

Modelos Lineares Generalizados - Verificação do Ajuste do Modelo

Erica Castilho Rodrigues

9 de Abril de 2015

Função $\frac{1}{2}$ Deviance

Função *Deviance*

- ▶ Podemos ver o ajuste de um modelo a um conjunto de dados como:
 - ▶ uma forma de substituir \mathbf{y} por $\hat{\boldsymbol{\mu}}$
- ▶ $\hat{\boldsymbol{\mu}}$ é o vetor de médias estimado a partir do modelo.
- ▶ Em Regressão Linear, substituíamos \mathbf{y} por $\hat{\mathbf{y}}$.
- ▶ Objetivo: encontrar um modelo com poucos parâmetros tal que essa substituição seja razoável.
- ▶ Os $\hat{\mu}$'s não serão exatamente iguais aos y 's.
- ▶ O quanto eles diferem?
- ▶ Pequena discrepância - tolerável.
- ▶ Discrepância grande - o modelo não está bom.

- ▶ Suponha que já encontramos:
 - ▶ qual a distribuição adequada;
 - ▶ qual a função de ligação mais razoável.
- ▶ Temos então

$Y_i \sim$ família exponencial canônica $E(Y_i) = \mu_i = g(\mathbf{x}_i^T \boldsymbol{\beta})$.

- ▶ Objetivo: determinar quantos termos são necessários no preditor linear

$$\mathbf{x}_i^T \boldsymbol{\beta} = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \cdots + \beta_p X_{ip}.$$

- ▶ Se optamos por um número grande de termos:
 - ▶ o modelo vai explicar bem os dados;
 - ▶ vai ficar complexo e com muitos parâmetros a estimar.

- ▶ Se optamos por um modelo com poucas variáveis:
 - ▶ o modelo é simples e fácil de estimar;
 - ▶ provavelmente não se ajustará bem aos dados.
- ▶ Queremos encontrar um modelo intermediário.
- ▶ Com n observações qual o número máximo de parâmetros que podemos ter? n .
- ▶ Caso contrário, não temos informação suficiente para estimar os parâmetros.
- ▶ Para encontrarmos uma reta precisamos de pelo menos dois pontos.

- ▶ Vejamos as nomenclaturas dos modelos.
- ▶ **Modelo Nulo:**
 - ▶ tem um único parâmetro (μ);
 - ▶ esse parâmetro é comum a todos os dados;
 - ▶ não tem covariáveis;

$$\eta_i = \mu .$$

- ▶ Os y 's variam entre si apenas por causa do componente aleatório.
- ▶ Não variam devido aos diferentes níveis das covariáveis.

- ▶ **Modelo Saturado ou Modelo Completo:**
 - ▶ tem o número máximo de parâmetros possível (n);
 - ▶ um parâmetro por observação;
 - ▶ não existe erro aleatório.
- ▶ Toda a variação é devida ao componente sistemático;
- ▶ Os y 's variam por causa dos níveis diferentes das covariáveis;
- ▶ O modelo explica toda variabilidade dos dados.

$$\eta_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \cdots + \beta_n X_{in}$$

onde n é o tamanho da amostra.

- ▶ O modelo nulo é simples demais.
- ▶ O modelo saturado é não informativo, apenas repete os dados.
- ▶ No modelo saturado podemos incluir ainda termos de interação.
- ▶ Queremos comparar os modelos.
- ▶ Encontrar um, que esteja entre o nulo e o saturado, e seja adequado aos dados.
- ▶ Vamos comparar modelos encaixados:
 - ▶ um está contido no outro;
 - ▶ podemos ir de um para outro apenas acrescentando ou excluindo covariáveis.

- ▶ Chamamos o modelo intermediário de p parâmetros modelo corrente ou modelo sob pesquisa.
- ▶ Devemos ou não incluir uma variável no modelo?
- ▶ Esse parâmetro extra será útil?
- ▶ Se não incluimos o modelo fica mal ajustado?
- ▶ Podemos usar uma medida para avaliar se o modelo está bem ajustado: **Deviance** ou Função Desvio.

Deviance ou Função Desvio

- ▶ Mede a qualidade de ajuste do modelo.
- ▶ É calculada como

$$D = 2[l(\mathbf{b}_{max}; \mathbf{y}) - l(\mathbf{b}, \mathbf{y})]$$

onde

- ▶ $l(\mathbf{b}_{max}; \mathbf{y})$ é o máximo da log-verossimilhança para o modelo saturado;
 - ▶ $l(\mathbf{b}, \mathbf{y})$ é o máximo da log-verossimilhança para o modelo sob pesquisa.
- ▶ Consiste em um teste da razão de verossimilhança que compara:
- ▶ o modelo saturado com o modelo corrente.

