

Spis treści

Spis treści

1	Wstęp	1
1.1	Statystyka matematyczna	1
1.2	Literatura	1
1.3	Model statystyczny	2
1.4	Preliminaria	3
2	ENMW	11
2.1	Określenie	11
2.2	Twierdzenie Rao-Blackwella	11
2.3	Model dwupunktowy	12
2.4	Model Poissona	14
2.5	Model gaussowski	18
2.6	Nierówność Cramera-Rao	20
2.7	Antyprzykłady	21
3	ENW	23
3.1	Przykład wstępny	23
3.2	Określenie	24
3.3	Model dwupunktowy	25
3.4	Model Poissona	26
3.5	Model gaussowski	29
3.6	Asymptotyka	31
3.7	Inne przykłady	31
4	EMNK	35
4.1	Przykład wstępny	35
4.2	Określenie	37
4.3	Model liniowy	38
4.4	Przykłady	39
4.5	Własności	41
4.6	Estymacja wariancji	41
4.7	Własności probabilistyczne	44

1 Wstęp

1.1 Statystyka matematyczna

STATYSTYKA

nauka poświęcona metodom badania (analizowania) zjawisk masowych; polega na systematyzowaniu obserwowanych cech ilościowych i jakościowych oraz przedstawianiu wyników w postaci zestawień tabelarycznych, wykresów, itp.; posługuje się rachunkiem prawdopodobieństwa.

STATYSTYKA MATEMATYCZNA

dział matematyki stosowanej oparty na rachunku prawdopodobieństwa; zajmuje się badaniem zbiorów na podstawie znajomości własności ich części.

Encyklopedia Popularna PWN, Warszawa 1982

1.2 Literatura

Literatura

- **Silvey S. D.** 1978: Wnioskowanie statystyczne, PWN Warszawa
- **Zieliński R.** 1990: Siedem wykładów wprowadzających do statystyki matematycznej, <http://www.impan.pl/~rziel/Books.html>
- **Jaworski S., Zieliński W.** 2012: Zbiór zadań z rachunku prawdopodobieństwa i statystyki matematycznej, <http://wojtek.zielinski.statystyka.info/dydaktyka.htm>

Literatura

- **Krzyśko M.** 1994 Statystyka matematyczna, UAM Poznań
- **Krzyśko M.** 1997 Statystyka matematyczna, Część II, UAM Poznań
- **Rao C. R.** 1982: Modele liniowe statystyki matematycznej, PWN, Warszawa
- **Rao C. R.** 1994: Statystyka i prawda, PWN, Warszawa
- **Zieliński R., Zieliński W.** 1990 Tablice statystyczne, PWN Warszawa
- **Zieliński W.** 2001, Tablice Statystyczne, Wyd. V poprawione i uzupełnione, Fundacja Rozwój SGGW

1.3 Model statystyczny

Model statystyczny: przykład 1

Model probabilistyczny

Rzucamy n -krotnie **symetryczną** monetą.

$$(\{0, 1, \dots, n\}, Bin(n, 0.5))$$

Model statystyczny

Rzucamy n -krotnie **jakaś** monetą.

$$(\{0, 1, \dots, n\}, \{Bin(n, \theta), \theta \in [0, 1]\})$$

Model statystyczny: przykład 2

Model probabilistyczny

W pewnym gatunku owadów jest 40% osobników męskich. Owady chwytamy do uzyskania ustalonej liczby k osobników męskich.

$$(\{k, k + 1, k + 2, \dots\}, NB(k, 0.4))$$

Model statystyczny

W pewnym gatunku owadów jest **pewien** odsetek osobników męskich. Owady chwytamy do uzyskania ustalonej liczby k osobników męskich.

$$(\{k, k + 1, k + 2, \dots\}, \{NB(k, \theta), \theta \in [0, 1]\})$$

Model statystyczny: przykład 3

Model probabilistyczny

Z grupy N osób wśród których jest **znana** liczba M kobiet losujemy n osób.

$$(\{0, 1, \dots, M\}, H(N, n, M))$$

Model statystyczny

Z grupy N osób wśród których jest **nieznana** liczba M kobiet losujemy n osób.

$$(\{0, 1, \dots, M\}, \{H(N, n, M), M \in \{0, 1, \dots, N\}\})$$

Model statystyczny

Określenie

$$(\mathcal{X}, \mathcal{B}, \{P_\theta, \theta \in \Theta\})$$

Problemy

- Ile wynosi θ ? (estymacja)
- W zbiorze Θ wyróżniony jest podzbiór Θ_0 . Czy $\theta \in \Theta_0$? (weryfikacja hipotez statystycznych)

Model statystyczny

Idea wnioskowania statystycznego

1.4 Preliminaria

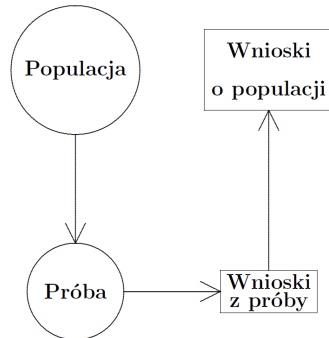
Próba

Określenie

niezależne zmienne losowe X_1, X_2, \dots, X_n o jednakowym rozkładzie P_θ z dystrybuantą F_θ i gęstością p_θ

Dystrybuanta empiryczna

$$F_n(t) = \frac{\#\{1 \leq j \leq n : X_j \leq t\}}{n}$$



Dystrybuanta empiryczna

Ważne fakty

- Dla każdego $t \in \mathbb{R}$ zachodzi $E_\theta F_n(t) = F_\theta(t)$
- Dla każdego $t \in \mathbb{R}$ zachodzi $P_\theta\{\lim_{n \rightarrow \infty} F_n(t) = F_\theta(t)\} = 1$
- Dla każdego $t \in \mathbb{R}$ rozkład zmiennej losowej

$$\sqrt{n} \frac{F_n(t) - F_\theta(t)}{\sqrt{F_\theta(t)(1 - F_\theta(t))}}$$

dąży do rozkładu $N(0, 1)$ przy $n \rightarrow \infty$

Dystrybuanta empiryczna

Podstawowe twierdzenie statystyki matematycznej

Jeżeli próba X_1, X_2, \dots, X_n pochodzi z rozkładu F_θ , to zmienna losowa

$$D_n = \sup_{-\infty < t < \infty} |F_n(t) - F_\theta(t)|$$

dąży do zera z prawdopodobieństwem 1.

Dystrybuanta empiryczna

Podstawowe twierdzenie statystyki matematycznej - ilustracja


$$(\{0, 1, \dots, 20\}, \{Bin(20, \theta), \theta \in [0, 1]\})$$

„Dystrybuanty” dla

$$\theta = 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9$$

Dystrybuanta empiryczna

Podstawowe twierdzenie statystyki matematycznej - ilustracja



Dystrybuanta empiryczna

Podstawowe twierdzenie - ilustracja $n = 10$

Próba: 9, 10, 13, 9, 10, 11, 5, 5, 12, 9



$$F_{10}(t) = \frac{\#\{1 \leq j \leq 10 : X_j \leq t\}}{10} = \begin{cases} 0, & t < 5, \\ 2/10, & t < 9, \\ 5/10, & t < 10, \\ 7/10, & t < 11, \\ 8/10, & t < 12, \\ 9/10, & t < 12, \\ 1, & t \geq 13, \end{cases}$$

Dystrybuanta empiryczna

Podstawowe twierdzenie - ilustracja $n = 10$

Dystrybuanta empiryczna

Podstawowe twierdzenie - ilustracja $n = 10$



Dystrybuanta empiryczna

Podstawowe twierdzenie - ilustracja $n = 10$



Dystrybuanta empiryczna

Podstawowe twierdzenie - ilustracja $n = 100$

Dystrybuanta empiryczna

Podstawowe twierdzenie - ilustracja $n = 1000$

Statystyka



Określenie

odwzorowanie $T : (\mathcal{X}, \{P_\theta, \theta \in \Theta\}) \rightarrow \mathbb{R}^k$

Statystyka jest zmienną losową!

