

15 Statystyka matematyczna

Rachunek prawdopodobieństwa opracował narzędzia potrzebne do obliczania szansy uzyskania konkretnych wyników eksperymentu losowego na podstawie ogólnych praw nim rządzących. Statystyka matematyczna zajmuje się problemem odwrotnym i umożliwia wnioskowanie na temat praw ogólnych na podstawie wyników eksperymentu losowego.

Definicja 15.1 (Model statystyczny eksperymentu losowego).

Model statystyczny eksperymentu losowego zakłada, że jego wyniki, x_1, x_2, \dots, x_n , są realizacją zbioru zmiennych losowych X_1, X_2, \dots, X_n zwanych **próbą losową**.

- Model może zawierać częściową specyfikację rozkładu pr. jakiemu podlegają X_i
- Np. model zakłada, że X_i podlegają rozkładowi Poissona o nieznanych wartościach parametrów μ

W ogólnym przypadku zmienne losowe X_i mogą podlegać różnym rozkładom prawdopodobieństwa i być statystycznie zależne.

Definicja 15.2 (Próba prosta).

Próbę losową nazywamy **prostą**, jeśli zmienne losowe X_1, X_2, \dots, X_n podlegają **temu samemu** rozkładowi i są statystycznie **niezależne**.

Często wyniki eksperymentu losowego charakteryzujemy za pomocą jednej wartości która jest funkcją tych wyników:

$$y = h(x_1, x_2, \dots, x_n)$$

Definicja 15.3 (Statystyka).

Statystyką Y nazywamy **zmienną losową** realizacją której jest wartość $y = h(x_1, x_2, \dots, x_n)$

$$Y = h(X_1, X_2, \dots, X_n)$$

Statystyka jest zatem zmienną losową będącą funkcją próby losowej.

Przykład 15.1 (Wartość średnia).

Częstą praktyką jest powtarzanie pomiaru wielokrotnie w tych samych warunkach i prezentowanie wyniku jako wartość średnią z uzyskanych pomiarów.

$$\bar{x} = h(x_1, x_2, \dots, x_n) = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{\sum_i^n x_i}{n}$$

Statystyką której realizacją jest wartość średnia jest **wartość średnia z próby**:

$$\bar{X} = h(X_1, X_2, \dots, X_n) = \frac{X_1 + X_2 + \dots + X_n}{n} = \frac{\sum_i^n X_i}{n}$$

Wyniki eksperymentu mogą posłużyć do oszacowania wielkości Θ , którą jesteśmy zainteresowani. Z reguły wielkość ta jest **parametrem** lub **funkcją parametrów** rozkładu modelowego.

Definicja 15.4 (Estymata).

Estymatą wielkości Θ nazywamy wartość θ , będącą funkcją tylko wyników eksperymentu

$$\theta = h(x_1, x_2, \dots, x_n)$$

Definicja 15.5 (Estymator).

Niech $\theta = h(x_1, x_2, \dots, x_n)$ będzie estymatą wielkości Θ . Estymata θ jest realizacją statystyki

$$\hat{\Theta} = h(X_1, X_2, \dots, X_n)$$

zwanej **estymatorem** wielkości Θ .

Przykład 15.2 (Estymator).

Niech x_i $i = 1, 2, \dots, n$ oznaczają ilości sprzedanych samochodów w salonie z ostatnich n dni roboczych. Jeśli sprzedamy jakiś samochód to na następny dzień będziemy musieli sprowadzić brakujące modele z fabryki. Chcemy oszacować prawdopodobieństwo P , że w danym dniu nie sprzedamy żadnego samochodu.

Jak skonstruować estymator wielkości P ?

Pr. P możemy oszacować na dwa sposoby:

- Jeśli przez sukces będziemy rozumieć zdarzenie polegające na braku sprzedaży w danym dniu to estymatorem, \hat{P}_1 może być stosunek ilości dni w których nie sprzedano żadnego samochodu do ilości wszystkich dni obserwacji:

$$\hat{P}_1 = \frac{k_0}{n} \quad k_0 = \sum_{i: x_i=0} 1$$

- Z drugiej strony możemy założyć, że ilość sprzedanych samochodów każdego dnia podlega rozkładowi Poissona o parametrze μ , który możemy oszacować jako średnią ilość sprzedanych samochodów na jeden dzień, $\hat{\mu} = \bar{X}$, a szukane prawdopodobieństwo $P = P(k = 0) = e^{-\mu}$. Zatem

$$\hat{P}_2 = e^{-\bar{X}}$$

Rysunek 15 przedstawia wyniki symulacji Monte Carlo dla $n = 30$ i wartości x_i pochodzących z rozkładu Poissona o parametrze $\mu = 2$.

