

Família de prioris conjugadas e uso sequencial do teorema de Bayes

Prof. Caio Azevedo

Família Conjugada

- Sejam
 - $F = \{p(x|\theta); \forall \theta \in \Theta\}$, uma família de modelos estatísticos (verossimilhança).
 - $p^* = \{p(\theta|\eta) \equiv p(\theta); \forall \eta \in \mathcal{B}\}$, uma família de prioris, em que η são os hiperparâmetros associados.
- Dizemos que a família p^* é conjugada à família F , se
$$\forall p(x|\theta) \in F \text{ e } p(\theta) \in p^* \rightarrow p(\theta|x) \in p^* .$$
- Na prática, essencialmente, ao identificar a respectiva verossimilhança, em função de θ , como sendo correspondente ao núcleo de alguma família de distribuições, essa família será a respectiva conjugada natural.

Exemplo: Bernoulli

- Seja $X_i | \theta \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$. Temos que:

$$L(\theta) = \theta^{n\bar{x}} (1 - \theta)^{n(1 - \bar{x})} \mathbb{1}_{(0,1)}(\theta),$$

que corresponde ao núcleo de uma distribuição beta($n\bar{x} + 1, n(1 - \bar{x}) + 1$). Assim, a distribuição beta(a, b) é a família conjugada de prioris para o modelo Bernoulli. Obs: Se $X \sim \text{beta}(a, b)$ então $f_X(x) = \frac{1}{\beta(a, b)} x^{a-1} (1-x)^{b-1} \mathbb{1}_{(0,1)}(x)$

Exemplo: exponencial

- Seja $X_i | \theta \stackrel{iid}{\sim} \exp(\theta)$. Temos que:

$$L(\theta) = \theta^{-n} e^{-n\bar{x}/\theta} \mathbb{1}_{(0,\infty)}(\theta)$$

que corresponde ao núcleo de uma distribuição $\text{IG}(n - 1, n\bar{x})$. Assim, a distribuição $\text{IG}(a, b)$ é a família conjugada de prioris para o modelo exponencial. Obs: Se $X \sim \text{IG}(a, b)$ então

$$f_X(x) = \frac{b^a}{\Gamma(a)} x^{-(a+1)} e^{-b/x} \mathbb{1}_{(0,\infty)}(x)$$

Exemplo: Poisson

- Seja $X_i | \theta \stackrel{iid}{\sim} \text{Poisson}(\theta)$. Temos que:

$$L(\theta) = \frac{\theta^{n\bar{x}} e^{-n\theta}}{\prod_{i=1}^n x_i!} \mathbb{1}_{(0,\infty)}(\theta) \propto \theta^{n\bar{x}} e^{-n\theta} \mathbb{1}_{(0,\infty)}(\theta)$$

que corresponde ao núcleo de uma distribuição gama($n\bar{x} + 1, 1/n$).

Assim, a distribuição gama(a, b) é a família de prioris conjugadas para o modelo Poisson. Obs: Se $X \sim \text{gama}(a, b)$ então

$$f_X(x) = \frac{1}{b^a \Gamma(a)} x^{a-1} e^{-x/b} \mathbb{1}_{(0,\infty)}(x)$$

Exemplo: Uniforme

- Seja $X_i | \theta \stackrel{iid}{\sim} U_{(0,\theta)}$. Temos que:

$$L(\theta) = \frac{1}{\theta^n} \prod_{i=1}^n \mathbb{1}_{(0,\theta)}(x_i)$$

Mas, note que ($\mathbf{x} = (x_1, \dots, x_n)'$):

$$\begin{aligned} \prod_{i=1}^n \mathbb{1}_{(0,\theta)}(x_i) = 1 &\leftrightarrow 0 < x_i < \theta, \forall i \leftrightarrow 0 < \min(\mathbf{x}) < \max(\mathbf{x}) < \theta \\ &\leftrightarrow 0 < y_1 < y_n < \theta \\ &\leftrightarrow \mathbb{1}_{(0,\theta)}(y_n) \mathbb{1}_{(0,y_n)}(y_1) = \mathbb{1}_{(y_1,\theta)}(y_n) \mathbb{1}_{(0,\theta)}(y_1) = 1 \end{aligned}$$

