

Modelos Lineares Generalizados - Estimação em Modelos Lineares Generalizados

Erica Castilho Rodrigues

23 de Maio de 2017

Introdução

- ▶ Vimos como encontrar o EMV usando algoritmos numéricos.
- ▶ Duas possibilidades:
 - ▶ Método de Newton Raphson;
 - ▶ Método Escore de Fisher.
- ▶ Iremos aplicar esses algoritmos para o caso do MLG.
- ▶ Em Regressão Linear o EMV tem forma fechada.
- ▶ Pode-se mostrar que é equivalente ao estimador de mínimos quadrados.

- ▶ Já nos MGL's os estimadores dos coeficientes β não tem forma fechada.
- ▶ Esses estimadores serão obtidos usando os algoritmos que vimos anteriormente.
- ▶ Considere uma amostra aleatória

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

que pertence à família exponencial em sua forma canônica, ou seja,

$$f(y_i, \theta_i) = \exp\{y_i b(\theta_i) + c(\theta_i) + d(\theta_i)\}.$$

- ▶ Considere que o preditor linear está relacionado com a média da seguinte maneira

$$E(Y_i) = \mu_i \quad \mu_i = g(\mathbf{x}_i^t \boldsymbol{\beta})$$

- ▶ Objetivo: estima o vetor $\boldsymbol{\beta}$.
- ▶ Temos que a log-verossimilhança é dada por

$$l(y_i, \theta_i) = \log(f(y_i, \theta_i)) = y_i b(\theta_i) + c(\theta_i) + d(\theta_i).$$

- ▶ A log-verossimilhança conjunta é dada por

$$\begin{aligned} l(\mathbf{y}, \boldsymbol{\theta}) &= \sum_i l(y_i, \theta_i) = \sum_{i=1}^n (y_i b(\theta_i) + c(\theta_i) + d(\theta_i)) \\ &= \sum_{i=1}^n y_i b(\theta_i) + \sum_{i=1}^n c(\theta_i) + \sum_{i=1}^n d(\theta_i). \end{aligned}$$

- ▶ Queremos encontrar o EMV para cada um dos β_j ($j=1,2,\dots,p$).
- ▶ Devemos então derivar a log-verossimilhança e igualar a zero.
- ▶ Vamos primeiro obter a função escore

$$U_j(\boldsymbol{\theta}) = \frac{dl(\mathbf{y}, \boldsymbol{\theta})}{d\beta_j} = \frac{d \sum_i l(y_i, \theta_i)}{d\beta_j} .$$

- ▶ Pode-se mostrar que a função escore é dada por

$$U_j(\boldsymbol{\theta}) = \sum_{i=1}^n \left[\frac{(y_i - \mu_i)}{\text{Var}(Y_i)} x_{ij} \left(\frac{\partial \mu_i}{\partial \eta_i} \right) \right] .$$

- ▶ Queremos então encontrar a a solução de

$$U_j(\theta) = \sum_{i=1}^n \left[\frac{(y_i - \mu_i)}{\text{Var}(Y_i)} x_{ij} \left(\frac{\partial \mu_i}{\partial \eta_i} \right) \right] = 0$$

para $j = 1, 2, \dots, p$.

- ▶ Usaremos o método Escore de Fisher.
- ▶ Não entraremos em detalhes sobre a construção do algoritmo.

- ▶ Vamos chamar \mathbf{b} o estimador do vetor β .
- ▶ Pode-se mostrar que a equação de atualização do algoritmo é dada por

$$\mathbf{X}^T \mathbf{W} \mathbf{X} \mathbf{b}^{(m)} = \mathbf{X}^T \mathbf{W} \mathbf{z}$$

- ▶ \mathbf{W} é uma matriz diagonal $n \times n$, cuja i -ésima entrada é dada por

$$[\mathbf{W}]_{ii} = \frac{1}{\text{Var}(Y_i)} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2$$

- ▶ e \mathbf{z} é um vetor cuja i -ésima entrada é dada por

$$\mathbf{z}_i = \sum_{k=1}^p x_{ik} b_k^{(m-1)} + (y_i - \mu_i) \left(\frac{\partial \eta_i}{\partial \mu_i} \right).$$

- ▶ A equação

$$\mathbf{X}^T \mathbf{W} \mathbf{X} \mathbf{b}^{(m)} = \mathbf{X}^T \mathbf{W} \mathbf{z}$$

tem o mesmo formato das equações normais no modelo linear quando usamos Mínimos Quadrados Ponderados.

