

# Estymacja parametrów

Krzysztof Topolski

Wykład 5

Wrocław, 7 marca 2012

# Metoda największej wiarygodności

Niech  $X_1, X_2, \dots, X_n$  będzie próbą losową z rozkładu o gęstości  $f(x | \theta_1, \dots, \theta_k)$  gdzie  $\theta_1, \dots, \theta_k$  oznaczają parametry rozkładu.

Rozkład łączny próby, czyli rozkład łączny wektora losowego  $(X_1, X_2, \dots, X_n)$  jest postaci

$$f(x_1 | \theta_1, \dots, \theta_k) \times \dots \times f(x_n | \theta_1, \dots, \theta_k),$$

co możemy zapisać jako

$$\prod_{i=1}^n f(x_i | \theta_1, \dots, \theta_k).$$

## Metoda największej wiarygodności

Niech  $X_1, X_2, \dots, X_n$  będzie próbą losową z rozkładu o gęstości  $f(x | \theta_1, \dots, \theta_k)$  gdzie  $\theta_1, \dots, \theta_k$  oznaczają parametry rozkładu.

Rozkład łączny próby, czyli rozkład łączny wektora losowego  $(X_1, X_2, \dots, X_n)$  jest postaci

$$f(x_1 | \theta_1, \dots, \theta_k) \times \dots \times f(x_n | \theta_1, \dots, \theta_k),$$

co możemy zapisać jako

$$\prod_{i=1}^n f(x_i | \theta_1, \dots, \theta_k).$$

## Metoda największej wiarygodności

Niech  $X_1, X_2, \dots, X_n$  będzie próbą losową z rozkładu o gęstości  $f(x | \theta_1, \dots, \theta_k)$  gdzie  $\theta_1, \dots, \theta_k$  oznaczają parametry rozkładu.

Rozkład łączny próby, czyli rozkład łączny wektora losowego  $(X_1, X_2, \dots, X_n)$  jest postaci

$$f(x_1 | \theta_1, \dots, \theta_k) \times \dots \times f(x_n | \theta_1, \dots, \theta_k),$$

co możemy zapisać jako

$$\prod_{i=1}^n f(x_i | \theta_1, \dots, \theta_k).$$

## Funkcja wiarygodności

$$\begin{aligned}L(\theta | x) &= L(\theta_1, \dots, \theta_k | x_1, \dots, x_n) \\ &= \prod_{i=1}^n f(x_i | \theta_1, \dots, \theta_k).\end{aligned}$$

## Definicja.

Dla każdej realizacji  $x = (x_1, \dots, x_n)$  próby losowej niech  $\hat{\theta}(x)$  będzie wartością parametru  $\theta$ , dla której funkcja  $L(\theta|x)$  osiąga swoje maksimum jako funkcja  $\theta$  z ustalonym  $x$ .

Estymatorem największej wiarygodności parametru  $\theta$  opartym na próbie  $(X_1, \dots, X_n)$  jest  $\hat{\theta}(X_1, \dots, X_n)$ .

Czasami estymator wyznaczony metodą największej wiarygodności nazywa się w skrócie estymatorem MLE od angielskiego terminu (Maximum Likelihood Estimator).

## Definicja.

Dla każdej realizacji  $x = (x_1, \dots, x_n)$  próby losowej niech  $\hat{\theta}(x)$  będzie wartością parametru  $\theta$ , dla której funkcja  $L(\theta|x)$  osiąga swoje maksimum jako funkcja  $\theta$  z ustalonym  $x$ .

Estymatorem największej wiarygodności parametru  $\theta$  opartym na próbie  $(X_1, \dots, X_n)$  jest  $\hat{\theta}(X_1, \dots, X_n)$ .

Czasami estymator wyznaczony metodą największej wiarygodności nazywa się w skrócie estymatorem MLE od angielskiego terminu **(Maximum Likelihood Estimator)**.

