

# Modelos Lineares Generalizados - Componentes do Modelo

Erica Castilho Rodrigues

11 de Maio de 2017

# Introdução

- ▶ Vejamos agora quais as componentes de um Modelo Linear Generalizado.
- ▶ Temos um conjunto de variáveis aleatórias independentes

$$Y_1, Y_2, \dots, Y_n$$

cada uma delas com uma distribuição que pertence à Família Exponencial.

- ▶ Vamos supor que as variáveis estão na forma canônica.
- ▶ Vimos que em geral a densidade de distribuições pertencentes a família exponencial podem ser escritas como

$$f(y; \theta) = s(\mathbf{y})t(\theta)e^{a(\mathbf{y})b(\theta)} .$$

- ▶ Vimos ainda que se  $a(y) = y$ ,
  - ▶  $b(\theta)$  é chamado parâmetro canônico da distribuição.

- ▶ Isso equivale a dizer que a variável está na forma canônica.
- ▶ Vamos considerar ainda que a distribuição depende apenas de um parâmetro  $\theta_j$ .
- ▶ Os demais parâmetros são conhecidos ou são apenas parâmetros de ruído, como o  $\sigma^2$ .
- ▶ Nesse caso temos que a função densidade é dada por

$$f(y_i; \theta_j) = \exp [y_i b(\theta_j) + c(\theta_j) + d(y_i)]$$

- ▶ A função de densidade conjunta é dada por

$$f(y_1, y_2, \dots, y_N; \theta_1, \dots, \theta_N) = \prod_{i=1}^N \exp [y_i b(\theta_i) + c(\theta_i) + d(y_i)]$$
$$= \exp \left[ \sum_{i=1}^N y_i b(\theta_i) + \sum_{i=1}^N c(\theta_i) + \sum_{i=1}^N d(y_i) \right] .$$

- ▶ A variáveis são i.i.d.?

- ▶ A função de densidade conjunta é dada por

$$f(y_1, y_2, \dots, y_N; \theta_1, \dots, \theta_N) = \prod_{i=1}^N \exp [y_i b(\theta_i) + c(\theta_i) + d(y_i)]$$
$$= \exp \left[ \sum_{i=1}^N y_i b(\theta_i) + \sum_{i=1}^N c(\theta_i) + \sum_{i=1}^N d(y_i) \right].$$

- ▶ A variáveis são i.i.d.? Não.
- ▶ Não são identicamente distribuídas.
- ▶ Cada variávei tem seu  $\theta_i$ .
- ▶ Esse parâmetro muda de uma variável para outra.

- ▶ Não estamos interessados diretamente no parâmetro  $\theta_j$ .
- ▶ Estamos interessados, geralmente, em um conjunto menor de parâmetros

$$\beta_1, \beta_2, \dots, \beta_p$$

onde  $p < N$ .

- ▶  $\theta_j$  é o valor esperado de  $Y_j$ ?

- ▶ Não estamos interessados diretamente no parâmetro  $\theta_j$ .
- ▶ Estamos interessados, geralmente, em um conjunto menor de parâmetros

$$\beta_1, \beta_2, \dots, \beta_p$$

onde  $p < N$ .

- ▶  $\theta_j$  é o valor esperado de  $Y_j$ ? Não necessariamente.
- ▶ Em alguns casos sim, por exemplo na Normal.
- ▶ Vamos denotar

$$E(Y_j) = \mu_j .$$

- ▶ Em geral, vamos ter que  $\mu_j$  é função de  $\theta_j$ .

- ▶ No modelo de Regressão Linear a relação entre o valor esperado d variável resposta e as explicativas é dada por

$$E(Y_i) = \mu_i = x_i^T \beta .$$

- ▶ Nos MLG's podemos definir

$$E(Y_i) = \mu_i = g(x_i^T \beta)$$

onde  $g(\cdot)$  é uma função genérica e é chamada **função de ligação**.

- ▶ O termo

$$x_i^T \beta$$

é chamado **preditor linear**.

