

---

# Statystyczna Analiza Danych 1

Skrypt do ćwiczeń

Ewa Szczurek  
Michał Ciach  
Magda Gryniewicz  
Anna Macioszek  
Błażej Miasojedow  
Bartosz Piotrowski  
Piotr Pokarowski  
Grzegorz Skoraczyński  
Paulina Urban  
Sem. letni 2018/2019

---

## Spis treści

<b>1</b>	<b>Zmienne losowe</b>	<b>3</b>
1.1	Rozkłady zmiennych losowych . . . . .	3
1.2	Wartość oczekiwana zmiennej losowej . . . . .	4
1.3	Wariancja zmiennej losowej . . . . .	4
1.4	Kwantyle . . . . .	4
<b>2</b>	<b>Ważne rozkłady</b>	<b>4</b>
2.1	Rozkład jednostajny dyskretny ( $\text{Uniform}(n)$ ) . . . . .	5
2.2	Rozkład jednostajny ciągły ( $\text{Uniform}(a, b)$ ) . . . . .	5
2.3	Rozkład zero-jedynkowy ( $\text{Bernoulli}(p)$ ) . . . . .	5
2.4	Rozkład dwumianowy ( $\text{Binomial}(n, p)$ ) . . . . .	5
2.5	Ujemny rozkład dwumianowy ( $\text{NegativeBinomial}(p, r)$ ) . . . . .	6
2.6	Rozkład wielomianowy ( $\text{Multinomial}(n, p_1, \dots, p_k)$ ) . . . . .	6
2.7	Rozkład hipergeometryczny ( $\text{Hypergeometric}(N, M, n)$ ) . . . . .	6
2.8	Rozkład geometryczny ( $\text{Geometric}(p)$ ) . . . . .	7
2.9	Rozkład Poissona ( $\text{Poisson}(\lambda)$ ) . . . . .	7
2.10	Rozkład Poissona-alternatywna definicja ( $\text{Poisson}(\lambda t)$ ) . . . . .	8
2.11	Rozkład wykładniczy ( $\text{Exp}(\lambda)$ ) . . . . .	9
2.12	Rozkład Laplace'a ( $\text{Laplace}(\mu, \sigma)$ ) . . . . .	10
2.13	Rozkład Normalny ( $\text{Normal}(\mu, \sigma^2)$ ) . . . . .	10
2.14	Rozkład $\chi^2$ ( $\text{ChiSquared}(\nu)$ ) . . . . .	11
2.15	Rozkład $t$ -Studenta ( $t(\nu)$ ) . . . . .	11
2.16	Rozkład Snedecora-Fishera $F$ ( $F(\nu_1, \nu_2)$ ) . . . . .	12
2.17	Przydatne funkcje: gamma i beta . . . . .	13
2.18	Rozkład Gamma ( $\text{Gamma}(\lambda, r)$ ) . . . . .	13
2.19	Rozkład Beta ( $\text{Beta}(\alpha, \beta)$ ) . . . . .	13

# 1 Zmienne losowe

Niech dana będzie przestrzeń probabilistyczna  $(\Omega, F, P)$ . Funkcję  $X$  określoną na zbiorze zdarzeń elementarnych  $\Omega$ , o wartościach będących podzbiorem zbioru liczb rzeczywistych

$$X : \Omega \rightarrow Y,$$

$Y \subset \mathbb{R}$  oraz taką, że dla każdego  $t \in \mathbb{R}$  zbiór

$$\{\omega \in \Omega : X(\omega) < t\}$$

jest zdarzeniem, czyli należy do zbioru zdarzeń  $F$ , nazywamy zmienną losową.

Podstawowe typy zmiennych losowych to

- Dyskretna (skokowa): Przyjmuje wartości ze skończonego lub przeliczalnego zbioru, np. wyników rzutu kostką
- Ciągła: Przyjmuje ciągłe wartości ze zbioru  $\mathbb{R}$ , np. pomiarów ekspresji genów

## Przykład 1.1. (Zmienna losowa ciągła)

- Eksperyment: rejestracja czasu  $X$  świecenia losowo wybranej żarówki, do przepalenia.
- $X$  to zmienna losowa o wartościach rzeczywistych nieujemnych.
- Wylosowanie innej żarówki da na ogół inną wartość. Wartości te są przyjmowane z pewnym prawdopodobieństwem, które możemy oszacować, losując i rejestrując odpowiednio dużo razy.

