

# Família exponencial

Prof. Caio Azevedo

# Introdução aos MLG

- A classe (mais simples) dos MLG é definida, essencialmente, por duas componentes, a saber:
  - A distribuição da variável resposta, a qual deve pertencer à família exponencial (parte aleatória).
  - Uma função de ligação, a qual associa, de forma adequada, a média da variável resposta ( $\mu_i$ ) à um preditor linear ( $g(\mu_i) = \mathbf{X}_i' \boldsymbol{\beta}$ ).
  - Portanto, a classe de MRNLH é uma caso particular dos MLG (exercício).

## Família exponencial (FE) bi-paramétrica

- Dizemos que uma v.a.  $Y$  (discreta ou contínua) pertence à família exponencial biparamétrica, nesse caso usaremos a notação

$$Y \sim FE(\theta, \phi),$$

se sua fdp é dada por:

$$f_Y(y; \theta, \phi) = \exp\{\phi[y\theta - b(\theta)] + c(y, \phi)\} \mathbb{1}_A(y). \quad (1)$$

# Família exponencial (FE) bi-paramétrica

- (cont.) em que  $\theta \in \Theta \subset \mathcal{R}$  (espaço paramétrico de  $\theta$ ),  
 $b(\theta) : \mathcal{R} \rightarrow \mathcal{R}$ ,  $c(y, \phi) : A \times \mathcal{R}^+ \rightarrow \mathcal{R}$ ,  $A$  é um conjunto que não depende nem de  $\theta$  nem de  $\phi$  (esta é uma das condições de regularidade) e, por sua vez,  $\phi (\phi > 0)$  é o parâmetro de precisão.
- Também trabalharemos com distribuições pertencentes à família exponencial uniparamétrica, ou seja, se  $\phi = 1$ . Nesse caso usamos  $Y \sim FE(\theta)$ .

# Comentários

- Diversas distribuições pertencem à essa classe, p.e.: normal, normal inversa, gama (exponencial), Poisson, binomial (Bernoulli), binomial negativa (sob certas circunstâncias), dentre outras.
- Há diversas outras classes de distribuições: família Tweedie, família de localização-escala, mistura de escala, mistura de localização-escala, família elíptica, dentre outras.
- Na maior parte do curso, nos concentraremos em distribuições pertencente à FE.

# Comentários

- Quando a média (valor esperado) não aparecer explicitamente na fdp (função de probabilidade, caso discreto; função densidade de probabilidade, ou simplesmente, densidade, caso contínuo), reparametrizaremos-na de modo a deixar a média explícita.
- Podemos também utilizar a notação  $f_Y(\cdot)$  para designar uma fdp, ou seja, sem especificar seus parâmetros.

# Propriedades

- Se  $Y \sim FE(\theta, \phi)$ , então:
  - $\mathcal{E}(Y) = \mu = b'(\theta) = \frac{\partial b(\theta)}{\partial \theta}$ .
  - $V(Y) = \phi^{-1}V(\mu)$ , em que  $V(\mu) = \frac{d\mu}{d\theta} = b''(\theta) = \frac{\partial^2 b(\theta)}{\partial \theta^2}$  (por isso  $\phi$  é chamado de parâmetro de precisão, pois quanto maior seu valor, menor será a variância).  $V(\cdot)$  é chamada de função de variância.
- Vamos provar as duas propriedades acima, para o caso contínuo. A prova para o caso discreto é análoga, substituindo-se as integrais por somatórios. Utilizaremos a notação  $f_Y(y; \theta, \phi) \equiv f_Y(y)$

# Propriedades

- Sob certas condições de regularidade, temos que

$$\mathcal{E}\left(\frac{\partial \ln f_Y(Y)}{\partial \theta}\right) = 0 \text{ e } \mathcal{E}\left(\frac{\partial^2 \ln f_Y(Y)}{\partial \theta^2}\right) = -\mathcal{E}\left[\left(\frac{\partial \ln f_Y(Y)}{\partial \theta}\right)^2\right].$$