- ▶ D é **grande** se:
 - ▶ o ajuste do modelo corrente é muito **pior** do que do saturado.
- ▶ D é **pequeno** se:
 - ▶ o ajuste do modelo corrente não é tão pior do que do saturado.
- ▶ O melhor ajuste possível é obtido com o modelo saturado.
- ▶ Pois ele explica toda a variabilidade dos dados.

- ▶ Observe que essa estatística pode ser escrita como

$$\lambda = \log \left(\frac{f(\mathbf{b}_{max}; \mathbf{y})}{f(\mathbf{b}, \mathbf{y})} \right) .$$

- ▶ O que isso te lembra?
- ▶ Teste da Razão de Verossimilhança.
- ▶ Estamos no fundo fazendo um Teste da Razão.
- ▶ Pode-se mostrar que a distribuição aproximada da estatística é

$$D \sim \chi^2_{(n-p)}$$

onde

- ▶ n é o número de observações na amostra;
- ▶ p é o número de parâmetros do modelo.

Exemplo:

- ▶ Considere uma amostra aleatória

$$Y_1, Y_2, \dots, Y_m$$

tal que $Y_i \sim \text{Bin}(n_i, \pi_i)$.

- ▶ Vamos encontrar a função Deviance para esse caso.
- ▶ A função de verossimhança é dada por

$$f(\mathbf{y}, \pi_i) = \prod_i \binom{n_i}{y_i} \pi_i^{y_i} (1 - \pi_i)^{n_i - y_i}$$

tirando o logaritmo

$$\begin{aligned} l(\mathbf{y}, \pi_i) &= \sum_i \left(\log \binom{n_i}{y_i} + y_i \log(\pi_i) + (n_i - y_i) \log(1 - \pi_i) \right) \\ &= \sum_i \left(y_i \log \left(\frac{\pi_i}{1 - \pi_i} \right) + n_i \log(1 - \pi_i) + \log \binom{n_i}{y_i} \right) \end{aligned}$$

Exemplo: (continuação)

- ▶ Vamos encontrar a log-verossimilhança do Modelo Saturado.
- ▶ No modelo saturado o valor predito é igual ao observado.
- ▶ O modelo não tem erro nenhum, se ajusta perfeitamente aos dados.
- ▶ Temos então que

$$(E(\hat{Y}_i)) = Y_i$$

como $E(Y_i) = n_i \pi_i$ temos que

$$(\hat{E}(Y_i)) = y_i = \hat{\pi}_i n_i \Rightarrow \hat{\pi}_i = \frac{y_i}{n_i}.$$

Exemplo: (continuação)

- ▶ Para obtermos o ponto onde a log-verossimilhança basta:
 - ▶ substituímos o valor estimado $\hat{\pi}_i$ na função

$$l(\mathbf{b}_{max}, \mathbf{y}) = \sum_i \left(y_i \log \left(\frac{y_i/n_i}{1 - y_i/n_i} \right) + n_i \log(1 - y_i/n_i) + \log \binom{n_i}{y_i} \right)$$

Exemplo: (continuação)

- ▶ Vamos agora calcular a log-verossimilhança máxima para o modelo sob análise.
- ▶ Vamos denotar por $\hat{\pi}_i$ as estimativas para os parâmetros π_i obtidas através do modelo.
- ▶ Os valores y_i são preditos da seguinte maneira

$$\hat{y}_i = n_i \hat{\pi}_i$$

onde $\hat{\pi}_i$ são os valores estimados a partir do modelo sob análise.

- ▶ A log-verossimilhança avaliada nesse ponto é dada por

$$\begin{aligned} l(\mathbf{b}, \mathbf{y}) &= \sum_i \left(y_i \log \left(\frac{\hat{y}_i/n_i}{1 - \hat{y}_i/n_i} \right) + n_i \log(1 - \hat{y}_i/n_i) + \log \binom{n_i}{y_i} \right) \\ &= \sum_i \left(y_i \log \left(\frac{\hat{y}_i/n_i}{\frac{n_i - \hat{y}_i}{n_i}} \right) + n_i \log \left(\frac{n_i - \hat{y}_i}{n_i} \right) + \log \binom{n_i}{y_i} \right) \\ &= \sum_i \left(y_i \log \left(\frac{\hat{y}_i}{n_i - \hat{y}_i} \right) + n_i \log \left(\frac{n_i - \hat{y}_i}{n_i} \right) + \log \binom{n_i}{y_i} \right) \end{aligned}$$

Exemplo: (continuação)