☒

## 1.1 Rozkłady zmiennych losowych

Rozkład zmiennej losowej  $X$  to funkcja  $P_X(A) = P(X^{-1}(A))$ , gdzie  $A$  to dowolny podzbiór zbioru wartości  $Y$ , a  $P$  to miara prawdopodobieństwa określona na zdarzeniach losowych. ( $A \in \mathcal{B}(Y)$ , gdzie  $\mathcal{B}(Y)$  sigma-ciało podzbiorów zbioru wartości zmiennej losowej  $X$ .)

Dystrybuanta zmiennej losowej  $X$  to funkcja dana wzorem

$$F_X(t) = P(\{\omega \in \Omega : X(\omega) \leq t\}) = P_X(\{x : x \leq t\}) = P_X((-\infty, t])$$

Rozkład zmiennej dyskretnej  $X$  zdefiniowany jest przez zbiór par  $x, P_X(x)$ , gdzie  $x \in Y$ : wartość zmiennej  $X$ , a  $P_X(x) = P_X(X = x) = P(\{\omega \in \Omega : X(\omega) = x\})$ : prawdopodobieństwo, że zmienna  $X$  przyjmie wartość  $x$ . Inaczej ujmując

$$P_X(x) = P(X^{-1}(x))$$

Dla dyskretnego rozkładu prawdopodobieństwa mamy

- Dla dowolnego  $A \subset Y$ ,  $P_X(A) = \sum_{x_i \in A} P_X(x_i)$
- $\sum_i P_X(x_i) = 1$

Rozkład zmiennej ciągłej  $X$ , to rozkład  $P_X$  dla którego istnieje funkcja  $f$ , taka że

$$P_X(A) = \int_A f(x) dx$$

zwana funkcją gęstości prawdopodobieństwa.

Dla ciągłego rozkładu prawdopodobieństwa mamy

- $\int_{-\infty}^{\infty} f(x) dx = 1$
- Dystrybuanta  $X$  wyraża się wzorem  $F_X(t) = \int_{-\infty}^t f(x) dx$

## 1.2 Wartość oczekiwana zmiennej losowej

Intuicyjnie ujmując, wartość oczekiwana to wartość określająca spodziewany wynik doświadczenia losowego.

Wartość oczekiwaną zmiennej dyskretnej  $X$  o rozkładzie  $P_X$  definiujemy jako

$$\mathbb{E}(X) = \sum_i x_i P_X(x_i)$$

Wartość oczekiwaną zmiennej ciągłej  $X$  o gęstości rozkładu  $f$  definiujemy zaś jako

$$\mathbb{E}(X) = \int_{-\infty}^{\infty} x f(x) dx.$$

Własności wartości oczekiwanej:

- $\mathbb{E}[aX + bY] = a \mathbb{E}[X] + b \mathbb{E}[Y]$ .
- $\mathbb{E}[\sum_{i=1}^n X_i] = \sum_{i=1}^n \mathbb{E}[X_i]$

## 1.3 Wariancja zmiennej losowej

Intuicyjnie, jest to miara zmienności zmiennej losowej.

Wariancję zmiennej losowej  $X$  liczymy jako średnią kwadratów odchyleń od wartości oczekiwanej.

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

Zachodzi też

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

Własności wariancji:

- $\text{Var}[aX + b] = \mathbb{E}[aX + b - a \mathbb{E}[X] - b]^2 = a^2 \mathbb{E}[X - \mathbb{E}[X]]^2 = a^2 \text{Var}[X]$ .
- dla niezależnych zmiennych losowych  $X_1, \dots, X_n$ ,  $\text{Var}[\sum_{i=1}^n X_i] = \sum_{i=1}^n \text{Var}[X_i]$

## 1.4 Kwantyle

Kwantylem rzędu  $p$  ( $0 < p < 1$ ) dla zmiennej losowej  $X$  typu ciągłego o dystrybuancie  $F$  i gęstości  $f$  nazywamy każdą liczbę  $x_p$  spełniającą którykolwiek z równoważnych warunków:

$$\begin{aligned} F(x_p) &= p \\ P(X \leq x_p) &= p \\ \int_{-\infty}^{x_p} f(x) dx &= p. \end{aligned}$$

