




# Komputerowa analiza danych doświadczalnych

Wykład 9  
6.05.2022

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

*Semestr letni 2021/2022*




# Metoda największej wiarygodności

## Próby z rozkładów cząstkowych

Rozkłady t-Studenta i  $\chi^2$

Testy statystyczne



# Jednoczesna estymacja kilku parametrów

# Jednoczesna estymacja kilku parametrów

- Jak już pamiętamy, w najogólniejszym przypadku mamy pewną ilość  $p$  parametrów  $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_p)$ , które chcemy estymować. Wtedy funkcja wiarygodności i równania wiarygodności:

$$L = \prod_{j=1}^N f(\mathbf{X}^{(j)}; \lambda) \quad l = \ln L = \sum_{j=1}^N \ln f(\mathbf{X}^{(j)}; \lambda) \quad \frac{\partial l}{\partial \lambda_i} = 0, \quad i=1, 2, \dots, p$$

- Niestety, w przypadku wielu parametrów wszystko nam się komplikuje dodatkowo z uwagi na możliwe **korelacje pomiędzy parametrami**
- Analogicznie jak dla 1 parametru, rozwijamy funkcję wiarygodności:

$$L(X^{(1)}, X^{(2)}, \dots, X^{(j)}; \lambda) = \sum_{j=1}^N \ln f(X^{(j)}; \lambda) \quad \tilde{\lambda} = (\tilde{\lambda}_1, \tilde{\lambda}_2, \dots, \tilde{\lambda}_p)$$

na szereg Taylora wokół punktu:

- Korzystając ze znikania 1-szych pochodnych dostajemy wtedy:

$$-(l(\lambda) - l(\tilde{\lambda})) = 1/2 (\lambda - \tilde{\lambda})^T A (\lambda - \tilde{\lambda}) + \dots$$

$$-A = \begin{pmatrix} \frac{\partial^2 l}{\partial \lambda_1^2} & \frac{\partial^2 l}{\partial \lambda_1 \partial \lambda_2} & \dots & \frac{\partial^2 l}{\partial \lambda_1 \partial \lambda_p} \\ \frac{\partial^2 l}{\partial \lambda_2 \partial \lambda_1} & \frac{\partial^2 l}{\partial \lambda_2^2} & \dots & \frac{\partial^2 l}{\partial \lambda_2 \partial \lambda_p} \\ \frac{\partial^2 l}{\partial \lambda_p \partial \lambda_1} & \frac{\partial^2 l}{\partial \lambda_p \partial \lambda_2} & \dots & \frac{\partial^2 l}{\partial \lambda_p^2} \end{pmatrix}$$

- Gdzie macierz A:

# Jednoczesna estymacja kilku parametrów

- W granicy  $N \rightarrow \infty$  można zastąpić macierz  $A$  odpowiednimi wartościami oczekiwanymi (niezależnymi od próby)  $B = E(A)$ 
  - **de facto zamieniamy**  $\lambda_1, \lambda_2, \dots, \lambda_p$  **na**  $\tilde{\lambda}_1, \tilde{\lambda}_2, \dots, \tilde{\lambda}_p$
- Jeśli zaniedbamy wyrazy wyższych rzędów w rozwinięciu na szereg Taylora, dostaniemy wówczas funkcję wiarygodności postaci:

$$L = k \exp\left(-1/2(\boldsymbol{\lambda} - \tilde{\boldsymbol{\lambda}})^T B(\boldsymbol{\lambda} - \tilde{\boldsymbol{\lambda}})\right) \quad C = B^{-1}$$

- Analogicznie jak dla jednego parametru, mamy tutaj  $p$ -wymiarowy rozkład normalny z macierzą kowariancji (dla estymatorów)
- Wariancje estymatorów największej wiarygodności dane są przez elementy diagonalne macierzy  $C$ :  $\sigma^2(\tilde{\lambda}_i) = c_{ii}$
- Elementy pozadiagonalne są kowariancjami poszczególnych par estymatorów:  $\text{cov}(\tilde{\lambda}_j, \tilde{\lambda}_k) = c_{jk} \quad \tilde{\lambda}_1, \tilde{\lambda}_2, \dots, \tilde{\lambda}_p$
- Możemy zdefiniować **współczynnik korelacji między estymatorami**:  $\rho(\tilde{\lambda}_j, \tilde{\lambda}_k) = \frac{\text{cov}(\tilde{\lambda}_j, \tilde{\lambda}_k)}{\sigma(\tilde{\lambda}_j)\sigma(\tilde{\lambda}_k)}$

# Jednoczesna estymacja kilku parametrów

- Analogicznie jak w przypadku z jednym parametrem, niepewnością estymacji (typu A) będzie pierwiastek kwadratowy z wariancji estymatora:

$$u(\tilde{\lambda}_i) = \sigma(\tilde{\lambda}_i) = \sqrt{c_{ii}}$$

- W przypadku 1D stwierdziliśmy, że za pomocą estymatora i jego niepewności możemy zdefiniować przedział obejmujący wartość prawdziwą estymowanego parametru z prawdopodobieństwem 68,3%. W przypadku wielowymiarowym przedział ten będzie określony również przez pełną macierz kowariancji (zależności między parametrami)
- Innymi słowy: obszar taki sprowadza się do elipsy kowariancji, analogicznej jak dla zmiennych losowych – czyli mamy **elipsy kowariancji dla estymowanych parametrów naszego rozkładu**
- Równanie **elipsoidy kowariancji** ( $p$ -wymiarowa przestrzeń):

$$g(\lambda) = 1 = 2 \{ I(\lambda) - I(\tilde{\lambda}) \} = (\lambda - \tilde{\lambda})^T B (\lambda - \tilde{\lambda})$$

- Dla  $g(\lambda) = 1$  mamy obszar ufności z prawdopodobieństwem 68,3%



# Jednoczesna estymacja kilku parametrów - przykład

# Jednoczesna estymacja kilku parametrów

- **Przykład:** badamy zasięg cząstek  $\alpha$  w materii powstałych w wyniku rozpadu promieniotwórczego. Zasięg podlega rozkładowi normalnemu wokół wartości średniej  $\rightarrow$  Innymi słowy, w wyniku eksperymentu mamy próbę losową o liczebności  $N$  z rozkładu normalnego
- Funkcja wiarygodności w tym przypadku:

$$L = \prod_{j=1}^N \frac{1}{\lambda_2 \sqrt{2\pi}} \exp \frac{-(X^{(j)} - \lambda_1)^2}{2\lambda_2^2} \quad l = \ln L = -\frac{1}{2} \sum_{j=1}^N \frac{(X^{(j)} - \lambda_1)^2}{2\lambda_2^2} - N \ln \lambda_2 - \text{const}$$