Prawdziwa wartość estymowanego parametru wynosi $P = P(k = 0) = e^{-2} \approx 0,1353$. Na podstawie symulacji Monte Carlo możemy oszacować wartość oczekiwaną oraz odchylenie standardowe estymatorów wielkości P . W przypadku estymatora \hat{P}_1 wartości te wynoszą 0,1354 oraz 0,0630 a dla estymatora \hat{P}_2 odpowiednio 0,1402 oraz 0,0361. Wartość oczekiwana estymatora \hat{P}_1 jest bliższa wartości prawdziwej niż estymatora \hat{P}_2 . Z drugiej jednak strony rozrzut estymatora \hat{P}_1 wokół wartości oczekiwanej jest większy niż estymatora \hat{P}_2 . Oba te parametry są podstawą oceny estymatorów.

Estymator będąc zmienną losową ma określony rozkład prawdopodobieństwa

$$\hat{\Theta} = h(X_1, X_2, \dots, X_n)$$

zależny od rozkładów zmiennych losowych X_i

Przykład 15.3 (Rozkład estymatora).

Jakie są rozkłady prawdopodobieństwa estymatorów \hat{P}_1, \hat{P}_2 z poprzedniego przykładu?

$$\hat{P}_1 = \frac{k_0}{n}$$

zmienna k_0 podlega rozkładowi [dwumianowemu](#)

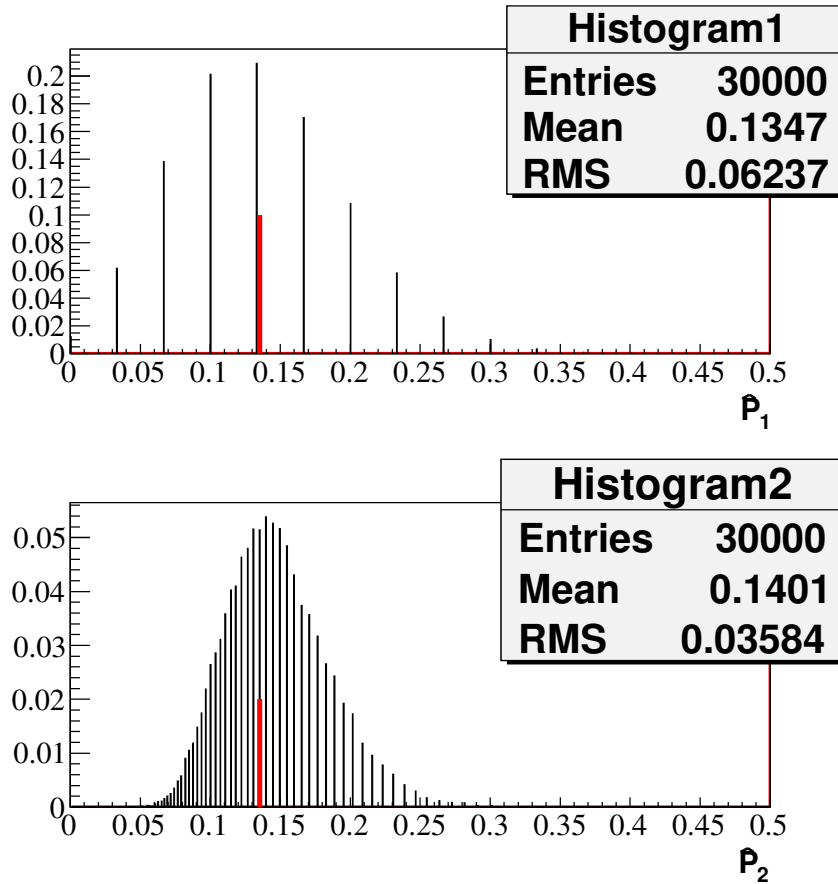
$$Bin(k_0; n, P) = \binom{n}{k_0} P^{k_0} (1 - P)^{n - k_0} \quad k_0 = 0, 1, \dots, n$$