## Jak wyznaczyć estymator największej wiarygodności?

Jeśli funkcja wiarygodności jest różniczkowalna względem  $\theta$  to możemy szukać kandydata na estymator MLE wśród wartości  $\theta$ , dla których

$$\frac{d}{d\theta}L(\theta|x) = L'(\theta|x) = 0.$$



## Jak wyznaczyć estymator największej wiarygodności?

Jeśli funkcja wiarygodności jest różniczkowalna względem  $\theta$  to możemy szukać kandydata na estymator MLE wśród wartości  $\theta$ , dla których

$$\frac{d}{d\theta}L(\theta|x) = L'(\theta|x) = 0.$$

## Przykład (Rozkład normalny)

Niech  $X_1, \dots, X_n$  będzie próbą z rozkładu normalnego  $N(\theta, 1)$ .

$$\begin{aligned}L(\theta|x) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} e^{-\frac{(x_i-\theta)^2}{2}} \\ &= \frac{1}{(2\pi)^{\frac{n}{2}}} e^{-\frac{1}{2} \sum_{i=1}^n (x_i-\theta)^2}\end{aligned}$$

Równanie

$$\frac{d}{d\theta} L(\theta|x) = 0$$

sprowadza się do równania

$$\sum_{i=1}^n (x_i - \theta) = 0.$$

Szukamy rozwiązania równania

$$\sum_{i=1}^n (x_i - \theta) = 0.$$

Przekształcając otrzymujemy równanie

$$\sum_{i=1}^n x_i - n\theta = 0$$

$$\theta = \frac{1}{n} \sum_{i=1}^n x_i.$$

Stąd  $\hat{\theta} = \bar{x}$  jest punktem, w którym funkcja wiarygodności może osiągać ekstremum.

Szukamy rozwiązania równania

$$\sum_{i=1}^n (x_i - \theta) = 0.$$

Przekształcając otrzymujemy równanie

$$\sum_{i=1}^n x_i - n\theta = 0$$

$$\theta = \frac{1}{n} \sum_{i=1}^n x_i.$$

Stąd  $\hat{\theta} = \bar{x}$  jest punktem, w którym funkcja wiarygodności może osiągać ekstremum.

Szukamy rozwiązania równania

$$\sum_{i=1}^n (x_i - \theta) = 0.$$

Przekształcając otrzymujemy równanie

$$\sum_{i=1}^n x_i - n\theta = 0$$

$$\theta = \frac{1}{n} \sum_{i=1}^n x_i.$$

Stąd  $\hat{\theta} = \bar{x}$  jest punktem, w którym funkcja wiarygodności może osiągać ekstremum.

Szukamy rozwiązania równania

$$\sum_{i=1}^n (x_i - \theta) = 0.$$

Przekształcając otrzymujemy równanie

$$\sum_{i=1}^n x_i - n\theta = 0$$

$$\theta = \frac{1}{n} \sum_{i=1}^n x_i.$$

Stąd  $\hat{\theta} = \bar{x}$  jest punktem, w którym funkcja wiarygodności może osiągać ekstremum.

Ponieważ

$$\frac{d^2}{d\theta^2} L(\theta|x)_{\theta=\bar{x}} < 0,$$

oraz nie ma innych kandydatów na maksimum, więc  $\bar{X}$  jest globalnym maksimum, a tym samym jest to estymator MLE parametru  $\theta$ .

## Przykład (rozkład 0-1)

Niech  $X_1, \dots, X_n$  będzie próbą z rozkładu 0-1 z prawdopodobieństwem wartości 1 równym  $p$ . Funkcja wiarygodności w tym przypadku ma postać

$$\begin{aligned}L(p|x) &= \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i} \\ &= p^y (1-p)^{n-y}\end{aligned}$$

gdzie  $y = \sum_{i=1}^n x_i$ .