- Układ równań wiarygodności:

$$\frac{\partial l}{\partial \lambda_1} = \sum_{j=1}^N \frac{X^{(j)} - \lambda_1}{2\lambda_2^2} = 0$$

$$\frac{\partial l}{\partial \lambda_2} = \frac{1}{\lambda_2^3} \sum_{j=1}^N (X^{(j)} - \lambda_1)^2 - \frac{N}{\lambda_2} = 0$$

- Rozwiązanie:

$$\tilde{\lambda}_1 = \frac{1}{N} \sum_{j=1}^N X^{(j)}$$

$$\tilde{\lambda}_2 = \sqrt{\frac{\sum_{j=1}^N (X^{(j)} - \lambda_1)^2}{N}}$$



# Jednoczesna estymacja kilku parametrów

- Wyznaczymy macierz  $A$ , a następnie  $B$  i macierz  $C$  poprzez policzenie drugich pochodnych i w granicy  $N \rightarrow \infty$  zastąpienie ich wartościami oczekiwanymi:

$$\frac{\partial^2 l}{\partial \lambda_1^2} = -\frac{N}{\lambda_2^2} \quad \frac{\partial^2 l}{\partial \lambda_1 \partial \lambda_2} = -\frac{2 \sum (X^{(j)} - \lambda_1)}{\lambda_2^3} \quad \frac{\partial^2 l}{\partial \lambda_2^2} = -\frac{3 \sum (X^{(j)} - \lambda_1)^2}{\lambda_2^4} + \frac{N}{\lambda_2^2}$$

$$B = \begin{pmatrix} N/\tilde{\lambda}_2^2 & 0 \\ 0 & 2N/\tilde{\lambda}_2^2 \end{pmatrix} \quad C = B^{-1} = \begin{pmatrix} \tilde{\lambda}_2^2/N & 0 \\ 0 & \tilde{\lambda}_2^2/2N \end{pmatrix}$$

- Elementy diagonalne macierzy  $C$  to odchylenia standardowe estymowanych parametrów
- Elementy pozadiagonalne wynoszą 0, zatem brak jest korelacji między estymowanymi parametrami

$$-(l(\boldsymbol{\lambda}) - l(\tilde{\boldsymbol{\lambda}})) = 1/2 (\boldsymbol{\lambda} - \tilde{\boldsymbol{\lambda}})^T A (\boldsymbol{\lambda} - \tilde{\boldsymbol{\lambda}}) + \dots$$

$$L = k \exp(-1/2 (\boldsymbol{\lambda} - \tilde{\boldsymbol{\lambda}})^T B (\boldsymbol{\lambda} - \tilde{\boldsymbol{\lambda}})) \quad C = B^{-1}$$

$$B = E(A), \text{ dla } N \rightarrow \infty, \boldsymbol{\lambda} = \tilde{\boldsymbol{\lambda}}$$

$$-A = \begin{pmatrix} \frac{\partial^2 l}{\partial \lambda_1^2} & \frac{\partial^2 l}{\partial \lambda_1 \partial \lambda_2} & \dots & \frac{\partial^2 l}{\partial \lambda_1 \partial \lambda_p} \\ \frac{\partial^2 l}{\partial \lambda_2 \partial \lambda_1} & \frac{\partial^2 l}{\partial \lambda_2^2} & \dots & \frac{\partial^2 l}{\partial \lambda_2 \partial \lambda_p} \\ \frac{\partial^2 l}{\partial \lambda_p \partial \lambda_1} & \frac{\partial^2 l}{\partial \lambda_p \partial \lambda_2} & \dots & \frac{\partial^2 l}{\partial \lambda_p^2} \end{pmatrix}$$

# Metoda najw. wiar. a programy do analizy

## 7.1 The Fit Method

The Fit method is implemented in ROOT for the histogram classes `TH1`, the sparse histogram classes, `THnSparse`, the graph classes, `TGraph`, `TGraph2D` and `TMultiGraph` for fitting a collection of Graphs with the same function.

### 7.1.1 The TH1::Fit Method

To fit a histogram programmatically, you can use the `TH1::Fit` method. Here is the signatures of `TH1::Fit` and an explanation of the parameters:

```
TFitResultPtr Fit(TF1 *function, Option_t *option, Option_t *goption,  
                 Axis_t xmin, Axis_t xmax)
```

- `function` a pointer to the fitted function (the fit model) object. One can also use the function name. This name may be one of ROOT pre-defined function names or a user-defined function. See the next paragraph for the list of pre-defined functions.
- `*option`: The second parameter is the fitting option. Here is the list of fitting options:
  - “ `W` ” Set all weights to 1 for non empty bins; ignore error bars
  - “ `WW` ” Set all weights to 1 including empty bins; ignore error bars
  - “ `I` ” Use integral of function in bin instead of value at bin center
  - “ `L` ” Use log likelihood method (default is chi-square method). To be used when the histogram represents counts
  - “ `WL` ” Weighted log likelihood method. To be used when the histogram has been filled with weights different than 1.
  - “ `P` ” Use Pearson chi-square method, using expected errors instead of the observed one given by `TH1::GetBinError` (default case). The expected error is instead estimated from the the square-root of the bin function value.

# Metoda najw. wiar. a programy do analizy

## Example: Likelihood fit

- Use the pdf of observables and maximize the product of likelihoods.

- In practice: minimize the  $-2 \times \text{logarithm}$  of the likelihoods

- Binned data**

- Use Poisson pdf for bin content

- Example:** data normally distributed

$$\mathcal{L} = \prod_{i=\text{bins}} \text{Poisson} \left[ N_i^{\text{obs}}, A \exp \left( -\frac{1(x_i - \bar{x})^2}{2\sigma^2} \right) \right]$$

- Unbinned data**



- Example:** normally distributed points about  $\alpha$

$$\mathcal{L} = \prod_{i=\text{measurements}} \frac{1}{\sqrt{2\pi}\sigma_i} \exp \left( -\frac{1(x_i - \alpha)^2}{2\sigma_i^2} \right)$$

$$-2 \ln \mathcal{L} = \sum_{i=\text{measurements}} \left[ \frac{(x_i - \alpha)^2}{\sigma_i^2} + 2 \ln(\sqrt{2\pi}\sigma_i) \right]$$

- It looks familiar, doesn't it?