Jest to rozkład dyskretny zatem rozkład estymatora też jest rozkładem dyskretnym i ma postać:

$$P(\hat{P}_1 = p_1 = \frac{k_0}{n}) = Bin(np_1; n, P) \quad p_1 = 0, 1/n, 2/n, \dots, 1$$

Powyższy rozkład dla $n = 30$ i $P = e^{-2}$ odpowiada górnemu wykresowi na rysunku 14.

$$\hat{P}_2 = e^{-\bar{X}}$$



Rysunek 14: Częstość wartości estymatora \hat{P}_1 (wykres górny) oraz \hat{P}_2 (rysunek dolny) dla próby losowej o liczebności $n = 30$ podlegających rozkładowi Poissona o parametrze $\mu = 2$. Próbę losową wygenerowano 30000 razy. Obserwowane częstości są dobrym przybliżeniem rozkładów prawdopodobieństwa jakim podlegają estymatory \hat{P}_1 oraz \hat{P}_2 . Czerwoną kreską oznaczono położenie estymowanej wielkości (wartość prawdziwa)

zmienne X_i podlegają rozkładowi Poissona o parametrze

$$\mu = -\ln P; \quad (P = e^{-\mu})$$

$$P(X_i = k) = e^{-\mu} \frac{\mu^k}{k!} \quad k = 0, 1, \dots, \infty$$

$Z = \sum_i^n X_i$ podlega rozkładowi Poissona o parametrze $n \cdot \mu$

$$P(Z = z) = e^{-n\mu} \frac{(n\mu)^z}{z!} = Poi(z; -n \ln P) \quad z = 0, 1, \dots, \infty$$

Jest to rozkład dyskretny zatem rozkład estymatora $\hat{P}_2 = e^{-Z/n}$ też jest rozkładem dyskretnym i ma postać:

$$P(\hat{P}_2 = p_2 = e^{-\frac{z}{n}}) = Poi(-n \ln p_2; -n \ln P) \quad p_2 = 0, \dots, e^{-2/n}, e^{-1/n}, 1$$

Powyższy rozkład dla $n = 30$ i $P = e^{-2}$ odpowiada dolnemu wykresowi na rysunku 18.

Znając rozkład estymatora można obliczyć jego wartość oczekiwaną i tym samym otrzymać pierwszą z wielkości używanych do oceny estymatorów.

Definicja 15.6 (Estymator nieobciążony).

Estymator $\hat{\Theta}$ parametru Θ jest **nieobciążony** jeśli

$$E[\hat{\Theta}] = \Theta$$

Różnicę $E[\hat{\Theta}] - \Theta$ nazywamy **obciążeniem** estymatora.

Przykład 15.4 (Obciążenie estymatora).

Jakie są obciążenia estymatorów \hat{P}_1, \hat{P}_2 ?

$$E[\hat{P}_1] = E\left[\frac{k_0}{n}\right] = \frac{E[k_0]}{n} = \frac{nP}{n} = P$$

Estymator \hat{P}_1 jest estymatorem **nieobciążonym**. W przypadku estymatora \hat{P}_2 nie można skorzystać z liniowości wartości oczekiwanej ponieważ związek między estymatorem \hat{P}_2 a zmienna losowa Z nie jest liniowy.

$$\begin{aligned} E[\hat{P}_2] &= \sum_{z=0}^{z=\infty} e^{-z/n} P^n \frac{(-n \ln P)^z}{z!} \\ &= P^n \sum_{z=0}^{z=\infty} \frac{(-e^{-1/n} n \ln P)^z}{z!} \\ &= P^n e^{-e^{-1/n} n \ln P} \\ &= P^{n(1-e^{-1/n})} \end{aligned}$$

gdzie skorzystaliśmy z rozwinięcia $e^x = \sum \frac{x^k}{k!}$.

