuje odpowiadający mu kwartył,  $x_{0m}$  - dolna granica tego przedziału,  $n_m$  - liczność przedziału, w którym występuje odpowiedni kwartył,  $\sum_{i=1}^{m-1} n_i$  - liczność skumulowana przedziału poprzedzającego przedział odpowiedniego kwartyła,  $h_m$  - długość przedziału klasowego, w którym jest odpowiedni kwartył.

**Przykład 5.1.** Dwóch pracowników wykonuje detale tego samego typu. Przeprowadzono obserwację czasu wykonywania pięciu detali przez robotnika pierwszego  $R_1$  oraz sześciu dla pracownika drugiego  $R_2$ . Otrzymano wyniki (w min)

- $R_1$  - 13, 16, 16, 19, 21,
- $R_2$  - 11, 11, 13, 13, 15, 15.

Średnie dla obu robotników

$$\begin{aligned}\bar{x}_{R_1} &= \frac{13 + 16 + 16 + 19 + 21}{5} = 17 \text{ min,} \\ \bar{x}_{R_2} &= \frac{11 + 11 + 13 + 13 + 15 + 15}{6} = 13 \text{ min.}\end{aligned}$$

Dominanty  $D_{R_1} = 16$  min, ponieważ najczęściej występującą wartością jest 16, natomiast w przypadku robotnika drugiego dominanty nie jesteśmy w stanie wyznaczyć.

Mediana w przypadku robotnika pierwszego. Mamy pięć elementów, jest to liczba nieparzysta, więc za wartość mediany przyjmujemy wartość elementu stojącego na miejscu  $\frac{5+1}{2} = 3$ , czyli  $Me_{R_1} = x_3 = 16$  min. Natomiast w przypadku drugim mamy parzystą liczbę elementów, zatem z faktu iż  $\frac{6}{2} = 3$  wynika, że  $Me_{R_2} = \frac{1}{2}(x_{\frac{6}{2}} + x_{\frac{6}{2}+1}) = \frac{1}{2}(x_3 + x_4) = \frac{1}{2}(13 + 13) = 13$  min.

Kwartyły dla pierwszego robotnika. Dzielimy nasze dane na dwie części 13, 16, 16 oraz 16, 19, 21. Stąd otrzymujemy, że  $Q_{1,R_1} = 16$  oraz  $Q_{3,R_1} = 19$ . Natomiast dla drugiego robotnika 11, 11, 13 oraz 13, 15, 15. Stąd otrzymujemy, że  $Q_{1,R_2} = 11$  oraz  $Q_{3,R_2} = 15$ .

### Charakterystyki zróżnicowania (rozproszenia)

Miary zróżnicowania zwane także miarami rozproszenia lub dyspersji pozwalają nam stwierdzić, czy dane są bardzo rozproszone czy też bardziej skoncentrowane, tj. mierzą jak się zachowują wokół miary centralnej (np. średniej).

*Wariancja*

- szereg szczegółowy

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2, \quad (5.13)$$

- szereg rozdzielczy punktowy

$$s^2 = \frac{1}{n} \sum_{i=1}^k (x_i - \bar{x})^2 \cdot n_i, \quad (5.14)$$

- szereg rozdzielczy przedziałowy

$$s^2 = \frac{1}{n} \sum_{i=1}^k (\dot{x}_i - \bar{x})^2 \cdot n_i. \quad (5.15)$$

Odchylenie standardowe

$$s = \sqrt{s^2}. \quad (5.16)$$

Odchylenie ćwiartkowe

$$Q = \frac{Q_3 - Q_1}{2}. \quad (5.17)$$

Współczynnik zmienności

$$V = \frac{s}{|\bar{x}|} 100\%, \quad (5.18)$$

przy założeniu, że  $\bar{x} \neq 0$ .

Rozstęp

$$R = x_{\max} - x_{\min}, \quad (5.19)$$

gdzie  $x_{\max}$  - największa dana statystyczna,  $x_{\min}$  - najmniejsza dana statystyczna.

**Przykład 5.2.** Dla danych z Przykładu 5.1 obliczymy miary rozproszenia. Mamy dla pracownika pierwszego

$$s_{R_1}^2 = \frac{1}{5} \sum_{i=1}^5 (x_i - \bar{x}_{R_1})^2 = \frac{1}{5} [(13 - 17)^2 + (16 - 17)^2 + (16 - 17)^2 + (19 - 17)^2 + (21 - 17)^2] = 7,6,$$

stąd  $s_{R_1} = \sqrt{s_{R_1}^2} = \sqrt{7,6} = 2,76$ . Natomiast dla robotnika drugiego

$$s_{R_2}^2 = \frac{1}{6} \sum_{i=1}^6 (x_i - \bar{x})^2 = 2,7,$$

stąd  $s_{R_2} = 1,63$ .

Współczynnik zmienności

$$V_{s,R_1} = \frac{2,76}{17} 100\% = 16,2\%, \quad V_{s,R_2} = \frac{1,63}{13} 100\% = 12,5\%.$$

Rozstęp  $R_{R_1} = 21 - 13 = 8$ ,  $R_{R_2} = 15 - 11 = 4$ .

Odchylenie ćwiartkowe

$$Q_{R_1} = \frac{19 - 16}{2} = 1,5, \quad Q_{R_2} = \frac{15 - 11}{2} = 2.$$

Zatem możemy stwierdzić, że drugi pracownik wykonuje dany detal szybciej oraz różnice w czasie wykonywania tego detalu dla drugiego pracownika są mniejsze. Chociaż z odchylenia ćwiartkowego wynikałoby by coś odwrotnego.

### Charakterystyki asymetrii

Asymetria mówi nam z której strony wartości centralnej (np. średniej) bardziej skupiają się wartości badanej cechy.

Współczynnik asymetrii obliczamy ze wzoru

$$A = \frac{\mu_3}{(s)^3}, \quad (5.20)$$

gdzie  $s$  - oznacza odchylenie standardowe, a  $\mu_3$  - trzeci moment centralny, który obliczamy ze wzorów

- szeregu szczegółowego

$$\mu_3 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3, \quad (5.21)$$

- szeregu rozdzielczego punktowego

$$\mu_3 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3 \cdot n_i, \quad (5.22)$$

- szeregu rozdzielczego przedziałowego

$$\mu_3 = \frac{1}{n} \sum_{i=1}^n (\hat{x}_i - \bar{x})^3 \cdot n_i. \quad (5.23)$$

Gdy współczynnik asymetrii równa się 0 to mówimy, że rozkład jest symetryczny. Gdy jest ujemny to mówimy o asymetrii lewostronnej, w przeciwnym przypadku o prawostronnej.