Mediana to kwantyl rzędu  $p = 0.5$

## 2 Ważne rozkłady

Rozkłady zmiennych losowych można podzielić na grupy

- Rozkłady jednostajne, dyskretny lub ciągły
- Rozkłady związane ze schematem Bernoulliego, lub losowaniem z bądź bez zwracania: rozkład zero-jedynkowy, dwumianowy, geometryczny i hipergeometryczny
- Rozkłady związane z rozkładem Poissona: Poissona i wykładniczy
- Rozkład normalny, występujący często w naturze, i inne związane z nim: t-Studenta, chi-kwadrat

## 2.1 Rozkład jednostajny dyskretny ( $\text{Uniform}(n)$ )

Zmienna  $X$  o rozkładzie jednostajnym dyskretnym przyjmuje z tym samym prawdopodobieństwem wartości z dowolnego skończonego zbioru. Tutaj oznaczamy go  $\{1, \dots, n\}$ , gdzie parametr  $n$  to liczba całkowita dodatnia.

$$P_X(x) = 1/n, \text{ dla } x = 1, 2, \dots, n$$

$$\mathbb{E}(X) = \frac{n+1}{2}$$

$$\text{Var}(X) = \frac{n^2-1}{12}$$

**Przykład 2.1. (Rzut kostką)**  $n = 6$ ,  $\mathbb{E}(X) = 3.5$ ,  $\text{Var}(X) = \frac{35}{12}$ . ☒

## 2.2 Rozkład jednostajny ciągły ( $\text{Uniform}(a, b)$ )

Zmienna  $X$  o rozkładzie jednostajnym ciągłym przyjmuje wartości z danego przedziału  $[a, b]$  z tym samym prawdopodobieństwem proporcjonalnym do jego długości.

$$P_X(x) = \frac{1}{b-a}, \text{ dla } x \in [a, b]$$

$$\mathbb{E}(X) = \frac{a+b}{2}$$

$$\text{Var}(X) = \frac{(b-a)^2}{12}$$

**Przykład 2.2.** Błąd zaokrąglania do liczb całkowitych na przedziale  $[-0.5, 0.5]$ . ☒

## 2.3 Rozkład zero-jedynkowy ( $\text{Bernoulli}(p)$ )

Zmienna  $X$  o rozkładzie zero-jedynkowym odpowiada próbie Bernoulliego mogącej zakończyć się sukcesem (wartość 1) albo porażką (0).  $X$  przyjmuje wartość 1 z prawdopodobieństwem  $p$  i wartość 0 z prawdopodobieństwem  $1-p$ .

$$P_X(0) = 1-p, P_X(1) = p$$

$$\mathbb{E}(X) = p$$

$$\text{Var}(X) = p(1-p)$$

**Przykład 2.3. (Rzut monetą)**  $p = 1-p = \mathbb{E}(X) = 0.5$ ,  $\text{Var}(X) = 1/4$ . ☒

## 2.4 Rozkład dwumianowy ( $\text{Binomial}(n, p)$ )


Zmienna  $X$  jest sumą wyników w  $n$  próbach Bernoulliego (schemacie Bernoulliego), czyli  $X = x$  oznacza, że w  $n$  próbach było  $x$  sukcesów ( $\text{Binomial}(n, p) = \text{Bernoulli}(p)$ )

$$P_X(x) = \binom{n}{x} p^x (1-p)^{n-x}, \text{ dla } x = 0, 1, \dots, n$$

$$\mathbb{E}(X) = np$$

$$\text{Var}(X) = np(1-p)$$

**Przykład 2.4.** Losowanie ze zwracaniem (po losowaniu odkładam spowrotem) z  $N$  kul, gdzie  $M$  jest białych a  $N-M$  czarnych. Sukces to kula biała. Prawdopodobieństwo sukcesu za każdym losowaniem to  $M/N$ . Losowanie  $n$  razy ze zwracaniem to schemat Bernoulliego. ☒



Rysunek 1: Rozkład dwumianowy. Ilustracja z [https://commons.wikimedia.org/wiki/File:Binomial\\_distribution\\_pmf.svg](https://commons.wikimedia.org/wiki/File:Binomial_distribution_pmf.svg)

## 2.5 Ujemny rozkład dwumianowy (NegativeBinomial( $p, r$ ))

Rozkład liczby prób Bernoulliego (z prawdopodobieństwem sukcesu  $p$  w jednej próbie) potrzebnych do uzyskania pierwszych  $r$  sukcesów.

