

Metody probabilistyczne

13. Elementy statystki matematycznej I

Wojciech Kotłowski

Instytut Informatyki PP
<http://www.cs.put.poznan.pl/wkotlowski/>

16.01.2020

Zagadnienia statystyki

Przeprowadzamy pewien eksperyment losowy, którego wynikiem są **dane**.


Celem jest wyciągnięcie ogólnych wniosków na temat zbiorowości / zjawiska / procesu, z którego dane pochodzą.

Wnioskowanie statystyczne jest podstawową metodologią badań w większości nauk (np. w medycynie, psychologii, ekonomii, fizyce eksperymentalnej), jak również stanowi bazę nowoczesnych metod sztucznej inteligencji (uczenie maszynowe) i analizy danych

Zagadnienia statystyki – przykłady


- Sondaż wyborczy na próbie losowo wybranych osób celem oszacowania prawdziwego poparcia dla partii w całej populacji kraju
- Wnioskowanie o zmianach temperatury na podstawie pomiarów ze stacji pogodowych
- Sprawdzenie, czy istnieje zależność między danymi zjawiskami (np. palenie papierosów a zachorowalność na nowotworowy)
- Testowanie skuteczności nowego leku poprzez porównanie wyników próby badawczej (podajemy lek) i kontrolnej (podajemy placebo)
- Szacowanie czasu przejazdu po drogach na podstawie danych z GPS urządzeń mobilnych
- Badania marketingowe celem kierowania do konsumentów personalizowanych reklam

Próba i populacja




- **Populacja (generalna)** – cała rozważana zbiorowość, np. wszyscy potencjalni wyborcy, wartości temperatur na całym globie, wszyscy możliwi pacjenci, itp.
- **Próba** – zespół elementów wylosowany z populacji („dane”), np. wyborcy wybrani do sondażu, wartości temperatur w stacjach pomiarowych, pacjenci wybrani do testowania leku, itp.

Próba i populacja



Celem wnioskowania statystycznego jest wyciągnięcie wniosków o całej populacji na podstawie losowo wybranej próby

Próba i populacja




Celem wnioskowania statystycznego jest wyciągnięcie wniosków o całej populacji na podstawie losowo wybranej próby

Uwaga: Zakładamy, że próba jest **reprezentatywna** (każdy element populacji ma równe szanse na wejście do próby) i **prosta** (każdy element próby losowany **niezależnie** od pozostałych).


Populacja a rozkład prawdopodobieństwa

Zwykle interesuje nas tylko konkretna **cecha** populacji, np. preferencje wyborcze, wysokość zarobków, temperatura, itp.




Populacja a rozkład prawdopodobieństwa

Zwykle interesuje nas tylko konkretna **cecha** populacji, np. preferencje wyborcze, wysokość zarobków, temperatura, itp.



Populacja a rozkład prawdopodobieństwa


Zwykle interesuje nas tylko konkretna **cecha** populacji, np. preferencje wyborcze, wysokość zarobków, temperatura, itp.



Zliczając częstości wystąpienia danej wartości cechy populację możemy traktować abstrakcyjnie jako **rozkład prawdopodobieństwa cechy**

Populacja a rozkład prawdopodobieństwa

Zwykle interesuje nas tylko konkretna **cecha** populacji, np. preferencje wyborcze, wysokość zarobków, temperatura, itp.



Zliczając częstości wystąpienia danej wartości cechy populację możemy traktować abstrakcyjnie jako **rozkład prawdopodobieństwa cechy**

Dla ciągłych cech modelujemy populację **gęstością prawdopodobieństwa**

Statystyka matematyczna

- Badaną cechą X modelujemy jako zmienną losową o pewnym rozkładzie P (na populacji)

Statystyka matematyczna

- Badaną cechą X modelujemy jako zmienną losową o pewnym rozkładzie P (na populacji)
- Próba o liczności n może być modelowana jako realizacje (wartości) n **niezależnych** zmiennych losowych

$$X_1, X_2, \dots, X_n$$

o tym samym rozkładzie P

Statystyka matematyczna


- Badaną cechę X modelujemy jako zmienną losową o pewnym rozkładzie P (na populacji)
- Próba o liczności n może być modelowana jako realizacje (wartości) n **niezależnych** zmiennych losowych

$$X_1, X_2, \dots, X_n$$


o tym samym rozkładzie P

- Obserwując próbę pochodzącą z nieznanego rozkładu P , wnioskujemy o interesujących nas własnościach tego rozkładu.

Rozkład empiryczny



Rozkład empiryczny



Rozkład empiryczny powstaje poprzez zliczenie częstości wystąpień poszczególnych wartości cechy **na próbie**.