**Przykład 5.3.** Policzmy asymetrię dla danych z Przykładu 5.1.

Dla robotnika pierwszego mamy

$$\mu_3 = \frac{1}{5} \sum_{i=1}^5 (x_i - \bar{x})^3 = \frac{1}{5} [(13 - 17)^3 + (16 - 17)^3 + (16 - 17)^3 + (19 - 17)^3 + (21 - 17)^3] = 1,2$$

więc  $A_{R_1} = \frac{1,2}{(2,76)^3} = 0,057$ . Analogicznie dla robotnika drugiego

$$\mu_3 = \frac{1}{6} \sum_{i=1}^6 (x_i - \bar{x})^3 = 0,$$

więc  $A_{R_2} = \frac{0}{(1,63)^3} = 0$ .

**Przykład 5.4.** W grupie 100 studentów przeprowadzono badanie liczby wypalanych dziennie papierosów. Oznaczając przez  $x_i$  liczbę wypalanych dziennie papierosów a przez  $n_i$  liczbę studentów (wypalających taką liczbę papierosów) otrzymano wyniki

$x_i$	0	5	10	15	20	25	30
$n_i$	5	10	20	30	20	10	5

Wyznaczyć średnią, wariancję, odchylenie standardowe, współczynnik zmienności, asymetrię, medianę, dominantę, kwartyle (pierwszy i trzeci), odchylenie ćwiartkowe.

*Rozwiązanie.* Dla wygody obliczenia wykonujemy w tabeli

$i$	$x_i$	$n_i$	$x_i \cdot n_i$	$x_i - \bar{x}$	$(x_i - \bar{x})^2 \cdot n_i$	$(x_i - \bar{x})^3 \cdot n_i$	$n_i^{sk}$	
1	0	5	0	-15	1125	-16875	5	
2	5	10	50	-10	1000	-10000	15	
3	10	20	200	-5	500	-2500	35	$Q_1$
4	15	30	450	0	0	0	65	$Me$
5	20	20	400	5	500	2500	85	$Q_3$
6	25	10	250	10	1000	10000	95	
7	30	5	150	15	1125	16875	100	
$\Sigma$	$\times$	100	1500	$\times$	5250	0	$\times$	

Zatem otrzymujemy

$$\begin{aligned}\bar{x} &= \frac{1}{100} \sum_{i=1}^7 x_i \cdot n_i = \frac{1}{100} 1500 = 15(\text{sztuk}), \\ s^2 &= \frac{1}{100} \sum_{i=1}^7 (x_i - \bar{x})^2 \cdot n_i = \frac{1}{100} 5250 = 52,5, \\ s &= \sqrt{52,5} \approx 7,2, \\ \mu_3 &= \frac{1}{100} \sum_{i=1}^7 (x_i - \bar{x})^3 \cdot n_i = \frac{1}{100} 0 = 0, \\ A &= \frac{0}{(7,2)^3} = 0, \\ V_s &= \frac{7,2}{15} 100\% = 48\%.\end{aligned}$$

Widzimy stąd, że średnia ilość wypalanych papierosów w tej grupie studentów wynosi 15 sztuk, z odchyleniem standardowym na plus lub minus 7,2 sztuki. Co więcej wiemy, że rozkład jest symetryczny. Współczynnik zmienności wynosi 48%, czyli jest duże zróżnicowanie w tej grupie pod względem wypalanych papierosów. Teraz przejdziemy do wyznaczenia pozostałych charakterystyk. Dominanta jest najprostsza do wyznaczenia, wynosi

$$D = 15,$$

ponieważ największa liczba studentów (30) wypala taką ilość papierosów. Mamy 100 wyników,  $\frac{100}{2} = 50$ , więc szukamy do której klasy wpada 50 element. Korzystając z liczności skumulowanych widzimy, że dla klasy czwartej ( $i = 4$ ). Zatem

$$Me = 15,$$

Liczmy miejsce kwartyli  $N_{Q_1} = \frac{100}{4} = 25$ ,  $N_{Q_3} = \frac{3 \cdot 100}{4} = 75$ . Szukamy do których klas należą elementy o tych numerach. Są to odpowiednio klasy trzecia i piąta. Stąd

$$Q_1 = 10, \quad Q_3 = 20.$$

Zatem

$$Q = \frac{20 - 10}{2} = 5.$$

□

**Przykład 5.5.** Analizując liczbę wyprodukowanych elementów pewnej brygady otrzymano wyniki, które zanotowano w poniższej tabeli, gdzie  $x_i$  - liczbę detali,  $n_i$  - ilość pracowników wyrabiających daną ilość elementów

$x_i$	12 - 14	14 - 16	16 - 18	18 - 20
$n_i$	6	7	11	6

Wyznaczyć średnią, wariancję, odchylenie standardowe, współczynnik zmienności, asymetrię, medianę, dominantę, kwartyle (pierwszy i trzeci), odchylnie ćwiatkowe.

*Rozwiązanie.* Tak jak w zadaniu poprzednim wygodnie będzie wykonywać rachunki w tabeli

$i$	$x_i$	$n_i$	$\dot{x}_i$	$\dot{x}_i \cdot n_i$	$\dot{x}_i - \bar{x}$	$(\dot{x}_i - \bar{x})^2 \cdot n_i$	$(\dot{x}_i - \bar{x})^3 \cdot n_i$	$n_i^{sk}$	
1	12 - 14	6	13	78	-3,1	57,66	-178,75	6	
2	14 - 16	7	15	105	-1,1	8,47	-9,32	13	$Q_1$
3	16 - 18	11	17	187	0,9	8,91	8,02	24	$Me, D, Q_3$
4	18 - 20	6	19	114	2,9	50,46	146,33	30	
$\Sigma$	$\times$	30	$\times$	484	$\times$	125,5	-33,72	$\times$	