Estymator

Statystykę taką, że $T(\mathcal{X}) = \Theta$ nazywamy estymatorem parametru θ

Oznaczenie: $\hat{\theta}$

Funkcja straty


Określenie

Funkcja

$$L : \Theta \times \Theta \rightarrow \mathbb{R}_+$$

taka, że

$$(\forall \theta \in \Theta) \quad L(\theta, \theta) = 0$$



Zadanie

Znaleźć taki estymator $\hat{\theta}$, który „minimalizuje” stratę $L(\hat{\theta}(x), \theta)$ dla wszystkich $\theta \in \Theta$

Typowo: minimalizacja $E_{\theta}L(\hat{\theta}(X), \theta)$

Kwadratowa funkcja straty

Określenie

Funkcja

$$\Theta \times \Theta \ni (\vartheta, \theta) \rightarrow L(\vartheta, \theta) = (\vartheta - \theta)^2 \in \mathbb{R}_+$$

Błąd średniokwadratowy estymatora $\hat{\theta}$

$$\begin{aligned} R_{\theta}(\hat{\theta}) &= E_{\theta}(\hat{\theta}(X) - \theta)^2 \\ &= E_{\theta}(\hat{\theta}(X) - E_{\theta}\hat{\theta}(X))^2 + (E_{\theta}\hat{\theta}(X) - \theta)^2 \\ &= D_{\theta}^2\hat{\theta}(X) + (E_{\theta}\hat{\theta}(X) - \theta)^2 \end{aligned}$$

Estymator nieobciążony

Określenie

$$E_{\theta}\hat{\theta} = \theta \quad (\forall \theta \in \Theta)$$

Błąd średniokwadratowy estymatora $\hat{\theta}$

Jeżeli $E_{\theta}\hat{\theta} = \theta$ ($\forall \theta \in \Theta$), to

$$R_{\theta}(\hat{\theta}) = D_{\theta}^2\hat{\theta}$$

Dostateczność

Określenie

Statystyka T jest dostateczna, jeżeli rozkład warunkowy $P_\theta\{\cdot|T = t\}$ nie jest zależny od θ dla wszystkich $\theta \in \Theta$.

Dostateczność

Przykład

$$(\{0, 1\}, \{D(\theta), \theta \in [0, 1]\})$$

Wnioskujemy o parametrze θ na podstawie próby X_1, X_2, \dots, X_5 .

Próba 1: $X_1 = 1, X_2 = 1, X_3 = 1, X_4 = 0, X_5 = 0$

Próba 2: $X_1 = 1, X_2 = 0, X_3 = 1, X_4 = 0, X_5 = 1$

Próba 3: $X_1 = 0, X_2 = 1, X_3 = 0, X_4 = 1, X_5 = 1$

Dostateczność

Przykład cd

Prawdopodobieństwa realizacji poszczególnych prób:

$$P_\theta\{\text{Próba 1}\} = \theta^3(1 - \theta)^2$$

$$P_\theta\{\text{Próba 2}\} = \theta^3(1 - \theta)^2$$

$$P_\theta\{\text{Próba 3}\} = \theta^3(1 - \theta)^2$$

Dostateczność

Przykład cd

Istotna informacja: $X_1 + X_2 + X_3 + X_4 + X_5$ (ozn T)

$$\begin{aligned} &P_\theta\{X_1 = x_1, X_2 = x_2, X_3 = x_3, X_4 = x_4, X_5 = x_5 | T = t\} \\ &= \begin{cases} 1/\binom{5}{t}, & \text{jeżeli } x_1 + x_2 + x_3 + x_4 + x_5 = t, \\ 0, & \text{w przeciwnym przypadku.} \end{cases} \end{aligned}$$

$T = \sum_{i=1}^5 X_i$ jest **dostateczna** dla wnioskowania o θ

Dostateczność

Twierdzenie o faktoryzacji

Statystyka T jest dostateczna dla rodziny rozkładów $\{P_\theta : \theta \in \Theta\}$ wtedy i tylko wtedy, gdy gęstość $p_\theta(x)$ może być przedstawiona w postaci

$$p_\theta(x) = g_\theta\{T(x)\}h(x),$$

gdzie funkcja h nie zależy od θ .

Dostateczność

Minimalna statystyka dostateczna

Statystykę dostateczną T nazywamy minimalną statystyką dostateczną, jeżeli dla każdej statystyki dostatecznej S istnieje funkcja h taka, że $T = h(S)$

Zupełność

Statystyka T jest zupełna, jeżeli dla wszystkich $\theta \in \Theta$ zachodzi $E_\theta h(T) = 0$, to $h \equiv 0$

Rodziny wykładnicze

Określenie

Rodzina rozkładów prawdopodobieństwa $\{P_\theta : \theta \in \Theta\}$ nazywa się rodziną wykładniczą, jeżeli każdy rozkład P_θ ma gęstość p_θ o postaci

$$p_\theta(x) = \exp \left\{ \sum_{j=1}^k c_j(\theta) T_j(x) - b(\theta) \right\} \cdot h(x),$$

gdzie $T_1(x), T_2(x), \dots, T_k(x)$ są liniowo niezależnymi funkcjami oraz $\{(c_1(\theta), c_2(\theta), \dots, c_k(\theta)) : \theta \in \Theta\}$ jest pewnym k -wymiarowym zbiorem w \mathbb{R}^k .

Rodziny wykładnicze

Twierdzenie

Jeżeli $\{P_\theta : \theta \in \Theta\}$ oraz $\Theta \subset \mathbb{R}^k$ jest rodziną wykładniczą rozkładów z gęstościami

$$p_\theta(x) = \exp \left\{ \sum_{j=1}^k c_j(\theta) T_j(x) - b(\theta) \right\} \cdot h(x),$$

to $(T_1(x), T_2(x), \dots, T_k(x))$ jest (k -wymiarową) minimalną statystyką dostateczną zupełną.

2 ENMW

2.1 Określenie

Estymatory nieobciążone o minimalnej wariancji

Problem

Model statystyczny $(\mathcal{X}, \mathcal{B}, \{P_\theta, \theta \in \Theta\})$

Niech $g : \Theta \rightarrow \mathbb{R}^1$ będzie znaną funkcją

Zadanie: oszacować nieznaną wartość $g(\theta)$

Estymatory nieobciążone o minimalnej wariancji

Estymator wielkości $g(\theta)$

Wybrać takie $\delta(X_1, X_2, \dots, X_n)$ by $(\forall \theta \in \Theta)$

$$E_\theta \delta(X_1, X_2, \dots, X_n) = g(\theta)$$

$$D_\theta^2(\delta) = E_\theta (\delta(X_1, X_2, \dots, X_n) - g(\theta))^2 = \min$$

2.2 Twierdzenie Rao-Blackwella

Estymatory nieobciążone o minimalnej wariancji

Twierdzenie (Rao-Blackwella)

Jeżeli \hat{g} jest estymatorem nieobciążonym i jeżeli T jest statystyką dostateczną zupełną, to $E_\theta(\hat{g}|T)$ jest również estymatorem nieobciążonym o jednostajnie nie większej wariancji niż wariancja estymatora \hat{g} .

Estymatory nieobciążone o minimalnej wariancji

Twierdzenie

Jeżeli T jest statystyką dostateczną zupełną i jeżeli dla danej funkcji g istnieje funkcja \hat{g} taka, że

$$(\forall \theta \in \Theta) E_\theta \hat{g}(T) = g(\theta),$$

to $\hat{g}(T)$ jest $ENMW[g(\theta)]$.

2.3 Model dwupunktowy

Estymatory nieobciążone o minimalnej wariancji - przykład

Model dwupunktowy: estymacja parametru θ

Model pojedynczej obserwacji X :

$$(\{0, 1\}, \{D(\theta), \theta \in [0, 1]\})$$

Rodzina $\{D(\theta), \theta \in [0, 1]\}$ jest rodziną wykładniczą:

$$\begin{aligned} p_\theta(x) &= \theta^x(1 - \theta)^{1-x} \\ &= \exp \left\{ x \log \frac{\theta}{1 - \theta} + \log(1 - \theta) \right\}, \quad x = 0, 1 \end{aligned}$$

Statystyka dostateczna: $T(x) = x$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model dwupunktowy: estymacja parametru θ

Model dla próby X_1, X_2, \dots, X_n :

$$\begin{aligned} &(\{0, 1\}, \{D(\theta), \theta \in [0, 1]\})^n \\ p_\theta(x_1, \dots, x_n) &= \prod_{i=1}^n \theta^{x_i}(1 - \theta)^{1-x_i} \\ &= \exp \left\{ \log \frac{\theta}{1 - \theta} \sum_{i=1}^n x_i + \log(1 - \theta) \right\} \end{aligned}$$

Statystyka dostateczna: $T = \sum X_i$.