$$P_X(x) = \binom{x-1}{r-1} (p)^r (1-p)^{x-r}, \text{ dla } x = r, r+1, \dots$$

$$\mathbb{E}(X) = \frac{r}{p}$$

$$\text{Var}(X) = \frac{r(1-p)}{p^2}$$

## 2.6 Rozkład wielomianowy (Multinomial( $n, p_1, \dots, p_k$ ))

Uogólnienie rozkładu dwumianowego. Tutaj zmienna  $X = [X_1, \dots, X_k]^T$  jest  $k$ -wymiarową zmienną, zliczającą ile wypadło wyników  $i$ -tego rodzaju w  $n$  próbach, każdy z prawdopodobieństwem  $p_1, \dots, p_k$ , gdzie  $\sum_i p_i = 1$ . Czyli wartość zmiennej losowej  $x = [x_1, \dots, x_k]^T$  oznacza, że w  $n$  próbach było  $x_i$  wyników typu  $i$ ,  $i \in 1, \dots, k$ , przy czym  $\sum_i x_i = n$  oraz  $x_i = 0, 1, \dots, n$ .

$$P_X([x_1, \dots, x_k]^T) = \binom{n}{x_1 \dots x_k} p_1^{x_1} p_2^{x_2} \dots p_k^{x_k},$$

gdzie  $\binom{n}{x_1 \dots x_k} = n! / (x_1! x_2! \dots x_k!)$ .

$$\mathbb{E}(X_i) = np_i$$

$$\text{Var}(X_i) = np_i(1 - p_i).$$

## 2.7 Rozkład hipergeometryczny (Hypergeometric( $N, M, n$ ))

Rozkład liczby sukcesów w pierwszych  $n$  próbach Bernoulliego, przy założeniu, że w  $N$  próbach będzie  $M$  sukcesów.

$$P_X(x) = \frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}} \text{ dla } x = 0, 1, \dots, n$$

$$\mathbb{E}(X) = np$$

$$\text{Var}(X) = (N-n)(N-1)np(1-p),$$

gdzie  $p = \frac{M}{N}$ .

**Przykład 2.5.** Losowanie bez zwracania (element wylosowany nie wraca z powrotem) z pudełka, w którym jest  $N$  kul, w tym  $M$  kul białych. Losujemy  $n$  kul. Zmienna losowa zliczająca, ile kul białych wylosujemy sięgając po  $n$  kul ma rozkład hipergeometryczny.  $\square$


## 2.8 Rozkład geometryczny ( $Geometric(p)$ )

Rozkład liczby prób Bernoulliego (z prawdopodobieństwem sukcesu  $p$  w jednej próbie) potrzebnych do uzyskania pierwszego sukcesu.

$$P_X(x) = p(1-p)^{x-1}, \text{ dla } x = 1, 2, \dots$$

$$\mathbb{E}(X) = \frac{1}{p}$$

$$\text{Var}(X) = \frac{1-p}{p^2}$$



Rysunek 2: Po lewej: rozkład geometryczny jak zdefiniowany powyżej. Po prawej: rozkład geometryczny w definicji liczby porażek przed pierwszą próbą (wówczas wartości zmiennej losowej geometrycznej to  $x = 0, 1, \dots$ ).

**Przykład 2.6.** Szansa na wygraną w loterii to 1 do 14mln. Jaka jest wartość oczekiwana liczby kuponów, które muszą nabyć, aby wygrać w loterii?  $\square$

## 2.9 Rozkład Poissona ( $Poisson(\lambda)$ )

Rozkład liczby zdarzeń w jednostce czasu przy założeniu że zdarzenia zachodzą jednostajnie w czasie z częstotliwością  $\lambda$ .


$$P_X(x) = \frac{\lambda^x}{x!} e^{-\lambda}, \text{ dla } x = 0, 1, \dots$$

$$\mathbb{E}(X) = \lambda$$

$$\text{Var}(X) = \lambda$$

Mówi się o nim "Prawo małych liczb", gdyż określa rozkład prawdopodobieństwa liczby wystąpień zdarzenia, które zdarza się rzadko ale ma bardzo wiele możliwości, aby się zdarzyć. Rozkład Poissona można wyprowadzić z rozkładu dwumianowego, gdy liczba prób  $n \rightarrow \infty$  i prawdopodobieństwo sukcesu  $p \rightarrow 0$ , tak, że  $np = \lambda$ .

