

II Klasyczna teoria estymacji

1. Estymacja parametru θ (podjęcie klasyczne - nie Bayesowskie)

θ $\xrightarrow{p_\theta(x)}$ X
 \uparrow \uparrow
 niezmienny (ale chwyłaj) obserwowane
 parametr(y) zdanie (a)

$p_\theta(x)$ - rodzina rozkładów prawdopodobieństwa opisując zmienną (e) losową X

Chcemy wywnioskować θ na podstawie X

$\tilde{\theta}(x)$ - estymator, ma nam dać informację o θ

Przykład

$$X = (x_1, \dots, x_N)$$

$$x_i = \theta + w_i$$

niezależne zmienne losowe

$$w_i \sim N(0, \sigma^2)$$

\downarrow \uparrow
 rozkład gęstości średnia wariancja

$$x_i \sim N(\theta, \sigma^2)$$

$$p_\theta(x) = p_\theta(x_1) \cdot \dots \cdot p_\theta(x_N)$$

$$p_{\theta}(x_i) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x_i - \theta)^2}{2\sigma^2}}$$

Miemy (x_1, \dots, x_N)

Jeli byłby "dobry" estymator Θ

- $\tilde{\Theta}(x) = x_1$

- $\tilde{\Theta}(x) = \frac{\sum_i x_i}{N}$

1.1 Optymalne estymatory

Nieobciążoność estymatora

$$\langle \tilde{\Theta} \rangle = \theta \quad \text{tzn.} \quad \int_{\theta} \tilde{\Theta}(x) p_{\theta}(x) dx = \theta$$

średnio daje prawdziwą wartość

- $\tilde{\Theta}(x) = x_1 \quad \langle \tilde{\Theta} \rangle = \langle x_1 \rangle = \theta \quad \text{OK}$

- $\tilde{\Theta}(x) = \frac{\sum_i x_i}{N} \quad \langle \tilde{\Theta} \rangle = \frac{1}{N} \sum_i \langle x_i \rangle = \theta \quad \text{OK}$

Optymalność estymatora

Wariancja estymatora

$$\Delta^2 \tilde{\Theta} = \langle (\tilde{\Theta} - \theta)^2 \rangle = \int (\tilde{\Theta}(x) - \theta)^2 p_{\theta}(x) dx$$

Chcemy aby $\Delta^2 \tilde{\Theta}$ było jak najmniejsza

Uwaga: mażna napisać estymator, który będzie dobry dla pewnej wartości θ a gorszy dla innych.

typowy przykład $\tilde{\theta} = \theta_0$ nie zależnie od danych - to jest przykład estymatora obciążonego

Zaczytaj bardziej interesującej jest:

11 Minimum variance unbiased estimator (MVU)

Nieobciążony estymator z minimalną wariancją

- minimalna wariancja dla wszystkich θ

Przykład

$$x_i \sim N(\theta, \sigma^2)$$

$$\tilde{\theta}(x_1, \dots, x_n) = \frac{1}{n} \sum_i x_i$$

$$\begin{aligned} \Delta^2 \tilde{\theta} &= \left\langle \left(\frac{1}{n} \sum_i x_i - \theta \right)^2 \right\rangle = \frac{1}{n^2} \langle (x_1 - \theta + x_2 - \theta + \dots + x_n - \theta)^2 \rangle = \\ &= \frac{1}{n^2} n \sigma^2 = \frac{\sigma^2}{n} \quad \text{jest MVU} \\ &\quad \text{(dowód poniżej)} \end{aligned}$$

$$\left\{ \begin{array}{l} \text{gdzie wziąć } \tilde{\theta}(x_1, \dots, x_n) \approx x_1 \\ \Delta^2 \tilde{\theta} \approx \sigma^2 \end{array} \right.$$

1.2 Ograniczenie Cramera-Rao (CR)

Chcemy mieć ograniczenie na najlepszy możliwy estymator nieobciążony wtedy jak istnieje estymator osiągający ograniczone wolumen i jest optymalny

Intuicja: $p_{\theta}(x)$ im bardziej różnił $p_{\theta}(x)$

zmieni się z θ tym większa precyzja estymacji
 w granicznym przypadku jest $\frac{d}{d\theta} p_{\theta}(x)$

