

# Podstawy matematyczne obliczeń kwantowych i SI

**Hanna Wojewódka-Ściążko**

Instytut Informatyki Teoretycznej i Stosowanej Polskiej Akademii Nauk

11 stycznia 2025



## ❖ Akademia Sztuki Kwantowej: Szkolenia z obliczeń kwantowych i SI kreujące innowacyjne społeczeństwo

*Projekt finansowany ze środków budżetu państwa, przyznanych przez Ministra Edukacji i Nauki w ramach Programu „Nauka dla Społeczeństwa II”*

- ▶ Numer projektu: **NdS-II/SP/0222/2024/01**
- ▶ Termin realizacji: **od 03/04/2024 do 03/04/2026**
- ▶ Źródło finansowania: **Ministerstwo Nauki i Szkolnictwa Wyższego**
- ▶ Nazwa programu i moduł: **Nauka dla Społeczeństwa II**



## ❖ etap szkoleń – wykłady online

- ▶ Elementy rachunku prawdopodobieństwa.
- ▶ Elementy statystyki matematycznej.
- ▶ Podstawy uczenia maszynowego.
  
- ▶ Elementy algebry liniowej.
- ▶ Algorytmy numeryczne znajdujące minimum lokalne zadanej funkcji celu.
- ▶ Wprowadzenie do obliczeń kwantowych.
- ▶ Algorytmy kwantowe.



## Sugerowana kolejność odtwarzania dotychczas udostępnionych wykładów

Wykład otwierający Akademię Sztuki Kwantowej (wykład na żywo z dnia 7.12.24)

### OBLICZENIA KWANTOWE (OK)

Elementy algebry liniowej – cz. 1

Elementy algebry liniowej – cz. 2

Wykład otwierający blok tematyczny OK  
(wykład na żywo z dnia 7.12.24)

Wprowadzenie do obliczeń kwantowych

Pomiary kwantowe

Informacja klasyczna i kwantowa

Zakaz klonowania

Kryptografia

### KLASYCZNE UCZENIE MASZYNOWE (KUM)

Elementy rachunku prawdopodobieństwa – cz. 1

Elementy rachunku prawdopodobieństwa – cz. 2

Elementy statystyki matematycznej – cz. 1

Elementy statystyki matematycznej – cz. 2

Wykład otwierający blok tematyczny KUM  
(wykład na żywo z dnia 7.12.24)

Perceptron

Sieci MLP

Sieci MLP (analiza)

Statystyczne metody uczenia maszynowego  
– wprowadzenie

Statystyczne metody uczenia maszynowego



## ❖ etap szkoleń – wykłady online

- ▶ Elementy rachunku prawdopodobieństwa.
- ▶ Elementy statystyki matematycznej.
- ▶ Podstawy uczenia maszynowego.
  
- ▶ Elementy algebry liniowej.
- ▶ Algorytmy numeryczne znajdujące minimum lokalne zadanej funkcji celu.  
pytania: [piotr@piotrgawron.eu](mailto:piotr@piotrgawron.eu)
- ▶ Wprowadzenie do obliczeń kwantowych.
- ▶ Algorytmy kwantowe.



# Ankieta oceny jakości szkoleń Akademii Sztuki Kwantowej

## I etap szkoleń Akademii Sztuki Kwantowej - termin I

7 gru 2024, 11:00 → 11 sty 2025, 17:00 Europe/Warsaw

grafik\_wykladow\_o... kadra\_dydaktyczna... opis\_blokow\_temat... Sugerowana kolejn...

Ankiety

Ankieta oceny jakości szkoleń Akademii Sztuki Kwantowej [Wypełnij](#)

SOBOTA, 7 GRUDNIA

**11:00** → 12:30 **Podstawy matematyczne obliczeń kwantowych i SI** 1h 30min

Zapoznanie z wykładowniczą i wprowadzenie do następujących czterech bloków tematycznych:

1. Elementy rachunku prawdopodobieństwa.
2. Elementy statystyki matematycznej.
3. Elementy algebry liniowej.
4. Algorytmy numeryczne znajdujące minimum lokalne zadanej funkcji celu.

Wskazanie, w jakim stopniu i dlaczego będą one istotne realizacji dalszej treści szkoleń.

Udostępnienie (na okres 5 tygodni) nagrań około 8h wykładów dotyczących następujących zagadnień (wykłady będą udostępniane stopniowo):

Elementy rachunku prawdopodobieństwa i statystyki matematycznej:

## ❖ II etap szkoleń – warsztaty teoretyczno-praktyczne (wstępny grafik)

### Uczenie maszynowe

- ▶ Toruń, 31.05-1.06.25;
- ▶ Kraków, 13-14.09.25;
- ▶ Warszawa, 4-5.10.25.

### Uczenie architektur kwantowych

- ▶ Toruń, 5-6.04.25;
- ▶ Chorzów, 24-25.05.25;
- ▶ Poznań, 20-21.09.25.



## III etap szkoleń – warsztaty i projekty zespołowe (wstępny grafik)

### Kwantowe sieci neuronowe i kwantowe metody jądrowe

- ▶ Kraków, 18-19.10.25;
- ▶ Warszawa, 15-16.11.25;
- ▶ Gdańsk, 14-15.03.26.

### Kwantowe wyzarczenie kombinatorycznych problemów optymalizacyjnych

- ▶ Chorzów, 4-5.10.25;
- ▶ Poznań, 17-18.01.26;
- ▶ Gdańsk, 21-22.03.26.





# Elementy rachunku prawdopodobieństwa



## Elementy rachunku prawdopodobieństwa

- ▶ Modelowanie doświadczenia losowego za pomocą **przestrzeni probabilistycznej**.
- ▶ **Zmienna losowa**, jej rozkład i dystrybuanta.
- ▶ Zmienna losowa dyskretna i absolutnie ciągła.
- ▶ **Centralne twierdzenie graniczne**.



