

Modelos Lineares Generalizados

Emilly Malveira de Lima

Análise de Dados Categóricos
Universidade Federal de Minas Gerais - UFMG

Modelo de regressão linear

Regressão linear

Tem o interesse de modelar o comportamento médio de uma variável de interesse por meio da combinação de covariáveis explicativas.

$$Y_i = \beta_0 + \beta_1 X_{1i} + \cdots + \beta_p X_{pi} + \varepsilon_i, \quad i = 1, \dots, n.$$

$$E[Y_i|X_i] = \beta_0 + \beta_1 X_{1i} + \cdots + \beta_p X_{pi} = \underbrace{\mathbf{X}'_i \boldsymbol{\beta}}_{\text{Preditor linear}}$$

- ε_i 's são independentes e têm a mesma distribuição, $N(0, \sigma^2)$
- $Y_i \sim N(E[Y_i|X_i], \sigma^2)$
- **Suposições do modelo:** linearidade, independência, homocedasticidade e **normalidade**

Modelos lineares generalizados

- Os MLGs foram propostos por Nelder and Wedderburn (1972) como uma extensão do modelo linear normal;
- são modelos para análise de dados em que a suposição de normalidade não é plausível;
- é possível modelar variáveis de interesse que assumem a forma de **contagem**, contínuas simétricas e assimétricas, **binárias** e **categóricas**;
- assume-se que a densidade da função de distribuição da variável resposta pertence à família exponencial.
- a modelagem da média não é feita de forma direta. É necessário escolher uma **função** que é capaz de relacionar as covariáveis com a média da variável resposta.

Estrutura do MLG

Há 3 perguntas a serem feitas na hora da construção de um MLG

1 Qual é a distribuição dos dados?

O vetor Y geralmente consiste em uma amostra aleatória proveniente de uma distribuição de probabilidade com densidade na família exponencial.

2 Quais são os preditores? Variáveis explicativas que possivelmente estão associadas à variável resposta.

3 Qual é a função da média que será modelada como função linear dos preditores? *Função de ligação*

Estrutura do MLG

Há 3 perguntas a serem feitas na hora da construção de um MLG

1 Qual é a distribuição dos dados?

O vetor \mathbf{Y} geralmente consiste em uma amostra aleatória proveniente de uma distribuição de probabilidade com densidade na família exponencial.

2 Quais são os preditores? Variáveis explicativas que possivelmente estão associadas à variável resposta.

3 Qual é a função da média que será modelada como função linear dos preditores? *Função de ligação*

Estrutura do MLG

Há 3 perguntas a serem feitas na hora da construção de um MLG

1 Qual é a distribuição dos dados?

O vetor \mathbf{Y} geralmente consiste em uma amostra aleatória proveniente de uma distribuição de probabilidade com densidade na família exponencial.

2 Quais são os preditores? Variáveis explicativas que possivelmente estão associadas à variável resposta.

3 Qual é a função da média que será modelada como função linear dos preditores? *Função de ligação*

Estrutura do MLG

Há 3 perguntas a serem feitas na hora da construção de um MLG

1 Qual é a distribuição dos dados?

O vetor \mathbf{Y} geralmente consiste em uma amostra aleatória proveniente de uma distribuição de probabilidade com densidade na família exponencial.

2 Quais são os preditores? Variáveis explicativas que possivelmente estão associadas à variável resposta.

3 Qual é a função da média que será modelada como função linear dos preditores? *Função de ligação*

Família exponencial

De maneira geral, uma distribuição é dita ser da família exponencial se sua densidade pode ser escrita na seguinte forma:

Estrutura da família exponencial

$$f(y|\theta, \phi) = \exp \left\{ \frac{y\theta - b(\theta)}{a(\phi)} + c(y, \phi) \right\}$$

- y é a variável de interesse
- θ é parâmetro natural (*função de ligação canônica*)
- ϕ parâmetro de escala
- a , b , e c são funções específicas que derterminam unicamente a distribuição.

Propriedades:

$$\mu = E(Y) = b'(\theta) = \frac{db(\theta)}{d\theta} \text{ e}$$
$$\sigma^2 = \text{Var}(Y) = b''(\theta)a(\phi) = \frac{d^2b(\theta)}{d\theta^2} a(\phi)$$

Tipos de respostas e distribuições

- **Contagem:** modelo de Poisson
- **Binária:** modelo Bernoulli
- **Catagórica:** modelo multinomial
- **Contínua assimétrica:** modelo gama
- **Outras:** etc

Resposta Poisson

Contagem/Taxas de ocorrência de eventos

- Número de acidentes de carro;
- Número de mortes por uma determinada doença;
- Número de casos de dengue em uma região (município, estado...)