Estymatory nieobciążone o minimalnej wariancji - przykład

Model dwupunktowy: estymacja parametru θ

Model dla statystyki T

$$(\{0, 1, \dots, n\}, \{Bin(n, \theta), \theta \in [0, 1]\})$$

Funkcja g : $g(\theta) = \theta$

Ponieważ

$$E_\theta T = n\theta,$$

więc

$$ENMW[\theta] = \frac{T}{n}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model dwupunktowy: estymacja wariancji $\theta(1 - \theta)$

Funkcja g : $g(\theta) = \theta(1 - \theta)$

Wyznaczyć \hat{g} taką, że $\forall \theta \in \Theta$

$$E_{\theta} \hat{g}(T) = \theta(1 - \theta)$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model dwupunktowy: estymacja wariancji $\theta(1 - \theta)$

$$\begin{aligned} E_{\theta} \hat{g}(T) &= \sum_{t=0}^n \hat{g}(t) \binom{n}{t} \theta^t (1 - \theta)^{n-t} = \theta(1 - \theta) \\ (1 - \theta)^n \sum_{t=0}^n \hat{g}(t) \binom{n}{t} \left(\frac{\theta}{1 - \theta}\right)^t &= \theta(1 - \theta) \\ \sum_{t=0}^n \hat{g}(t) \binom{n}{t} \left(\frac{\theta}{1 - \theta}\right)^t &= \left(\frac{\theta}{1 - \theta}\right) \left(1 + \left(\frac{\theta}{1 - \theta}\right)\right)^{n-2} \end{aligned}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model dwupunktowy: estymacja wariancji $\theta(1 - \theta)$

Podstawienie: $v = \theta/(1 - \theta)$

$$\begin{aligned} \sum_{t=0}^n \hat{g}(t) \binom{n}{t} v^t &= v (1 + v)^{n-2} \\ \sum_{t=0}^n \hat{g}(t) \binom{n}{t} v^t &= \sum_{t=0}^{n-2} \binom{n-2}{t} v^{t+1} \\ ENMW[\theta(1 - \theta)] &= \frac{T(n - T)}{n(n - 1)} \end{aligned}$$

2.4 Model Poissona

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: estymacja $P_\theta\{X = 0\} = e^{-\theta}$

Model pojedynczej obserwacji X :

$$(\{0, 1, 2, \dots\}, \{Po(\theta), \theta \in \mathbb{R}_+\})$$

Rodzina $\{Po(\theta), \theta \in \mathbb{R}_+\}$ jest rodziną wykładniczą:

$$\begin{aligned} p_\theta(x) &= \frac{\theta^x}{x!} e^{-\theta} \\ &= \exp\{x \log \theta - \theta\} \frac{1}{x!}, \quad x = 0, 1, 2, \dots \end{aligned}$$

Statystyka dostateczna: $T(x) = x$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: estymacja $P_\theta\{X = 0\} = e^{-\theta}$

Model dla próby X_1, X_2, \dots, X_n :

$$\begin{aligned} &(\{0, 1, 2, \dots\}, \{Po(\theta), \theta \in \mathbb{R}_+\})^n \\ p_\theta(x_1, \dots, x_n) &= \prod_{i=1}^n \frac{\theta^{x_i}}{x_i!} e^{-\theta} \\ &= \exp\left\{\log \theta \sum_{i=1}^n x_i - n\theta\right\} \frac{1}{\prod x_i!} \end{aligned}$$

Statystyka dostateczna: $T = \sum X_i$.

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: estymacja $P_\theta\{X = 0\} = e^{-\theta}$

Model dla statystyki T

$$(\{0, 1, 2, \dots\}, \{Po(n\theta), \theta \in \mathbb{R}_+\})$$

Funkcja g : $g(\theta) = e^{-\theta} \stackrel{\text{ozn}}{=} \lambda$

- estymator nieobciążony λ^*
- $\hat{\lambda} = E(\lambda^*|T)$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: estymacja $P_\theta\{X = 0\} = e^{-\theta}$

$$Y_j = \begin{cases} 1, & \text{jeżeli } X_j = 0, \\ 0, & \text{jeżeli } X_j > 0. \end{cases}$$

$$\lambda^* = \frac{1}{n} \sum_{j=1}^n Y_j$$

Estymator λ^* jest nieobciążony

$$E_\theta Y_j = 1 \cdot P_\theta\{X = 0\} + 0 \cdot P_\theta\{X > 0\} = e^{-\theta}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: estymacja $P_\theta\{X = 0\} = e^{-\theta}$

Wyznaczamy $\hat{\lambda} = E_\theta(\lambda^*|T)$

$$\begin{aligned} E_\theta(\lambda^*|T = t) &= E_\theta\left(\frac{1}{n} \sum_{j=1}^n Y_j | T = t\right) \\ &= E_\theta(Y_1 | T = t) = P_\theta\{X_1 = 0 | T = t\} \\ &= \sum_{x_2 + \dots + x_n = t} P_\theta\{X_1 = 0, X_2 = x_2, \dots, X_n = x_n | T = t\} \\ &\quad \underline{\text{ozn}} \heartsuit \end{aligned}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: estymacja $P_\theta\{X = 0\} = e^{-\theta}$

$$\begin{aligned} &P_\theta\{X_1 = x_1, X_2 = x_2, \dots, X_n = x_n | T = t\} \\ &= \frac{P_\theta\{X_1 = x_1, X_2 = x_2, \dots, X_n = x_n, T = t\}}{P_\theta\{T = t\}} \\ &= \begin{cases} 0, & \text{jeżeli } \sum x_i \neq t \\ \frac{\theta^{x_1 + \dots + x_n} e^{-n\theta}}{x_1! \dots x_n!} \cdot \frac{t!}{(n\theta)^t e^{-n\theta}}, & \text{jeżeli } \sum x_i = t \end{cases} \\ &= \begin{cases} 0, & \text{jeżeli } \sum x_i \neq t \\ \frac{t!}{n^t x_1! \dots x_n!}, & \text{jeżeli } \sum x_i = t \end{cases} \end{aligned}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: estymacja $P_\theta\{X = 0\} = e^{-\theta}$

Ponieważ

$$(\alpha_1 + \dots + \alpha_n)^t = \sum_{x_1 + \dots + x_n = t} \frac{t!}{x_1! \dots x_n!} \alpha_1^{x_1} \dots \alpha_n^{x_n}$$

więc

$$\sum_{x_1 + \dots + x_n = t} \frac{t!}{x_1! \dots x_n!} = n^t$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: estymacja $P_\theta\{X = 0\} = e^{-\theta}$

Zatem

$$\heartsuit = \sum_{x_2 + \dots + x_n = t} \frac{t!}{n^t x_2! \dots x_n!} = \frac{(n-1)^t}{n^t}$$

Czyli

$$\hat{\lambda} = \left(1 - \frac{1}{n}\right)^T$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: $D_\lambda^2 \hat{\lambda}$ vs $D_\lambda^2 \lambda^*$

$$D_\lambda^2 \hat{\lambda} = E_\lambda \hat{\lambda}^2 - \lambda^2$$

$$\begin{aligned} E_\theta \hat{\lambda}^2 &= \sum_{t=0}^{\infty} \left[\left(1 - \frac{1}{n}\right)^t \right]^2 \frac{(n\theta)^t}{t!} e^{-n\theta} = e^{-n\theta} \sum_{t=0}^{\infty} \frac{\left[\frac{(n-1)^2}{n} \theta\right]^t}{t!} \\ &= e^{-n\theta} e^{\frac{(n-1)^2}{n} \theta} = e^{-(2 + \frac{1}{n})\theta} \end{aligned}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: $D_\lambda^2 \hat{\lambda}$


$$D_\lambda^2 \hat{\lambda} = \lambda^{(2 - \frac{1}{n})} - \lambda^2$$

Model Poissona: $D_\lambda^2 \lambda^*$

$$D_\lambda^2 \lambda^* = \frac{\lambda(1 - \lambda)}{n}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: $D_{\lambda}^2 \hat{\lambda}$ vs $D_{\lambda}^2 \lambda^*$



Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: estymacja $P_{\theta}\{X = 0\} = e^{-\theta}$

Niech $\varepsilon > 0$

$$P_{\lambda}\{|\lambda^* - \lambda| < \varepsilon\} = ? \quad P_{\lambda}\{|\hat{\lambda} - \lambda| < \varepsilon\} = ?$$

$$\lambda^* = \frac{1}{n} \sum_{i=1}^n Y_i; \quad \sum_{i=1}^n Y_i \sim \text{Bin}(n, \lambda = e^{-\theta})$$

$$\hat{\lambda} = \left(1 - \frac{1}{n}\right)^T; \quad T = \sum_{i=1}^n X_i \sim \text{Po}(n\theta = -n \log \lambda)$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model Poissona: estymacja $P_{\theta}\{X = 0\} = e^{-\theta}$ ($\varepsilon = 0.05; n = 50$)

