

# Extensões ao modelo normal

Tiago M. Magalhães

Departamento de Estatística - ICE-UFJF

Juiz de Fora, 10 de junho de 2024



# Roteiro

- 1 Introdução
- 2 Modelo lineares generalizados
- 3 Modelos de dispersão
- 4 Estudo de simulação
- 5 Referências bibliográficas



# Roteiro

- 1 Introdução
- 2 Modelo lineares generalizados
- 3 Modelos de dispersão
- 4 Estudo de simulação
- 5 Referências bibliográficas



# Modelo de regressão linear

Como nós vimos, existem fenômenos (variável resposta,  $Y$ ) que podem ser descritos por um conjunto de variáveis preditoras ( $\mathbf{x}$ ), da seguinte forma:

$$Y \sim \mathcal{D}(\mu, \sigma^2),$$



# Modelo de regressão linear

Como nós vimos, existem fenômenos (variável resposta,  $Y$ ) que podem ser descritos por um conjunto de variáveis preditoras ( $\mathbf{x}$ ), da seguinte forma:

$$Y \sim \mathcal{D}(\mu, \sigma^2),$$

em que  $\mu = \mathbf{x}^\top \boldsymbol{\beta}$  e  $\sigma^2$  são a média e variância, respectivamente, da distribuição de  $Y$ ,  $\mathbf{x} = (x_1, x_2, \dots, x_p)^\top$  é um vetor conhecido,  $\boldsymbol{\beta} = (\beta_1, \beta_2, \dots, \beta_p)^\top$  e  $\sigma^2$  são parâmetros desconhecidos.



# Modelo de regressão linear

Como nós vimos, existem fenômenos (variável resposta,  $Y$ ) que podem ser descritos por um conjunto de variáveis preditoras ( $\mathbf{x}$ ), da seguinte forma:

$$Y \sim \mathcal{D}(\mu, \sigma^2),$$

em que  $\mu = \mathbf{x}^\top \boldsymbol{\beta}$  e  $\sigma^2$  são a média e variância, respectivamente, da distribuição de  $Y$ ,  $\mathbf{x} = (x_1, x_2, \dots, x_p)^\top$  é um vetor conhecido,  $\boldsymbol{\beta} = (\beta_1, \beta_2, \dots, \beta_p)^\top$  e  $\sigma^2$  são parâmetros desconhecidos.



# Modelo de regressão linear

É conveniente escrever a relação entre as variáveis resposta e preditora da seguinte forma:

$$Y = \mathbf{x}^T \boldsymbol{\beta} + \varepsilon,$$

em que  $\varepsilon \sim \mathcal{D}(0, \sigma^2)$ , sendo  $\varepsilon$  denominado de erro.



# Modelo de regressão linear

É conveniente escrever a relação entre as variáveis resposta e preditora da seguinte forma:

$$Y = \mathbf{x}^T \boldsymbol{\beta} + \varepsilon,$$

em que  $\varepsilon \sim \mathcal{D}(0, \sigma^2)$ , sendo  $\varepsilon$  denominado de erro.



# Modelo de regressão linear

A fim de estimar  $\beta$  e  $\sigma^2$ , e explicitar a relação entre as variáveis, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^\top)^\top$ , i.e.,  $(Y_1, \mathbf{x}_1^\top)^\top, (Y_2, \mathbf{x}_2^\top)^\top, \dots, (Y_n, \mathbf{x}_n^\top)^\top$ ,



# Modelo de regressão linear

A fim de estimar  $\beta$  e  $\sigma^2$ , e explicitar a relação entre as variáveis, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^\top)^\top$ , i.e.,  $(Y_1, \mathbf{x}_1^\top)^\top, (Y_2, \mathbf{x}_2^\top)^\top, \dots, (Y_n, \mathbf{x}_n^\top)^\top$ , com

$$Y_\ell \sim \mathcal{D}(\mu_\ell, \sigma^2),$$

em que  $\mu_\ell = \mathbf{x}_\ell^\top \beta$ ,  $\mathbf{x}_\ell = (x_{\ell 1}, x_{\ell 2}, \dots, x_{\ell p})^\top$ ,  $\ell = 1, 2, \dots, n$ .



# Modelo de regressão linear

A fim de estimar  $\beta$  e  $\sigma^2$ , e explicitar a relação entre as variáveis, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^\top)^\top$ , i.e.,  $(Y_1, \mathbf{x}_1^\top)^\top, (Y_2, \mathbf{x}_2^\top)^\top, \dots, (Y_n, \mathbf{x}_n^\top)^\top$ , com

$$Y_\ell \sim \mathcal{D}(\mu_\ell, \sigma^2),$$

em que  $\mu_\ell = \mathbf{x}_\ell^\top \beta$ ,  $\mathbf{x}_\ell = (x_{\ell 1}, x_{\ell 2}, \dots, x_{\ell p})^\top$ ,  $\ell = 1, 2, \dots, n$ .