- (Primeira igualdade) Temos que :

$$\begin{aligned}\mathcal{E}\left(\frac{\partial \ln f_Y(Y)}{\partial \theta}\right) &= \int_A \frac{\partial \ln f_Y(y)}{\partial \theta} f_Y(y) dy \\ &= \int_A \frac{\partial f_Y(y)}{\partial \theta} \frac{1}{f_Y(y)} f_Y(y) dy = \int_A \frac{\partial f_Y(y)}{\partial \theta} dy \\ &\stackrel{*}{=} \underbrace{\frac{\partial}{\partial \theta} \int_A f_Y(y) dy}_1 = \frac{\partial}{\partial \theta} 1 = 0.\end{aligned}\tag{2}$$

\* sob as condições de regularidade.

# Propriedades

- Por outro lado, note que (regra da derivada do quociente)

$$\begin{aligned}\frac{\partial^2 \ln f_Y(y)}{\partial \theta^2} &= \frac{\partial}{\partial \theta} \left( \frac{\partial \ln f_Y(y)}{\partial \theta} \right) = \frac{\partial}{\partial \theta} \left( \frac{\partial f_Y(y)}{\partial \theta} \frac{1}{f_Y(y)} \right) \\ &= \left[ \frac{\partial^2 f_Y(y)}{\partial \theta^2} f_Y(y) - \left( \frac{\partial f_Y(y)}{\partial \theta} \right)^2 \right] \frac{1}{f_Y^2(y)} \\ &= \frac{\partial^2 f_Y(y)}{\partial \theta^2} \frac{1}{f_Y(y)} - \left( \frac{\partial f_Y(y)}{\partial \theta} \right)^2 \frac{1}{f_Y(y)^2} \\ &= \frac{\partial^2 f_Y(y)}{\partial \theta^2} \frac{1}{f_Y(y)} - \left( \frac{\partial \ln f_Y(y)}{\partial \theta} \right)^2.\end{aligned}\tag{3}$$

- (Segunda igualdade) Tomando o valor esperado de (3), vem que (\* sob as condições de regularidade.):

$$\begin{aligned}
 \mathcal{E} \left( \frac{\partial^2 \ln f_Y(Y)}{\partial \theta^2} \right) &= \int_A \frac{\partial^2 \ln f_Y(y)}{\partial \theta^2} f_Y(y) dy \\
 &= \int_A \left( \frac{\partial^2 f_Y(y)}{\partial \theta^2} \frac{1}{f_Y(y)} - \left( \frac{\partial \ln f_Y(y)}{\partial \theta} \right)^2 \right) f_Y(y) dy \\
 &= \int_A \frac{\partial^2 f_Y(y)}{\partial \theta^2} dy - \int_A \left( \frac{\partial \ln f_Y(y)}{\partial \theta} \right)^2 f_Y(y) dy \\
 &\stackrel{*}{=} \underbrace{\frac{\partial^2}{\partial \theta^2} \int_A f_Y(y) dy}_{1} - \mathcal{E} \left[ \left( \frac{\partial \ln f_Y(y)}{\partial \theta} \right)^2 \right] \\
 &= \frac{\partial^2}{\partial \theta^2} 1 - \mathcal{E} \left[ \left( \frac{\partial \ln f_Y(y)}{\partial \theta} \right)^2 \right] = -\mathcal{E} \left[ \left( \frac{\partial \ln f_Y(y)}{\partial \theta} \right)^2 \right].
 \end{aligned}$$

- Por (2), temos também que:

$$\begin{aligned}
 \mathcal{V} \left( \frac{\partial \ln f_Y(Y)}{\partial \theta} \right) &= \mathcal{E} \left[ \left( \frac{\partial \ln f_Y(Y)}{\partial \theta} \right)^2 \right] - \underbrace{\left[ \mathcal{E} \left( \frac{\partial \ln f_Y(Y)}{\partial \theta} \right) \right]}_0^2 \\
 &= \mathcal{E} \left[ \left( \frac{\partial \ln f_Y(Y)}{\partial \theta} \right)^2 \right] = -\mathcal{E} \left( \frac{\partial^2 \ln f_Y(Y)}{\partial \theta^2} \right) \quad (5)
 \end{aligned}$$