- ▶ Vamos agora subtrair as duas funções para obter a Deviance

$$D = 2[l(\mathbf{b}_{max}; \mathbf{y}) - l(\mathbf{b}, \mathbf{y})]$$

$$D = 2 \left[\sum_i \left(y_i \log \left(\frac{y_i/n_i}{1 - y_i/n_i} \right) + n_i \log(1 - y_i/n_i) + \log \binom{n_i}{y_i} \right) - \sum_i \left(y_i \log \left(\frac{\hat{y}_i}{n_i - \hat{y}_i} \right) + n_i \log \left(\frac{n_i - \hat{y}_i}{n_i} \right) + \log \binom{n_i}{y_i} \right) \right]$$

$$= 2 \left[\sum_i y_i \log \left(\frac{y_i}{\hat{y}_i} \right) - y_i \log \left(\frac{n_i - \hat{y}_i}{n_i - y_i} \right) + n_i \log \left(\frac{n_i - \hat{y}_i}{n_i - y_i} \right) \right]$$

Exemplo: (continuação)

- ▶ Portanto

$$D = 2 \left[\sum_i y_i \log \left(\frac{y_i}{\hat{y}_i} \right) + (n_i - y_i) \log \left(\frac{n_i - \hat{y}_i}{n_i - y_i} \right) \right]$$

é a função Deviance quando a variável resposta tem distribuição Binomial.

Exemplo:

- ▶ Considere uma amostra aleatória

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

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

- ▶ A média é modelada por

$$E(Y_i) = \mu_i = \mathbf{x}_i^T \beta.$$

- ▶ A função de ligação? Identidade.
- ▶ Vamos encontrar a função Deviance nesse caso.

Exemplo: (continuação)

- ▶ A função de verossimilhança é dada por

$$f(\mathbf{y}; \beta) = \prod_i \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(y_i - \mu_i)^2} = \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_i (y_i - \mu_i)^2}$$

a log-verossimilhança é dada por

$$\log(f(\mathbf{y}; \beta)) = -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mu_i)^2 - \frac{n}{2} \log(2\pi\sigma^2).$$

Exemplo: (continuação)

- ▶ Para o modelo saturado temos que a média estimada pelo modelo é exatamente igual a observação.
- ▶ Portanto

$$\hat{E}(Y_i) = \hat{\mu}_i = y_i .$$

- ▶ Para obtermos o ponto onde a log-verossimilhança basta:
 - ▶ substituímos o valor estimado $\hat{\pi}_i$ na log-verossimilhança

$$\begin{aligned} \log(f(\mathbf{y}; \beta)) &= -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - y_i)^2 - \frac{n}{2} \log(2\pi\sigma^2) \\ &= -\frac{n}{2} \log(2\pi\sigma^2) . \end{aligned}$$

Exemplo: (continuação)

- ▶ Para o modelo sob análise temos que

$$\hat{E}(Y_i) = \hat{\mu}_i = \mathbf{x}_i^T \hat{\beta}$$

onde $\hat{\beta}$ é o estimador de β .

- ▶ A log-verossimilhança do modelo sob análise fica então

$$\log(f(\mathbf{y}; \beta)) = -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{x}_i^T \hat{\beta})^2 - \frac{n}{2} \log(2\pi\sigma^2)$$

Exemplo: (continuação)

- ▶ Temos então que

$$l(\mathbf{b}_{max}, \mathbf{y}) = -\frac{n}{2} \log(2\pi\sigma^2)$$

$$l(\mathbf{b}, \mathbf{y}) = -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{x}_i^T \hat{\beta})^2 - \frac{n}{2} \log(2\pi\sigma^2).$$

- ▶ A Função Deviance fica

$$D = 2 [l(\mathbf{b}_{max}, \mathbf{y}) - l(\mathbf{b}, \mathbf{y})]$$

ou seja

$$D = 2 \left[-\frac{n}{2} \log(2\pi\sigma^2) - \left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{x}_i^T \hat{\beta})^2 - \frac{n}{2} \log(2\pi\sigma^2) \right) \right]$$

Exemplo: (continuação)

- ▶ Ficamos então com

$$D = 2 \left[\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{x}_i^T \hat{\beta})^2 \right] = \frac{1}{\sigma^2} \sum_{i=1}^n (y_i - \mathbf{x}_i^T \hat{\beta})^2$$

- ▶ Se desconsiderarmos o termo $1/\sigma^2$ esse termo corresponde a que medida em regressão linear?
- ▶ Soma de quadrados dos resíduos

$$e_i = y_i - \mathbf{x}_i^T \hat{\beta}.$$

Exemplo:

- ▶ Considere uma amostra

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

independente tal que $Y_i \sim \text{Poisson}(\lambda_i)$.