# Modelo de regressão linear

De forma alternativa,

$$Y_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta} + \varepsilon_\ell,$$

com  $\varepsilon_\ell \sim \mathcal{D}(0, \sigma^2)$ ,  $\ell = 1, 2, \dots, n$ .



# Modelo de regressão linear

De forma alternativa,

$$Y_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta} + \varepsilon_\ell,$$

com  $\varepsilon_\ell \sim \mathcal{D}(0, \sigma^2)$ ,  $\ell = 1, 2, \dots, n$ . Em outras palavras,  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  são variáveis aleatórias independentes e com a mesma variância  $\sigma^2$ .



# Modelo de regressão linear

De forma alternativa,

$$Y_l = \mathbf{x}_l^T \boldsymbol{\beta} + \varepsilon_l,$$

com  $\varepsilon_l \sim \mathcal{D}(0, \sigma^2)$ ,  $l = 1, 2, \dots, n$ . Em outras palavras,  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  são variáveis aleatórias independentes e com a mesma variância  $\sigma^2$ .



# Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;



# Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;
- Os erros:



# Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;
- Os erros:
  - têm média zero;

# Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;
- Os erros:
  - têm média zero;
  - variância constante;



# Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;
- Os erros:
  - têm média zero;
  - variância constante;
  - e são não correlacionados.



# Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;
- Os erros:
  - têm média zero;
  - variância constante;
  - e são não correlacionados.



# Modelo de regressão normal linear

Para obter estimativas dos parâmetros, somente é necessário usar os estimadores oriundos do **método de mínimos quadrados**. Porém, para uso de procedimentos inferenciais, como testes de hipóteses ou intervalos de confiança,



# Modelo de regressão normal linear

Para obter estimativas dos parâmetros, somente é necessário usar os estimadores oriundos do **método de mínimos quadrados**. Porém, para uso de procedimentos inferenciais, como testes de hipóteses ou intervalos de confiança, a seguinte suposição precisa ser adicionada:

$$Y_\ell \sim \mathcal{N}(\mu_\ell, \sigma^2),$$



# Modelo de regressão normal linear

Para obter estimativas dos parâmetros, somente é necessário usar os estimadores oriundos do **método de mínimos quadrados**. Porém, para uso de procedimentos inferenciais, como testes de hipóteses ou intervalos de confiança, a seguinte suposição precisa ser adicionada:

$$Y_\ell \sim \mathcal{N}(\mu_\ell, \sigma^2),$$

de forma equivalente,  $Y_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta} + \varepsilon_\ell$ , com  $\varepsilon_\ell \sim \mathcal{N}(0, \sigma^2)$ ,  $\ell = 1, 2, \dots, n$ .



# Modelo de regressão normal linear

Para obter estimativas dos parâmetros, somente é necessário usar os estimadores oriundos do **método de mínimos quadrados**. Porém, para uso de procedimentos inferenciais, como testes de hipóteses ou intervalos de confiança, a seguinte suposição precisa ser adicionada:

$$Y_\ell \sim \mathcal{N}(\mu_\ell, \sigma^2),$$

de forma equivalente,  $Y_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta} + \varepsilon_\ell$ , com  $\varepsilon_\ell \sim \mathcal{N}(0, \sigma^2)$ ,  $\ell = 1, 2, \dots, n$ .



# Modelo de regressão normal linear

Isto é, nós precisamos assumir que a natureza dos dados segue uma distribuição normal. Como ela é uma distribuição simétrica, com suporte na reta real,



# Modelo de regressão normal linear

Isto é, nós precisamos assumir que a natureza dos dados segue uma distribuição normal. Como ela é uma distribuição simétrica, com suporte na reta real, supor normalidade em situações em que os dados são assimétricos, estritamente positivos ou de contagem pode não ser razoável.



# Modelo de regressão normal linear

Isto é, nós precisamos assumir que a natureza dos dados segue uma distribuição normal. Como ela é uma distribuição simétrica, com suporte na reta real, supor normalidade em situações em que os dados são assimétricos, estritamente positivos ou de contagem pode não ser razoável.