- ▶ Um Modelo Linear Generalizado é composto por 3 componentes:
  - ▶ uma distribuição de probabilidade pertencente à família exponencial;
  - ▶ um preditor linear

$$\eta = x_i^T \beta .$$

- ▶ uma função de ligação  $g(\cdot)$  tal que

$$E(Y_i) = \mu_i = g(x_i^T \beta) .$$

## Preditor Linear

- ▶ Incorpora informação sobre as variáveis explicativas no modelo.
- ▶ Ele está relacionado com  $\mu_i$  através da função de ligação

$$\mu_i = g(x_i^T \beta).$$

- ▶ É uma combinação linear de parâmetros desconhecidos

$$\beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix}$$

## Função de Ligação

- ▶ Fornece a relação entre o preditor linear e a média da variável.
- ▶ A escolha dessa função pode ser arbitrária.
- ▶ Veremos que para cada modelo existem escolhas mais convenientes.
- ▶ É interessante que a imagem de  $g(\cdot)$  esteja restrita aos valores onde  $\mu_j$  está definido.
- ▶ Exemplo:
  - ▶ temos uma distribuição Poisson,
  - ▶ logo  $\mu_j > 0$ ,
  - ▶ seria interessante então que

$$g(x_j^T \beta) > 0.$$

- ▶ Em alguns casos não é possível garantir isso.

## Função de Ligação Canônica

- ▶ Cada distribuição da Família Exponencial tem uma função de ligação especial.
- ▶ Essa ligação ocorre quando

$$b(\theta_i) = \eta = x_i^T \beta .$$

- ▶ Ou seja, igualamos o **parâmetro canônico** ao **preditor linear**.
- ▶ Veremos que ela defini uma estatística suficiente.

- ▶ Vamos substituir

$$b(\theta_i) = x_i^T \beta$$

na função de densidade.

- ▶ Ficamos com

$$f(\mathbf{y}; \theta_1, \dots, \theta_N) =$$

- ▶ Vamos substituir

$$b(\theta_i) = x_i^T \beta$$

na função de densidade.

- ▶ Ficamos com

$$f(\mathbf{y}; \theta_1, \dots, \theta_N) = \exp \left[ \sum_{i=1}^N y_i b(\theta_i) + \sum_{i=1}^N c(\theta_i) + \sum_{i=1}^N d(y_i) \right]$$

$$= \exp \left[ \sum_{i=1}^N y_i x_i^T \beta + \sum_{i=1}^N c(\theta_i) + \sum_{i=1}^N d(y_i) \right]$$

$$= \exp \left[ \sum_{i=1}^N y_i \sum_{j=1}^p x_{ij} \beta_j + \sum_{i=1}^N c(\theta_i) + \sum_{i=1}^N d(y_i) \right]$$

$$= \exp \left[ \sum_{j=1}^p \beta_j \sum_{i=1}^N y_i x_{ij} + \sum_{i=1}^N c(\theta_i) + \sum_{i=1}^N d(y_i) \right]$$

- ▶ Qual estatística suficiente para estimar  $\beta_1$ ?

- ▶ Qual estatística suficiente para estimar  $\beta_1$ ?

$$\sum_{i=1}^N y_i X_{i1}$$

- ▶ E para  $\beta_j$ ?

- ▶ Qual estatística suficiente para estimar  $\beta_1$ ?

$$\sum_{i=1}^N y_i X_{i1}$$

- ▶ E para  $\beta_j$ ?

$$\sum_{i=1}^N y_i X_{ij}$$

- ▶ Veremos que as ligações canônicas facilitam na estimação dos parâmetros.
- ▶ Elas tornam a função de densidade côncava.
- ▶ Portanto possuem um ponto de máximo global.
- ▶ A tabela a seguir mostra alguns exemplos de ligações canônicas

| Distribuição | Normal          | Binomial  | Poisson            | Gama              | Normal Inversa    |
|--------------|-----------------|---|--------------------|-------------------|-------------------|
| Ligação      | $\theta = \eta$ | $\log\left(\frac{\theta}{1-\theta}\right) = \eta$ | $\log(\mu) = \eta$ | $\mu^{-1} = \eta$ | $\mu^{-2} = \eta$ |

## Exemplo:

- ▶ O modelo de Regressão Linear é um caso específico de um MLG.
- ▶ Temos nesse caso que

$$Y_i \sim N(\mu_i, \sigma^2) \quad E(Y_i) = \mu_i = x_i^T \beta .$$

- ▶ A função de ligação é a identidade, pois a média é igual ao preditor linear.
- ▶ Esse modelo é geralmente escrito da forma

$$\mathbf{Y} = \mathbf{X}\beta + \epsilon$$

onde  $\epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$  são i.i.d. tais que  $\epsilon_j \sim N(0, \sigma^2)$ .

