

1.3 Wieloparametrowe ograniczone C-R

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

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

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

mierz kowariancji
mierz Fishera

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

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

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

W negatywnej:

$$\Delta^2 \theta_i \geq (F^{-1})_{ii} \quad \left\{ \begin{array}{l} \text{Mierz} \\ \text{determina ches)ba} \\ \text{wymag} \\ \text{nieujemny} \end{array} \right.$$

F - mierz symetryczna, $F \geq 0$

Dowód:

$$\int dx \tilde{\theta}_i(x) p_{\vec{\theta}}(x) = \theta_i$$

$$\int dx \tilde{\theta}_i(x) \frac{\partial p_{\vec{\theta}}(x)}{\partial \theta_j} = \delta_{ij} \quad \text{- (podobnie z obrotami)}$$

$$\int dx \tilde{\theta}_i(x) \cdot (\nabla_{\vec{\theta}} p_{\vec{\theta}}(x))^T = 1$$

$$\int dx \nabla p_{\vec{\theta}}(x) = 0 \quad \text{regularny}$$

{ Mierz a, b dowolne wartości ciągłej k

$$\int dx a^T (\tilde{\theta} - \theta) (\tilde{\theta} - \theta)^T a p_{\vec{\theta}}(x)$$

$$\cdot \int \frac{1}{p_{\theta}(x)} b^T (\nabla p_{\theta}(x)) (\nabla p_{\theta}(x))^T b \geq C-S$$

$$\left(\int dx b^T \nabla p_{\theta}(x) (\tilde{\theta} - \theta) a \right)^2$$

$$a^T C_{\tilde{\theta}} a \cdot b^T F b \geq (b^T a)^2$$

Możemy być spełnione dla dowolnych a i b

Np. biorąc $a = b = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$ i to mamy

$$\left\{ \begin{array}{l} \Delta^2_{\tilde{\theta} ii} \cdot F_{ii} \geq 1 \quad \Delta^2_{\tilde{\theta} ii} \geq \frac{1}{F_{ii}} \\ \text{ale musimy być ograniczone} \end{array} \right.$$

Wtedy $b = F^{-1} a$

$$a^T C_{\tilde{\theta}} a \cdot a^T F^{-1} a \geq (a^T F^{-1} a)^2$$

$$a^T (C_{\tilde{\theta}} - F^{-1}) a \geq 0$$

$$C_{\tilde{\theta}} \geq F^{-1}$$

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

↓
mniejsza

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

wyściana:

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

1, 4 Model liniowy

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

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

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

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

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

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

$$\vec{x} \sim N(H\vec{\theta}, \sigma^2 \cdot \mathbb{1}) \quad \begin{array}{l} \text{- wieloparametrowy} \\ \text{gaus, o średniej } H\vec{\theta} \\ \text{; macierz kowariancji } \sigma^2 \mathbb{1} \end{array}$$

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

Wzrostek nie wyszczególnić :

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

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

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

macierz sym.

Jakli $H^T H$ odwracalna to :

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

$$\text{estymator } \vec{\theta} = (H^T H)^{-1} H^T \vec{x}$$

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

⚠ - dyspersyjny błąd.

1.3 Estymacja funkcji od wielu parametrów

$g(\vec{\theta})$ $\left\{ \begin{array}{l} g \text{ również może być wielowymiarowa} \\ \text{ale dla uproszczenia mieć skalara} \end{array} \right.$

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

2. Estymacja nielokalnej wiarygodności (max-likelihood)


Ce zrobić kiedy wamle wysydzasz c-R
nie spełniają i nie potrafią p.ć optymalnego
estymatora.

2.1 Estymator nielokalnej wiarygodności

$$p_{\theta}(x)$$

jeśli mamy x_0 to jako estymator przyjmujemy
tę wartość θ dla której $p_{\theta}(x)$ maksymalne

$p_{\theta}(x=x_0)$ - likelihood function



Intuicja: wartość parametru, dla którego obserwowane
zdanie jest najbardziej prawdopodobne

Uwaga

Zamiast wyznaczyć sobie $\max \log p_{\theta}(x=x_0)$

a to do tego samego punktu bo log monotoniczny

Przykład

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

$$\frac{d}{d\theta} \log p_\theta(x) = 0 \quad \text{- szukamy max}$$

$$\frac{1}{\sigma^2} \sum_i (x_i - \theta) = 0 \quad \Leftrightarrow \quad \hat{\theta}_{ML}(x) = \frac{1}{N} \sum_i x_i$$