- Voltando à fdp da FE (Equação (1)), temos que

$$\frac{\partial \ln f_Y(y)}{\partial \theta} = \phi [y - b'(\theta)]. \quad (6)$$

$$\frac{\partial^2 \ln f_Y(y)}{\partial \theta^2} = -\phi b''(\theta). \quad (7)$$

- De (2) em (6), vem que:

$$\begin{aligned}\mathcal{E} \left( \frac{\partial \ln f_Y(y)}{\partial \theta} \right) &= \mathcal{E} [\phi(Y - b'(\theta))] = 0 \\ &\rightarrow \mathcal{E}(Y) = b'(\theta).\end{aligned}$$

- De (4) e (5) em (7), temos que:

$$\begin{aligned}\mathcal{V} \left( \frac{\partial \ln f_Y(Y)}{\partial \theta} \right) &= -\mathcal{E} \left( \frac{\partial^2 \ln f_Y(Y)}{\partial \theta^2} \right) \\ &\rightarrow \mathcal{V}[\phi(Y - b'(\theta))] = -\mathcal{E}(-\phi b''(\theta)) \\ &\rightarrow \phi^2 \mathcal{V}(Y) = \phi b''(\theta) \rightarrow \mathcal{V}(Y) = b''(\theta) \phi^{-1}.\end{aligned}$$

## Exemplo: Poisson

- Seja  $Y \sim \text{Poisson}(\lambda)$ ,  $\lambda > 0$ , então  $A = \{0, 1, 2, \dots\}$  e

$$\begin{aligned}f_Y(y) &= \frac{e^{-\lambda} \lambda^y}{y!} = \exp\{y \ln(\lambda) - \lambda - \ln(y!)\} \\&= \exp\{\phi[y\theta - b(\theta)] + c(y, \phi)\}\end{aligned}$$

em que  $\theta = \ln(\lambda)$ ,  $b(\theta) = \exp(\theta)$ ,  $\phi = 1$ ,  $c(y, \phi) = -\ln(y!)$

## Exemplo: Binomial

- Seja  $Y^*$  a proporção de sucessos em  $n$  ensaios de Bernoulli independentes. Logo, temos que  $nY^* \sim \text{binomial}(n, \mu)$ . Nesse caso  $E(Y^*) = \mu, \mu \in (0, 1)$ . Além disso, em termos da distribuição de  $Y^*$  (exercício), temos que  $A = \{0, 1/n, 2/n, \dots, 1\}$  e

$$\begin{aligned} f_{Y^*}(y^*) &= \binom{n}{ny^*} \mu^{ny^*} (1 - \mu)^{n-ny^*} = \exp \left\{ \ln \binom{n}{ny^*} + ny^* \ln \left( \frac{\mu}{1-\mu} \right) \right. \\ &\quad \left. + n \ln(1-\mu) \right\} = \exp \left\{ n \left[ y^* \ln \left( \frac{\mu}{1-\mu} \right) + \ln(1-\mu) \right] \right. \\ &\quad \left. + \ln \binom{n}{ny^*} \right\} = \exp \{ \phi[y\theta - b(\theta)] + c(y, \phi) \} \end{aligned}$$

## Exemplo: Binomial

- (Cont.) em que  
 $\theta = \ln\left(\frac{\mu}{1-\mu}\right)$ ,  $b(\theta) = \ln(1 + e^\theta)$ ,  $\phi = n$ ,  $c(y^*, \phi) = \ln\binom{\phi}{y^*}$ .
- Se  $n = 1$ ,  $Y^* = Y \sim \text{Bernoulli}(\mu)$ .