**Exemplo:**

- ▶ Uma clínica local está interessada em evitar epidemias de gripe.
- ▶ A clínica envia informativos aos pacientes.
- ▶ Esses informativos tem como objetivo incentivá-los a tomar uma vacina contra a doença.
- ▶ 50 pacientes foram selecionados ao acaso.
- ▶ E para cada um deles verificou-se se, de fato, tomaram a vacina.

**Exemplo: (continuação)**

- ▶ Defina a variável

$$Y_i = \begin{cases} 1 & \text{se o paciente toma vacina} \\ 0 & \text{se o paciente não toma a vacina.} \end{cases}$$

- ▶ Qual a distribuição de  $Y_i$ ?

**Exemplo: (continuação)**

- ▶ Defina a variável

$$Y_i = \begin{cases} 1 & \text{se o paciente toma vacina} \\ 0 & \text{se o paciente não toma a vacina.} \end{cases}$$

- ▶ Qual a distribuição de  $Y_i$ ?

$$Y_i \sim \text{Bern}(\theta_i)$$

onde  $\theta_i$  é a probabilidade do paciente tomar a vacina.

- ▶ A probabilidade  $\theta_i$  pode depender de variáveis como:
  - ▶ idade;
  - ▶ conhecimento sobre a doença;
  - ▶ sexo.

**Exemplo: (continuação)**

- ▶ A função densidade é dada por

$$f(y_i, \theta_i) =$$

**Exemplo: (continuação)**

- ▶ A função densidade é dada por

$$f(y_i, \theta_i) = \theta^{y_i} (1 - \theta_i)^{1 - y_i} =$$

**Exemplo: (continuação)**

- ▶ A função densidade é dada por

$$f(y_i, \theta_i) = \theta^{y_i} (1 - \theta_i)^{1 - y_i} = \exp \{ y_i \log \theta_i + (1 - y_i) \log(1 - \theta_i) \}$$

=

**Exemplo: (continuação)**

- ▶ A função densidade é dada por

$$f(y_i, \theta_i) = \theta^{y_i} (1 - \theta_i)^{1 - y_i} = \exp \{y_i \log \theta_i + (1 - y_i) \log(1 - \theta_i)\}$$

$$= \theta^{y_i} (1 - \theta_i)^{1 - y_i} =$$

**Exemplo: (continuação)**

- ▶ A função densidade é dada por

$$f(y_i, \theta_i) = \theta^{y_i}(1-\theta_i)^{1-y_i} = \exp \{y_i \log \theta_i + (1 - y_i) \log(1 - \theta_i)\}$$

$$= \theta^{y_i}(1 - \theta_i)^{1-y_i} = \exp \left\{ \underbrace{y_i \log \left( \frac{\theta_i}{1 - \theta_i} \right)}_{b(\theta_i)} + \underbrace{\log(1 - \theta_i)}_{c(\theta_i)} \right\}$$

**Exemplo: (continuação)**

- ▶ Vejamos primeiro como fica a ligação canônica nesse caso.
- ▶ Lembre que a ligação canônica é dada por

$$b(\theta_i) = x_i^T \beta$$

- ▶ Nesse caso temos então que

**Exemplo: (continuação)**

- ▶ Vejamos primeiro como fica a ligação canônica nesse caso.
- ▶ Lembre que a ligação canônica é dada por

$$b(\theta_i) = x_i^T \beta$$

- ▶ Nesse caso temos então que

$$b(\theta_i) = \log \left( \frac{\theta_i}{1 - \theta_i} \right) \Rightarrow \log \left( \frac{\theta_i}{1 - \theta_i} \right) = x_i^T \beta = \eta .$$

- ▶ Nesse caso temos ainda que

$$E(Y_i) = \theta_i .$$

**Exemplo: (continuação)**

- ▶ Vamos isolar  $\theta_i$  para verificarmos qual é a função  $g(\cdot)$  nesse caso.
- ▶ Temos que