# Roteiro

- 1 Introdução
- 2 Modelo lineares generalizados**
- 3 Modelos de dispersão
- 4 Estudo de simulação
- 5 Referências bibliográficas



# Família exponencial de distribuições

Uma alternativa para ajustar os dados é supor que a sua natureza segue alguma distribuição da **família exponencial**, i.e.,

$$Y \sim \mathcal{FE}(\theta, \phi).$$



# Família exponencial de distribuições

Uma alternativa para ajustar os dados é supor que a sua natureza segue alguma distribuição da **família exponencial**, i.e.,

$$Y \sim \mathcal{FE}(\theta, \phi).$$



# Família exponencial de distribuições

Se  $Y \sim \mathcal{FE}(\theta, \phi)$ , sua função densidade de probabilidade pode ser escrita da seguinte forma

$$f(y) = \exp \{ \phi [y\theta - b(\theta) + c(y)] + d(y, \phi) \},$$



# Família exponencial de distribuições

Se  $Y \sim \mathcal{FE}(\theta, \phi)$ , sua função densidade de probabilidade pode ser escrita da seguinte forma

$$f(y) = \exp \{ \phi [y\theta - b(\theta) + c(y)] + d(y, \phi) \},$$

em que  $b(\cdot)$ ,  $c(\cdot)$  e  $d(\cdot, \cdot)$  são funções conhecidas,



# Família exponencial de distribuições

Se  $Y \sim \mathcal{FE}(\theta, \phi)$ , sua função densidade de probabilidade pode ser escrita da seguinte forma

$$f(y) = \exp \{ \phi [y\theta - b(\theta) + c(y)] + d(y, \phi) \},$$

em que  $b(\cdot)$ ,  $c(\cdot)$  e  $d(\cdot, \cdot)$  são funções conhecidas,  $\theta$  e  $\phi$ , são, respectivamente, os parâmetros canônico e de precisão



# Família exponencial de distribuições

Se  $Y \sim \mathcal{FE}(\theta, \phi)$ , sua função densidade de probabilidade pode ser escrita da seguinte forma

$$f(y) = \exp \{ \phi [y\theta - b(\theta) + c(y)] + d(y, \phi) \},$$

em que  $b(\cdot)$ ,  $c(\cdot)$  e  $d(\cdot, \cdot)$  são funções conhecidas,  $\theta$  e  $\phi$ , são, respectivamente, os parâmetros canônico e de precisão (o inverso,  $\phi^{-1}$ , é o parâmetro de dispersão).



# Família exponencial de distribuições

Se  $Y \sim \mathcal{FE}(\theta, \phi)$ , sua função densidade de probabilidade pode ser escrita da seguinte forma

$$f(y) = \exp \{ \phi [y\theta - b(\theta) + c(y)] + d(y, \phi) \},$$

em que  $b(\cdot)$ ,  $c(\cdot)$  e  $d(\cdot, \cdot)$  são funções conhecidas,  $\theta$  e  $\phi$ , são, respectivamente, os parâmetros canônico e de precisão (o inverso,  $\phi^{-1}$ , é o parâmetro de dispersão).



# Família exponencial de distribuições

Além disso, se  $Y \sim \mathcal{FE}(\theta, \phi)$ , então

$$\mathbb{E}(Y) = \frac{db(\theta)}{d\theta} = \mu \text{ e } \text{Var}(Y) = \phi^{-1} \frac{d^2 b(\theta)}{d\theta^2} = \phi^{-1} V(\mu),$$



# Família exponencial de distribuições

Além disso, se  $Y \sim \mathcal{FE}(\theta, \phi)$ , então

$$\mathbb{E}(Y) = \frac{db(\theta)}{d\theta} = \mu \text{ e } \text{Var}(Y) = \phi^{-1} \frac{d^2 b(\theta)}{d\theta^2} = \phi^{-1} V(\mu),$$

em que  $V = V(\mu)$  é denominada de função de variância e



# Família exponencial de distribuições

Além disso, se  $Y \sim \mathcal{FE}(\theta, \phi)$ , então

$$\mathbb{E}(Y) = \frac{db(\theta)}{d\theta} = \mu \text{ e } \text{Var}(Y) = \phi^{-1} \frac{d^2 b(\theta)}{d\theta^2} = \phi^{-1} V(\mu),$$

em que  $V = V(\mu)$  é denominada de função de variância e  $\theta = \int V^{-1} d\mu = q(\mu)$ ,



# Família exponencial de distribuições

Além disso, se  $Y \sim \mathcal{FE}(\theta, \phi)$ , então

$$\mathbb{E}(Y) = \frac{db(\theta)}{d\theta} = \mu \text{ e } \text{Var}(Y) = \phi^{-1} \frac{d^2b(\theta)}{d\theta^2} = \phi^{-1} V(\mu),$$

em que  $V = V(\mu)$  é denominada de função de variância e  $\theta = \int V^{-1} d\mu = q(\mu)$ , sendo  $q(\mu)$  uma função conhecida um-a-um de  $\mu$ .



# Família exponencial de distribuições

Além disso, se  $Y \sim \mathcal{FE}(\theta, \phi)$ , então

$$\mathbb{E}(Y) = \frac{db(\theta)}{d\theta} = \mu \text{ e } \text{Var}(Y) = \phi^{-1} \frac{d^2b(\theta)}{d\theta^2} = \phi^{-1} V(\mu),$$

em que  $V = V(\mu)$  é denominada de função de variância e  $\theta = \int V^{-1} d\mu = q(\mu)$ , sendo  $q(\mu)$  uma função conhecida um-a-um de  $\mu$ . As Tabelas 1 e 2 apresentam as quantidades mencionadas até aqui para cinco casos.