## Exemplo: Normal

- Seja  $Y \sim N(\mu, \sigma^2)$ , temos que  $A = (-\infty, \infty)$ ,  
 $\mu \in (-\infty, \infty)$ ,  $\sigma^2 \in (0, \infty)$  e

$$\begin{aligned}f_Y(y) &= \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2\sigma^2}(y-\mu)^2\right\} \\&= \exp\left\{\frac{1}{\sigma^2}\left(\mu y - \frac{\mu^2}{2}\right) - \frac{1}{2}\left[\ln(2\pi\sigma^2) + \frac{y^2}{\sigma^2}\right]\right\} \\&= \exp\{\phi[y\theta - b(\theta)] + c(y, \phi)\}\end{aligned}$$

em que  $\theta = \mu$ ,  $b(\theta) = \frac{\theta^2}{2}$ ,  $\phi = \sigma^{-2}$ ,  $c(y, \phi) = \frac{1}{2}\ln(\phi/2\pi) - \frac{\phi y^2}{2}$ .

## Exemplo: gama

- Usualmente consideramos  $Y \sim \text{gama}(a, b)$ ,  $a, b > 0$ , em que  $\mathcal{E}(Y) = ab$ ,  $\mathcal{V}(Y) = ab^2$  e  $A = (-\infty, \infty)$ . Nesse caso  $f(Y) = \frac{1}{\Gamma(a)b^a}y^{a-1}e^{-y/b}$ .
- Contudo, consideraremos uma outra parametrização que consiste em escrever a fdp de  $Y$  em termos de  $\mu = \mathcal{E}(Y)$  e do parâmetro de precisão  $\phi$  (exercício), de modo que

$$CV(Y) = DP(Y)/\mathcal{E}(Y) = \phi^{-1/2},$$

o que implica que

$$\mathcal{V}(Y) = V(\mu)/\phi.$$

## Exemplo: Gamma

■ Assim:

$$\begin{aligned}f_Y(y) &= \frac{1}{\Gamma(\phi)} \left( \frac{\phi y}{\mu} \right)^{\phi} \exp \left\{ -\frac{\phi y}{\mu} \right\} y^{-1} = \exp \left\{ \phi \left[ -\frac{y}{\mu} - \ln(\mu) \right] \right. \\&\quad \left. - \ln \Gamma(\phi) + \phi \ln(\phi y) - \ln(y) \right\} = \exp \left\{ \phi \left[ -\frac{y}{\mu} - \ln(\mu) \right] \right. \\&\quad \left. + (\phi - 1) \ln(y) + \phi \ln(\phi) - \ln \Gamma(\phi) \right\} \\&= \exp \{ \phi [y\theta - b(\theta)] + c(y, \phi) \}\end{aligned}$$

## Exemplo: Gamma

- (cont.) em que  $\theta = -1/\mu$ ,  $b(\theta) = -\ln(-\theta)$  e  
 $c(y, \phi) = (\phi - 1)\ln(y) + \phi\ln(\phi) - \ln\Gamma(\phi)$ .
- Se  $\phi = 1$ , então  $Y \sim \exp(\mu)$ .
- Se  $\phi = k/2$  e  $\mu = k$ , então  $Y \sim \chi^2_{(k)}$ .

## Exemplo: normal inversa

- Seja  $Y \sim NI(\mu, \phi)$ ,  $\mu, \phi > 0$ , então  $A = (0, \infty)$  e

$$f_Y(y) = \frac{\phi^{1/2}}{\sqrt{2\pi y^3}} \exp\left\{-\frac{\phi(y - \mu)^2}{2\mu^2 y}\right\}.$$

- Exercício: colocar na forma da família exponencial.

# Principais distribuições pertencentes à FE

Distribuição	$b(\theta)$	$\theta$	$\phi$	$V(\mu)$
Normal	$\theta^2/2$	$\mu$	$\sigma^{-2}$	1
Poisson	$e^\theta$	$\ln \mu$	1	$\mu$
Binomial	$\ln(1 + e^\theta)$	$\ln(\mu/(1 - \mu))$	n	$\mu(1 - \mu)$
Gama	$-\ln(-\theta)$	$-1/\mu$	$1/(CV^2)$	$\mu^2$
N.Inversa	$-\sqrt{-2\theta}$	$-1/2\mu^2$	$\phi$	$\mu^3$

OBS:  $\theta$  é chamado de parâmetro canônico.