Przykład: preferencje wyborcze

- Rozważmy drugą turę wyborów prezydenckich z kandydatami A i B .
W populacji kandydat A ma poparcie 60%, a B – 40%

Przykład: preferencje wyborcze

- Rozważmy drugą turę wyborów prezydenckich z kandydatami A i B . W populacji kandydat A ma poparcie 60%, a B – 40%
- Niech $X \in \{0, 1\}$ koduje poparcie kandydata A ($X = 1$) lub B ($X = 0$)

Przykład: preferencje wyborcze

- Rozważmy drugą turę wyborów prezydenckich z kandydatami A i B . W populacji kandydat A ma poparcie 60%, a B – 40%
- Niech $X \in \{0, 1\}$ koduje poparcie kandydata A ($X = 1$) lub B ($X = 0$)
- Cecha X ma więc rozkład dwupunktowy z parametrem $p = 0.6$

Przykład: preferencje wyborcze

- Rozważmy drugą turę wyborów prezydenckich z kandydatami A i B . W populacji kandydat A ma poparcie 60%, a B – 40%
- Niech $X \in \{0, 1\}$ koduje poparcie kandydata A ($X = 1$) lub B ($X = 0$)
- Cecha X ma więc rozkład dwupunktowy z parametrem $p = 0.6$
- Pobraliśmy próbę $n = 10$ elementów otrzymując wartości:

0, 1, 0, 1, 1, 1, 0, 0, 1, 0

Przykład: preferencje wyborcze

- Rozważmy drugą turę wyborów prezydenckich z kandydatami A i B . W populacji kandydat A ma poparcie 60%, a B – 40%
- Niech $X \in \{0, 1\}$ koduje poparcie kandydata A ($X = 1$) lub B ($X = 0$)
- Cecha X ma więc **rozkład dwupunktowy z parametrem $p = 0.6$**
- Pobraliśmy próbę $n = 10$ elementów otrzymując wartości:

0, 1, 0, 1, 1, 1, 0, 0, 1, 0

- Rozkład empiryczny jest **rozkładem dwupunktowym z parametrem $\hat{p} = \frac{5}{10} = 0.5$**

Teoria estymacji

W ramach tego wykładu zajmiemy się tylko zadaniem **estymacji parametrów rozkładu**

Teoria estymacji zajmuje się szacowaniem interesujących parametrów rozkładu na populacji na podstawie próby

Teoria estymacji

W ramach tego wykładu zajmiemy się tylko zadaniem **estymacji parametrów rozkładu**

Teoria estymacji zajmuje się szacowaniem interesujących parametrów rozkładu na populacji na podstawie próby

Przykład: Cecha w populacji ma rozkład normalny $N(\mu, \sigma^2)$, gdzie μ i σ^2 są nieznane. Szacujemy te wartości na podstawie próby.

Statystyka i estymator

Próba: Niezależne zmienne losowe X_1, X_2, \dots, X_n o rozkładzie P .

Statystyka i estymator

Próba: Niezależne zmienne losowe X_1, X_2, \dots, X_n o rozkładzie P .

Statystka

Statystyką $T = T(X_1, X_2, \dots, X_n)$ nazywamy dowolną funkcję próby

Uwaga: statystyka jest **zmienną losową**, ponieważ jest funkcją zmiennych losowych!

Statystyka i estymator

Próba: Niezależne zmienne losowe X_1, X_2, \dots, X_n o rozkładzie P .

Statystka

Statystyką $T = T(X_1, X_2, \dots, X_n)$ nazywamy dowolną funkcję próby

Uwaga: statystyka jest **zmienną losową**, ponieważ jest funkcją zmiennych losowych!

Estymator

Estymatorem $\hat{\theta} = \hat{\theta}(X_1, X_2, \dots, X_n)$ nazywamy statystykę szacującą nieznaną wartość parametru θ rozkładu P

Uwaga: estymator jest zmienną losową, więc ma swój rozkład, wartość oczekiwaną, wariancję, itp.

Przykład: szacowanie wartości oczekiwanej

Założmy, że chcemy oszacować **wartość oczekiwaną** $\mu = EX$ rozkładu zmiennej losowej X .

Przykład: szacowanie wartości oczekiwanej

Założmy, że chcemy oszacować **wartość oczekiwaną** $\mu = EX$ rozkładu zmiennej losowej X .

Rozważmy estymator parametru μ będący średnią arytmetyczną próby

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

Przykład: szacowanie wartości oczekiwanej

Założmy, że chcemy oszacować **wartość oczekiwaną** $\mu = EX$ rozkładu zmiennej losowej X .

Rozważmy estymator parametru μ będący średnią arytmetyczną próby

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

Zgodnie z prawem wielkich liczb:

$$\bar{X}_n \xrightarrow{\text{pr. 1}} \mu,$$

a więc zwiększając wielkość próby n do nieskończoności, estymator $\hat{\mu}$ zbiega do prawdziwej wartości parametru μ .

Zgodność estymatora

Estymator $\hat{\theta}$ parametru θ nazywamy **silnie zgodnym** jeśli:

$$\hat{\theta} \xrightarrow{\text{z pr. 1}} \theta$$

Estymator nazywamy **słabo zgodnym** jeśli

$$\hat{\theta} \xrightarrow{P} \theta$$

Zgodność estymatora oznacza, że zbiega on do prawdziwej wartości parametru, gdy rozmiar próby n rośnie do nieskończoności

Zgodność estymatora

Estymator $\hat{\theta}$ parametru θ nazywamy **silnie zgodnym** jeśli:

$$\hat{\theta} \xrightarrow{\text{z pr. 1}} \theta$$

Estymator nazywamy **słabo zgodnym** jeśli

$$\hat{\theta} \xrightarrow{P} \theta$$

Zgodność estymatora oznacza, że zbiega on do prawdziwej wartości parametru, gdy rozmiar próby n rośnie do nieskończoności

Wniosek: estymator $\hat{\mu} = \bar{X}_n$ jest silnie zgodnym estymatorem wartości oczekiwanej $\mu = EX$.