## Przestrzeń probabilistyczna

### Definicja

Przestrzenią probabilistyczną nazywamy trójkę  $(\Omega, \mathcal{F}, \mathbb{P})$ , składającą się z:

- ▶ niepustego zbioru  $\Omega$  (przestrzeń zdarzeń elementarnych),
- ▶ odpowiedniego zbioru  $\mathcal{F}$  (przestrzeń zdarzeń losowych) podzbiorów zbioru  $\Omega$ ,
- ▶ miary probabilistycznej, czyli funkcji  $\mathbb{P} : \mathcal{F} \rightarrow [0, 1]$ , takiej że
  - (1)  $\mathbb{P}(\Omega) = 1$ ,
  - (2) dla rozłącznych  $A_1, A_2, \dots \in \mathcal{F}$  zachodzi  $\mathbb{P}(A_1 \cup A_2 \cup \dots) = \mathbb{P}(A_1) + \mathbb{P}(A_2) + \dots$



## ❖ Zmienna losowa

### Zmienna losowa

Funkcja  $X : \Omega \rightarrow \mathbb{R}$ , która **każdemu możliwemu wynikowi doświadczenia losowego przypisuje wartość rzeczywistą.**



## ❖ Zmienna losowa

### Zmienna losowa

Funkcja  $X : \Omega \rightarrow \mathbb{R}$ , która **każdemu możliwemu wynikowi doświadczenia losowego przypisuje wartość rzeczywistą.**

### Zmienna losowa dyskretna

Przyjmuje **tylko skończoną lub przeliczalną liczbę wartości.**



## ❖ Zmienna losowa

### Zmienna losowa

Funkcja  $X : \Omega \rightarrow \mathbb{R}$ , która **każdemu możliwemu wynikowi doświadczenia losowego przypisuje wartość rzeczywistą.**

### Zmienna losowa dyskretna

Przyjmuje **tylko skończoną lub przeliczalną liczbę wartości.**

### Zmienna losowa ciągła

Teoretycznie **może przyjąć dowolną wartość z określonego przedziału.**



## Przykłady dyskretnych rozkładów prawdopodobieństwa



## ❖ Zmienna losowa dyskretna

- ▶ **Rozkład** zmiennej losowej  $X$  dyskretniej określamy wskazując pary  $(x_i, p_i)$  odpowiednio:
  - ▶ wartości tej zmiennej
  - ▶ i prawdopodobieństw, z jakimi są one przyjmowane ( $p_i := \mathbb{P}(X = x_i)$ ).





## ❖ Zmienna losowa dyskretna

- ▶ **Rozkład** zmiennej losowej  $X$  dyskretniej określamy wskazując pary  $(x_i, p_i)$  odpowiednio:
  - ▶ wartości tej zmiennej
  - ▶ i prawdopodobieństw, z jakimi są one przyjmowane ( $p_i := \mathbb{P}(X = x_i)$ ).

Zbiór tych par

$$\{(x_1, p_1), (x_2, p_2), \dots\}$$

nazywamy **bazą**.



## ❖ Zmienna losowa dyskretna

- ▶ **Rozkład** zmiennej losowej  $X$  dyskretniej określamy wskazując pary  $(x_i, p_i)$  odpowiednio:
  - ▶ wartości tej zmiennej
  - ▶ i prawdopodobieństw, z jakimi są one przyjmowane ( $p_i := \mathbb{P}(X = x_i)$ ).

Zbiór tych par

$$\{(x_1, p_1), (x_2, p_2), \dots\}$$

nazywamy **bazą**.

$x_1$	$x_2$	$x_3$	$\dots$
$p_1$	$p_2$	$p_3$	$\dots$



## ❖ Zmienna losowa dyskretna

- ▶ **Rozkład** zmiennej losowej  $X$  dyskretniej określamy wskazując pary  $(x_i, p_i)$  odpowiednio:
  - ▶ wartości tej zmiennej
  - ▶ i prawdopodobieństw, z jakimi są one przyjmowane ( $p_i := \mathbb{P}(X = x_i)$ ).

Zbiór tych par

$$\{(x_1, p_1), (x_2, p_2), \dots\}$$

nazywamy **bazą**.

$x_1$	$x_2$	$x_3$	$\dots$
$p_1$	$p_2$	$p_3$	$\dots$

- ▶ **Dystrybuanta** zmiennej losowej  $X$  dyskretniej:

$$F_X(x) = \mathbb{P}(X \leq x) = \sum_{i: x_i \leq x} p_i.$$



## Przykłady dyskretnych rozkładów prawdopodobieństwa

- ▶ Rozkład **dwupunktowy**.
- ▶ Rozkład **dwumianowy**.
- ▶ Rozkład **Poissona**.
- ▶ Rozkład **geometryczny**.



## ➤ Rozkład Poissona


- ▶ Zmienna losowa  $X$  ma rozkład Poissona o parametrze  $\lambda > 0$ , jeśli  $X$  przyjmuje wartości ze zbioru  $\{0, 1, 2, \dots\}$  oraz

$$\mathbb{P}(X = k) = \frac{1}{k!} \lambda^k e^{-\lambda} \quad \text{dla każdego } k \in \{0, 1, \dots\}.$$

- ▶ Oznaczenie:  $X \sim Pois(\lambda)$ .




# Rozkład Poissona



Rysunek: Rozkład Poissona (dla parametrów:  $\lambda = 5$ ,  $\lambda = 10$  i  $\lambda = 20$ ).



## Rozkład Poissona



Rysunek: Dystrybuanta rozkładu Poissona (dla parametrów:  $\lambda = 5$ ,  $\lambda = 10$  i  $\lambda = 20$ ).



## ❖ Rozkład Poissona

### Uwaga

Rozkład Poissona jest zazwyczaj wykorzystywany w sytuacjach, w których liczymy wystąpienia pewnych zdarzeń w jednostce czasu lub przestrzeni.

### Przykład

- ▶ Liczymy liczbę klientów, którzy odwiedzają dany sklep między 13:00 a 14:00.
- ▶ Na podstawie danych z poprzednich dni wiemy, że średnio 15 klientów odwiedza ten sklep między 13:00 a 14:00.
- ▶ Zmienna losowa  $X \sim Pois(\lambda = 15)$  właściwie opisuje losową liczbę klientów w tym sklepie (między 13:00 a 14:00).





## ❖ Rozkład Poissona

### Przykład

Przyjmijmy, że liczba wiadomości e-mail, które otrzymuje pewien pracownik w ciągu dnia roboczego, może być modelowana za pomocą rozkładu Poissona, przy średniej liczbie 0,2 wiadomości na minutę. *Jakie jest prawdopodobieństwo, że w ciągu 5 minut nie otrzyma on żadnej wiadomości?*

## ➤ Rozkład Poissona

### Przykład

Przyjmijmy, że liczba wiadomości e-mail, które otrzymuje pewien pracownik w ciągu dnia roboczego, może być modelowana za pomocą rozkładu Poissona, przy średniej liczbie 0,2 wiadomości na minutę. *Jakie jest prawdopodobieństwo, że w ciągu 5 minut nie otrzyma on żadnej wiadomości?*

- ▶ Niech  $Y$  będzie zmienną losową opisującą liczbę wiadomości e-mail, które pracownik otrzymał w dowolnym pięciominutowym odstępie czasu.

