

IV. Bayesovské odhady (Bayesovská statistika)

parametrický model

X_1, \dots, X_n je náhodný výběr
odleh. jai' $F(x, \theta)$ a
hustotou $f(x, \theta)$

apriorní rozdělení parametru θ (θ je náhodná veličina)

další informace o parametru θ :
doměny
zrůsnosti
jinéjší pozorování

aposteriorní rozdělení
parametru θ

Závěry o parametru θ (bodové odhady, intervalové odhady, ...)

Bayesovský přístup využívá kromě původních dat ještě informaci o parametru θ , kterou máme k dispozici nezávisle na našich datech:

- objektivní (informace z podobných úloh, z minulosti)
- subjektivní (názor, zkušenost)

Tato mimodátová informace o hodnotě neznámého parametru θ je vyjádřena pomocí před. rozdělení \Rightarrow parametr θ považujeme za náhodnou veličinu.

Výhody: využítí apriorní informace; lze použít i pro malý počet pozorování

Nevýhody: volba apriorního rozdělení (subjektivita) \Rightarrow rozdílné výsledky, nemožnost ověření správnosti

Příklad (lékařská diagnostika)

zdraví nemocí trpí 3% populace. Nemoc je diagnostikována na základě testu, který má senzitivitu 0,7 a specifitu 0,98. Určete pravděpodobnost správné diagnózy, pokud byl výsledek testu pozitivní, resp. negativní.

N = lekovaná osoba je nemocná
 $+$ = výsledek lékařské pozicivní
 $-$ = výsledek lékařské negativní

$P(N) = 0,03$... apriorní pravděpodobnost (apriorní informace)

$P(+|N) = 0,7$... senzitivita lékařů

$P(-|\bar{N}) = 0,98$... specificita lékařů

$P(N|+) = \frac{P(+|N) \cdot P(N)}{P(+|N) \cdot P(N) + P(+|\bar{N}) \cdot P(\bar{N})} = 0,52$

} aposteriorní pravděpodobnosti

$P(\bar{N}|-) = \frac{P(-|\bar{N}) \cdot P(\bar{N})}{P(-)} = 0,99$

Matematický model

X_1, \dots, X_m je náh. vektor, kde X_i má hustotu $f(x_i, \theta)$, kde $\theta \in \Theta \subset \mathbb{R}^p$ je neznámý parametr

θ je ným p -rozměrným náh. vektorem ρ hustota $g(\theta)$... apriorní hustota

nerozdělnost: $\pi(x|\theta) = \pi(x_1, \dots, x_m|\theta) = \prod_{i=1}^m f(x_i, \theta)$... podmíněná hustota n. v. $(X_1, \dots, X_m)^T$ při daném θ .

Účel (Bayesov)

Pro podmíněnou hustotu náh. vektoru θ při daném $X = (X_1, \dots, X_m)^T$ platí:

$\pi(\theta|x) = \frac{\pi(x|\theta) \cdot g(\theta)}{\int_{\Theta} \pi(x|\theta) \cdot g(\theta) d\theta}$

iž-li $\int_{\Theta} \pi(x|\theta) \cdot g(\theta) d\theta \neq 0$... aposteriorní hustota

Poznámka

φ -li Θ diskrétní náh. vellos \Rightarrow pravd. funkce $q(\Theta)$.

$$\pi(\Theta|x) = \frac{\pi(x|\Theta) \cdot q(\Theta)}{\sum_{\Theta \in \Theta} \pi(x|\Theta) \cdot q(\Theta)} \quad \varphi \text{ a priori} \text{ pravd. funkce}$$

Příklad (IQ daného člověka)

Chceme určit IQ daného člověka. Necháme jej učitel test, jeho výsledky označíme X . $X =$ výsledky je výsledky testu u daného člověka

$$X \sim N(\Theta, 100)$$

\uparrow IQ daného člověka
 \uparrow variabilita výsledků

Cíl: Odhad parametru Θ .