- ▶ A diferença é que aqui ela é resolvida iterativamente.
- ▶ Esse método é chamado Método de Mínimos Quadrados Ponderados Iterativo.

- ▶ A maioria dos softwares utiliza esse método de estimação.
- ▶ Escolhem um valor inicial $\mathbf{b}^{(0)}$.
- ▶ Utilizam esse valor para encontrar \mathbf{W} e \mathbf{z} .

$$[\mathbf{W}]_{ii} = \frac{1}{\text{Var}(Y_i)} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2$$

$$\mathbf{z}_i = \sum_{k=1}^p x_{ik} \mathbf{b}_k^{(m-1)} + (y_i - \mu_i) \left(\frac{\partial \eta_i}{\partial \mu_i} \right) .$$

- ▶ Utilizam \mathbf{z} e \mathbf{W} para atualizar $\mathbf{b}^{(1)}$

$$\mathbf{X}^T \mathbf{W} \mathbf{X} \mathbf{b}^{(1)} = \mathbf{X}^T \mathbf{W} \mathbf{z}$$

- ▶ $\mathbf{b}^{(1)}$ é então usado para obter melhores aproximações de \mathbf{W} e \mathbf{z} .
- ▶ O algoritmo continua até que

$$|\mathbf{b}^{(m)} - \mathbf{b}^{(m-1)}|$$

seja bem pequeno.

Exemplo:

- ▶ Vamos ajustar uma Regressão de Poisson.
- ▶ Considere uma amostra aleatória

$$Y_1, \dots, Y_n$$


tal que $Y_i \sim^{iid} \text{Poisson}(\mu_i)$.

- ▶ A Tabela a seguir apresenta os dados observados

y_i	2	3	6	7	8	9	10	12	15
x_i	-1	-1	0	0	0	0	1	1	1

Exemplo: (continuação)

- ▶ A figura a seguir mostra o gráfico de dispersão entre as duas variáveis.



Exemplo: (continuação)

- ▶ Como a variância se comporta?
- ▶ Ela aumenta quando Y aumenta.
- ▶ Isso faz sentido no modelo Poisson?
- ▶ Sim pois

$$E(Y_i) = \text{Var}(Y_i) .$$

- ▶ Vamos modelar a média dessas variáveis da seguinte maneira

$$E(Y_i) = \mu_i = \beta_0 + \beta_1 x_i .$$

- ▶ Precisamos somar o erro ϵ_j nesse caso?
- ▶ Não.

Exemplo: (continuação)

- ▶ Então o modelo é perfeito? Não comete erro nenhum?
- ▶ O erro vem do fato de

$$Y_i \sim \text{Poisson}(\mu_i) .$$

- ▶ Os valores observamos de Y_i estarão em torno de μ_i .
- ▶ Não serão exatamente μ_i .
- ▶ Assim como acontece no modelo de regressão

$$Y_i \sim N(\mu_i, \sigma^2) .$$

- ▶ A diferença é que o modelo de regressão pode ser escrito de duas maneiras equivalentes

$$Y_i \sim N(\mu_i, \sigma^2) \quad Y_i = \mu_i + \epsilon_i \text{ com } \epsilon_i \sim N(0, \sigma^2) .$$

- ▶ Os MLG's podem ser escritos apenas do primeiro modo.

Exemplo: (continuação)

- ▶ Temos então que

$$Y_i \sim \text{Poisson}(\mu_i)$$

com

$$E(Y_i) = \mu_i = \beta_0 + \beta_1 x_i = \mathbf{x}_i^T \boldsymbol{\beta}$$

onde

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} \quad \mathbf{x}_i = \begin{bmatrix} 1 \\ x_1 \end{bmatrix}$$

- ▶ Qual função de ligação estamos usando aqui?
- ▶ Identidade

$$\mu_i = g(\mathbf{x}_i^T \boldsymbol{\beta}) = \mathbf{x}_i^T \boldsymbol{\beta} = \eta_i$$

Exemplo: (continuação)

