

## 3. Podjęcie Bayesowskie

dotychczas myśleliśmy tak:  $p_{\theta}(x)$

gdzie  $\theta$  oznacza nieznany parametr  
i myśleliśmy o rachunku rachunków prawdopodobieństwa

teraz myśleliśmy tak  $p(x|\theta)$

a  $\theta$  jest zmienną losową z pewnym rozkładem  
a priori  $p(\theta)$ . Zatem podjęcie jest  
chcemy pokazać istnienie wykorzystując wiedzę  
a priori albo gdy nie potrafimy znaleźć opt.  
estymatorów (nie istnieją...) w podejściu klasycznym

## 3.1 Optymalny Estymator Bayesowski

w podejściu klasycznym minimalizujemy:

$$S^2 \bar{\theta} = \int dx (\tilde{\theta}(x) - \theta)^2 p_{\theta}(x) \quad \text{i wymagamy}$$

nieobciążoności estymatora

w podejściu Bayesowskim minimalizujemy  
średnią wariancję:

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

Korzystając z równ. 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 przez znalezienie dla każdego  $x$   
tego  $\tilde{\theta}(x)$  który minimalizuje  $\int dx (\tilde{\theta}(x) - \theta)^2 p(\theta|x)$

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

$$\Downarrow$$


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

Optymalny estymator: Bayesowski;

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

Wartość oczekiwana rozkładu a posteriori

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



Dla optymalnego estymatora: optymalny estymator

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

Intuicja:

W ogólnosci  $\mathcal{J}^2 \tilde{\theta}$  będzie zależał od wartości estymatora

ale im więcej danych tym większy wpływ wartości

a priori, stąd:

$$p(\theta|x) \propto \underbrace{p(x|\theta)}_{\text{sygnal}} \underbrace{p(\theta)}_{\text{wzrost niepewności}} \approx p(x|\theta)$$

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

Wniosek:

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

### 3.2 Modele gaussowskie

Przykład

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

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

Wzrost gaussowski wartości 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

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

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

Oczywiście:

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

Redukcja a posteriori jest gaussowska  
(nie musimy szukać nie było problemu)

Więc jest to rozwiązanie:

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

bedzie tym wzorem im więcej prób a  
wzrost redukcji a priori bedzie mniejszy  
im większe  $N$ , średnia z więcej

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

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

$$= \alpha \cdot \bar{x} + (1-\alpha) M_{\theta}$$

↑  
wzrost danych

↑  
obciążenie ze średnią a priori

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

wpłynęła na szacunki.

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

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

A średnia wariancja estymator

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

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

Przyjmując jest procesem z redukcją a priori dla danych a posteriori które dla danych całkowitego itp. Tak jest dla gaussowskich redukcji a priori; gaussowskich procesów

Bayesowski model liniowy

---

$$\vec{x} = H \vec{\theta} + \vec{w} \quad \vec{x} = [x_1, \dots, x_N]$$
$$\vec{\theta} = [\theta_1, \dots, \theta_k]$$

$$\vec{w} \sim \mathcal{N}(0, C_w)$$

↑ macierz kowariancji szumu

$$p(\vec{x} | \vec{\theta}) = \frac{1}{\sqrt{(2\pi)^N \det C_w}} e^{-\frac{1}{2} (\vec{x} - H\vec{\theta})^T C_w^{-1} (\vec{x} - H\vec{\theta})}$$

ale teraz mamy również  $\vec{\theta}$  traktujemy jako zmienną losową  $\vec{\theta} \sim \mathcal{N}(\vec{\mu}_\theta, C_\theta)$  - redukcja a priori

Czyli  $p(\vec{\theta}) = \frac{1}{\sqrt{(2\pi)^N \det C_\theta}} e^{-\frac{1}{2} (\vec{\theta} - \vec{\mu}_\theta)^T C_\theta^{-1} (\vec{\theta} - \vec{\mu}_\theta)}$

Czyli  $p(\vec{\theta}) = \frac{1}{\sqrt{(2\pi)^n \det C_\theta}} e^{-\frac{1}{2}(\vec{\theta} - \vec{\mu}_\theta)^T C_\theta^{-1} (\vec{\theta} - \vec{\mu}_\theta)}$

Chcemy obliczyć  $p(\vec{\theta} | \vec{x})$

Liwnym (z dwudziestu do stajdu i wyrazu nie):  
zależym od  $\theta$

$$p(\vec{x} | \vec{\theta}) p(\vec{\theta}) \approx e^{-\frac{1}{2} \left[ (\vec{x} - H\vec{\theta})^T C_w^{-1} (\vec{x} - H\vec{\theta}) + (\vec{\theta} - \vec{\mu}_\theta)^T C_\theta^{-1} (\vec{\theta} - \vec{\mu}_\theta) \right]}$$

$$\approx e^{-\frac{1}{2} \left[ \vec{\theta}^T H^T C_w^{-1} H \vec{\theta} - 2\vec{\theta}^T H^T C_w^{-1} \vec{x} + \vec{\theta}^T C_\theta^{-1} \vec{\theta} - 2\vec{\theta}^T C_\theta^{-1} \mu_\theta \right]}$$

