

Metody Ekonometryczne

Goodness of fit i wprowadzenie do wnioskowania statystycznego

Jakub Mućk
Szkola Główna Handlowa w Warszawie

Estymator MNK

- Dla jednorównaniowego modelu liniowego:

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon, \quad (1)$$

estymator MNK (OLS) przyjmuję postać:

$$\hat{\beta}^{OLS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}. \quad (2)$$

- Estymator wariancji-kowariancji można zapisać jako:

$$\text{Var}(\hat{\beta}^{OLS}) = \mathbb{S}_{\varepsilon}^2 (\mathbf{X}^T \mathbf{X})^{-1}, \quad (3)$$

gdzie wariancja składnika losowego można oszacować jako $\mathbb{S}_{\varepsilon}^2$:

$$\mathbb{S}_{\varepsilon}^2 = \frac{e^T e}{n - (k + 1)} = \frac{SSE(\hat{\beta}^{OLS})}{df} \quad (4)$$

gdzie $SSE(\hat{\beta}^{OLS})$ to suma kwadratów reszt, a df to **liczba stopni swobody**.

Założenia:

- 1 $rz(\mathbf{X}) = k + 1 \leq n$
- 2 $\mathbb{E}(\mathbf{X}\varepsilon) = 0$
- 3 $\mathbb{E}(\varepsilon) = 0$
- 4 $Var(\varepsilon) = \mathbb{E}(\varepsilon\varepsilon^T) = I\sigma^2$
- 5 $\varepsilon_i \sim N(0, \sigma^2)$

Twierdzenie Gaussa - Markowa

Estymator $\hat{\beta}$ uzyskany Klasyczną Metodą Najmniejszych Kwadratów jest estymatorem **BLUE** [*best linear unbiased estimator*], tj. zgodnym, nieobciążonym i najefektywniejszy w klasie liniowych estymatorów wektora β .

- nieobciążoność, czyli: $\mathbb{E}(\hat{\beta}^{OLS}) = \beta$
- najefektywniejszy, czyli posiadający najmniejszą wariancję w swojej klasie
- zgodny, czyli: $\text{plim}_{n \rightarrow \infty} \hat{\beta}_n^{OLS} = \beta$.

Goodness-of-fit

- **Miary dopasowania (*goodness-of-fit*)** pozwalają ocenić stopień dopasowania wartości teoretycznych wynikających z oszacowań modelu ekonometrycznego do danych empirycznych.
- **Miary dopasowania (*goodness-of-fit*) nie stanowią formalnego kryterium jakości modelu.**
- Przykładowe miary dopasowania dla jednorównaniowego liniowego modelu ekonometrycznego:
 - ▶ R^2 ,
 - ▶ skorygowany \bar{R}^2 ,
 - ▶ kryteria informacyjne.

- Współczynnik determinacji R^2 jest wynikiem dekompozycji **łącznej obserwowanej wariancji/zmienności SST (total variance)**:

$$SST = \sum_{i=1}^N (y_i - \bar{y})^2 = (\mathbf{y} - \bar{\mathbf{y}})^T (\mathbf{y} - \bar{\mathbf{y}}) \quad (5)$$

gdzie \bar{y} ($\bar{\mathbf{y}}$) to średnia wartość (wektor z średnią wartością).

- Punktem wyjścia jest *liniowy* model:

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon, \quad (6)$$

- oszacowania parametrów β pozwalają wyznaczyć wartości teoretyczne ($\hat{\mathbf{y}}$) oraz reszty ($\hat{\mathbf{e}}$):

$$\mathbf{y} = \mathbf{X}\hat{\beta} + \hat{\mathbf{e}} = \hat{\mathbf{y}} + \hat{\mathbf{e}}. \quad (7)$$

- Wykorzystując powyższy fakt i definicje łącznej wariancji/zmienności (SST):

$$SST = (\hat{\mathbf{y}} + \hat{\mathbf{e}} - \bar{\mathbf{y}})^T (\hat{\mathbf{y}} + \hat{\mathbf{e}} - \bar{\mathbf{y}}) = (\hat{\mathbf{y}} - \bar{\mathbf{y}})^T (\hat{\mathbf{y}} - \bar{\mathbf{y}}) + \hat{\mathbf{e}}^T \hat{\mathbf{e}} + 2(\hat{\mathbf{y}} - \bar{\mathbf{y}})^T \hat{\mathbf{e}} \quad (8)$$