- 1 $\sigma$  uncertainty:** increase of  $-2 \ln \mathcal{L}$  by 1




# Metoda najw. wiar. a programy do analizy

## Simple fits

```
myh2->Fit("gaus", "", "", -2., 2.);
```



```
myh2->GetFunction("gaus")->Draw();
```



```
TFitResultPtr fitres = myh2->Fit("gaus", "S");
```

```
fitres->Parameter(2);
```

```
fitres->ParError(2);
```

```
fitres->Chi2();
```

```
fitres->Ndf();
```


- Some predefined fit functions available:

- Exponential
- Gaussian
- Landau
- Polynomial (up to 9<sup>th</sup> degree)

- Most common options:

- "L" likelihood fit
- "WL" likelihood fit with weighed points
- "Q" quiet mode: do not print info on screen
- "S" save the results in a TFitResultPtr object.





# Stopnie swobody

# Stopnie swobody

- Wariancję populacji określamy przez sumę kwadratów różnic:

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

← Dlaczego  $1/(n-1)$ ? To jest średnia różnicy kwadratów, powinno być  $1/n$

- Zajmijmy się kwadratami różnic:  $\sum_{i=1}^n (X_i - \bar{X})^2$

- Wartości  $X_i$  mogą przybierać dowolne wartości
- Dowolność ta jest jednak ograniczona ograniczony warunkiem (**wiązanie**) istnienia wartości średniej:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \Rightarrow \sum_{i=1}^n (X_i - \bar{X}) = 0$$

- Mówimy, że **liczba stopni swobody** dla sumy kwadratów wynosi  $n-1$
- Suma kwadratów dzielona przez liczbę stopni swobody to **odchylenie średnie kwadratowe (root-mean square - RMS)**



# Pobieranie próby z rozkładów cząstkowych

# Próby z rozkładów cząstkowych

- Czasem mamy do czynienia z sytuacją, gdy nie da się wybrać losowo próby z populacji generalnej
- Możemy jednak podzielić populację generalną na **podpopulacje**:
- Przykład:
  - badamy jakąś cechę wszystkich studentów w Europie – populacja generalna
  - najłatwiej to zrobić poprzez badanie tej cechy na poszczególnych uniwersytetach – podpopulacje
  - rozkład podpopulacji **nie jest** taki sam jak rozkład populacji generalnej
  - podpopulacje są jednak związane z całą populacją
- W jaki sposób wnioskować o całej populacji na podstawie prób losowych wybranych z podpopulacji?



# Próby z rozkładów cząstkowych

- Dzielimy populację generalną  $G$  na  $t$  podpopulacji  $G_i$
- Prawdopodobieństwo, że zmienna losowa należy do  $G_i$ :  $P(X \in G_i) = p_i$
- Podpopulacje  $G_i$ , które są opisane gęstościami prawdopodobieństwa  $f_i(x)$  i mają odpowiednie dystrybuanty  $F_i(x)$ :

$$F_i(x) = \int_{-\infty}^x f_i(x) dx = P(X \leq x | x \in G_i)$$

- Dla całej populacji mamy zatem:

$$F(x) = P(X \leq x | x \in G) = \sum_{i=1}^t P(X < x | X \in G_i) P(X \in G_i) = \sum_{i=1}^t P(X \in G_i) F_i(x) = \sum_{i=1}^t p_i F_i(x)$$

- Dla gęstości prawdopodobieństwa populacji:  $f(x) = \sum_{i=1}^t p_i f_i(x)$

- Obliczamy wartość oczekiwaną populacji  $G$ :

$$\hat{x} = E(X) = \int_{-\infty}^{\infty} x f(x) dx = \sum_{i=1}^t p_i \int_{-\infty}^{\infty} x f_i(x) dx = \sum_{i=1}^t p_i \hat{x}_i$$

# Próby z rozkładów cząstkowych

- Wartość oczekiwana populacji  $G$ :

$$\hat{x} = E(X) = \int_{-\infty}^{\infty} xf(x) dx = \sum_{i=1}^t p_i \int_{-\infty}^{\infty} xf_i(x) dx = \sum_{i=1}^t p_i \hat{x}_i$$

- **Wniosek:** wartość oczekiwana z populacji to średnia ważona wartości oczekiwanych podpopulacji pomnożonych przez ich prawdopodobieństwa
- Jak zatem wyznaczyć **wariancję populacji** na podstawie podpopulacji?

$$\sigma^2(X) = E((X - \hat{x})^2) = \sum_{i=1}^t p_i E\left(\left[(X - \hat{x}_i) + (\hat{x}_i - \hat{x})\right]^2\right) = \sum_{i=1}^t p_i (\sigma_i^2 + (\hat{x}_i - \hat{x})^2)$$

- **Wniosek:** wariancja populacji jest średnią ważoną wariancji z podpopulacji  $\sigma_i$  i wariancji wartości średniej podpopulacji  $\hat{x}_i$  względem wartości średniej z całej populacji  $\hat{x}$
- To nie koniec... Teraz musimy wybrać **próby losowe z podpopulacji i policzyć estymatory**

# Próby z rozkładów cząstkowych

- Teraz z każdej podpopulacji wybierzmy próbkę o liczności  $n_i$ , w sumie  $n$  elementów:  $n = \sum_{i=1}^t n_i$ . Średnia arytmetyczna z całej próby wynosi wtedy:

$$\bar{X}_p = \frac{1}{n} \sum_{i=1}^t \sum_{j=1}^{n_i} X_{ij} = \frac{1}{n} \sum_{i=1}^t n_i \bar{X}_i$$

- Wartość oczekiwana i wariancja (niepewność) średniej z całej próby:

$$E(\bar{X}_p) = \frac{1}{n} \sum_{i=1}^t n_i \hat{x}_i \quad \text{próbki z poszczególnych podpopulacji}$$

$$\sigma^2(\bar{X}_p) = \frac{1}{n^2} \sum_{i=1}^t n_i^2 E\left((\bar{X}_i - \hat{x}_i)^2\right) = \frac{1}{n^2} \sum_{i=1}^t n_i^2 \sigma^2(\bar{X}_i) = \frac{1}{n} \sum_{i=1}^t \frac{n_i}{n} \sigma_i^2$$

# Estymatory dla rozkładów cząstkowych

- Zauważmy jednak, że wartość średnia  $\bar{X}_p$  nie może być estymatorem wartości oczekiwanej z całej populacji  $\hat{x}$ , gdyż zależy ona od dowolnego wyboru wielkości  $n_i$  próbek cząstkowych

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

- Jeśli jednak porównamy wzory na średnią z populacji i całej próby:

$$\hat{x} = \sum_{i=1}^t p_i \hat{x}_i \qquad \bar{X}_p = \frac{1}{n} \sum_{i=1}^t n_i \hat{x}_i$$

