



# Komputerowa analiza danych doświadczalnych

Wykład podsumowujący  
21.05.2021

dr inż. Łukasz Graczykowski  
[lukasz.graczykowski@pw.edu.pl](mailto:lukasz.graczykowski@pw.edu.pl)

*Semestr letni 2020/2021*



# Parametry rozkładów prawdopodobieństwa


## Generowanie liczb i metody Monte Carlo

## Dopasowanie modelu do danych


## Testy statystyczne

# Statystyczna analiza danych

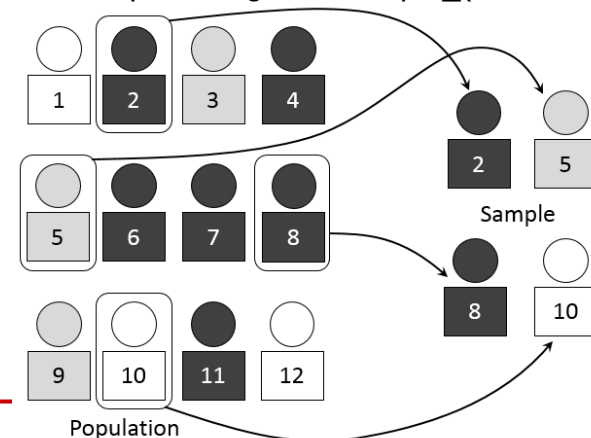
- Statystyczna analiza danych:
  - traktujemy pomiar jako pewien element zbioru wszystkich możliwych pomiarów (pewnej cechy **populacji** o danym rozkładzie prawdopodobieństwa – najczęściej nieznanym)
  - na podstawie skończonej liczby pomiarów, obserwacji (**próby losowej**, podzbioru populacji), która ma swój rozkład prawdopodobieństwa (znany z pomiarów czy obserwacji), próbujemy dowiedzieć się czegoś (czyli **estymować**) na temat parametrów rozkładu całej populacji
  - innymi słowy, na podstawie próby losowej (pomiarów, obserwacji) stawiamy hipotezy i wyciągamy wnioski dotyczące interesującej nas cechy całej populacji



<https://www.proprofs.com/quiz-school/story.php?title=3d-q-sampling-distributions>



[https://en.wikipedia.org/wiki/Sample\\_\(statistics\)](https://en.wikipedia.org/wiki/Sample_(statistics))



# Rozkłady 1D - momenty

$$m_l = E(X^l) = \int_{-\infty}^{\infty} x^l f(x) dx \quad \text{momenty zwykłe}$$

$$m_1 = \mu = E(X) = \int_{-\infty}^{\infty} x f(x) dx$$


$$\mu_l = E((X - \hat{x})^l) \quad \text{momenty centralne}$$

$$\mu_2 \equiv \sigma^2(X) \equiv E((X - \hat{x})^2) = \int_{-\infty}^{\infty} (x - \hat{x})^2 f(x) dx$$

$$\gamma = \frac{\mu_3}{\sigma^3} \quad K = \frac{\mu_4}{\sigma^4} - 3 \quad \text{wsp. asymetrii, kurtoza}$$

## Procent osób zarabiających dane kwoty brutto

Na podstawie danych GUS za 2010 rok, like-a-geek.jogger.pl




[http://lh3.ggpht.com/-UhjcSGuME9Q/UgCqCj00\\_nl/AAAAAAAAAWXU/-0ZlMA9pPnU/image\\_thumb%25255B2%25255D.png?imgmax=800](http://lh3.ggpht.com/-UhjcSGuME9Q/UgCqCj00_nl/AAAAAAAAAWXU/-0ZlMA9pPnU/image_thumb%25255B2%25255D.png?imgmax=800)

Skewness is the asymmetry of a distribution. A positively skewed distribution has a "tail" pulled in the positive direction. A negatively skewed distribution has a "tail" pulled in the negative direction. Most stock-market returns are negatively skewed.



### NORMAL NOT ALWAYS THE NORM

Kurtosis refers to how peaked the curve is: steeper means positive kurtosis and flatter means negative kurtosis. Fat tails occur when there are more outside returns on the downside or upside, or both, than the normal curve suggests.



dominanta

$$P(X = x_{max}) = \max$$

$$\frac{df(x)}{dx} = 0 \quad \frac{d^2 f(x)}{dx^2} < 0$$

**Momenty to uśrednienia danych podniesione do kolejnych potęg**

<http://www.advisor.ca/wp-content/uploads/2012/07/normal-not-always-the-norm.gif>

# Rozkłady 1D – kwantyle

- **Mediana** dzieli rozkład prawdopodobieństwa na dwa obszary o równym prawdopodobieństwie

$$F(x_{0,5}) = P(X < x_{0,5}) = 0,5$$

- Mediana  $x_{0,5}$  jest **kwantylem** (*ang. quantile*) rzędu 0,5

- Ogólna definicja **kwantylu rzędu  $q$** ,  $x_q$ :  $F(x_q) = P(X < x_q) = q$

- **kwartył dolny**  $x_{0,25}$

- **kwartył górny**  $x_{0,75}$

- **decyle**  $x_{0,1}, x_{0,2}, \dots, x_{0,9}$


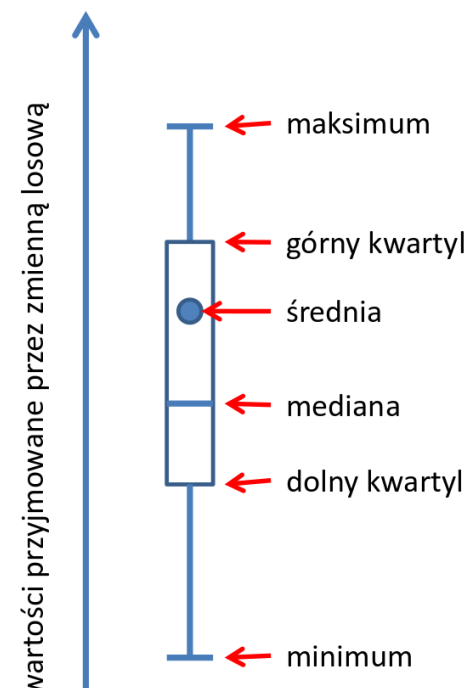
- funkcja  $x_q(q)$  jest funkcją odwrotną do dystrybuanty

$$F(x_q) = \int_{-\infty}^{x_q} f(x) dx = q, q \in \langle -1; 1 \rangle$$

- Kwantyl rzędu  $q$  jest taką liczbą  $x_q$ , że  $q \cdot 100\%$  elementów w danej próbkce (populacji) ma wartość pomiaru (badanej cechy) nie większą niż  $x_q$