- $(\hat{\mathbf{y}} - \bar{\mathbf{y}})^T (\hat{\mathbf{y}} - \bar{\mathbf{y}})$ to łączna zmienność wartości teoretycznych (SSR), tj. wynikających z oszacowań oraz zmienności zmiennych objaśniających.
- Jeżeli modeli liniowy zawiera wyraz wolny to wtedy $(\hat{\mathbf{y}} - \bar{\mathbf{y}})^T \hat{\mathbf{e}} = 0$.
- $\hat{\mathbf{e}}^T \hat{\mathbf{e}}$ to suma kwadratów reszt (SSE). Ostatecznie:

$$\underbrace{SST}_{\text{Total}} = \underbrace{SSR}_{\text{Regression}} + \underbrace{SSE}_{\text{Errors}}. \quad (9)$$

- Współczynnik determinacji R^2 stanowi zatem relację **zmienności wyjaśnionej** (SSE) do **zmienności łącznej** (SST) :

$$R^2 = \frac{SSR}{SST} = \frac{\sum_{i=1}^N (\hat{y} - \bar{y})^2}{\sum_{i=1}^N (y - \bar{y})^2}, \quad (10)$$

a z dekompozycji łącznej wariancji (SST) może zostać wyrażony przy pomocy **zmienności reszt**:

$$R^2 = 1 - \frac{SSE}{SST}. \quad (11)$$

- Charakterystyki R^2 :

- ▶ $R^2 \in (0, 1)$
- ▶ R^2 faworyzuje modele z większą liczbą zmiennych egzogenicznych
- ▶ konstrukcja R^2 opiera się o uwzględnienie wyrazu wolnego w modelu.

- W przypadku, gdy w specyfikacji modelu ekonometrycznego nie uwzględniono wyrazu wolnego, współczynnik R^2 może przyjmować wartości powyżej jedności.
- Rozwiązaniem tego problemu jest niescentrowany R_N^2 :

$$R_N^2 = 1 - \frac{\mathbf{e}\mathbf{e}^T}{\mathbf{y}\mathbf{y}^T} \quad (12)$$

- ▶ \mathbf{e} - wektor reszt.
 - ▶ \mathbf{y} - wektor obserwacji zmiennej endogenicznej.
 - ▶ W porównaniu ze standardowym R^2 obserwowana zmienność nie jest zcentrowana wokół wartości średniej, tj. $\mathbf{y}\mathbf{y}^T$.
- $R_N^2 \in \langle 0, 1 \rangle$
 - Interpretacja: większa wartość R_N^2 oznacza większą rolę zmiennych egzogenicznych w wyjaśnianiu zmienności zmiennej objaśnianej.

- Współczynnik determinacji R^2 zawsze będzie faworyzował modele z większą liczbą zmiennych.
- W porównaniu z podstawowym współczynnikiem R^2 , **skorygowany współczynnik \bar{R}^2** uwzględnia również **liczbę stopni swobody**:

$$\bar{R}^2 = R^2 - \frac{k}{n - (k + 1)}(1 - R^2) \quad (13)$$

- Skorygowany współczynnik R^2 przyjmuje zazwyczaj niższe wartości:

$$\bar{R}^2 \leq R^2 \quad (14)$$

w szczególności możliwe jest przyjmowanie wartości poniżej 0.

- Skorygowany \bar{R}^2 jest **pozbawiony standardowej interpretacji**.

- Kryterium Akaike'a (AIC)** jest miernikiem, który uwzględnia zarówno dopasowanie do obserwacji (**funkcja wiarygodności**) oraz liczbę stopni swobody:

$$AIC = \underbrace{\ln \frac{1}{n} \sum_{i=1}^n e_i^2}_{\text{funkcja wiarygodności}} + \underbrace{\frac{2(k+1)}{n}}_{\text{liczba stopni swobody}} \quad (15)$$

gdzie n to liczba obserwacji, $k+1$ to liczba oszacowanych parametrów oraz e_i to reszta dla i -tej obserwacji.