Zatem

$$\bar{x} = \frac{1}{30} \sum_{i=1}^4 \dot{x}_i \cdot n_i = \frac{1}{30} 484 \approx 16,1,$$

$$s^2 = \frac{1}{30} \sum_{i=1}^4 (\dot{x}_i - \bar{x})^2 \cdot n_i = \frac{1}{30} 125,5 \approx 4,2,$$

$$s = \sqrt{4,2} \approx 2,$$

$$\mu_3 = \frac{1}{30} \sum_{i=1}^4 (\dot{x}_i - \bar{x})^3 \cdot n_i = \frac{1}{30} (-33,72) \approx -1,1,$$

$$A = \frac{-1,1}{2^3} = -0,14,$$

$$V_s = \frac{2,0}{16,1} 100\% = 12,4\%.$$

Otrzymujemy stąd, że średnio robotnik wykonuje 16,1 sztuki elementu, z odchyleniem standardowym plus, minus 2 elementy, przy dosyć małym zróżnicowaniu (12,4%) oraz niewielkim większym skupieniu poniżej średniej. Pozostałe charakterystyki. Miejsce mediany, to  $\frac{30}{2} = 15$ . Jest to klasa 3, zatem korzystając ze wzoru (5.7) otrzymujemy

$$Me = 16 + \frac{\frac{1}{2}30 - (6 + 7)}{11} \cdot 2 = 16 + 0,4 = 16,4.$$

Przedziałem dominanty jest w tym przypadku ten sam przedział, co przedział mediany, zatem

$$D = 16 + \frac{11 - 7}{(11 - 7) + (11 - 6)} \cdot 2 = 16 + 0,9 = 16,9.$$

Miejsce kwartyli  $N_{Q_1} = \frac{30}{4} \approx 8$ ,  $N_{Q_3} = \frac{3 \cdot 30}{4} \approx 23$ . Zatem

$$\begin{aligned} Q_1 &= 14 + \frac{8 - 6}{7} \cdot 2 = 14,6, \\ Q_3 &= 16 + \frac{23 - 13}{11} \cdot 2 = 17,8. \end{aligned}$$

Stąd też

$$Q = \frac{17,8 - 14,6}{2} = 1,6.$$

□

Wszystkie charakterystyki możemy podzielić na miary klasyczne - to te przy wyliczaniu wykorzystujemy wartości wszystkich elementów w próbie oraz miary pozycyjne - to te gdzie wyznaczamy miejsce (pozycję) elementów w uporządkowanej próbie. Pojawia się naturalne pytanie dlaczego nie ograniczyć się do jednego typów miar? Wykorzystanie jednych czy drugich zależy od kontekstu zadania oraz postaci samych danych. Czasami w próbie pojawia się wartość, która wyraźnie odstaje (jest dużo mniejsza lub dużo większa od naszych danych). Przy liczeniu średniej arytmetycznej zostanie jej wartość uwzględniona przy liczeniu i może w znaczny sposób zawyżyć lub zaniżyć liczoną daną, natomiast przy miarach pozycyjnych nie zostanie to uwzględnione. Z drugiej strony nasze dane mogą być danymi wziętymi np. z Rocznika Statystycznego i dotyczyć dochodów gospodarstw rolnych w zależności od powierzchni. Na ogół w takich tabelach klasy skrajne są podawane jako: poniżej 1ha, powyżej 50ha. I przy liczeniu miar klasycznych mamy problem jakiego wybrać reprezentanta dla tych klas (tj. jakie wybrać  $x_i$ ). Zatem użycie konkretnej miary zależy od konkretnego zagadnienia którym się zajmujemy. W podręczniku zostały policzone zarówno jedne jak i drugie mimo, że w konkretnych zadaniach powinno korzystać z albo z jednych miar albo z drugich.

### 5.3 Zadania do samodzielnego rozwiązania

**5.1.** W fabryce w ciągu pięciu dni roboczych wyprodukowano pięć wyrobów o wadze: 12, 14, 16, 18, 20. Obliczyć średnią i odchylenie standardowe.

**5.2.** W pewnej szkole badano wzrost dziewcząt klas czwartych. Otrzymano wyniki: 140, 148, 148, 148, 150, 150, 156, 156, 160, 160, 160, 160, 162, 163, 164, 166, 168, 169, 170, 175, 175, 180. Obliczyć: medianę, dominantę, kwartyle pierwszy i drugi oraz odchylenie ćwiartkowe.

**5.3.** Oceny studentów z przedmiotu statystyka przedstawia tabela

Ocena	3	3,5	4	4,5	5
Liczba studentów	25	30	10	15	20

Obliczyć: średnią, odchylenie standardowe, współczynnik zmienności, asymetrię.

**5.4.** Poniższa tabela przedstawia dane dotyczące wydajności pracy (w szt/h) pewnego wydziału zakładu produkcyjnego. Wyznaczyć medianę, dominantę, kwartyle pierwszy i trzeci oraz odchylenie ćwiartkowe.

Wydajność	40	50	60	30	25	20
ilość pracowników	15	10	30	10	15	10

**5.5.** Dla poniższego szeregu rozdzielczego przedziałowego, przedstawiającego staż pracy pracowników pewnego przedsiębiorstwa, obliczyć: średnią, wariancję, odchylenie standardowe, współczynnik zmienności, asymetrię.

przedział	1 – 5	5 – 10	10 – 15	15 – 20	20 – 25	25 – 30	30 – 35
ilość elementów	10	20	25	30	35	10	20

**5.6.** Dla poniższego szeregu rozdzielczego przedziałowego obliczyć: medianę, dominantę, kwartyl pierwszy i drugi oraz odchylenie ćwiartkowe.

0 – 4	4 – 8	8 – 12	12 – 16	16 – 20	20 – 24	24 – 28
10	20	30	40	10	5	10





## Wykład 6

# Elementy statystyki matematycznej

W tym wykładzie omówione są podstawy estymacji oraz testowania hipotez statystycznych.

## 6.1 Pewne rozkłady stosowane w statystyce

*Rozkład chi-kwadrat* ( $\chi^2$ ). Jeżeli zmienne losowe  $X_1, X_2, \dots, X_k$  są niezależnymi zmiennymi losowymi o rozkładzie normalnym  $N(0, 1)$ , to zmienną losową  $\chi^2$  określamy następująco

$$\chi^2 = \sum_{i=1}^k X_i^2,$$

i mówimy, że ma rozkład  $\chi^2$  o  $k$  „stopniach swobody”. Zmienna losowa o rozkładzie chi-kwadrat przyjmuje wartości dodatnie, a jej rozkład zależy od liczby stopni swobody  $k$ . Dla małych wartości  $k$  jest to rozkład silnie asymetryczny, natomiast w miarę wzrostu  $k$  asymetria jest mniejsza.  $k$  wyznaczamy najczęściej jako  $k = n - 1$ , gdzie  $n$  jest liczebnością próby. Parametry tego rozkładu, to

$$E(\chi^2) = k, \quad \sigma(\chi^2) = \sqrt{2k}.$$

Piszemy wtedy  $\chi^2 \sim \chi^2(k, \sqrt{2k})$ .

Jeżeli  $k$  wzrasta, to rozkład chi-kwadrat zbliża się do rozkładu normalnego o tych samych parametrach. Przyjmuje się, że przy  $k = 30$  przybliżenie wartości rozkładu chi-kwadrat wartościami rozkładu normalnego jest wystarczająco dokładne.