- W przypadku ogonów rozkładu kwantyle mogą być lepszą wielkością niż momenty

- **Momenty i kwantyle to dwa najczęstsze opisy numeryczne danych liczbowych**



# Rozkłady 2D

## momenty

$$\lambda_{10} = E(x) = \hat{x}$$

$$\lambda_{01} = E(y) = \hat{y}$$

$$\mu_{11} = E((X - \hat{x})(Y - \hat{y})) = cov(X, Y)$$

$$\mu_{20} = E((X - \hat{x})^2) = \sigma^2(X)$$

$$\mu_{02} = E((Y - \hat{y})^2) = \sigma^2(Y)$$

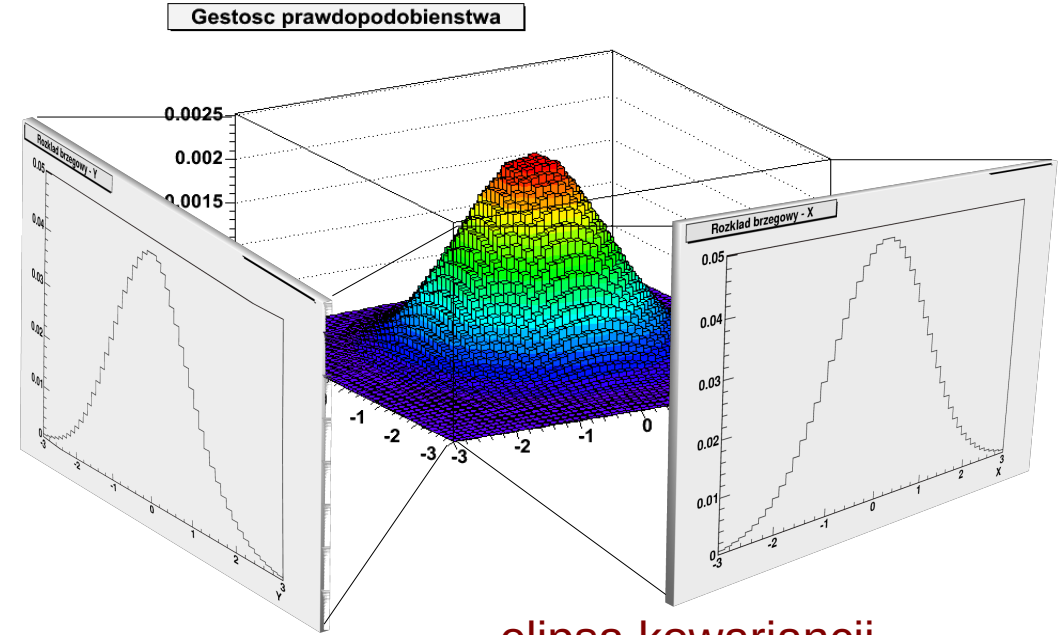
## kowariancja

$$cov(X, Y) = \mu_{11} = E(X \cdot Y) - E(X) \cdot E(Y)$$






## wsp. korelacji (Pearsona)

$$\rho(X, Y) = \frac{cov(X, Y)}{\sigma(X)\sigma(Y)} \quad -1 \leq \rho(X, Y) \leq 1$$

Współczynnik korelacji a liniowa zależność zmiennych (niekoniecznie **przyczyna-skutek**)



## elipsa kowariancji



# Generatory liczb pseudolosowych

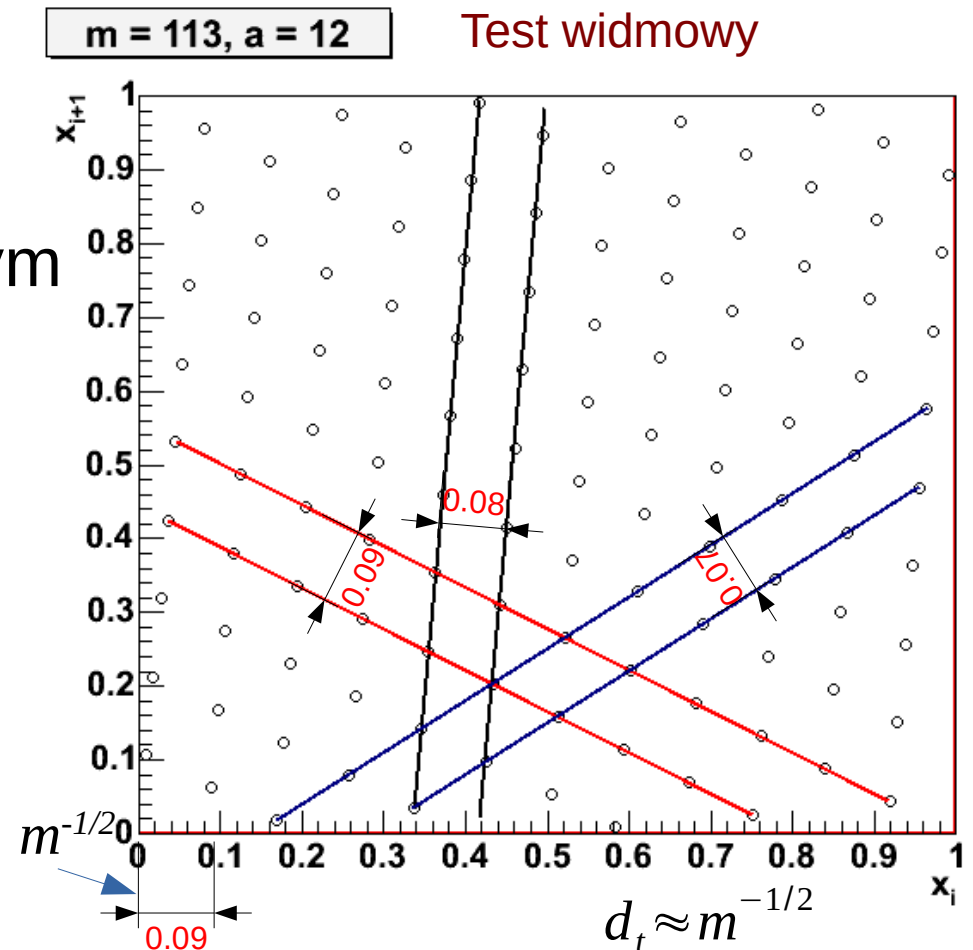
- Komputer, urządzenie deterministyczne, może generować tylko liczby pseudolosowe
  - kolejna generowana liczba jest funkcją liczb wcześniej wygenerowanych
  - *ziarno (seed)* – wartość początkowa (można ją ustalić np. z zegara systemowego)
- Generujemy liczby z jednakowym prawdopodobieństwem (rozkład jednorodny)

Liniowy kongruentny generator liniowy (LCG)

$$x_{j+1} = (a \cdot x_j + c) \bmod m$$


Multiplikacyjny liniowy kongruentny generator liniowy (MLCG)

$$x_{j+1} = (a \cdot x_j) \bmod m$$



# Transformacja rozkładu jednorodnego

- **Metoda odwrotnej dystrybuanty**
- Transformację rozkładu jednostajnego możemy wykorzystać do generowania liczb losowych o skomplikowanych gęstościach prawdopodobieństwa



$$f(x) dx = g(y) dy$$

$$\text{gdy } f(x) \equiv 1 \Rightarrow dx = g(y) dy = dG(y)$$

$$g(y) = G'(y)$$

↑  
dystrybuanta

$$\int dx = \int dG(y)$$

$$x = G(y)$$

↖ musi istnieć

$$y = G^{-1}(x) \equiv H(x)$$

$$x_{min} = G(y_{min}), x_{max} = G(y_{max})$$

$$y_{min} = G^{-1}(0), y_{max} = G^{-1}(1)$$

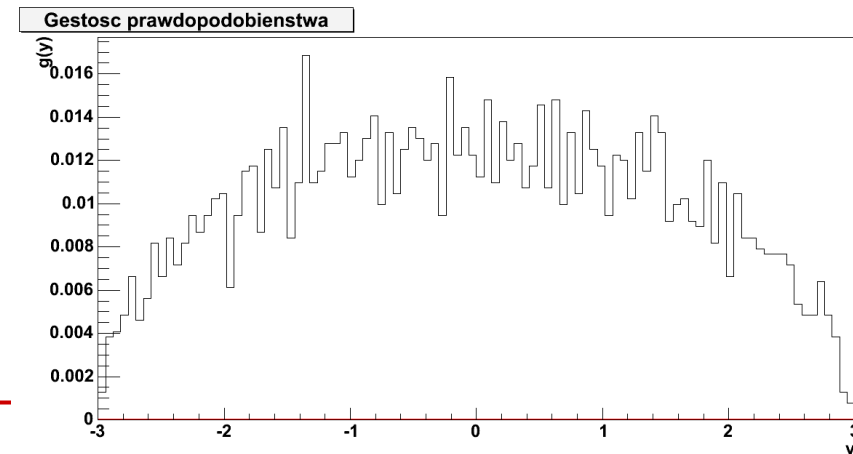

Czyli: liczymy dystrybuantę  $G(y)$   
a następnie funkcję odwrotną  $G^{-1}(y)$

Zmienna losowa  $X$  po transformacji  
 $y = G^{-1}(x)$  ma rozkład  $g(y)$



# Metoda (akceptacji) von Neumanna




- Metoda generacji liczb metodą odwrotnej dystrybuanty ma swoje ograniczenia – dystrybuanta musi być znana (i być funkcją wzajemnie jednoznaczną), czyli musi istnieć funkcja odwrotna
- Metoda (akceptacji-odrzuceń) von Neumanna wymaga znajomości jedynie gęstości prawdopodobieństwa i pozwala na otrzymanie liczb z praktycznie dowolnego rozkładu
- Jak to działa?
  - generujemy parę liczb z rozkładu jednorodnego:  $(y_i, u_i)$
  - sprawdzamy, czy  $u_i < g(y_i)$
  - jeśli warunek jest spełniony, akceptujemy liczbę  $y_i$ ,  
jeśli nie - odrzucamy



