

# Bayesovská modelování

(1)

- aplikace: ekonoetrie, medicína, sport, řízení, soudnictví, meteorologie...

$$P(H|D) = \frac{P(D|H) \cdot P(H)}{P(D)}$$

H - hypotéza (o parametrech)  
D - data

$$\propto P(D|H) \cdot P(H)$$

schází normalizační  
aby  $\int_0^1 H = 1$

aposteriorní pdf

model (líklost, věrohodnostní funkce)

apriorní

marginalní věrohodnost

$$= \int_H P(D|H) \cdot P(H) dH$$

$$= \sum_H \sim$$

- vyjádřit pdf příklady pro ilustraci

$H = \{ \text{poklad studenta, věk libora, rychlost auta, hustota deště, proudění, kouzlení ... } \}$

~  $D|H, D, \dots$

- regularizující role aprioria (existují - měříce vnitřní ve větru...)

- Proporce

$$P(A, B) = P(A|B) \cdot P(B)$$

$$= P(B|A) \cdot P(A)$$

$$= P(A) \cdot P(B) \quad \text{iff } A \perp B$$

$$P(A) = \int_B P(A|B) \cdot P(B) dB$$

$$= \int_B P(A, B) dB$$

## Formulácie

$X$  - data (vektor dat, ...) - napr. merané spotreby

$\theta$  - parametre (vektor) - napr. stredná hodnota spotreby ...

$\alpha$  - hyperparametre

$$X = \{x_1, \dots, x_n\}$$

$\bar{x}$  - predvypočítaná hodnota

Model  $X \sim p(X|\theta)$  - likelihood, úroveň hodnotenia  $\theta$

Apriori distribúcia  $\theta \sim p(\theta|\alpha) = p(\theta)$  -  $\alpha$  často nepísané a ani dôležité  
v budúcnosti (všetkým)

Aposteriori

$$p(\theta|X) \propto p(X|\theta) p(\theta)$$
$$= \frac{p(X|\theta) \cdot p(\theta)}{\int p(X|\theta) \cdot p(\theta) d\theta} = \frac{p(X|\theta) p(\theta)}{p(X)}$$

↳ to znamená, že  $\theta$  závisí od  $\alpha$  na  $\alpha'$

Predikcia

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

↳ vyčíslenie parametra

Joint data likelihood

$$p(x_1, \dots, x_n|\theta) = \prod_{i=1}^n p(x_i|\theta)$$

↳ Bayes:

$$p(\theta|x_1, \dots, x_n) \propto p(X|\theta) p(\theta)$$
$$\propto p(\theta) \cdot \prod_{i=1}^n p(x_i|\theta)$$

PF

2

Hemofilia - porucha sťažlivosti krvi

- valzand na chromozam X

↳ ♂ XY - nemoc if x postre

↳ ♀ XX - nemoc jen if oba x postre

⇒ fatalni

Iskruce:

Zena ?


Jed bratr - pozitivni (⇒ matka mala 1X pozitivni)

Jed otec - negativni

⇒  $\begin{cases} \theta = 1 & (\text{je nemoc}) \\ \theta = 0 & (\text{nem}) \end{cases}$

Apriori  $P(\theta = 1) = P(\theta = 0) = \frac{1}{2}$

Data: 2 syni  $\begin{cases} j_1 - \text{negativni} \\ j_2 - \text{negativni} \end{cases}$



Aposteriori  $P(\theta = 1 | \varphi) = ?$

$$P(\theta = 1 | \varphi) = \frac{P(\theta = 1) \cdot P(\varphi | \theta = 1)}{P(\varphi | \theta = 1) \cdot P(\theta = 1) + P(\varphi | \theta = 0) \cdot P(\theta = 0)}$$

$$= \frac{\left(\frac{1}{2} \cdot \frac{1}{2}\right) \cdot \frac{1}{2}}{\left(\frac{1}{2} \cdot \frac{1}{2}\right) \cdot \frac{1}{2} + (1 \cdot 1) \cdot \frac{1}{2}} = \frac{\frac{1}{8}}{\frac{1}{8} + \frac{1}{2}} = \frac{1}{5}$$