- ▶ Vejamos como usar o Método Escore de Fisher para estimar β .
- ▶ Vamos obter a matriz \mathbf{W} .
- ▶ Vimos que

$$[\mathbf{W}]_{ii} = \frac{1}{\text{Var}(Y_i)} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 .$$

- ▶ Temos que

$$\text{Var}(Y_i) = \mu_i = \beta_0 + \beta_1 x_i .$$

- ▶ Além disso

$$\mu_i = \eta_i \Rightarrow \frac{\partial \mu_i}{\partial \eta_i} = 1 .$$

Exemplo: (continuação)

- ▶ Portanto

$$[\mathbf{W}]_{ii} = \frac{1}{\text{Var}(Y_i)} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 = \frac{1}{\beta_0 + \beta_1 x_i}.$$

- ▶ Como não temos o valor de β_0 e β_1 , substituímos pelos seus estimadores b_0 e b_1

$$[\mathbf{W}]_{ii} = \frac{1}{b_0 + b_1 x_i}.$$

- ▶ Veremos agora como fica \mathbf{z} .
- ▶ Vimos que

$$\mathbf{z}_i = \sum_{k=1}^p x_{ik} b_k^{(m-1)} + (y_i - \mu_i) \left(\frac{\partial \eta_i}{\partial \mu_i} \right).$$

- ▶ Temos que

$$\eta_i = \mu_i \Rightarrow \frac{\partial \eta_i}{\partial \mu_i} = 1.$$

Exemplo: (continuação)

- ▶ Portanto

$$\begin{aligned} \mathbf{z}_i &= \sum_{k=1}^p x_{ik} \mathbf{b}_k^{(m-1)} + (y_i - \mu_i) \left(\frac{\partial \eta_i}{\partial \mu_i} \right) \\ &= b_0 + b_1 x_i + (y_i - b_0 - b_1 x_i) = y_i \end{aligned}$$

onde

- ▶ b_0 é estimador de β_0 ;
- ▶ b_1 é estimador de β_1 .
- ▶ O próximo passo é encontrar a equação para atualização do estimador $\mathbf{b}^{(m)}$.

Exemplo: (continuação)

- ▶ Essa atualização é obtida através de

$$\mathbf{X}^T \mathbf{W} \mathbf{X} \mathbf{b}^{(m)} = \mathbf{X}^T \mathbf{W} \mathbf{z}$$

- ▶ Vejamos como fica o termo $\mathbf{X}^T \mathbf{W} \mathbf{X}$.
- ▶ Temos que

$$\mathbf{X} = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} \quad \mathbf{W} = \begin{bmatrix} \frac{1}{b_0 + b_1 x_1} & 0 & \dots & 0 \\ 0 & \frac{1}{b_0 + b_1 x_2} & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & \frac{1}{b_0 + b_1 x_n} \end{bmatrix}$$

logo

$$\mathbf{X}^T \mathbf{W} = \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \end{bmatrix} \begin{bmatrix} \frac{1}{b_0 + b_1 x_1} & 0 & \dots & 0 \\ 0 & \frac{1}{b_0 + b_1 x_2} & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & \frac{1}{b_0 + b_1 x_n} \end{bmatrix}$$

Exemplo: (continuação)

$$\mathbf{X}^T \mathbf{W} = \begin{bmatrix} \frac{1}{b_0 + b_1 x_1} & \frac{1}{b_0 + b_1 x_2} & \cdots & \frac{1}{b_0 + b_1 x_n} \\ \frac{x_1}{b_0 + b_1 x_1} & \frac{x_2}{b_0 + b_1 x_2} & \cdots & \frac{x_n}{b_0 + b_1 x_n} \end{bmatrix}$$

então

$$\begin{aligned} \mathbf{X}^T \mathbf{W} \mathbf{X} &= \begin{bmatrix} \frac{1}{b_0 + b_1 x_1} & \frac{1}{b_0 + b_1 x_2} & \cdots & \frac{1}{b_0 + b_1 x_n} \\ \frac{x_1}{b_0 + b_1 x_1} & \frac{x_2}{b_0 + b_1 x_2} & \cdots & \frac{x_n}{b_0 + b_1 x_n} \end{bmatrix} \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \\ 1 & x_n \end{bmatrix} \\ &= \begin{bmatrix} \sum_{i=1}^n \frac{1}{b_0 + b_1 x_i} & \sum_{i=1}^n \frac{x_i}{b_0 + b_1 x_i} \\ \sum_{i=1}^n \frac{x_i}{b_0 + b_1 x_i} & \sum_{i=1}^n \frac{x_i^2}{b_0 + b_1 x_i} \end{bmatrix} \end{aligned}$$