# Metoda von Neumanna z funkcją pom.


- Wydajność metody von Neumanna można poprawić, jeśli odpowiednio zawężymy obszar losowania:
  - wprowadzamy funkcję pomocniczą  $s(y)$ , z której “łatwo” wygenerować zmienne losowe (np. metodą odwrotnej dystrybuanty), i która spełnia warunek:  $g(y) \leq c \cdot s(y)$ ,  $a < y < b$
  - generujemy liczbę losową  $y_i$  z rozkładu  $s(y)$  na przedziale  $a < y_i < b$  oraz liczbę  $u_i$  z rozkładu jednorodnego na przedziale  $0 < u_i < 1$
  - odrzucaamy liczbę  $y_i$ , jeżeli:  $u_i \geq \frac{g(y_i)}{c \cdot s(y_i)}$
  - wydajność metody:

$$E = \frac{\int_a^b g(y) dy}{c \int_a^b s(y) dy}$$




# Centralne twierdzenie graniczne

- Wyobraźmy sobie eksperyment polegający na rzucie kostką (kostkami) i obserwowaniu całkowitej liczby oczek:
  - kolejne rzuty kostką (kostkami) są niezależne
  - jeśli rzucamy kostką jednokrotnie (albo 1 kostką), to prawdopodobieństwo uzyskania danej wartości jest jednakowe
  - jeśli rzucamy kostką dwukrotnie (albo 2 kostkami), to prawdopodobieństwo uzyskania sumy oczek nie jest już jednakowe
  - jeśli rzucimy kostką  $n$ -krotnie ( $n$ -kostkami)  $\rightarrow$  rozkład normalny



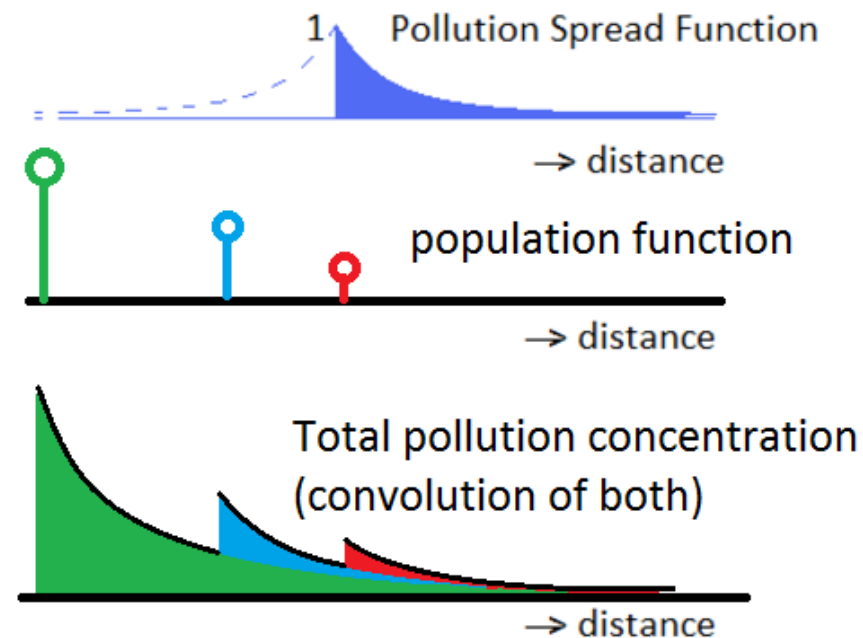
# Centralne twierdzenie graniczne



# Suma zmiennych losowych jako splot

<https://www.quora.com/The-density-function-of-the-sum-of-two-random-variables-is-the-convolution-of-their-respective-densities-What-is-the-intuition-behind-this>

- Wyobraźmy sobie taką sytuację:
  - Mieszkaś w wiosce obok rzeki
  - Mieszkańcy wioski wrzucają do rzeki odpady biologiczne
  - Koncentracja odpadów w funkcji odległości od miejsca zrzutu (*Pollution Spread Function, PSF*) jest zależna od ich rozkładu przez mikroorganizmy w rzece
  - Ilość wrzucanych odpadów zależy od populacji miejscowości na rzece



- Jaka jest pełna funkcja opisująca poziom zanieczyszczeń w rzece?
- Jest to **splot** dwóch rozkładów – funkcji populacji oraz funkcji koncentracji odpadów
- Innymi słowy, zastępujemy każdy punkt w funkcji populacji przez funkcję koncentracji przeskalowaną przez wagę funkcji populacji

# Suma zmiennych losowych jako splot

- Przypadek splotu dwóch rozkładów jednorodnych:

$$f_x(x) = \begin{cases} 1, & 0 \leq x < 1 \\ 0, & \text{w przeciwnym razie} \end{cases} \quad f_y(y) = \begin{cases} 1, & 0 \leq y < 1 \\ 0, & \text{w przeciwnym razie} \end{cases}$$


$$f(u) = \int_0^1 f_x(x) f_y(u-x) dx = \int_0^1 f_y(u-x) dx \quad \begin{matrix} v = u-x \\ dv = -dx \end{matrix} \Rightarrow f(u) = - \int_u^{u-1} f_y(v) dv = \int_{u-1}^u f_y(v) dv$$

- Zmienna  $u$  zmienia się od 0 do 2, zatem rozważmy 2 przypadki:

$$(a) \quad 0 \leq u < 1: f_1(u) = \int_0^u f_y(v) dv = \int_0^u 1 dv = u$$

$$(b) \quad 1 \leq u < 2: f_2(u) = \int_{u-1}^1 f_y(v) dv = \int_{u-1}^1 1 dv = 2 - u$$

- Zgodnie z CTG – im więcej rozkładów w splocie, tym bardziej rozkład sumy przypomina rozkład Gaussa:



# Estymatory

- Typowy problem analizy danych: znamy (np. z prawa fizycznego) ogólną postać gęstości prawdopodobieństwa w danej populacji, należy “jedynie” wyznaczyć parametry tego rozkładu. Przykład:
  - mierzymy rozpad radioaktywny w czasie:  $N(t) = N_0(1 - \exp(-\lambda t))$
  - parametr  $\lambda$  wyznaczamy na podstawie próby – mierząc skończoną ilość razy ilość rozpadów w czasie → wynik nigdy nie będzie dokładny, bo próba jest skończona, mamy problem **estymacji parametrów**
  - poszukiwana wielkość uzyskiwana jest funkcją elementów próby (**statystyką**) i jest nazywana **estymatorem**:  $S = S(X_1, X_2, \dots, X_n)$
  - estymator jest **nieobciążony**, jeżeli niezależnie od liczebności próby jego wartość oczekiwana jest równa wartości estymowanego parametru:

$$E(S(X_1, X_2, \dots, X_n)) = \lambda, \text{ dla każdego } n$$

- estymator jest **zgodny**, jeżeli jego wariancja znika:

$$\lim_{n \rightarrow \infty} \sigma(S(X_1, X_2, \dots, X_n)) = 0$$

# Estymator wartości oczekiwanej

## Populacja

- opisana funkcją gęstości:

$$f(x) = P(X=x)$$

- posiada **wartość oczekiwaną**:

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

- wartość oczekiwana rozkładu to **jedna liczba**
  - nie jest zmienną losową
  - chcemy ją zmierzyć doświadczalnie

- np. dla rozkł. Gaussa:

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

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

## Próba losowa

- zakładamy, że **średnia arytmetyczna** z elementów próby jest estymatorem wartości oczekiwanej

- **średnia arytmetyczna** jest statystyką:

$$\bar{X} = \frac{1}{n} (X_1 + X_2 + \dots + X_n)$$

- **jest zmienną losową** (zależy od elementów próby)
- posiada swoją **wartość oczekiwaną** oraz **wariancję**
- oczekujemy, że będzie ona *estymatorem nieobciążonym* i *zgodnym* wartości oczekiwanej populacji:

$$E(\bar{X}) = E(X) = \hat{x}, \text{ dla każdego } n$$

$$\lim_{n \rightarrow \infty} \sigma(\bar{X}) = 0$$

- **Na wykładzie pokazane jest jak to sprawdzić**



# Estymatory - podstawowe

- Przykładowe **estymatory nieobciążone**:

- **wartości oczekiwanej populacji** → **średnia arytmetyczna z próby**:

$$\bar{X} = \frac{1}{n} (X_1 + X_2 + \dots + X_n)$$

- **wariancji populacji** → **średnia odchyłeń kwadratowych**:

$$S^2(X) = \frac{1}{n-1} ((X_1 - \bar{X})^2 + (X_2 - \bar{X})^2 + \dots + (X_n - \bar{X})^2) \quad \text{-1 wynika z jednego równania więzów (istnienie średniej)}$$

- **Wariancje (niepewności) estymatorów**:

- **wariancja średniej arytmetycznej**:

$$\sigma^2(\bar{X}) = \frac{1}{n} S^2(X) = \frac{1}{n(n-1)} \sum_{i=1}^n (X_i - \bar{X})^2$$

- **wariancja średniej odchyłeń kwadratowych**:

$$\sigma^2(S^2(X)) = S^4(X) \left( \frac{2}{n-1} \right)$$

- **Uwaga!** Wariancje estymatorów są również estymatorami – możemy więc liczyć np. wariancję wariancji średniej arytmetycznej, itd.