Seznamni analyza - Mat s. syn, negativni. Vyuzijeme predchizi aposteriori jako apriori → rekurzivni Bayes

$$P(\theta = 1 | j_1, j_2, j_3) \propto P(j_3 | \theta) \cdot P(\theta | j_1, j_2)$$


$$= \frac{\frac{1}{2} \cdot \frac{1}{5}}{\frac{1}{2} \cdot \frac{1}{5} + 1 \cdot \frac{4}{5}} = \frac{\frac{1}{10}}{\frac{1}{10} + \frac{8}{10}} = \frac{1}{9} \quad (4)$$

Q: Co udává tedy řídek a priori a a priori post?

A: řídek je prst vrt počátek / konec experimentu

Q: A jak to bude vypadat ve spojitém světě?

↳ Uncertainty = neurčitost



## Přechodíme od pevné k distribuci

◦ propovízané  
distribuce  $\left\{ \begin{array}{l} p_i - \text{průběh } \mathbb{1} \text{ jeví } \Sigma \text{ probitů probitů } \Omega \\ \sum_i p_i = 1, \quad p_i \in [0,1], \quad p(\emptyset) = 1 \\ p(\emptyset) = 0 \end{array} \right.$

Spjaty hustoty  $p(\omega), \omega \in \Omega \subset \mathbb{R}^n$

$$\int p(\omega) d\omega = 1$$

Když umíme prst pomocí měry, pak je naše spjatyost  $\text{dub } \Omega$

## Apriori distribuce

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

- Teoreticky máme na  $p(\theta)$  malý požadavek

↳ např.  $\theta^{\text{true}} \in \text{supp } p(\theta)$  → jinak by u nás selhalo

- Prakticky chceme

→ to nejlepší reprezentovat kvalitě (neurčitost)

→ Spicatel a priori vs. plocha (af. a priori)

→ uniformovaná a priori vlastně není a priori h.p.?

→ aby se nám dobře počítalo


→ nezapomínat na přec. a posteriori?

→ momenty, median, modus... - to je pro výpočty

Pf Ploane se na fousot site.  
 Poung  $\begin{cases} 0 & \text{- paket se worakhol} \\ 1 & \text{- wadhol} \end{cases}$

$X_i \in \{0,1\} \rightarrow$  albernikiow  
 (Bernoulli)  $p(X_i=1) = \theta \in [0,1]$

! pst q se paket wadhol ?  
 $f(x|\theta) = \theta^{x_i} (1-\theta)^{1-x_i}$




$E[X] = \theta$   
 var  $X = \theta(1-\theta)$

madme mēreul  $X = \{x_1, x_2, \dots, x_n\} = \{0, 1, 1, 0, 1\}$

Approxuo

- ↳ beta
- ↳  $\theta \sim \beta(a,b)$



$p(\theta) = \frac{1}{B(a,b)} \cdot \theta^{a-1} (1-\theta)^{b-1}$

$E[\theta] = \frac{a}{a+b}$   
 var  $\theta = \frac{ab}{(a+b)^2(a+b+1)}$

Bayes

$$\begin{aligned}
 p(\theta|x) &\propto p(x|\theta)p(\theta) \\
 &\propto p(\theta) \cdot \prod_{i=1}^n p(x_i|\theta) \\
 &\propto \frac{1}{B(a,b)} \theta^{a-1} (1-\theta)^{b-1} \cdot \prod_{i=1}^n \theta^{x_i} (1-\theta)^{1-x_i} \\
 &= \frac{1}{B(a,b)} \theta^{a-1} (1-\theta)^{b-1} \cdot \theta^{\sum x_i} (1-\theta)^{\sum (1-x_i)} \\
 &= \frac{1}{B(a,b)} \theta^{(a+\sum x_i)-1} (1-\theta)^{(b+\sum (1-x_i))-1}
 \end{aligned}$$

$\sim \beta\left(\underbrace{a+\sum x_i}_{\text{Subjekt } x_i=1}, \underbrace{b+\sum (1-x_i)}_{\text{indipēch, } x_i=0}\right)$

↳ 100%

↳ čemu jsou obsaženo?

