

Apriorní rozdělení

Jan Kracík

jan.kratic@vsb.cz

Apriorní rozdělení (spolu s modelem) reprezentuje informaci o neznámém parametru θ , která je dostupná předem, tj. bez informace z dat.

Má zásadní význam v případě, že data jsou málo informativní.

Problém

Jak sestavit apriorní rozdělení při nedostatečném množství apriorní informace?

Obecné poznámky

- Apriorní rozdělení často volíme “přibližné”. Lepší než nic!
- Apriorní rozdělení musí nést co nejméně “špatné” informace.
- Preferujeme *kompatibilitu s apriorní informací* před jednoduchostí. V praxi volíme kompromis.

Příklad

Viz segmentace obrazu, Gibbsovo apriorní rozdělení:

$$f(x) = \frac{1}{Z(\beta)} \exp(-\beta H(x))$$

$$H(x) = - \sum_{(i,j) \in S} \left(\sum_{(k,l) \in N(i,j)} \delta(x_{ij}, x_{kl}) \right)$$

$$\sum_{(i,j) \in S} \left(\sum_{(k,l) \in N(i,j)} \delta(x_{ij}, x_{kl}) \right) = 2 \left(n^2 - \text{délka hranice} \right)$$

Apriorní rozdělení - příklad

- Zvolené apriorní rozdělení neobsahuje informace o počtu objektů a jejich poloze, jen o délce hranice: Preferuje segmentaci s kratší délkou hranice mezi oblastmi (“správná” informace).
- Apriorní rozdělení je přibližné. Lze např. zvolit vhodnější potenciál (lineární členy) i parametry.
- Obsahuje “špatnou” informaci: nejpravděpodobnější je segmentace s délkou hranice 0.

$$x \in \operatorname{Argmax} f(x) \Leftrightarrow (\forall (i, j) \in S : x_{ij} = 0) \vee (\forall (i, j) \in S : x_{ij} = 1)$$

- Díky informaci z dat je “špatná” část informace potlačena, “správná” zůstává (je kompatibilní s daty). Celkově má apriorní hustota pozitivní vliv na dobrý výsledek.
- Apriorní rozdělení lze dále vylepšit (např. hierarchický model).

V praxi často využíváme přibližné postupy.

- Θ konečná množina: subjektivní přiřazení pravděpodobností
- Θ nekonečná (nespočetná): konečné dělení množiny, dále jako pro diskrétní θ
problém: určení pravděpodobností chvostů
- někdy je jednodušší zvolit apriorní rozdělení $f(x) = \int f(x|\theta)f(\theta)d\theta$; odtud lze (někdy) určit $f(\theta)$.

Apriorní rozdělení s maximální entropií

Informace ve formě momentů, pravděpodobností zajímavých jevů, ...

Obecně:

$$\int g_k(\theta) f(\theta) d\theta = \omega_k, \quad (1)$$

kde $g_k : \Theta \rightarrow \mathbb{R}$, $\omega_k \in \mathbb{R}$, $k = 1, \dots, n$. Apriorní rozdělení pak lze volit tak, aby mělo maximální entropii vzhledem k daným omezením.

Pro diskrétní parametr θ :

$$f(\theta = \theta_i) = \frac{\exp(-\sum_k \lambda_k g_k(\theta_i))}{\sum_i \exp(-\sum_k \lambda_k g_k(\theta_i))},$$

kde λ_k jsou Lagrangeovy multiplifikátory; určíme tak, aby platila omezení (1).

Podobně pro spojitý parametr:

$$f(\theta) = \frac{\exp(-\sum_k \lambda_k g_k(\theta))}{\int \exp(-\sum_k \lambda_k g_k(\theta)) d\theta}$$

Hierarchické apriorní rozdělení

Často lze zvolit vhodné apriorní rozdělení až na neznámý parametr. K tomuto parametru přistupujeme stejně jako ke všem ostatním: považujeme jej za náhodnou veličinu a hledáme pro něj vhodné apriorní rozdělení.

