

Família Exponencial

Tópicos de Estatística

José Passos

ISEG-UTL

29 de Outubro de 2011



- Alguns dos modelos paramétricos estudados até aqui são casos particulares de uma classe mais geral de modelos designada família exponencial.
- Esta família tem um conjunto de propriedades que são extremamente úteis.

Definição: família exponencial com um parâmetro

Dizemos que $\{f(x | \theta) : \theta \in \Theta\}$ é uma família exponencial se existem funções $\eta(\theta)$, $c(\theta)$, $t(x)$ e $h(x)$ tal que,

$$f(x | \theta) = h(x)c(\theta) \exp \{\eta(\theta)t(x)\}$$

onde $\theta \in \Theta$, $\{x : f(x|\theta) > 0\}$ não depende de θ , $h(x) \geq 0$, $t(x)$ não pode depender de θ , $c(\theta) \geq 0$ e $\eta(\theta)$ não pode depender de x .

Definição: família exponencial com um ou mais parâmetros

Dizemos que $\{f(x | \theta) : \theta \in \Theta\}$ é uma família exponencial se existem funções $\eta(\theta)$, $c(\theta)$, $t(x)$ e $h(x)$ tal que,

$$f(x | \theta) = h(x)c(\theta) \exp \left\{ \sum_{j=1}^k \eta_j(\theta)t_j(x) \right\}$$

onde $x \in \chi$ (que pode ser discreto ou contínuo), $\theta \in \Theta$, o suporte não depende de θ , $h(x) \geq 0$, $t_j(x)$ são funções reais dependentes apenas de x (não podem depender de θ), $c(\theta) \geq 0$ e $\eta_j(\theta)$ são funções reais dependentes apenas de θ (não podem depender de x).

Notas:

- Se $f(x | \theta)$ é da família exponencial o suporte, $\{x : f(x | \theta) > 0\}$, não depende de θ ;
- Esta família tem como casos particulares a normal, exponencial, gama, qui-quadrado, beta, binomial, Poisson, geométrica, etc.;
- Para verificar se uma família de funções densidade ou funções probabilidade está na família exponencial, temos que identificar as funções $h(x)$, $c(\theta)$, $\eta_j(\theta)$ e $t_j(x)$ e mostrar que a família se pode expressar na forma anterior;
- As k estatísticas t_1, \dots, t_k são suficientes.

- Se $\dim(\theta) = k$ diz-se que a família exponencial é completa
- Se $\dim(\theta) > k$ os parâmetros não são identificáveis
- Se $\dim(\theta) < k$ diz-se que a família exponencial é curvada
- Numa família exponencial curvada o estimador da máxima verosimilhança não é estatística suficiente pelo que a inferência deve ser condicionada numa estatística ancilária.
- Qualquer família paramétrica que seja suficientemente lisa (smooth) pode ser aproximada localmente, em torno do verdadeiro valor do parâmetro por uma família exponencial curvada.

Exemplos:

- Distribuição binomial:

$$\begin{aligned}f(x | p) &= \binom{n}{x} p^x (1-p)^{n-x} \\&= \binom{n}{x} (1-p)^n \left(\frac{p}{1-p}\right)^x \\&= \binom{n}{x} (1-p)^n \exp \left\{ \log \left(\frac{p}{1-p}\right) x \right\}.\end{aligned}$$

com $k = 1$, $h(x) = \binom{n}{x}$, $c(p) = (1-p)^n$, $\eta_1(p) = \log \left(\frac{p}{1-p}\right)$ e $t_1(x) = x$.

- Distribuição Poisson:

$$\begin{aligned}f(x | \theta) &= \frac{e^{-\theta} \theta^x}{x!} \\ &= \frac{1}{x!} e^{-\theta} \exp\{x \log \theta\}.\end{aligned}$$

com $k = 1$, $h(x) = 1/x!$, $c(\theta) = e^{-\theta}$, $\eta_1(\theta) = \log \theta$ e $t_1(x) = x$.

- Distribuição Normal:

$$\begin{aligned} f(x | \mu, \sigma^2) &= (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{(x - \mu)^2}{2\sigma^2} \right\} \\ &= (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{\mu^2}{2\sigma^2} \right\} \exp \left\{ \frac{\mu}{\sigma^2} x - \frac{1}{2\sigma^2} x^2 \right\}. \end{aligned}$$

com $k = 2$, $h(x) = 1$, $c(\mu, \sigma^2) = (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{\mu^2}{2\sigma^2} \right\}$,
 $\eta_1(\mu, \sigma^2) = \mu/\sigma^2$, $\eta_2(\mu, \sigma^2) = -1/(2\sigma^2)$, $t_1(x) = x$ e
 $t_2(x) = x^2$.