Estymator \hat{P}_2 jest estymatorem obciążonym, jego obciążenie wynosi

$$E[\hat{P}_2] - P = P^{n(1-e^{-1/n})} - P$$

Dla $n = 30$ i $P = e^{-2}$ obciążenie estymatora wynosi 0,0045.

Dla $n \rightarrow \infty$ wyrażenie $n(1 - e^{-1/n}) \rightarrow 1$ i tym samym

$$E[\hat{P}_2] \rightarrow P$$

Estymatory takie nazywamy **asymptotycznie nieobciążonymi**

Definicja 15.7 (Estymator asymptotycznie nieobciążony).

Estymator $\hat{\Theta}$ parametru Θ jest **asymptotycznie nieobciążony** jeśli

$$\lim_{n \rightarrow \infty} E[\hat{\Theta}] = \Theta$$

Twierdzenie 15.1 (Nieobciążony estymator wartości oczekiwanej i wariancji).

Załóżmy że próba losowa X_1, X_2, \dots, X_n jest próbą prostą z rozkładu o nieznannej wartości oczekiwanej μ oraz wariancji σ^2 . Nieobciążonymi estymatorami tych wielkości są:

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

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

Dowód.

$$E[\hat{\mu}] = \frac{1}{n} \sum_{i=1}^n E[X_i] = \frac{1}{n} \sum_{i=1}^n \mu = \frac{1}{n} n\mu = \mu$$

Aby dowieść drugą część twierdzenia, rozpatrzmy najpierw zmienną losową $Y_i = X_i - \bar{X}$. Na mocy liniowości wartości oczekiwanej oraz pierwszej części twierdzenia:

$$E[Y_i] = E[X_i - \bar{X}] = \mu - \mu = 0$$

Zatem

$$\text{Var}[Y_i] = E[Y_i^2] - (E[Y_i])^2 = E[Y_i^2]$$

□

$$\begin{aligned} E[\hat{\sigma}^2] &= \frac{1}{n-1} \sum_{i=1}^n E[(X_i - \bar{X})^2] \\ &= \frac{1}{n-1} \sum_{i=1}^n \text{Var}[X_i - \bar{X}] \\ &= \frac{1}{n-1} \sum_{i=1}^n \text{Var}\left[X_i - \frac{1}{n} \sum_{j=1}^n X_j\right] \\ &= \frac{1}{n-1} \sum_{i=1}^n \text{Var}\left[X_i - \frac{1}{n} X_i - \frac{1}{n} \sum_{j \neq i} X_j\right] \\ &= \frac{1}{n-1} \sum_{i=1}^n \text{Var}\left[\frac{n-1}{n} X_i - \frac{1}{n} \sum_{j \neq i} X_j\right] \\ &= \frac{1}{n-1} \sum_{i=1}^n \left[\frac{(n-1)^2}{n^2} \text{Var}[X_i] + \frac{1}{n^2} \sum_{j \neq i} \text{Var}[X_j] \right] \\ &= \frac{1}{n-1} \sum_{i=1}^n \left[\frac{(n-1)^2}{n^2} \sigma^2 + \frac{1}{n^2} (n-1) \sigma^2 \right] \\ &= \frac{1}{n-1} \sum_{i=1}^n \frac{(n-1)}{n} \sigma^2 \\ &= \frac{1}{n} \sum_{i=1}^n \sigma^2 = \frac{1}{n} n \sigma^2 = \sigma^2 \end{aligned}$$

Czynnik $\frac{1}{n-1}$ w drugiej części twierdzenia 17.1 pojawia się dlatego, że nie znamy wartości oczekiwanej μ i zamiast niej używamy estymatora \bar{X} .

Twierdzenie 15.2 (Nieobciążony estymator wariancji).

Załóżmy że próba losowa X_1, X_2, \dots, X_n jest próbą prostą z rozkładu o **znanej** wartości oczekiwanej μ oraz **nieznanej** wariancji σ^2 . Nieobciążonym estymatorem wariancji będzie:

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

Dowód.

$$\begin{aligned} E[\hat{\sigma}^2] &= \frac{1}{n} \sum_{i=1}^n E[(X_i - \mu)^2] \\ &= \frac{1}{n} \sum_{i=1}^n \sigma^2 = \frac{1}{n} n \sigma^2 = \sigma^2 \end{aligned}$$

□

Twierdzenie 17.1 uzupełnione estymatorami momentów wyższych rzędów stanowi podstawę ogólnej metody znajdowania estymatorów zwanej metodą momentów.