Poisson

Função de probabilidade

$$f_Y(y|\lambda) = \frac{\lambda^y}{y!} e^{-\lambda}, \quad y = 0, 1, 2, \dots; \quad \lambda > 0.$$

Forma da família exponencial

$$f_Y(y|\lambda) = \exp\{y \log(\lambda) - \lambda + [-\log(y!)]\}$$

$$\theta = \log(\lambda); \quad b(\theta) = \lambda = \exp(\theta); \quad a(\phi) = 1; \quad c(y, \phi) = -\log(y!)$$

Média e variância

$$\mu = b'(\theta) = \exp(\theta) = \lambda$$

$$\sigma^2 = b''(\theta)a(\phi) = \lambda$$

Resposta Binária

Binária Quando temos o intuito de modelar uma variável resposta 0-1 (“fracasso-sucesso”), ou seja, a probabilidade de sucesso de algum evento de interesse

- probabilidade de um paciente desenvolver algum tipo de doença;
- probabilidade de um indivíduos possuir plano de saúde;
- probabilidade de um cliente de banco ser inadimplente;

Bernoulli

Função de probabilidade

$$f_Y(y|\pi) = \pi^y(1 - \pi)^{1-y}, \quad y = \{0, 1\}, \quad 0 < \pi < 1.$$

Forma da família exponencial

$$f_Y(y|\pi) = \exp \left\{ y \log \left(\frac{\pi}{1 - \pi} \right) - [-\log(1 - \pi)] \right\}$$

$$\theta = \log \left(\frac{\pi}{1 - \pi} \right); \quad b(\theta) = \log(1 + \exp(\theta)); \quad a(\phi) = 1; \quad c(y, \phi) = 0$$

Média e variância

$$\mu = b'(\theta) = \frac{\exp(\theta)}{1 + \exp(\theta)} = \pi$$

$$\sigma^2 = b''(\theta)a(\phi) = \frac{\exp(\theta)}{[1 + \exp(\theta)]^2} = \pi(1 - \pi)$$

Função de ligação

- Sejam X_1, X_2, \dots, X_p um conjunto de covariáveis.
- A média da variável resposta

$$\mu = E(Y)$$

é relacionada com X_1, X_2, \dots, X_p através de uma função de ligação g

- A relação entre μ e η é definida por

$$g(\mu) = g(E[Y]) = \eta = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p = \mathbf{X}'\boldsymbol{\beta}$$

- geralmente são utilizadas as funções canônicas, ou seja, $\theta = \eta$

Função de ligação

Exemplo: Poisson (Regressão de Poisson)

Sob a ligação canônica devemos ter

$$\theta = \log(\lambda) = \eta = \mathbf{X}'\beta$$

então

$$g(E(Y)) = g(\lambda) = \log(\lambda)$$

Para o modelo de Poisson g é chamada de ligação *log*

Função de ligação

Exemplo: Bernoulli (Regressão logística)

Sob a função de ligação canônica temos

$$\theta = \log\left(\frac{\pi}{1-\pi}\right) = \eta = \mathbf{X}'\beta$$

então

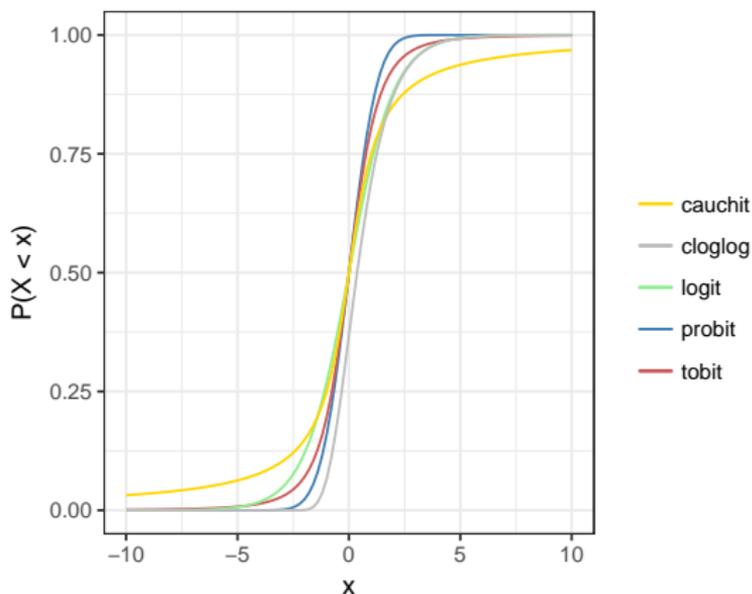
$$g(E(Y)) = g(\pi) = \log\left(\frac{\pi}{1-\pi}\right)$$