- Bayesowskie kryterium Schwarza (BIC)** jest miernikiem, który uwzględnia zarówno dopasowanie do obserwacji (**funkcja wiarygodności**) oraz liczbę stopni swobody:

$$BIC = \underbrace{\ln \frac{1}{n} \sum_{i=1}^n e_i^2}_{\text{funkcja wiarygodności}} + \underbrace{\frac{(k+1) \ln(n)}{n}}_{\text{liczba stopni swobody}} \quad (16)$$

gdzie oznaczenia jak w przypadku AIC.

- Kryteria AIC i BIC **maleją wraz ze wzrostem funkcji wiarygodności** oraz **rosną wraz ze wzrostem liczby parametrów**.
- Kryteria AIC i BIC nie posiadają interpretacji i są wykorzystywane do porównania dopasowania modeli.


Miernik	Opis
R^2	Ogólny miernik, interpretacja , rośnie wraz z liczbą zmiennych
Niescentrowany R^2	model bez wyrazu wolnego
Skorygowany R^2	uwzględnia <i>korektę</i> na liczbę zmiennych, porównanie modeli
Kryterium AIC	uwzględnia <i>korektę</i> na liczbę zmiennych, porównanie modeli
Kryterium BIC	uwzględnia <i>korektę</i> na liczbę zmiennych, porównanie modeli; $BIC < AIC$


Powyższe mierniki kwantyfikują jedynie dopasowanie modelu do obserwowanych danych. Wspomniane dopasowanie do danych ma charakter informacyjny i **nie stanowi głównego kryterium w wyborze modelu.**


- Kwartet Anscombe'a to przykład **czterech** zbiorów danych z dwoma zmiennymi x i y .
- Średnia x : 9.
- Średnia y : 4.1.
- Wariancja y : 7.5,
- Wariancja x : 11.
- Współczynnik korelacji: 0.816
- Równanie regresji z oszacowanymi parametrami:


$$y = 3 + .5x, \quad (17)$$


a R^2 wynosi 0.63.




















Wnioskowanie statystyczne

- **Wnioskowanie statystyczne** (*statistical inference*) pozwala na generalizację wyników estymacji pewnych cech charakterystyk uzyskanych na podstawie całej próby na całą populację.
- **Wnioskowanie statystyczne** obejmuje:
 - ▶ **Estymację** nieznanymi parametrów.
 - ★ Estymacja parametryczna
⇒ bazuje na założeniu o rozkładzie prawdopodobieństwa.
 - ★ Estymacja nieparametryczna
⇒ brak założeń o rozkładzie prawdopodobieństwa.
 - ★ Estymacja semiparametryczna.
 - ▶ **Weryfikację hipotez** statystycznych.
- **Wnioskowanie statystyczne** można oprzeć m.in na:
 - ▶ **Podjęciu częstościowym.**
 - ▶ **Podjęciu bayesowskim.**

- Zgodnie z zasadami wnioskowania statystycznego można wyróżnić dwa ryzyka wynikające z wykorzystania testów statystycznych, których konstrukcja opiera się na klarownie sformułowanych hipotezach: **zerowej** (\mathcal{H}_0) oraz **alternatywnej** (\mathcal{H}_1):

Błąd pierwszego rodzaju

to **odrzućcie** \mathcal{H}_0 , która w rzeczywistości jest **prawdziwa**.

Błąd drugiego rodzaju

to **przyjęcie** \mathcal{H}_0 , która w rzeczywistości jest **fałszywa**.

- **Rozmiar testu** (*size of test*) to prawdopodobieństwo (błédnego) odrzucenia hipotezy zerowej jeżeli jest ona prawdziwa.

$$\alpha = Pr(\text{odrzucenie } \mathcal{H}_0 | \mathcal{H}_0) \quad (18)$$

- ▶ Rozmiar testu to inaczej prawdopodobieństwo popełnienia błédu I rodzaju.

- **Moc testu** (*power of test*) to prawdopodobieństwo (poprawnego) odrzucenia hipotezy zerowej jeżeli prawdziwa jest hipoteza alternatywna.

$$\beta = Pr(\text{odrzucenie } \mathcal{H}_0 | \mathcal{H}_1) \quad (19)$$

- ▶ Moc testu to inaczej dopełnienie prawdopodobieństwa popełnienia błédu II rodzaju.