Ogólne własności - jeśli istnieje estymator efektywny - wystarczy C-R t_0 zamiast t ten sam, który znajduje max-likelihood parametry to zamiast wyszukania t_0 :

$$\frac{d}{d\theta} \log p_\theta(x) = \lambda(\theta) \quad \begin{matrix} \uparrow \\ \text{efektywny estymator} \end{matrix}$$

czyli θ dla którego minimum to $\hat{\theta}_{ML} = \tilde{\theta}(x)$ □

W szczególności dla modeli liniowych

2.2. Asymptotyczne efektywności Max-likelihood

W ogólności nie ma gwarancji, że max-likelihood wystarczy C-R ani, że jest najlepszym estymatorem ale ... jeśli dużo nie zależy od obliczeń to tak

Twierdzenie

$$P_\theta^{(N)}(x^{(N)}) = p_\theta(x_1) \cdot \dots \cdot p_\theta(x_N)$$

↑

N punktów
obserwacji

itd. w granicy $N \rightarrow \infty$ estymator

$$x^{(N)} = [x_1, \dots, x_N]$$

$\left\{ \begin{array}{l} x_i \text{ może} \\ \text{reprezentować wiele} \\ \text{danych} \end{array} \right.$

Wtedy w granicy $N \rightarrow \infty$, estymator ML będzie miał rozkład.

$$\tilde{\Theta}_{ML} \stackrel{N \rightarrow \infty}{\sim} \mathcal{N}(\Theta, F^{(N)^{-1}}), \quad F^{(N)} = N \cdot F$$

czyli wyściga $C-R$, i jest nieobciążony

Lemat:

Niech $p_1(x), p_2(x)$ - różnymi prawdop.

$$\int p_1(x) \log \frac{p_1(x)}{p_2(x)} \geq 0$$

||
 $D(p_1 | p_2)$ - entropia względna

Dowód Lematu:

funkcja $\log t$ - własność Jensen. $\log(\sum_i w_i t_i) \geq \sum_i w_i \log t_i$
 $w_i \geq 0 \quad \sum w_i = 1$

$$\sum_x \underbrace{p_1(x)}_{w_i} \log \frac{\underbrace{p_2(x)}_{t_i}}{p_1(x)} \leq \log \sum_x p_2(x) = 0$$

$$t_i = \frac{1}{p_1(x)} \quad w_i = p_1(x)$$

czyli $\sum_x p_1(x) \log \frac{p_2(x)}{p_1(x)} \geq 0$ □

Dowód twierdzenia

Ziarnka techniczne: • wartość θ na 2-gim poziomie $\log \beta_\theta(x)$
 • $\left\langle \frac{\partial}{\partial \theta} \log \beta_\theta(x) \right\rangle = 0$

• asymptotycznie nieobciążony!

Niech $\tilde{\Theta}$ - będzie naszym estymatorem, funkcja wygładzona dla θ :

$$\frac{1}{N} \log p_{\tilde{\theta}}^{(N)}(x^{(N)}) = \frac{1}{N} \sum_i \log p_{\tilde{\theta}}(x_i)$$

2 prawa wielkich liczb, to zbieg do średniej cym

$$\frac{1}{N} \log p_{\tilde{\theta}}^{(N)}(x^{(N)}) \xrightarrow{N \rightarrow \infty} \int dx p_{\theta_0}(x) \log p_{\tilde{\theta}}(x)$$

↑
prawdopodobieństwo

2 lemitu

$$\leq \int dx p_{\theta_0}(x) \log p_{\theta_0}(x)$$

Czyli maksimum $\frac{1}{N} \log p_{\tilde{\theta}}^{(N)}(x^{(N)})$ dla $N \rightarrow \infty$

bedzie odpowiadac $\tilde{\theta}_{ML} = \theta_0$

- asymptotycznie nieobciążony $\tilde{\theta}_{ML}$

* asymptotycznie efektywne

Twierdzenie o wart. średniej $\left\{ \begin{array}{l} \text{dla wartości} \\ \text{wzrost: } \theta_0 < \tilde{\theta} \end{array} \right.$