**Exemplo: (continuação)**

- ▶ Vamos isolar  $\theta_i$  para verificarmos qual é a função  $g(\cdot)$  nesse caso.
- ▶ Temos que

$$\log \left( \frac{\theta_i}{1 - \theta_i} \right) = \eta$$

**Exemplo: (continuação)**

- ▶ Vamos isolar  $\theta_i$  para verificarmos qual é a função  $g(\cdot)$  nesse caso.
- ▶ Temos que

$$\log \left( \frac{\theta_i}{1 - \theta_i} \right) = \eta$$

$$\left( \frac{\theta_i}{1 - \theta_i} \right) = e^\eta$$

$$\theta_i = e^\eta - \theta_i e^\eta \quad \therefore \quad \theta_i(1 + e^\eta) = e^\eta$$

$$\theta_i = \frac{e^\eta}{1 + e^\eta}$$

**Exemplo: (continuação)**

- ▶ Dividindo o numerador e o denominador por  $e^\eta$  ficamos com

$$\theta_i = \frac{e^\eta(1/e^\eta)}{(1 + e^\eta)(1/e^\eta)} = \frac{1}{1 + e^{-\eta}}$$

- ▶ Ou seja, a função de ligação é dada por

$$E(Y_i) = \theta_i = \frac{1}{1 + e^{-x_i^T \beta}}$$

- ▶ Esse tipo de ligação é chamada ligação logística.
- ▶ Essa ligação pode levar a valores não válidos de  $\mu_i$ ?

**Exemplo: (continuação)**

- ▶ Dividindo o numerador e o denominador por  $e^\eta$  ficamos com

$$\theta_i = \frac{e^\eta(1/e^\eta)}{(1 + e^\eta)(1/e^\eta)} = \frac{1}{1 + e^{-\eta}}$$

- ▶ Ou seja, a função de ligação é dada por

$$E(Y_i) = \theta_i = \frac{1}{1 + e^{-x_i^T \beta}}$$

- ▶ Esse tipo de ligação é chamada ligação logística.
- ▶ Essa ligação pode levar a valores não válidos de  $\mu_i$ ? Não.
- ▶ Em que intervalo  $\mu_i$  está definido?

**Exemplo: (continuação)**

- ▶ Dividindo o numerador e o denominador por  $e^\eta$  ficamos com

$$\theta_i = \frac{e^\eta(1/e^\eta)}{(1 + e^\eta)(1/e^\eta)} = \frac{1}{1 + e^{-\eta}}$$

- ▶ Ou seja, a função de ligação é dada por

$$E(Y_i) = \theta_i = \frac{1}{1 + e^{-x_i^T \beta}}$$

- ▶ Esse tipo de ligação é chamada ligação logística.
- ▶ Essa ligação pode levar a valores não válidos de  $\mu_i$ ? Não.
- ▶ Em que intervalo  $\mu_i$  está definido?  $[0, 1]$ .
- ▶ Observe que a função

$$\frac{1}{1 + e^{-\eta}}$$

está sempre dentro do intervalo  $[0, 1]$ .

**Exemplo: (continuação)**

- ▶ A ligação logística é a mais usada para dados Benoulli.
- ▶ Existem, porém, outras possibilidades.
- ▶ Probit

$$\Phi^{-1}(\theta_i) = x_i^T \beta \Rightarrow \theta_i = \Phi(x_i^T \beta)$$

onde  $\Phi(\cdot)$  é a função de distribuição acumulada da  $N(0, 1)$ .

- ▶ Essa função também está definida no intervalo  $[0, 1]$ .

**Exemplo: (continuação)**

- ▶ Complemento log-log

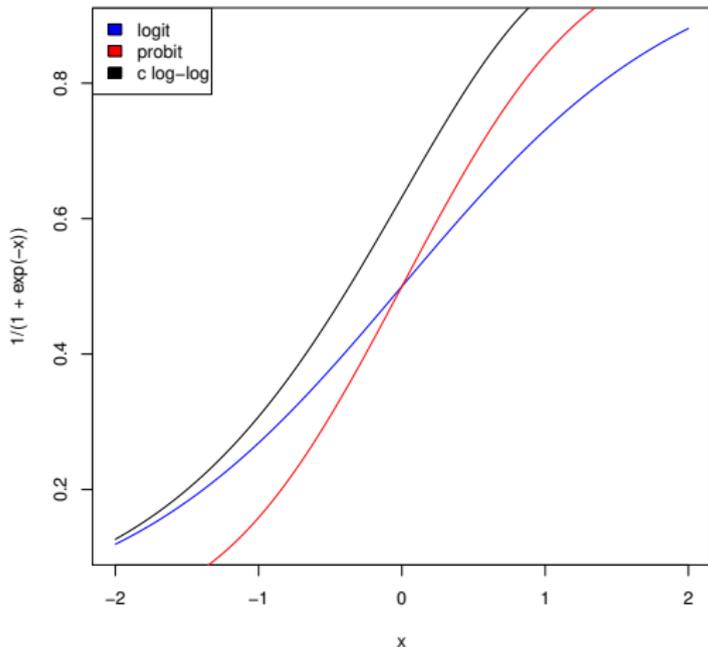
$$\log(-\log(1 - \theta_i)) = x_i^T \beta$$