# Metoda największej wiarygodności

- **Funkcją wiarygodności** nazywamy iloczyn postaci:

$$L = \prod_{j=1}^N f(\mathbf{X}^{(j)}; \boldsymbol{\lambda})$$



- **Jak wyznaczyć maksimum?**

– **warunek konieczny: przyrównać pierwszą pochodną  $L$  do zera**

- Różniczkowanie iloczynu jest jednak niewygodne, wprowadzamy więc **logarytm funkcji wiarygodności  $L$ :**

$$l = \ln L = \sum_{j=1}^N \ln f(\mathbf{x}^{(j)}; \boldsymbol{\lambda})$$

- **Funkcją wiarygodności** jest odpowiednikiem gęstości prawdopodobieństwa, tylko określona dla parametrów. Ponieważ jest funkcją próby losowej, jest również zmienną losową



**równania wiarygodności**

$$\frac{\partial l}{\partial \lambda_i} = 0, \quad i = 1, 2, \dots, p$$

# Przykład – estymacja rozkładu norm.

- **Przykład:** badamy rozkład wagi studentów
  - rozkład wagi studentek w populacji jest opisany rozkładem normalnym o wartości średniej  $\mu$  i wariancji  $\sigma^2$
  - założmy, że wybraliśmy  $N=10$  reprezentantów, których wagi (w kg)  $X^{(j)}$  układają się następująco:
    - 52,2 55,3 59,0 57,6 67,6 72,6 68,9 62,6 67,6 81,6
  - **Zadanie:** na podstawie wyniku pomiaru znajdź najbardziej wiarygodną estymację parametrów rozkładu
  - oczywiście funkcja rozkładu prawdopodobieństwa każdego wyniku (wagi studentek) dana jest wzorem:
  - konstruujemy funkcję wiarygodności:

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

$$L(\hat{\mu}, \hat{\sigma}) = \sigma^{-n} (2\pi)^{-n/2} \exp\left[-\frac{1}{2\hat{\sigma}^2} \sum_{j=1}^N (x^{(j)} - \hat{\mu})^2\right]$$

# Przykład – estymacja rozkładu norm.

- oraz logarytmiczną funkcję wiarygodności:

$$l(\hat{\mu}, \hat{\sigma}) = \ln L(\hat{\mu}, \hat{\sigma}) = \ln \left( \hat{\sigma}^{-N} (2\pi)^{-n/2} \left[ -\frac{1}{2\hat{\sigma}^2} \sum_{j=1}^N (x^{(j)} - \hat{\mu})^2 \right] \right) = -\frac{1}{2\hat{\sigma}^2} \sum_{j=1}^N (x^{(j)} - \hat{\mu})^2 + \text{const}$$

- równania wiarygodności:

$$\frac{dl(\hat{\mu}, \hat{\sigma})}{d\hat{\mu}} = 0 \quad \frac{dl(\hat{\mu}, \hat{\sigma})}{d\hat{\sigma}} = 0$$

$$\frac{dl(\hat{\mu}, \hat{\sigma})}{d\hat{\mu}} = \frac{-2 \sum_{j=1}^N (x^{(j)} - \hat{\mu})(-1)}{2\hat{\sigma}} = 0 \Rightarrow \sum_{j=1}^N (x^{(j)}) - N\hat{\mu} = 0 \Rightarrow \hat{\mu} = \frac{\sum_{j=1}^N x^{(j)}}{n}$$

$$\frac{dl(\hat{\mu}, \hat{\sigma})}{d\hat{\sigma}} = -\frac{n}{2\hat{\sigma}} + \frac{\sum_{j=1}^N (x^{(j)} - \hat{\mu})}{2\hat{\sigma}^2} = 0 \Rightarrow \hat{\sigma}^2 = \frac{\sum_{j=1}^N (x^{(j)} - \hat{\mu})^2}{n}$$

padło mailowo pytanie, czemu nie n-1

- estymatorem największej wiarygodności jest **obciążony** estymator wariancji

- dla formalności powinniśmy jeszcze sprawdzić drugie pochodne...

# Estymatory obciążone

- Czasem nie da się wyznaczyć estymatora nieobciążonego: jaki jest warunek osiągnięcia minimalnej wariancji?

- Można pokazać (Brandt), że zajdzie tak, gdy:  $E(S) = B(\lambda) + \lambda$

$$I' = A(\lambda)(S - E(S)) \quad I = B(\lambda)S + C(\lambda) + D \quad L = d \exp(B(\lambda)S + C(\lambda))$$

- Wtedy w przypadku estymatora nieobciążonego o minimalnej wariancji otrzymujemy:

$$\sigma^2(S) = \frac{1}{I(\lambda)} = \frac{1}{E(I'^2)}$$

$$\sigma^2(S) = \frac{1}{|A(\lambda)|}$$

- Estymatory spełniające powyższe warunki nazywamy **estymatorami o najniższej wariancji**

- Przykład – rozkład Poissona:  $f(k) = \frac{\lambda^k}{k!} e^{-\lambda}$

$$\frac{dl}{d\lambda} = I' = \sum_{j=1}^N \left\{ \frac{k^{(j)}}{\lambda} - 1 \right\} =$$

$$\frac{1}{\lambda} \sum_{j=1}^N \{k^{(j)} - \lambda\} = \frac{N}{\lambda} (\bar{K} - \lambda)$$

$$\tilde{\lambda} = \bar{K}, \quad \sigma^2(\bar{K}) = \frac{N}{\lambda}$$

$$I' = A(\lambda)(\tilde{\lambda} - \lambda) \quad \sigma^2(S) = \frac{1}{|A(\lambda)|}$$

# Rozkład $\chi^2$ – zastosowanie

- Rozkład  $\chi^2$  stosuje się jako **miarę ufności** uzyskanego wyniku (**odchylenia elementów próby od wartości średniej populacji**). Im mniejsza wartość  $\chi^2$  tym pozornie słuszniejszy wynik. Jako miary zaufania do wyniku używa się wielkości:

$$f(\chi^2) = k \cdot (\chi^2)^{\lambda-1} e^{-1/2\chi^2} \quad k = \frac{1}{\Gamma(\lambda) 2^\lambda} \quad W(\chi^2) = 1 - F(\chi^2) \equiv p = 1 - \alpha$$

nazywanej **poziomem ufności** (zwykle podawanym w % ilości odchyżeń standardowych rozkładu normalnego  $\sigma$ )

– wielkość  $\alpha$  jest nazywana **poziomem istotności**

- W rzeczywistych przypadkach mamy do czynienia z pełnym rozkładem Gaussa o dowolnym  $a$  i  $\sigma$ . Wprowadzamy wtedy odpowiednie przeskalowanie

elementy próby losowej

$$\chi^2 = X^2 = \frac{(X_1 - a)^2 + (X_2 - a)^2 + \dots + (X_n - a)^2}{\sigma^2}$$

- a w ogólnym przypadku wielowymiarowym, gdy zmienne są zależne:



$$\chi^2 = X^2 = (\mathbf{X} - \mathbf{a})^T \mathbf{B} (\mathbf{X} - \mathbf{a})$$

# Rozkład $\chi^2$ a estymator wariancji

- Można udowodnić, że zmienna losowa:  $\frac{n-1}{\sigma^2} S^2$  ← estymator wariancji

ma rozkład  $\chi^2$  z  $f=n-1$  stopniami swobody. Wynika to stąd, że wyrażenia  $(X_i - \bar{X})^2$  nie są liniowo niezależne (co już wiemy). Każde dodatkowe równanie (więzy) pomiędzy wyrażeniami  $(X_i - \bar{X})^2$  redukuje liczbę stopni swobody o 1