- W pakietach ekonometryczno-statystycznych szeroko stosowane jest **p-value (probability value)**, które mierzy **prawdopodobieństwo błędu pierwszego rodzaju**.
- W praktyce ekonometrycznej nie rozważa się minimalizacji obu ryzyk i wnioskowanie statystyczne jest najczęściej przeprowadzane na podstawie analizy prawdopodobieństw błędu pierwszego rodzaju.
- **Poziom krytyczny** oznacza arbitralnie wybrany poziom prawdopodobieństwa błędu I rodzaju, który można uznać za akceptowalny. Najczęściej jest równy: 0.01, 0.05 lub 0.1.

Statystyczna istotność oszacowań

- Test t-studenta pozwala zweryfikować istotność oszacowania parametru dla każdej zmiennej objaśniającej (x_j) osobno, tj.:

$$\mathcal{H}_0 : \beta_j = 0 \quad \mathcal{H}_1 : \beta_j \neq 0 \quad (20)$$

- Statystyka testowa:

$$t_j = \frac{\hat{\beta}_j}{\mathbb{S}(\hat{\beta}_j)} \quad (21)$$

gdzie $\hat{\beta}_j$ to oszacowanie punktowe parametru β_j , a $\mathbb{S}(\hat{\beta}_j)$ to błąd szacunku.

- Statystyka testowa testu t-studenta jest odwrotnością względnego błędu szacunku.
- Wartości krytyczne pochodzą z rozkładu t-studenta i można je uzyskać dla określonej liczby stopni swobody ($df = n - (k + 1)$) oraz przyjętego poziomu krytycznego (α).
- Jeżeli $|t_j| > t^{df, \alpha/2}$ - to mamy podstawy do odrzucenia \mathcal{H}_0 na rzecz \mathcal{H}_1 .
- Jeżeli $|t_j| < t^{df, \alpha/2}$ - to nie ma podstaw do odrzucenia \mathcal{H}_0 na rzecz \mathcal{H}_1 .

- Łączna istotność oszacowań parametrów może być weryfikowana przy pomocy testu Walda, tj.:

$$\mathcal{H}_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0 \quad (22)$$

$$\mathcal{H}_1 : \exists_{j \in \{1, \dots, k\}} \beta_j \neq 0 \quad (23)$$

- Statystyka testowa:

$$\mathcal{F} = \frac{R^2/k}{(1 - R^2)/(n - (k + 1))} \quad (24)$$

- Statystyka testowa \mathcal{F} ma rozkład F-Snedecora z $r_1 = k$ oraz $r_2 = n - (k + 1)$ stopniami swobody.
- Jeżeli $\mathcal{F} > \mathcal{F}^{r_1, r_2, \alpha}$ - to mamy podstawy do odrzucenia \mathcal{H}_0 na rzecz \mathcal{H}_1 .
- Jeżeli $\mathcal{F} < \mathcal{F}^{r_1, r_2, \alpha}$ - to nie ma podstaw do odrzucenia \mathcal{H}_0 na rzecz \mathcal{H}_1 .

MNK z ograniczeniami

- **Test Walda** umożliwia przede wszystkim **szersze testowanie restrykcji liniowych**.

$$\mathcal{H}_0 : \mathbf{R} \times \beta = q \quad (25)$$

Macierz restrykcji \mathbf{R} jest wymiarów $r \times (k+1)$, gdzie r to liczba restrykcji. Restrykcje są zapisywane *wierszowo*, a test Walda pozwala na weryfikację koniunkcji wszystkich restrykcji.

- Statystyka testowa:

$$\mathcal{F} = \frac{(SSE(\hat{\beta}^R) - SSE(\hat{\beta}))/r}{SSE(\hat{\beta})/(n - (k + 1))} \quad (26)$$

ma rozkład F-Snedecora z $r_1 = r$ oraz $r_2 = n - (k + 1)$.