Ve složitějších úlohách velmi častý přístup.

Hierarchickým apriorním rozdělením rozumíme rozdělení s hustotou $f(\theta)$ ve tvaru

$$f(\theta) = \int_{\Theta_1 \times \dots \times \Theta_n} f(\theta|\theta_1)f(\theta_1|\theta_2) \dots f(\theta_{n-1}|\theta_n)f(\theta_n)d\theta_1 \dots d\theta_n.$$

Příklad

Skrytý markovovský řetězec s neznámými pravděpodobnostmi přechodu

Pozorované veličiny: y_1, \dots, y_t

Skryté veličiny (parametry): x_1, \dots, x_t, η

$$f(y_1, \dots, y_t | x_0, \dots, x_t, \eta) = \prod_{\tau=1}^t f(y_\tau | x_\tau)$$

$$f(x_1, \dots, x_t | x_0, \eta) = \prod_{\tau=1}^t f(x_\tau | x_{\tau-1}, \eta)$$

$$f(\eta) = \dots$$

Množina (rodina) \mathcal{F} hustot pravděpodobnosti parametru θ se nazývá *konjugovaná* pro model $f(x|\theta)$, jestliže pro každé apriorní rozdělání $f(\theta)$ z \mathcal{F} a každé pozorování x je aposteriorní rozdělání $f(\theta|x)$ jakožto hustota θ rovněž z \mathcal{F} .

Příklady

Viz odhad parametru

- alternativního rozdělání,
- normálního rozdělání se známým rozptylem.

Poznámky

- Množina všech hustot θ je konjugovaná, ale nezajímavá.
- Zajímavé jsou malé a parametrizované konjugované rodiny.
- Konjugovaná rodina hustot je určena modelem.
- Ne pro každý model existují konjugovaná apriorní rozdělání.
- Výpočet aposteriorního rozdělání spočívá v určení parametru.
- Velmi praktické, ale ne vždy vhodné.

Definice

Uvažujme statistický model $f(x|\theta)$ náhodné veličiny X s hodnotami v \mathcal{X} . Nechť pro $T : \mathcal{X} \rightarrow \mathbb{R}^n$, $n \in \mathbb{N}$ platí

$$f(x|T(X) = t, \theta) = f(x|T(X) = t).$$

Statistiku T pak nazýváme *postačující statistikou modelu* $f(x|\theta)$.

Postačující statistika nese stejnou informaci o parametru θ jako náhodná veličina X .

Nechť $t = T(x)$. Pak

$$\begin{aligned} f(\theta|x) &= f(\theta|x, t) \\ &= \frac{f(x, t|\theta)f(\theta)}{\int f(x, t|\theta)f(\theta)d\theta} \\ &= \frac{f(x|t, \theta)f(t|\theta)f(\theta)}{\int f(x|t, \theta)f(t|\theta)f(\theta)d\theta} \\ &= \frac{f(x|t)f(t|\theta)f(\theta)}{f(x|t) \int f(t|\theta)f(\theta)d\theta} \\ &= \frac{f(t, \theta)f(\theta)}{\int f(t, \theta)f(\theta)d\theta} = f(\theta|t) \end{aligned}$$

Statistický model, který lze vyjádřit ve tvaru

$$f(x|\theta) = C(\theta) \exp \left(\sum_{i=1}^n B_i(\theta) S_i(x) \right),$$

kde $B_1, \dots, B_n : \Theta \rightarrow \mathbb{R}$, $S_1, \dots, S_n : \mathcal{X} \rightarrow \mathbb{R}$, $C : \Theta \rightarrow \mathbb{R}$, se nazývá *exponenciální rodina* s postačujícími statistikami S_1, \dots, S_n .