- To widać, że jeżeli warunek  $p_i = n_i/n$  jest spełniony, to wartość średnia z populacji  $\hat{x}$  może być estymowana przez wyznaczenie najpierw wartości średnich poszczególnych prób  $\bar{X}_i$ , wewnątrz poszczególnych podpopulacji, a potem przez wyrażenie:

$$\tilde{X} = \sum_{i=1}^t p_i \bar{X}_i \quad \text{- estymator wartości średniej z populacji}$$

zależny od wartości średnich z prób

$$p_i = \frac{n_i}{n}$$

- Wariancja powyższego estymatora:  $\sigma^2(\tilde{X}) = \sum_{i=1}^t p_i^2 \sigma^2(\bar{X}_i) = \sum_{i=1}^t \frac{p_i^2}{n_i} \sigma_i^2$
- Oczywiście, chcielibyśmy tak dobierać próbki, by była ona jak najmniejsza:  $n_i = n p_i \sigma_i / \sum_{i=1}^t p_i \sigma_i$

# Estymatory dla rozkładów cząstkowych

- Gdzie my to wszystko wykorzystujemy i po co?
  - Możemy sobie wyobrazić badania społeczne, gdzie próbujemy wnioskować na temat całej populacji poprzez analizy poszczególnych podgrup (podpopulacji) – np. analizujemy dane na temat wszystkich studentów w Europie poprzez poszczególne analizy studentów poszczególnych typów uczelni (np. osobno techniczne, medyczne, ogólne)
  - Albo rozkład powierzchni zajmowanej przez pewien gatunek trawy
  - Czy przeprowadzamy badania kliniczne leku w wielu ośrodkach w różnych krajach





FIGURE 6: Percentage basal grass cover, fire damage and rock cover per subpopulation and total population of *Haworthia koelmaniorum* var. *Mcurtryi* within the study area.



# Rozkład $\chi^2$

# Rozkład $\chi^2$

- Załóżmy (dla uproszczenia), że badamy populację opisaną standardowym rozkładem Gaussa o wartości oczekiwanej 0 i wariancji 1
- Pobieramy z niego próbę  $n$ -elementową i tworzymy sumę kwadratów:

$$\chi^2 = X_1^2 + X_2^2 + \dots + X_n^2$$

- Zmienna  $\chi^2$  podlega **rozkładowi chi-kwadrat** o  $n$  stopniach swobody
- Funkcja gęstości prawdopodobieństwa:

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

- Dystrybuanta:

$$F(\chi^2) = \frac{1}{\Gamma(\lambda) 2^\lambda} \int_0^{\chi^2} u^{\lambda-1} e^{-1/2u} du$$

– gdzie  $\lambda = 1/2n$  a  $n$  to liczba stopni swobody

# Rozkład $\chi^2$

- Funkcja charakterystyczna rozkładu  $\chi^2$  ma postać:


$$\phi_{\chi^2}(t) = (1 - 2it)^{-\lambda}$$

- Korzystając z jej własności funkcji charakterystycznej otrzymujemy natychmiast, że suma dwóch różnych  $\chi^2$  o  $n_1$  i  $n_2$  stopniach swobody daje również rozkład  $\chi^2$  o  $n = n_1 + n_2$  stopniach swobody
- Różniczkując funkcję charakterystyczną możemy wyznaczyć wartość oczekiwaną i wariancję rozkładu  $\chi^2$ :
$$E\{X^2\} = -i\phi_{\chi^2}'(0) = 2\lambda \equiv n$$
$$E\{(X^2)^2\} = -i\phi_{\chi^2}''(0) = 4\lambda^2 + 4\lambda$$
$$\sigma^2(X^2) = E\{(X^2)^2\} - (E\{X^2\})^2 = 4\lambda \equiv 2n$$
- Czyli wartość oczekiwana rozkładu  $\chi^2$  wynosi  $n$  a wariancja  $2n$



# Rozkład $\chi^2$

- Wykresy rozkładu i dystrybuanty rozkładu  $\chi^2$  dla  $n$  od 1 do 20



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

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

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

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



# Rozkład t-Studenta

# Rozkład t-Studenta

- Załóżmy  $X_1, \dots, X_n$  są zmiennymi losowymi pochodzącymi z rozkładu normalnego  $\mathcal{N}(\mu, \sigma^2)$

- Estymator wartości oczekiwanej (średnia z próby) to:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

a estymator wariancji to:

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

- Wtedy, zmienna  $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$  ma rozkład normalny standardowy (o średniej 1 i odchyleniu 0)


- A zmienna  $\frac{\bar{X} - \mu}{S/\sqrt{n}}$ , gdzie zastąpiliśmy odchylenie jego estymatorem ma **rozkład t-Studenta** o  $n-1$  stopniach swobody

# Rozkład t-Studenta


- Funkcja gęstości prawdopodobieństwa

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

$\nu$  – liczba stopni swobody



- Jak widać, rozkład t-Studenta jest symetryczny względem 0
- Rozkład **dąży do rozkładu Gaussa** gdy  $\nu \rightarrow \infty$
- Z symetrii względem 0 mamy związek (analogicznie jak dla Gaussa):  $P(|t| \leq t) = 2F(|t|) - 1$



# Poziom ufności

# Poziom ufności


- Rozkłady  $\chi^2$  oraz t-Studenta pozwalają nam wprowadzić pojęcie **poziomu ufności** dla estymowanych wartości średnich oraz wariancji