λ	$P_\lambda\{ \lambda^* - \lambda < \varepsilon\}$	$P_\lambda\{ \hat{\lambda} - \lambda < \varepsilon\}$
0.1	0.7661	0.9793
0.2	0.6235	0.8358
0.3	0.5593	0.7275
0.4	0.5291	0.6256
0.5	0.5201	0.6052
0.6	0.5291	0.5719
0.7	0.5593	0.5912
0.8	0.6235	0.6240
0.9	0.7661	0.8092

2.5 Model gaussowski

Estymatory nieobciążone o minimalnej wariancji - przykład

Model gaussowski: estymacja parametrów

Model pojedynczej obserwacji X :

$$(\mathbb{R}, \{N(\mu, \sigma^2), \theta = (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}_+\})$$

Rodzina $\{N(\mu, \sigma^2), \theta = (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}_+\}$ jest wykładnicza

Estymatory nieobciążone o minimalnej wariancji - przykład

Model gaussowski: estymacja parametrów

$$\begin{aligned} f_{\mu, \sigma}(x) &= \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\} \\ &= \exp\left\{-\frac{1}{2\sigma^2}x^2 + \frac{\mu}{\sigma^2}x - \left(\frac{\mu^2}{2\sigma^2} + \log(\sigma\sqrt{2\pi})\right)\right\} \end{aligned}$$

Statystyka dostateczna: $(T_1(x), T_2(x)) = (x, x^2)$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model gaussowski: estymacja parametrów

Model dla próby X_1, X_2, \dots, X_n :

$$\begin{aligned} &(\mathbb{R}, \{N(\mu, \sigma^2), \theta = (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}_+\})^n = \\ &(\mathbb{R}^n, \{N_n(\mu\mathbf{1}_n, \sigma^2\mathbf{I}_n), \theta = (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}_+\}) \end{aligned}$$

Statystyka dostateczna: $(T_1, T_2) = (\sum X_i, \sum X_i^2)$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model gaussowski: estymacja parametrów

Niech

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

$$S^2 = \begin{cases} \sum_{i=1}^n (X_i - \mu)^2, & \mu \text{ jest znane,} \\ \sum_{i=1}^n (X_i - \bar{X})^2, & \mu \text{ nie jest znane.} \end{cases}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model gaussowski: estymacja parametrów

Zmienna losowa \bar{X} ma rozkład $N\left(\mu, \frac{\sigma^2}{n}\right)$

Zmienna losowa S^2/σ^2 ma rozkład chi-kwadrat z ν stopniami swobody:

$$\nu = \begin{cases} n, & \mu \text{ jest znane,} \\ n - 1, & \mu \text{ nie jest znane.} \end{cases}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model gaussowski: estymacja parametrów

$$E_{\mu,\sigma} S^\alpha = \begin{cases} \frac{\sigma^\alpha}{K_{\nu,\alpha}}, & \nu + \alpha > 0, \\ \infty, & \nu + \alpha \leq 0, \end{cases}$$

gdzie $K_{\nu,\alpha} = \Gamma\left(\frac{\nu}{2}\right) / \left(2^{\frac{\alpha}{2}} \Gamma\left(\frac{\nu+\alpha}{2}\right)\right)$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model gaussowski: estymacja parametrów

Jeżeli μ oraz σ nie są znane, to

- $ENMW[\mu] = \bar{X}$
- $ENMW[\sigma^2] = \frac{1}{n-1} S^2$

- $ENMW[\sigma] = \frac{\Gamma(\frac{n-1}{2})}{\sqrt{2}\Gamma(\frac{n}{2})}S$
- $ENMW\left[\frac{\mu}{\sigma}\right] = \frac{\sqrt{2}\Gamma(\frac{n-1}{2})}{\Gamma(\frac{n}{2}-1)}\frac{\bar{X}}{S}$

2.6 Nierówność Cramera-Rao

Estymatory nieobciążone o minimalnej wariancji

Informacja

Ilością informacji o θ zawartą w X nazywamy wielkość $I_\theta = E_\theta[\{\partial \log p_\theta(X)/\partial \theta\}^2]$

Estymatory nieobciążone o minimalnej wariancji

Nierówność Cramera-Rao

Niech $\{P_\theta : \theta \in \Theta\}$ będzie rodziną rozkładów, niech θ będzie parametrem liczbowym i niech Θ będzie przedziałem na prostej. Zakładamy, że dla każdego θ rozkład P_θ ma gęstość p_θ . Jeżeli spełnione są pewne warunki regularności, to nierówność

$$D_\theta^2 \theta^* \geq I_\theta^{-1}$$

spełniona jest dla każdego estymatora nieobciążonego θ^* parametru θ

Estymatory nieobciążone o minimalnej wariancji

Efektywność

Liczbę

$$\text{eff}(\theta^*) = \frac{I_\theta^{-1}}{D_\theta^2 \theta^*}$$

nazywamy *efektywnością* estymatora θ^*

Lemat

Jeżeli spełnione są warunki regularności, to

$$I_\theta = E_\theta \left[-\frac{\partial^2}{\partial \theta^2} \log p_\theta(X) \right]$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model gaussowski

Obliczamy I_μ

$$p_\mu(\mathbf{x}) = \left(\frac{1}{\sigma\sqrt{2\pi}} \right)^n \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \mu)^2 \right\}$$

$$\log p_\mu(\mathbf{x}) = -n \log(\sigma\sqrt{2\pi}) - \frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \mu)^2$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Model gaussowski

$$\frac{\partial}{\partial \mu} \log p_\mu(\mathbf{x}) = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \mu)$$

$$\frac{\partial^2}{\partial \mu^2} \log p_\mu(\mathbf{x}) = -\frac{n}{\sigma^2}$$

Zatem

$$I_\mu = \frac{n}{\sigma^2}$$

Ponieważ $D^2 \bar{X} = \sigma^2/n$, więc

$$\text{eff}(\bar{X}) = 1$$

2.7 Antyprzykłady

Estymatory nieobciążone o minimalnej wariancji - przykład

Zły estymator - ucięty rozkład Poissona

Model pojedynczej obserwacji X :

$$(\{1, 2, \dots\}, \{P_\theta : \theta > 0\})$$

$$P_\theta\{X = x\} = \frac{\theta^x e^{-\theta}}{x!(1 - e^{-\theta})}$$

Zadanie: oszacować $e^{-\theta}$ na podstawie jednej obserwacji

Estymatory nieobciążone o minimalnej wariancji - przykład

Zły estymator - ucięty rozkład Poissona

$T(X)$ jest ENMW $[e^{-\theta}]$, jeżeli

$$\sum_{x=1}^{\infty} T(x) \frac{\theta^x e^{-\theta}}{x!(1 - e^{-\theta})} = e^{-\theta}$$

Rozwiązanie:

$$T(x) = (-1)^{x+1}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Nie istnieje ENMW

Model pojedynczej obserwacji X :

$$(\mathbb{Z}, \{P_{\theta} : \theta \in \mathbb{Z}\})$$

$$P_{\theta}\{X = \theta - 1\} = P_{\theta}\{X = \theta\} = P_{\theta}\{X = \theta + 1\} = \frac{1}{3}$$

Estymator nieobciążony: $\hat{\theta}(X) = X$

Wariancja: $D^2\hat{\theta} = 2/3$

Estymatory nieobciążone o minimalnej wariancji - przykład

Nie istnieje ENMW

Niech $a_0 + a_1 + a_2 = 0$ oraz

$$\delta(x) = \begin{cases} a_0, & \text{mod}(x; 3) = 0 \\ a_1, & \text{mod}(x; 3) = 1 \\ a_2, & \text{mod}(x; 3) = 2 \end{cases}$$

Niech $\theta^*(X) = X + \delta(X)$

Estymatory nieobciążone o minimalnej wariancji - przykład

Nie istnieje ENMW

$$E_{\theta}\theta^* = \theta \quad (\forall \theta \in \Theta)$$

$$D_{\theta}^2\theta^* = \begin{cases} ((a_2 - 1)^2 + a_0^2 + (a_1 + 1)^2)/3, & \text{mod}(\theta; 3) = 0 \\ ((a_0 - 1)^2 + a_1^2 + (a_2 + 1)^2)/3, & \text{mod}(\theta; 3) = 1 \\ ((a_1 - 1)^2 + a_2^2 + (a_0 + 1)^2)/3, & \text{mod}(\theta; 3) = 2 \end{cases}$$

Estymatory nieobciążone o minimalnej wariancji - przykład

Nie istnieje ENMW

θ	$D_{\theta}^2 \hat{\theta} = 2/3$	$D_{\theta}^2 \theta^*$
0	0.6667	2.1667
1	0.6667	0.1667
2	0.6667	1.1667
3	0.6667	2.1667
4	0.6667	0.1667
5	0.6667	1.1667

3 ENW

3.1 Przykład wstępny

ENW: przykład wstępny

Wykonano 50 rzutów nieznaną monetą i otrzymano 32 orły.