Przykład: preferencje wyborcze

Rozważmy drugą turę wyborów prezydenckich (kandydaci $A \equiv 1$ i $B \equiv 0$). Zmienna $X \in \{0, 1\}$ (poparcie A) ma rozkład $B(p)$, gdzie $p = EX$ jest poparciem kandydata w populacji.

Przykład: preferencje wyborcze

Rozważmy drugą turę wyborów prezydenckich (kandydaci $A \equiv 1$ i $B \equiv 0$). Zmienna $X \in \{0, 1\}$ (poparcie A) ma rozkład $B(p)$, gdzie $p = EX$ jest poparciem kandydata w populacji.

Estymator wartości oczekiwanej p :

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{\text{\#sukcesów w próbie}}{n}$$

jest częstością sukcesów w próbie.

Przykład: preferencje wyborcze

Rozważmy drugą turę wyborów prezydenckich (kandydaci $A \equiv 1$ i $B \equiv 0$). Zmienna $X \in \{0, 1\}$ (poparcie A) ma rozkład $B(p)$, gdzie $p = EX$ jest poparciem kandydata w populacji.

Estymator wartości oczekiwanej p :

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{\text{\#sukcesów w próbie}}{n}$$

jest częstością sukcesów w próbie.

\hat{p} jest silnie zgodnym estymatorem parametru p .

Metoda momentów

Estymator wartości oczekiwanej \bar{X}_n jest przykładem zastosowania tzw. metody momentów:

Chcąc oszacować moment rozkładu $m_k = E(X^k)$, użyjmy estymatora \hat{m}_k będącego odpowiednim momentem rozkładu empirycznego:

$$\hat{m}_k = \frac{1}{n} \sum_{i=1}^n X_i^k$$

(zamiast wartości oczekiwanej bierzemy średnią po próbie)

Przykład: estymator wariancji

Chcemy oszacować **wariancję** $\sigma^2 = D^2(X)$ rozkładu zmiennej losowej X .

Przykład: estymator wariancji

Chcemy oszacować **wariancję** $\sigma^2 = D^2(X)$ rozkładu zmiennej losowej X .

Ponieważ $D^2(X) = E(X^2) - (EX)^2 = m_2 - m_1^2$, bierzemy estymator wariancji:

$$\hat{\sigma}^2 = \hat{m}_2 - \hat{m}_1^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X}_n)^2$$

Przykład: estymator wariancji

Chcemy oszacować **wariancję** $\sigma^2 = D^2(X)$ rozkładu zmiennej losowej X .

Ponieważ $D^2(X) = E(X^2) - (EX)^2 = m_2 - m_1^2$, bierzemy estymator wariancji:

$$\hat{\sigma}^2 = \hat{m}_2 - \hat{m}_1^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X}_n)^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

Przykład: estymator wariancji

Chcemy oszacować **wariancję** $\sigma^2 = D^2(X)$ rozkładu zmiennej losowej X .

Ponieważ $D^2(X) = E(X^2) - (EX)^2 = m_2 - m_1^2$, bierzemy estymator wariancji:

$$\hat{\sigma}^2 = \hat{m}_2 - \hat{m}_1^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X}_n)^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

Zadanie 1

Uzasadnij, ostatnią równość, tzn. pokaż wzór skróconego mnożenia:

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

Zwróć uwagę na analogię do $E((X - EX)^2) = E(X^2) - (EX)^2$, tyle że zamiast uśredniać po rozkładzie, uśredniamy po próbie.

Przykład: estymator wariancji

Chcemy oszacować **wariancję** $\sigma^2 = D^2(X)$ rozkładu zmiennej losowej X .

Ponieważ $D^2(X) = E(X^2) - (EX)^2 = m_2 - m_1^2$, bierzemy estymator wariancji:

$$\hat{\sigma}^2 = \hat{m}_2 - \hat{m}_1^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X}_n)^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

Zadanie 2

Pokaż, że $\hat{\sigma}^2$ jest silnie zgodny poprzez dwukrotne zastosowania prawa wielkich liczb do $\frac{1}{n} \sum_{i=1}^n X_i^2$ oraz do \bar{X}_n .

Estymator nieobciążony

Zgodność estymatora jest własnością **asymptotyczną**: mówi o zachowaniu estymatora tylko dla **bardzo dużych prób** ($n \rightarrow \infty$)

Estymator nieobciążony

Zgodność estymatora jest własnością **asymptotyczną**: mówi o zachowaniu estymatora tylko dla **bardzo dużych prób** ($n \rightarrow \infty$)

Obciążenie estymatora

Obciążeniem estymatora $\hat{\theta}$ parametru θ nazywamy różnicę między wartością oczekiwaną estymatora a nieznaną wartością parametru:

$$E(\hat{\theta}) - \theta$$

Estymator nieobciążony

Zgodność estymatora jest własnością **asymptotyczną**: mówi o zachowaniu estymatora tylko dla **bardzo dużych prób** ($n \rightarrow \infty$)