Definicja 15.8 (Moment rzędu n).

Niech X jest zmienną losową. **Momentem** zmiennej X rzędu n nazywamy

$$\mu_n = E[X^n]$$

Definicja 15.9 (Estymator momentu rzędu n).

Niech X_1, X_2, \dots, X_k jest próbą prostą. **Estymatorem** momentu (lub momentem z próby losowej) rzędu n nazywamy

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

Twierdzenie 15.3 (Estymatory momentów).

Niech X_1, X_2, \dots, X_k jest próbą prostą.

$$E[\hat{\mu}_n] = \mu_n; \quad \text{Var}[\hat{\mu}_n] = \frac{1}{k} \text{Var}[X^n]$$

Dowód.

$$\begin{aligned} E[\hat{\mu}_n] &= \frac{1}{k} \sum_{i=1}^k E[X_i^n] \\ &= \frac{k \mu_n}{k} = \mu_n \\ \text{Var}[\hat{\mu}_n] &= \frac{1}{k^2} \sum_{i=1}^k \text{Var}[X_i^n] \\ &= \frac{k \text{Var}[X^n]}{k^2} = \frac{\text{Var}[X^n]}{k} \end{aligned}$$

□

Definicja 15.10 (Metoda momentów).

Niech nieznanymi parametry Θ rozkładu zm. los. X da się wyrazić jako funkcja pewnej liczby momentów tego rozkładu:

$$\Theta = f(\mu, \sigma^2, \mu_2, \dots)$$

wtedy

$$\hat{\Theta} = f(\hat{\mu}, \hat{\sigma}^2, \hat{\mu}_2, \dots)$$

Estymator $\hat{\Theta}$ nazywamy **estymatorem metody momentów**.

- Jeśli funkcja f jest liniowa to nieobciążoność estymatorów momentów przenosi się na estymator $\hat{\Theta}$ w przeciwnym przypadku estymator będzie obciążony.

Przykład 15.5 (Odległość punktów od środka okręgu).

Dysponujemy próbą prostą x_1, x_2, \dots, x_n odległości losowo wybranych punktów wewnątrz okręgu o promieniu R od środka tego okręgu.

Jak skonstruować nieobciążony estymator nieznannej wartości promienia R ?

$$f(x; R) = \frac{2x}{R^2} \quad 0 < x < R$$

$$\mu = \frac{2}{3}R$$

Nieobciążonym estymatorem R metody momentów jest

$$\hat{R}_1 = \frac{3}{2}\hat{\mu} = \frac{3}{2}\bar{X}$$

Wartości ekstremalne jako estymatory

Niech zm. los. X będzie określona na przedziale $[\alpha, \beta]$. Dysponując próbą prostą x_1, x_2, \dots, x_n :

- $\hat{\alpha} = \text{Min}(x_1, x_2, \dots, x_n)$
- $\hat{\beta} = \text{Max}(x_1, x_2, \dots, x_n)$

Przykład 15.6 (Odległość punktów od środka okręgu).

Czy $\hat{\beta} = \text{Max}(x_1, x_2, \dots, x_n)$ jest nieobciążonym estymatorem parametru R z poprzedniego przykładu?

Twierdzenie 15.4 (Rozkład wartości maksymalnej).

Niech X_1, X_2, \dots, X_n będą *niezależnymi* zm. los. o dystrybuancie F_X i gęstości pr. f_X oraz niech $Z = \text{Max}(X_1, X_2, \dots, X_n)$.
Wtedy

- $F_Z(z) = (F_X(z))^n$
- $f_Z(z) = \frac{d}{dz} [(F_X(z))^n] = n(F_X(z))^{n-1} f_X(z)$

Dowód.

$$\begin{aligned} F_Z(z) &= P(Z \leq z) \\ &= P(\text{Max}(X_1, X_2, \dots, X_n) \leq z) \\ &= P(X_1 \leq z, X_2 \leq z, \dots, X_n \leq z) \\ &= P(X_1 \leq z) \cdot P(X_2 \leq z) \cdots P(X_n \leq z) \\ &= (F_X(z))^n \end{aligned}$$

□

Twierdzenie 15.5 (Rozkład wartości minimalnej).