# Família exponencial de distribuições

Além disso, se  $Y \sim \mathcal{FE}(\theta, \phi)$ , então

$$\mathbb{E}(Y) = \frac{db(\theta)}{d\theta} = \mu \text{ e } \text{Var}(Y) = \phi^{-1} \frac{d^2 b(\theta)}{d\theta^2} = \phi^{-1} V(\mu),$$

em que  $V = V(\mu)$  é denominada de função de variância e  $\theta = \int V^{-1} d\mu = q(\mu)$ , sendo  $q(\mu)$  uma função conhecida um-a-um de  $\mu$ . As Tabelas 1 e 2 apresentam as quantidades mencionadas até aqui para cinco casos.



Tabela 1: Distribuições discretas pertencentes à  $\mathcal{FE}$ .

Quantidade	Binomial	Poisson
$\theta$	$\log \frac{\mu}{1 - \mu}$	$\log \mu$
$\phi$	$n$	1
$b(\theta)$	$\log(1 + e^\theta)$	$e^\theta$
$c(y)$	0	0
$d(y, \phi)$	$\log \binom{\phi}{\phi y}$	$-\log y!$
$V(\mu)$	$\mu(1 - \mu)$	$\mu$

Tabela 2: Distribuições contínuas pertencentes à  $\mathcal{FE}$ .

Quantidade	Gama	Normal	Normal inversa
$\theta$	$-\frac{1}{\mu}$	$\mu$	$-\frac{1}{2\mu^2}$
$\phi$	$\frac{1}{CV^2}$	$\frac{1}{\sigma^2}$	$\phi$
$b(\theta)$	$-\log(-\theta)$	$\frac{\theta^2}{2}$	$-\sqrt{-2\theta}$
$c(y)$	$\log y$	$-\frac{y^2}{2}$	$-\frac{1}{2y}$
$d(y, \phi)$	$-\log y + \phi \log \phi - \log \Gamma(\phi)$	$\frac{1}{2} \log \frac{\phi}{2\pi}$	$\frac{1}{2} \log \frac{\phi}{2\pi y^3}$
$V(\mu)$	$\mu^2$	1	$\mu^3$



# Família exponencial de distribuições

Partindo da mesma ideia de um modelo de regressão linear, nós podemos supor que  $\mu = \mathbf{x}^\top \boldsymbol{\beta}$ . Todavia, notem que, não há nenhuma restrição sobre os vetores  $\mathbf{x}$  e  $\boldsymbol{\beta}$ .



# Família exponencial de distribuições

Partindo da mesma ideia de um modelo de regressão linear, nós podemos supor que  $\mu = \mathbf{x}^\top \boldsymbol{\beta}$ . Todavia, notem que, não há nenhuma restrição sobre os vetores  $\mathbf{x}$  e  $\boldsymbol{\beta}$ .

Isso pode ser problemático, pois a média de uma Bernoulli, por exemplo, está contida no intervalo entre 0 e 1



# Família exponencial de distribuições

Partindo da mesma ideia de um modelo de regressão linear, nós podemos supor que  $\mu = \mathbf{x}^\top \boldsymbol{\beta}$ . Todavia, notem que, não há nenhuma restrição sobre os vetores  $\mathbf{x}$  e  $\boldsymbol{\beta}$ .

Isso pode ser problemático, pois a média de uma Bernoulli, por exemplo, está contida no intervalo entre 0 e 1 e o resultado de  $\mathbf{x}^\top \boldsymbol{\beta}$  poderá estar fora desse intervalo.



# Família exponencial de distribuições

Partindo da mesma ideia de um modelo de regressão linear, nós podemos supor que  $\mu = \mathbf{x}^\top \boldsymbol{\beta}$ . Todavia, notem que, não há nenhuma restrição sobre os vetores  $\mathbf{x}$  e  $\boldsymbol{\beta}$ .

Isso pode ser problemático, pois a média de uma Bernoulli, por exemplo, está contida no intervalo entre 0 e 1 e o resultado de  $\mathbf{x}^\top \boldsymbol{\beta}$  poderá estar fora desse intervalo.



# Família exponencial de distribuições

Para contornar esse problema, ao invés de nós ajustarmos a média, nós podemos ajustar uma função dela, i.e.,

$$g(\mu) = \mathbf{x}^\top \boldsymbol{\beta},$$



# Família exponencial de distribuições

Para contornar esse problema, ao invés de nós ajustarmos a média, nós podemos ajustar uma função dela, i.e.,

$$g(\mu) = \mathbf{x}^\top \boldsymbol{\beta},$$

em que  $g(\cdot)$  é uma função invertível e conhecida, sendo ela denominada de **função de ligação**.