*Rozkład t-Studenta*. Jeżeli zmienna losowa  $Z$  ma rozkład  $N(0, 1)$  i  $\chi^2$  ma rozkład  $\chi^2 \sim \chi^2(k, \sqrt{2k})$ , oraz powyższe zmienne losowe są niezależne, to mówimy, że zmienna  $T = \frac{Z}{\chi^2} \sqrt{k}$  ma rozkład t-Studenta o  $k$  stopniach swobody. Parametry rozkładu t-Studenta

$$E(T) = 0, \text{ dla } k \geq 2, \quad \sigma(T) = \sqrt{\frac{k}{k-2}}, \text{ dla } k \geq 3.$$

Dla  $k > 30$  zmienna o rozkładzie t-Studenta ma rozkład zbliżony do rozkładu normalnego standaryzowanego  $N(0, 1)$ .

## 6.2 Estymacja

Mając do dyspozycji jedynie próbkę pobraną z całej populacji losową możemy oszacować wartość interesujących nas parametrów na podstawie tej próbki. Takie szacowanie na podstawie próbki nazywa się *estymacją*.

Wskaźniki, które możemy obliczyć z próby, będziemy nazywali statystykami, a odpowiadające im wskaźniki dotyczące populacji parametrami populacji.

Dobry estymator powinien posiadać trzy podstawowe cechy:

- Powinien być *nieobciążony*, co oznacza, że powinien być wolny od błędów systematycznych. Błędy systematyczne to takie, które są popełniane „stałe”, np. robiąc pomiary zawsze zawyżamy lub zaniżamy wartość parametru.
- Powinien być *efektywny*, tzn. minimalizuje błąd oszacowania. Inaczej mówiąc powinien mieć jak najmniejszą wariancję.
- Powinien być *zgodny*, tzn. wraz ze wzrostem liczebności próbki zwiększa się prawdopodobieństwo, że jego wartość zbliża się do wartości szacowanego parametru.

Wyróżniamy dwa sposoby szacowania nieznanego parametru: estymacja punktowa i estymacja przedziałowa.

*Estymacja punktowa* polega na wybraniu statystyki na podstawie której będziemy szacowali wartość interesującego nas parametru. Istnieją różne metody wyznaczania estymatorów. My ograniczymy się do padania kilku gotowych estymatorów.

- Estymacja wartości oczekiwanej dla rozkładu normalnego. Jeżeli cecha  $X$  z populacji ma rozkład normalny  $N(\mu, \sigma)$ , przy czym znane jest  $\sigma$ . Wtedy estymatorem wartości oczekiwanej jest średnia z próby. Jest to estymator nieobciążony, efektywny i zgodny.
- Estymacja wariancji dla rozkładu normalnego. Jeżeli cecha  $X$  z populacji ma rozkład normalny  $N(\mu, \sigma)$ , przy czym znane jest  $\mu$ , to wtedy za estymator wariancji możemy przyjąć  $s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$ , który jest estymatorem nieobciążonym, zgodnym i efektywnym. Jeżeli  $\mu$  jest nieznanne, to za estymator przyjmujemy  $s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ , który jest estymatorem efektywnym, zgodnym i nieobciążonym. Zwykła wariancja z próby, którą rozważaliśmy w poprzednim rozdziale, jest estymatorem obciążonym.

*Estymacja przedziałowa* polega na szacowaniu wartości nieznanego parametru za pomocą tzw. przedziału ufności.

*Przedziałem ufności* nazywamy taki przedział, który z zadaniem z góry prawdopodobieństwem  $(1 - \alpha)$ , zwanym poziomem ufności (lub współczynnikiem ufności), pokrywa nieznaną wartość szacowanego parametru. Interpretacja poziomu ufności: przy wielokrotnym pobieraniu prób  $n$ -elementowych i wyznaczaniu na ich podstawie granic przedziałów ufności, średnio w  $(1 - \alpha) \cdot 100\%$  przypadków otrzymujemy przedziały pokrywające nieznaną wartość. Sposób konstrukcji przedziału ufności związany jest z rozkładem odpowiedniego estymatora. Teraz podamy przedziały ufności dla podstawowych parametrów rozkładu cechy w zbiorowości generalnej.

Przedział ufności dla przeciętne  $\mu$ . Zakładając, że cecha  $X$  w zbiorowości generalnej ma rozkład  $N(\mu, \sigma)$  oraz znane jest  $\sigma$  lub  $n > 30$ . Wtedy przedział ufności dla parametru  $\mu$  (wartości oczekiwanej) ma postać

$$\bar{x} - t_\alpha \frac{\sigma}{\sqrt{n}} < \mu < \bar{x} + t_\alpha \frac{\sigma}{\sqrt{n}}, \quad (6.1)$$

gdzie  $t_\alpha$  odczytuje się z tablic rozkładu normalnego, korzystając z relacji

$$\Phi(t_\alpha) = 1 - \frac{\alpha}{2}.$$

Jeżeli natomiast  $n < 30$  i  $\sigma$  jest nieznane, to wtedy przedział przyjmuje postać

$$\bar{x} - t_{\alpha, n-1} \frac{s}{\sqrt{n-1}} < \mu < \bar{x} + t_{\alpha, n-1} \frac{s}{\sqrt{n-1}}, \quad (6.2)$$

gdzie  $t_{\alpha, n-1}$  odczytuje się z tablic rozkładu Studenta dla  $n - 1$  stopni swobody.

**Przykład 6.1.** Zakładając, że roczne wydatki na paliwo można uznać za cechę o rozkładzie  $N(\mu, \sigma)$ , pobrano próbę losową liczącą 100 małych zakładów. Uzyskano  $\bar{x} = 12$  oraz  $s = 4,72$  (w tys. zł). Wyznaczyć przedział ufności dla wartości oczekiwanej na poziomie ufności  $1 - \alpha = 0,96$ .

