

3. Podjęcie Bayesowskie

dotychczas myśleliśmy tak: $p_{\theta}(x)$
gdzie θ oznacza nieznany parametr
 ; mówiliśmy o rachunku rachunków prawdopodobieństwa

teraz myśleliśmy tak $p(x|\theta)$

a θ jest zmienną losową z pewnym rozkładem
 a priory $p(\theta)$. Zatem podjęcie jest
 decyzją polegającą na wybraniu jednej z
 alternatyw albo gdy nie potrafimy znaleźć opt.
 estymatorów (nie istnieją...) w podejściu klasycznym

3.1 Optymalny Estymator Bayesowski

w podejściu klasycznym minimalizujemy:
 $J^2 \bar{\theta} = \int dx (\bar{\theta}(x) - \theta)^2 p_{\theta}(x)$ i wybieramy
 nieobciążonego estymatora

w podejściu Bayesowskim minimalizujemy
 średnią wariancję:

$$J^2 \bar{\theta} = \int dx d\theta (\bar{\theta}(x) - \theta)^2 \underbrace{p(x|\theta) p(\theta)}_{p(x, \theta)}$$

Korzystając z warunku Bayesa: $p(x, \theta) = p(\theta|x) p(x)$:

$$= \int \left[\int d\theta (\bar{\theta}(x) - \theta)^2 p(\theta|x) \right] p(x) dx$$

Ponieważ $p(x) \geq 0$ szukamy optymalnego

estymatora czynnika zmniejszenia dla każdego x
 + tego: $\tilde{\theta}(x)$ który minimalizuje $\int dx (\tilde{\theta}(x) - \theta)^2 p(\theta|x)$

$$\frac{d}{d\tilde{\theta}} \int d\theta (\tilde{\theta} - \theta)^2 p(\theta|x) = \int d\theta 2(\tilde{\theta} - \theta) p(\theta|x) = 0$$

⇓


$$\tilde{\theta} = \int d\theta \theta p(\theta|x)$$

Optymalny estymator: Bayesowski:

$$\tilde{\theta}(x) = \langle \theta \rangle_{p(\theta|x)}$$

wartość oczekiwana rozkładu a posteriori

$$\underbrace{p(\theta|x)}_{\text{a posteriori}} = \frac{p(x, \theta)}{p(x)} = \frac{p(x|\theta) \overbrace{p(\theta)}^{\text{a priori}}}{p(x)}$$



Właściwość optymalnego estymatora: optymalny estymator

$$\begin{aligned} \int dx \int d\theta (\theta - \tilde{\theta}(x))^2 p(\theta|x) p(x) dx &= \\ &= \int dx \left(\int d\theta (\theta - \langle \theta \rangle_{p(\theta|x)}}^2 p(\theta|x) \right) p(x) dx \\ &= \int dx \sigma^2_{\theta|p(\theta|x)} p(x) dx \end{aligned}$$

Intuicja:

W ogólności $\sigma^2_{\tilde{\theta}}$ będzie zależał od wielkości próby
 ale im więcej danych tym wpływ większy
 a priori słabszy:

$$p(\theta|x) \propto \underset{\substack{\uparrow \\ \text{sygnal} \\ \text{z} \\ \Theta}}{p(x|\theta)} \underset{\substack{\uparrow \\ \text{wielkość} \\ \text{z} \\ \Theta}}{p(\theta)} \approx p(x|\theta)$$

Jaki danych mieć estymator będzie dobrany
 w kierunku średniej wartości a priori,
 w największym problemie polepszyć Bayesowskiego:
 wybór wartości a priori!

Uwaga:

ponieważ ma dane $p(x|\theta)$, $p(\theta)$, aby
 obliczyć $p(\theta|x)$ musimy obliczyć $p(x) = \int d\theta p(x|\theta)p(\theta)$

$$p(\theta|x) = \frac{p(x|\theta)p(\theta)}{\int d\theta' p(x|\theta')p(\theta')}$$

Nie zawsze trzeba wybrać cętkę, ale
 wygodnie w miaromiarach to jest prosta normalna
 wartość $p(\theta|x)$, bo nie zależy od θ .