Niech X_1, X_2, \dots, X_n będą *niezależnymi* zm. los. o dystrybuancie F_X i gęstości pr. f_X oraz niech $V = \text{Min}(X_1, X_2, \dots, X_n)$.
Wtedy

- $F_V(v) = 1 - [1 - F_X(v)]^n$

- $f_V(v) = \frac{d}{dv} [1 - [1 - F_X(v)]^n] = n[1 - F_X(v)]^{n-1} f_X(v)$

Dowód.

$$\begin{aligned}
 F_V(v) &= P(V \leq v) \\
 &= P(\text{Min}(X_1, X_2, \dots, X_n) \leq v) \\
 &= 1 - P(\text{Min}(X_1, X_2, \dots, X_n) > v) \\
 &= 1 - P(X_1 > v, X_2 > v, \dots, X_n > v) \\
 &= 1 - [1 - P(X_1 \leq v)] \cdot [1 - P(X_2 \leq v)] \cdots [1 - P(X_n \leq v)] \\
 &= 1 - [1 - F_X(v)]^n
 \end{aligned}$$

□

Przykład 15.7 (Odległość punktów od środka okręgu).

Czy $Z = \text{Max}(X_1, X_2, \dots, X_n)$ jest nieobciążonym estymatorem parametru R z poprzedniego przykładu?

Rozwiązanie.

$$\begin{aligned}
 F_X(x) &= \left[\frac{x}{R}\right]^2 \quad 0 < x < R \\
 f_Z(z) &= \frac{2n}{R} \left[\frac{z}{R}\right]^{2n-1} \quad 0 < z < R \\
 E[Z] &= \frac{2n}{R^{2n}} \int_0^R z^{2n} dz = \frac{2n}{2n+1} R
 \end{aligned}$$

Zatem zmienna losowa Z jest estymatorem obciążonym ale

$$\hat{R}_2 = \frac{2n+1}{2n} Z; \quad E[\hat{R}_2] = R$$

jest już estymatorem nieobciążonym.

Definicja 15.11 (Efektywność estymatora).

Niech $\hat{\Theta}_1$ i $\hat{\Theta}_2$ będą nieobciążonymi estymatorami tego samego parametru Θ . Estymator $\hat{\Theta}_1$ nazywamy bardziej efektywnym od estymatora $\hat{\Theta}_2$ wtedy gdy

$$\text{Var}[\hat{\Theta}_1] < \text{Var}[\hat{\Theta}_2]$$

Przykład 15.8 (Efektywność estymatora).

Który z estymatorów \hat{R}_1 czy \hat{R}_2 jest bardziej efektywny?

$$\begin{aligned}
 f(x; R) &= \frac{2x}{R^2}; \quad \text{Var}[X] = \frac{R^2}{18} \\
 \text{Var}[\hat{R}_1] &= \text{Var}\left[\frac{3}{2}\bar{X}\right] \\
 &= \text{Var}\left[\frac{3}{2} \frac{\sum_{i=1}^n X_i}{n}\right] \\
 &= \frac{9}{4n^2} \sum_{i=1}^n \text{Var} X_i \\
 &= \frac{9}{4n^2} n \frac{R^2}{18} \\
 &= \frac{R^2}{8n}
 \end{aligned}$$

$$Z = \text{Max} (X_1, X_2, \dots, X_n)$$

$$E[Z] = \frac{2n}{2n+1}R$$

$$E[Z^2] = \frac{2n}{R^{2n}} \int_0^R z^{2n+1} dz = \frac{2n}{2n+2}R^2 = \frac{n}{n+1}R^2$$

$$\begin{aligned} \text{Var} [Z] &= E[Z^2] - E[Z]^2 \\ &= \frac{n}{n+1}R^2 - \frac{4n^2}{(2n+1)^2}R^2 \\ &= \frac{n(2n+1)^2 - 4n^2(n+1)}{(n+1)(2n+1)^2}R^2 \\ &= \frac{n}{(n+1)(2n+1)^2}R^2 \\ \text{Var} [\hat{R}_2] &= \text{Var} \left[\frac{2n+1}{2n}Z \right] \\ &= \frac{(2n+1)^2}{4n^2} \frac{n}{(n+1)(2n+1)^2}R^2 \\ &= \frac{R^2}{4n(n+1)} \end{aligned}$$

$$\text{Var} [\hat{R}_1] = \frac{R^2}{8n} > \text{Var} [\hat{R}_2] = \frac{R^2}{4n(n+1)}$$