$SSE(\hat{\beta}^R)$ - jest sumą kwadratów reszt modelu z restrykcjami;

$SSE(\hat{\beta})$ - jest sumą kwadratów reszt modelu bez restrykcji;

- Przykłady wykorzystania testu Walda:

- ▶ Weryfikowanie restrykcji ekonomicznych.
- ▶ Test pominiętych zmiennych.

- **Przykład #1:** test Walda na istotność zmiennych w modelu:

$$\mathbf{R} = \begin{bmatrix} 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix} \quad \text{oraz} \quad q = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

- **Przykład #2:** załóżmy, że mamy cztery zmienne egzogeniczne oraz

- ① $\beta_1 = \beta_3$
- ② $\beta_2 = \nu$
- ③ $\beta_1 + \beta_4 = \gamma$.

Wtedy:

$$\mathbf{R} = \begin{bmatrix} 0 & 1 & 0 & -1 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 & 1 \end{bmatrix} \quad \text{oraz} \quad q = \begin{bmatrix} 0 \\ \nu \\ \gamma \end{bmatrix}$$

- Punktem wyjścia jest **minimalizacja sumy kwadratów reszt** jednak **przy pewnych ograniczeniach**:

$$\min SSE(\hat{\beta}^R) = \min (\mathbf{y} - \mathbf{X}\beta)^T (\mathbf{y} - \mathbf{X}\beta) \quad (27)$$

$$\text{p.w.} \quad R\beta = q. \quad (28)$$

- Funkcja Lagrange'a:

$$\mathcal{L}(\beta, \lambda) = (\mathbf{y} - \mathbf{X}\beta)^T (\mathbf{y} - \mathbf{X}\beta) + 2\lambda^T (R\beta - q). \quad (29)$$

- Warunki pierwszego rzędu na optymalizację (minimalizację):

$$\frac{\partial \mathcal{L}}{\partial \beta} = -2\mathbf{X}^T (\mathbf{y} - \mathbf{X}\beta) + 2R^T \lambda = 0, \quad (30)$$

$$\frac{\partial \mathcal{L}}{\partial \lambda} = 2(R\beta - q) = 0. \quad (31)$$

- Po uproszczeniu otrzymujemy następujący (macierzowy) układ równań:

$$\begin{bmatrix} \mathbf{X}^T \mathbf{X} & R^T \\ R & 0 \end{bmatrix} \begin{bmatrix} \beta \\ \lambda \end{bmatrix} = \begin{bmatrix} \mathbf{X}^T \mathbf{y} \\ q \end{bmatrix} \quad (32)$$

- Zatem rozwiązanie tego układu równań będzie zawierać estymator RLS (*restricted least squares*):

$$\hat{\beta}^R = \hat{\beta}^{OLS} - (\mathbf{X}^T \mathbf{X})^{-1} R^T \left[R (\mathbf{X}^T \mathbf{X})^{-1} R^T \right]^{-1} (R \hat{\beta}^{OLS} - q), \quad (33)$$

a towarzysząca wariancja wynosi:

$$\text{Var}(\hat{\beta}^R) = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1} - (\mathbf{X}^T \mathbf{X})^{-1} R^T \left[R (\mathbf{X}^T \mathbf{X})^{-1} R^T \right]^{-1} R (\mathbf{X}^T \mathbf{X})^{-1} \quad (34)$$

- Statystyka \mathcal{F} ma rozkład F-Snedecora z $r_1 = r$ oraz $r_2 = n - (k + 1)$ stopniami swobody.

$$\mathcal{F} = \frac{(SSE(\hat{\beta}^R) - SSE(\hat{\beta}))/r}{SSE(\hat{\beta})/(n - (k + 1))} \quad (35)$$

ma rozkład F-Snedecora z $r_1 = r$ oraz $r_2 = n - (k + 1)$.

$SSE(\hat{\beta}^R)$ - jest sumą kwadratów reszt modelu z restykcjami;

$SSE(\hat{\beta})$ - jest sumą kwadratów reszt modelu bez restykcji;

- Ogólniejsza statystyka \mathcal{W} :

$$\mathcal{W} = r\mathcal{F} \quad (36)$$

- ma rozkład χ^2 z r stopniami swobody.