Przykład

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

$$p(x|\theta) = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^N e^{-\frac{1}{2\sigma^2} \sum_i (x_i - \theta)^2}$$

Wtedy gausowski rozkład a priori

$$p(\theta) = \frac{1}{\sqrt{2\pi}\sigma_\theta} e^{-\frac{1}{2\sigma_\theta^2} (\theta - \mu_\theta)^2}$$

↑
średnia a priori

$$p(x|\theta) \cdot p(\theta) = e^{-\frac{1}{2} \left[\frac{1}{\sigma^2} \sum_i (x_i - \theta)^2 + \frac{1}{\sigma_\theta^2} (\theta - M_\theta)^2 \right]}$$

Kładąc \sim postać μ :

$$p(\theta|x) = \frac{e^{-\frac{1}{2} G(\theta)}}{\int d\theta' e^{-\frac{1}{2} G(\theta')} d\theta'}$$

Przebieg $G(\theta)$:

$$G(\theta) = \theta^2 \left(\frac{N}{\sigma^2} + \frac{1}{\sigma_\theta^2} \right) - 2\theta \left(\frac{N\bar{x}}{\sigma^2} + \frac{M_\theta}{\sigma_\theta^2} \right) + \frac{1}{\sigma^2} \sum_i x_i^2 + \frac{1}{\sigma_\theta^2} M_\theta^2$$

to nie zależy od θ
wec się skracają

Mamy dane: definicji równy warunkiem od θ

$$\text{Zdefiniujmy } \sigma_{\theta|x}^2 = \frac{1}{\frac{N}{\sigma^2} + \frac{1}{\sigma_\theta^2}}$$

$$M_{\theta|x} = \left(\frac{N}{\sigma^2} \bar{x} + \frac{M_\theta}{\sigma_\theta^2} \right) \sigma_{\theta|x}^2$$

Wtedy z definicji $\sigma_{\theta|x}$ możemy mieć zależność od θ

$$G(\theta) = \frac{1}{\sigma_{\theta|x}^2} (\theta - M_{\theta|x})^2 + \dots$$

Oczywiście:

$$\dots - \frac{1}{2\sigma_{\theta|x}^2} (\theta - M_{\theta|x})^2$$

$$p(\theta|x) = \frac{1}{\sqrt{2\pi\sigma_{\theta|x}^2}} e^{-\frac{1}{2\sigma_{\theta|x}^2}(\theta - \mu_{\theta|x})^2}$$

Redukcja a posteriori jest gaussowska
(nie musimy zwracać się do problemu)

Widzimy że jego wariancja

$$\sigma_{\theta|x}^2 = \frac{1}{\frac{N}{\sigma^2} + \frac{1}{\sigma_0^2}}$$

bedzie tym wiecej im wiecej prób a
wplyw redukcji a priori bedzie mniejszy
im wiecej N , średnia z wagi

$$\begin{aligned} \mu_{\theta|x} &= \left(\frac{N}{\sigma^2} \bar{x} + \frac{1}{\sigma_0^2} \mu_0 \right) \sigma_{\theta|x}^2 = \\ &= \frac{\frac{N}{\sigma^2}}{\frac{N}{\sigma^2} + \frac{1}{\sigma_0^2}} \bar{x} + \frac{\frac{1}{\sigma_0^2}}{\frac{N}{\sigma^2} + \frac{1}{\sigma_0^2}} \mu_0 = \\ &= \alpha \cdot \bar{x} + (1-\alpha) \mu_0 \end{aligned}$$

↑
wzrost od
danych

↑
obniżenie
ze średniej a priori

Dla danych N redukcja a priori nie ma znaczenia
: $\alpha \rightarrow 1$, im α bliżej 0 tym większy
wpływ redukcji a priori.

Dla tego problem optymalny estymator
jest funkcją do redukcji a (średnia a posteriori)

$$\tilde{\theta}(x) = \mu_{\theta|x}$$

A średnia warunkowa estymator

$$\Delta^2 \tilde{\theta} = \int dx \Delta^2 \theta / p(\theta|x) p(x) = \int dx \sigma_{\theta|x}^2 p(x) = \frac{1}{\frac{N}{\sigma^2} + \frac{1}{\sigma_0^2}}$$

W granicy $N \rightarrow \infty$ $\tilde{\theta}(x) = \bar{x}$ $\Delta^2 \tilde{\theta} = \frac{\sigma^2}{N}$

Przyjmując jest procesem z rozdzielnością a priori
 dla Wtargth a posteriori Tctwe dla licznia
 estymacji itp. Tak jest dla gausowskich
 rozdzielności a priori; gausowskich procesów

3.2

3.3 Bayesian Cramer-Rao bound + bernstein von Mises etc....

Jakie są bliźniaki między podjętymi Bayesian
 a podjętymi przez informację Fisher, tzn.