Exemplo: (continuação)

- ▶ Veremos agora como fica o termo $\mathbf{X}^T \mathbf{Wz}$.
- ▶ Temos que

$$\mathbf{z} = \begin{bmatrix} y_1 \\ y_2 \\ \cdots \\ y_n \end{bmatrix} \quad \mathbf{X}^T \mathbf{W} = \begin{bmatrix} \frac{1}{b_0 + b_1 x_1} & \frac{1}{b_0 + b_1 x_2} & \cdots & \frac{1}{b_0 + b_1 x_n} \\ \frac{x_1}{b_0 + b_1 x_1} & \frac{x_2}{b_0 + b_1 x_2} & \cdots & \frac{x_n}{b_0 + b_1 x_n} \end{bmatrix}$$

- ▶ Logo

$$\mathbf{X}^T \mathbf{Wz} = \begin{bmatrix} \frac{1}{b_0 + b_1 x_1} & \frac{1}{b_0 + b_1 x_2} & \cdots & \frac{1}{b_0 + b_1 x_n} \\ \frac{x_1}{b_0 + b_1 x_1} & \frac{x_2}{b_0 + b_1 x_2} & \cdots & \frac{x_n}{b_0 + b_1 x_n} \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \cdots \\ y_n \end{bmatrix}$$

Exemplo: (continuação)

$$\mathbf{X}^T \mathbf{Wz} = \begin{bmatrix} \sum_{i=1}^n \frac{y_i}{b_0 + b_1 x_i} \\ \sum_{i=1}^n \frac{x_i y_i}{b_0 + b_1 x_i} \end{bmatrix}$$

- ▶ Portanto $\mathbf{b}^{(m)}$ será atualizado a partir da equação

$$\mathbf{X}^T \mathbf{W} \mathbf{X} \mathbf{b}^{(m)} = \mathbf{X}^T \mathbf{Wz}$$

ou seja

$$\begin{bmatrix} \sum_{i=1}^n \frac{1}{b_0 + b_1 x_i} & \sum_{i=1}^n \frac{x_i}{b_0 + b_1 x_i} \\ \sum_{i=1}^n \frac{x_i}{b_0 + b_1 x_i} & \sum_{i=1}^n \frac{x_i^2}{b_0 + b_1 x_i} \end{bmatrix} \mathbf{b}^{(m)} = \begin{bmatrix} \sum_{i=1}^n \frac{y_i}{b_0 + b_1 x_i} \\ \sum_{i=1}^n \frac{x_i y_i}{b_0 + b_1 x_i} \end{bmatrix}$$

Exemplo: (continuação)

- ▶ Para os dados observados temos que

$$\mathbf{y} = \mathbf{z} = \begin{bmatrix} 2 \\ 3 \\ \dots \\ 15 \end{bmatrix} \quad \mathbf{X} = \begin{bmatrix} 1 & -1 \\ 1 & -1 \\ \vdots & \vdots \\ 1 & 1 \\ 1 & 1 \end{bmatrix}$$

- ▶ Vamos escolher os seguintes valores iniciais

$$b_0^{(0)} = 7 \quad b_1^{(0)} = 5.$$

- ▶ Temos que

$$(\mathbf{X}^T \mathbf{W} \mathbf{X})^{(1)} = \begin{bmatrix} 1.821429 & -0.75 \\ -0.75 & 1.25 \end{bmatrix}$$

Exemplo: (continuação)

$$(\mathbf{X}^T \mathbf{Wz})^{(1)} = \begin{bmatrix} 9.869048 \\ 0.5833 \end{bmatrix}$$

► Portanto

$$\begin{bmatrix} 1.821429 & -0.75 \\ -0.75 & 1.25 \end{bmatrix} \mathbf{b}^{(1)} = \begin{bmatrix} 9.869048 \\ 0.5833 \end{bmatrix}$$

o que implica que

$$\mathbf{b}^{(1)} = \begin{bmatrix} 1.821429 & -0.75 \\ -0.75 & 1.25 \end{bmatrix}^{-1} \begin{bmatrix} 9.869048 \\ 0.5833 \end{bmatrix} = \begin{bmatrix} 7.4514 \\ 4.9375 \end{bmatrix}$$