Złotienia

$$\langle \tilde{\theta} \rangle = \int dx \tilde{\theta}(x) p_{\theta}(x) = \theta \quad \text{— nieobciążoność}$$

w rozkładach będących
potrzebawców;

$$(*) \frac{d\langle \tilde{\theta} \rangle}{d\theta} = \int dx \tilde{\theta}(x) \frac{dp_{\theta}(x)}{d\theta} = 1 \quad \text{— lokalna nieobciążoność}$$

$$(**) \int dx \frac{dp_{\theta}(x)}{d\theta} = 0 \quad \text{— warunek regularności}$$

|| jeśli mamy zamknięty
 kłębność całkowania
 i różniczkowania,

$$\frac{d}{d\theta} \int dx p_{\theta}(x) = \frac{d}{d\theta} 1 = 0 \quad \text{spełniony}$$

Wyprawczenie:

$$\underbrace{\int dx p_{\theta}(x) (\tilde{\theta}(x) - \theta)^2}_{\Delta^2 \tilde{\theta}} = \underbrace{\int dx \frac{1}{p_{\theta}(x)} \left(\frac{dp_{\theta}(x)}{d\theta} \right)^2}_F$$

$$= \int dx \left[\sqrt{p_{\theta}(x)} (\tilde{\theta}(x) - \theta) \right]^2 \cdot \int dx \left(\frac{1}{\sqrt{p_{\theta}(x)}} \frac{dp_{\theta}(x)}{d\theta} \right)^2$$

$$\stackrel{C-S}{\geq} \left(\int dx (\tilde{\theta}(x) - \theta) \frac{dp_{\theta}(x)}{d\theta} \right)^2 = \underbrace{\left(\int dx \tilde{\theta}(x) \frac{dp_{\theta}(x)}{d\theta} \right)}_{I(*)} - \theta \underbrace{\left(\int dx \frac{dp_{\theta}(x)}{d\theta} \right)}_{I(**)}$$

$$\Delta^2 \tilde{\theta} \geq \frac{1}{F} \quad \left[\begin{array}{l} \int dx \frac{1}{p_{\theta}(x)} \left(\frac{d p_{\theta}(x)}{d\theta} \right)^2 \\ \text{Informacja Fishera} \end{array} \right]$$

F w ogólnosci zależy od θ

Uwaga:

Miernic spójności i inne równoważne postaci il F

$$F = \left\langle \left(\frac{d}{d\theta} \log p_{\theta}(x) \right)^2 \right\rangle = \int dx p_{\theta}(x) \frac{1}{p_{\theta}(x)^2} \left(\frac{d p_{\theta}(x)}{d\theta} \right)^2 = \int \frac{1}{p_{\theta}(x)} \left(\frac{d p_{\theta}(x)}{d\theta} \right)^2$$

$$F = - \left\langle \frac{d^2}{d\theta^2} \log p_{\theta}(x) \right\rangle$$

↑ jawnie widzieć addytywność

Jeśli miernik spójności estymator nie obciążony dla

lotarego $\Delta^2 \tilde{\theta} = \frac{1}{F}$ wtedy il jest
 optymalny. Miernik wtedy $\tilde{\theta}$ jest „efficient”.

Addytywność F

Jeśli $p_{\theta}^{(12)}(x_1, x_2) = p_{\theta}^{(1)}(x_1) \cdot p_{\theta}^{(2)}(x_2)$ wtedy

$$F^{(12)} = F^{(1)} + F^{(2)}$$

Wniosek: N niezależnych realizacji zmiennej
 losowej X : $F^{(N)} = N \cdot F$

$$\delta^2 \tilde{\theta} \geq \frac{1}{N \cdot F}$$

Przykład

$$x_i \sim N(\theta, \sigma^2)$$

$$i = 1, \dots, N$$

$$p_{\theta}(x_i) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i - \theta)^2}{2\sigma^2}}$$

$$F = \left\langle \left(\frac{d}{d\theta} \log p_{\theta}(x_i) \right)^2 \right\rangle = \int d p_{\theta}(x) \left(\frac{x - \theta}{\sigma^2} \right)^2 = \frac{\sigma^2}{\sigma^4} = \frac{1}{\sigma^2}$$

Mając N realizacji :

$$\delta^2 \tilde{\theta} \geq \frac{1}{NF} = \frac{\sigma^2}{N}$$

Czyli tyle ile wynosi z estymatora $\tilde{\theta} = \frac{\sum x_i}{N}$

eficient estymator

Wysycanie mierzalności CR

Potrzeba na wypracowanie mierzalności C-5 wysycam : iff:

$$\lambda(\theta) \sqrt{p_{\theta}(x)} (\hat{\theta}(x) - \theta) = \frac{1}{\sqrt{p_{\theta}(x)}} \frac{d p_{\theta}(x)}{d\theta}$$

$$\left[\frac{d}{d\theta} \log p_{\theta}(x) = \lambda(\theta) (\hat{\theta}(x) - \theta) \right]$$

