

## 7. PODSTAWOWE WŁASNOŚCI ESTYMATORÓW

W wykładzie tym przedstawimy kryteria, pozwalające ocenić jakość danego estymatora, bądź wybrać z pewnego zbioru ten, który w pewnym sensie jest najlepszy.

Precyzując pojęcie *najlepszy estymator* napotykamy dwa problemy.

1. Estymator parametru  $\theta$ ,  $\hat{\theta} = t(X_1, X_2, \dots, X_n)$  jest zmienną losową, co oznacza, że jego wartość zależy od zdarzenia losowego  $\omega \in \Omega$ . Może się zdarzyć zatem tak, że dla  $\hat{\theta}_1$  i  $\hat{\theta}_2$  - konkurencyjnych estymatorów parametru  $\theta$  - zachodzi

$$|\theta - \hat{\theta}_1(\omega)| < |\theta - \hat{\theta}_2(\omega)| \quad \text{dla pewnych } \omega \in \Omega$$

a

$$|\theta - \hat{\theta}_1(\omega)| > |\theta - \hat{\theta}_2(\omega)| \quad \text{dla innych } \omega \in \Omega.$$

Mamy zatem sytuację, że dla pewnych zdarzeń losowych wartości pierwszego estymatora są bliższe szacowanego parametru  $\theta$  niż wartości drugiego estymatora, a dla innych zdarzeń losowych jest na odwrót. Stosując takie porównanie nie jesteśmy w stanie rozstrzygnąć, który estymator jest lepszy. Problem ten można rozwiązać rozważając wartości oczekiwane estymatorów bądź ich funkcji. Takie podejście doprowadziło do definicji obciążenia i błędu średniokwadratowego estymatora, podanych dalej w tym wykładzie.

2. Nie znamy wartości szacowanego parametru  $\theta$ , a miary jakości estymatora bądź zachodzenie dla niego danych własności mogą od  $\theta$  zależeć. Dlatego zwykle żąda się by miara przyjmowała optymalną wartość, a własność zachodziła dla każdej  $\theta \in \Theta$ .

### Estymatory nieobciążone

**Definicja.** Mówimy, że  $\hat{\theta} = t(X_1, X_2, \dots, X_n)$  jest *nieobciążonym estymatorem* parametru  $\theta$  jeśli

$$E_{\theta}(\hat{\theta}) = \theta \quad \text{dla każdego } \theta \in \Theta.$$

W pozostałych przypadkach  $\hat{\theta}$  nazywamy *estymatorem obciążonym*. Funkcję  $B(\theta) = E_{\theta}(\hat{\theta}) - \theta$ , gdzie  $\theta \in \Theta$ , nazywamy *obciążeniem estymatora*  $\hat{\theta}$ .

Z powyższych definicji natychmiast wynika, że  $\hat{\theta}$  jest estymatorem nieobciążonym wtedy i tylko wtedy, gdy jego obciążenie jest funkcją tożsamościowo równą zero.

**Przykład 7.1.** Niech  $X_1, X_2, \dots, X_n$  będzie prostą próbą losową z populacji  $X$  o rozkładzie z wartością oczekiwaną  $EX = \mu$ . Wówczas  $\hat{\mu} = \bar{X}$  jest nieobciążonym estymatorem parametru  $\mu$ .

**Przykład 7.2.** Niech  $X_1, X_2, \dots, X_n$  będzie prostą próbą losową z populacji  $X$  o rozkładzie z wartością oczekiwaną  $EX = \mu$  i dodatnią wariancją  $Var(X) = \sigma^2 > 0$ . Załóżmy, że nie znamy ani  $\mu$  ani  $\sigma^2$ . Wówczas

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

jest estymatorem obciążonym parametru  $\sigma^2$ , bo

$$E_{(\mu, \sigma^2)}(\hat{\sigma}^2) = \frac{n-1}{n} \sigma^2 \neq \sigma^2,$$

natomiast

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

jest estymatorem nieobciążonym  $\sigma^2$ .

**Definicja.** Mówimy, że ciąg estymatorów  $\hat{\theta}_n = t_n(X_1, X_2, \dots, X_n)$  parametru  $\theta$  jest *asymptotycznie nieobciążony* jeśli

$$\lim_{n \rightarrow \infty} E_{\theta}(\hat{\theta}_n) = \theta \quad \text{dla każdego } \theta \in \Theta.$$

### Błąd średniokwadratowy estymatora

Porządane własności estymatora parametru  $\theta$  jest to by jego rozproszenie wokół szacowanej  $\theta$  było małe. Rozproszenie to możemy mierzyć jako wartość oczekiwaną z kwadratu różnicy między estymatorem i  $\theta$ .