*Rozwiązanie.* Ponieważ  $n > 100$  oraz  $\sigma$  jest nieznane, więc korzystamy z przedziału postaci (6.1). Otrzymujemy

$$12 - t_\alpha \frac{4,72}{\sqrt{100}} < \mu < 12 + t_\alpha \frac{4,72}{\sqrt{100}},$$

gdzie  $\Phi(t_\alpha) = 1 - \frac{0,04}{2} = 0,98$ . Z tablic rozkładu normalnego otrzymujemy  $t_\alpha = 2,05$ . Zatem

$$\mu \in (11,2; 12,8).$$

□

**Przykład 6.2.** Poddano analizie wydatki na odzież w wiejskich rodzinach 5-osobowych. Z populacji tych rodzin wylosowano próbę 289-elementów. Na podstawie przeprowadzonych obserwacji ustalono przeciętną skalę wydatków na odzież  $\bar{x} = 100$  zł. Badania z lat ubiegłych wykazały, że rozkład wydatków na odzież jest rozkładem normalnym o stałej wariancji  $\sigma^2 = 576$ . Wyznaczyć przedział ufności średnich miesięcznych wydatków na odzież w wiejskich rodzinach 5-osobowych przyjmując poziom ufności  $1 - \alpha = 0,98$ .

*Rozwiązanie.* Korzystając ze wzoru (6.1) dla  $\Phi(t_\alpha) = 0,99$ ,  $t_\alpha = 2,35$ . Zatem  $96,682 < \mu < 103,318$ . W rodzinach 5-osobowych miesięczne wydatki na odzież zawierają się w przedziale  $\mu \in (96,68\text{zł}; 103,32\text{zł})$ . □

## 6.3 Testowanie hipotez statystycznych

*Hipotezę statystyczną* nazywamy każdy sąd o całej populacji, wydany bez przeprowadzenia badania całej populacji. Prawdziwość przypuszczenia (hipotezy) sprawdza się na podstawie próby losowej.

*Hipoteza  $H_0$* . Jest to hipoteza, której prawdziwość sprawdzamy.

*Hipoteza  $H_1$* . Jest to hipoteza, którą jesteśmy skłonni przyjąć w przypadku odrzucenia hipotezy  $H_0$ .

*Test statystyczny*. Są to reguły postępowania na podstawie których przyjmujemy lub odrzucamy hipotezę  $H_0$ .

Przy testowaniu hipotez statystycznych możemy popełnić dwa błędy. Odrzucić hipotezę  $H_0$  pomimo, że jest ona prawdziwa. Błąd tego rodzaju nazywamy *błędem I rodzaju*. Lub też możemy przyjąć hipotezę mimo, że jest ona fałszywa. Błąd tego rodzaju nazywamy *błędem II rodzaju*.

*Poziom istotności*. Oznaczmy przez  $\alpha$  i jest to prawdopodobieństwo popełnienia błędu I rodzaju.

Prawdopodobieństwo popełnienia błędu drugiego rodzaju oznaczamy przez  $\beta$ . Dobry test statystyczny powinien charakteryzować się tym, że  $\beta$  powinno być bliskie zeru.

Sprawdzianem hipotezy nazywamy taką statystykę, której wartość obliczona na podstawie pobranej próby losowej, pozwalana na podjęcie decyzji o odrzuceniu (lub nie) hipotezy  $H_0$ . Zbiorem krytycznym nazywamy zbiór tych wartości sprawdzianu hipotezy, które przemawiają za odrzuceniem hipotezy  $H_0$ .

*Zbiór krytyczny* jest to zbiór tych wartości sprawdzianu hipotezy, które przemawiają za odrzuceniem hipotezy  $H_0$ .

### Testy dla wartości oczekiwanej dla jednej próby

Rozważamy hipotezę zerową:

$$H_0 : \mu = \mu_0 \quad (6.3)$$

wobec jednej z trzech hipotez alternatywnych:

$$H_1 : \mu \neq \mu_0 \quad (6.4)$$

$$H'_1 : \mu < \mu_0 \quad (6.5)$$

$$H''_1 : \mu > \mu_0 \quad (6.6)$$

Model 1 Zakładamy, że badana cecha  $x$  ma rozkład normalny  $N(\mu, \sigma)$  o znanym odchyleniu standardowym  $\sigma$ . Statystyka testowa:

$$T = \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n} \quad (6.7)$$

która przy założeniu prawdziwości hipotezy  $H_0$  ma rozkład normalny  $N(0, 1)$ , w związku z czym obszar krytyczny – w zależności od przyjętej hipotezy alternatywnej ( $H_1$ ,  $H'_1$  albo

$H_1''$ ) – ma postać:

$$W_\alpha = \left(-\infty, -t_{1-\frac{\alpha}{2}}\right) \cup \left(t_{1-\frac{\alpha}{2}}, \infty\right) \quad (6.8)$$

$$W'_\alpha = (-\infty, -t_{1\alpha}) \quad (6.9)$$

$$W''_\alpha = (t_{1-\alpha}, \infty) \quad (6.10)$$

gdzie  $t_{1-\frac{\alpha}{2}}$  i  $t_{1-\alpha}$  są kwantylami rozkładu normalnego  $N(0, 1)$  rzędów  $1 - \frac{\alpha}{2}$  i  $1 - \alpha$ .

*Model 2* Jeżeli cecha  $x$  ma rozkład normalny  $N(\mu, \sigma)$  o nieznanym odchyleniu standardowym  $\sigma$ , to weryfikacja hipotezy  $H_0$  dokonujemy za pomocą statystyki testowej

$$T = \frac{\bar{x} - \mu_0}{s} \sqrt{n} \quad (6.11)$$

która ma rozkład t-Studenta o  $n - 1$  stopniach swobody (przy założeniu prawdziwości hipotezy  $H_0$ ). W zależności od przyjętej hipotezy alternatywnej obszar krytyczny przybiera postać:

$$W_\alpha = \left(-\infty, -t_{n-1; 1-\frac{\alpha}{2}}\right) \cup \left(t_{n-1; 1-\frac{\alpha}{2}}, \infty\right) \quad (6.12)$$

$$W'_\alpha = (-\infty, -t_{n-1; 1\alpha}) \quad (6.13)$$

$$W''_\alpha = (t_{n-1; 1-\alpha}, \infty) \quad (6.14)$$

gdzie  $t_{n-1; 1-\frac{\alpha}{2}}$  oraz  $t_{n-1; 1-\alpha}$  są kwantylami rozkładu t-Studenta o  $n - 1$  stopniach swobody.