Jeli między $\lambda(\theta)$, $\hat{\theta}(x)$ tie powrose równanie spełniane wysycamy C-R

Przykład

$$x_i = N(\theta, \sigma^2)$$

$$p_{\theta}(x) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i - \theta)^2}{2\sigma^2}}$$

$$\log p_{\theta}(x) = -\frac{N}{2} \log 2\pi\sigma^2 - \sum_{i=1}^N \frac{(x_i - \theta)^2}{2\sigma^2}$$

$$\frac{d}{d\theta} \log p_{\theta}(x) = \sum_i \frac{(x_i - \theta)}{\sigma^2} = \lambda(\theta) (\hat{\theta}(x) - \theta)$$

jesti weźmiemy $\hat{\theta}(x) = \bar{x} = \frac{\sum x_i}{N}$, $\lambda(\theta) = \frac{N}{\sigma^2}$

1.3 Wieloparametrowe ograniczenie C-R

$$p_{\vec{\theta}}(x) \quad \vec{\theta} = (\theta_1, \dots, \theta_k) =: \theta$$

$$\vec{x} = (x_1, \dots, x_N) =: x$$

$$\boxed{C_{\vec{\theta}} \geq F^{-1}} \quad \left\{ C_{\theta} - IF_{\theta}^{-1} \geq 0 \right.$$

macierz kowariancji macierz Fishera

$$(C_{\vec{\theta}})_{ij} = \int dx p_{\theta}(x) (\tilde{\theta}_i(x) - \theta_i) (\tilde{\theta}_j(x) - \theta_j)$$

$$\text{gdzie } (F)_{ij} = \int dx \frac{1}{p_{\theta}(x)} \frac{\partial p_{\theta}(x)}{\partial \theta_i} \frac{\partial p_{\theta}(x)}{\partial \theta_j} \quad \left. \begin{array}{l} \text{Macierz} \\ \text{Fishera} \\ \text{(symetryczna} \\ \text{definiowana przez)} \end{array} \right\}$$

$$\left\{ F \right\}_{ij} = \left\langle - \frac{\partial^2 \log p_{\theta}(x)}{\partial \theta_i \partial \theta_j} \right\rangle$$

$$\left\{ \tau \quad \tilde{\theta}_j = \left(- \frac{\partial \tilde{\theta}_i}{\partial \theta_j} \right) \right\}$$

W szczególności:

$$\Delta^2 \tilde{\theta}_i \geq (F^{-1})_{ii} \quad \left\{ \begin{array}{l} \text{M. macierz} \\ \text{dodatnio określona} \\ \text{wyraz diagonalne} \\ \text{nieujemny} \end{array} \right.$$

F - macierz symetryczna, $F \geq 0$

Wyrowadzenie:

$$\begin{aligned} w^T C w \cdot v^T F v &= \int dx p(x) w_i (\tilde{\theta}_i - \theta_i) (\tilde{\theta}_j - \theta_j) w_j \\ &= \int dx \frac{1}{p(x)} v_i \frac{\partial p(x)}{\partial \theta_i} \frac{\partial p(x)}{\partial \theta_j} v_j \geq \left(\int dx w_i (\tilde{\theta}_i - \theta_i) \frac{\partial p(x)}{\partial \theta_i} v_i \right)^2 \\ &= (w^T v)^2 \quad \text{bierzemy } w = Fv \end{aligned}$$

$$v^T F C F v = v^T F v \geq (v^T F v)^2$$

$$v^T F C F v \geq v^T F v$$

$$F C F \geq F \Rightarrow C \geq F^{-1} \quad \square$$

Uwaga:

$$\Delta^2 \tilde{\theta}_{ii} \geq (F^{-1})_{ii} \geq (F_{ii})^{-1}$$

↓
mniejsze

$$\left\{ \begin{array}{l} 1 = e_i^T \sqrt{F} \sqrt{F^{-1}} e_i \leq e_i^T F e_i \quad e_i^T F^{-1} e_i \\ (F^{-1})_{ii} \geq \frac{1}{F_{ii}} \end{array} \right.$$

wyścime:

$$\vec{\nabla} \ln p_{\theta}(x) = F(\vec{g}(x) - \vec{\theta})$$

1.5 Estymacja funkcji od wielu parametrów

$g(\vec{\theta})$ { g również może być wielomianem
ale dla uproszczenia może być skalar

$$\Delta^2 \tilde{g} \approx \vec{\nabla} g \cdot F^{-1} (\vec{\nabla} g)^T$$