- Wartości p– przykład:



$$P(|Y - a| \leq \sigma) = 68,3\% \quad P(|Y - a| > \sigma) = 31,7\%$$

$$P(|Y - a| \leq 2\sigma) = 95,4\% \quad P(|Y - a| > 2\sigma) = 4,6\%$$

$$P(|Y - a| \leq 3\sigma) = 99,8\% \quad P(|Y - a| > 3\sigma) = 0,2\%$$

# Weryfikacja hipotez statystycznych

- **Przykład:** rozważamy zmienną losową  $X$  opisaną standardowym rozkładem Gaussa (średnia 0, odchylenie 1). Pobieramy 10-elementową próbę, uzyskaliśmy średnią arytmetyczną:  $\bar{X}=0,5$
- Jak na podstawie tej jednej realizacji próby (np. wyniku eksperymentu) możemy stwierdzić, czy pochodzi ona z takiej populacji? Innymi słowy, naszą **hipotezą** jest: **próba losowa pochodzi z rozkładu Gaussa o średniej 0 i odchyleniu 1**
- Procedura weryfikacji hipotezy nazywana jest **testem statystycznym**
- Jeżeli **hipoteza jest słuszna (nasze założenie)** to wartość średnia (będąca również zmienną losową)  $\bar{X}$  ma rozkład normalny ze średnią 0 i odchyleniem std.  $1/\sqrt{10}$

$$\sigma^2(\bar{X}) = \frac{1}{n} \sigma^2(X) = \frac{1}{10} \cdot 1 \Rightarrow \sqrt{\sigma^2(\bar{X})} = \frac{1}{\sqrt{10}}$$

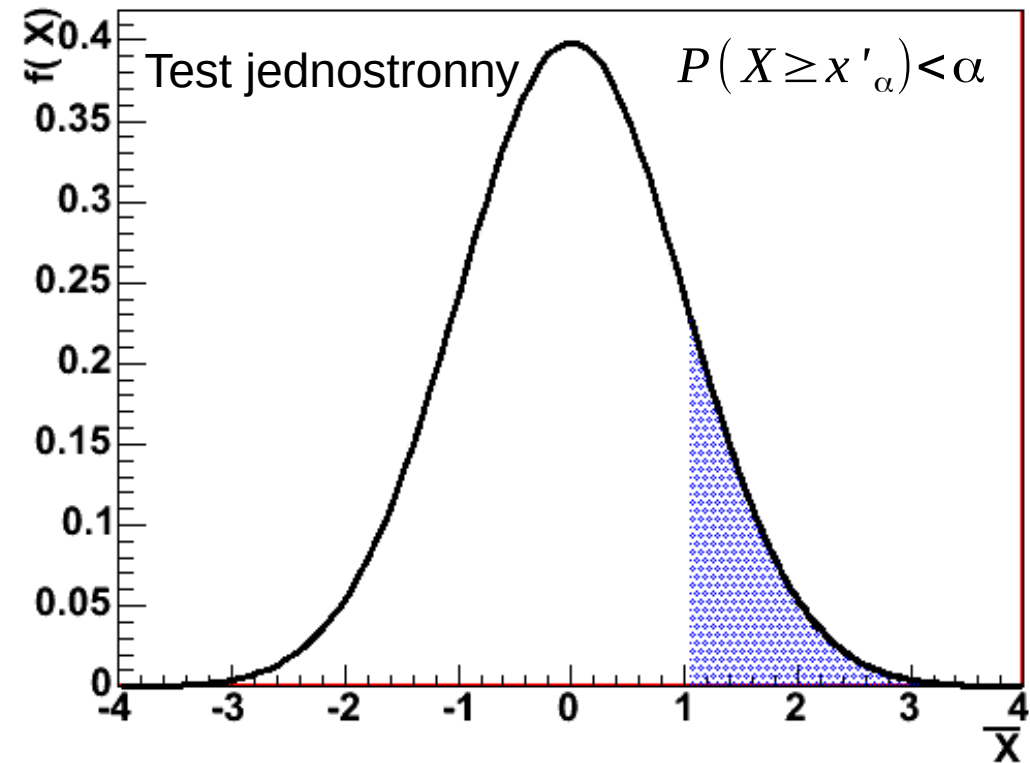



# Weryfikacja hipotez statystycznych

- Jak na podstawie **konkretnej realizacji próby** sprawdzić, czy założona hipoteza jest prawdziwa?
  - **I:** musimy ustalić pewną wartość prawdopodobieństwa  $\alpha$  (zwanego **poziomem istotności**, z reguły mała wartość, np. 0,01, albo 0,03, czy 0,05)
  - **II:** pytamy, czy prawdopodobieństwo zaobserwowania określonych wartości próby jest mniejsze niż  $\alpha$ :  $P(|\bar{X}| \geq 0,5) < \alpha$
  - **nierówność spełniona** – jest mało prawdopodobne, aby próba pochodziła z rozkładu określonego przez testowaną hipotezę → **możemy ją odrzucić**
  - **prawdopodobieństwo zaobserwowania tego, że  $|\bar{X}|$  jest duże, jest bardzo małe, ale takie nam się trafiło – więc prawdopodobnie (z prawdopodobieństwem  $1-\alpha$ ) nasza hipoteza nie jest słuszna**
  - **III:** jeśli prawdopodobieństwo jest mniejsze niż przyjęta wartość prawdopodobieństwa (poziom istotności)  $\alpha$ , odrzucamy hipotezę na zadanym poziomie istotności

# Weryfikacja hipotez statystycznych

## Rozkład wartości średniej $\bar{X}$



- Jeśli (w naszym przykładzie) wartość średnia znajduje się w zaznaczonym obszarze (nazywamy go **obszarem krytycznym**), to hipotezę odrzucamy
  - jeśli oczekujemy rozkładu normalnego o średniej 0 i małym odchyleniu (np. 10), a z próby losowej (konkretny eksperyment) mamy średnią 1000, to lądujemy w “ogonie” rozkładu średniej i na podstawie tej konkretnej próby odrzucamy hipotezę (**ale na podstawie innej próby moglibyśmy zaakceptować**)

# Weryfikacja hipotez statystycznych

- W ogólnym przypadku używamy innych wielkości niż średnia:
  - definiujemy jakąś (wygodną dla nas) statystykę testową  $T$  (np. różnicę między wynikiem eksperymentu a krzywą teoretyczną)
  - ustalamy poziom istotności  $\alpha$
  - wyznaczamy taki zbiór  $U$ , który określa obszar zmienności statystyki testowej  $T$ , taki że prawdopodobieństwo znalezienia się w nim jest ograniczone wartością  $\alpha$ :  $P(T \in U) = \alpha$
  - z pobranej próby wyznaczamy konkretną wartość statystyki testowej  $T'$ : jeżeli znajduje się ona **wewnątrz** obszaru krytycznego  $U$ , **odrzucaamy hipotezę** (mówimy: krzywa teoretyczna nie opisuje wyniku eksperymentu), czyli odrzucaamy hipotezę, jeżeli  $T' \in U$



# Test dobroci $\chi^2$ dopasowania

# Test $\chi^2$ dobroci dopasowania

- Mamy  $N$  pomiarów  $g_i$ ,  $i=1, 2, \dots, N$  oraz ich niepewności  $\sigma_i$
- Wartości  $f_i$ ,  $i=1,2,\dots,N$  określają nam prawdziwy rozkład danej wielkości mierzonej (**np. znaleziony poprzez estymację**)
- **Dla każdego pomiaru liczymy wielkość  $u_i$ :**  $u_i = \frac{g_i - f_i}{\sigma_i}$ ,  $i=1,2,\dots,N$
- Jeśli nasza teoria (wartości  $f_i$ ) jest prawdziwa, to rozkłady różnic  $u_i$  mają postać standardowego rozkładu normalnego – **nasza hipoteza**
- Jeśli tak, to rozkład  $\chi^2$  o  $N$  stopniach swobody będzie miała wielkość:  
$$T = \sum_{i=1}^N u_i^2 = \sum_{i=1}^N \left( \frac{g_i - f_i}{\sigma_i} \right)^2$$
- **(Subiektywnie)** oczekujemy małej wartości wielkości  $T$
- Gdy hipoteza jest **fałszywa**, wówczas poszczególne różnice  $u_i$  przyjmują duże wartości (wartość  $T$  jest duża)
- Jak określić granicę zmienności  $T$ ? Można zauważyć, że granica ta jest określona **kwantylem**  $\chi_{1-\alpha}^2$ , czyli:  $P(T > \chi_{1-\alpha}^2) = \alpha$



$$F(x_q) = P(X \leq x_q) = q$$
$$P(X > x_q) = 1 - q$$

# Test $\chi^2$ dobroci dopasowania

- Podsumowując, w naszym przypadku musimy dla danej realizacji próby (wyniku eksperymentu) wyznaczyć wartość testową  $T$  i porównać ją z odpowiednim kwantylem rozkładu  $\chi^2$  o odpowiedniej liczbie stopni swobody:

$$T > \chi_{1-\alpha}^2$$

- **Jeżeli ten warunek jest spełniony, to hipotezę odrzucamy** (punkty teoretyczne nie opisują danych eksperymentalnych na zadanym poziomie istotności)
- Skąd wziąć kwantyl? Z tablic lub z dystrybuanty:



