

2. Estymacja największej wiarygodności (max-likelihood)


Ce zrobić kilka ważnych uwag odnoszących się do
nie spełniają i nie potrzebują być optymalnego
estymatora.

2.1 Estymator największej wiarygodności

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

jest mierny x_0 to jego estymator największej
wiarygodności $\hat{\theta}$ dla którego $p_{\theta}(x)$ ma największe

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



Intuicja: wartości parametru, dla którego obserwowane
zdanie najbardziej prawdopodobne
Waga

Zobaczyć jakichś sułci max $\log p_{\theta}(x=x_0)$
a to do tego sam punkt bo log monotoniczny

Przykład

1.1.1.1.2.1

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

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

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

Ogólna własność - jeśli istnieje estymator efektywny - wystarczy C-R t_0 zwał t_0 ten sam, który znajduje max-likelihood

parametrów w modelu wystarczy t_0 :

$$\frac{d}{d\theta} \log p_\theta(x) = \lambda(\theta) \left(\underbrace{f(x; \theta)}_{\text{efektywny estymator}} \right)$$

Czyli θ dla którego minimum $t_0 \hat{\theta}_{ML} = f(x)$ (4)

W szczególności dla modeli liniowych

2.2. Asymptotyczne efektywności Max-likelihood

W ogólnosci nie ma gwarancji, że max-likelihood wystarczy C-R ani, że jest najlepszym estymatorem ale ... jeśli dużo nie zależy od obserwacji t_0 t_0

Twierdzenie

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

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

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

↑
N punktów
eksperymentu

Wtedy w granicy $N \rightarrow \infty$, estymator

ML będzie miał rozkład.

$$\hat{\Theta}_{ML} \stackrel{N \rightarrow \infty}{\sim} \mathcal{N}(\Theta_0, F^{(N)^{-1}}), \quad F^{(N)} = N \cdot F$$

czyli wyścig $C-R$, i jest nieobciążony

Lemmat:

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

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

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

Dowód Lemmat:

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

$$\sum_x p_1(x) \log \frac{p_2(x)}{p_1(x)} \leq \log \sum_x p_2(x) = 0$$

$\underbrace{\quad}_{w_i} \quad \underbrace{\quad}_{t_i}$

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

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

Dowód twierdzenia

2. Tablica likelihood: • istnieją θ_0 , 2-gie p.d.f. $\log p_{\theta}(x)$

$$\bullet \left(\frac{\partial}{\partial \theta} \log p_{\theta}(x) \right) = 0$$

• asymptotyczny niezbiżanie

Nuż $\tilde{\theta}$ - będzie naszym estymatorem, który wiążemy
dla $n \rightarrow \infty$:

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

2. prawe wielkości limit, to z tego do średniej cym

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

↑
prawdnie wartości

2. Limit

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

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

będzie odpowiadające $\tilde{\theta}_{ML} = \theta_0$

- asymptotyczny niezbiżanie $\tilde{\theta}_{ML}$

• asymptotyczny efektywności

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

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

$$\frac{\left. \frac{\partial \log p_{\theta}^{(N)}(k)}{\partial \theta} \right|_{\theta=\bar{\theta}}}{\bar{\theta} - \theta_0} = \left. \frac{\partial^2 \log p_{\theta}^{(N)}(k)}{\partial \theta^2} \right|_{\theta=\bar{\theta}}$$

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

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

$$(*) \left. \frac{\partial \log p_{\theta}^{(N)}(k)}{\partial \theta} \right|_{\theta=\theta_0} = \left. \frac{\partial^2 \log p_{\theta}^{(N)}(k)}{\partial \theta^2} \right|_{\theta=\bar{\theta}} (\theta_0 - \tilde{\theta}_{ML})$$

Wtedy:

$$\left. \frac{\partial^2 \log p_{\theta}^{(N)}(k)}{\partial \theta^2} \right|_{\theta=\bar{\theta}} = N \frac{1}{N} \sum_i \left. \frac{\partial^2 \log p_{\theta}(k_i)}{\partial \theta^2} \right|_{\theta=\bar{\theta}}$$

Wzrost $N \rightarrow \infty$ $\tilde{\theta}_{ML} \rightarrow \theta$ a więc $\bar{\theta}$

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

$$= -NF(\theta_0)$$

2 kieru

$$\left. \frac{\partial \log p_{\theta}^{(N)}(k)}{\partial \theta} \right|_{\theta=\theta_0} = \underbrace{\frac{1}{N} \sum_i \left. \frac{\partial \log p_{\theta}(k_i)}{\partial \theta} \right|_{\theta=\theta_0}}_{\text{suma niezależnych zmiennych losowych}}$$

$$\langle \dots \rangle = 0$$

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

korony

$$\langle \eta^2 \rangle = \left\langle \frac{1}{N} \left(\sum_i \frac{\partial \log p_{\theta}(x_i)}{\partial \theta} \right)^2 \right\rangle =$$

$$= \frac{1}{N} \sum_i \left\langle \left(\frac{\partial \log p_{\theta}(x_i)}{\partial x_i} \right)^2 \right\rangle_{\theta=\theta_0} = F(\theta_0)$$

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

Czyli:

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

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

Uwaga: 2 góry nie wiadomo jak duży

N trzeba by więc ale zwykłej $c \leq 1000$ wystarczy.

Przykład $\hat{\theta}$ max-likelihood to estymacja φ
 jeśli $p_0 = e^{-1/2}$ $p_1 = e^{-1/2}$ ale jeśli
 N ciastek od C-R mniejszy niż 1%