Estymator \hat{R}_2 jest bardziej efektywny niż estymator \hat{R}_1 .

$$\lim_{n \rightarrow \infty} \text{Var} [\hat{R}_1] = \lim_{n \rightarrow \infty} \text{Var} [\hat{R}_2] = 0$$

Definicja 15.12 (Estymator zgodny).

Estymator $\hat{\Theta}$ parametru Θ jest **zgodny** jeśli

$$\lim_{n \rightarrow \infty} \text{Var} [\hat{\Theta}] = 0$$

W pewnych dość często spotykanych problemach możemy określić dolne ograniczenie na wariancję nieobciążonego estymatora.

Twierdzenie 15.6 (Twierdzenie Cramera-Rao).

Niech X_1, X_2, \dots, X_n jest próbą **prostą** o gęstości $f(x; \Theta)$, Takiej, że:

- $\forall x, \exists \frac{\partial}{\partial \Theta} \ln f(x; \Theta)$
- jeśli X jest **ograniczona** to ograniczenie nie zależy od Θ
- jeśli X jest **nieograniczona** to $f(x; \Theta)$ ma **ciągłą pochodną** i jest **całkowalna** dla każdej wartości Θ .

Wtedy wariancja **nieobciążonego** estymatora $\hat{\Theta}$ spełnia nierówność:

$$\text{Var} [\hat{\Theta}] \geq \frac{1}{nE\left[\left(\frac{\partial}{\partial \Theta} \ln f(x; \Theta)\right)^2\right]}$$

Definicja 15.13 (Estymator najefektywniejszy).

Estymator **nieobciążony** którego wariancja przyjmuje wartość minimalną

$$\text{Var} [\hat{\Theta}] = \frac{1}{nE\left[\left(\frac{\partial}{\partial \Theta} \ln f(x; \Theta)\right)^2\right]}$$

nazywamy estymatorem **najefektywniejszym**.

W przypadku estymatorów obciążonych podstawą oceny jakości estymatora nie może być tylko jego wariancja. W takich wypadkach podstawą oceny jakości estymatora jest średni błąd kwadratowy.

Definicja 15.14 (Średni błąd kwadratowy estymatora).

Niech $\hat{\Theta}$ będzie estymatorem parametru Θ . **Średnim błędem kwadratowym** estymatora nazywamy:

$$\begin{aligned} \text{MSE} [\hat{\Theta}] &= E [(\hat{\Theta} - \Theta)^2] \\ &= E [(\hat{\Theta} - E[\hat{\Theta}] + E[\hat{\Theta}] - \Theta)^2] \\ &= E [(\hat{\Theta} - E[\hat{\Theta}])^2 + 2(\hat{\Theta} - E[\hat{\Theta}])(E[\hat{\Theta}] - \Theta) \\ &\quad + (E[\hat{\Theta}] - \Theta)^2] \\ &= E [(\hat{\Theta} - E[\hat{\Theta}])^2] + 2(E[\hat{\Theta}] - \Theta)E[\hat{\Theta} - E[\hat{\Theta}]] \\ &\quad + E[(E[\hat{\Theta}] - \Theta)^2] \\ &= \text{Var} [\hat{\Theta}] + (E[\hat{\Theta}] - \Theta)^2 \\ &= \text{Wariancja} + \text{Obciążenie}^2 \end{aligned}$$

Średni błąd kwadratowy który jest wartością oczekiwaną kwadratu różnicy między estymatorem a wartością estymowaną jest sumą wariancji estymatora i kwadratu jego obciążenia. **Uwaga:** Estymatory obciążone mogą mieć mniejszy średni błąd kwadratowy niż dolne ograniczenie na wariancję estymatora nieobciążonego dane przez twierdzenia Cramera-Rao.