# Família exponencial de distribuições

Para contornar esse problema, ao invés de nós ajustarmos a média, nós podemos ajustar uma função dela, i.e.,

$$g(\mu) = \mathbf{x}^\top \boldsymbol{\beta},$$

em que  $g(\cdot)$  é uma função invertível e conhecida, sendo ela denominada de **função de ligação**.



# Modelos lineares generalizados

Propostos por Nelder e Wedderburn (1972), os modelos lineares generalizados (MLG) supõem um fenômeno  $Y$ ,



# Modelos lineares generalizados

Propostos por Nelder e Wedderburn (1972), os modelos lineares generalizados (MLG) supõem um fenômeno  $Y$ , tal que  $Y \sim \mathcal{FE}(\theta, \phi)$ , com  $g(\mu) = \mathbf{x}^\top \boldsymbol{\beta}$ .



# Modelos lineares generalizados

Propostos por Nelder e Wedderburn (1972), os modelos lineares generalizados (MLG) supõem um fenômeno  $Y$ , tal que  $Y \sim \mathcal{FE}(\theta, \phi)$ , com  $g(\mu) = \mathbf{x}^\top \boldsymbol{\beta}$ .



# Modelos lineares generalizados

Da mesma forma o que ocorre no modelo de regressão linear, para explicitar a relação entre as variáveis, é necessário estimar os parâmetros do modelo, para isso, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^T)^T$ ,



# Modelos lineares generalizados

Da mesma forma o que ocorre no modelo de regressão linear, para explicitar a relação entre as variáveis, é necessário estimar os parâmetros do modelo, para isso, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^T)^T$ , i.e.,  $(Y_1, \mathbf{x}_1^T)^T, (Y_2, \mathbf{x}_2^T)^T, \dots, (Y_n, \mathbf{x}_n^T)^T$ ,



# Modelos lineares generalizados

Da mesma forma o que ocorre no modelo de regressão linear, para explicitar a relação entre as variáveis, é necessário estimar os parâmetros do modelo, para isso, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^\top)^\top$ , i.e.,  $(Y_1, \mathbf{x}_1^\top)^\top, (Y_2, \mathbf{x}_2^\top)^\top, \dots, (Y_n, \mathbf{x}_n^\top)^\top$ , com

$$Y_\ell \sim \mathcal{FE}(\theta_\ell, \phi),$$



# Modelos lineares generalizados

Da mesma forma o que ocorre no modelo de regressão linear, para explicitar a relação entre as variáveis, é necessário estimar os parâmetros do modelo, para isso, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^\top)^\top$ , i.e.,  $(Y_1, \mathbf{x}_1^\top)^\top, (Y_2, \mathbf{x}_2^\top)^\top, \dots, (Y_n, \mathbf{x}_n^\top)^\top$ , com

$$Y_\ell \sim \mathcal{FE}(\theta_\ell, \phi),$$

em que  $g(\mu_\ell) = \mathbf{x}_\ell^\top \beta$ ,  $\mathbf{x}_\ell = (x_{\ell 1}, x_{\ell 2}, \dots, x_{\ell p})^\top$ ,  $\ell = 1, 2, \dots, n$ .



# Modelos lineares generalizados

Da mesma forma o que ocorre no modelo de regressão linear, para explicitar a relação entre as variáveis, é necessário estimar os parâmetros do modelo, para isso, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^\top)^\top$ , i.e.,  $(Y_1, \mathbf{x}_1^\top)^\top, (Y_2, \mathbf{x}_2^\top)^\top, \dots, (Y_n, \mathbf{x}_n^\top)^\top$ , com

$$Y_\ell \sim \mathcal{FE}(\theta_\ell, \phi),$$

em que  $g(\mu_\ell) = \mathbf{x}_\ell^\top \boldsymbol{\beta}$ ,  $\mathbf{x}_\ell = (x_{\ell 1}, x_{\ell 2}, \dots, x_{\ell p})^\top$ ,  $\ell = 1, 2, \dots, n$ .



# Modelos lineares generalizados

Os estimadores do vetor  $\beta$  e escalar  $\phi$  são obtidos pelo método da máxima verossimilhança.