# Test $\chi^2$ - przykład

## Zadanie

### Weryfikacja hipotez statystycznych (5 pkt.)

- ▶ Przeprowadzono eksperyment naświetlania wodorowej komory pęcherzykowej wiązką fotonów w celu badania oddziaływań fotonów z protonami. Fotony powodują powstawanie par elektron-pozyton, które mogą być wykorzystane do monitorowania wiązki fotonów. Częstość występowania zdjęć z 0,1,2,... parami elektron-pozyton powinna podlegać rozkładowi Poissona. Należy wczytać dane z pliku [plik](#) (w pierwszej kolumnie znajduje się liczba par elektronowych na zdjęciu k, a w drugiej liczba zdjęć zawierających k par elektronowych). Widzimy, że rozkład ten przypomina rozkład Poissona - próbujemy zatem obliczyć estymator największej wiarygodności dla parametry rozkładu Poissona (patrz [Wykład 10](#) slajd 13) (1 pkt.)
- ▶ Narysować na jednym wykresie punkty pomiarowe i dopasowanie (metodą estymatora największej wiarygodności).
- ▶ Sprawdzić jakość dopasowania za pomocą testu  $\chi^2$ . W tym celu należy zaimplementować funkcję obliczającą statystykę testową

$$\chi^2 \text{ zgodnie z wzorem } T = \sum_k \frac{(n_k - np_k)^2}{np_k}$$

gdzie:  $n_k$  - liczba obserwacji w k-tym binie,  $np_k$  - przewidywana przez teorię liczba przypadków w k-tym binie

- ▶ Określić liczbę stopni swobody i obliczyć wartość statystyki testowej. (1 pkt.)
- ▶ Zaimplementować funkcję zwracającą wynik testu  $\chi^2$  na zadanym poziomie istotności  $\alpha$

Wykorzystując zaimplementowaną funkcję zweryfikować hipotezę mówiącą, że dane pomiarowe podlegają rozkładowi Poissona. Dobrać odpowiednią wartość poziomu istotności. Uwaga! Kwanyl możemy odczytać z policzonej na ostatnich zajęciach dystrybuanty. (2 pkt.)






# Test $\chi^2$ - przykład

- Po wczytaniu danych z pliku histogram eksperymentalny wygląda następująco (nasza próba losowa):

Wynik eksperymentu



- Zakładamy hipotezę:** teoria mówi to jest rozkład Poissona (“na oko” zresztą tak wygląda)
- Rozkład Poissona ma tylko jeden parametr (wartość średnią):

$$f(k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

- Musimy go zatem jakoś wyznaczyć z próby losowej – jak?  
**Na przykład metodą największej wiarygodności** – szukamy estymatora nieobciążonego największej wiarygodności o minimalnej wariancji (kilka slajdów temu):

$$\frac{dl}{d\lambda} = l' = \sum_{j=1}^N \left\{ \frac{k^{(j)}}{\lambda} - 1 \right\} =$$

$$\frac{1}{\lambda} \sum_{j=1}^N \{k^{(j)} - \lambda\} = \frac{N}{\lambda} (\bar{K} - \lambda)$$

$$\tilde{\lambda} = \bar{K}, \quad \sigma^2(\bar{K}) = \frac{N}{\lambda}$$

**Przypomnienie – definicja estymatora o min. wariancji:**

$$l' = A(\lambda)(\tilde{\lambda} - \lambda)$$
$$\sigma^2(S) = \frac{1}{|A(\lambda)|}$$

# Test $\chi^2$ - przykład

- Czyli estymatorem największej wiarygodności o minimalnej wariancji dla rozkładu Poissona jest średnia arytmetyczna z próby
- Oczywiście w naszym przypadku mamy histogram, który zawiera jakąś całkowitą liczbę wejść (całka z histogramu nie jest równa 1), wobec tego do średniej dodajemy wagi w postaci liczby wejść w danym binie i średnia staje się średnią ważoną:

$$\tilde{\lambda} = \frac{\sum_k k \cdot n_k}{\sum_k n_k}$$

- W naszym przypadku wartość ta wynosi mniej więcej:  $\tilde{\lambda} \approx 2,33$


- Rysujemy więc funkcję:

$$n \cdot p_k = n \cdot f(k) = n \cdot \frac{\tilde{\lambda}^k}{k!} e^{-\tilde{\lambda}}, \text{ gdzie } n = \sum_k n_k$$

- Jak teraz sprawdzić, czy faktycznie nasza hipoteza jest słuszna?

- **Testujemy dobroć dopasowania**

Wynik eksperymentu



# Test $\chi^2$ - przykład

- Musimy zatem wyznaczyć wartość statystyki testowej  $T$ :

$$T = \sum_{k=0}^7 u_i^2 = \sum_{k=0}^7 \frac{(n_k - np_k)^2}{np_k} \approx 10,53$$

- Co dalej? Zakładamy poziom istotności, na przykład:  $\alpha = 0,01$
- Musimy jeszcze określić liczbę stopni swobody – ile ich jest?
  - liczba binów (8) minus 1 minus liczba parametrów (1)

$$r - 1 - p = 8 - 1 - 1 = 6$$

- Teraz szukamy odpowiedniego kwantyla rozkładu  $\chi^2$  o 6 stopniach swobody:  $\chi_{1-\alpha}^2 = \chi_{0,99}^2 \approx 16,81$
- Porównujemy statystykę z kwantylem:  $T = 10,51 < \chi_{0,99}^2 = 16,81$
- **Warunek  $T > \chi_{1-\alpha}^2$  nie jest spełniony, zatem na poziomie istotności  $\alpha = 0,01$  nie ma podstaw do odrzucenia hipotezy**



# Hipotezy zerowa i alternatywna

## Błędy I i II rodzaju

Na podstawie:


<https://www.statystyczny.pl/hipotezy-statystyczne/>

# Hipoteza zerowa i alternatywna

- Hipoteza może być różna, przykłady hipotez:
  - średni wzrost Polaków to 175 cm
  - 2% dzieci w wieku szkolnym nie lubi czekolady
  - poziom szczęścia dwie minuty po zjedzeniu dużej porcji lodów jest wyższy niż przed zjedzeniem tejże dużej porcji lodów
- **Hipoteza zerowa** ( $H_0$ ) to w uproszczeniu taka, gdy nie widzimy różnicy – np. czujemy się tak samo po zjedzeniu lodów jak przed
  - w przypadku pomiarów, np. wartość  $\chi^2$  jest mała → teoria opisuje dane
- **Hipoteza alternatywna** ( $H_A$ ) to przeciwieństwo hipotezy zerowej, którą możemy zdefiniować na kilka sposobów, np.:
  - np. jest różnica w szczęściu w zjedzeniu lodów (test dwustronny)
  - poziom szczęścia po zjedzeniu lodów jest mniejszy (test jednostronny)
  - poziom szczęścia po zjedzeniu lodów jest większy (test jednostronny)
  - w przypadku pomiarów  $\chi^2$  jest duże → teoria nie opisuje danych (test jednostronny – rozkład  $\chi^2$  jest niesymetryczny)
- **Statystyka testowa** - to funkcja próby, na podstawie której wnioskuje się o odrzuceniu lub nie hipotezy statystycznej – wielkość mająca swój rozkład prawd.