*Model 3* Jeżeli próba pochodzi z dowolnego rozkładu (posiadającego jednakże skończoną wariancję), ale jest wystarczająco duża ( $n \geq 100$ ), wówczas statystyka testowa przyjmuje postać:

$$T = \frac{\bar{x} - \mu_0}{s} \sqrt{n} \quad (6.15)$$

Przy założeniu prawdziwości hipotezy  $H_0$  i dla dostatecznie dużej próby statystyka powyższa ma rozkład (w przybliżeniu) normalny  $N(0, 1)$ , w związku z czym obszar krytyczny w zależności od hipotezy alternatywnej ma postać:

$$W_\alpha = \left(-\infty, -t_{1-\frac{\alpha}{2}}\right) \cup \left(t_{1-\frac{\alpha}{2}}, \infty\right) \quad (6.16)$$

$$W'_\alpha = (-\infty, -t_{1\alpha}) \quad (6.17)$$

$$W''_\alpha = (t_{1-\alpha}, \infty) \quad (6.18)$$

**Przykład 6.3.** Załóżmy, że długość „życia opon” samochodowych ma rozkład normalny  $N(\mu, \sigma)$ . Producent twierdzi, że wartość przeciętna tej charakterystyki jest równa 50 tys. km. Na podstawie 100 losowo wybranych opon otrzymano  $\bar{x} = 45$  tys. km oraz  $s = 8$  tys. km. Czy na poziomie istotności  $\alpha = 0,05$  można uważać, że producent ma rację?

*Rozwiązanie.* Będziemy korzystali z modelu trzeciego. Mamy


$$H_0 : \mu = 50,$$

$$H_1 : \mu \neq 50.$$

Obliczamy teraz wartość statystyki testowej

$$T = \frac{\bar{x} - \mu_0}{s} \sqrt{n} = \frac{45 - 50}{8} \sqrt{100} = -6,25.$$

Teraz  $t_\alpha$ . Mamy  $\Phi(t_\alpha) = 1 - \frac{0,05}{2} = 0,975$ , stąd  $t_\alpha = 1,95$ . Zatem wartość statystyki testowej wpada do zbioru krytycznego, czyli należy odrzucić hipotezę  $H_0$  na rzecz hipotezy alternatywnej  $H_1$ . Innymi słowy producent nie ma racji twierząc, że przeciętna długość życia opon wynosi 50 tys. km. Na poniższym obrazku na szaro został zaznaczony zbiór krytyczny.



Rysunek 6.1: Interpretacja zbioru krytycznego z Przykładu 6.3

□

**Przykład 6.4.** W pewnym rejonie morza dokonano 5 niezależnych pomiarów głębokości morza. Otrzymano średnią głębokość morza  $\bar{x} = 770\text{m}$  oraz odchylenie standardowe  $s = 6,2$ . Na poziomie istotności  $\alpha = 0,02$  zweryfikować hipotezę, że średnia głębokość morza w tym rejonie wynosi  $\mu = 775\text{m}$ , przyjmując że rozkład pomiarów głębokości w tym rejonie morza ma rozkład normalny.

*Rozwiązanie.* Korzystamy z modelu drugiego. Testujemy hipotezę

$$H_0 : \mu = 775\text{m}$$

$$H_1 : \mu \neq 775\text{m}$$

Statystyka testowa przyjmuje wartość

$$T = \frac{770 - 775}{6,2} \sqrt{4} = -1,6.$$

Wartość  $t_{4;0,02} = 3,747$  odczytujemy z tablic kwantyli rozkładu t-Studenta. Widzimy stąd, że wartość statystyki testowej nie należy do zbioru krytycznego, zatem nie ma podstaw do odrzucenia hipotezy zerowej. □

## 6.4 Zadania do samodzielnego rozwiązania

**6.1.** Poddano analizie wydatki na opłaty za telefon TP S.A w 100 gospodarstwach domowych w pewnym miesiącu. Na podstawie przeprowadzonych obserwacji ustalono średnią miesięczną opłatę za telefon  $\bar{x} = 95$  zł i odchylenie standardowe  $\sigma = 15$  zł. Zakładamy że wydatki mają rozkład normalny. Na poziomie ufności  $1 - \alpha = 0,98$  wyznaczyć przedział ufności dla wartości przeciętnej miesięcznych opłat za telefon.

Odp  $91,55 < \mu < 98,45$ .

**6.2.** W zakładzie „Alfa” zbadano staż pracowników fizycznych. Z populacji tych pracowników wylosowano próbę 169-elementową, z której obliczono  $\bar{x} = 7,2$  lat. Rozkład stażu pracowników fizycznych jest rozkładem normalnym z odchyleniem standardowym  $\sigma = 3,2$  lat. Przyjmując współczynnik ufności zbudować przedział ufności dla nieznanego średniego stażu pracy w populacji pracowników fizycznych w tym zakładzie.

Odp.  $6,634 < \mu < 7,766$ .

**6.3.** Cecha  $X$  ma rozkład  $N(\mu, \sigma)$ , gdzie  $\mu, \sigma$  są nieznanymi. Na podstawie próby 17 elementowej obliczono  $\bar{x} = 60, s = 0,5$ . Zweryfikować hipotezę  $H_0 : \mu = 61,5$ , wobec hipotezy alternatywnej  $H_1 : \mu \neq 61,5$  na poziomie istotności  $\alpha = 0,05$ .

Odp. Odrzucamy  $H_0$ .

**6.4.** Z dużej partii słupów betonowych wybrano próbkę losową 64 słupów. Rednia wytrzymałość na ściskanie w tej próbce wynosiła  $\bar{x} = 245$  kG/cm<sup>2</sup>. Odchylenie standardowe  $s = 5$  kG/cm<sup>2</sup>. Zweryfikować hipotezę  $H_0 : \mu = 240$  kG/cm<sup>2</sup>, wobec hipotezy alternatywnej  $H_1 : \mu \neq 240$  kG/cm<sup>2</sup>, na poziomie istotności  $\alpha = 0,01$ , przy założeniu, że wytrzymałość na ściskanie jest zmienną losową o rozkładzie normalnym.

Odp. Odrzucamy  $H_0$ .

**6.5.** W pewnym zakładzie wybrano losowo 10 pracowników. Otrzymano średni wiek  $\bar{x} = 32$  lata oraz odchylenie standardowe  $s = 4$  lata. Zakładając, że wiek pracowników ma rozkład normalny zweryfikować hipotezę, na poziomie istotności  $\alpha = 0,05$ , że średni wiek pracowników jest istotnie wyższy niż 30 lat. ( $Wsk.H_0 : \mu = 30, H_1 : \mu > 30$ ). Odp. Nie ma podstaw do odrzucenia  $H_0$ .

tzn. nie możemy twierdzić, że średni wiek w przedsiębiorstwie jest istotnie większy od 30 lat.



## Wykład 7

# Wybrane zagadnienia procesów stochastycznych

W tym wykładzie omówione jest pojęcie procesu stochastycznego.

## 7.1 Podstawowe definicje

**Definicja 7.1.** Niech  $T \subset \mathbb{R}$ . Rodzinę zmiennych losowych  $\{X_t : t \in T\}$  określonych na tej samej przestrzeni probabilistycznej nazywamy *procesem stochastycznym*.