Obciążenie estymatora

Obciążeniem estymatora $\hat{\theta}$ parametru θ nazywamy różnicę między wartością oczekiwaną estymatora a nieznaną wartością parametru:

$$E(\hat{\theta}) - \theta$$

Estymator nieobciążony

Estymator nazywamy **nieobciążonym** jeśli jego obciążenie jest równe zero, tzn:

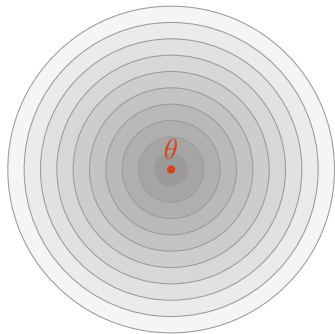

$$E(\hat{\theta}) = \theta$$

Estymator „średnio” trafia w wybrany parametr.

Uwaga: to ma sens, bo estymator jest **zmienną losową**, więc ma swoją wartość oczekiwaną!

Estymator nieobciążony

Zgodnie z prawem wielkich liczb, wartość oczekiwaną estymatora $E(\hat{\theta})$ można interpretować jako średnią wartość estymatora przy wielokrotnym losowaniu próby



Estymator nieobciążony


Zgodnie z prawem wielkich liczb, wartość oczekiwaną estymatora $E(\hat{\theta})$ można interpretować jako średnią wartość estymatora przy wielokrotnym losowaniu próby



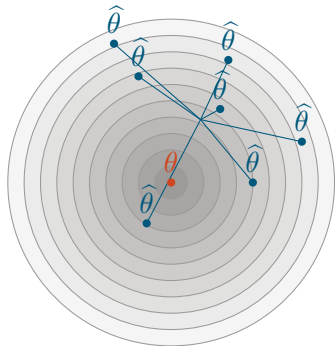
Estymator nieobciążony

Zgodnie z prawem wielkich liczb, wartość oczekiwaną estymatora $E(\hat{\theta})$ można interpretować jako średnią wartość estymatora przy wielokrotnym losowaniu próby

Estymator nieobciążony



Estymator obciążony



Estymator wartości oczekiwanej

Estymator wartości oczekiwanej $\mu = EX$ postaci:

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

jest nieobciążony

Estymator wartości oczekiwanej

Estymator wartości oczekiwanej $\mu = EX$ postaci:

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

jest nieobciążony

Dowód:

$$E(\hat{\mu}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right)$$

Estymator wartości oczekiwanej

Estymator wartości oczekiwanej $\mu = EX$ postaci:

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

jest nieobciążony

Dowód:

$$E(\hat{\mu}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \underbrace{EX_i}_{=\mu}$$

Estymator wartości oczekiwanej

Estymator wartości oczekiwanej $\mu = EX$ postaci:

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

jest nieobciążony

Dowód:

$$E(\hat{\mu}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \underbrace{EX_i}_{=\mu} = \mu$$

Estymator wartości oczekiwanej

Estymator wartości oczekiwanej $\mu = EX$ postaci:

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

jest nieobciążony

Dowód:

$$E(\hat{\mu}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \underbrace{EX_i}_{=\mu} = \mu$$

(jest to przypomnienie z wykładu o twierdzeniach granicznych, gdzie już udowodniliśmy, że $E\bar{X}_n = \mu$)

Estymator wariancji

Wyznacz obciążenie estymatora wariancji $\sigma^2 = D^2(X)$ postaci:

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

Estymator wariancji

Wyznacz obciążenie estymatora wariancji $\sigma^2 = D^2(X)$ postaci:

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

Odpowiedź:

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

Estymator wariancji

Wyznacz obciążenie estymatora wariancji $\sigma^2 = D^2(X)$ postaci:

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

Odpowiedź:

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

Ze wzoru skróconego mnożenia mamy:

$$D^2(X) = E(X^2) - \underbrace{(EX)^2}_{=\mu}, \quad \text{oraz} \quad D^2(\bar{X}_n) = E(\bar{X}_n^2) - \underbrace{(E\bar{X}_n)^2}_{=\mu},$$

Estymator wariancji

Wyznacz obciążenie estymatora wariancji $\sigma^2 = D^2(X)$ postaci:

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

Odpowiedź:

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

Ze wzoru skróconego mnożenia mamy:

$$D^2(X) = E(X^2) - \underbrace{(EX)^2}_{=\mu}, \quad \text{oraz} \quad D^2(\bar{X}_n) = E(\bar{X}_n^2) - \underbrace{(E\bar{X}_n)^2}_{=\mu},$$

stąd:

$$E(\hat{\sigma}^2) = D^2(X) + \mu^2 - (D^2(\bar{X}_n) + \mu^2) = D^2(X) - D^2(\bar{X}_n)$$

Estymator wariancji

Wyznacz obciążenie estymatora wariancji $\sigma^2 = D^2(X)$ postaci:

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

Odpowiedź:

$$E(\hat{\sigma}^2) = D^2(X) - D^2(\bar{X}_n)$$

Estymator wariancji

Wyznacz obciążenie estymatora wariancji $\sigma^2 = D^2(X)$ postaci:

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

Odpowiedź:

$$E(\hat{\sigma}^2) = D^2(X) - D^2(\bar{X}_n)$$

Zauważmy, że:

$$D^2(X) = \sigma^2$$

Estymator wariancji

Wyznacz obciążenie estymatora wariancji $\sigma^2 = D^2(X)$ postaci:

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

Odpowiedź:

$$E(\hat{\sigma}^2) = D^2(X) - D^2(\bar{X}_n)$$

Zauważmy, że:

$$D^2(X) = \sigma^2$$

$$D^2(\bar{X}_n) = D^2\left(\frac{1}{n} \sum_{i=1}^n X_i\right)$$

Estymator wariancji

Wyznacz obciążenie estymatora wariancji $\sigma^2 = D^2(X)$ postaci:

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

Odpowiedź:

$$E(\hat{\sigma}^2) = D^2(X) - D^2(\bar{X}_n)$$

Zauważmy, że:

$$\begin{aligned} D^2(X) &= \sigma^2 \\ D^2(\bar{X}_n) &= D^2\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \underbrace{D^2(X_i)}_{\sigma^2} = \frac{\sigma^2}{n} \end{aligned}$$

Estymator wariancji

Wyznacz obciążenie estymatora wariancji $\sigma^2 = D^2(X)$ postaci:

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

Odpowiedź:

$$E(\hat{\sigma}^2) = D^2(X) - D^2(\bar{X}_n)$$

Zauważmy, że:

$$\begin{aligned} D^2(X) &= \sigma^2 \\ D^2(\bar{X}_n) &= D^2\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \underbrace{D^2(X_i)}_{\sigma^2} = \frac{\sigma^2}{n} \end{aligned}$$

Stąd:

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

Estymator wariancji $\hat{\sigma}^2$ jest **obciążony** (niedoszacowuje!)

Ratujemy estymator wariancji

Pokazaliśmy, że:

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

Ratujemy estymator wariancji

Pokazaliśmy, że:

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

Modyfikujemy estymator wariancji:

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

Ratujemy estymator wariancji

Pokazaliśmy, że:

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

Modyfikujemy estymator wariancji:

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

Nowy estymator jest **nieobciążony**, ponieważ:

$$E(\hat{\sigma}_*^2) = E\left(\frac{n}{n-1} \hat{\sigma}^2\right) = \frac{n}{n-1} E(\hat{\sigma}^2) = \frac{\cancel{n}}{\cancel{n-1}} \frac{\cancel{n-1}}{\cancel{n}} \sigma^2 = \sigma^2$$

Podsumowanie

Nieobciążony estymator wartości średniej $\mu = EX$:

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

Nieobciążony estymator wariancji $\sigma^2 = D^2(X)$:

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

Podsumowanie

Nieobciążony estymator wartości średniej $\mu = EX$:

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

Nieobciążony estymator wariancji $\sigma^2 = D^2(X)$:

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

Zadanie 3

Niech $\hat{\mu} = \sum_{i=1}^n c_i X_i$ będzie estymatorem wartości oczekiwanej $\mu = EX$ dla pewnych współczynników c_1, \dots, c_n niezależnych od danych. Jaki warunek muszą spełniać te stałe, aby estymator był **nieobciążony**?

Brak obciążenia nie wystarcza

Łatwo uzyskać estymator nieobciążony, który jest **trywialny**

Brak obciążenia nie wystarcza

Łatwo uzyskać estymator nieobciążony, który jest trywialny

Rozważmy estymator wartości oczekiwanej postaci $\hat{\mu}_1 = X_1$

Brak obciążenia nie wystarcza

Łatwo uzyskać estymator nieobciążony, który jest trywialny

Rozważmy estymator wartości oczekiwanej postaci $\hat{\mu}_1 = X_1$

Mamy: $E(\hat{\mu}_1) = EX_1 = \mu$ (estymator nieobciążony!)

Brak obciążenia nie wystarcza

Łatwo uzyskać estymator nieobciążony, który jest **trywialny**

Rozważmy estymator wartości oczekiwanej postaci $\hat{\mu}_1 = X_1$

Mamy: $E(\hat{\mu}_1) = EX_1 = \mu$ (estymator nieobciążony!)

Ale ten estymator odrzuca wszystkie elementy próby poza X_1 !

Brak obciążenia nie wystarcza

Łatwo uzyskać estymator nieobciążony, który jest **trywialny**

Rozważmy estymator wartości oczekiwanej postaci $\hat{\mu}_1 = X_1$

Mamy: $E(\hat{\mu}_1) = EX_1 = \mu$ (estymator nieobciążony!)

Ale ten estymator odrzuca wszystkie elementy próby poza X_1 !

Np. przy szacowaniu poparcia kandydata A w wyborach, $\hat{\mu}_1$ zwraca wartość równą pierwszemu elementowi próby, czyli **0 lub 1!**

Brak obciążenia nie wystarcza

Łatwo uzyskać estymator nieobciążony, który jest trywialny

Rozważmy estymator wartości oczekiwanej postaci $\hat{\mu}_1 = X_1$

Mamy: $E(\hat{\mu}_1) = EX_1 = \mu$ (estymator nieobciążony!)

Ale ten estymator odrzuca wszystkie elementy próby poza X_1 !