- Niech  $X$  - liczba zdarzeń w danym przedziale czasowym
- Podzielmy ten przedział na bardzo wiele ( $n$ ) bardzo małych podprzedziałów.
- Tak małych, że prawdopodobieństwo zajścia więcej niż jednego zdarzenia jest zaniebdywalne w porównaniu z prawdopodobieństwem  $p$  zajścia jednego zdarzenia (które samo jest bardzo małe).
- Załóżmy, że
  1. zdarzenia w podprzedziałach są niezależne
  2. prawdopodobieństwo zdarzenia jest identyczne w każdym podprzedziale
  3. zdarzenia nie zachodzą naraz
- Rozkład  $X$  będzie przybliżony przez rozkład dwumianowy, z liczbą prób  $n$  równej liczbie podprzedziałów i prawdopodobieństwem sukcesu  $p$ . A ten rozkład z kolei przybliży rozkład Poissona z parametrem  $np$ .



Rysunek 3: Rozkład Poissona. Ilustracja z [https://commons.wikimedia.org/wiki/File:Poisson\\_distribution\\_PMF.png](https://commons.wikimedia.org/wiki/File:Poisson_distribution_PMF.png)

**Przykład 2.7.** Rozkład Poissona: Policz w R Rozważmy dwie kostki rzucone razem 100 razy. Niech  $X$  zmienna losowa odpowiadająca liczbie razy, gdy wypadły dwie szóstki. Rozkład  $X$  to rozkład dwumianowy z  $n = 100$  i  $p = 1/36$ .

- Policz w  $R$  prawdopodobieństwa  $X = k$  dla  $k = 0, \dots, 11$ .
- Przybliżmy ten rozkład rozkładem Poissona z  $\lambda = np$ . Policz te same prawdopodobieństwa w przybliżonym rozkładzie.

☒

## 2.10 Rozkład Poissona-alternatywna definicja ( $Poisson(\lambda t)$ )

Rozkład liczby zdarzeń w przedziale czasowym długości  $t$  przy założeniu że zdarzenia zachodzą jednostajnie w czasie z częstotliwością  $\lambda$ .

$$P_X(x) = \frac{(\lambda t)^x}{x!} e^{-\lambda t}, \text{ dla } x = 0, 1, \dots$$

$$\mathbb{E}(X) = \lambda t$$

$$\text{Var}(X) = \lambda t$$

Powyżej definiowaliśmy przyjmując  $t = 1$ .



## 2.11 Rozkład wykładniczy ( $\text{Exp}(\lambda)$ )


Rozkład czasu, który upłynie do pierwszego zdarzenia, przy założeniu że zdarzenia zachodzą jednostajnie w czasie z częstotliwością  $\lambda$ .

$$f(x) = \lambda e^{-\lambda x}, \text{ dla } x \in [0, \infty)$$

$$\mathbb{E}(X) = 1/\lambda$$

$$\text{Var}(X) = 1/\lambda^2$$

Dystrybuanta rozkładu wykładniczego wyraża się wzorem  $F(x) = \int_{-\infty}^x f(u)du = 1 - e^{-\lambda x}$  dla  $x \geq 0$  i  $F(x) = 0$  dla  $x < 0$ .



Rysunek 4: Rozkład wykładniczy. Ilustracja z [https://upload.wikimedia.org/wikipedia/commons/b/b1/Exponential\\_distribution\\_pdf.png](https://upload.wikimedia.org/wikipedia/commons/b/b1/Exponential_distribution_pdf.png)

Rozkład wykładniczy ma własność braku pamięci (patrz zadania).  
Rozkład wykładniczy ściśle wiąże się z rozkładem Poissona.

- Weźmy rozkład Poissona z parametrem  $\lambda$  odpowiadający liczbie zdarzeń w jednostce czasu.
- Załóżmy, że zdarzenie następuje w chwili  $t_0$ .
- Niech zmienna  $T$  oznacza czas do następnego zdarzenia.
- Rozkład  $T$  można wyznaczyć z prawdopodobieństwa

$$P(T > t) = P(\text{ w przedziale } (t_0, t_0 + t) \text{ nie zaszło żadne zdarzenie}).$$

- Liczba zdarzeń w przedziale  $(t_0, t_0 + t)$  długości  $t$  zadana jest rozkładem Poissona z parametrem  $\lambda t$ 
  - a zatem to prawdopodobieństwo wynosi  $e^{-\lambda t} =$
  - $= 1 -$  dystrybuanta rozkładu wykładniczego z parametrem  $\lambda$
  - czyli rozkład  $T$  to wykładniczy z parametrem  $\lambda$ .
- W ogólności, czasy pomiędzy kolejnymi zdarzeniami w rozkładzie Poissona( $\lambda$ ), to niezależnie i identycznie rozłożone zmienne losowe o rozkładzie wykładniczym z parametrem  $\lambda$ .