Zamiast rozważania funkcji  $L(\theta|x)$  łatwiej jest rozważać jej logarytm, a więc funkcję  $\log L(p|x)$ .

$$\log L(p|x) = \log(p^y [1 - p]^{n-y}) = y \log(p) + (n - y) \log(1 - p).$$

Gdy  $0 < y < n$ , to różniczkując funkcję  $\log L(p|x)$  względem  $p$  otrzymujemy

$$\frac{d}{dp} \log L(p|x) = y \frac{1}{p} - (n - y) \frac{1}{1 - p}.$$

Przyrównując pochodną do zera otrzymujemy równanie

$$y \frac{1}{p} - (n - y) \frac{1}{1 - p} = 0.$$

Zamiast rozważania funkcji  $L(\theta|x)$  łatwiej jest rozważać jej logarytm, a więc funkcję  $\log L(p|x)$ .

$$\log L(p|x) = \log(p^y [1 - p]^{n-y}) = y \log(p) + (n - y) \log(1 - p).$$

Gdy  $0 < y < n$ , to różniczkując funkcję  $\log L(p|x)$  względem  $p$  otrzymujemy

$$\frac{d}{dp} \log L(p|x) = y \frac{1}{p} - (n - y) \frac{1}{1 - p}.$$

Przyrównując pochodną do zera otrzymujemy równanie

$$y \frac{1}{p} - (n - y) \frac{1}{1 - p} = 0.$$

Zamiast rozważania funkcji  $L(\theta|x)$  łatwiej jest rozważać jej logarytm, a więc funkcję  $\log L(p|x)$ .

$$\log L(p|x) = \log(p^y [1 - p]^{n-y}) = y \log(p) + (n - y) \log(1 - p).$$

Gdy  $0 < y < n$ , to różniczkując funkcję  $\log L(p|x)$  względem  $p$  otrzymujemy

$$\frac{d}{dp} \log L(p|x) = y \frac{1}{p} - (n - y) \frac{1}{1 - p}.$$

Przyrównując pochodną do zera otrzymujemy równanie

$$y \frac{1}{p} - (n - y) \frac{1}{1 - p} = 0.$$

Zamiast rozważania funkcji  $L(\theta|x)$  łatwiej jest rozważać jej logarytm, a więc funkcję  $\log L(p|x)$ .

$$\log L(p|x) = \log(p^y [1 - p]^{n-y}) = y \log(p) + (n - y) \log(1 - p).$$

Gdy  $0 < y < n$ , to różniczkując funkcję  $\log L(p|x)$  względem  $p$  otrzymujemy