Teorema: momentos

Se X é v.a. com f.d.p. ou f.p. na família exponencial, tem-se,

$$E \left(\sum_{j=1}^k \frac{\partial \eta_j(\theta)}{\partial \theta_l} t_j(X) \right) = -\frac{\partial}{\partial \theta_l} \log c(\theta)$$

$$\text{Var} \left(\sum_{j=1}^k \frac{\partial \eta_j(\theta)}{\partial \theta_l} t_j(X) \right) = -\frac{\partial^2}{\partial \theta_l^2} \log c(\theta) - E \left(\sum_{j=1}^k \frac{\partial^2 \eta_j(\theta)}{\partial \theta_l^2} t_j(X) \right)$$

Nota: a vantagem deste resultado está no facto de os momentos poderem ser calculados com recurso a diferenciação, em vez de integração.

Exemplo: distribuição binomial,

- Para calcular $E(X)$, tem-se, do exemplo anterior,

$$\frac{d}{dp} \eta_1(p) = \frac{d}{dp} \log \frac{p}{1-p} = \frac{1}{p(1-p)}$$
$$\frac{d}{dp} \log c(p) = \frac{d}{dp} n \log(1-p) = -\frac{n}{1-p}$$

e portanto,

$$E\left(\frac{1}{p(1-p)} X\right) = \frac{n}{1-p}$$

donde se tira $E(X) = np$.

Exemplo (cont.):

- Para calcular $Var(X)$, tem-se,

$$\frac{d^2}{dp^2} \eta_1(p) = \frac{2p - 1}{p^2(1 - p)^2}$$
$$\frac{d^2}{dp^2} \log c(p) = -\frac{n}{(1 - p)^2}$$

e portanto,

$$Var\left(\frac{1}{p(1 - p)}X\right) = \frac{n}{(1 - p)^2} - E\left(\frac{2p - 1}{p^2(1 - p)^2}X\right)$$

donde se tira $Var(X) = np(1 - p)$.

Definição: família exponencial com parametrização natural

A família exponencial é por vezes parametrizada do seguinte modo,

$$f(x | \eta) = h(x) c^*(\eta) \exp \left\{ \sum_{j=1}^k \eta_j t_j(x) \right\}$$

O conjunto

$$\mathfrak{N} = \left\{ \eta = (\eta_1, \dots, \eta_k) : \int_{\mathcal{X}} h(x) \exp\left(\sum_{j=1}^k \eta_j t_j(x)\right) dx < \infty \right\}$$

designa-se espaço parâmetro natural da família.

Exemplo: distribuição binomial:

- Espaço parâmetro: $\Theta = \{p : 0 < p < 1\}$
- Espaço parâmetro natural: $\aleph = \{\eta_1 : -\infty < \eta_1 < +\infty\}$
onde $\eta_1 = \eta_1(p) = \log \frac{p}{1-p}$. Na parametrização natural tem-se,

$$f(x | \eta_1) = \binom{n}{x} (1 + e^{\eta_1})^{-n} \exp \{ \eta_1 x \}.$$

Exemplo: distribuição normal:

- Espaço parâmetro:

$$\Theta = \left\{ (\mu, \sigma^2) : -\infty < \mu < +\infty, 0 < \sigma^2 < +\infty \right\}$$

- Espaço parâmetro natural:

$$\aleph = \left\{ (\eta_1, \eta_2) : -\infty < \eta_1 < +\infty, -\infty < \eta_2 < 0 \right\} \text{ onde}$$
$$\eta_1 = \mu/\sigma^2 \text{ e } \eta_2 = -1/(2\sigma^2)$$

Corolário:

Se X é v.a. com f.d.p. ou f.p. na família exponencial com parâmetro natural $\eta_1 = \eta_1(\theta)$, tem-se (para simplificar e sem perda de generalidade vamos fazer $k = 1$ e $\dim(\theta) = 1$),

$$E(t_1(X)) = -\frac{d}{d\eta_1} \log c(\eta_1)$$

$$Var(t_1(X)) = -\frac{d^2}{d\eta_1^2} \log c(\eta_1)$$

Nota: a parametrização natural simplifica o cálculo dos momentos da estatística $t_1(X)$.

- Dada uma amostra casual de dimensão n , a f.d.p. ou f.p. $f(x_1, \dots, x_n)$, está na família exponencial se,

$$f(x_1, \dots, x_n | \theta) = c(\theta)^n \left(\prod_{i=1}^n h(x_i) \right) \exp \left\{ \sum_{j=1}^k \eta_j(\theta) \sum_{i=1}^n T_j(x_i) \right\}$$

- Fazendo $T_j(x) = \sum_{i=1}^n T_j(x_i)$, as v.a.'s $T_j(X)$, $j = 1, \dots, k$ designam-se estatísticas naturais,

$$f(x_1, \dots, x_n | \theta) = c(\theta)^n \left(\prod_{i=1}^n h(x_i) \right) \exp \left\{ \sum_{j=1}^k \eta_j(\theta) T_j(x) \right\}$$

Teorema: distribuição conjunta de $T_j(X)$

A distribuição conjunta de $T_1(X), \dots, T_k(X)$ é da família exponencial com parâmetro natural $\eta_1(\theta), \dots, \eta_k(\theta)$

- Casella and Berger (2002), *Statistical Inference*, 2nd Edition, Duxbury (pags. 111-116).