- Wartość średnia z próby**

- pokazaliśmy, że rozkład t-Studenta ma wielkość

$$\frac{\bar{X} - \mu}{S/\sqrt{n}}$$

- możemy zatem zdefiniować prawdopodobieństwo wokół wartości oczekiwanej

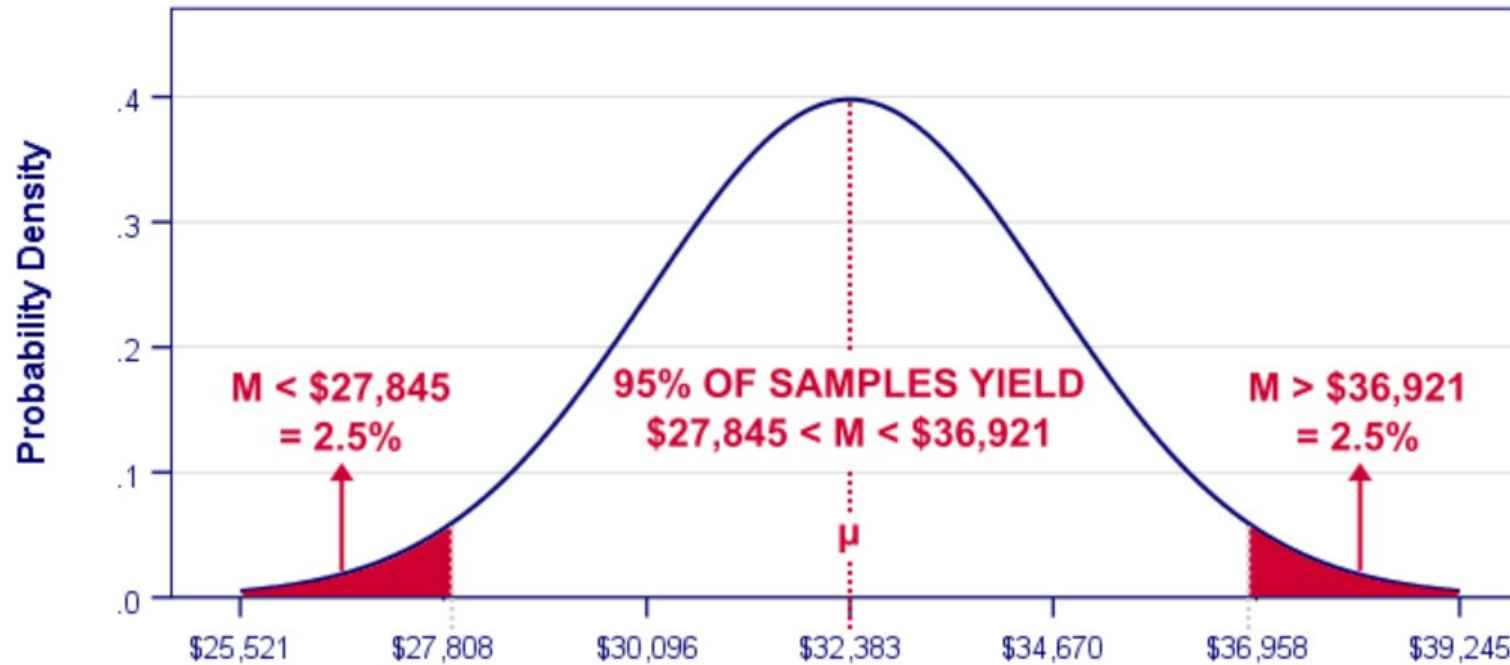


- oczekujemy, że nasz wynik (estymowana wartość średnia z próby) mieści się w przedziale wyznaczonym przez poziom ufności
- Dla dużych wartości  $n$  możemy to prawdopodobieństwo estymować rozkładem normalnym (t-Student  $\rightarrow$  rozkład normalny)

# Poziom ufności


Sampling Distribution Mean Income

$\mu = \$32,383$  |  $\sigma = \$22,874$  |  $N = 100$



**SAMPLING  
DISTRIBUTION  
FOR SAMPLE  
MEANS**

**SAMPLE 1**  
**SAMPLE 2**  
**SAMPLE 3**  
**SAMPLE ...**



**CONFIDENCE  
INTERVALS  
DIFFERENT  
SAMPLES**

**95% OF ALL SAMPLES YIELD 95% CI THAT CONTAINS  $\mu$**


© www.spss-tutorials.com

# Poziom ufności

- Rozkłady  $\chi^2$  oraz t-Studenta pozwalają nam wprowadzić pojęcie **poziomu ufności** dla estymowanych wartości średnich oraz wariancji

- **Wariancja z próby**

- Można, że rozkład  $\chi^2$  ma wielkość  $\frac{n-1}{\sigma^2} S^2$  ← estymator wariancji
- możemy zatem zdefiniować prawdopodobieństwo wokół wariancji



$$\frac{(n-1)s^2}{\chi^2_{\alpha/2}} \leq \sigma^2 \leq \frac{(n-1)s^2}{\chi^2_{1-\alpha/2}}$$

- oczekujemy, że nasz wynik (estymowana wariancja z próby) mieści się w przedziale wyznaczonym przez poziom ufności

[https://en.wikipedia.org/wiki/Confidence\\_interval](https://en.wikipedia.org/wiki/Confidence_interval)





# Weryfikacja hipotez statystycznych

# 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



- 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  $T' \in U$

# Hipoteza zerowa a hipoteza alternatywna

- Każde testowanie hipotez zaczynamy od założenia, że **nie ma związku** między zmiennymi lub nie ma różnic między porównywanymi grupami.

**Hipoteza zerowa ( $H_0$ ) zawsze mówi o braku związku między zmiennymi lub o braku różnicy.**

- Hipoteza alternatywna (badawcza),  $H_A$ , stawiana jest przez nas i dotyczy sytuacji wytłumaczenia zjawiska, kiedy hipoteza zerowa jest fałszywa
  - z metodologicznego punktu widzenia nie jest możliwe, aby w pełni udowodnić jej prawdziwość.
  - wystarczy, że pojawi się jeden przypadek zaprzeczający hipotezie i staje się ona fałszywa (odnosi się to również do teorii).

**Hipotezy w badaniach falsyfikujemy a nie potwierdzamy.**

# 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.



# 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 $\chi^2$ i doświadczalny rozkład częstości

- Możemy również rozważać zmienną losową  $X$ , (opisaną rozkładem  $f(x)$ ) którą dzielimy na  $r$  przedziałów (histogram):  $\xi_1, \xi_2, \dots, \xi_i, \dots, \xi_r$

- Całkując  $f(x)$  w przedziałach otrzymujemy prawdopodobieństwo  $p_i$  zaobserwowania zmiennej  $X$  w danym przedziale (binie):

$$p_i = P(x \in \xi_i) = \int_{\xi_i} f(x) dx; \quad \sum_{i=1}^r p_i = 1$$

- Z pobranej próby o liczebności  $n$  oznaczamy przez  $n_i$  elementy leżące w danym przedziale  $\xi_i$

- Oczywiście zachodzi relacja:  $n = \sum_{i=1}^r n_i$   
suma wejść w poszczególnych binach równa jest liczebności próby

- Oczekiwalibyśmy** (zakładając prawdziwość  $f(x)$ ), **że:**  $n_i = np_i$

- Hipoteza:** zakładamy, że dla dużych wartości liczb  $n_i$  ich wariancja równa się  $n_i$  (patrz dyskusja o rozkładzie Poissona) i że rozkład wielkości  $u_i$ :

$$u_i^2 = \frac{(n_i - np_i)^2}{n_i}, \quad \text{lub} \quad u_i^2 = \frac{(n_i - np_i)^2}{np_i} \quad \text{ma rozkład Gaussa}$$