Np. przy szacowaniu poparcia kandydata A w wyborach, $\hat{\mu}_1$ zwraca wartość równą pierwszemu elementowi próby, czyli **0 lub 1!**

Średnio jest to poprawne (równe prawdziwemu poparciu), ale jest to raczej kiepskie oszacowanie poparcia.

Brak obciążenia nie wystarcza

Łatwo uzyskać estymator nieobciążony, który jest **trywialny**

Rozważmy estymator wartości oczekiwanej postaci $\hat{\mu}_1 = X_1$

Mamy: $E(\hat{\mu}_1) = EX_1 = \mu$ (estymator nieobciążony!)

Ale ten estymator odrzuca wszystkie elementy próby poza X_1 !


Np. przy szacowaniu poparcia kandydata A w wyborach, $\hat{\mu}_1$ zwraca wartość równą pierwszemu elementowi próby, czyli **0 lub 1!**

Średnio jest to poprawne (równe prawdziwemu poparciu), ale jest to raczej kiepskie oszacowanie poparcia.

Potrzebujemy innych kryteriów oceny estymatorów

Wariancja estymatora


Chcemy, aby nieobciążony estymator miał jak najmniejszą **wariancję** $D^2(\hat{\theta})$




Wariancja estymatora

Chcemy, aby nieobciążony estymator miał jak najmniejszą **wariancję** $D^2(\hat{\theta})$

Estymator nieobciążony




Estymator nieobciążony




Wariancja estymatora

Chcemy, aby nieobciążony estymator miał jak najmniejszą **wariancję** $D^2(\hat{\theta})$

Estymator nieobciążony
Duża wariancja



Estymator nieobciążony
Mała wariancja



Relacja efektywności

Rozważmy dwa estymatory **nieobciążone** $\hat{\theta}_1$ i $\hat{\theta}_2$ parametru θ . Mówimy, że $\hat{\theta}_1$ jest **efektywniejszy** od estymatora $\hat{\theta}_2$, jeśli

$$D^2(\hat{\theta}_1) \leq D^2(\hat{\theta}_2)$$

dla każdej wartości parametru θ .

Relacja efektywności

Rozważmy dwa estymatory **nieobciążone** $\hat{\theta}_1$ i $\hat{\theta}_2$ parametru θ . Mówimy, że $\hat{\theta}_1$ jest **efektywniejszy** od estymatora $\hat{\theta}_2$, jeśli

$$D^2(\hat{\theta}_1) \leq D^2(\hat{\theta}_2)$$

dla każdej wartości parametru θ .

- Ściślej powinno być: „efektywniejszy lub tak samo efektywny jak”

Relacja efektywności

Rozważmy dwa estymatory **nieobciążone** $\hat{\theta}_1$ i $\hat{\theta}_2$ parametru θ . Mówimy, że $\hat{\theta}_1$ jest **efektywniejszy** od estymatora $\hat{\theta}_2$, jeśli

$$D^2(\hat{\theta}_1) \leq D^2(\hat{\theta}_2)$$

dla każdej wartości parametru θ .

- Ściślej powinno być: „efektywniejszy lub tak samo efektywny jak”
- Warunek „dla każdego θ ” jest potrzebny, ponieważ wariancje estymatorów mogą zależeć od parametru rozkładu

Relacja efektywności

Rozważmy dwa estymatory **nieobciążone** $\hat{\theta}_1$ i $\hat{\theta}_2$ parametru θ . Mówimy, że $\hat{\theta}_1$ jest **efektywniejszy** od estymatora $\hat{\theta}_2$, jeśli

$$D^2(\hat{\theta}_1) \leq D^2(\hat{\theta}_2)$$

dla każdej wartości parametru θ .

- Ściślej powinno być: „efektywniejszy lub tak samo efektywny jak”
- Warunek „dla każdego θ ” jest potrzebny, ponieważ wariancje estymatorów mogą zależeć od parametru rozkładu
- Relacja efektywności dotyczy tylko estymatorów **nieobciążonych**

Relacja efektywności

Rozważmy dwa estymatory **nieobciążone** $\hat{\theta}_1$ i $\hat{\theta}_2$ parametru θ . Mówimy, że $\hat{\theta}_1$ jest **efektywniejszy** od estymatora $\hat{\theta}_2$, jeśli

$$D^2(\hat{\theta}_1) \leq D^2(\hat{\theta}_2)$$

dla każdej wartości parametru θ .

- Ściślej powinno być: „efektywniejszy lub tak samo efektywny jak”
- Warunek „dla każdego θ ” jest potrzebny, ponieważ wariancje estymatorów mogą zależeć od parametru rozkładu
- Relacja efektywności dotyczy tylko estymatorów **nieobciążonych**
- Relacja efektywności jest **porządkiem częściowym**, tzn. dwa estymatory mogą być nieporównywalne w sensie efektywności

Relacja efektywności

Rozważmy dwa estymatory **nieobciążone** $\hat{\theta}_1$ i $\hat{\theta}_2$ parametru θ . Mówimy, że $\hat{\theta}_1$ jest **efektywniejszy** od estymatora $\hat{\theta}_2$, jeśli

$$D^2(\hat{\theta}_1) \leq D^2(\hat{\theta}_2)$$

dla każdej wartości parametru θ .