Exemplo: (continuação)

- ▶ A tabela a seguir mostra os valores de \mathbf{b} para alguns passos do algoritmo

m	1	2	3	4
$b_1^{(m)}$	7	7.45139	7.45163	7.45163
$b_2^{(m)}$	5	4.93750	4.93531	4.93530

- ▶ O algoritmo parece ter convergido para os seguintes valores de \mathbf{b}

$$b_0^{(m)} = \hat{\beta}_0 = 7.45 \quad b_1^{(m)} = \hat{\beta}_1 = 4.93 .$$

Propriedades do Estimador Máxima Verossimilhança

- ▶ Assintoticamente não viesados

$$\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta .$$

- ▶ Consistente

$$\hat{\theta} \xrightarrow{\mathcal{P}} \theta$$

($\hat{\theta}$) converge em probabilidade para θ).

- ▶ Variância mínima:

- ▶ $\hat{\theta}$ possui variância mínima para amostras grandes.

- ▶ Distribuição assintótica:

- ▶ a distribuição de $\hat{\theta}$ converge para uma normal.

- ▶ Veremos agora as propriedades do EMV para o caso dos Modelos Lineares Generalizados.

- ▶ Duas principais ferramentas para inferência estatística:
 - ▶ intervalos de confiança e testes de hipóteses.
- ▶ Veremos como obtê-los no caso nos Modelos Lineares Generalizados.

Intervalo de Confiança

- ▶ Fornece uma estimativa intervalar para o parâmetro.
- ▶ A amplitude do intervalo dá uma ideia da precisão dessa estimativa.

Testes de Hipóteses

- ▶ Podemos comparar dois modelos.
- ▶ Queremos identificar qual deles se ajusta melhor aos dados.
- ▶ Um modelo é mais simples que o outro - tem menos parâmetros.
- ▶ Esse modelo é chamado modelo nulo e corresponde a H_0 .
- ▶ Deve ser um caso particular do modelo H_1 .
- ▶ Se os dois modelos ajustam bem os dados:
 - ▶ devemos escolher H_0 , pelo critério da parcimônia.

- ▶ Para fazermos inferências sobre o parâmetro:
 - ▶ precisamos da distribuição de probabilidade do estimador.
- ▶ Seja S uma estatística de interesse.
- ▶ Em geral, pode-se mostrar que, para tamanhos de amostra grandes

$$\frac{S - E(S)}{\sqrt{\text{Var}(S)}} \sim N(0, 1)$$

$$\frac{(S - E(S))^2}{\text{Var}(S)} \sim \chi^2_{(1)}$$

- ▶ Para o caso que \mathbf{S} é um vetor de dimensão p temos que

$$[\mathbf{S} - E(\mathbf{S})]^T \mathbf{V}^{-1} [\mathbf{S} - E(\mathbf{S})] \sim \chi^2_{(p)}$$

onde

$$\text{Cov}(\mathbf{S}) = \mathbf{V}.$$

- ▶ Vamos denotar por \mathbf{b} o estimador do vetor de parâmetros β .
- ▶ Pode-se mostrar que, se a amostra tem tamanho grande,

$$E(\mathbf{b}) = \beta$$

$$(\mathbf{b} - \beta)^T I(\beta)(\mathbf{b} - \beta) \sim \chi^2_{(p)}$$

ou

$$\mathbf{b} \sim N\left(\beta, I(\beta)^{-1}\right)$$

onde $I(\beta)$ é matriz de Informação de Fisher de β cujo termo jk é dado por

$$[I(\beta)]_{jk} = \sum_{i=1}^n \frac{x_{ij}x_{ik}}{\text{Var}(Y_i)} \left(\frac{\partial \mu_i}{\partial \eta_i}\right)^2.$$

- ▶ No caso em que β tem apenas um parâmetro temos que, para n grande

$$\mathbf{b} \sim N\left(\beta, I(\beta)^{-1}\right)$$

onde

$$I(\beta) = \sum_{i=1}^n \frac{x_i^2}{\text{Var}(Y_i)} \left(\frac{\partial \mu_i}{\partial \eta_i}\right)^2 .$$

- ▶ No caso dos MLG's todos esses resultados só valem se a amostra é grande.
- ▶ No caso dos modelos de Regressão Linear esses resultados são exatos.