Współliniowość

- **Współliniowość deterministyczna** to sytuacja, w której jedna ze zmiennych objaśniających może zostać przedstawiona jako kombinacja liniowa pozostałych regresorów. Wówczas niemożliwe jest uzyskanie estymatora β^{OLS} .
- **Współliniowość stochastyczna** polega na wysokiej zależności statystycznej pomiędzy zmiennymi objaśniającymi.
- Problem współliniowości (stochastycznej) może powodować zwiększenie **wariancji estymatora MNK (zmniejszenie efektywności)**.
- Współliniowość może zostać zidentyfikowana przy pomocy **czynnika inflacji wariancji CIW (ang. Variance Inflation Factor)**. Dla każdej ze zmiennych objaśniających konstruowany jest model x_j , w którym zmienną objaśnianą jest ona sama, a zmiennymi objaśniającymi pozostałe zmienne z wyjściowego zbioru regresorów, czyli:

$$\forall_{j \in J - \{j\}} x_j = \beta_0 + \beta_1 x_1 + \dots + \beta_J x_J + \varepsilon \quad (37)$$

Dla każdego modelu jest obliczany współczynnik determinacji R^2 , a następnie CIW_j :

$$CIW_j = \frac{1}{1 - R_j^2} \quad (38)$$

- **Wartości CIW powyżej 10 sugerują problem współliniowości**. Wtedy R^2 z regresji pomocniczej jest większe od 0.9.

W przypadku współliniowości kluczowa jest identyfikacja źródeł tego problemu, tj. czy wynika z jakości danych czy też specyfikacji modelu ekonometrycznego.

- Brak zmian.
- Usunięcie zmiennych współliniowych zmiennych objaśniających.
Usunięcie zmiennych objaśniających z specyfikacji modelu może doprowadzić do obciążenia oszacowań parametrów uzyskanych MNK.
- Transformacja zmiennych objaśniających.
- Wykorzystanie regresji grzbietowej (*ridge regression*):

$$\hat{\beta}^{RIDGE} = (\mathbf{X}^T \mathbf{X} + \lambda I)^{-1} \mathbf{X}^T \mathbf{y} \quad (39)$$

gdzie λ to skalar a I to macierz jednostkowa.

Estymator regresji grzbietowej $\hat{\beta}^{RIDGE}$ jest **obciążony**, ale posiada **mniejszą wariancję (jest bardziej efektywny)** niż $\hat{\beta}^{OLS}$.

Normalność rozkładu składnika losowego

- **Normalność rozkładu składnika losowego** nie jest wymaganą własnością składnika losowego, ale umożliwia korzystanie z testów statystycznych weryfikujących pozostałe własności składnika losowego.
- Badanie normalności składnika losowego:
 - ▶ histogram reszt,
 - ▶ testy statystyczne, np. test Jarque'a-Berry.

- **Test Jarque'a-Berry** jest najpopularniejszą metodą w weryfikacji normalności składnika losowego. Statystyka tego testu opiera się na kurtozie i skośności reszt:

$$JB = \frac{n}{6} \left(S^2 + \frac{1}{4} (K - 3)^2 \right) \quad (40)$$

gdzie S i K to odpowiednio estymatory skośności oraz kurtozy składnika losowego:

$$S = \frac{\frac{1}{n} \sum_{i=1}^n (e_i - \bar{e})^3}{\left(\frac{1}{n} \sum_{i=1}^n (e_i - \bar{e})^2 \right)^{\frac{3}{2}}} \quad \text{oraz} \quad K = \frac{\frac{1}{n} \sum_{i=1}^n (e_i - \bar{e})^4}{\left(\frac{1}{n} \sum_{i=1}^n (e_i - \bar{e})^2 \right)^2} - 3 \quad (41)$$

- Hipotezą zerową jest normalność składnika losowego:

$$\mathcal{H}_0 : \varepsilon \sim \mathcal{N}(0, \sigma^2)$$

- Wartość statystyki testowej ma rozkład χ^2 z dwoma stopniami swobody. Jeżeli wartość JB jest większa od wartości krytycznej z rozkładu χ^2 to są podstawy do odrzucenia \mathcal{H}_0 .
- Odrzucenie hipotezy zerowej uniemożliwia korzystanie z testów statystycznych. Ale w przypadku dużej próby, własności asymptotyczne testów nadal są pożądane.