Klarifikace: $\hat{\Theta} = X \sim N(\Theta, 100)$ je nekonzistentní odhad parametru Θ s rozptylem 100.

Bayesovský: Rodička IQ v populaci má normální rozdělení $N(100, 225)$, tedy $\Theta \sim N(100, 225)$ a priori rozdělení parametru Θ

$$q(\Theta) = \frac{1}{\sqrt{2\pi \cdot 225}} \cdot \exp\left\{-\frac{(\Theta - 100)^2}{2 \cdot 225}\right\}, \quad \Theta \in \mathbb{R} \quad \dots \text{a priori hustota}$$

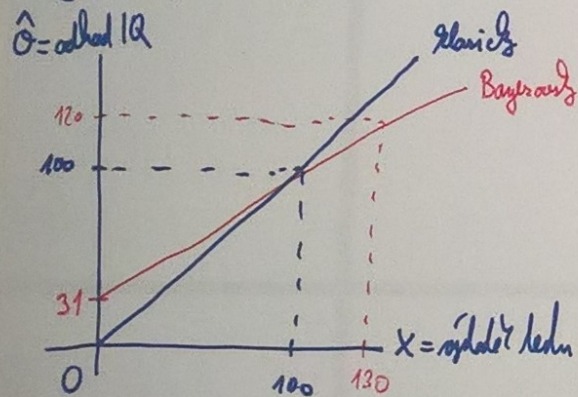
$$\pi(x|\Theta) = f(x, \Theta) = \frac{1}{\sqrt{2\pi \cdot 100}} \cdot \exp\left\{-\frac{(x - \Theta)^2}{2 \cdot 100}\right\}, \quad x \in \mathbb{R}$$

$$\pi(\theta|x) = \frac{\pi(x|\theta) \cdot q(\theta)}{\int \pi(x|\theta) \cdot q(\theta) d\theta} = \frac{\frac{1}{\sqrt{2\pi \cdot 100}} \cdot \exp\left\{-\frac{(x-\theta)^2}{2 \cdot 100}\right\} \cdot \frac{1}{\sqrt{2\pi \cdot 225}} \cdot \exp\left\{-\frac{(\theta-100)^2}{2 \cdot 225}\right\}}{\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi \cdot 100}} \cdot \exp\left\{-\frac{(x-\theta)^2}{2 \cdot 100}\right\} \cdot \frac{1}{\sqrt{2\pi \cdot 225}} \cdot \exp\left\{-\frac{(\theta-100)^2}{2 \cdot 225}\right\} d\theta} = \dots =$$

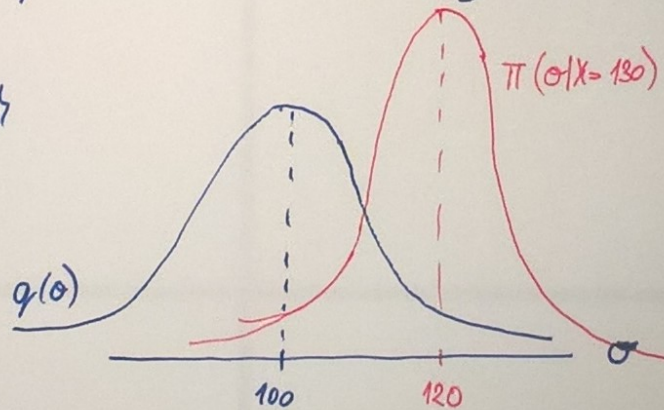
$$= \frac{1}{\sqrt{2\pi \cdot \frac{900}{13}}} \cdot \exp\left\{-\frac{(\theta - \frac{400+9x}{13})^2}{2 \cdot \frac{900}{13}}\right\}$$

aposteriorní hustota, hustota $N\left(\frac{400+9x}{13}, \frac{900}{13}\right)$.

Bayesovy bychom tedy IQ daného člověka odhadli pomocí 'střední' hodnoty aposteriorního rozdělení, tj. $\frac{400+9x}{13}$, kde x je výsledok testu (realizace n. v. X)



Model daná osoba má výsledok testu $x = 130$.