## 2.12 Rozkład Laplace'a ( $Laplace(\mu, \sigma)$ )

Funkcja gęstości prawdopodobieństwa dla rozkładu Laplace'a wyraża się wzorem

$$f(x; \mu, \sigma) = \frac{1}{2\sigma} \exp\left(-\frac{|x - \mu|}{\sigma}\right),$$


gdzie  $\mu \in \mathbb{R}$ ,  $\sigma \in \mathbb{R}$ .

$$\mathbb{E}(X) = \mu$$

$$\text{Var}(X) = 2\sigma^2$$

Dystrybuanta

$$F(x) = \begin{cases} 1 - \frac{1}{2} \exp\left(-\frac{x - \mu}{\sigma}\right), & \text{dla } x \geq \mu \\ \frac{1}{2} \exp\left(\frac{x - \mu}{\sigma}\right), & \text{dla } x < \mu \end{cases}$$



Rysunek 5: Rozkład Laplace'a-wykres gęstości. Ilustracja z [https://upload.wikimedia.org/wikipedia/commons/thumb/0/0a/Laplace\\_pdf\\_mod.svg/500px-Laplace\\_pdf\\_mod.svg.png](https://upload.wikimedia.org/wikipedia/commons/thumb/0/0a/Laplace_pdf_mod.svg/500px-Laplace_pdf_mod.svg.png)

## 2.13 Rozkład Normalny ( $Normal(\mu, \sigma^2)$ )

Zwany także rozkładem Gaussowskim. Parametry: średnia  $\mu \in \mathbb{R}$ , wariancja  $\sigma^2 \in \mathbb{R}_+$ , z dodatnim pierwiastkiem (odchylenie standardowe).


$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right), \text{ dla } x \in \mathbb{R}$$

$$\mathbb{E}(X) = \mu$$


$$\text{Var}(X) = \sigma^2$$

Rozkład normalny standardowy ma średnią  $\mu = 0$  i wariancję  $\sigma^2 = 1$ . Stąd, jego funkcja gęstości to

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}, \text{ dla } x \in \mathbb{R}$$



Rysunek 6: Rozkład normalny-wykres gęstości. Ilustracja z [https://upload.wikimedia.org/wikipedia/commons/thumb/7/74/Normal\\_Distribution\\_PDF.svg/1000px-Normal\\_Distribution\\_PDF.svg.png](https://upload.wikimedia.org/wikipedia/commons/thumb/7/74/Normal_Distribution_PDF.svg/1000px-Normal_Distribution_PDF.svg.png)



Rysunek 7: Rozkład normalny-Reguła empiryczna. Ilustracja z [https://upload.wikimedia.org/wikipedia/commons/a/a9/Empirical\\_Rule.PNG](https://upload.wikimedia.org/wikipedia/commons/a/a9/Empirical_Rule.PNG)

## 2.14 Rozkład $\chi^2$ ( $\text{ChiSquared}(\nu)$ .)

Rozkład sumy kwadratów  $\nu$  niezależnych rozkładów standardowych normalnych. Parametr  $\nu$  jest liczbą całkowitą dodatnią i zwany jest stopniem swobody.

$$f(x) = \frac{x^{\nu/2-1} e^{-x/2}}{2^{\nu/2} \Gamma(\nu/2)} \text{ dla } x \geq 0$$


$$\mathbb{E}(X) = \nu$$

$$\text{Var}(X) = 2\nu$$

## 2.15 Rozkład $t$ -Studenta ( $t(\nu)$ .)

Rozkład wartości zmiennej  $X$  gdy  $X = \frac{Y}{\sqrt{Z/\nu}}$  dla zmiennej  $Y$  standardowej normalnej  $Y \sim \text{Normal}(0,1)$  i  $Z \sim \text{ChiSquared}(\nu)$ . Parametr  $\nu$  jest liczbą całkowitą dodatnią i zwany jest stopniem swobody.

$$f(x) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\pi\nu}\Gamma\left(\frac{\nu}{2}\right)(1+x^2/\nu)^{(\nu+1)/2}} \text{ dla } x \in \mathbb{R}$$

Rysunek 8: Rozkład  $\chi^2$  - wykres gęstości. Ilustracja z Wikipedia

$$\mathbb{E}(X) = \nu$$

$$\text{Var}(X) = \frac{2\nu}{\nu - 2}$$

Zastosowania rozkładów  $\chi^2$  i  $t$  – *Studenta* w statystyce odkrywamy na następnych wykładach.