## ❖ Rozkład Poissona

### Przykład

Przyjmijmy, że liczba wiadomości e-mail, które otrzymuje pewien pracownik w ciągu dnia roboczego, może być modelowana za pomocą rozkładu Poissona, przy średniej liczbie 0,2 wiadomości na minutę. *Jakie jest prawdopodobieństwo, że w ciągu 5 minut nie otrzyma on żadnej wiadomości?*

- ▶ Niech  $Y$  będzie zmienną losową opisującą liczbę wiadomości e-mail, które pracownik otrzymał w dowolnym pięciominutowym odstępie czasu.
- ▶ Wtedy  $Y \sim Pois(\lambda)$  z  $\lambda = 5(0,2) = 1$ .

## ❖ Rozkład Poissona

### Przykład

Przyjmijmy, że liczba wiadomości e-mail, które otrzymuje pewien pracownik w ciągu dnia roboczego, może być modelowana za pomocą rozkładu Poissona, przy średniej liczbie 0,2 wiadomości na minutę. *Jakie jest prawdopodobieństwo, że w ciągu 5 minut nie otrzyma on żadnej wiadomości?*

- ▶ Niech  $Y$  będzie zmienną losową opisującą liczbę wiadomości e-mail, które pracownik otrzymał w dowolnym pięciominutowym odstępie czasu.
- ▶ Wtedy  $Y \sim Pois(\lambda)$  z  $\lambda = 5(0,2) = 1$ .
- ▶ Stąd

$$\mathbb{P}(Y = 0) = \frac{1}{0!} \lambda^0 e^{-\lambda} = \frac{1}{0!} 1^0 e^{-1} = \frac{1}{e} \approx 0,3679.$$

## ❖ Rozkład Poissona jako przybliżenie rozkładu dwumianowego

### Uwaga

Rozkład Poissona z parametrem  $\lambda > 0$  można traktować jako granicę ciągu rozkładów dwumianowych z parametrami  $n$  i  $p = \lambda/n$ ,  $n \in \mathbb{N}$  (fakt ten często wykorzystuje się w praktyce, gdyż w wielu zastosowaniach rozkład Poissona jest wygodniejszy do obliczeń niż rozkład dwumianowy, zwłaszcza dla dużych wartości  $n$ ).



## ❖ Rozkład Poissona jako przybliżenie rozkładu dwumianowego

### Uwaga

Rozkład Poissona z parametrem  $\lambda > 0$  można traktować jako granicę ciągu rozkładów dwumianowych z parametrami  $n$  i  $p = \lambda/n$ ,  $n \in \mathbb{N}$  (fakt ten często wykorzystuje się w praktyce, gdyż w wielu zastosowaniach rozkład Poissona jest wygodniejszy do obliczeń niż rozkład dwumianowy, zwłaszcza dla dużych wartości  $n$ ).

### Twierdzenie

Ustalmy  $\lambda > 0$  i rozważmy zmienne losowe  $X_n \sim B(n, p = \frac{\lambda}{n})$  dla  $n \in \mathbb{N}$ . Wtedy, dla każdego  $k \in \{0, 1, \dots\}$ , mamy

$$\lim_{n \rightarrow \infty} \mathbb{P}(X_n = k) = \frac{e^{-\lambda} \lambda^k}{k!}.$$

## ➤ Rozkład geometryczny


- ▶ Zmienna losowa  $X$  ma rozkład geometryczny o parametrze  $p \in (0, 1]$ , jeśli  $X$  przyjmuje wartości naturalne oraz

$$\mathbb{P}(X = k) = p(1 - p)^{k-1} \quad \text{dla każdego } k \in \{1, 2, \dots\}.$$

- ▶ Oznaczenie:  $X \sim \text{Geo}(p)$ .



## Rozkład geometryczny

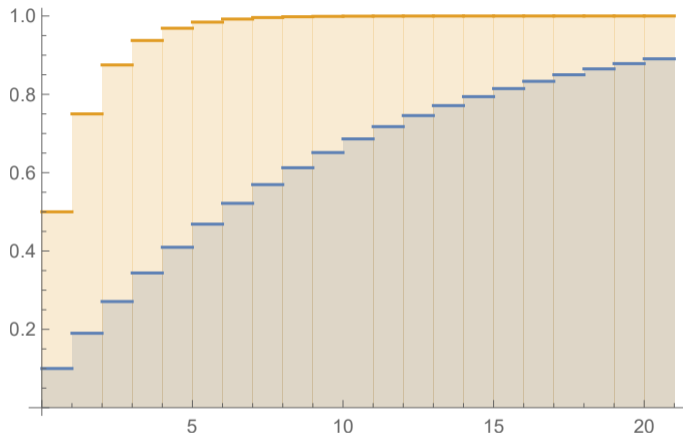


Rysunek: Rozkład geometryczny (dla parametrów:  $p = 0,1$  i  $p = 0,5$ ).





## Rozkład geometryczny



Rysunek: Dystrybuanta rozkładu geometrycznego (dla parametrów:  $p = 0,1$  i  $p = 0,5$ ).



## ❖ Rozkład geometryczny

### Uwaga

Eksperyment losowy stojący za rozkładem geometrycznym wygląda następująco:

- ▶ Załóżmy, że rzucamy stroniczą monetą ( $\mathbb{P}(\text{orzeł}) = p$  oraz  $\mathbb{P}(\text{reszka}) = 1 - p$ ), aż do momentu uzyskania orła.



## ❖ Rozkład geometryczny

### Uwaga

Eksperyment losowy stojący za rozkładem geometrycznym wygląda następująco:

- ▶ Załóżmy, że rzucamy stroniczą monetą ( $\mathbb{P}(\text{orzeł}) = p$  oraz  $\mathbb{P}(\text{reszka}) = 1 - p$ ), aż do momentu uzyskania orła.
- ▶ Zmienna losowa  $X$ , która opisuje łączną liczbę rzutów monetą w tym eksperymencie, ma rozkład geometryczny o parametrze  $p$ .



## ❖ Rozkład geometryczny

### Uwaga

Eksperyment losowy stojący za rozkładem geometrycznym wygląda następująco:

- ▶ Załóżmy, że rzucamy stroniczą monetą ( $\mathbb{P}(\text{orzeł}) = p$  oraz  $\mathbb{P}(\text{reszka}) = 1 - p$ ), aż do momentu uzyskania orła.
- ▶ Zmienna losowa  $X$ , która opisuje łączną liczbę rzutów monetą w tym eksperymencie, ma rozkład geometryczny o parametrze  $p$ .

Można myśleć o tym eksperymencie jako o powtarzaniu niezależnych prób Bernoulliego aż do momentu zaobserwowania pierwszego sukcesu.