$$\frac{d}{dp} \log L(p|x) = y \frac{1}{p} - (n - y) \frac{1}{1 - p}.$$

Przyrównując pochodną do zera otrzymujemy równanie

$$y \frac{1}{p} - (n - y) \frac{1}{1 - p} = 0.$$

## Przykład cd.

Szukamy rozwiązania równania

$$y \frac{1}{p} - (n - y) \frac{1}{1 - p} = 0.$$

Przekształcając otrzymujemy kolejno równania

$$\frac{y}{p} = \frac{n - y}{1 - p}$$

$$p(n - y) = y(1 - p) = y - yp$$

$$pn - py = y - yp$$

$$p = \frac{y}{n} \equiv \frac{1}{n} \sum_{i=1}^n x_i.$$

## Przykład cd.

Szukamy rozwiązania równania

$$y \frac{1}{p} - (n - y) \frac{1}{1 - p} = 0.$$

Przekształcając otrzymujemy kolejno równania

$$\frac{y}{p} = \frac{n - y}{1 - p}$$

$$p(n - y) = y(1 - p) = y - yp$$

$$pn - py = y - yp$$

$$p = \frac{y}{n} \equiv \frac{1}{n} \sum_{i=1}^n x_i.$$

## Przykład cd.

Szukamy rozwiązania równania

$$y \frac{1}{p} - (n - y) \frac{1}{1 - p} = 0.$$

Przekształcając otrzymujemy kolejno równania

$$\frac{y}{p} = \frac{n - y}{1 - p}$$

$$p(n - y) = y(1 - p) = y - yp$$

$$pn - py = y - yp$$

$$p = \frac{y}{n} \equiv \frac{1}{n} \sum_{i=1}^n x_i.$$

## Przykład cd.

Szukamy rozwiązania równania

$$y \frac{1}{p} - (n - y) \frac{1}{1 - p} = 0.$$

Przekształcając otrzymujemy kolejno równania

$$\frac{y}{p} = \frac{n - y}{1 - p}$$

$$p(n - y) = y(1 - p) = y - yp$$

$$pn - py = y - yp$$

$$p = \frac{y}{n} \equiv \frac{1}{n} \sum_{i=1}^n x_i.$$



Szukamy rozwiązania równania

$$y \frac{1}{p} - (n - y) \frac{1}{1 - p} = 0.$$

Przekształcając otrzymujemy kolejno równania

$$\frac{y}{p} = \frac{n - y}{1 - p}$$

$$p(n - y) = y(1 - p) = y - yp$$

$$pn - py = y - yp$$

$$p = \frac{y}{n} \equiv \frac{1}{n} \sum_{i=1}^n x_i.$$

Łatwo pokazać, że dla  $p = \frac{1}{n} \sum_{i=1}^n x_i$ , funkcja  $\log L(p|x)$  osiąga maksimum globalne. Ponieważ funkcja logarytmiczna przy podstawie większej niż 1 jest funkcją rosnącą, to w punkcie  $p = \frac{1}{n} \sum_{i=1}^n x_i$  maksimum globalne osiąga również funkcja wiarygodności  $L(p|x)$ .

Stąd

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n x_i$$

jest estymatorem MLE parametru  $p$ .

Niech  $X_1, \dots, X_n$  będzie próbą z rozkładu normalnego  $N(\theta, 1)$  o której dodatkowo wiemy, że  $\theta$  jest dodatnia.

Bez tego dodatkowego ograniczenia estymatorem wyznaczonym metodą największej wiarygodności parametru  $\theta$  jest  $\bar{X}$ , średnia z próby.

Gdy  $\bar{X}$  przyjmuje wartość ujemną otrzymujemy estymator spoza zakresu wartości parametru  $\theta$ .

Niech  $X_1, \dots, X_n$  będzie próbą z rozkładu normalnego  $N(\theta, 1)$  o której dodatkowo wiemy, że  $\theta$  jest dodatnia.

Bez tego dodatkowego ograniczenia estymatorem wyznaczonym metodą największej wiarygodności parametru  $\theta$  jest  $\bar{X}$ , średnia z próby.

Gdy  $\bar{X}$  przyjmuje wartość ujemną otrzymujemy estymator spoza zakresu wartości parametru  $\theta$ .

# Estymator MLE o ograniczonym zasięgu

Niech  $X_1, \dots, X_n$  będzie próbą z rozkładu normalnego  $N(\theta, 1)$  o której dodatkowo wiemy, że  $\theta$  jest dodatnia.

Bez tego dodatkowego ograniczenia estymatorem wyznaczonym metodą największej wiarygodności parametru  $\theta$  jest  $\bar{X}$ , średnia z próby.

Gdy  $\bar{X}$  przyjmuje wartość ujemną otrzymujemy estymator spoza zakresu wartości parametru  $\theta$ .

Gdy  $\bar{x}$  jest ujemne, to dla  $\theta \geq 0$  funkcja wiarygodności  $L(\theta|x)$  jest funkcją malejącą ze względu na  $\theta$ , a więc osiąga swoje maksimum dla

$$\hat{\theta} = 0.$$

Tak więc w przypadku dodatkowego założenia  $\theta \geq 0$  estymatorem MLE parametru  $\theta$  jest

$$\hat{\theta} = \begin{cases} \hat{X}, & \text{gdy } \hat{X} \geq 0 \\ 0, & \text{gdy } \hat{X} < 0 \end{cases}$$