# Statystyka testowa

- **Statystyka testowa** - to funkcja próby, na podstawie której wnioskuje się o odrzuceniu lub nie hipotezy statystycznej – wielkość mająca swój rozkład prawdopodobieństwa
- Z naszej próby losowej (eksperymentu) dostajemy jedną wartość – ona znajduje się gdzieś w tym rozkładzie
- Obszar krytyczny (obszar odrzuceń) jest zawsze na końcu rozkładu
  - jeśli hipoteza mówi, że coś jest różne – dwustronny
  - mniejsze lub większe – jednostronny
- **Statystyka testowa ma swój (różny) rozkład zarówno dla  $H_0$  jak i  $H_A$ !!!**



# Błąd I rodzaju

- **Błąd I rodzaju** to taki, gdzie odrzucamy hipotezę zerową a była ona prawdziwa
  - $H_0$ : poziom szczęścia (średnio w populacji) po zjedzeniu dużej porcji lodów jest taki sam jak przed
  - $H_A$ : poziom szczęścia (średnio w populacji) się zmienia
  - my na podstawie doświadczenia (próby losowej) zjedliśmy lody i np. przez te okropne wyrzuty sumienia, że znowu za dużo kalorii :) odrzucamy hipotezę zerową na rzecz alternatywnej
  - jeżeli w wyniku wielu prób losowych wynika, że jednak lądujemy w ogonie rozkładu owego szczęścia, to popełnimy właśnie błąd pierwszego rodzaju – bo odrzuciliśmy hipotezę zerową, która była prawdziwa
- Prawdopodobieństwo popełnienia błędu I rodzaju określa **poziom istotności**  $\alpha$ , stąd oczekujemy, by był jak najmniejszy


# Błąd II rodzaju

- **Błąd II rodzaju** to taki, gdy nie odrzucimy hipotezy fałszywej
  - ma on miejsce w sytuacji, kiedy jednak ten poziom szczęścia przed zjedzeniem lodów i po zjedzeniu się różni. Jeśli (**średnio w społeczeństwie**) te wyrzuty sumienia z powodu zjedzenia dobrych i smacznych lodów powodują, że poziom szczęścia zdecydowanie spada po zjedzeniu lodów, a my stwierdzimy (**na podstawie próby losowej**), że nie ma żadnej różnicy, to wtedy popełniamy błąd II rodzaju. **Nie odrzucamy hipotezy zerowej, mimo że jest ona fałszywa.**
- **Prawdopodobieństwo** popełnienia błędu II rodzaju określamy jako  $\beta$



# Moc testu

- Moc testu (prawdopodobieństwo, że prawidłowo odrzucimy hipotezę zerową) to  $1-\beta$ . Inaczej mówiąc jest to prawdopodobieństwo niepopęlnienia błędu II rodzaju.
- Moc testu zależy od kilku czynników:
  - Wielkości próby użytej w badaniu (im większa próba, tym większa moc testu).
  - Rzeczywistej wielkości efektu na tle losowej zmienności w populacji.
  - Przyjętego poziomu istotności  $\alpha$  (między błędem I i II rodzaju jest taka zależność, że jeżeli zwiększamy prawdopodobieństwo popełnienia danego błędu, jednocześnie zmniejszamy je dla drugiego).




Rys.2 Relacje między błędem I, II rodzaju oraz mocą


# Moc testu

## Moc testu: interpretacja graficzna (1)

rozkłady statystyki testowej przy założeniu prawdziwości  
hipotezy zerowej i alternatywnej



# Testy statystyczne



# Dalsza lektura

---

- Polecam poniższe strony:
  - <https://www.statystyczny.pl/hipotezy-statystyczne/>
  - <http://pogotowiestatystyczne.pl/istotnosc-statystyczna/>
  - [http://coin.wne.uw.edu.pl/azylicz/sm/sm09\\_2016.pdf](http://coin.wne.uw.edu.pl/azylicz/sm/sm09_2016.pdf)

### Przykładowe zadania na kolokwium z KADD (wykład):

1) Dana jest dystrybuanta zmiennej X:

x	$(-\infty, -2>$	$(-2, 1>$	$(1, 3>$	$(3, \infty)$
F(x)	0	0.2	0.8	1.0

Wyznacz funkcję prawdopodobieństwa.

2) Zmienna losowa X ma funkcję prawdopodobieństwa postaci:

x	-3	-1	3	5
p <sub>i</sub>	0.1	0.2	0.5	0.2

Wyznaczyć funkcje prawdopodobieństwa zmienne U:

a)  $U = 2X + 3$

b)  $U = X^3$

c)  $U = X^2 - 5$

Ponadto wyznaczyć wartości oczekiwane i wariancję.

3) Zmienna losowa ma rozkład prawdopodobieństwa:

$$f(x) = c \cdot \sin(x) \quad x \in [0, \pi]$$

a) Dobrać stałą c, aby f(x) była gęstością prawdopodobieństwa

b) Wyznaczyć funkcję dystrybuanty

c) Wyznaczyć wartość oczekiwaną, wariancję, odchylenie standardowe

d) Wyznaczyć medianą

4) Zaproponować metodą do generacji liczb z rozkładu potęgowego

5) Zaproponować metodę do generacji liczb z rozkładu sinusoidalnego

6) Dwuwymiarowa zmienna losowa (X,Y) ma rozkład gęstości:  $f(x,y) = 1/(20\pi) \cdot \exp(-0.5 \cdot (x^2/4 + y^2/25))$ . Zbadać, czy zmienne X, Y są niezależne, Podać sposób na obliczenie (obliczyć):  $P(-1 < X < 2, 0 < Y < 3)$


7) Dane są dwie próby:

A) 21, 19, 14, 27, 25, 23, 22, 18, 21 (N = 9)

B) 16, 24, 22, 21, 25, 21, 18 (N=7)

Czy przy poziomie istotności 5% wariancja próby (B) jest mniejsza niż próby (A)?

8) Zweryfikuj hipotezę, że 10 pomiarów zostało wylosowane z populacji o wartości średniej 25.6? Przyjmij, że poziom istotności wynosi 10%, załóż, że populacji ma rozkład normalny. Pomiary: 22.03, 27.05, 27.5, 22.7, 25.3, 26.2, 27.9, 21.2, 23.3, 25.5.



**KONIEC**

# Test t-Studenta

- Mamy zmienną losową  $X$  o rozkładzie normalnym. Pobieramy próbę losową o liczebności  $N$  i wartości średniej  $\bar{X}$
- Wariancja wartości średniej:  $\sigma^2(\bar{X}) = \sigma^2(X)/N$
- Dla dostatecznie dużych prób wartość średnia z próby (na mocy centralnego twierdzenia granicznego) ma rozkład normalny  $(\hat{x}, \sigma(\bar{X}))$
- Zmienna  $y = \frac{\bar{X} - \hat{x}}{\sigma(\bar{X})}$  ma standardowy rozkład normalny
- Na ogół nie znamy jednak odchylenia standardowego  $\sigma^2(X)$
- Posługujemy się estymatorem wariancji:  
$$s_X^2 = \frac{1}{N-1} \sum_{j=1}^N (X_j - \hat{x})^2 \qquad s_{\bar{X}}^2 = \frac{1}{N(N-1)} \sum_{j=1}^N (x_j - \bar{x})^2$$
- **Pytanie:** jak bardzo będziemy odbiegać od rozkładu Gaussa, jeżeli we wzorze na  $y$  zastąpimy odchylenie estymatorem?
- Dla uproszczenia, przyjmiemy, że  $\hat{x} = 0$  (każdy rozkład Gaussa możemy przesunąć o wartość średnią)

# Test t-Studenta

- Rozpatrzmy zmienną losową  $T$  zdefiniowaną następująco:

$$T = \bar{X} / s_{\bar{X}} = \bar{X} \cdot \sqrt{N} / S_X$$

- Wielkość  $(N-1)s_X^2 = fs_X^2$  ma rozkład  $\chi^2$  o liczbie stopni swobody  $f = N-1$
- Wzór na zmienną  $T$  zmieni się nam zatem następująco:

$$T = \bar{X} / s_{\bar{X}} = \bar{X} \cdot \sqrt{N} \cdot \sqrt{f} / \chi$$

- Dystrybuanta zmiennej  $T$  będzie określona wzorem:

$$F(t) = P(T < t) = P\left(\frac{\bar{X} \sqrt{N} \sqrt{f}}{\chi} < t\right) = \frac{\Gamma\left(\frac{1}{2}(f+1)\right)}{\Gamma\left(\frac{1}{2}f\right) \sqrt{\pi} \sqrt{f}} \int_{-\infty}^t \left(1 + \frac{t^2}{f}\right)^{\frac{1}{2}(f+1)} dt$$