W przypadku  $T = \mathbb{Z}$  albo  $T = \mathbb{Z}$  mówimy o *procesie z czasem dyskretnym* albo też o *szeregu czasowym*. Jeżeli natomiast  $T = \langle a, b \rangle$ , gdzie  $-\infty \leq a < b \leq \infty$ , to mówimy o procesie z czasem ciągłym.

Proces stochastyczny  $\{X_t : t \in T\}$  możemy rozumieć jako funkcję dwóch zmiennych  $\omega, t$ . Dla ustalonego  $t$ ,  $X_t(\cdot)$  jest zmienną losową. Natomiast dla ustalonego  $\omega \in \Omega$ ,  $X_{(\cdot)} = X_{(\cdot)}(\omega)$  jest rzeczywistą funkcją zmiennej  $t$ . Tę funkcję nazywamy *trajektorią procesu*  $\{X_t : t \in T\}$ .

Dla każdego skończonego zbioru  $\{t_1, \dots, t_n\} \subset T$  określamy układ zmiennych losowych  $X_{t_1}, \dots, X_{t_n}$ , które mają mają rozkład zadany przez skończenie wymiarowe dystrybuanty

$$F_{t_1, \dots, t_n}(x_1, \dots, x_n) = P(X_{t_1} \leq x_1, \dots, X_{t_n} \leq x_n). \quad (7.1)$$

**Definicja 7.2.** Niech  $\{X_t : t \in T\}$  będzie procesem stochastycznym takim, że dla każdego  $t \in T$  istnieje wartość oczekiwana  $E(X_t)$ . Wtedy funkcję  $m_X(t) = E(X_t)$  określoną na zbiorze  $T$  nazywamy *wartością oczekiwaną* procesu stochastycznego  $\{X_t\}$ . Jeżeli ponadto  $E(|X_t|^2) < \infty$  dla wszystkich  $t \in T$ , to wtedy funkcję dwóch zmiennych określoną na zbiorze  $T \times T$  wzorem  $K(s, t) = E[(X_s - m_X(s))(X_t - m_X(t))]$  nazywamy *funkcją korelacyjną* procesu stochastycznego.

**Definicja 7.3.** Mówimy, że proces stochastyczny  $\{X_t : t \in T\}$  jest *ściśle stacjonarny*, jeżeli dla dowolnego  $n \in \mathbb{N}$ , dla dowolnych liczb rzeczywistych  $x_1, \dots, x_n$  i dowolnych  $t_1, \dots, t_n$  oraz  $h$  takich, że  $t_i \in T, t_i + h \in T, i = 1, 2, \dots, n$  jest

$$F_{t_1, \dots, t_n}(x_1, \dots, x_n) = F_{t_1+h, \dots, t_n+h}(x_1, \dots, x_n). \quad (7.2)$$

Wprost z definicji procesu stochastycznego wynika, że wszystkie zmienne losowe mają takie same rozkłady oraz, że wartość oczekiwana procesu i funkcja kowariancyjna procesu nie zmieniają się przy przesunięciach.

**Przykład 7.4** (Biały szum). Biały szum jest to proces  $\{X_t : t \in \mathbb{Z}\}$  nieskorelowanych zmiennych losowych o zerowej wartości oczekiwanej i stałą skończoną funkcją kowariancyjną. Nazwa procesu pochodzi wywodzi się z jego podobieństwa do własności fizycznych białego światła.

**Przykład 7.5.** Niech  $Y_1, Y_2, Y_3$  będą zmiennymi losowymi. Utwórzmy proces

$$X_t = Y_1 + Y_2 t + \frac{1}{2} Y_3 t^2, \quad t \geq 0.$$

Proces  $X_t$  może być użyty do opisu położenia punktu materialnego poruszającego się ruchem jednostajnie przyspieszonym z przyspieszeniem  $Y_3$ , jeżeli w chwili początkowej  $t = 0$  punkt ma położenie  $Y_1$  i prędkość  $Y_2$ .

Rozważmy ciąg zmiennych losowych  $\{X_n : n \in \mathbb{N}\}$ , które przyjmują tylko wartości całkowitoliczbowe. Niech  $S$  będzie zbiorem liczb całkowitych  $i$  takich, że  $i \in S$  wtedy i tylko wtedy, gdy istnieje  $n \in \mathbb{N}$  takie, że  $P(X_n = i) > 0$ . Zbiór  $S$  może być skończony lub przeliczalny (tzn. równoliczny ze zbiorem liczb naturalnych). Będziemy go nazywać *zbiorem stanów* procesu stochastycznego  $\{X_n : n \in \mathbb{N}\}$  a jego punkty będziemy nazywali *stanami*. Bez straty ogólności zakładamy, że  $S = \{0, 1, \dots, N\}$  albo też  $S = \{1, 2, \dots\}$ .

**Definicja 7.6.** Ciąg całkowitoliczbowych zmiennych losowych  $\{X_n : n \in \mathbb{N}\}$  nazywamy *łańcuchem Markowa* z czasem dyskretnym i zbiorem stanów  $S$ , jeżeli

$$P(X_{n+1} = j | X_n = i, X_{n-1} = i_{n-1}, \dots, X_0 = i_0) = P(X_{n+1} = j | X_n = i) \quad (7.3)$$

dla wszystkich  $n = 0, 1, 2, \dots$  i wszystkich  $i, j, i_{n-1}, \dots, i_0 \in S$  takich, że  $P(X_n = i, X_{n-1} = i_{n-1}, \dots, X_0 = i_0) > 0$ .

Warunek (7.3) nazywany *warunkiem Markowa* oznacza, że prawdopodobieństwo znalezienia się procesu w czasie  $n+1$  w stanie  $j$  zależy jedynie od tego w jakim stanie znajdował się proces w czasie  $n$ .

Prawdopodobieństwa warunkowe

$$P(X_{n+1} = j | X_n = i) = p_{ij}(n, n+1) \quad (7.4)$$

(jeżeli są określone) nazywamy *prawdopodobieństwami przejścia* ze stanu  $i$  w czasie  $n$  do stanu  $j$  w czasie  $n+1$ , czasami też *prawdopodobieństwami przejścia pierwszego rzędu*. Analogicznie prawdopodobieństwa warunkowe

$$P(X_{n+m} = j | X_n = i) = p_{ij}(n, n+m) \quad (7.5)$$

dla naturalnego  $m \geq 1$  nazywamy *prawdopodobieństwami przejścia* ze stanu  $i$  w czasie  $n$  do stanu  $j$  w czasie  $n+m$ , lub też *prawdopodobieństwami przejścia  $m$ -tego rzędu*. Jeżeli prawdopodobieństwa przejścia  $p_{ij}(n, n+m)$  niezależą od czasów  $n$  i  $n+m$ , ale tylko do ich odległości  $m$ , to mówimy, że proces Markowa jest *jednorodny*.