$$-\log(1 - \theta_i) = e^{x_i^T \beta} \quad \therefore \quad (1 - \theta_i) = \exp(-e^{x_i^T \beta})$$

$$\theta_i = 1 - \exp(-e^{x_i^T \beta})$$

- ▶ Também está definida no intervalo  $[0,1]$ .
- ▶ Para valores pequenos de  $\theta_i$ :
  - ▶ fica bem próxima da ligação logística.

**Exemplo: (continuação)** O gráfico a seguir compara as três funções de ligação.



**Exemplo:**

- ▶ Queremos modelar o número de pessoas infectadas por uma determinada doença.
- ▶ Seja  $Y_i$  o número de casos do  $i$ -ésimo grupo de pessoas.
- ▶ Suponha que a doença seja não contagiosa.
- ▶ Vamos considerar que o número de casos nas cidades são independentes entre si.
- ▶ Vamos considerar ainda que o número de casos segue uma distribuição

## Exemplo:

- ▶ Queremos modelar o número de pessoas infectadas por uma determinada doença.
- ▶ Seja  $Y_i$  o número de casos do  $i$ -ésimo grupo de pessoas.
- ▶ Suponha que a doença seja não contagiosa.
- ▶ Vamos considerar que o número de casos nas cidades são independentes entre si.
- ▶ Vamos considerar ainda que o número de casos segue uma distribuição de Poisson, ou seja,

$$f(y_i, \theta_i) = \frac{\theta_i^{y_i} e^{-\theta_i}}{y_i!}$$

onde  $\theta_i$  denota o número de casos esperados no grupo  $i$ .

**Exemplo: (continuação)**

- ▶ A função de densidade pode ser escrita como

**Exemplo: (continuação)**

- ▶ A função de densidade pode ser escrita como

$$f(y_i, \theta_i) =$$

**Exemplo: (continuação)**

- ▶ A função de densidade pode ser escrita como

$$f(y_i, \theta_i) = \exp \left\{ \underbrace{y_i \log(\theta_i)}_{b(\theta_i)} - \underbrace{\theta_i}_{c(\theta_i)} - \underbrace{\log(y_i!)}_{d(y_i)} \right\} .$$

- ▶ Como fica a ligação canônica nesse caso?

**Exemplo: (continuação)**

- ▶ A função de densidade pode ser escrita como

$$f(y_i, \theta_i) = \exp \left\{ \underbrace{y_i \log(\theta_i)}_{b(\theta_i)} - \underbrace{\theta_i}_{c(\theta_i)} - \underbrace{\log(y_i!)}_{d(y_i)} \right\} .$$

- ▶ Como fica a ligação canônica nesse caso?

$$b(\theta_i) = \log(\theta_i)$$

vimos que a ligação canônica é dada por

**Exemplo: (continuação)**

- ▶ A função de densidade pode ser escrita como

$$f(y_i, \theta_i) = \exp \left\{ \underbrace{y_i \log(\theta_i)}_{b(\theta_i)} - \underbrace{\theta_i}_{c(\theta_i)} - \underbrace{\log(y_i!)}_{d(y_i)} \right\} .$$

- ▶ Como fica a ligação canônica nesse caso?

$$b(\theta_i) = \log(\theta_i)$$

vimos que a ligação canônica é dada por

$$b(\theta_i) = \eta = x_i^T \beta$$

portanto ficamos com

$$\log(\theta_i) = x_i^T \beta \text{ ou } \theta_i = e^{x_i^T \beta}$$

**Exemplo: (continuação)**

- ▶ O número esperado de casos pode depender de variáveis como:

## Exemplo: (continuação)

- ▶ O número esperado de casos pode depender de variáveis como:
  - ▶ tamanho da população;
  - ▶ características da população, como faixa etária, sexo, história média.
- ▶ Uma das variáveis que devemos considerar aqui é o tamanho da população.
- ▶ Talvez um local tenha mais casos apenas porque sua população é maior.
- ▶ Essa variável entra no modelo sem um  $\beta$  associado.
- ▶ Ela é chamada *offset*.
- ▶ Veremos mais detalhes sobre isso adiante.