Exemplo: Uniforme

- Logo, temos que:

$$L(\theta) = \frac{1}{\theta^n} \mathbb{1}_{(0,\theta)}(y_n) \mathbb{1}_{(0,y_n)}(y_1) \propto \frac{1}{\theta^n} \mathbb{1}_{(y_n, \infty)}(\theta),$$

que corresponde ao núcleo de uma distribuição Pareto($n - 1, y_n$).

Obs: Se $X \sim \text{Pareto}(a, b)$ então $f_X(x) = \frac{ab^a}{x^{a+1}} \mathbb{1}_{[b, \infty)}(x)$

Exemplo: Normal

- Seja $X_i | \sigma^2 \stackrel{iid}{\sim} N(\mu, \sigma^2)$, (μ conhecido). Temos que

$$\begin{aligned}L(\sigma^2) &= \frac{1}{(2\pi)^{n/2} (\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2} \mathbb{1}_{(0,\infty)}(\sigma^2) \\&\propto (\sigma^2)^{-n/2} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2} \mathbb{1}_{(0,\infty)}(\sigma^2)\end{aligned}$$

que corresponde ao núcleo de uma distribuição

$\text{IG}(n/2 - 1, \sum_{i=1}^n (x_i - \mu)^2 / 2)$. Assim, a distribuição $\text{IG}(a, b)$ é a família conjugada de prioris para o modelo normal com a média conhecida. Obs: Se $X \sim \text{IG}(a, b)$ então

$$f_X(x) = \frac{b^a}{\Gamma(a)} x^{-(a+1)} e^{-b/x} \mathbb{1}_{(0,\infty)}(x)$$

Exemplo: Normal

- Seja $X_i | \mu \stackrel{iid}{\sim} N(\mu, \sigma^2)$, (σ^2 conhecido). Temos que

$$\begin{aligned} L(\mu) &= \frac{1}{(2\pi)^{n/2} (\sigma^2)^{n/2}} e^{-\frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu)^2} \mathbb{1}_{\mathcal{R}}(\mu) \\ &\propto e^{-\frac{1}{\sigma^2} (\sum_{i=1}^n x_i^2 - 2\mu \sum_{i=1}^n x_i + n\mu^2)} \mathbb{1}_{\mathcal{R}}(\mu) \\ &\propto e^{-\frac{n}{\sigma^2} (\mu^2 - 2\mu \bar{x})} \mathbb{1}_{\mathcal{R}}(\mu) \propto e^{-\frac{n}{\sigma^2} (\mu - \bar{x})^2} \mathbb{1}_{\mathcal{R}}(\mu) \end{aligned}$$

que corresponde ao núcleo de uma distribuição $N(\bar{x}, \sigma^2/n)$. Assim, a distribuição $N(a, b^2)$ é a família conjugada de prioris para o modelo normal com a variância conhecida. Obs: Se $X \sim N(a, b^2)$ então

$$f_X(x) = \frac{1}{\sqrt{2\pi b^2}} e^{-\frac{1}{2b^2}(x-a)^2} \mathbb{1}_{(0,\infty)}(x)$$

Família Conjugada na família exponencial

- Dizemos que uma variável aleatória $X|\theta$ pertence à **família exponencial** (k paramétrica) se sua distribuição puder ser escrita como

$$p(x|\theta) = \exp \left\{ \sum_{j=1}^k c_j(\theta) t_j(x) + d(\theta) \right\} a(x) \mathbb{1}_A(x)$$

em que A não depende de θ .

- Seja $X_i|\theta \stackrel{i.i.d}{\sim} X|\theta, i = 1, \dots, n$, então

$$p(\mathbf{x}|\theta) = \exp \left\{ \sum_{j=1}^k c_j(\theta) \sum_{i=1}^n t_j(x_i) + nd(\theta) \right\} \prod_{i=1}^n a(x_i) \mathbb{1}_A(\mathbf{x})$$

Família Conjugada na família exponencial (cont.)