## Przykłady rozkładów prawdopodobieństwa typu ciągłego



## ❖ Zmienna losowa absolutnie ciągła

Zmienną losową  $X$  nazywamy **absolutnie ciągłą**,



## ❖ Zmienna losowa absolutnie ciągła

Zmienną losową  $X$  nazywamy **absolutnie ciągłą**, jeśli

$$F_X(x) = \mathbb{P}(X \leq x) = \int_{-\infty}^x f_X(u) du \quad \text{dla dowolnego } u \in \mathbb{R}$$

dla pewnej nieujemnej funkcji  $f_X$ ,



## ❖ Zmienna losowa absolutnie ciągła

Zmienną losową  $X$  nazywamy **absolutnie ciągłą**, jeśli

$$F_X(x) = \mathbb{P}(X \leq x) = \int_{-\infty}^x f_X(u) du \quad \text{dla dowolnego } u \in \mathbb{R}$$

dla pewnej nieujemnej funkcji  $f_X$ , zwanej **funkcją gęstości** zmiennej  $X$ .





## ❖ Zmienna losowa absolutnie ciągła

Zmienną losową  $X$  nazywamy **absolutnie ciągłą**, jeśli

$$F_X(x) = \mathbb{P}(X \leq x) = \int_{-\infty}^x f_X(u) du \quad \text{dla dowolnego } u \in \mathbb{R}$$

dla pewnej nieujemnej funkcji  $f_X$ , zwanej **funkcją gęstości** zmiennej  $X$ .

► **Rozkład** zmiennej losowej  $X$  absolutnie ciągłej:

$$\mathbb{P}(X \in A) = \int_A f_X(u) du \quad \text{dla } A \subset \mathbb{R}.$$



## Przykłady rozkładów prawdopodobieństwa typu ciągłego

- ▶ Rozkład **jednostajny** na odcinku.
- ▶ Rozkład **normalny**.
- ▶ Rozkład **normalny standardowy**.
- ▶ Rozkład **wykładniczy**.



## ➤ Rozkład wykładniczy

- ▶ Zmienna losowa  $X$  ma **rozkład wykładniczy** o parametrze  $\lambda > 0$ , jeśli  $X$  przyjmuje wartości rzeczywiste nieujemne oraz

$$f_X(x) = \begin{cases} \lambda e^{-\lambda x} & \text{dla } x \geq 0 \\ 0 & \text{w przeciwnym razie.} \end{cases}$$

- ▶ Oznaczenie:  $X \sim \text{Exp}(\lambda)$ .



## ➤ Rozkład wykładniczy

- ▶ Zmienna losowa  $X$  ma **rozkład wykładniczy** o parametrze  $\lambda > 0$ , jeśli  $X$  przyjmuje wartości rzeczywiste nieujemne oraz

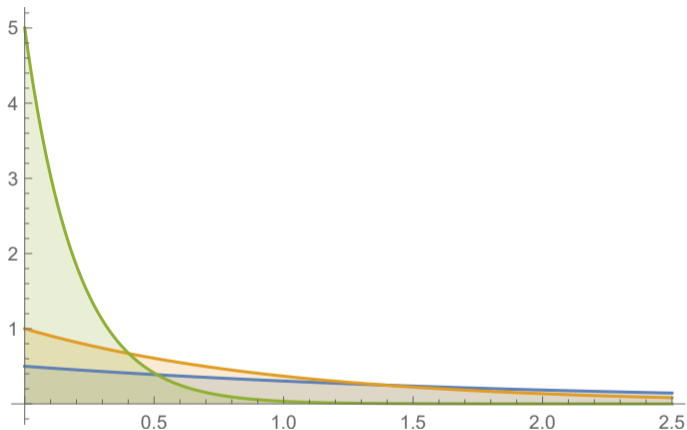
$$f_X(x) = \begin{cases} \lambda e^{-\lambda x} & \text{dla } x \geq 0 \\ 0 & \text{w przeciwnym razie.} \end{cases}$$

- ▶ Oznaczenie:  $X \sim \text{Exp}(\lambda)$ .
- ▶ Dystrybuanta:

$$F_X(x) = \begin{cases} 0 & \text{dla } x < 0 \\ 1 - e^{-\lambda x} & \text{dla } x \geq 0. \end{cases}$$




## Rozkład wykładniczy



Rysunek: Rozkład wykładniczy (dla parametrów:  $\lambda = 0,5$ ,  $\lambda = 1$  i  $\lambda = 5$ ).



## Rozkład wykładniczy



Rysunek: Dystrybuanta rozkładu wykładniczego (dla parametrów:  $\lambda = 0,5$ ,  $\lambda = 1$  i  $\lambda = 5$ ).



## ❖ Rozkład **wykładniczy** o parametrze $\lambda > 0$

### Uwaga

Rozkład wykładniczy można traktować jako ciągły odpowiednik rozkładu geometrycznego.

Przypomnijmy, że eksperyment losowy stojący za rozkładem geometrycznym to rzucanie monetą aż do momentu zaobserwowania orła.

## ❖ Rozkład **wykładniczy** o parametrze $\lambda > 0$

### Uwaga

Rozkład wykładniczy można traktować jako ciągły odpowiednik rozkładu geometrycznego.

Przypomnijmy, że eksperyment losowy stojący za rozkładem geometrycznym to rzucanie monetą aż do momentu zaobserwowania orła.

Założmy, że

- ▶ rzuty monetą odbywają się co  $\Delta$  sekundy  
(dla małych  $\Delta$ : rzuty odbywają się niemal natychmiast jeden po drugim);



## ❖ Rozkład **wykładniczy** o parametrze $\lambda > 0$

### Uwaga

Rozkład wykładniczy można traktować jako ciągły odpowiednik rozkładu geometrycznego.

Przypomnijmy, że eksperyment losowy stojący za rozkładem geometrycznym to rzucanie monetą aż do momentu zaobserwowania orła.

Założmy, że

- ▶ rzuty monetą odbywają się co  $\Delta$  sekundy  
(dla małych  $\Delta$ : rzuty odbywają się niemal natychmiast jeden po drugim);
- ▶ prawdopodobieństwo sukcesu (otrzymania orła) w każdej próbie wynosi  $p = \Delta\lambda$   
(dla małych  $\Delta$ : jest bardzo małe).

## ❖ Rozkład **wykładniczy** o parametrze $\lambda > 0$

### Uwaga

Rozkład wykładniczy można traktować jako ciągły odpowiednik rozkładu geometrycznego.

Przypomnijmy, że eksperyment losowy stojący za rozkładem geometrycznym to rzucanie monetą aż do momentu zaobserwowania orła.

Założmy, że

- ▶ rzuty monetą odbywają się co  $\Delta$  sekundy  
(dla małych  $\Delta$ : rzuty odbywają się niemal natychmiast jeden po drugim);
- ▶ prawdopodobieństwo sukcesu (otrzymania orła) w każdej próbie wynosi  $p = \Delta\lambda$   
(dla małych  $\Delta$ : jest bardzo małe).