Variabilita původního (klasického) odhadu byla 100, v bayesovském případě klasika má $\frac{900}{13} = 69$.

poznámka

$$\pi(\theta|x) = \frac{\pi(x|\theta) \cdot q(\theta)}{\int \pi(x|\theta) \cdot q(\theta) d\theta}$$

normalizace na θ (normující konstanta, aby $\pi(\theta|x)$ byla hustota)

\Rightarrow protože Bayesova věta píše ne přesně

$$\pi(\theta|x) \propto \pi(x|\theta) \cdot q(\theta)$$

↑
je přímo měřena
(s měřítkem)

to nám umožní z pouhých k.o. nezávislé hustoty:

$$q(\theta) \geq 0, \text{ ale } \int_{\Theta} q(\theta) \neq 1 \text{ (je typicky } + \infty)$$

např. $q(\theta) = 1, \theta \in \mathbb{R}$, nebo $q(\theta) = 1$ pro $\theta > 0$.

Postup při baysovském modelování:

1) X_1, \dots, X_n je máh. vzájemně nezávislé rozdělení s hustotou $f(x, \theta)$, kde θ je neznámý parametr. Necht' $x = (x_1, \dots, x_n)^T$ je realizace tohoto máh. vzájemně (naše data).
Definujeme sdruženou hustotu $(X_1, \dots, X_n)^T$ jako $\pi(x|\theta) = \prod_{i=1}^n f(x_i, \theta)$.

2) zvolíme apriorní hustotu $q(\theta)$.

3) Pomocí Bayesovy věty získáme aposteriorní rozdělení $\pi(\theta|x)$.

4) Pomocí $\pi(\theta|x)$ provádíme statistickou inferenci (odhady, testy, ...)

5) Porovnáme vhodnost našeho modelu.

Volba apriorního rozdělení

apriorní hustota $q(\theta)$ by měla odrazet naši apriorní informaci o parametru θ

- ↳ $q(\theta)$ vyplývá přímo z apriorní informace
- ↳ $q(\theta)$ odhadneme pomocí histogramu, nebo jádrového odhadu
- ↳ $q(\theta)$ vyplývá nějaký parametrický model; my odhadneme jen jeho parametry

1) Informační apriorní rozdělení - neinformační

- nemáme žádnou informaci o parametru θ (všechny hodnoty jsou stejně „pravděpodobné“)



$$q(\theta) = 1, \theta \in \Theta \quad \text{může být i nezávislá hustota}$$

Příklad

X_1, \dots, X_n máh. vzhl. k $A(\theta)$, $\theta \in (0, 1)$

neinformační apriorní hustota: $q(\theta) = 1$, $\theta \in (0, 1)$.

reálná parametrizace $p := \sqrt{\theta}$, $p \in (0, 1)$... věta o transformaci $q(p) = 2p$, $p \in (0, 1)$.
prochá transformace



přímelné apriorní hustoty se liší a aposteriorní hustoty \Rightarrow rozdílné výsledky.

2) Jeffreysova apriorní hustota - neinformační

$q(\theta) \propto \sqrt{\det J(\theta)}$, kde $J(\theta)$ je Fisherova informační matice o parametru θ příslušná X_i .

Poznámka

Co kdyby volba $q(\theta)$ je aposteriorní rozdělení $\pi(\theta|x)$ stejné pro všechny reparametrizace $\pi(\theta)$.

3) Konjugované apriorní rozdělení

Necht' apriorní hustota $q(\theta)$ patří do nějaké třídy hustot \mathcal{F} . Řekneme, že $q(\theta)$ je konjugovaná vzhledem k rozhodnutí $\pi(x|\theta)$, pokud i aposteriorní hustota $\pi(\theta|x)$ patří do \mathcal{F} .

Poznámka

\mathcal{F} se volí tak, aby obsahovala co nejméně hustot.

Vhledání se provádí např. za pomoci postlačujících statistik.