Rozważmy jednorodny łańcuch Markowa  $\{X_n\}$ . Prawdopodobieństwa przejścia pierwszego rzędu  $P(X_{n+1} = j | X_n = i)$  są w tym przypadku niezależne od  $n$ , będziemy je oznaczać  $p_{ij}$ . Ponieważ dla każdego  $i \in S$  istnieje  $n \in \mathbb{N}$  takie, że  $P(X_n = i) > 0$ , więc prawdopodobieństw warunkowe  $P(X_{n+1} = j | X_n = i) = p_{ij}$  są zdefiniowane dla wszystkich  $j \in S$ . Wszystkie te prawdopodobieństwa możemy wstawić do kwadratowej macierzy  $\mathbf{P} = [p_{ij}]_{i,j \in S}$ . Dla każdego  $n \in \mathbb{N}$

$$p_{ij} > 0, \quad i, j \in S; \quad \sum_{j \in S} p_{ij} = 1, \quad i \in S. \quad (7.6)$$

Kwadratową macierz o powyższych własnościach nazywamy *macierzą stochastyczną*.

Oznaczmy dalej

$$p_i = P(X_0 = i), \quad i \in S. \quad (7.7)$$

Oczywiście

$$p_i \geq 0, i \in S, \sum_{i \in S} p_i = 1. \quad (7.8)$$

Rozkład prawdopodobieństwa  $\mathbf{p} = \{p_i : i \in S\}$  nazywamy *prawdopodobieństwami początkowymi*.

**Twierdzenie 7.7.** Niech  $\{X_n : n \in \mathbb{N}\}$  będzie procesem stochastycznym o zbiorze stanów  $S = \{0, 1, \dots\}$ . Niech  $\mathbf{p} = \{p_i : i \in S\}$  jest wektorem spełniającym (7.8) oraz  $\mathbf{P} = [p_{ij}]_{i,j \in S}$  macierzą spełniającą (7.6). Wtedy proces  $X_t$  jest jednorodnym łańcuchem Markowa z rozkładem początkowym  $\mathbf{p}$  i macierzą przejścia  $\mathbf{P}$ , wtedy i tylko wtedy, gdy wszystkie skończoniewymiarowe rozkłady tego procesu są postaci

$$P(X_0 = i_0, X_1 = i_1, \dots, X_k = i_k) = p_{i_0} p_{i_0 i_1} \dots p_{i_{k-1} i_k} \quad (7.9)$$

dla wszystkich  $i_0, i_1, \dots, i_k \in S$  i wszystkich  $k \in \mathbb{N}$ .

Rozważmy teraz jednorodny łańcuch Markowa o macierzy prawdopodobieństw przejścia  $P$ . Połóżmy  $p_{ij}^{(0)} = \delta_{ij}$ , gdzie  $\delta_{ij}$  jest symbolem Kroneckera

$$\delta_{ij} = \begin{cases} 0 & i \neq j \\ 1 & i = j \end{cases}$$

Dalej  $p_{ij}^{(1)} = p_{ij}$  i dla wszystkich  $n \geq 1$  definiujemy indukcyjnie

$$p_{ij}^{(n+1)} = \sum_{k \in S} p_{ik}^{(n)} p_{kj}. \quad (7.10)$$

Można dowieść, że powyższe szeregi są zbieżne dla każdego  $n \geq 1$ , oraz że macierze  $\mathbf{P}^{(n)}$  z elementami  $p_{ij}^{(n)}$  są macierzami stochastycznymi. Z warunku (7.10) wynika, że

$$\mathbf{P}^{(2)} = \mathbf{P} \cdot \mathbf{P} = \mathbf{P}^2, \quad \mathbf{P}^{(n)} = \mathbf{P}^{(n-1)} \cdot \mathbf{P} = \mathbf{P} \cdot \mathbf{P}^{(n-1)} = \mathbf{P} \cdot \mathbf{P}^n.$$

**Przykład 7.8** (Zadanie o ruinie gracza). Gracz A oraz jego przeciwnik B grają w pewną powtarzającą się grę, która może skończyć się tylko wygraną jednego z nich. W grze jest kapitał  $a$  jednostek, przy czym na początku gracz A ma  $z$  jednostek kapitału, natomiast jego przeciwnik  $a - z$  jednostek. Jeżeli wygra gracz A zyskuje od swego przeciwnika 1 jednostkę kapitału, jeżeli przegra 1 jednostkę traci. Gracze grają tak długo aż jeden z nich straci cały swój kapitał. Zakładamy, że prawdopodobieństwa wygrania graczy A i B są  $p$  i  $q = 1 - p$  odpowiednio, oraz że wszystkie partie gry są niezależne. Jeżeli  $X_n$  oznacza kapitał, który po  $n$ -tej partii posiada gracz A, to wtedy  $\{X_n\}$  jest jednorodnym łańcuchem Markowa ze stanami  $S = \{0, 1, \dots, a\}$  i wektorem prawdopodobieństw początkowych  $p_z =$

$1, p_j = 0, j \neq z$  oraz prawdopodobieństwami przejścia  $p_{00} = p_{aa} = 1, p_{i,i+1} = p, p_{i,i-1} = q, 1 \leq i \leq a - 1$ . Macierz prawdopodobieństw przejścia ma wtedy postać

$$\mathbf{P} = \begin{bmatrix} 1 & 0 & 0 & 0 & \dots & 0 & 0 & 0 \\ q & 0 & p & 0 & \dots & 0 & 0 & 0 \\ 0 & q & 0 & p & \dots & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \dots & q & 0 & p \\ 0 & 0 & 0 & 0 & \dots & 0 & 0 & 1 \end{bmatrix}$$



# Bibliografia

- [1] L.Gajek, M. Kałuszka, *Wnioskowanie statystyczne dla studentów*, WNT, Warszawa 1998.
- [2] J. Józwiak, J. Podgórski, *Statystyka od podstaw*, PWE, Warszawa 2006.
- [3] W. Krysicki, J. Bartos, W. Dyczka, K. Królikowska, M. Wasilewski, *Rachunek prawdopodobieństwa i statystyka matematyczna w zadaniach cz. I i II*, PWN, Warszawa 2004.
- [4] J. Ombach, *Rachunek prawdopodobieństwa wspomagany komputerowo - Maple*, Wydawnictwo UJ, Kraków 2000.