- Ściślej powinno być: „efektywniejszy lub tak samo efektywny jak”
- Warunek „dla każdego θ ” jest potrzebny, ponieważ wariancje estymatorów mogą zależeć od parametru rozkładu
- Relacja efektywności dotyczy tylko estymatorów **nieobciążonych**
- Relacja efektywności jest **porządkiem częściowym**, tzn. dwa estymatory mogą być nieporównywalne w sensie efektywności

Estymator nieobciążony efektywniejszy od wszystkich innych estymatorów nieobciążonych (jeśli istnieje) nazywamy **estymatorem efektywnym**

Przykład

Dla próby losowej X_1, X_2, \dots, X_n rozważmy rodzinę estymatorów wartości oczekiwanej μ postaci:

$$\hat{\mu}_k = \frac{1}{k} \sum_{i=1}^k X_i, \quad k = 1, \dots, n$$

(czyli $\hat{\mu}_k$ bierze średnią z k pierwszych elementów próby)

Przykład

Dla próby losowej X_1, X_2, \dots, X_n rozważmy rodzinę estymatorów wartości oczekiwanej μ postaci:

$$\hat{\mu}_k = \frac{1}{k} \sum_{i=1}^k X_i, \quad k = 1, \dots, n$$

(czyli $\hat{\mu}_k$ bierze średnią z k pierwszych elementów próby)

$$E(\hat{\mu}_k) = \frac{1}{k} \sum_{i=1}^k \underbrace{EX_i}_{\mu} = \mu \quad (\text{nieobciążone})$$

Przykład

Dla próby losowej X_1, X_2, \dots, X_n rozważmy rodzinę estymatorów wartości oczekiwanej μ postaci:

$$\hat{\mu}_k = \frac{1}{k} \sum_{i=1}^k X_i, \quad k = 1, \dots, n$$

(czyli $\hat{\mu}_k$ bierze średnią z k pierwszych elementów próby)

$$E(\hat{\mu}_k) = \frac{1}{k} \sum_{i=1}^k \underbrace{EX_i}_{\mu} = \mu \quad (\text{nieobciążone})$$

$$D^2(\hat{\mu}_k) = \frac{1}{k^2} \sum_{i=1}^k \underbrace{D^2(X_i)}_{\sigma^2} = \frac{\sigma^2}{k}$$

Przykład

Dla próby losowej X_1, X_2, \dots, X_n rozważmy rodzinę estymatorów wartości oczekiwanej μ postaci:

$$\hat{\mu}_k = \frac{1}{k} \sum_{i=1}^k X_i, \quad k = 1, \dots, n$$

(czyli $\hat{\mu}_k$ bierze średnią z k pierwszych elementów próby)

$$E(\hat{\mu}_k) = \frac{1}{k} \sum_{i=1}^k \underbrace{EX_i}_{\mu} = \mu \quad (\text{nieobciążone})$$

$$D^2(\hat{\mu}_k) = \frac{1}{k^2} \sum_{i=1}^k \underbrace{D^2(X_i)}_{\sigma^2} = \frac{\sigma^2}{k}$$

Estymator $\hat{\mu}_n = \bar{X}_n$ jest **najefektywniejszy**, a $\hat{\mu}_1 = X_1$ **najmniej efektywny**

Zadanie

Zadanie 4

Rozważ estymator wartości oczekiwanej μ postaci:

$$\hat{\mu} = \sum_{i=1}^n c_i X_i,$$

dla pewnych współczynników c_1, \dots, c_n (niezależnych od danych). Załóżmy, że $\hat{\mu}$ jest **nieobciążony** (patrz zadanie 3). Dla jakich wartości c_1, \dots, c_n ma on **najmniejszą wariancję**?

Czy estymator może mieć dowolnie małą wariancję?

Czy estymator może mieć dowolnie małą wariancję?

Nierówność Craméra-Rao

Niech $\hat{\theta}$ będzie nieobciążonym estymatorem parametru θ wyznaczonym z próby X_1, X_2, \dots, X_n . Zdefiniujemy **funkcję informacji Fishera** $I(\theta)$ jako:

- Dla rozkładów dyskretnych:

$$I(\theta) = E \left(\left(\frac{\partial \ln p(X)}{\partial \theta} \right)^2 \right), \quad \text{gdzie } p(x) \text{ jest prawd. wartości } x$$

- Dla rozkładów ciągłych:

$$I(\theta) = E \left(\left(\frac{\partial \ln f(X)}{\partial \theta} \right)^2 \right), \quad \text{gdzie } f(x) \text{ jest gęstością}$$

Wtedy:

$$D^2(\hat{\theta}) \geq \frac{1}{nI(\theta)}$$

Czy estymator może mieć dowolnie małą wariancję?