Jakie jest prawdopodobieństwo wyrzucenia orła w pojedynczym rzucie?

ENW: przykład wstępny

Model statystyczny rzutów monetą


$$(\{0, 1, \dots, 50\}, \{Bin(50, \theta), \theta \in [0, 1]\})$$

Prawdopodobieństwo uzyskania 32 orłów w 50 rzutach

$$p_{\theta}(32) = \binom{50}{32} \theta^{32} (1 - \theta)^{50-32}$$

Dla jakiego θ uzyskanie 32 orłów jest najbardziej prawdopodobne?

ENW: przykład wstępny



ENW: przykład wstępny

Zasada wiarygodności

Wybrać tę wartość parametru θ , dla której uzyskanie 32 orłów w 50 rzutach jest najbardziej prawdopodobne
 tzn. wartość θ maksymalizującą $p_\theta(32)$

3.2 Określenie

Estymatory największej wiarygodności

Wiarygodność

Model statystyczny $(\mathcal{X}, \mathcal{B}, \{P_\theta, \theta \in \Theta\})$

Dla ustalonego $x \in \mathcal{X}$ wielkość

$$L(\theta; x) = p_\theta(x)$$

nazywamy wiarygodnością parametru θ .

Estymatory największej wiarygodności

Estymator Największej Wiarygodności

Jeżeli przy każdym ustalonym $x \in \mathcal{X}$ istnieje $\hat{\theta} = \hat{\theta}(x) \in \Theta$ takie, że

$$L(\hat{\theta}; x) \geq L(\theta; x) \quad (\forall \theta \in \Theta),$$

to odwzorowanie $\hat{\theta} : \mathcal{X} \rightarrow \Theta$ nazywamy estymatorem największej wiarygodności.

Estymatory największej wiarygodności

Twierdzenie

Jeżeli $h : \Theta \rightarrow \Theta$ jest funkcją różnowartościową oraz $\hat{\theta}$ jest $ENW[\theta]$, to $h(\hat{\theta})$ jest $ENW[h(\theta)]$.

ENW funkcji parametrycznej

Jeżeli $h : \Theta \rightarrow \Theta$, to $ENW[h(\theta)]$ określamy jako $h(\hat{\theta})$, gdzie $\hat{\theta}$ jest $ENW[\theta]$.

3.3 Model dwupunktowy

Estymator Największej Wiarygodności - przykład

Model dwupunktowy: $ENW[\theta]$

Zaobserwowano $X_1 = x_1, \dots, X_n = x_n$.

Wiarygodność parametru θ :

$$L(\theta; x_1, \dots, x_n) = \binom{n}{t} \theta^t (1 - \theta)^{n-t} \quad \left(t = \sum_{i=1}^n x_i \right)$$

Znaleźć $\hat{\theta}$ maksymalizujące wiarygodność (t jest ustalone)

Estymator Największej Wiarygodności - przykład

Model dwupunktowy: $ENW[\theta]$

$\hat{\theta}$ jest rozwiązaniem równania

$$\frac{dL(\theta; x_1, \dots, x_n)}{d\theta} = 0$$

Estymator Największej Wiarygodności - przykład

Model dwupunktowy: $ENW[\theta]$

Zamiast $L(\theta; x_1, \dots, x_n) = \binom{n}{t} \theta^t (1 - \theta)^{n-t}$ łatwiej

$$\begin{aligned} \mathcal{L}(\theta; x_1, \dots, x_n) &= \log L(\theta; x_1, \dots, x_n) \\ &= \log \binom{n}{t} + t \log \theta + (n - t) \log(1 - \theta) \end{aligned}$$

Estymator Największej Wiarygodności - przykład

Model dwupunktowy: $ENW[\theta]$

Mamy

$$\frac{d\mathcal{L}}{d\theta} = \frac{t}{\theta} - \frac{n-t}{1-\theta} = 0$$
$$ENW[\theta] = \frac{T}{n}$$

Estymator Największej Wiarygodności - przykład

Model dwupunktowy: $ENW[\theta(1-\theta)]$

$$ENW[\theta(1-\theta)] = \hat{\theta}(1-\hat{\theta})$$

gdzie

$$\hat{\theta} = ENW[\theta]$$

3.4 Model Poissona

Estymator Największej Wiarygodności - przykład

Model Poissona: $ENW[\theta]$

Zaobserwowano $X_1 = x_1, \dots, X_n = x_n$.

Wiarygodność parametru θ :

$$L(\theta; x_1, \dots, x_n) = \frac{(n\theta)^t}{x_1! \cdots x_n!} e^{-(n\theta)} \quad \left(t = \sum_{i=1}^n x_i \right)$$

Znaleźć $\hat{\theta}$ maksymalizujące wiarygodność (t jest ustalone)

Estymator Największej Wiarygodności - przykład

Model Poissona: $ENW[\theta]$

$\hat{\theta}$ jest rozwiązaniem równania

$$\frac{dL(\theta; x_1, \dots, x_n)}{d\theta} = 0$$

Estymator Największej Wiarygodności - przykład

Model Poissona: $ENW[\theta]$

Zamiast $L(\theta; x_1, \dots, x_n) = \frac{(n\theta)^t}{x_1! \dots x_n!} e^{-(n\theta)}$ łatwiej

$$\begin{aligned}\mathcal{L}(\theta; x_1, \dots, x_n) &= \log L(\theta; x_1, \dots, x_n) \\ &= t \log n + t \log \theta - \sum_{i=1}^n \log(x_i!) - n\theta\end{aligned}$$

Estymator Największej Wiarygodności - przykład

Model Poissona: $ENW[\theta]$

Mamy

$$\begin{aligned}\frac{d\mathcal{L}}{d\theta} &= \frac{t}{\theta} - n = 0 \\ ENW[\theta] &= \frac{T}{n}\end{aligned}$$

Estymator Największej Wiarygodności - przykład

Model Poissona: $ENW[\lambda = e^{-\theta}]$

$$ENW[\lambda] = e^{-\tilde{\theta}} \left(\stackrel{\text{ozn}}{=} \tilde{\lambda} \right)$$

gdzie

$$\tilde{\theta} = ENW[\theta]$$

Estymator Największej Wiarygodności - przykład

Model Poissona: $ENW[\lambda]$ vs $ENMW[\lambda]$

Ryzyko $\tilde{\lambda} = ENW[\lambda]$

$$R_{\tilde{\lambda}}(\lambda) = E_{\theta}(\tilde{\lambda} - \lambda)^2 = E_{\theta}\tilde{\lambda}^2 - 2\lambda E_{\theta}\tilde{\lambda} + \lambda^2$$

Ryzyko $\hat{\lambda} = ENMW[\lambda]$

$$R_{\hat{\lambda}}(\lambda) = E_{\theta}(\hat{\lambda} - \lambda)^2 = D_{\theta}^2 \hat{\lambda}^2$$

Estymator Największej Wiarygodności - przykład

Model Poissona: $R_{\tilde{\lambda}}(\lambda)$

$$E_{\theta} \tilde{\lambda}^2 = \sum_{t=0}^{\infty} \left(e^{-\frac{t}{n}} \right)^2 \frac{(n\theta)^t}{t!} e^{-n\theta} = e^{-n\theta} \sum_{t=0}^{\infty} \frac{(n\theta e^{-\frac{2}{n}})^t}{t!}$$

$$= \exp \left\{ -n\theta \left(1 - e^{-\frac{2}{n}} \right) \right\} = \lambda^{n(1-e^{-\frac{2}{n}})}$$

$$E_{\theta} \tilde{\lambda} = \sum_{t=0}^{\infty} e^{-\frac{t}{n}} \frac{(n\theta)^t}{t!} e^{-n\theta} = e^{-n\theta} \sum_{t=0}^{\infty} \frac{(n\theta e^{-\frac{1}{n}})^t}{t!}$$

$$= \exp \left\{ -n\theta \left(1 - e^{-\frac{1}{n}} \right) \right\} = \lambda^{n(1-e^{-\frac{1}{n}})}$$

Estymator Największej Wiarygodności - przykład

Model Poissona: $R_{\tilde{\lambda}}(\lambda)$


$$R_{\tilde{\lambda}}(\lambda) = \lambda^{n(1-e^{-\frac{2}{n}})} - 2\lambda^{1+n(1-e^{-\frac{1}{n}})} + \lambda^2$$

Model Poissona: $R_{\hat{\lambda}}(\lambda)$

$$R_{\hat{\lambda}}(\lambda) = D_{\lambda}^2 \hat{\lambda} = \lambda^{(2-\frac{1}{n})} - \lambda^2$$

Estymator Największej Wiarygodności - przykład

Model Poissona: $R_{\tilde{\lambda}}(\lambda)$ vs $R_{\hat{\lambda}}(\lambda)$



3.5 Model gaussowski

Estymator Największej Wiarygodności - przykład

Model gaussowski: $ENW[\mu]$ i $ENW[\sigma^2]$

Zaobserwowano $X_1 = x_1, \dots, X_n = x_n$.

