

3. Podjęcie Bayesowskie

dotychczas myśleliśmy tak: $p_{\theta}(x)$
 ; mówiliśmy o rachunku rachunków prawdopodobieństwa
 równość określony możemy parametr

teraz myśleliśmy tak $p(x|\theta)$

a θ jest zmienną losową z pewnym rozkładem
 a priori $p(\theta)$. Zdecydujemy się jeśli
 chcemy podejść: estymacja wykorzystując wiedzę
 a priori albo gdy nie potrafimy znaleźć opt.
 estymatorów (nie istnieją...) w podejściu klasycznym

3.1 Optimalny Estymator Bayesowski

w podejściu klasycznym minimalizujemy:

$$J^2 \bar{\theta} = \int dx (\tilde{\theta}(x) - \theta)^2 p_{\theta}(x)$$
 i wybieramy
 najbardziej estymatora

w podejściu Bayesowskim minimalizujemy
 średnią wariancję:

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

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

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

Ponieważ $p(x) \geq 0$ szukamy optymalnego
 estymatora szukamy zmienną dla każdego x
 takiego $\tilde{\theta}(x)$ który minimalizuje $\int dx (\tilde{\theta}(x) - \theta)^2 p(\theta|x)$

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

⇓

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

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


Optymalny estymator: Bayesowski:

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

Ważną cechą jest redukcja apriory

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

a posteriori



Pro optymalnego estymatora:

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

Intuicja:

W ogólnym $\tilde{\theta}$ będzie zależał od wiedzy apriory
ale im więcej danych tym wpływ wiedzy
a priori słabiej:

$$p(\theta|x) \propto p(x|\theta) p(\theta) \approx p(x|\theta)$$

\uparrow \uparrow
 słabiej wpływa większe wpływa
 θ θ

Jaki danych mieć estymator będzie dobrany
w kierunku średniej redukcji apriory,
największy problem polega na Bayesowskiego: to
wybrać redukcję apriory!

Uwaga:

...

parametri 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 wykonać całkę, ale
 wygodnie w miaromiarach to jest prosta normalna
 rozkład $p(\theta|x)$, bo nie zależy od θ .

Przykład

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

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

Wzrost gaussowski rozkład a priori

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

↑
średnia a priori

$$p(x|\theta) \cdot p(\theta) =$$

$$= \left(\frac{1}{\sqrt{2\pi\sigma^2}}\right)^N \frac{1}{\sqrt{2\pi\sigma_\theta^2}} \cdot e^{-\frac{1}{2} \left[\frac{1}{\sigma^2} \sum_i (x_i - \theta)^2 + \frac{1}{\sigma_\theta^2} (\theta - \mu_\theta)^2 \right]}$$

Rozkład \sim prostokątny:

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

Przeprawy $G(\theta)$:

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

to nie zależy od θ
wec są składowe

Mamy dane: danejmi są pomiary niezależne od θ

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 g_θ wiemy że zależy od θ

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

Czyli:

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

Recht a posteriori tej gausowskiej (nie musimy sobie nie być problemem)

Widzimy że jego szerokość:

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

bedzie tym wiecej im wiecej prob a wplywu recht a priori bedzie mniejsze im wiecej N , srednia z koly

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

\uparrow
wzrost od danych

\uparrow
determinacja z srednia a priori

danyh θ ^{obliczenia} ze średnią μ a prici σ^2

Dla danych N realizacji a prici nie ma znaczenia
 $i \in \{1, \dots, N\}$ im bliżej 0 tym większy
 wpływ realizacji a prici.

Dla tego problem optymalny estymator
 jest funkcją do minimum a (średnia a prici)

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

A średnia wariancja estymator

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

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

Przybliżenie jest poprawie z realizacjami a prici
 dla danych a prici. Takie do liczenia
 estymatora itp. Tak jest dla gaussowskich
 realizacji a prici; gaussowskich procesów

3.2

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

Jakie są bliższe metody podjęte Bayesian
 • podjęcie przez infomację F_1 theory.

Wypracowanie metod mierzonych C-R dla podjęte Bayesian:

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

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

Zdefiniujmy:

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

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

$$\underbrace{\int 2 \frac{dp(x|\theta)}{d\theta} \frac{dp(\theta)}{d\theta}}_0 = \underbrace{\int p(\theta) d\theta}_F + \underbrace{\int d\theta \frac{1}{p(\theta)} \left(\frac{dp(\theta)}{d\theta} \right)^2}_I$$

$$\int p(\theta, x) g(\theta, x) = \int p(\theta) (\tilde{\theta}(x) - \theta) \frac{dp(x|\theta)}{d\theta} + p(x|\theta) (\tilde{\theta}(x) - \theta) \frac{dp(\theta)}{d\theta}$$

$$= \int (\tilde{\theta}(x) - \theta) \frac{d(p(x|\theta)p(\theta))}{d\theta} = \int \tilde{\theta}(x) \frac{dp(x|\theta)}{d\theta} \stackrel{!}{=} \int \theta \frac{dp(\theta)}{d\theta}$$

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

zatemby se moze breg, ze znika $p(\theta)$

\Downarrow

$$J_{\theta}^2 \geq \frac{1}{F + I}$$

wiezy Fisher

wkt. od wady a priori

Przykład

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

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

Wiemy, gausowski rozkład a priori

$$p(\theta) = \frac{1}{\sqrt{2\pi\sigma_0^2}} e^{-\frac{1}{2\sigma_0^2} (\theta - \mu_0)^2}$$

$$p(\theta) = \frac{1}{\sqrt{2\pi}\sigma_0} e^{-\frac{1}{2\sigma_0^2}(\theta - \mu_0)^2}$$

↑
średnia a priori

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

$$I = \int \frac{1}{\sqrt{2\pi}\sigma_0} e^{-\frac{1}{2\sigma_0^2}(\theta - \mu_0)^2} \frac{1}{\sigma^2} \left(\frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(\theta - \mu)^2} \right)^2$$

$$= \frac{1}{\sigma_0^2}$$

$$\Delta^2 \tilde{\theta} \geq \frac{1}{\frac{N}{\sigma^2} + \frac{1}{\sigma_0^2}}$$

Widzimy że albo niewłaściwe przybliżenie mamy uzyskanie bo w rzeczywistości uzyskujemy równość. Oczywiście wtedy mamy uzyskanie $\hat{\theta}$.

Bernstein-van-Mises theorem

(the miracle w pierwszym szeregowym przypadku)

Podajemy przydatne założenia o regularności $p(\theta)$, $p(x|\theta)$

Dla N niezależnych obserwacji (x_1, \dots, x_N) ,

istniejący średniociek $\tilde{\theta}(x) = \int d\theta p(\theta|x_1, \dots, x_N) \theta$

i $\tilde{\theta}$ dąży do Gaussa słupkowego w limit produkcyjnym

wzrost:

$$\sqrt{N} (\tilde{\theta}_B - \theta_0) \xrightarrow{N \rightarrow \infty} N(0, \frac{1}{F_{\theta\theta}})$$

Nie ma znaczenia prior...