Nierówność Craméra-Rao

Niech $\hat{\theta}$ będzie nieobciążonym estymatorem parametru θ wyznaczonym z próby X_1, X_2, \dots, X_n . Zdefiniujmy **funkcję informacji Fishera** $I(\theta)$ jako:

- Dla rozkładów dyskretnych:

$$I(\theta) = E \left(\left(\frac{\partial \ln p(X)}{\partial \theta} \right)^2 \right), \quad \text{gdzie } p(x) \text{ jest prawd. wartości } x$$

- Dla rozkładów ciągłych:

$$I(\theta) = E \left(\left(\frac{\partial \ln f(X)}{\partial \theta} \right)^2 \right), \quad \text{gdzie } f(x) \text{ jest gęstością}$$

Wtedy:

$$D^2(\hat{\theta}) \geq \frac{1}{nI(\theta)}$$

Dowód

Dowód znajduje się w materiałach dodatkowych

Przykład

Założmy że X ma rozkład normalny $N(\mu, \sigma^2)$ i chcemy estymować μ

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

Przykład

Założmy że X ma rozkład normalny $N(\mu, \sigma^2)$ i chcemy estymować μ

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

$$\text{Mamy: } \ln f(x) = \ln \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right) - \frac{(x - \mu)^2}{2\sigma^2}$$

Przykład

Założmy że X ma rozkład normalny $N(\mu, \sigma^2)$ i chcemy estymować μ

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

$$\text{Mamy: } \ln f(x) = \ln \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right) - \frac{(x - \mu)^2}{2\sigma^2}$$

$$\frac{\partial \ln f(x)}{\partial \mu} = -\frac{\partial}{\partial \mu} \left(\frac{(x - \mu)^2}{2\sigma^2} \right) =$$

Przykład

Założmy że X ma rozkład normalny $N(\mu, \sigma^2)$ i chcemy estymować μ

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

$$\text{Mamy: } \ln f(x) = \ln \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right) - \frac{(x - \mu)^2}{2\sigma^2}$$

$$\frac{\partial \ln f(x)}{\partial \mu} = -\frac{\partial}{\partial \mu} \left(\frac{(x - \mu)^2}{2\sigma^2} \right) = \frac{x - \mu}{\sigma^2}$$

Przykład

Założmy że X ma rozkład normalny $N(\mu, \sigma^2)$ i chcemy estymować μ

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

$$\text{Mamy: } \ln f(x) = \ln \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right) - \frac{(x - \mu)^2}{2\sigma^2}$$

$$\frac{\partial \ln f(x)}{\partial \mu} = -\frac{\partial}{\partial \mu} \left(\frac{(x - \mu)^2}{2\sigma^2} \right) = \frac{x - \mu}{\sigma^2}$$

$$I(\mu) = E \left(\left(\frac{X - \mu}{\sigma^2} \right)^2 \right) =$$

Przykład

Założmy że X ma rozkład normalny $N(\mu, \sigma^2)$ i chcemy estymować μ

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

$$\text{Mamy: } \ln f(x) = \ln \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right) - \frac{(x - \mu)^2}{2\sigma^2}$$

$$\frac{\partial \ln f(x)}{\partial \mu} = -\frac{\partial}{\partial \mu} \left(\frac{(x - \mu)^2}{2\sigma^2} \right) = \frac{x - \mu}{\sigma^2}$$

$$I(\mu) = E \left(\left(\frac{X - \mu}{\sigma^2} \right)^2 \right) = \frac{1}{\sigma^4} \underbrace{E \left((X - \mu)^2 \right)}_{\sigma^2} = \frac{1}{\sigma^2}$$

Przykład – c.d.

$$X \sim N(\mu, \sigma^2), \quad I(\mu) = \frac{1}{\sigma^2}$$

Z nierówności Craméra-Rao wynika więc, że dla dowolnego nieobciążonego estymatora $\hat{\mu}$ wartości oczekiwanej μ :

$$D^2(\hat{\mu}) \geq \frac{1}{nI(\mu)} = \frac{1}{n1/\sigma^2} = \frac{\sigma^2}{n}.$$

Przykład – c.d.

$$X \sim N(\mu, \sigma^2), \quad I(\mu) = \frac{1}{\sigma^2}$$

Z nierówności Craméra-Rao wynika więc, że dla dowolnego nieobciążonego estymatora $\hat{\mu}$ wartości oczekiwanej μ :

$$D^2(\hat{\mu}) \geq \frac{1}{nI(\mu)} = \frac{1}{n1/\sigma^2} = \frac{\sigma^2}{n}.$$

Ale wiemy, że estymator \bar{X}_n jest nieobciążony i ma wariancję $\frac{\sigma^2}{n}$!

Przykład – c.d.

$$X \sim N(\mu, \sigma^2), \quad I(\mu) = \frac{1}{\sigma^2}$$

Z nierówności Craméra-Rao wynika więc, że dla dowolnego nieobciążonego estymatora $\hat{\mu}$ wartości oczekiwanej μ :

$$D^2(\hat{\mu}) \geq \frac{1}{nI(\mu)} = \frac{1}{n1/\sigma^2} = \frac{\sigma^2}{n}.$$

Ale wiemy, że estymator \bar{X}_n jest nieobciążony i ma wariancję $\frac{\sigma^2}{n}$!

Wniosek: Estymator $\hat{\mu} = \bar{X}_n$ wartości oczekiwanej μ jest **efektywny** jeśli X ma rozkład normalny.

Zadanie

Zadanie 4

Pokaż, że funkcja informacji Fishera $I(p)$ dla rozkładu dwupunktowego $B(p)$ ma postać:

$$I(p) = \frac{1}{p(1-p)}$$

Następnie pokaż, że estymator \bar{X}_n wartości oczekiwanej p jest efektywny dla tego rozkładu