Nie zawsze da się w prosty sposób zaproponować estymator wielkości którą jesteśmy zainteresowani. Istnieje ogólna metoda wyznaczania estymatorów.

Definicja 15.15 (Zasada największej wiarygodności).

Dysponując wynikami eksperymentu losowego x_1, x_2, \dots, x_n należy tak dobrać estymowane parametry aby wyniki te były **najbardziej wiarygodne** (bardziej prawdopodobne niż **te same** wyniki przy **innych** wartościach estymowanych parametrów).

Definicja 15.16 (Funkcja wiarygodności).

Niech $\vec{x} = x_1, x_2, \dots, x_n$ jest realizacją próby losowej $\vec{X} = X_1, X_2, \dots, X_n$ o rozkładach zależnych od parametru Θ . **Zasada największej wiarygodności** sugeruje estymację parametru Θ wartością która **maksymalizuje** funkcję będącą **łącznym pr. (gęstością pr.)** realizacji próby losowej rozumianej jako funkcję parametru Θ . Funkcję tę nazywamy **funkcją wiarygodności**

$$\begin{aligned} L(\Theta) &= L(\Theta; \vec{x}) = P(\vec{X} = \vec{x}; \Theta) = P(\vec{X}) \\ L(\Theta; \vec{x}) &= f_{\vec{X}}(\vec{x}; \Theta) \end{aligned}$$

Funkcja wiarygodności

Jeśli $\vec{X} = X_1, X_2, \dots, X_n$ jest próbą **prostą**:

$$\begin{aligned} L(\Theta) &= p(x_1; \Theta)p(x_2; \Theta) \cdots p(x_n; \Theta) \\ L(\Theta) &= f(x_1; \Theta)f(x_2; \Theta) \cdots f(x_n; \Theta) \end{aligned}$$

Jeśli próba **nie** jest prosta to:

$$\begin{aligned} L(\Theta) &= p_1(x_1; \Theta)p_2(x_2|x_1; \Theta) \cdots p_n(x_n|x_1, x_2, \dots, x_{n-1}; \Theta) \\ L(\Theta) &= f_1(x_1; \Theta)f_2(x_2|x_1; \Theta) \cdots f_n(x_n|x_1, x_2, \dots, x_{n-1}; \Theta) \end{aligned}$$

Definicja 15.17 (Estymator metody największej wiarygodności).

Estymatą **metody największej wiarygodności** jest wartość $\theta = h(x_1, x_2, \dots, x_n)$ która **maksymalizuje** (zwykle zeruje pierwszą pochodną) funkcję wiarygodności $L(\Theta)$. Estymata ta jest realizacją estymatora

$$\hat{\Theta} = h(X_1, X_2, \dots, X_n)$$

zwanego estymatorem **metody największej wiarygodności**.

- $L(\hat{\Theta}) = \text{Sup} \{L(\Theta)\}; \Rightarrow \frac{\partial L(\Theta)}{\partial \Theta} |_{\Theta=\hat{\Theta}} = 0$
- $\text{Var} [\hat{\Theta}] \approx \frac{-1}{\frac{\partial^2 \ln L(\Theta)}{\partial \Theta^2} |_{\Theta=\hat{\Theta}}}$

Postać estymatora wariancji estymatora metody największej wiarygodności wynika z faktu, że dla dużych próbek estymator ma w przybliżeniu rozkład normalny.

Estymatory metody największej wiarygodności są:

- **niezmiennicze** - Jeśli $\hat{\Theta}$ jest estymatorem największej wiarygodności parametru Θ to $g(\hat{\Theta})$ jest estymatorem największej wiarygodności wielkości $g(\Theta)$, (jeśli g jest odwracalna).
- **asymptotycznie nieobciążone**;
- **asymptotycznie najefektywniejsze** -

$$\text{Var} [\hat{\Theta}] \rightarrow \frac{1}{nE[(\frac{\partial}{\partial \Theta} \ln f(x))^2]}$$

Ostatnia własność oznacza, że estymator wariancji estymatora dąży do dolnego ograniczenia danego przez twierdzenie Cramera-Rao.