Wiarygodność parametru (μ, σ^2) :

$$L(\mu, \sigma^2; x_1, \dots, x_n) = \left(\frac{1}{\sigma\sqrt{2\pi}} \right)^n \exp \left\{ -\frac{1}{2} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma} \right)^2 \right\}$$

Znaleźć $\hat{\mu}$ i $\hat{\sigma}^2$ maksymalizujące wiarygodność

Estymator Największej Wiarygodności - przykład

Model gaussowski: $ENW[\mu]$ i $ENW[\sigma^2]$

$(\hat{\mu}, \hat{\sigma}^2)$ jest rozwiązaniem równania

$$\begin{cases} \frac{\partial L(\mu, \sigma^2; x_1, \dots, x_n)}{\partial \mu} = 0 \\ \frac{\partial L(\mu, \sigma^2; x_1, \dots, x_n)}{\partial \sigma^2} = 0 \end{cases}$$

Estymator Największej Wiarygodności - przykład

Model gaussowski: $ENW[\mu]$ i $ENW[\sigma^2]$

Zamiast $L(\theta; x_1, \dots, x_n)$ łatwiej

$$\begin{aligned} \mathcal{L}(\mu, \sigma^2; x_1, \dots, x_n) &= \log L(\mu, \sigma^2; x_1, \dots, x_n) \\ &= -n \log \sqrt{2\pi} - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \end{aligned}$$

Estymator Największej Wiarygodności - przykład

Model gaussowski: $ENW[\mu]$ i $ENW[\sigma^2]$

Mamy

$$\begin{cases} \frac{\partial \mathcal{L}}{\partial \mu} = -\frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0 \\ \frac{\partial \mathcal{L}}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 = 0 \end{cases}$$

Estymator Największej Wiarygodności - przykład

Model gaussowski: $ENW[\mu]$ i $ENW[\sigma^2]$

Otrzymujemy

$$ENW[\mu] = \bar{X}$$
$$ENW[\sigma^2] = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

Estymator Największej Wiarygodności - przykład

Model gaussowski: estymacja wariancji

Niech $c > 0$ oraz

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

Ryzyko estymatora $S^2(c)$:

$$R_{\mu, \sigma^2} \left(c \sum_{i=1}^n (X_i - \bar{X})^2 \right)$$

Dla jakiego c ryzyko jest jednostajnie najmniejsze?

Estymator Największej Wiarygodności - przykład

Model gaussowski: estymacja wariancji

$$R_{\mu, \sigma^2} \left(c \sum_{i=1}^n (X_i - \bar{X})^2 \right)$$
$$= E_{\mu, \sigma^2} \left[c \sum_{i=1}^n (X_i - \bar{X})^2 - \sigma^2 \right]^2$$
$$= \sigma^4 [c^2(n^2 - 1) - 2c(n - 1) + 1]$$

Estymator Największej Wiarygodności - przykład

Model gaussowski: estymacja wariancji

$$R_{\mu, \sigma^2}(ENMW[\sigma^2]) = \frac{2}{n-1} \sigma^4$$

$$R_{\mu, \sigma^2}(ENW[\sigma^2]) = \frac{2n-1}{n^2} \sigma^4$$

Estymator o jednostajnie najmniejszym ryzyku

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

3.6 Asymptotyka

Estymator Największej Wiarygodności

Twierdzenie

Niech $p_\theta(x)$ spełniają pewne warunki regularności.

Jeżeli X_1, \dots, X_n są niezależnymi zmiennymi losowymi o tym samym rozkładzie o gęstości $p_\theta(x)$, to równanie wiarygodności

$$\frac{\partial}{\partial \theta} [p_\theta(x_1) \cdots p_\theta(x_n)] = 0$$

ma rozwiązanie $\hat{\theta}_n(x_1, \dots, x_n)$ takie, że

Estymator Największej Wiarygodności

Twierdzenie

$$\forall \varepsilon > 0 \quad \lim_{n \rightarrow \infty} P_\theta \left\{ \left| \hat{\theta}_n(X_1, \dots, X_n) - \theta \right| < \varepsilon \right\} = 1$$

$$(*) \quad \sqrt{n} \left(\hat{\theta}_n(X_1, \dots, X_n) - \theta \right) \rightarrow N \left(0, \frac{1}{I_\theta} \right).$$

Definicja

Estymator $\hat{\theta}_n$ spełniający warunek (*) nazywamy *asymptotycznie efektywnym*

3.7 Inne przykłady

Inne przykłady

Rodziny wykładnicze

Estymujemy parametr θ jednoparametrowej rodziny wykładniczej $p_\theta(x) = \exp\{\theta T(x) - b(\theta)\}$.

Wiarogodność

$$L(\theta; x_1, \dots, x_n) = \exp \left\{ \theta \sum_{i=1}^n T(x_i) - nb(\theta) \right\}$$

Inne przykłady

Rodziny wykładnicze

Estymator Największej Wiarogodności $\hat{\theta}_n = ENW[\theta]$ istnieje i jest rozwiązaniem równania

$$\frac{1}{n} \sum_{i=1}^n T(x_i) = \frac{db(\theta)}{d\theta}$$

Inne przykłady

Rodziny wykładnicze

Ponadto

$$\forall \varepsilon > 0 \quad \lim_{n \rightarrow \infty} P_\theta \left\{ \left| \hat{\theta}_n - \theta \right| < \varepsilon \right\} = 1$$

$$\sqrt{n} \left(\hat{\theta}_n - \theta \right) \rightarrow N \left(0, \frac{1}{I_\theta = D_\theta^2 T} \right)$$

Inne przykłady

ENW wyznaczony tylko numerycznie

Model statystyczny

$$(\mathbb{R}_+, \{P_\theta : \theta \in \mathbb{R}_+\})$$
$$p_\theta(x) = \theta x^{\theta-1} \exp \{-x^\theta\}$$

Inne przykłady

ENW wyznaczony tylko numerycznie

Rozkład próby

$$p_{\theta}(x_1, \dots, x_n) = \theta \left(\prod_{i=1}^n x_i \right)^{\theta-1} \exp \left\{ - \sum_{i=1}^n x_i^{\theta} \right\}$$

Logarytm wiarygodności

$$\mathcal{L}(\theta; x_1, \dots, x_n) = n \log \theta + (\theta - 1) \sum_{i=1}^n x_i - \sum_{i=1}^n \exp \{ \theta \log x_i \}$$

Inne przykłady

ENW wyznaczony tylko numerycznie

Pochodna

$$\frac{d\mathcal{L}(\theta; x_1, \dots, x_n)}{d\theta} = \frac{n}{\theta} + \sum_{i=1}^n x_i - \sum_{i=1}^n \log x_i \exp \{ \theta \log x_i \}$$

$$\frac{d\mathcal{L}(\theta; x_1, \dots, x_n)}{d\theta} \text{ jest ciągła}$$

$$\lim_{\theta \rightarrow 0} \frac{d\mathcal{L}(\theta; x_1, \dots, x_n)}{d\theta} = +\infty, \quad \lim_{\theta \rightarrow +\infty} \frac{d\mathcal{L}(\theta; x_1, \dots, x_n)}{d\theta} = -\infty$$

Inne przykłady

ENW wyznaczony tylko numerycznie

Równanie wiarygodności

$$\frac{d\mathcal{L}(\theta; x_1, \dots, x_n)}{d\theta} = 0$$

ma rozwiązanie.

