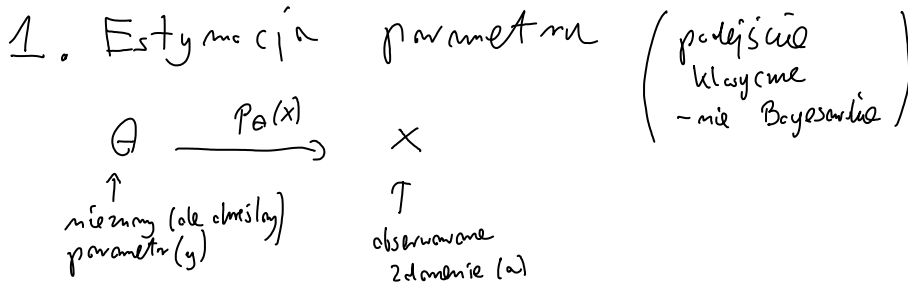


II Klasyfikacja teorii estymacji



$p_{\theta}(x)$ - rodzina rozkładów prawdopodobieństwa opisujące zmienną losową X

Chcemy wyznaczyć 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
 $w_i \sim N(0, \sigma^2)$
 rozkład Gaussa \uparrow średnia \uparrow 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)

Jaki byłby "dobry" estymator θ

- $\tilde{\theta}(x) = x_1$
- $\tilde{\theta}(x) = \frac{\sum x_i}{N}$

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

- $\tilde{\theta}(x) = x_1 \quad \langle \tilde{\theta} \rangle = \langle x_1 \rangle = \theta \quad \text{OK}$
- $\tilde{\theta}(x) = \frac{\sum x_i}{N} \quad \langle \tilde{\theta} \rangle = \frac{1}{N} \sum \langle x_i \rangle = \theta \quad \text{OK}$

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: najmniej najlepszy estymator; który będzie dobry dla pewnych wartości θ a gorszy dla innych. Najbardziej przydatny $\tilde{\theta} = \theta_0$ nie zależy od danych - to jest najbardziej estymator obciążonego

Zacząć bardziej interesującej jest:

"Minimum variance unbiased estimator" (MVU)

Nieobciążony estymator z minimalną wariancją

- minimalna wariancja dla wszystkich θ

Przykład

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

$$\tilde{\theta}(x_1, \dots, x_N) = \frac{1}{N} \sum x_i$$

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

$$\left\{ \begin{array}{l} \text{gdzie widać } \tilde{\theta}(x_1, \dots, x_N) = x_1 \quad \Delta^2 \tilde{\theta} = \sigma^2 \end{array} \right.$$

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

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

$$\stackrel{C-S}{\geq} \left(\int dx (\tilde{\theta}(x) - \theta) \frac{d p_{\theta}(x)}{d\theta} \right)^2 = \underbrace{\left(\int dx \tilde{\theta}(x) \frac{d p_{\theta}(x)}{d\theta} \right)}_{I(*)} - \underbrace{\theta \left(\int dx \frac{d p_{\theta}(x)}{d\theta} \right)}_{0}$$

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

F w ogólnosci zależy od θ

Uwaga:

Mając spójności inne równoważne postaci 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

Jedli miły estimator nie obciążony dla

Lotarego $\Delta^2 \tilde{\theta} = \frac{1}{F}$ wtedy jest optymalny. Mówimy 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 : $F^{(N)} = N \cdot F$

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

$$D^{-1} \geq N \cdot F$$

Przykład

$$x_i \sim N(\theta, \sigma^2) \quad i = 1, \dots, N$$

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

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

Mając N realizacji :

$$D_{\theta}^2 \approx \frac{1}{NF} = \frac{\sigma^2}{N}$$

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

Wyszukiwanie maksimum CR

Potrzeba nam wyznaczenie minimum C-5 wyszczególniamy :

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

$$\boxed{\frac{d}{d\theta} \log p_{\theta}(x) = \lambda(\theta) (\hat{\theta}(x) - \theta)}$$

Jeli znajemy $\lambda(\theta)$, $\hat{\theta}(x)$ to poszukujemy minimum spełniane wyszczególniamy C-R

Przykład

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

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

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

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

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

Ogólnie:

$$\log p_{\theta}(x) = \lambda(\theta) \hat{\theta}(x) + a(\theta) + b(x), \quad \begin{matrix} a' = -\lambda \cdot \theta \\ \lambda' = \lambda \end{matrix}$$

$$p_{\theta}(x) = e^{a(\theta)} e^{b(x)} e^{\lambda(\theta) \hat{\theta}(x)}$$

Szerzej przydałby się tw. exponential family

$$p_{\theta}(x) = e^{a(\theta) + b(x) + c(\theta) d(x)}$$

gdzie żeby estymacja θ była efficient $\theta = -\frac{\frac{da}{d\theta}}{\frac{dc}{d\theta}}$

Jeśli $-\frac{\frac{da}{d\theta}}{\frac{dc}{d\theta}} \neq \theta$ wtedy nie istnieje estymator θ