Zdefiniujmy  $C_{\vec{\theta}|\vec{x}}^{-1} = H^T C_w^{-1} H + C_\theta^{-1}$

$$\mu_{\vec{\theta}|\vec{x}} = C_{\vec{\theta}|\vec{x}} \cdot (H^T C_w^{-1} \vec{x} + C_\theta^{-1} \mu_\theta)$$

$$\approx e^{-\frac{1}{2} \left( (\vec{\theta} - \mu_{\vec{\theta}|\vec{x}} \right)^T C_{\vec{\theta}|\vec{x}}^{-1} (\vec{\theta} - \mu_{\vec{\theta}|\vec{x}})}$$

Czyli rozdziel a postawiamy:

$$p(\vec{\theta} | \vec{x}) = \frac{1}{\sqrt{(2\pi)^k \det C_{\vec{\theta}|\vec{x}}}} e^{-\frac{1}{2} \left( (\vec{\theta} - \mu_{\vec{\theta}|\vec{x}} \right)^T C_{\vec{\theta}|\vec{x}}^{-1} (\vec{\theta} - \mu_{\vec{\theta}|\vec{x}})}$$

Optymalny estymator:  $\tilde{\theta} = \mu_{\vec{\theta}|\vec{x}}$

$$\Delta_{\tilde{\theta}}^2 = C_{\vec{\theta}|\vec{x}}$$

Uwaga: Jeśli  $\vec{w}, \vec{\theta}$  nie są gaussowski

to wani macina uij: estymatora

$$\tilde{\theta} = \mu_{\vec{\theta}|\vec{x}} = C_{\vec{\theta}|\vec{x}} \cdot (H^T C_w^{-1} \vec{x} + C_\theta^{-1} \mu_\theta)$$

Wtedy da kost mng

$$\Delta_{\tilde{\theta}}^2 = C_{\vec{\theta}|\vec{x}} = H^T C_w^{-1} H + C_\theta^{-1}$$

Nie koniecznie będzie to najlepszy estymator, ale  
 można pokazać że będzie najlepszy spośród  
 estymatorów liniowych tzn:

$$\hat{\theta}(\vec{x}) = \sum_n a_n x_n + a_0$$

Kroć, dobre rozwiązania i efektywne numerycznie

W granicy  $C_\theta^{-1} \rightarrow 0$  wrócimy do najlepszego  
 liniowego estymatora w estymacji klasycznej!

Mocno skorzysta z Woodbury identity:  
 $\{A, C\}$  nieosobliwe

$$\begin{aligned} (A + UCV^T)^{-1} &= \\ &= A^{-1} - A^{-1}U(C^{-1} + V^T A^{-1}U)^{-1}V^T A^{-1} \end{aligned}$$

Wtedy:

$$\begin{aligned} C_{\theta|x} &= (C_\theta^{-1} + H^T C_w^{-1} H)^{-1} = \\ &= C_\theta - C_\theta H^T (C_w + H C_\theta H^T)^{-1} H C_\theta \end{aligned}$$

Dowód:

$$\begin{aligned} (A(I + A^{-1}UCV^T))^{-1} &= \\ &= (I + A^{-1}UCV^T)^{-1} \cdot A^{-1} = \\ &= \left( \sum_n (-1)^n (A^{-1}UCV^T)^n \right) A^{-1} \\ &= \left( I - A^{-1}UCV^T + \sum_{n=2}^{\infty} (-1)^n (A^{-1}UCV^T)^n \right) A^{-1} = \\ &= \left( I - A^{-1}U \sum_{n=0}^{\infty} (CV^T A^{-1}U)^n CV^T (-1)^n \right) A^{-1} = \end{aligned}$$

$$(C^{-1} + V^T A^{-1}U)^{-1} = (I + V^T A^{-1}U)^{-1} C =$$

$$\left. \begin{aligned}
 & \left\{ \begin{aligned}
 & (C^{-1} + V^T A^{-1} U)^{-1} = (I + V^T A^{-1} U)^{-1} C = \\
 & = \sum_{m=0}^{\infty} (-1)^m (V^T A^{-1} U)^m \cdot C = \\
 & = (I - A^{-1} U (C^{-1} + V^T A^{-1} U)^{-1} V^T) A^{-1} = \\
 & = A^{-1} - A^{-1} U (C^{-1} + V^T A^{-1} U)^{-1} V^T A^{-1}
 \end{aligned} \right.
 \end{aligned}$$