Niech  $X$  będzie losowym czasem, po którym zaobserwujemy pierwszy "sukces". Wtedy rozkład zmiennej losowej  $X$  zbiega do rozkładu wykładniczego  $Exp(\lambda)$ , gdy  $\Delta$  dąży do zera.

## ❖ Rozkład **wykładniczy** o parametrze $\lambda > 0$

### Uwaga

Niech  $X \sim \text{Exp}(\lambda)$  dla  $\lambda > 0$ . Wtedy  $X$  ma własność *braku pamięci*, tzn.

$$\mathbb{P}(X > x + a | X > a) = \mathbb{P}(X > x) \quad \text{dla } a, x \geq 0.$$



## ❖ Rozkład **wykładniczy** o parametrze $\lambda > 0$

### Uwaga

Niech  $X \sim \text{Exp}(\lambda)$  dla  $\lambda > 0$ . Wtedy  $X$  ma własność **braku pamięci**, tzn.

$$\mathbb{P}(X > x + a | X > a) = \mathbb{P}(X > x) \quad \text{dla } a, x \geq 0.$$

Z punktu widzenia oczekiwania na pierwszy sukces, własność **braku pamięci** oznacza, że nie ma znaczenia, jak długo czekaliśmy do tej pory. Jeśli nie zaobserwowaliśmy sukcesu do czasu  $a$ , rozkład czasu oczekiwania (od momentu  $a$ ) na następny sukces jest taki sam, jak gdybyśmy zaczęli od momentu zero.



## Centralne twierdzenie graniczne (CTG)



## Centralne twierdzenie graniczne

### Centralne twierdzenie graniczne (CTG)

Dany jest ciąg

$$X_1, X_2, \dots, X_n$$

niezależnych zmiennych losowych o jednakowym rozkładzie

## Centralne twierdzenie graniczne

### Centralne twierdzenie graniczne (CTG)

Dany jest ciąg

$$X_1, X_2, \dots, X_n$$

**niezależnych** zmiennych losowych o **jednakowym rozkładzie**  
(zmiennie mają jednakowe wartości oczekiwane i wariancje:

$$\mathbb{E}(X_1) = \dots = \mathbb{E}(X_n) = m, \quad D^2(X_1) = \dots = D^2(X_n) = \sigma^2)$$

## Centralne twierdzenie graniczne

### Centralne twierdzenie graniczne (CTG)

Dany jest ciąg

$$X_1, X_2, \dots, X_n$$

**niezależnych** zmiennych losowych o **jednakowym rozkładzie**  
(zmiennie mają jednakowe wartości oczekiwane i wariancje:

$$\mathbb{E}(X_1) = \dots = \mathbb{E}(X_n) = m, \quad D^2(X_1) = \dots = D^2(X_n) = \sigma^2)$$

**Wówczas dla odpowiednio dużych  $n$  rozkład zmiennej losowej**

$$Z_n = X_1 + X_2 + \dots + X_n$$

**można przybliżyć rozkładem normalnym  $\mathcal{N}(nm, \sigma^2 n)$ .**



## Centralne Twierdzenie Graniczne

### Uwaga

Przypuśćmy, że interesująca nas zmienna losowa jest sumą dużej liczby niezależnych zmiennych losowych (o skończonej wariancji).

## Centralne Twierdzenie Graniczne

### Uwaga

Przypuśćmy, że interesująca nas zmienna losowa jest sumą dużej liczby niezależnych zmiennych losowych (o skończonej wariancji).

Dzięki CTG wiemy, że rozkład tej zmiennej **można aproksymować rozkładem normalnym**, szczególnie gdy liczba składników jest duża.

## Centralne Twierdzenie Graniczne

### Uwaga

Przypuśćmy, że interesująca nas zmienna losowa jest sumą dużej liczby niezależnych zmiennych losowych (o skończonej wariancji).

Dzięki CTG wiemy, że rozkład tej zmiennej można aproksymować rozkładem normalnym, szczególnie gdy liczba składników jest duża.

Przykłady:

- ▶ **Błędy pomiarów laboratoryjnych:** Zazwyczaj są modelowane jako zmienne losowe o rozkładzie normalnym, ponieważ powstają w wyniku sumowania wielu drobnych, niezależnych błędów.

## Centralne Twierdzenie Graniczne

### Uwaga

Przypuśćmy, że interesująca nas zmienna losowa jest sumą dużej liczby niezależnych zmiennych losowych (o skończonej wariancji).

Dzięki CTG wiemy, że rozkład tej zmiennej **można aproksymować rozkładem normalnym**, szczególnie gdy liczba składników jest duża.

### Przykłady:

- ▶ **Błędy pomiarów laboratoryjnych:** Zazwyczaj są modelowane jako zmienne losowe o rozkładzie normalnym, ponieważ powstają w wyniku sumowania wielu drobnych, niezależnych błędów.
- ▶ **Próbki populacji:** Gdy losowo pobieramy próbkę z populacji w celu uzyskania wiedzy statystycznej na jej temat, możemy modelować wynikową statystykę (np. średnią próbkową) jako zmienną losową o rozkładzie normalnym.

## Centralne Twierdzenie Graniczne

### Uwaga

CTG w wielu przypadkach może znacząco uprościć obliczenia.

### Przykład:

- ▶ Jeśli mamy problem, w którym interesuje nas suma tysiąca niezależnych zmiennych losowych, znalezienie rozkładu tej sumy metodą bezpośrednich obliczeń może okazać się niezwykle trudne.



## Centralne Twierdzenie Graniczne

### Uwaga

CTG w wielu przypadkach może znacząco uprościć obliczenia.

### Przykład:

- ▶ Jeśli mamy problem, w którym interesuje nas suma tysięcy niezależnych zmiennych losowych, znalezienie rozkładu tej sumy metodą bezpośrednich obliczeń może okazać się niezwykle trudne.

Natomiast jeśli znamy średnią i wariancję zmiennych losowych  $X_i$ , to (korzystając z CTG) możemy od razu zapisać rozkład.



## Centralne Twierdzenie Graniczne

### Uwaga

CTG w wielu przypadkach może znacząco uprościć obliczenia.

### Przykład:

- ▶ Jeśli mamy problem, w którym interesuje nas suma tysiąca niezależnych zmiennych losowych, znalezienie rozkładu tej sumy metodą bezpośrednich obliczeń może okazać się niezwykle trudne.

Natomiast jeśli znamy średnią i wariancję zmiennych losowych  $X_i$ , to (korzystając z CTG) możemy od razu zapisać rozkład.