# Test $\chi^2$ i doświadczalny rozkład częstości

- Wtedy, suma kwadratów:  $T = \sum_{i=1}^r u_i^2$
- Będzie miała (dla dużych  $n$ ) rozkład  $\chi^2$
- **Jaka jest liczba stopni swobody?** Z definicji histogramu mamy jedno **równanie więzów**:  $n = \sum_{i=1}^r n_i$
- Zatem zmienne  $u_i$  **nie są niezależne**, więc liczba stopni swobody równa się  $r-1$
- Oczywiście, jeżeli dodatkowo estymujemy  $p$  parametrów rozkładu na podstawie pomiarów (wprowadzamy  $p$  kolejnych więzów uzależniających od siebie wielkości  $u_i$ ), to liczba stopni swobody wynosi  $r-1-p$
- Wartość  $T$  porównujemy, tak jak do tej pory, z kwantylami rozkładu  $\chi^2$  o określonej liczbie stopni swobody dla danego poziomu istotności  $\alpha$ :  $T > \chi_{1-\alpha}^2$
- **Jeśli nierówność jest spełniona – odrzucamy hipotezę**

# 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  $\alpha$

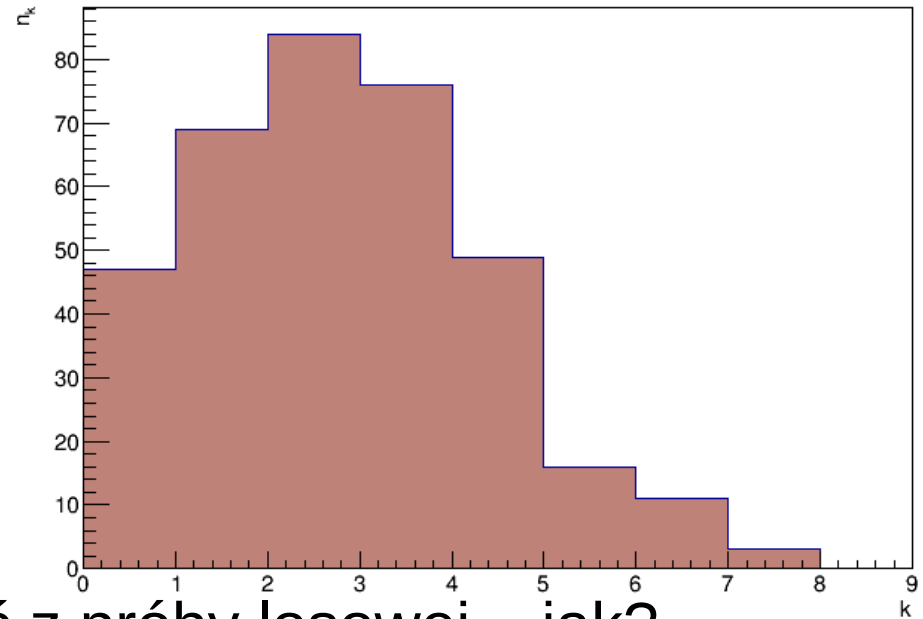
Wykorzystując zaimplementowaną funkcję zweryfikować hipotezę mówiącą, że dane pomiarowe podlegają rozkładowi Poissona. Dobrać odpowiednią wartość poziomu istotności. Uwaga! Kwanyl możemy odczytać z policzonej na ostatnich zajęciach dystrybuanty. (2 pkt.)



# 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 – wyprowadziliśmy go sobie na Wykładzie 10:

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

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

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

**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**



# Test równości wariancji (test $F$ -Fishera)

# Test równości wariancji (*F*-Fishera)

- **Problem:** porównywanie wariancji populacji o jednakowych wartościach średnich
- **Przykład:** pomiar tej samej wielkości dwoma przyrządami pomiarowymi (zakładamy brak niepewności systematycznych – typu B)
- **Pytanie (hipoteza):** czy pomiary będą miały jednakowe wariancje (czy dokładność pomiaru jest jednakowa dla obu przyrządów)?
- Załóżmy, że rozważane populacje mają rozkład normalny
- Pobieramy próby o liczebności  $N_1$  i  $N_2$
- Dla każdej z pobranych prób wyznaczamy wariancję i liczymy iloraz
$$F = s_1^2 / s_2^2 \quad s^2(X) = \frac{1}{N-1} \sum_{i=1}^N (X_i - \bar{X})^2 \quad s^2(\bar{X}) = \frac{1}{N \cdot (N-1)} \sum_{i=1}^N (X_i - \bar{X})^2 = s^2(X) / N$$
- Jeśli hipoteza o równości wariancji jest **prawdziwa**, to iloraz  $F$  powinien być bliski jedności  $F \sim 1$

# Test równości wariancji ( $F$ -Fishera)

- Można udowodnić, że tego typu wielkość ma rozkład  $F$ -Fishera

$$f(F) = \left(\frac{f_1}{f_2}\right)^{\frac{1}{2}f_1} \frac{\Gamma\left(\frac{1}{2}(f_1+f_2)\right)}{\Gamma\left(\frac{1}{2}f_1\right)\Gamma\left(\frac{1}{2}f_2\right)} F^{\frac{1}{2}f_1-1} \left(1 + \frac{f_1}{f_2}F\right)^{-\frac{1}{2}(f_1+f_2)} \quad f_1 = N_1 - 1; \quad f_2 = N_2 - 1$$

- Szukamy zatem analogicznie wartości granicznej określającej obszar krytyczny, która jest odpowiednim kwantylem rozkładu  $F$ -Fischera:

$$P\left(\frac{S_1^2}{S_2^2} > F_{1-\alpha}\right) = \alpha$$

- Ostatecznie sprawdzamy zatem warunek:

$$\frac{S_1^2}{S_2^2} > F_{1-\alpha}$$

- To jest test jednostronny**, na ogół posługujemy jednak **testem dwustronnym**:

$$\frac{S_g^2}{S_k^2} > F_{1-\alpha/2}(f_g, f_k), \text{ gdzie } f \text{ to liczby stopni swobody}$$

# Test równości wariancji (*F*-Fishera)

- Czyli w praktyce musimy zweryfikować hipotezę:

$$\frac{s_g^2}{s_k^2} > F_{1-\alpha/2}(f_g, f_k) = F'_{\alpha}(f_g, f_k)$$

- Indeksy *g* i *k* oznaczają większą i mniejszą wariancję z próby, czyli:

$$s_g^2 > s_k^2$$

- Jeżeli nierówność jest **spełniona**, to hipotezę o równości wariancji można **odrzuć**

# Test równości wariancji - przykład

Numer pomiaru	Przyrząd 1	Przyrząd 2				
1	100	97	0,2	0,04	-2,86	8,16
2	101	101	1,2	1,44	1,14	1,31
3	102	102	2,2	4,84	2,14	4,59
4	100	99	0,2	0,04	-0,86	0,73
5	98	101	-1,8	3,24	1,14	1,31
6	97	98	-2,8	7,84	-1,86	3,45
7	100	101	0,2	0,04	1,14	1,31
8	101		1,2	1,44		
9	99		-0,8	0,64		
10	100		0,2	0,04		
Średnia	99,8	99,86				
Stopnie swobody	9	6				
S <sup>2</sup>	19,6	20,86				
S <sup>2</sup> /f	2,18	3,48				
F	1,6					