Exemplo:

- ▶ Vamos considerar o caso da distribuição Normal.
- ▶ Ele não deixa de ser um caso específico dos MLG's.
- ▶ Veremos que os resultados coincidem com aqueles obtidos no curso de Regressão Linear.
- ▶ Iremos considerar então que

$$Y_i \sim N(\mu_i, \sigma^2) \quad \mu_i = \mathbf{x}_i^T \boldsymbol{\beta}$$

onde $\boldsymbol{\beta}$ é um vetor de parâmetros de dimensão p .

Exemplo: (continuação)

- ▶ Vejamos como usar o Método Escore de Fisher para estimar β .
- ▶ Vamos obter a matriz \mathbf{W} .
- ▶ Vimos que

$$[\mathbf{W}]_{ii} = \frac{1}{\text{Var}(Y_i)} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 .$$

- ▶ Temos que

$$\text{Var}(Y_i) = \sigma^2 .$$

- ▶ Além disso

$$\mu_i = \eta_i \Rightarrow \frac{\partial \mu_i}{\partial \eta_i} = 1 .$$

Exemplo: (continuação)

- ▶ Portanto

$$[\mathbf{W}]_{ii} = \frac{1}{\text{Var}(Y_i)} = \frac{1}{\sigma^2}.$$

- ▶ Além disso

$$\begin{aligned} \mathbf{z}_i &= \sum_{k=1}^p x_{ik} \mathbf{b}_k^{(m-1)} + (y_i - \mu_i) \left(\frac{\partial \eta_i}{\partial \mu_i} \right) \\ &= \sum_{k=1}^p x_{ik} \mathbf{b}_k^{(m-1)} + (y_i - \mu_i) = y_i \end{aligned}$$

Exemplo: (continuação)

- ▶ Vimos que a equação de atualização do parâmetro é dada por

$$\mathbf{X}^T \mathbf{W} \mathbf{X} \mathbf{b}^{(m)} = \mathbf{X}^T \mathbf{W} \mathbf{z} .$$

- ▶ E temos que

$$\mathbf{W} = \frac{1}{\sigma^2} \mathbf{I}$$

$$\mathbf{z} = \mathbf{y}$$

logo a equação fica

$$\frac{1}{\sigma^2} \mathbf{X}^T \mathbf{X} \mathbf{b}^{(m)} = \frac{1}{\sigma^2} \mathbf{X}^T \mathbf{y}$$

e portanto

$$\mathbf{b} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

que é justamente o estimador do mínimos quadrados do modelo de regressão.

Exemplo: (continuação)

- ▶ Temos nesse caso que

$$\mathbf{b} \sim N(\boldsymbol{\beta}, I(\boldsymbol{\beta})^{-1})$$

os termos da matriz de Informação de Fisher ficam

$$[I(\boldsymbol{\beta})]_{jk} = \sum_{i=1}^n \frac{x_{ij}x_{ik}}{\text{Var}(Y_i)} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 = \sum_{i=1}^n \frac{x_{ij}x_{ik}}{\sigma^2}.$$

- ▶ Temos então que

$$I(\boldsymbol{\beta}) = \frac{1}{\sigma^2}(\mathbf{X}^T \mathbf{X})$$

ou seja

$$I(\boldsymbol{\beta}) = \sigma^2(\mathbf{X}^T \mathbf{X})^{-1}$$

- ▶ Isso significa que

$$\mathbf{b} \sim N(\boldsymbol{\beta}, \sigma^2(\mathbf{X}^T \mathbf{X})^{-1})$$

que foi o mesmo resultado visto no curso de Regressão Linear.

- **Exercício:** Verifique se a distribuição normal inversa pertence à família exponencial. Caso isso seja verdade, encontre o parâmetro canônico e a ligação canônica dessa distribuição.

$$f(y; \mu, \sigma^2) = \left(\frac{1}{2\pi\sigma^2 y^3} \right)^{1/2} \exp \left\{ -\frac{(y - \mu)^2}{2\mu^2\sigma^2 y} \right\}$$

$$f(y_i, \theta_i) = \exp\{y_i b(\theta_i) + c(\theta_i) + d(\theta_i)\}.$$