### Uwaga

Powszechnie uznaje się, że **jeśli  $n \geq 30$ , to przybliżenie rozkładem normalnym jest bardzo dobre.**

## ❖ Jak stosować CTG?

1. Zapsujemy zmienną losową, która nas interesuje,  $Y$ , jako sumę  $n$  niezależnych zmiennych losowych:

$$Y = X_1 + X_2 + \dots + X_n \quad \text{takich, że} \quad m = \mathbb{E}(X_i), \quad \sigma^2 = D^2(X_i).$$

2. Wyliczamy  $\mathbb{E}(Y)$  i  $D^2(Y)$ , pamiętając o tym, że  $\mathbb{E}(Y) = nm$ ,  $D^2(Y) = n\sigma^2$ .



## ❖ Jak stosować CTG?

1. Zapsujemy zmienną losową, która nas interesuje,  $Y$ , jako sumę  $n$  niezależnych zmiennych losowych:

$$Y = X_1 + X_2 + \dots + X_n \quad \text{takich, że} \quad m = \mathbb{E}(X_i), \quad \sigma^2 = D^2(X_i).$$

2. Wyliczamy  $\mathbb{E}(Y)$  i  $D^2(Y)$ , pamiętając o tym, że  $\mathbb{E}(Y) = nm$ ,  $D^2(Y) = n\sigma^2$ .
3. Zgodnie z CLT, rozkład zmiennej losowej

$$Z = \frac{Y - \mathbb{E}(Y)}{\sqrt{D^2(Y)}} = \frac{Y - nm}{\sqrt{n}\sigma}$$

możemy przybliżyć rozkładem normalnym standardowym.

## ❖ Jak stosować CTG?

4. Aby znaleźć  $\mathbb{P}(y_1 \leq Y \leq y_2)$ , możemy zapisać

$$\begin{aligned}\mathbb{P}(y_1 \leq Y \leq y_2) &= \mathbb{P}\left(\frac{y_1 - nm}{\sqrt{n}\sigma} \leq \frac{Y - nm}{\sqrt{n}\sigma} \leq \frac{y_2 - nm}{\sqrt{n}\sigma}\right) \\ &= \mathbb{P}\left(\frac{y_1 - nm}{\sqrt{n}\sigma} \leq Z \leq \frac{y_2 - nm}{\sqrt{n}\sigma}\right) \\ &= \mathbb{P}\left(Z \leq \frac{y_2 - nm}{\sqrt{n}\sigma}\right) - \mathbb{P}\left(Z \leq \frac{y_1 - nm}{\sqrt{n}\sigma}\right) \\ &= \Phi\left(\frac{y_2 - nm}{\sqrt{n}\sigma}\right) - \Phi\left(\frac{y_1 - nm}{\sqrt{n}\sigma}\right).\end{aligned}$$



## ✦ Jak stosować Centralne Twierdzenie Graniczne

### Przykład

W systemie komunikacyjnym każdy pakiet danych składa się z 1000 bitów. Z powodu szumów, każdy bit może zostać odebrany z błędem z prawdopodobieństwem  $0,1$ . Zakłada się, że błędy bitów zachodzą niezależnie. **Znajdź prawdopodobieństwo, że w danym pakiecie danych będzie więcej niż 120 błędów.**



## ❖ Jak stosować Centralne Twierdzenie Graniczne

### Przykład

W systemie komunikacyjnym każdy pakiet danych składa się z 1000 bitów. Z powodu szumów, każdy bit może zostać odebrany z błędem z prawdopodobieństwem 0,1. Zakłada się, że błędy bitów zachodzą niezależnie. **Znajdź prawdopodobieństwo, że w danym pakiecie danych będzie więcej niż 120 błędów.**

Dla każdego  $i \in \mathbb{N}$  niech  $X_i$  będzie następującą zmienną losową:

$$X_i = \begin{cases} 1 & \text{jeśli } i\text{-ty bit został odebrany z błędem} \\ 0 & \text{w przeciwnym razie.} \end{cases}$$



## ❖ Jak stosować CTG?

$X_i$  są niezależnymi zmiennymi losowymi o jednakowym rozkładzie dwupunktowym z parametrem  $p = 0,1$ , więc

$$m = \mathbb{E}(X_i) = p = 0,1 \quad \text{ i } \quad \sigma^2 = D^2(X_i) = p(1-p) = 0,09.$$

## ❖ Jak stosować CTG?

$X_i$  są niezależnymi zmiennymi losowymi o jednakowym rozkładzie dwupunktowym z parametrem  $p = 0,1$ , więc

$$m = \mathbb{E}(X_i) = p = 0,1 \quad \text{i} \quad \sigma^2 = D^2(X_i) = p(1-p) = 0,09.$$

Niech

$$Y = X_1 + \dots + X_{1000}.$$

## ✦ Jak stosować CTG?

$X_i$  są niezależnymi zmiennymi losowymi o jednakowym rozkładzie dwupunktowym z parametrem  $p = 0,1$ , więc

$$m = \mathbb{E}(X_i) = p = 0,1 \quad \text{ i } \quad \sigma^2 = D^2(X_i) = p(1-p) = 0,09.$$

Niech

$$Y = X_1 + \dots + X_{1000}.$$

**Chcemy znaleźć**  $\mathbb{P}(Y > 120)$ .

## ❖ Jak stosować CTG?

$X_i$  są niezależnymi zmiennymi losowymi o jednakowym rozkładzie dwupunktowym z parametrem  $p = 0,1$ , więc

$$m = \mathbb{E}(X_i) = p = 0,1 \quad \text{ i } \quad \sigma^2 = D^2(X_i) = p(1-p) = 0,09.$$

Niech

$$Y = X_1 + \dots + X_{1000}.$$

**Chcemy znaleźć  $\mathbb{P}(Y > 120)$ .** Korzystając z CLT (oraz tablic rozkładu normalnego), mamy

$$\begin{aligned} \mathbb{P}(Y > 120) &= \mathbb{P}\left(\frac{Y - nm}{\sqrt{n\sigma^2}} > \frac{120 - nm}{\sqrt{n\sigma^2}}\right) = \mathbb{P}\left(Z > \frac{120 - 1000 * 0,1}{\sqrt{1000 * 0,09}}\right) = \\ &= 1 - \mathbb{P}\left(Z \leq \frac{20}{\sqrt{90}}\right) \approx 1 - \Phi\left(20/\sqrt{90}\right) = 1 - \Phi(2,11) = 1 - 0,9826 = 0,0174. \end{aligned}$$



# Elementy statystyki matematycznej



## Elementy statystyki matematycznej

- ▶ Statystyka opisowa a statystyka matematyczna.
- ▶ Teoretyczne podstawy wnioskowania statystycznego.
- ▶ **Weryfikacja hipotez statystycznych.**
- ▶ Testy różnicy średnich dla obserwacji powiązanych w pary. **Sparowany test  $t$  i test Wilcoxon dla par obserwacji.**
- ▶ Testy zgodności. Testy normalności rozkładu. **Test Shapiro-Wilka.**



# Testy statystyczne w *Pythonie*

The screenshot shows the SciPy documentation website for the `ttest_1samp` function. The browser address bar shows the URL `https://docs.scipy.org/doc/scipy/reference/generated/scipy.stats.ttest_1samp.html`. The SciPy logo and navigation links are visible at the top. A search bar is present on the left. The main content area displays the function signature and description.