- Korzystamy z kwantyli funkcji  $F$

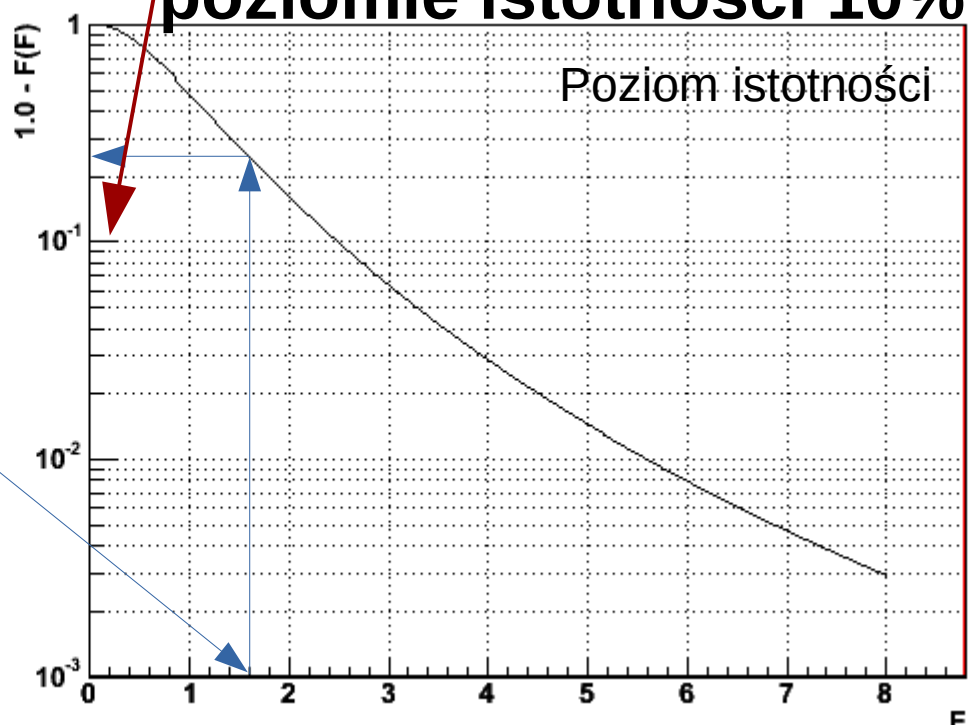

$$F''_{0,2}(6,9) = F_{0,9}(6,9) = 2.51$$

$$F''_{0,1}(6,9) = F_{0,95}(6,9) = 3.29$$

$$F''_{0,02}(6,9) = F_{0,99}(6,9) = 5.61$$

$$F''_{0,01}(6,9) = F_{0,995}(6,9) = 6.89$$

- 1.6 < 3.29 – nie ma podstaw do odrzucenia hipotezy na poziomie istotności 10%**





# Porównanie wartości średnich (test t-Studenta)

# Test równości średnich ( $t$ -Studenta)

- **Problem:** porównywanie wartości średnich dwóch prób losowych
- **Przykład:** badamy średni wzrost studentek 1 roku w Warszawie (populacja  $X$ ) oraz w Nowym Jorku (populacja  $Y$ )
- **Pytanie (hipoteza):** czy wartości średnie obu populacji, na podstawie pobranych prób losowych, są jednakowe?
- Tak postawiona hipoteza cicho zakłada, że  $X$  i  $Y$  to te same populacje
- Powyższe rozważania możemy **uogólnić** na porównanie wartości średnich dwóch prób losowych z populacji  $X$  oraz  $Y$  o liczebnościach  $N_1$  i  $N_2$



# Zastosowanie testu t-Studenta

- **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 średnich:

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

- Wariancje średnich 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  $\Delta/\sigma(\Delta)$  powinien podlegać rozkładowi Gaussa

# 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



- 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 stabilizowane 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
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





# 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 niepopelnienia 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 popelnienia danego błędu, jednocześnie zmniejszamy je dla drugiego).