# Roteiro

- 1 Introdução
- 2 Modelo lineares generalizados
- 3 Modelos de dispersão**
- 4 Estudo de simulação
- 5 Referências bibliográficas



# Família de dispersão

Uma segunda alternativa para ajustar um conjunto de dados é supor que a sua natureza segue alguma distribuição da **família de dispersão**, i.e.,

$$Y \sim \mathcal{FD}(\theta, \phi).$$

# Família de dispersão

Uma segunda alternativa para ajustar um conjunto de dados é supor que a sua natureza segue alguma distribuição da **família de dispersão**, i.e.,

$$Y \sim \mathcal{FD}(\theta, \phi).$$

# Família de dispersão

Se  $Y \sim \mathcal{FD}(\theta, \phi)$ , sua função densidade de probabilidade (ou função de probabilidade) pode ser escrita da seguinte forma



# Família de dispersão

Se  $Y \sim \mathcal{FD}(\theta, \phi)$ , sua função densidade de probabilidade (ou função de probabilidade) pode ser escrita da seguinte forma

$$f(y) = \exp \{ \phi t(y, \theta) + a(y, \phi) \},$$



# Família de dispersão

Se  $Y \sim \mathcal{FD}(\theta, \phi)$ , sua função densidade de probabilidade (ou função de probabilidade) pode ser escrita da seguinte forma

$$f(y) = \exp \{ \phi t(y, \theta) + a(y, \phi) \},$$

em que  $t(\cdot, \cdot)$  e  $a(\cdot)$  são funções conhecidas,  $\theta \in \mathbb{R}$  e  $\phi > 0$ .



# Família de dispersão

Se  $Y \sim \mathcal{FD}(\theta, \phi)$ , sua função densidade de probabilidade (ou função de probabilidade) pode ser escrita da seguinte forma

$$f(y) = \exp \{ \phi t(y, \theta) + a(y, \phi) \},$$

em que  $t(\cdot, \cdot)$  e  $a(\cdot)$  são funções conhecidas,  $\theta \in \mathbb{R}$  e  $\phi > 0$ .



Tabela 3: Distribuições da família de dispersão.

Distribuição	Suporte
Binomial	$\{0, 1, \dots, n\}$
Gama	$(0, \infty)$
Normal inversa	$(0, \infty)$
Normal	$(-\infty, \infty)$
Poisson	$\{0, 1, \dots\}$
Secante hiperbólica generalizada	$(-\infty, \infty)$
Binomial negativa	$\{0, 1, \dots\}$
Família exponencial	$\subset \mathbb{R}$
Modelos Morris	$\subset \mathbb{R}$
Classe Tweedie	$\subset \mathbb{R}$

Tabela 4: Distribuições da família de dispersão.

Distribuição	Suporte
Hipérbole	$(0, \infty)$
Hiperbólica	$(-\infty, \infty)$
Leipnik	$(-1, 1)$
Log-gama	$(0, \infty)$
Normal inversa recíproca	$(0, \infty)$
Gama inversa	$(0, \infty)$
Leipnik transformada	$(0, 1)$
Simplex	$(0, 1)$
von-Mises	$(0, 2\pi)$

# Família de dispersão

Partindo da mesma ideia de um modelo de regressão linear, nós podemos supor que  $\theta = \mathbf{x}^\top \boldsymbol{\beta}$ . Todavia, notem que, não há nenhuma restrição sobre os vetores  $\mathbf{x}$  e  $\boldsymbol{\beta}$ .



# Família de dispersão

Partindo da mesma ideia de um modelo de regressão linear, nós podemos supor que  $\theta = \mathbf{x}^\top \boldsymbol{\beta}$ . Todavia, notem que, não há nenhuma restrição sobre os vetores  $\mathbf{x}$  e  $\boldsymbol{\beta}$ .

Isso pode ser problemático, pois se  $\theta$  está contido no intervalo entre 0 e 1, o resultado de  $\mathbf{x}^\top \boldsymbol{\beta}$  precisará estar dentro desse intervalo.



# Família de dispersão

Partindo da mesma ideia de um modelo de regressão linear, nós podemos supor que  $\theta = \mathbf{x}^\top \boldsymbol{\beta}$ . Todavia, notem que, não há nenhuma restrição sobre os vetores  $\mathbf{x}$  e  $\boldsymbol{\beta}$ .

Isso pode ser problemático, pois se  $\theta$  está contido no intervalo entre 0 e 1, o resultado de  $\mathbf{x}^\top \boldsymbol{\beta}$  precisará estar dentro desse intervalo.



# Família de dispersão

Para contornar esse problema, ao invés de nós ajustarmos  $\theta$ , nós podemos ajustar uma função dele,



# Família de dispersão

Para contornar esse problema, ao invés de nós ajustarmos  $\theta$ , nós podemos ajustar uma função dele, i.e.,

$$g(\theta) = \mathbf{x}^\top \boldsymbol{\beta},$$



# Família de dispersão

Para contornar esse problema, ao invés de nós ajustarmos  $\theta$ , nós podemos ajustar uma função dele, i.e.,

$$g(\theta) = \mathbf{x}^\top \boldsymbol{\beta},$$

em que  $g(\cdot)$  é uma função invertível e conhecida, sendo ela denominada de **função de ligação**.