Section Navigation

- scipy
- scipy.cluster
- scipy.constants
- scipy.datasets
- scipy.differentiate
- scipy.fft
- scipy.fftpack
- scipy.integrate
- scipy.interpolate
- scipy.io
- scipy.linalg
- scipy.ndimage
- scipy.odr
- scipy.optimize
- scipy.signal
- scipy.sparse
- scipy.spatial
- scipy.special
- scipy.stats**

Installing [User Guide](#) [API reference](#) [Building from source](#) [Development](#) [Release notes](#) 1.15.0 (stable) [i](#) [p](#) [t](#)

Search

SciPy API > Statistical functions (`scipy.stats`) > `ttest_1samp`

## scipy.stats. ttest\_1samp

**ttest\_1samp**(*a*, *popmean*, *axis*=0, *nan\_policy*='propagate', *alternative*='two-sided', \*, *keepdims*=False) [\[source\]](#)

Calculate the T-test for the mean of ONE group of scores.

This is a test for the null hypothesis that the expected value (mean) of a sample of independent observations *a* is equal to the given population mean, *popmean*.

**Parameters:**

- a** : *array\_like*  
Sample observations.
- popmean** : *float or array\_like*  
Expected value in null hypothesis. If *array\_like*, then its length along *axis* must equal 1, and it must otherwise be broadcastable with *a*.
- axis** : *int or None, default: 0*  
If an int, the axis of the input along which to compute the statistic. The statistic of each axis-slice (e.g. row) of the input will appear in a corresponding element of the output. If `None`, the input will be raveled before computing the statistic.
- nan\_policy** : {'propagate', 'omit', 'raise'}  
Defines how to handle input NaNs.

On this page  
[ttest\\_1samp](#)



# Elementy algebry liniowej



## Elementy algebry liniowej

- ▶ Liczby zespolone.
- ▶ **Wektory. Iloczyn skalarny wektorów.** Notacja Diraca.
- ▶ **Baza** i wymiar przestrzeni wektorowej. Norma euklidesowa. Wektory **unormowane** i **ortogonalne**.
- ▶ **Macierze** i działania wykonywane na macierzach.



## Wektor $n$ -wymiarowy i notacja Diraca

### Wektor $n$ -wymiarowy

$n$ -wymiarowym wektorem  $\mathbf{v}$  nazywamy uporządkowaną tablicę  $n$  liczb:  $x_1, x_2, \dots, x_n$ .

$$|u\rangle = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (\text{postać kolumnowa}) \quad \langle u| = [x_1 \quad x_2 \quad \cdots \quad x_n] \quad (\text{postać wierszowa})$$



# Macierz

## Definicja

**Macierzą** nazywamy **prostokątną tablicę liczb** (rzeczywistych bądź zespolonych), symboli lub wyrażeń.



# Macierz

## Definicja

**Macierzą** nazywamy **prostokątną tablicę liczb** (rzeczywistych bądź zespolonych), symboli lub wyrażeń.

## Przykład

Przykład macierzy o wymiarach  $m \times n$ :

$$A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix}.$$



# Iloczyn macierzy



## ✚ Iloczyn macierzy

Dane są macierze  $\mathbf{A} \in \mathbb{K}^{mk}$  oraz  $\mathbf{B} \in \mathbb{K}^{kn}$ , takie że

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1k} \\ a_{21} & a_{22} & \cdots & a_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mk} \end{bmatrix}, \quad \mathbf{B} = \begin{bmatrix} b_{11} & b_{12} & \cdots & b_{1n} \\ b_{21} & b_{22} & \cdots & b_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ b_{k1} & b_{k2} & \cdots & b_{kn} \end{bmatrix}.$$

Wynikiem **pomnożenia macierzy  $\mathbf{A}$  przez macierz  $\mathbf{B}$**  jest macierz  $\mathbf{C} \in \mathbb{K}^{mn}$  postaci

$$\mathbf{C} = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1n} \\ c_{21} & c_{22} & \cdots & c_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ c_{m1} & c_{m2} & \cdots & c_{mn} \end{bmatrix},$$

gdzie  $c_{2n} = a_{21}b_{1n} + a_{22}b_{2n} + \cdots + a_{2k}b_{kn}$  dla  $i \in \{1, 2, \dots, m\}$ ,  $j \in \{1, 2, \dots, n\}$ .

# ✦ Iloczyn macierzy

$$\mathbf{AB} = \begin{bmatrix} \langle a_1 | \\ \langle a_2 | \\ \vdots \\ \langle a_m | \end{bmatrix} \begin{bmatrix} |b_1\rangle & |b_2\rangle & \dots & |b_n\rangle \end{bmatrix} = \begin{bmatrix} \langle a_1 | b_1 \rangle & \langle a_1 | b_2 \rangle & \dots & \langle a_1 | b_n \rangle \\ \langle a_2 | b_1 \rangle & \langle a_2 | b_2 \rangle & \dots & \langle a_2 | b_n \rangle \\ \vdots & \vdots & \ddots & \vdots \\ \langle a_m | b_1 \rangle & \langle a_m | b_2 \rangle & \dots & \langle a_m | b_n \rangle \end{bmatrix}$$



✚ Iloczyn macierzy – zapis ułatwiający odczytanie wymiaru macierzy wynikowej

$$\begin{bmatrix} -2 & 1 & 0 \\ 0 & 2 & -1 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & -1 \\ 1 & 2 \end{bmatrix} = \begin{bmatrix} -2 & -1 \\ -1 & -4 \end{bmatrix}$$

The image shows a handwritten matrix multiplication on a grid background. The first matrix is  $\begin{bmatrix} -2 & 1 & 0 \\ 0 & 2 & -1 \end{bmatrix}$  and the second is  $\begin{bmatrix} 1 & 0 \\ 0 & -1 \\ 1 & 2 \end{bmatrix}$ . The result is  $\begin{bmatrix} -2 & -1 \\ -1 & -4 \end{bmatrix}$ . The calculation steps are written inside the second matrix: the top row is  $[-2+0+0 \quad 0-1+0]$  and the bottom row is  $[0+0-1 \quad 0-2-2]$ .