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

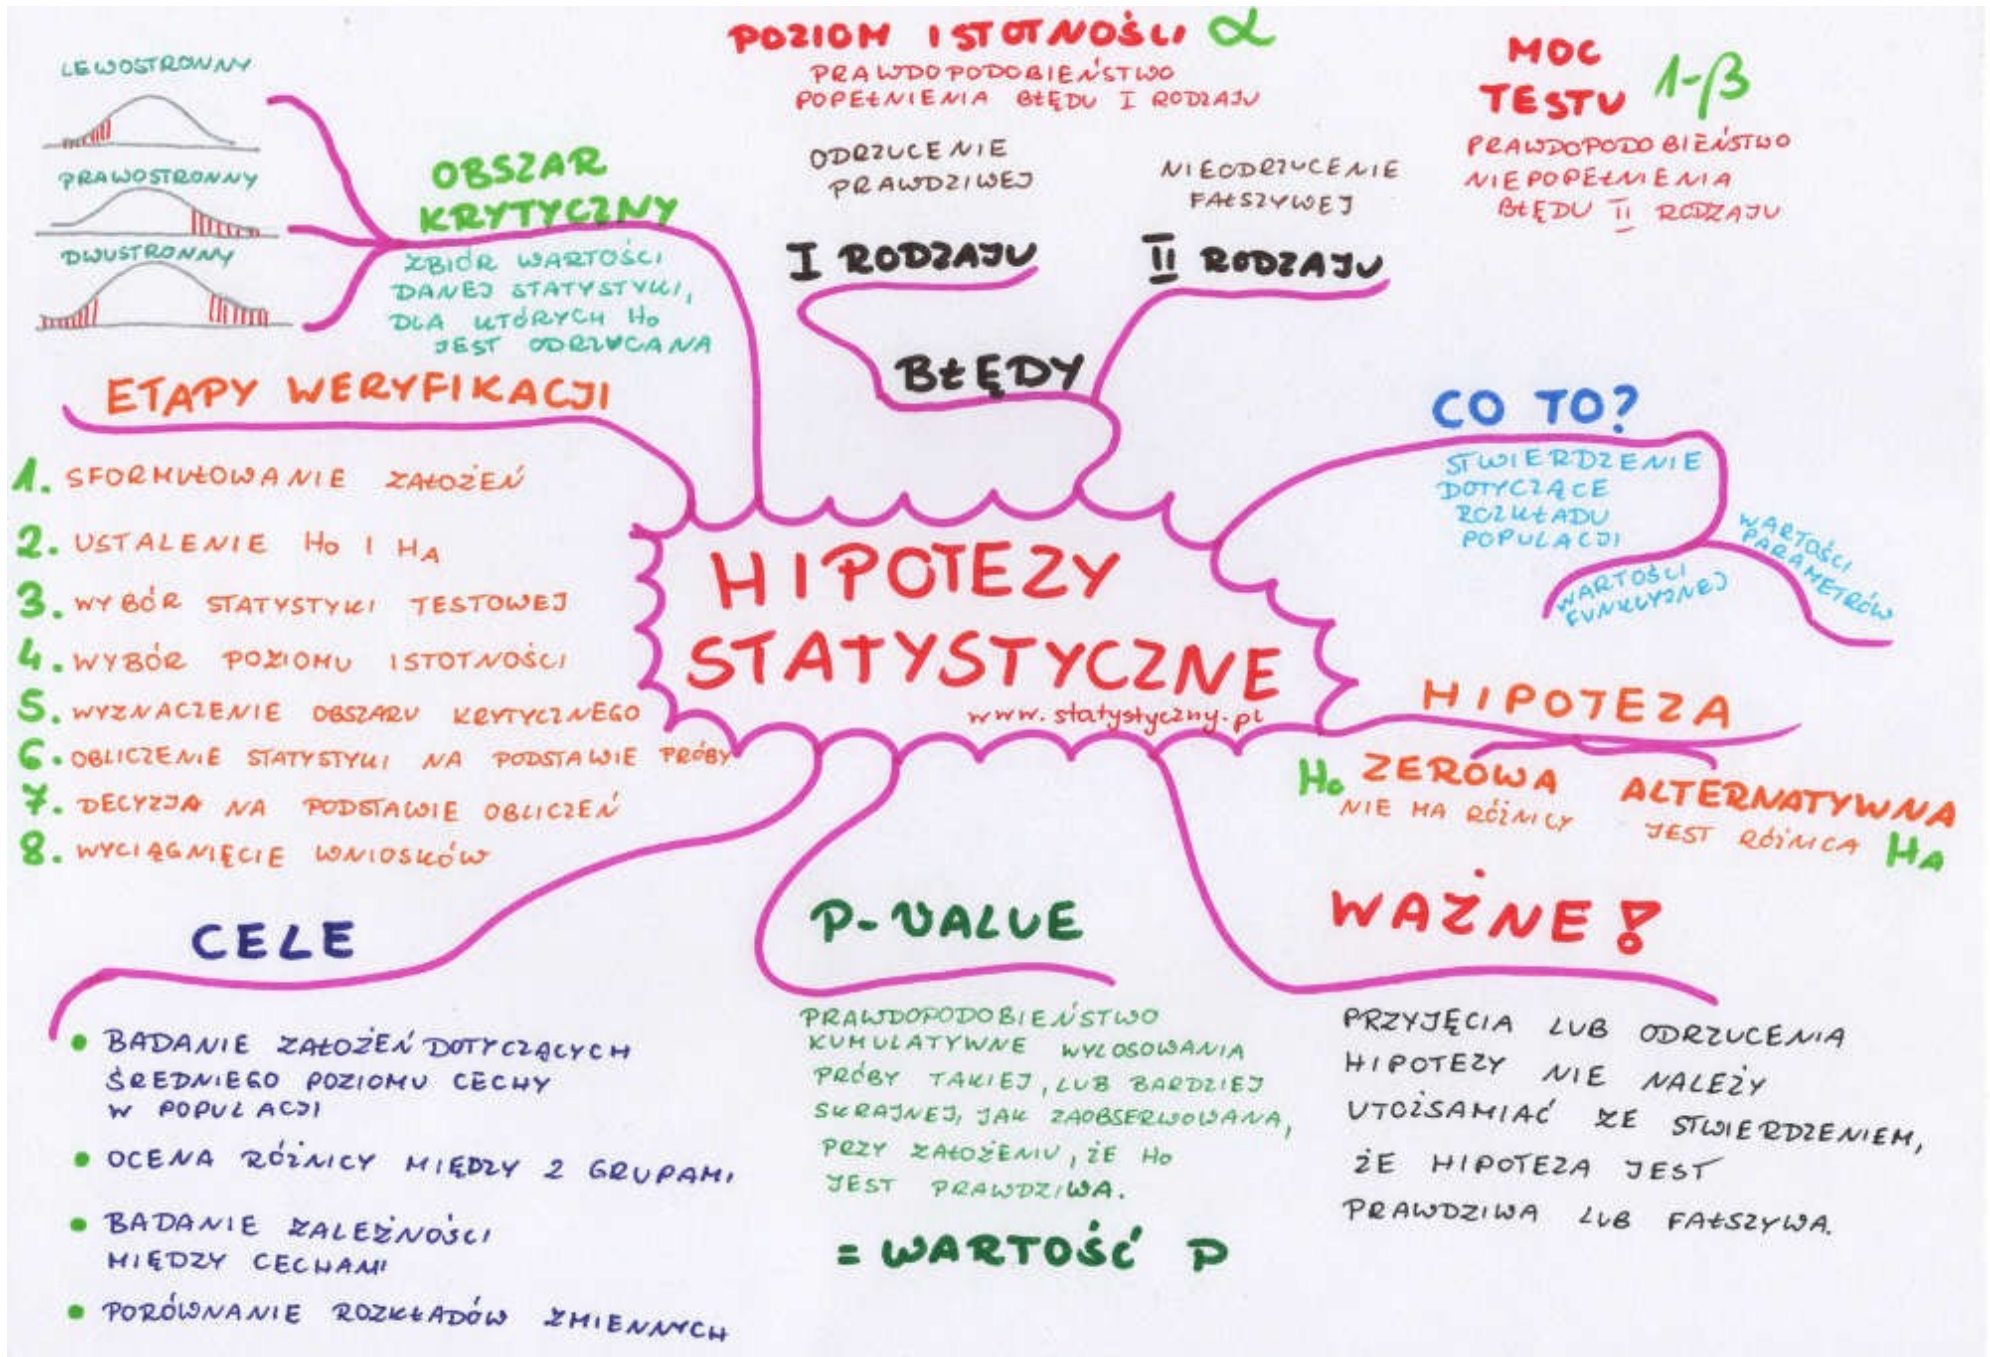
# Moc testu


## Moc testu: interpretacja graficzna (1)

rozkłady statystyki testowej przy założeniu prawdziwości  
hipotezy zerowej i alternatywnej



# Testy statystyczne





**KONIEC**