**Definicja.** Funkcję

$$MSE_{\hat{\theta}}(\theta) = E_{\theta} \left( \hat{\theta} - \theta \right)^2, \quad \text{gdzie } \theta \in \Theta,$$

nazywamy *błędem średniokwadratowym estymatora*  $\hat{\theta}$  parametru  $\theta$ .

Zauważmy, że

$$\begin{aligned} MSE_{\hat{\theta}}(\theta) &= E_{\theta} \left( \hat{\theta} - \theta \right)^2 = E_{\theta} \left( \hat{\theta} - E_{\theta} \hat{\theta} - (\theta - E_{\theta} \hat{\theta}) \right)^2 \\ &= E_{\theta} \left( \hat{\theta} - E_{\theta} \hat{\theta} \right)^2 - 2(\theta - E_{\theta} \hat{\theta}) E_{\theta} \left( \hat{\theta} - E_{\theta} \hat{\theta} \right) + (\theta - E_{\theta} \hat{\theta})^2 = \\ &= Var_{\theta}(\hat{\theta}) + (B(\theta))^2, \end{aligned} \tag{1}$$

bo  $E_\theta(\hat{\theta} - E_\theta\hat{\theta}) = E_\theta\hat{\theta} - E_\theta(E_\theta\hat{\theta}) = E_\theta\hat{\theta} - E_\theta\hat{\theta} = 0$ . Oznacza to, że błąd średniokwadratowy estymatora to suma jego wariancji i kwadratu obciążenia. W szczególności dla nieobciążonych estymatorów  $\hat{\theta}$  parametru  $\theta$  wzór (1) redukuje się do

$$MSE_{\hat{\theta}}(\theta) = Var_\theta(\hat{\theta}),$$

i minimalizowanie błędu średniokwadratowego jest równoważne minimalizowaniu wariancji.

### Estymatory zgodne

Niech  $X_1, X_2, \dots$  będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie zależnym od parametru  $\theta \in \Theta$ . Dla dowolnego naturalnego  $n$  tworzymy próbę losową  $X_1, X_2, \dots, X_n$  i na jej podstawie budujemy estymator  $\hat{\theta}_n = t_n(X_1, X_2, \dots, X_n)$  parametru  $\theta$ .

**Definicja.** Mówimy, że ciąg estymatorów  $\hat{\theta}_n = t_n(X_1, X_2, \dots, X_n)$ ,  $n \geq 1$ , parametru  $\theta$  jest

- *zgodny w sensie zbieżności średniokwadratowej* jeśli błąd średniokwadratowy  $\hat{\theta}_n$  zbiega do zera wraz ze wzrostem liczności próby do nieskończoności:

$$\lim_{n \rightarrow \infty} E_\theta((\hat{\theta}_n - \theta)^2) = 0 \quad \text{dla wszystkich } \theta \in \Theta;$$

- *mocno zgodny* jeśli z prawdopodobieństwem 1 realizacje  $\hat{\theta}_n$  dążą do  $\theta$ , gdy liczność próby wzrasta do nieskończoności

$$P_\theta\left(\lim_{n \rightarrow \infty} \hat{\theta}_n = \theta\right) = 1 \quad \text{dla wszystkich } \theta \in \Theta;$$

- *(słabo) zgodny* jeśli dla dostatecznie dużych licznosci próby estymator  $\hat{\theta}_n$  z dużym prawdopodobieństwem przyjmuje wartości bliskie  $\theta$ :

$$\lim_{n \rightarrow \infty} P_\theta(|\hat{\theta}_n - \theta| < \varepsilon) = 1 \quad \text{dla każdego } \varepsilon > 0 \text{ i dla wszystkich } \theta \in \Theta.$$

W terminach rodzajów zbieżności ciągów zmiennych losowych

- zgodność w sensie zbieżności średniokwadratowej oznacza, że ciąg  $\hat{\theta}_n$  zbiega w sensie zbieżności średniokwadratowej do  $\theta$ :  $\hat{\theta}_n \xrightarrow{L^2} \theta$ ;
- mocna zgodność oznacza, że ciąg  $\hat{\theta}_n$  zbiega z  $P_\theta$ -prawdopodobieństwem 1 do  $\theta$ :  $\hat{\theta}_n \xrightarrow{1} \theta$ ;
- słaba zgodność oznacza, że ciąg  $\hat{\theta}_n$  zbiega według prawdopodobieństwa do  $\theta$ :  $\hat{\theta}_n \xrightarrow{P} \theta$ .