Exponenciální rodina

Apriorní hustoty ve tvaru

$$f(\theta) \propto (C(\theta))^v \exp \left(\sum_{i=1}^n B_i(\theta) V_i \right) \quad (2)$$

pro nějaké $(v, V_1, \dots, V_n) \in \mathbb{R}^{n+1}$ představují konjugované hustoty pro exponenciální rodinu s postačujícími statistikami S_1, \dots, S_n .

$$f(\theta | x_1, \dots, x_t) \propto (C(\theta))^{v+t} \exp \left(\sum_{i=1}^n B_i(\theta) \left(V_i + \sum_{\tau=1}^t S_i(x_\tau) \right) \right)$$

Aposteriorní rozdělení má stejný tvar jako apriorní pro hodnoty parametrů

$$\left(v + t, V_1 + \sum_{\tau=1}^t S_1(x_\tau), \dots, V_n + \sum_{\tau=1}^t S_n(x_\tau) \right).$$

Exponenciální rodina

Pro libovolnou posloupnost pozorování x_1, \dots, x_t je vektorová funkce

$$\left(\sum_{\tau=1}^t S_1(x_\tau), \dots, \sum_{\tau=1}^t S_n(x_\tau) \right)$$

postačují statistikou modelu

$$f(x_1, \dots, x_t | \theta) = (C(\theta))^t \exp \left(\sum_{i=1}^n B_i(\theta) \sum_{\tau=1}^t S_i(x_\tau) \right).$$

Dimenze této postačující statistiky *nezávisí* na počtu pozorování t .

Konjugovaná apriorní hustoty vybraných jednoparametrických modelů

Neznámý parametr: θ , ostatní parametry jsou známe

Model	Rozdělení x	Konjug. rozdělení θ
Normální	$\mathcal{N}(\theta, \sigma^2)$	$\mathcal{N}(\mu, \xi^2)$
Normální	$\mathcal{N}(\mu, \frac{1}{\theta})$	$\mathcal{G}(\alpha, \beta)$
Poissonovo	$\mathcal{P}(\theta)$	$\mathcal{G}(\alpha, \beta)$
Gama	$\mathcal{G}(\nu, \theta)$	$\mathcal{G}(\alpha, \beta)$
Binomické	$\mathcal{Bi}(n, \theta)$	$\mathcal{Be}(\alpha, \beta)$
Multinomické rozdělení	$\mathcal{M}_k(\theta_1, \dots, \theta_k)$	$\mathcal{D}(\alpha_1, \dots, \alpha_k)$

Neinformativní apriorní hustoty

V případě, že není k dispozici žádná vhodná apriorní informace, lze využít tzv. neinformativních apriorních rozdělání. Nejčastěji používaná jsou Jeffreysovy a referenční hustoty.

Uvažujme statistický model $f(x|\theta)$. *Fisherova informace* pro $\Theta \subset \mathbb{R}$ je definována vztahem

$$I(\theta) = E \left(\left(\frac{\partial \ln f(x|\theta)}{\partial \theta} \right)^2 \middle| \theta \right)$$

Poznámka

$$E \left(\left(\frac{\partial \ln f(x|\theta)}{\partial \theta} \right) \middle| \theta \right) = 0$$

$I(\theta)$ charakterizuje množství informace, které o parametru θ přinese pozorování x . Tato informace je závislá na θ .

Jeffreysova apriorní hustota pro model $f(x|\theta)$ je definována jako

$$f(\theta) \propto (I(\theta))^{\frac{1}{2}}.$$

Jeffreysova apriorní hustota je často nevlastní (nemá konečný integrál, nejde o skutečnou hustotu).

Jeffreysova apriorní hustota

Pro $\Theta \subset \mathbb{R}^n$ definujeme *Fisherovu informační matici*:

$$(I(\Theta))_{ij} = E \left(\left(\frac{\partial \ln f(x|\theta)}{\partial \theta_i} \right) \left(\frac{\partial \ln f(x|\theta)}{\partial \theta_j} \right) \middle| \theta \right)$$

Jeffreysova apriorní hustota:

$$f(\theta) \propto (\det I(\theta))^{\frac{1}{2}}$$