- ▶ Modelamos na verdade é a proporção de pessoas da população que são infectadas.
- ▶ Essa proporção é modelada por

$$e^{(x_i^T \beta)}$$

onde as variáveis  $x$  incluem características da população.

- ▶ Dessa maneira, o número de casos esperados na população é dado por

$$\theta_i = ne^{(x_i^T \beta)}$$

onde

- ▶  $n$  é o tamanho da população sob risco;
  - ▶  $e^{(x_i^T \beta)}$  é a taxa de casos da doença.
- ▶ A taxa de casos vai depender das características da população.

**Exemplo: (continuação)**

- ▶ Suponha que queremos verificar como a incidência da doença depende da idade.
- ▶ Pegamos grupos de faixas etárias distintas

30–34    35–39    40–44    45–49    50–54    55–59    60–64    65–69

- ▶ Para cada um desses grupos contamos o número de casos da doença.
- ▶ A taxa da doença em cada grupo é estimada por

$$\frac{\text{número de casos no grupo}}{\text{tamanho do grupo}} = \frac{y_i}{n_i}.$$

- ▶ Se a doença é rara esse número é muito pequeno, da ordem de  $10^{-5}$ .

**Exemplo: (continuação)**

- ▶ Portanto multiplicamos o resultado por 100.000

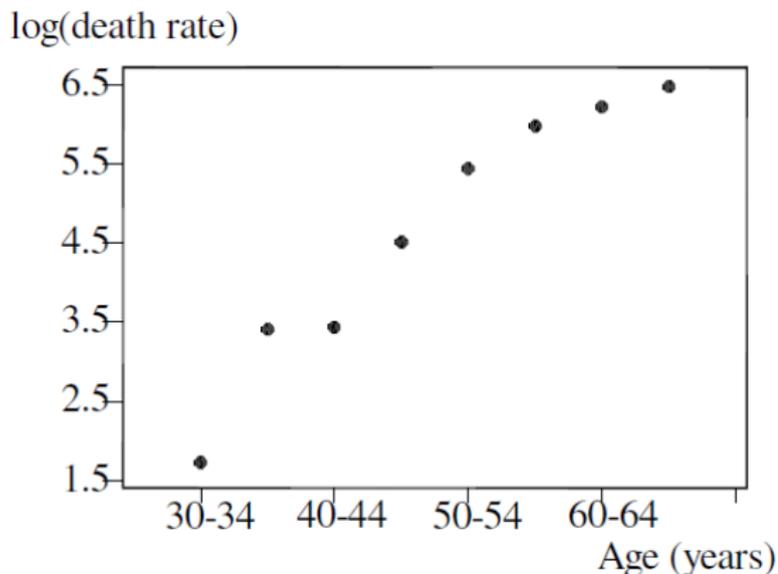
$$\frac{y_i}{n_i} \times 100.000 .$$

- ▶ Um valor de 5,2, por exemplo, significa que :
  - ▶ a taxa de casos da doença é de 5,2 casos por 100.000 habitantes.
- ▶ Veja a tabela abaixo.

| Age group (years) | Number of deaths, $y_i$ | Population size, $n_i$ | Rate per 100,000 men per year, $y_i/n_i \times 10,000$ |
|-------------------|-------------------------|------------------------|--|
| 30 - 34           | 1                       | 17,742                 | 5.6  |
| 35 - 39           | 5                       | 16,554                 | 30.2   |
| 40 - 44           | 5                       | 16,059                 | 31.1   |
| 45 - 49           | 12                      | 13,083                 | 91.7   |
| 50 - 54           | 25                      | 10,784                 | 231.8  |
| 55 - 59           | 38                      | 9,645                  | 394.0  |
| 60 - 64           | 54                      | 10,706                 | 504.4  |
| 65 - 69           | 65                      | 9,933                  | 654.4  |

## Exemplo: (continuação)

- ▶ A figura a seguir mostra como o log da taxa de casos varia com a idade.



- ▶ A relação entre o log da taxa e a idade parece linear.
- ▶ Quanto maior a idade maior o número de casos.