# Família de dispersão

Para contornar esse problema, ao invés de nós ajustarmos  $\theta$ , nós podemos ajustar uma função dele, i.e.,

$$g(\theta) = \mathbf{x}^\top \boldsymbol{\beta},$$

em que  $g(\cdot)$  é uma função invertível e conhecida, sendo ela denominada de **função de ligação**.



# Modelos de dispersão

Propostos por Jørgensen (1997), os modelos de dispersão supõem um fenômeno  $Y$ ,



# Modelos de dispersão

Propostos por Jørgensen (1997), os modelos de dispersão supõem um fenômeno  $Y$ , tal que  $Y \sim \mathcal{FD}(\theta, \phi)$ , com  $g(\theta) = \mathbf{x}^\top \beta$ .



# Modelos de dispersão

Propostos por Jørgensen (1997), os modelos de dispersão supõem um fenômeno  $Y$ , tal que  $Y \sim \mathcal{FD}(\theta, \phi)$ , com  $g(\theta) = \mathbf{x}^\top \boldsymbol{\beta}$ .



# Modelos de dispersão

Da mesma forma o que ocorre no modelo de regressão linear, para explicitar a relação entre as variáveis, é necessário estimar os parâmetros do modelo, para isso, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^T)^T$ ,



# Modelos de dispersão

Da mesma forma o que ocorre no modelo de regressão linear, para explicitar a relação entre as variáveis, é necessário estimar os parâmetros do modelo, para isso, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^T)^T$ , i.e.,  $(Y_1, \mathbf{x}_1^T)^T, (Y_2, \mathbf{x}_2^T)^T, \dots, (Y_n, \mathbf{x}_n^T)^T$ ,



# Modelos de dispersão

Da mesma forma o que ocorre no modelo de regressão linear, para explicitar a relação entre as variáveis, é necessário estimar os parâmetros do modelo, para isso, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^\top)^\top$ , i.e.,  $(Y_1, \mathbf{x}_1^\top)^\top, (Y_2, \mathbf{x}_2^\top)^\top, \dots, (Y_n, \mathbf{x}_n^\top)^\top$ , com

$$Y_\ell \sim \mathcal{FD}(\theta_\ell, \phi),$$



# Modelos de dispersão

Da mesma forma o que ocorre no modelo de regressão linear, para explicitar a relação entre as variáveis, é necessário estimar os parâmetros do modelo, para isso, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^\top)^\top$ , i.e.,  $(Y_1, \mathbf{x}_1^\top)^\top, (Y_2, \mathbf{x}_2^\top)^\top, \dots, (Y_n, \mathbf{x}_n^\top)^\top$ , com

$$Y_\ell \sim \mathcal{FD}(\theta_\ell, \phi),$$

em que  $g(\theta_\ell) = \mathbf{x}_\ell^\top \beta$ ,  $\mathbf{x}_\ell = (x_{\ell 1}, x_{\ell 2}, \dots, x_{\ell p})^\top$ ,  $\ell = 1, 2, \dots, n$ .



# Modelos de dispersão

Da mesma forma o que ocorre no modelo de regressão linear, para explicitar a relação entre as variáveis, é necessário estimar os parâmetros do modelo, para isso, é necessário retirar uma amostra independente de tamanho  $n$  do vetor  $(Y, \mathbf{x}^\top)^\top$ , i.e.,  $(Y_1, \mathbf{x}_1^\top)^\top, (Y_2, \mathbf{x}_2^\top)^\top, \dots, (Y_n, \mathbf{x}_n^\top)^\top$ , com

$$Y_\ell \sim \mathcal{FD}(\theta_\ell, \phi),$$

em que  $g(\theta_\ell) = \mathbf{x}_\ell^\top \beta$ ,  $\mathbf{x}_\ell = (x_{\ell 1}, x_{\ell 2}, \dots, x_{\ell p})^\top$ ,  $\ell = 1, 2, \dots, n$ .



# Modelos de dispersão

Os estimadores do vetor  $\beta$  e escalar  $\phi$  são obtidos pelo método da máxima verossimilhança.



# Roteiro

- 1 Introdução
- 2 Modelo lineares generalizados
- 3 Modelos de dispersão
- 4 Estudo de simulação**
- 5 Referências bibliográficas



# Estudo de simulação

Para avaliar o desempenho dos estimadores de máxima verossimilhança, nós utilizaremos o método de Monte Carlo. Nossa suposição será de que  $Y \sim \mathcal{FE}(\theta, \phi)$ , com  $g(\mu) = \beta_1 + \beta_2 x$ .



# Estudo de simulação

Para avaliar o desempenho dos estimadores de máxima verossimilhança, nós utilizaremos o método de Monte Carlo. Nossa suposição será de que  $Y \sim \mathcal{FE}(\theta, \phi)$ , com  $g(\mu) = \beta_1 + \beta_2 x$ .