## 2.16 Rozkład Snedecora-Fishera $F$ ( $F(\nu_1, \nu_2)$ )

Rozkład zmiennej  $X = \frac{Y/\nu_1}{Z/\nu_2}$ , dla  $Y$  i  $Z$  niezależnych zmiennych  $\sim \chi^2$  ze stopniami swobody  $\nu_1$  i  $\nu_2$ .

$$f(x) = \frac{1}{B(\nu_1/2, \nu_2/2)} \frac{\left(\frac{\nu_1}{\nu_2}\right)^{\nu_1/2} x^{\nu_1/2-1}}{\left(1 + \frac{\nu_1}{\nu_2}x\right)^{(\nu_1+\nu_2)/2}} \text{ dla } x > 0.$$

$$E(X) = \frac{\nu_2}{\nu_2 - 2} \text{ dla } \nu_2 > 2$$

$$\text{Var}(X) = \frac{2\nu_2^2(\nu_1 + \nu_2 - 2)}{\nu_1(\nu_2 - 2)^2(\nu_2 - 4)} \text{ dla } \nu_2 > 4$$

Rysunek 9: Rozkład Snedecora-Fishera  $F$ . Tutaj  $d_1 = \nu_1$  i  $d_2 = \nu_2$ . Wikipedia

## 2.17 Przydatne funkcje: gamma i beta

O funkcjach gamma i beta można myśleć jak o odpowiednio ciągłych wersjach silni  $n!$  i symbolu Newtona  $\binom{n}{k}$ .

Funkcja Beta  $B(\alpha, \beta)$  zdefiniowana jest na liczbach dodatnich  $\alpha, \beta > 0$  jako

$$B(\alpha, \beta) = \int_0^1 t^{\alpha-1}(1-t)^{\beta-1} dt = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha+\beta)}.$$

Dla  $\alpha$  i  $\beta$  dodatnich całkowitych

$$B(\alpha, \beta) = \frac{(\alpha-1)!(\beta-1)!}{(\alpha+\beta-1)!}$$

Funkcja Gamma  $\Gamma(x): \mathbb{R}_+ \rightarrow \mathbb{R}$  zdefiniowana jest na liczbach dodatnich  $x > 0$

$$\Gamma(x) = \int_0^{\infty} t^{x-1} e^{-t} dt$$

Ponieważ  $\Gamma(x+1) = x\Gamma(x)$  i  $\Gamma(1) = 1$ , dla dodatniego całkowitego  $x$  zachodzi

$$\Gamma(x) = (x-1)!$$

## 2.18 Rozkład Gamma (Gamma( $\lambda, r$ ))

Rozkład czasu, który upłynie do pierwszych  $r$  zdarzeń, przy założeniu że zdarzenia zachodzą jednostajnie w czasie z częstotliwością  $\lambda$ .

$$f(x) = \frac{1}{\Gamma(r)} \lambda^r x^{r-1} e^{-\lambda x}, \text{ dla } x \in [0, \infty)$$

$$\mathbb{E}(X) = r/\lambda$$

$$\text{Var}(X) = r/\lambda^2$$

## 2.19 Rozkład Beta (Beta( $\alpha, \beta$ ))

Rozkład tej części jednostki czasu, który upłynie do pierwszych  $\alpha$  zdarzeń, przy założeniu że zachodzi  $\alpha + \beta$  zdarzeń na jednostkę czasu (jednostajnie tak jak w rozkładzie Poissona).

$$f(x) = \frac{x^\alpha(1-x)^{\beta-1}}{B(\alpha, \beta)}, \text{ dla } x \in [0, 1]$$

$$\mathbb{E}(X) = \frac{\alpha}{(\alpha + \beta)}$$

$$\text{Var}(X) = \frac{\alpha\beta}{(\alpha + \beta)^2(\alpha + \beta + 1)}$$