Para o modelo de Bernoulli g é chamada de ligação *logit*.

- O modelo de regressão logística é expresso por

$$p(y|\mathbf{x}) = \frac{\exp(\mathbf{X}'\beta)}{1 + \exp(\mathbf{X}'\beta)}$$

Outras ligações na regressão logística



- Mais utilizadas: logit, probit e complemento log-log.

Inferência nos MLG's

- Inferência baseada na teoria assintótica de máxima verossimilhança;
- Métodos numéricos: Newton Raphson e Escore de Fisher

Exemplo: Função de verossimilhança da Bernoulli

$$L(\beta) = \prod_{i=1}^n f_Y(y_i|\pi) = \pi^{y_i}(1 - \pi)^{1-y_i} = \prod_{i=1}^n \frac{\exp(y_i \mathbf{X}'_i \beta)}{1 + \exp(\mathbf{X}'_i \beta)}$$

Função de log-verossimilhança

$$l(\beta) = \log L(\beta) = \sum_{i=1}^n \{y_i \mathbf{X}'_i \beta - \log[1 + \exp(\mathbf{X}'_i \beta)]\}$$

Porém, nos MLG's os estimadores dos β 's **NÃO** são encontrados de forma analítica.

Newton-Raphson

- o algoritmo de *Newton-Raphson* é comumente utilizado para calcular o EMV de β .

Algoritmo de Newton-Raphson

Seja $l'(\beta)$ o logaritmo da função de verossimilhança. A cada passo do algoritmo NR a estimativa β^t é atualizada por

$$\beta^{t+1} = \beta^t + [l''(\beta)]^{-1}l'(\beta^t)$$

em que

$l'(\beta) = \left(\frac{\partial l(\beta)}{\partial \beta_0}, \frac{\partial l(\beta)}{\partial \beta_1}, \dots, \frac{\partial l(\beta)}{\partial \beta_p} \right)$ conhecido com vetor *score*

$l''(\beta)$ é a matriz de segundas derivadas com $(p + 1) \times (p + 1)$ elementos

Inferência nos GLM's

Teste de Hipóteses

- Baseados na teoria assintótica de MV;
- usualmente três estatísticas específicas para realizar testes sobre β 's:
 - i Wald
 - ii Razão de verossimilhanças
 - iii Escore

1) Teste de Wald para testar a hipótese de nulidade do efeito das covariáveis, ou seja, $H_0 : \beta_j = 0$.

- ▶ A estatística de teste $X_j^2 = \left(\frac{\hat{\beta}_j}{EP(\hat{\beta}_j)} \right)^2$ segue uma distribuição χ^2 com 1 gl.

Inferências nos MLG's

Teste de Hipóteses

2) TRV para testar modelos aninhados.

$$TRV = -2 \left[\frac{\ell(H_0)}{\ell(H_1)} \right] \underset{\sim}{\text{assintótica}} \chi_{p-q}$$

Sendo p o n^o de parâmetros do modelo sem restrição, e q do modelo com restrição.

No R

glm()

- **formula:** $y \sim x_1 + x_2 + \dots$
- **family:** binomial(link = "logit")
poisson(link = "log")
gaussian(link = "identity")
Gamma(link = "inverse")
- **data**
- **offset**

TRV

anova(**modelo sob restrição, modelo sem restrição**)

Referências

Nelder, J., & Wedderburn, R. (1972). Generalized Linear Models. *Journal of the Royal Statistical Society. Series A (General)*, 135(3), 370-384.

Cordeiro, G. M., & Demétrio, C. G. (2008). *Modelos lineares generalizados e extensões*. Sao Paulo.

Dobson, A. J., & Barnett, A. (2008). *An introduction to generalized linear models*. CRC press.