Serão 5.000 réplicas, para tamanho de amostras  $n = 10, 20, 40, 80, 160$ , para as distribuições normal (ligação identidade), Bernoulli (ligação logito) e gama (ligação log),  $\beta = (1, 1)^\top$  e  $\phi = 10$ , para a Bernoulli,  $\phi = 1$ .



# Estudo de simulação

Para avaliar o desempenho dos estimadores de máxima verossimilhança, nós utilizaremos o método de Monte Carlo. Nossa suposição será de que  $Y \sim \mathcal{FE}(\theta, \phi)$ , com  $g(\mu) = \beta_1 + \beta_2 x$ .

Serão 5.000 réplicas, para tamanho de amostras  $n = 10, 20, 40, 80, 160$ , para as distribuição normal (ligação identidade), Bernoulli (ligação logito) e gama (ligação log),  $\beta = (1, 1)^\top$  e  $\phi = 10$ , para a Bernoulli,  $\phi = 1$ .



# Estudo de simulação

O desempenho será avaliado através do viés absoluto e do erro quadrático médio (EQM). Sem perda de generalidade, o viés absoluto e o EQM do estimador de um parâmetro  $\delta$  são dados, respectivamente por



# Estudo de simulação

O desempenho será avaliado através do viés absoluto e do erro quadrático médio (EQM). Sem perda de generalidade, o viés absoluto e o EQM do estimador de um parâmetro  $\delta$  são dados, respectivamente por

$$\text{Viés absoluto} = \left| \hat{\delta}_{\text{MC}} - \delta \right| \text{ e } \text{EQM} = \sum_{i=1}^{5.000} \frac{(\hat{\delta}_i - \delta)^2}{5.000},$$

em que  $\hat{\delta}_{\text{MC}} = 5.000^{-1} \sum_{i=1}^{5.000} \hat{\delta}_i$ .



# Estudo de simulação

O desempenho será avaliado através do viés absoluto e do erro quadrático médio (EQM). Sem perda de generalidade, o viés absoluto e o EQM do estimador de um parâmetro  $\delta$  são dados, respectivamente por

$$\text{Viés absoluto} = \left| \hat{\delta}_{\text{MC}} - \delta \right| \text{ e } \text{EQM} = \sum_{i=1}^{5.000} \frac{(\hat{\delta}_i - \delta)^2}{5.000},$$

em que  $\hat{\delta}_{\text{MC}} = 5.000^{-1} \sum_{i=1}^{5.000} \hat{\delta}_i$ .






Figura 1: Viés absoluto dos parâmetros - normal.




Figura 2: EQM dos parâmetros - normal.




Figura 3: Viés absoluto dos parâmetros - Bernoulli.




Figura 4: EQM dos parâmetros - Bernoulli.




Figura 5: Viés absoluto dos parâmetros - gama.




Figura 6: EQM dos parâmetros - gama.

# Estudo de simulação

De maneira geral, para tamanhos de amostras grandes (80 e 160), os estimadores para  $\beta$  e  $\phi$  têm viés absoluto e EQM próximos a zero.



# Estudo de simulação

De maneira geral, para tamanhos de amostras grandes (80 e 160), os estimadores para  $\beta$  e  $\phi$  têm viés absoluto e EQM próximos a zero.

Para amostras pequenas (10 e 20), o estimador de  $\phi$  parece não ser confiável.



# Estudo de simulação

De maneira geral, para tamanhos de amostras grandes (80 e 160), os estimadores para  $\beta$  e  $\phi$  têm viés absoluto e EQM próximos a zero.

Para amostras pequenas (10 e 20), o estimador de  $\phi$  parece não ser confiável.

No caso da Bernoulli, o estimador de  $\beta$  também retornou estimativas longes dos valores verdadeiros.



# Estudo de simulação

De maneira geral, para tamanhos de amostras grandes (80 e 160), os estimadores para  $\beta$  e  $\phi$  têm viés absoluto e EQM próximos a zero.

Para amostras pequenas (10 e 20), o estimador de  $\phi$  parece não ser confiável. No caso da Bernoulli, o estimador de  $\beta$  também retornou estimativas longes dos valores verdadeiros.



# Roteiro

- 1 Introdução
- 2 Modelo lineares generalizados
- 3 Modelos de dispersão
- 4 Estudo de simulação
- 5 Referências bibliográficas



# Referências bibliográficas I

Jørgensen, B. (1997), *The Theory of Dispersion Models*, Chapman & Hall, London.

Nelder, J. A. e Wedderburn, R. W. M. (1972), 'Generalized linear models', *Journal of the Royal Statistical Society. Series A (General)* **135**(3), 370–384.



# Obrigado!

✉ [tiago.magalhaes@ufjf.br](mailto:tiago.magalhaes@ufjf.br)

📄 [ufjf.br/tiago\\_magalhaes](https://ufjf.br/tiago_magalhaes)

🌐 Departamento de Estatística, Sala 319