$$\frac{\frac{\partial \log p_{\tilde{\theta}}^{(N)}(k)}{\partial \theta} \Big|_{\theta=\tilde{\theta}}}{\tilde{\theta} - \theta_0} = \frac{\frac{\partial \log p_{\theta_0}^{(N)}(k)}{\partial \theta} \Big|_{\theta=\theta_0}}{\frac{\partial^2 \log p_{\theta_0}^{(N)}(k)}{\partial \theta^2} \Big|_{\theta=\tilde{\theta}}}$$

gdzie $\theta_0 < \tilde{\theta} < \hat{\theta}$

Jeli $\tilde{\theta} = \tilde{\theta}_{ML}$ to $\frac{\partial \log p_{\tilde{\theta}}^{(N)}(k)}{\partial \theta} \Big|_{\theta=\tilde{\theta}_{ML}} = 0$

$$(*) \frac{\partial \log p_{\theta_c}^{(N)}(k)}{\partial \theta} \Big|_{\theta=\theta_c} = \frac{\partial^2 \log p_{\theta_c}^{(N)}(k)}{\partial \theta^2} \Big|_{\theta=\tilde{\theta}} (\theta_c - \tilde{\theta}_{ML})$$

Wzrost:

$$\frac{\partial^2 \log p_{\theta_c}^{(N)}(k)}{\partial \theta^2} \Big|_{\theta=\tilde{\theta}} = N \frac{1}{N} \sum \frac{\partial^2 \log p_{\theta_c}(k_i)}{\partial \theta^2} \Big|_{\theta=\tilde{\theta}}$$

$$\overline{\frac{\partial \theta^2}{\partial \theta^2}} \Big|_{\theta = \bar{\theta}} \sim \frac{\partial \theta^2}{\partial \theta^2} \Big|_{\theta = \bar{\theta}}$$

Wtedy w miarę $N \rightarrow \infty$ $\tilde{\theta}_{ML} \rightarrow \theta_0$ a więc $i \bar{\theta}$

$$\approx N \frac{1}{N} \sum \frac{\partial^2 \log p_{\theta}(x_i)}{\partial \theta^2} \Big|_{\theta = \theta_0} \rightarrow N \left\langle \frac{\partial^2 \log p_{\theta}(x_i)}{\partial \theta^2} \Big|_{\theta = \theta_0} \right\rangle$$

$$= -NF(\theta_0)$$

2 kłaki

$$\frac{\partial \log p_{\theta}^{(N)}(x)}{\partial \theta} \Big|_{\theta = \theta_0} = \frac{1}{\sqrt{N}} \sum_i \frac{\partial \log p_{\theta}(x_i)}{\partial \theta} \Big|_{\theta = \theta_0}$$

- suma losowa będąca sumą niezależnych zmiennych losowych

$$\langle \eta \rangle = 0$$

$$\begin{aligned} \langle \eta^2 \rangle &= \left\langle \left(\sum_i \frac{\partial \log p_{\theta}(x_i)}{\partial \theta} \right)^2 \right\rangle = \\ &= \sum_i \left\langle \left(\frac{\partial \log p_{\theta}(x_i)}{\partial \theta} \right)^2 \right\rangle = F(\theta_0) \end{aligned}$$

$$\eta \stackrel{N \rightarrow \infty}{\sim} N(0, F(\theta_0)^{-1})$$

Czyli:

$$\tilde{\theta}_{ML} - \theta_0 = \frac{\frac{\partial \log p_{\theta}^{(N)}(x)}{\partial \theta} \Big|_{\theta = \theta_0}}{\frac{\partial^2 \log p_{\theta}^{(N)}(x)}{\partial \theta^2} \Big|_{\theta = \bar{\theta}}} \stackrel{N \rightarrow \infty}{\sim} N\left(0, \frac{NF(\theta_0)}{NF^2(\theta_0)}\right)$$

$$(\tilde{\theta}_{ML} - \theta_0) \stackrel{N \rightarrow \infty}{\sim} N\left(\theta_0, \frac{1}{NF}\right)$$

Wniosek: 2 góry nie wiadomo jak duży

N trzeba by było ale zamykać $c \leq 1000$
wystarcza.

Przykład $\hat{\theta}$ max-likelihood do estymacji φ
jeśli $p_0 = \cos^2 \frac{\varphi}{2}$ $p_1 = \cos^2 \frac{\varphi}{2}$ ale jednak
 N odstęp od C-R mniejszy niż 1%