Iloczyn macierzy – w *WolframAlpha* $\{-2,1,0\},\{0,2,-1\}\cdot\{1,0\},\{0,-1\},\{1,2\}$ 

NATURAL LANGUAGE

MATH INPUT

EXTENDED KEYBOARD

EXAMPLES

UPLOAD

compute input

Input

$$\begin{pmatrix} -2 & 1 & 0 \\ 0 & 2 & -1 \end{pmatrix} \cdot \begin{pmatrix} 1 & 0 \\ 0 & -1 \\ 1 & 2 \end{pmatrix}$$

Result

 Step-by-step solution

$$\begin{pmatrix} -2 & -1 \\ -1 & -4 \end{pmatrix}$$

Dimensions

 Step-by-step solution2 (rows)  $\times$  2 (columns)

## ✦ Iloczyn zewnętrzny wektorów

### Definicja

Wynikiem **iloczynu zewnętrznego** wektora kolumnowego  $|u\rangle$  i wektora wierszowego  $\langle v|$  jest macierz

$$|u\rangle\langle v| = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \begin{bmatrix} y_1 & y_2 & \cdots & y_m \end{bmatrix} = \begin{bmatrix} x_1y_1 & x_1y_2 & \cdots & x_1y_m \\ x_2y_1 & x_2y_2 & \cdots & x_2y_m \\ \vdots & \vdots & \ddots & \vdots \\ x_ny_1 & x_ny_2 & \cdots & x_ny_m \end{bmatrix}.$$



## ✦ Iloczyn zewnętrzny wektorów

### Definicja

Wynikiem **iloczynu zewnętrznego** wektora kolumnowego  $|u\rangle$  i wektora wierszowego  $\langle v|$  jest macierz

$$|u\rangle\langle v| = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \begin{bmatrix} y_1 & y_2 & \cdots & y_m \end{bmatrix} = \begin{bmatrix} x_1y_1 & x_1y_2 & \cdots & x_1y_m \\ x_2y_1 & x_2y_2 & \cdots & x_2y_m \\ \vdots & \vdots & \ddots & \vdots \\ x_ny_1 & x_ny_2 & \cdots & x_ny_m \end{bmatrix}.$$



## Iloczyn zewnętrzny wektorów





## Iloczyn zewnętrzny wektorów (widziany jako iloczyn macierzy)

$$\begin{bmatrix} 2 \\ -1 \\ 2 \end{bmatrix} \begin{bmatrix} 1 & 8 & -4 \end{bmatrix} = \begin{bmatrix} 2 \cdot 1 & 2 \cdot 8 & 2 \cdot (-4) \\ (-1) \cdot 1 & (-1) \cdot 8 & (-1) \cdot (-4) \\ 2 \cdot 1 & 2 \cdot 8 & 2 \cdot (-4) \end{bmatrix} = \begin{bmatrix} 2 & 16 & -8 \\ -1 & -8 & 4 \\ 2 & 16 & -8 \end{bmatrix}$$



## Iloczyn skalarny wektorów



## ✦ Iloczyn skalarny wektorów (widziany jako iloczyn macierzy)

$$\begin{bmatrix} 1 & 8 & -4 \end{bmatrix} \begin{bmatrix} 2 \\ -1 \\ 2 \end{bmatrix} = \begin{bmatrix} 2-8-8 \end{bmatrix} = \begin{bmatrix} -14 \end{bmatrix} = \underline{\underline{-14}}$$



Iloczyn skalarny wektorów – w *WolframAlpha*

Input interpretation

$(1, 8, -4) \cdot (2, -1, 2)$

Result

-14

Number line

Number name

negative fourteen

POWERED BY THE WOLFRAM LANGUAGE



## ✦ Iloczyn skalarny w $n$ -wymiarowej przestrzeni współrzędnych zespolonych

### Definicja

W przestrzeni wektorowej  $\mathbb{C}^n$  iloczyn skalarny definiujemy następującym wzorem:

$$\langle u|v \rangle = \overline{x_1}y_1 + \overline{x_2}y_2 + \dots + \overline{x_n}y_n \quad \text{dla dowolnych } |u\rangle, |v\rangle \in \mathbb{C}^n.$$



Iloczyn skalarny w  $n$ -wymiarowej przestrzeni współrzędnych zespolonych

$$\langle u | = [2+i, -i], \quad |v\rangle = \begin{bmatrix} 1 \\ 1+i \end{bmatrix}$$

$$\begin{aligned} \langle u | v \rangle &= (2-i) \cdot 1 + i(1+i) = \\ &= \cancel{2} - \cancel{i} + i + i^2 = \\ &= 2 - 1 = \underline{1} \end{aligned}$$



# Wyznacznik macierzy



## Wyznacznik macierzy

### Wyznacznik macierzy

To  **pewna liczba (lub ogólniej wartość) przypisywana macierzy kwadratowej  $A$**  i oznaczana symbolem  $\det(A)$  lub  $|A|$ .

Wartość ta jest otrzymywana przez odpowiednie przemnożenie i dodawanie wartości macierzy.





# Wyznacznik macierzy

## Wyznaczniki macierzy wymiarów $1 \times 1$ i $2 \times 2$



Dla  $\mathbf{A} = [a_{11}]$  :  $\det(A) = a_{11}$ .



## Wyznacznik macierzy

### Wyznaczniki macierzy wymiarów $1 \times 1$ i $2 \times 2$

▶

$$\text{Dla } \mathbf{A} = [a_{11}] : \det(\mathbf{A}) = a_{11}.$$

▶

$$\text{Dla } \mathbf{A} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} : \det(\mathbf{A}) = a_{11}a_{22} - a_{21}a_{12}.$$



# Wyznacznik macierzy

$$\begin{vmatrix} 2 & 1 & 0 \\ -1 & 0 & 1 \\ 2 & 3 & -1 \end{vmatrix} = \begin{vmatrix} 2 & 1 & 0 \\ -1 & 0 & 1 \\ 2 & 3 & -1 \end{vmatrix} = \begin{vmatrix} 2 & 1 & 0 \\ -1 & 0 & 1 \\ 2 & 3 & -1 \end{vmatrix} =$$

$= 2 \cdot 0 \cdot (-1) + (-1) \cdot 3 \cdot 0 + 2 \cdot 1 \cdot 1 - 2 \cdot 0 \cdot 0 - 2 \cdot 3 \cdot 1 - (-1) \cdot 1 \cdot (-1) =$   
 $= 2 - 6 - 1 = -5$



## Wyznacznik macierzy – w *Mathematica*

```
In[26]:= MatrixForm[{{2, 1, 0}, {-1, 0, 1}, {2, 3, -1}}]  
|postać macierzy
```

```
Out[26]//MatrixForm=
```

$$\begin{pmatrix} 2 & 1 & 0 \\ -1 & 0 & 1 \\ 2 & 3 & -1 \end{pmatrix}$$

```
In[27]:= Det[{{2, 1, 0}, {-1, 0, 1}, {2, 3, -1}}]  
|wyznacznik
```

```
Out[27]= -5
```