Wtedy jest efficient ale istnieje dla funkcji od parametru $g(\theta) = -\frac{\frac{da}{d\theta}}{\frac{dc}{d\theta}}$ $\hat{\theta}$

$\hat{\theta}$ estymacja θ^2 jeśli $x_i = N(\theta, \sigma^2)$

1.3 Wieloparametrowe ograniczone C-R

$$p_{\vec{\theta}}(\vec{x}) \quad \vec{\theta} = (\theta_1, \dots, \theta_k) =: \theta$$
$$\vec{x} = (x_1, \dots, x_n) =: x$$

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

macierz kowariancji macierz Fishera

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

$$\text{gdzie } (F)_{ij} = \int dx \frac{1}{p_{\vec{\theta}}(x)} \frac{\partial p_{\vec{\theta}}(x)}{\partial \theta_i} \frac{\partial p_{\vec{\theta}}(x)}{\partial \theta_j} \quad \left. \begin{matrix} \text{Macierz} \\ \text{Fishera} \\ \text{(symetryczna} \\ \text{determinant dodatni)} \end{matrix} \right\}$$

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

W szczególności:

$$\Delta^2 \theta_i \geq (F^{-1})_{ii} \quad \left\{ \begin{matrix} \text{M. macierz} \\ \text{determinant dodatni} \\ \text{macierz odwrotna} \end{matrix} \right.$$

$\Delta w_i \approx (w_i^{-1} e_i) \}$ wyrażenie
nieujednolite

F - macierz symetryczna, $F \geq 0$

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

i
macierze

$$\begin{cases} 1 = e_i^T F^{-1} F F^{-1} e_i \leq e_i^T F e_i & e_i^T F^{-1} e_i \\ (F^{-1})_{ii} \geq \frac{1}{F_{ii}} \end{cases}$$

wyściana:

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

1.4 Model liniowy

$$\vec{x} = H \cdot \vec{\theta} + \vec{w}$$

$$\vec{x} = [x_1, \dots, x_N]$$

$$\vec{\theta} = [\theta_1, \dots, \theta_k]$$

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

$$\vec{w} = [w_1, \dots, w_N]$$

Jak $N > k$: H macierz $n \times k$ to

$$\vec{x} \sim N(H\vec{\theta}, \sigma^2 \mathbb{I})$$

- wieloparametrowy
gaus i średnia $H\vec{\theta}$
i macierz kowariancji $\sigma^2 \mathbb{I}$

$$p(\vec{x}) = \left(\frac{1}{\sqrt{2\pi\sigma^2}}\right)^N e^{-\frac{1}{2\sigma^2}(\vec{x} - H\vec{\theta})^T(\vec{x} - H\vec{\theta})}$$

Wzrost nie wyszczelnić :

$$\vec{\nabla} \log p(\vec{x}) = -\frac{1}{2\sigma^2} \vec{\nabla}_{\vec{\theta}} \left(\vec{x}^T \vec{x} + \vec{\theta}^T H^T H \vec{\theta} - \underbrace{\vec{\theta}^T H^T \vec{x} - \vec{x}^T H \vec{\theta}}_{-2\vec{x}^T H \vec{\theta}} \right)$$

$$= -\frac{1}{2\sigma^2} \cdot (-2 H^T \tilde{x} + 2 H^T H \theta) = \frac{1}{\sigma^2} (H^T \tilde{x} - H^T H \theta)$$

$$\left\{ \begin{array}{l} \vec{\nabla}_{\theta} (a^T \theta) = a \quad \left\{ \frac{\partial}{\partial \theta_j} \sum a_i \theta_i = a_j \right. \end{array} \right.$$

$$\left\{ \begin{array}{l} \vec{\nabla}_{\theta} (\theta^T A \theta) = 2A\theta \quad \left\{ \begin{array}{l} \frac{\partial}{\partial \theta_k} \left(\sum_{ij} \theta_i A_{ij} \theta_j \right) = \sum_i \theta_i A_{ik} \\ + \sum_j A_{ki} \theta_i = 2A \end{array} \right. \end{array} \right.$$

Jaki $H^T H$ odwrócić to -1 :

$$\vec{\nabla} \log p(x) = \frac{1}{\sigma^2} (H^T H) \left(\underbrace{(H^T H)^{-1} H^T \tilde{x}}_{\tilde{\theta}} - \theta \right)$$

czyli punkt $\tilde{\theta} = (H^T H)^{-1} H^T \tilde{x}$

Matrix Fishera: $F = \frac{H^T H}{\sigma^2}$

• Dla ogólniejszego sumy gaussowskiego

$$\tilde{w} \sim N(0, C) \quad \uparrow \text{matrix kowariancji}$$

$$F = H^T C^{-1} H \quad \tilde{\theta} = (H^T C^{-1} H)^{-1} H^T C^{-1} \tilde{x}$$

1.5 Estymacja punkty i ich waha parametrów

$$g(\tilde{\theta}) \quad \left\{ \begin{array}{l} g \text{ równie; mié byi wieloparametrowe} \\ \text{ale dla uproszczenia mié tylko jedno}$$

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