Wiemy, że dla ciągu zmiennych losowych zarówno z jego zbieżności średniokwadratowej jak i ze zbieżności z z prawdopodobieństwem 1 wynika jego zbieżność według prawdopodobieństwa. Stąd każdy estymator zgodny w sensie zbieżności średniokwadratowej jak i każdy estymator mocno zgodny jest zgodny.

**Twierdzenie 7.1.** Jeśli ciąg estymatorów  $\hat{\theta}_n$  parametru  $\theta$  jest asymptotycznie nieobciążony i

$$\lim_{n \rightarrow \infty} \text{Var}_{\theta}(\hat{\theta}_n) = 0 \quad \text{dla każdego } \theta \in \Theta,$$

to  $\hat{\theta}_n$  jest zgodnym ciągiem estymatorów.

**Przykład 7.3.** Niech  $X_1, X_2, \dots$  będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie z nieznaną wartością oczekiwaną  $\mu$ . Z mocnego prawa wielkich liczb Kołmogorowa natychmiast wynika, że  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$  jest mocno zgodnym estymatorem parametru  $\mu$ . Stąd  $\bar{X}_n$  jest też słabo zgodnym estymatorem  $\mu$ .

Jeśli dodatkowo założymy, że  $X_1, X_2, \dots$  mają skończoną wariancję  $\sigma^2$ , to otrzymamy, że  $\bar{X}_n$  jest także zgodnym w sensie zbieżności średniokwadratowej estymatorem  $\mu$ .

**Przykład 7.4.** Niech  $X_1, X_2, \dots$  będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie z nieznanymi wartością oczekiwaną  $\mu$  i wariancją  $\sigma^2$ . Wtedy

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

są mocno zgodnymi estymatorami parametru  $\sigma^2$ . Zatem są to także estymatory słabo zgodne. Ponadto, przy dodatkowym założeniu, że  $X_1, X_2, \dots$  mają skończony czwarty moment centralny, zarówno  $\hat{\sigma}^2$  jak i  $S^2$  są zgodnymi w sensie zbieżności średniokwadratowej estymatorami parametru  $\sigma^2$ .

**Przykład 7.5.** Niech  $X_1, X_2, \dots, X_n$  będzie próbą losową z populacji  $X$  o rozkładzie jednostajnym na przedziale  $[0, \theta]$ , gdzie  $\theta > 0$ . W przykładzie 7.6 wyznaczaliśmy następujące estymatory parametru  $\theta$ :

$$\hat{\theta}_{MM} = 2\bar{X}, \quad \hat{\theta}_{NW} = X_{n:n}.$$

(a)  $E_{\theta}(\hat{\theta}_{MM}) = \theta$ , co oznacza, że estymator  $\hat{\theta}_{MM}$  jest nieobciążony.  $E_{\theta}(\hat{\theta}_{NW}) = \frac{n}{n+1}\theta \neq \theta$ , więc estymator  $\hat{\theta}_{NW}$  jest obciążony. Ponieważ

$$\lim_{n \rightarrow \infty} E_{\theta}(\hat{\theta}_{NW}) = \theta,$$

jest on asymptotycznie nieobciążony.

(b) Błędy średniokwadratowe rozważanych estymatorów wynoszą:

$$MSE_{\hat{\theta}_{MM}}(\theta) = \frac{\theta^2}{3n}, \quad MSE_{\hat{\theta}_{NW}}(\theta) = \frac{2}{(n+1)(n+2)}\theta^2.$$

(c) Estymator  $\hat{\theta}_{MM}$  jest mocno zgodny, zaś  $\hat{\theta}_{NW}$  jest słabo zgodny. Można pokazać, że  $\hat{\theta}_{NW}$  jest także mocno zgodny, ale to przekracza zakres naszego wykładu.

### Własności estymatorów największej wiarygodności

Estymatory otrzymane metodą największej wiarygodności, przy dość ogólnych założeniach, mają dobre własności asymptotyczne - można pokazać, że jeśli są spełnione pewne warunki regularności, to estymatory te są mocno zgodne i asymptotycznie nieobciążone.