Wyprowadzenie analogii mierzniarski C-R dla podjętymi Bayesian:

$$\Delta^2 \tilde{\theta} = \int dx d\theta p(x|\theta) p(\theta) (\tilde{\theta}(x) - \theta)^2 = \int dx d\theta p^2(x, \theta)$$

$$p(\theta, x) = \sqrt{p(x|\theta) p(\theta)} (\tilde{\theta}(x) - \theta)$$

Zdefiniujmy:

$$g(\theta, x) = \sqrt{\frac{p(\theta)}{p(x|\theta)}} \frac{dp(x|\theta)}{d\theta} + \sqrt{\frac{p(x|\theta)}{p(\theta)}} \frac{dp(\theta)}{d\theta} = \frac{1}{\sqrt{p(x|\theta)p(\theta)}} \frac{dp(x|\theta)p(\theta)}{d\theta}$$

$$J(\theta, x) = \sqrt{\frac{1}{p(x|\theta)}} \frac{d}{d\theta} + \sqrt{\frac{1}{p(\theta)}} \frac{d}{d\theta} = \sqrt{\frac{1}{p(x|\theta)p(\theta)}} \frac{d}{d\theta}$$

$$\int g(\theta, x)^2 d\theta dx = \int d\theta dx \frac{p(\theta)}{p(x|\theta)} \left(\frac{dp(x|\theta)}{d\theta} \right)^2 + \frac{p(x|\theta)}{p(\theta)} \left(\frac{dp(\theta)}{d\theta} \right)^2$$

$$\underbrace{\int 2 \frac{d(p(x|\theta))}{d\theta} \frac{dp(\theta)}{d\theta}}_0 = \underbrace{\int p(\theta) d\theta}_{\mathbb{F}} \mathbb{F}_\theta + \underbrace{\int d\theta \frac{1}{p(\theta)} \left(\frac{dp(\theta)}{d\theta} \right)^2}_{\mathbb{I}}$$

$$\begin{aligned} \int p(x|\theta) g(\theta, x) &= \int p(\theta) (\tilde{\theta}(x) - \theta) \frac{dp(x|\theta)}{d\theta} + p(x|\theta) (\tilde{\theta}(x) - \theta) \frac{dp(\theta)}{d\theta} \\ &= \int (\tilde{\theta}(x) - \theta) \frac{d(p(x|\theta)p(\theta))}{d\theta} = \int x \tilde{\theta}(x) \underbrace{p(x|\theta)}_1 \Big|_{\theta_-}^{\theta_+} - \int \theta \frac{dp(\theta)}{d\theta} d\theta \end{aligned}$$

$$= \underbrace{-\theta p(\theta)}_0 \Big|_{\theta_-}^{\theta_+} + \int p(\theta) d\theta = 1$$

zależy od mi breg. uż. zm. kł. $p(\theta)$

\Downarrow

$$\int_{\Theta} \tilde{\theta}^2 \geq \frac{1}{\mathbb{F} + \mathbb{I}}$$

wzrosty Fisher | wkł. od wiedzy a priori

Przykład

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

$$p(x|\theta) = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^N e^{-\frac{1}{2\sigma^2} \sum_i (x_i - \theta)^2}$$

Wiermy gausowski rozkład a priori

$$p(\theta) = \frac{1}{\sqrt{2\pi}\sigma_\theta} e^{-\frac{1}{2\sigma_\theta^2} (\theta - \mu_\theta)^2}$$

↑
średnia a priori

$$F = N \cdot \frac{1}{\sigma^2}$$

$$I = \int \frac{1}{\sqrt{2\pi}\sigma_\theta} e^{-\frac{1}{2\sigma_\theta^2} (\theta - \mu_\theta)^2} \frac{(\theta - \mu_\theta)^2}{\sigma_\theta^4} \left[\frac{1}{\sqrt{2\pi}\sigma_\theta} e^{-\frac{1}{2\sigma_\theta^2} (\theta - \mu_\theta)^2} \right]^2$$

$$= \frac{1}{\sigma_\theta^2}$$

$$\Delta_\theta^2 \geq \frac{1}{\frac{N}{\sigma^2} + \frac{1}{\sigma_\theta^2}}$$

Widzimy iż dla niewłaściwie dużych N mamy uzyskanie θ o większej dokładności niż w rzeczywistości. Odcinek ten jest wtedy naszym uzyskaniem θ .

Bernstein-Rao-Mises theorem

(tę poprawkę w pierwszym sześcianym przypadku)

Przy pierwszym zliczeniu o rozdzielności $p(\theta)$, $p(x|\theta)$

Dla N , parameŕów elementu: (x_1, \dots, x_N) ,

estymujemy Œrednie r. oblicz $\tilde{\theta}(\vec{x}) = \int d\theta p(\theta | x_1, \dots, x_N) \theta$

i $\tilde{\theta}$ dla Gaussa sŕylnego w Œwiet pr. oblicz

wzrost:

$$\sqrt{N} (\tilde{\theta}_B - \theta_c) \xrightarrow{N \rightarrow \infty} N(0, \frac{1}{F_{\theta_c}})$$

Nie ma znaczenia prior ...