**Exemplo: (continuação)**

- ▶ A função de ligação canônica parece adequada nesse caso?

**Exemplo: (continuação)**

- ▶ A função de ligação canônica parece adequada nesse caso?
- ▶ Sim.
- ▶ A relação entre a taxa de incidência da doença e a idade parece de fato exponencial.

## Exemplo:

- ▶ Estamos analisando a descendência entre línguas.
- ▶ O Grego, por exemplo, é descendente do grego antigo.
- ▶ Suponha que duas línguas são separadas por um tempo  $t$ .
- ▶ A proximidade entre duas línguas é dada pelo número de palavras iguais com o mesmo sentido.
- ▶ Por exemplo, “amigo” tem o mesmo sentido no português do Brasil ou de Portugal.

## Exemplo: (continuação)

- ▶ A probabilidade de terem a mesma palavra representando o mesmo significado é dada por

$$e^{-\theta t}$$

quanto mais distantes, menor a probabilidade de terem palavras em comum.

- ▶ O parâmetro  $\theta$  controla a velocidade com que essa probabilidade decai para zero.
- ▶ Se o valor de  $\theta$  é pequeno:
  - ▶ mesmo duas línguas muito distantes no tempo tendem a ser parecidas.

**Exemplo: (continuação)**

- ▶ Vamos denotar por  $Y_i$  a variável indicadora que diz se duas línguas tem palavras em comum ou não.
- ▶ Portanto

$$Y_i = \begin{cases} 1 & \text{se as línguas usam a mesma palavra para} \\ & \text{representar o } i\text{-ésimo significado} \\ 0 & \text{caso contrário.} \end{cases}$$

- ▶ Temos então que

$$P(Y_i = 1) = e^{-\theta t}$$

$$P(Y_i = 0) = 1 - e^{-\theta t}$$

- ▶ Esse é um caso especial de qual distribuição?

**Exemplo: (continuação)**

- ▶ Vamos denotar por  $Y_i$  a variável indicadora que diz se duas línguas tem palavras em comum ou não.
- ▶ Portanto

$$Y_i = \begin{cases} 1 & \text{se as línguas usam a mesma palavra para} \\ & \text{representar o } i\text{-ésimo significado} \\ 0 & \text{caso contrário.} \end{cases}$$

- ▶ Temos então que

$$P(Y_i = 1) = e^{-\theta t}$$

$$P(Y_i = 0) = 1 - e^{-\theta t}$$

- ▶ Esse é um caso especial de qual distribuição? Bernoulli.
- ▶ A diferença é que o parâmetro de interesse não é a probabilidade de sucesso.
- ▶ Estamos interessados no parâmetro  $\theta$ .

**Exemplo: (continuação)**

- ▶ A função densidade é dada por

$$f(y_i, \theta) =$$

**Exemplo: (continuação)**

- ▶ A função densidade é dada por

$$f(y_i, \theta) = (e^{-\theta t})^{y_i} (1 - e^{-\theta t})^{1-y_i} .$$

- ▶ Pode ser reescrita como

$$f(y_i, \theta) =$$

**Exemplo: (continuação)**

- ▶ A função densidade é dada por

$$f(y_i, \theta) = (e^{-\theta t})^{y_i} (1 - e^{-\theta t})^{1-y_i} .$$

- ▶ Pode ser reescrita como

$$\begin{aligned} f(y_i, \theta) &= \exp \left\{ y_i \log(e^{-\theta t}) + (1 - y_i) \log(1 - e^{-\theta t}) \right\} \\ &= \exp \left\{ y_i \log \left( \frac{e^{-\theta t}}{1 - e^{-\theta t}} \right) + \log(1 - e^{-\theta t}) \right\} \end{aligned}$$

- ▶ Como fica a ligação canônica nesse caso?

**Exemplo: (continuação)**

- ▶ Temos que

$$b(\theta) = \log \left( \frac{e^{-\theta t}}{1 - e^{-\theta t}} \right)$$

e portanto a ligação canônica é dada por

**Exemplo: (continuação)**

- ▶ Temos que

$$b(\theta) = \log \left( \frac{e^{-\theta t}}{1 - e^{-\theta t}} \right)$$

e portanto a ligação canônica é dada por

$$\log \left( \frac{e^{-\theta t}}{1 - e^{-\theta t}} \right) = x_i^T \beta .$$