- Neste caso, a família conjugada de prioris é dada por

$$p(\theta) = \exp \left\{ \sum_{j=1}^k c_j(\theta) \alpha_j + \beta d(\theta) \right\} k(\beta, \boldsymbol{\alpha}) \mathbb{1}_{\Theta}(\theta)$$

em que $k(\beta, \boldsymbol{\alpha})$ é uma constante de normalização adequada e
 $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_k)'$.

Família Conjugada na família exponencial (cont.)

- Consequentemente, a posteriori será dada por (exercício):

$$p(\theta|\mathbf{x}) = \exp \left\{ \sum_{j=1}^k c_j(\boldsymbol{\theta}) \left[\alpha_j + \sum_{i=1}^n t_j(x_i) \right] + (\beta + n)d(\boldsymbol{\theta}) \right\} \times k(\beta + n, \boldsymbol{\alpha}, \mathbf{t}) \mathbb{1}_{\Theta}(\boldsymbol{\theta})$$

em que $k(\beta + n, \boldsymbol{\alpha}, \mathbf{t})$ é uma constante de normalização adequada e $\mathbf{t} = (t_1, \dots, t_n)'$.

Uso sequencial do teorema de Bayes

- Sejam $\mathbf{x}_1 = (x_1, \dots, x_n)'$ e $\mathbf{x}_2 = (x_{n+1}, \dots, x_{n+m})'$ amostras de $X|\theta$, tomadas sequencialmente e defina $\mathbf{x}^* = (\mathbf{x}'_1, \mathbf{x}'_2)'$.
- Dessa forma, temos que

$$p(\theta|\mathbf{x}_1) = \frac{p(\mathbf{x}_1|\theta)p(\theta)}{p(\mathbf{x}_1)}, p(\mathbf{x}_1) = \int_{\Theta} p(\mathbf{x}_1|\theta)p(\theta)d\theta$$

- Por outro lado, temos que

$$p(\theta|\mathbf{x}^*) = \frac{p(\mathbf{x}^*|\theta)p(\theta)}{p(\mathbf{x}^*)}, p(\mathbf{x}^*) = \int_{\Theta} p(\mathbf{x}^*|\theta)p(\theta)d\theta$$

Uso sequencial do teorema de Bayes (cont.)

- Agora, note que $p(\mathbf{x}^*|\theta) = p((\mathbf{x}'_1, \mathbf{x}'_2)'|\theta) = p(\mathbf{x}_2|\theta, \mathbf{x}_1)p(\mathbf{x}_1|\theta)$.

Logo, vem que

$$\begin{aligned} p(\theta|\mathbf{x}^*) &= \frac{p(\mathbf{x}_2|\theta, \mathbf{x}_1)p(\mathbf{x}_1|\theta)p(\theta)}{p(\mathbf{x}^*)} = \frac{p(\mathbf{x}_2|\theta, \mathbf{x}_1)}{\frac{p(\mathbf{x}^*)}{p(\mathbf{x}_1)}} \frac{p(\mathbf{x}_1|\theta)p(\theta)}{p(\mathbf{x}_1)} \\ &= \frac{p(\mathbf{x}_2|\theta, \mathbf{x}_1)}{\int_{\Theta} p(\mathbf{x}_2|\theta, \mathbf{x}_1) \frac{p(\mathbf{x}_1|\theta)p(\theta)}{p(\mathbf{x}_1)} d\theta} p(\theta|\mathbf{x}_1) \\ &= \frac{p(\mathbf{x}_2|\theta, \mathbf{x}_1)}{\int_{\Theta} p(\mathbf{x}_2|\theta, \mathbf{x}_1)p(\theta|\mathbf{x}_1)d\theta} p(\theta|\mathbf{x}_1) = \frac{p(\mathbf{x}_2|\theta, \mathbf{x}_1)p(\theta|\mathbf{x}_1)}{p(\mathbf{x}_2)} \end{aligned}$$