Istnieje $ENW[\theta]$

Inne przykłady

ENW wyznaczony niejednoznacznie

Model statystyczny

$$\left(\mathbb{R}, \left\{ U \left(\theta - \frac{1}{2}, \theta + \frac{1}{2} \right) : \theta \in \mathbb{R} \right\} \right)$$

Rozkład próby

$$p_\theta(x_1, \dots, x_n) = \begin{cases} 1, & \text{gdy } \theta - \frac{1}{2} \leq x_1, \dots, x_n \leq \theta + \frac{1}{2}, \\ 0, & \text{poza tym.} \end{cases}$$

Inne przykłady

ENW wyznaczony niejednoznacznie

Wiarogodność

$$L(\theta; x_1, \dots, x_n) = \begin{cases} 1, & \text{gdy } x_{n:n} - \frac{1}{2} \leq \theta \leq x_{1:n} + \frac{1}{2}, \\ 0, & \text{poza tym.} \end{cases}$$

$$x_{1:n} = \min\{x_1, \dots, x_n\}, \quad x_{n:n} = \max\{x_1, \dots, x_n\}$$

Każda liczba z przedziału $[X_{n:n} - \frac{1}{2}, X_{1:n} + \frac{1}{2}]$ jest ENW $[\theta]$.

Inne przykłady

ENW nie istnieje (model błędów grubych)

Model statystyczny

$$\left(\mathbb{R}, \{ P_{\mu, \sigma^2} : (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}_+ \} \right)$$

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

Inne przykłady

ENW nie istnieje (model błędów grubych)

Wiarogodność

$$L(\mu, \sigma^2; x_1, \dots, x_n) = \prod_{i=1}^n p_{\mu, \sigma^2}(x_i)$$

Dla każdego $M > 0$ istnieją (μ, σ^2) takie, że

$$L(\mu, \sigma^2; x_1, \dots, x_n) > M$$

4 EMNK

4.1 Przykład wstępny

EMNK: przykład wstępny

Funkcja Cobba–Douglasa

W ekonomicznej teorii produkcji rozważa się funkcję produkcji Cobba–Douglasa:

$$z = AL^\alpha K^\beta$$

gdzie z oznacza wielkość produkcji, L jest nakładem pracy, K nakładem kapitału. Liczby A, α, β są pewnymi stałymi. Ekonomisci interesują się wielkościami A, α i β .

EMNK: przykład wstępny


Eksperyment

W celu oceny nieznanymi wielkościami A, α, β prowadzone są obserwacje wielkości produkcji Z_i przy różnych nakładach L_i oraz K_i , przy czym zakłada się, że obserwacje te obciążone są efektami losowymi ε_i

$$Z_i = AL_i^\alpha K_i^\beta + \varepsilon_i, \quad i = 1, \dots, n$$


EMNK: przykład wstępny

Eksperyment



EMNK: przykład wstępny

Eksperyment




EMNK: przykład wstępny

Eksperyment

EMNK: przykład wstępny

Zasada najmniejszych kwadratów



Jako oszacowania nieznanych parametrów A, α, β przyjmuje się takie wartości, przy których błędy losowe są małe

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Z_i - AL_i^\alpha K_i^\beta)^2 = \min!$$

4.2 Określenie

Estymator najmniejszych kwadratów

Model

Obserwujemy zmienne losowe Y_1, \dots, Y_n takie, że

$$EY_i = g_i(\theta), \quad i = 1, \dots, n$$

$$\theta \in \Theta \subset \mathbb{R}^k$$

$g_i : \Theta \rightarrow \mathbb{R}^1$ są znanymi funkcjami

Estymator najmniejszych kwadratów

Kryterium

$$S(\theta) = \sum_{i=1}^n (Y_i - g_i(\theta))^2$$

Estymator najmniejszych kwadratów

Wielkość $\hat{\theta} \stackrel{\text{ozn}}{=} EMNK[\theta]$ minimalizująca $S(\theta)$

Resztowa suma kwadratów

$$S(\hat{\theta}) = \sum_{i=1}^n (Y_i - g_i(\hat{\theta}))^2$$

4.3 Model liniowy

Model liniowy

Definicja

Modelem liniowym nazywamy model statystyczny, w którym obserwacje Y_1, \dots, Y_n mają postać

$$Y_i = \beta_1 x_{1i} + \dots + \beta_p x_{pi} + \varepsilon_i, \quad i = 1, \dots, n$$

gdzie x_{ji} są ustalonymi liczbami, β_j są nieznanymi parametrami modelu, ε_i są niezależnymi „błędami losowymi” takimi, że $E\varepsilon_i = 0$ oraz $D^2\varepsilon_i = \sigma^2$

Model liniowy

Zapis macierzowy

$$Y = X\beta + \varepsilon.$$

$$Y' = (Y_1, \dots, Y_n) \quad \beta' = (\beta_0, \beta_1, \dots, \beta_p) \quad \varepsilon' = (\varepsilon_1, \dots, \varepsilon_n)$$

$$X = \begin{bmatrix} x_{11} & \dots & x_{p1} \\ x_{12} & \dots & x_{p2} \\ \vdots & \dots & \vdots \\ x_{1n} & \dots & x_{pn} \end{bmatrix}$$

Założenie: macierz X jest pełnego rzędu

Model liniowy

Resztowa suma kwadratów

$$\begin{aligned} S(\beta) &= \sum_{i=1}^n \left(Y_i - \sum_{j=1}^p \beta_j x_{ji} \right)^2 \\ &= (Y - X\beta)'(Y - X\beta) = Y'Y - 2\beta'X'Y + \beta'X'X\beta \end{aligned}$$

$$\frac{\partial S(\beta)}{\partial \beta'} = -2X'Y + 2X'X\beta$$

Model liniowy

Układ równań normalnych

$$\mathbf{X}'\mathbf{X}\beta = \mathbf{X}'\mathbf{Y}$$

Estymator najmniejszych kwadratów

$$EMNK[\beta] = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} \stackrel{\text{ozn}}{=} \hat{\beta}$$

Uwaga geometryczna

$\mathbf{X}\hat{\beta}$ jest rzutem \mathbf{Y} na $\{\mathbf{X}\beta : \beta \in \mathbb{R}^p\}$

$$(\mathbf{Y} - \mathbf{X}\hat{\beta})'\mathbf{X} = \mathbf{0}$$

Model liniowy

EMNK funkcji liniowej

Jeżeli $c \in \mathbb{R}^p$, to

$$EMNK[c'\beta] = c'\hat{\beta}$$

Przykład

$$\beta_1 = [1, 0, \dots, 0]\beta$$

$$EMNK[\beta_1] = [1, 0, \dots, 0]\hat{\beta}$$

4.4 Przykłady

Estymacja μ

Zadanie

Na podstawie obserwacji Y_1, \dots, Y_n oszacować ich wartość oczekiwaną μ .

Estymacja μ

Model

$$Y_i = \mu + \varepsilon_i, \quad i = 1, \dots, n$$

Zapis macierzowy

$$\mathbf{Y}' = [Y_1, \dots, Y_n]', \quad \beta = \mu, \quad \mathbf{X} = \mathbf{1}_n$$

Estymator

$$EMNK[\mu] = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = \bar{Y}$$

Estymacja $\mu_1 - \mu_2$

Zadanie

Na podstawie obserwacji Y_1, \dots, Y_{n_1} o wartości oczekiwanej μ_1 oraz Y_{n_1+1}, \dots, Y_n o wartości oczekiwanej μ_2 oszacować $\mu_1 - \mu_2$

Estymacja $\mu_1 - \mu_2$

Model

$$\begin{aligned} Y_i &= x_{i1}\mu_1 + x_{i2}\mu_2 + \varepsilon_i, \quad i = 1, \dots, n \\ x_{i1} &= 1, x_{i2} = 0 \text{ dla } i = 1, \dots, n_1 \\ x_{i1} &= 0, x_{i2} = 1 \text{ dla } i = n_1 + 1, \dots, n \end{aligned}$$

Zapis macierzowy

$$\beta' = [\mu_1, \mu_2], \quad X = \begin{bmatrix} \mathbf{1}_{n_1} & \mathbf{0}_{n_1} \\ \mathbf{0}_{n-n_1} & \mathbf{1}_{n-n_1} \end{bmatrix}$$

Estymacja $\mu_1 - \mu_2$

Estymator wektora $\beta' = [\mu_1, \mu_2]$

$$\begin{aligned} EMNK[\beta] &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} \\ &= \begin{bmatrix} n_1 & 0 \\ 0 & n_2 \end{bmatrix}^{-1} \begin{bmatrix} \sum_{i=1}^{n_1} Y_i \\ \sum_{i=n_1+1}^n Y_i \end{bmatrix} \\ &= \begin{bmatrix} \frac{1}{n_1} \sum_{i=1}^{n_1} Y_i \\ \frac{1}{n-n_1} \sum_{i=n_1+1}^n Y_i \end{bmatrix} \end{aligned}$$