↳ apod. nad stejnou funkcí funkční tvar jako apod.

Q: Co když je použijeme na rovnici  $x_1$ ?

A: repeat

Apropos, která vedou na apod. je stejná když  
přechází rovnice se užívají konjugované

Tady bylo  $\beta = \text{Alter} \times \beta$

Když konstanta často nemusíme dopisovat

Dokázat příkladu

↳ předtím  $p(\tilde{x}=1 | x) = \int_0^1 p(\tilde{y}=1 | \theta) p(\theta | y) d\theta$

$$= \int_0^1 \theta p(\theta | y) d\theta$$

$$= E[\theta | y] = \frac{a}{d+b}$$

# Exponential family, conjug. approx.

ET:  $p(x|\theta) = f(x) \cdot g(\theta) \cdot e^{\eta(\theta) \cdot T(x)}$

$f(x)$  → fct. stat. rez. ca  $\theta$   
 $g(\theta)$  → log-partitioa  
 $\int g(\theta) = 1$  →  $\int g(\theta) = A(\theta)$   
 $\eta(\theta)$  → par. par. (cazuri  $\eta(\theta) = \theta$ )

U.S.:  $\prod p(x_i|\theta) = p(x_1, \dots, x_n|\theta) = f(x_1) \cdot \dots \cdot f(x_n) \cdot (g(\theta))^n \cdot e^{\eta(\theta) \cdot \sum_{i=1}^n T(x_i)}$

→ data sunt "observații" re  $\mathcal{L}$  statistice locale =  
nu trebuie.  $\xi, \eta$  merge foarte bine!

ET = {  $N, \chi^2$ , Alter, Binomial, Poisson, Multis, ... }

## Conjugat approx

$p(\theta) = p(\theta|\nu, \xi) = h(\nu, \xi) \cdot [g(\theta)]^\nu \cdot e^{\eta(\theta) \xi}$

⇒ aposterior:

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

$\nu' = \nu + 1$   
 $\xi' = \xi + T(x)$

} 1 mergeu

⇒ batch (Batch) update:

$p(\theta|x_1, \dots, x_n) \propto p(\theta) \cdot \prod p(x_i|\theta)$   
 $= \dots$

$\nu' = \nu + n$   
 $\xi' = \xi + \sum T(x_i)$

- $N(\mu, \sigma^2) \rightarrow \mu \sim N(m, \tau^2)$
- Alter( $\theta$ )  $\rightarrow \theta \sim \beta(a, b)$
- Pois( $\lambda$ )  $\rightarrow \lambda \sim \text{Gamma}(a, b)$

- Binomial( $p$ )  $\rightarrow \beta(a, b)$
- Multis( $p_1, \dots, p_k$ )  $\rightarrow \text{Dir}(\alpha_1, \dots, \alpha_k)$

PF | Poisson -  $\mu$

Binomial -  $\beta$

$\mathcal{N}(\mu, \sigma^2) - \mathcal{N}(\mu, \sigma^2)$

---

PF | line. regresse

$$y_i = x_i \beta + e_i$$

$$e_i \sim \mathcal{N}(0, \sigma^2) \rightarrow \text{random!}$$

$y_i, x_i$  - beobachtete Werte,  $x_i = [\dots]$

$$b = ?$$

$$\beta = [ ]$$

$$\hookrightarrow y_i \sim \mathcal{N}(x_i \beta, \sigma^2)$$

$$p(y_i | x_i, \beta, \sigma^2) \propto \exp \left\{ -\frac{1}{2\sigma^2} (y_i - x_i \beta)^2 \right\}$$

$$= \exp \left\{ -\frac{1}{2} \left[ \sigma^{-2} y_i^2 - 2 \cdot y_i \cdot \underbrace{(x_i \beta)}_{\text{Skalar}} + (x_i \beta)(x_i \beta) \right] \right\}$$

$$\propto \exp \left\{ \text{Tr} \begin{bmatrix} -2y^T \\ \beta \beta^T \end{bmatrix} \right\}$$