- A odpowiadająca jej funkcja gęstości, nosząca nazwę **rozkładu t-Studenta**:

$$f(t) = \frac{\Gamma\left(\frac{1}{2}(f+1)\right)}{\Gamma\left(\frac{1}{2}f\right) \sqrt{\pi} \sqrt{f}} \left(1 + \frac{t^2}{f}\right)^{\frac{1}{2}(f+1)}$$



# Rozkład t-Studenta

- $f=1$
- 2
- 3
- 4
- 5
- 6
- 7
- 8
- 9
- 10
- Jak widać, rozkład t-Studenta jest symetryczny względem 0
- Rozkład dąży do rozkładu Gaussa gdy  $f \rightarrow \infty$
- Z symetrii względem 0 mamy związek (analogicznie jak dla Gaussa):  $P(|t| \leq t) = 2F(|t|) - 1$

- Możemy wyznaczyć graniczne wartości  $\pm t'_\alpha$  odpowiadające poziomowi istotności  $\alpha$  poprzez całkę:

$$\int_0^{t'_\alpha} f(t) dt = \frac{1}{2}(1 - \alpha), \text{ gdzie } t'_\alpha = t_{1 - \frac{1}{2}\alpha}$$

- Kwantyle  $t'_\alpha = t_{1 - \frac{1}{2}\alpha}$  są tablicowane dla różnych poziomów istotności  $\alpha$  oraz liczby stopni swobody  $f$
- Jest to dwustronny test t-Studenta (jednostronny analogicznie)

# Zastosowanie testu t-Studenta

- **Hipoteza:** zakładamy, że nasza populacja przewiduje wartość oczekiwaną z populacji mającej rozkład normalny równą  $\lambda_0$
- Pobieramy próbę o liczebności  $N$  i wyznaczamy wartość średnią  $\bar{X}$  oraz wariancję  $S_X$
- Jeżeli przy założonym poziomie istotności  $\alpha$  zachodzi nierówność:

$$|t| = \frac{|\bar{X} - \lambda_0| \sqrt{N}}{S_X} > t'_\alpha = t_{1 - \frac{1}{2}\alpha}$$

- Wtedy **odrzucaamy** naszą hipotezę
- W przypadku testu jednostronnego  $t = \frac{\bar{X} - \lambda_0}{S_X} > t_{2\alpha} = t_{1-\alpha}$

# Zastosowanie testu t-Studenta

- Powyższe rozważania możemy **uogólnić** na porównanie wartości średnich dwóch prób losowych z populacji  $X$  oraz  $Y$  o liczebnościach  $N_1$  i  $N_2$

- **Hipoteza:** równość wartości średnich z obu populacji:  $\hat{x} = \hat{y}$

- Zakładamy (z centralnego twierdzenia granicznego), że wartości średnie z prób mają rozkład normalny z wariancjami:

$$\sigma^2(\bar{X}) = \sigma^2(X)/N_1, \quad \sigma^2(\bar{Y}) = \sigma^2(Y)/N_2$$

- Wariancje są estymowane przez estymatory:

$$s_{\bar{X}}^2 = \frac{1}{N_1(N_1-1)} \sum_{j=1}^{N_1} (X_j - \bar{X})^2 \quad s_{\bar{Y}}^2 = \frac{1}{N_2(N_2-1)} \sum_{j=1}^{N_2} (Y_j - \bar{Y})^2$$

- Różnica wartości średnich z próby również ma rozkład zbliżony do normalnego:  $\Delta = \bar{X} - \bar{Y} \Rightarrow \sigma^2(\Delta) = \sigma^2(\bar{X}) + \sigma^2(\bar{Y})$

- Jeśli hipoteza jest prawdziwa, wówczas oczywiste jest, że  $\hat{\Delta} = 0$  oraz iloraz  $\hat{\Delta}/s_{\Delta}$  powinien podlegać rozkładowi Gaussa

- Tak postawiona hipoteza cicho zakłada, że  $X$  i  $Y$  to te same populacje

# Test różnic t-Studenta

- Skoro tak, to oczywiście  $\sigma^2(X)=\sigma^2(Y)$ , zatem można je estymować za pomocą jednego estymatora jako średnią ważoną z dwóch prób:

$$s^2 = \frac{(N_1 - 1)s_X^2 + (N_2 - 1)s_Y^2}{(N_1 - 1) + (N_2 - 1)}$$

- Wtedy możemy zdefiniować estymatory:

$$s_{\bar{X}}^2 = s^2 / N_1, \quad s_{\bar{Y}}^2 = s^2 / N_2, \quad s_{\Delta}^2 = s_{\bar{X}}^2 + s_{\bar{Y}}^2 = \frac{N_1 + N_2}{N_1 \cdot N_2} s^2$$

- Można udowodnić, że zmienna  $\Delta/s(\Delta)$  podlega rozkładowi t-Studenta z liczbą stopni swobody  $f = N_1 + N_2 - 2$
- Równość wartości średnich można więc weryfikować posługując się **testem różnic Studenta**
- $\Delta/s(\Delta)$  obliczana jest na podstawie wyników dwóch prób. Jej wartość bezwzględną porównujemy z kwantylem rozkładu Studenta o liczbie stopni swobody  $f$  dla ustalonego poziomu istotności  $\alpha$ . Sprawdzamy nierówność (**spełniona – odrzucamy hipotezę**):

$$|t| = \frac{|\Delta|}{s_{\Delta}} = \frac{|\bar{X} - \bar{Y}|}{s_{\Delta}} > t'_{\alpha} = t_{1 - \frac{1}{2}\alpha}$$

# Rozkład t-Studenta

- $f=1$
- 2
- 3
- 4
- 5
- 6
- 7
- 8
- 9
- 10
- Jak widać, rozkład t-Studenta jest symetryczny względem 0
- Rozkład dąży do rozkładu Gaussa gdy  $f \rightarrow \infty$
- Z symetrii względem 0 mamy związek (analogicznie jak dla Gaussa):  $P(|t| \leq t) = 2F(|t|) - 1$

- Możemy wyznaczyć graniczne wartości  $\pm t'_\alpha$  odpowiadające poziomowi istotności  $\alpha$  poprzez całkę:

$$\int_0^{t'_\alpha} f(t) dt = \frac{1}{2}(1-\alpha), \text{ gdzie } t'_\alpha = t_{1-\frac{1}{2}\alpha}$$

- Kwantyle  $t'_\alpha = t_{1-\frac{1}{2}\alpha}$  są stacjonarne dla różnych poziomów istotności  $\alpha$  oraz liczby stopni swobody  $f$
- Jest to dwustronny test t-Studenta (jednostronny analogicznie)

# Test różnic t-Studenta - przykład

Numer pomiaru	Przyrząd 1	Przyrząd 2				
1	100	97	-0,21	0,04	-3,8	14,44
2	101	101	0,79	0,62	0,2	0,04
3	102	102	1,79	3,2	1,2	1,44
4	100	99	-0,21	0,04	-1,8	3,24
5	98	101	-2,21	4,89	0,2	0,04
6	97	108	-3,21	10,31	7,2	51,84
7	100	101	-0,21	0,04	0,2	0,04
8	101	102	0,79	0,62	1,2	1,44
9	99	96	-1,21	1,47	-4,8	23,04
10	100	101	-0,21	0,04	0,2	0,04
11	98		-2,21	4,89		
12	101		0,79	0,62		
13	100		-0,21	0,04		
14	102		1,79	3,2		
15	103		2,79	7,78		
16	101		0,79	0,62		
17	99		-1,21	1,47		
18	100		-0,21	0,04		
19	102		1,79	3,2		
Ilość pomiarów	19	10				
Średnia	100,21	100,8	-0,59			
Stopnie swobody	18	9				
S <sup>2</sup>	43,16	95,6				
S <sup>2</sup> /f	2,4	10,62				
S <sup>2</sup>	49,1					
S <sup>2</sup> Delta	8,18					

- Mamy kwantyle:

$$t'_{0,2}(27) = t_{0,9}(27) = 1,71$$

$$t'_{0,1}(27) = t_{0,95}(27) = 2,05$$

$$t'_{0,02}(27) = t_{0,99}(27) = 2,77$$

$$t'_{0,01}(27) = t_{0,995}(27) = 3,05$$

$$t'_{0,004}(27) = t_{0,998}(27) = 3,43$$

$$t'_{0,002}(27) = t_{0,999}(27) = 3,69$$

- Hipotezy nie można odrzucić