Estymacja $\mu_1 - \mu_2$

Estymator różnicy $\mu_1 - \mu_2$

Jeżeli $c' = [1, -1]$, to $c'\beta = \mu_1 - \mu_2$

$$EMNK[\mu_1 - \mu_2] = \frac{1}{n_1} \sum_{i=1}^{n_1} Y_i - \frac{1}{n-n_1} \sum_{i=n_1+1}^n Y_i$$

Estymator średniej μ_1

Jeżeli $c' = [1, 0]$, to $c'\beta = \mu_1$

$$EMNK[\mu_1] = \frac{1}{n_1} \sum_{i=1}^{n_1} Y_i$$

4.5 Własności

Własności $EMNK$

Nieobciążoność

$EMNK[\beta]$ jest estymatorem nieobciążonym o macierzy kowariancji $\sigma^2(\mathbf{X}'\mathbf{X})^{-1}$

$$E_{\beta}\hat{\beta} = E_{\beta}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'E_{\beta}\mathbf{Y} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\beta = \beta$$

Własności $EMNK$

Funkcja estymowalna

Funkcję parametryczną $c'\beta$ nazywamy estymowalną, jeżeli istnieje jej estymator nieobciążony postaci $b'\mathbf{Y}$

Twierdzenie

Funkcja parametryczna $c'\beta$ jest estymowalna wtedy i tylko wtedy, gdy $c \in \text{Im}\mathbf{X}'$

Własności $EMNK$

Twierdzenie Gaussa–Markowa

Jeżeli błędy losowe $\varepsilon_1, \dots, \varepsilon_n$ są nieskorelowanymi zmiennymi losowymi o zerowej wartości oczekiwanej i takiej samej wariancji, to dla każdej estymowalnej funkcji parametrycznej $c'\beta$ i dla każdego nieobciążonego estymatora liniowego $b'\mathbf{Y}$ tej funkcji zachodzi

$$D_{\beta}^2(c'\hat{\beta}) \leq D_{\beta}^2(b'\mathbf{Y}), \quad \forall \beta \in \mathbb{R}^p$$

4.6 Estymacja wariancji

Estymacja wariancji σ^2

Resztowa suma kwadratów

$$\begin{aligned} S(\hat{\beta}) &= \sum_{i=1}^n \left(Y_i - \sum_{j=1}^p \hat{\beta}_j x_{ji} \right)^2 = \|\mathbf{Y} - \mathbf{X}\hat{\beta}\|^2 \\ &= (\mathbf{Y} - \mathbf{X}\hat{\beta})'(\mathbf{Y} - \mathbf{X}\hat{\beta}) \\ &= (\mathbf{Y} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y})'(\mathbf{Y} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}) \\ &= \mathbf{Y}'(\mathbf{I} - \mathbf{X}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X})(\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{Y} \\ &= \mathbf{Y}'(\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{Y} \end{aligned}$$

Estymacja wariancji σ^2

Resztowa suma kwadratów

$$\begin{aligned} E_{\beta, \sigma^2} \|Y - X\hat{\beta}\|^2 &= E_{\beta, \sigma^2} Y'(I - X(X'X)^{-1}X')Y \\ &= \text{tr} E_{\beta, \sigma^2} (I - X(X'X)^{-1}X')YY' \\ &= \text{tr} \{ (I - X(X'X)^{-1}X') E_{\beta, \sigma^2} (YY') \} \\ &= \sigma^2 \text{tr} (I - X(X'X)^{-1}X') \\ &= (n - \text{rz}X) \sigma^2 \end{aligned}$$

Estymacja wariancji σ^2

$EMNK[\sigma^2]$

$$\hat{\sigma}^2 = \frac{1}{n - \text{rz}X} Y'(I - X(X'X)^{-1}X')Y$$

Estymacja wariancji σ^2

Zadanie

Na podstawie obserwacji Y_1, \dots, Y_n o wartości oczekiwanej μ oszacować ich wariancję σ^2 .

Estymacja wariancji σ^2

Model

$$Y_i = \mu + \varepsilon_i, \quad i = 1, \dots, n$$

Zapis macierzowy

$$\begin{aligned} Y' &= [Y_1, \dots, Y_n]', \quad \beta = \mu, \quad X = \mathbf{1}_n \\ \text{rz}X &= 1 \end{aligned}$$

Estymacja wariancji σ^2

Estymator

$$\begin{aligned}
\hat{\sigma}^2 &= \frac{1}{n-1} \mathbf{Y}' \left(\mathbf{I} - \frac{1}{n} \mathbf{1}_n \mathbf{1}_n' \right) \mathbf{Y} \\
&= \frac{1}{n-1} \left\{ \mathbf{Y}' \mathbf{Y} - \frac{1}{n} (\mathbf{Y}' \mathbf{1}_n) (\mathbf{1}_n' \mathbf{Y}) \right\} \\
&= \frac{1}{n-1} \left\{ \sum_{i=1}^n Y_i^2 - \frac{1}{n} \left(\sum_{i=1}^n Y_i \right)^2 \right\} \\
&= \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2
\end{aligned}$$

Estymacja wariancji σ^2

Zadanie

Na podstawie obserwacji Y_1, \dots, Y_{n_1} o wartości oczekiwanej μ_1 i wariancji σ^2 oraz Y_{n_1+1}, \dots, Y_n o wartości oczekiwanej μ_2 i wariancji σ^2 oszacować σ^2

Estymacja wariancji σ^2

Model

$$Y_i = x_{i1}\mu_1 + x_{i2}\mu_2 + \varepsilon_i, \quad i = 1, \dots, n$$

$$x_{i1} = 1, x_{i2} = 0 \text{ dla } i = 1, \dots, n_1$$

$$x_{i1} = 0, x_{i2} = 1 \text{ dla } i = n_1 + 1, \dots, n$$

Zapis macierzowy

$$\beta' = [\mu_1, \mu_2], \quad \mathbf{X} = \begin{bmatrix} \mathbf{1}_{n_1} & \mathbf{0}_{n_1} \\ \mathbf{0}_{n-n_1} & \mathbf{1}_{n-n_1} \end{bmatrix}$$

$$\text{rz} \mathbf{X} = 2$$

Estymacja wariancji σ^2

Estymator

$$\begin{aligned}
(n-2)\hat{\sigma}^2 &= \mathbf{Y}' \left(\mathbf{I} - \begin{bmatrix} \mathbf{1}_{n_1} & \mathbf{0}_{n_1} \\ \mathbf{0}_{n_2} & \mathbf{1}_{n_2} \end{bmatrix} \begin{bmatrix} n_1 & 0 \\ 0 & n_2 \end{bmatrix}^{-1} \begin{bmatrix} \mathbf{1}'_{n_1} & \mathbf{0}'_{n_2} \\ \mathbf{0}'_{n_1} & \mathbf{1}'_{n_2} \end{bmatrix} \right) \mathbf{Y} \\
&= \sum_{i=1}^{n_1} \left(Y_i - \frac{1}{n_1} \left(\sum_{i=1}^{n_1} Y_i \right) \right)^2 + \\
&\quad + \sum_{i=n_1+1}^n \left(Y_i - \frac{1}{n_2} \left(\sum_{i=n_1+1}^n Y_i \right) \right)^2
\end{aligned}$$

4.7 Własności probabilistyczne

Rozkłady prawdopodobieństwa estymatorów

Model

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

$$\boldsymbol{\beta}' = (\beta_0, \beta_1, \dots, \beta_p)$$

$$\boldsymbol{\varepsilon}' = (\varepsilon_1, \dots, \varepsilon_n) \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$$

EMNK

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}$$

$$s^2 = \hat{\sigma}^2 = \frac{1}{n - \text{rz}\mathbf{X}} \mathbf{Y}'(\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}')\mathbf{Y}$$

Rozkłady prawdopodobieństwa estymatorów

Twierdzenie

Jeżeli $\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n)$ oraz $\text{rz}\mathbf{X} = p$, to

- $\hat{\boldsymbol{\beta}} \sim N_p(\boldsymbol{\beta}, \sigma^2(\mathbf{X}'\mathbf{X})^{-1})$
- $(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})' \mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}) \sim \sigma^2 \chi_p^2$
- $\hat{\boldsymbol{\beta}}$ jest niezależne od s^2
- $(n-p)s^2 \sim \sigma^2 \chi_{n-p}^2$