- ▶ A função de verossimilhança é dada por

$$f(\mathbf{y}, \boldsymbol{\lambda}) = \prod_i \lambda_i^{y_i} \frac{e^{-\lambda_i}}{y_i!}$$

portanto a log-verossimilhança é dada por

$$\log(f(\mathbf{y}, \boldsymbol{\lambda})) = \sum_i (y_i \log(\lambda_i) - \lambda_i - \log(y_i!))$$

$$\sum_i y_i \log(\lambda_i) - \sum_i \lambda_i - \sum_i \log(y_i!).$$

- ▶ Vamos encontrar a Deviance para esse modelo.

Exemplo: (continuação)

- ▶ Para o modelo saturado temos que a média estimada pelo modelo é exatamente igual a observação.
- ▶ Portanto

$$\hat{E}(Y_i) = \hat{\lambda}_i = y_i.$$

- ▶ Vamos substituir λ_i por y_i na log-verossimilhança

$$\log(f(\mathbf{y}; \beta)) = \sum_i y_i \log(y_i) - \sum_i y_i - \sum_i \log(y_i!).$$

Exemplo: (continuação)

- ▶ Vamos denotar por $\hat{\lambda}_i$ a média estimada pelo modelo sob análise.
- ▶ Para obtermos a log-verossimilhança no modelo sob análise basta substituir esse valor na equação

$$\sum_i y_i \log(\hat{\lambda}_i) - \sum_i \hat{\lambda}_i - \sum_i \log(y_i!).$$

- ▶ Temos então que

$$l(\mathbf{b}_{max}, \mathbf{y}) = \sum_i y_i \log(y_i) - \sum_i y_i - \sum_i \log(y_i!)$$

$$l(\mathbf{b}, \mathbf{y}) = \sum_i y_i \log(\hat{\lambda}_i) - \sum_i \hat{\lambda}_i - \sum_i \log(y_i!)$$

Exemplo: (continuação)

- ▶ A função Deviance fica

$$\begin{aligned}
 D &= 2 [l(\mathbf{b}_{max}, \mathbf{y}) - l(\mathbf{b}, \mathbf{y})] \\
 &= \sum_i y_i \log(y_i) - \sum_i y_i - \sum_i \log(y_i!) - \\
 &\quad \left(\sum_i y_i \log(\hat{\lambda}_i) - \sum_i \hat{\lambda}_i - \sum_i \log(y_i!) \right) \\
 &= \sum_i y_i \log \left(\frac{y_i}{\hat{\lambda}_i} \right) + \sum_i (\hat{\lambda}_i - y_i)
 \end{aligned}$$

Exemplo: (continuação)

- ▶ Vamos retomar um exemplo visto na aula anterior.
- ▶ A Tabela a seguir apresenta os dados observados

Exemplo: (continuação)

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

Exemplo: (continuação)

- ▶ O modelo ajustado foi o seguinte

$$\hat{y}_i = 7,4516 + 4,9353x_i$$

- ▶ A tabela a seguir mostra os valores necessários para o cálculo da Deviance

Exemplo: (continuação)

- ▶ A Deviance é dada por

$$D = 2 [0,94735 - 0] = 1,8947 .$$

- ▶ Você acha que o modelo está bem ajustado?
- ▶ Aparentemente sim, pois a Deviance é pequena.

- ▶ A Deviance é sempre maior ou igual a zero.
- ▶ Quando aumentamos o número de variáveis o que acontece?
- ▶ O ajuste do modelo aos dados melhora.
- ▶ A **Deviance diminui**.
- ▶ Qual a Deviance do modelo saturado? Zero.
- ▶ Então esse é o modelo ideal? Não.
- ▶ O modelo tem muitos parâmetros.

- ▶ Precisamos verificar se:
 - ▶ a redução na Deviance justifica inclusão de uma nova variável.
- ▶ Vejamos agora como testar adequação do modelo usando a Deviance.
- ▶ Pode-se mostrar que, se o modelo é adequado

$$D \sim \chi_{n-p}^2$$

onde

- ▶ n é o tamanho da amostra;
- ▶ p é o número de parâmetros do modelo.

Exemplo:

- ▶ Considere o exemplo da Regressão de Poisson.
- ▶ O valor calculado da Deviance foi de

$$D = 1,8947 .$$

- ▶ Nesse caso $p = 2$ e $n = 9$.
- ▶ Se o modelo está bem ajustado

$$D \sim \chi_7^2 .$$

- ▶ Qual o valor esperado da distribuição? 7.
- ▶ Você acha que o modelo está bem ajustado?
- ▶ O modelo não é bem ajustado para valores pequenos ou grandes de D ? Grandes.
- ▶ A Deviance observada é bem menor que o esperado, o modelo está bem ajustado.
- ▶ A Deviance é pequena, se comparada com o que seria esperado. \Rightarrow Modelo bem ajustado!

Exemplo:

- ▶ Hipóteses:

H_0 : O modelo está bem ajustado (Deviance Pequena)

H_1 : O modelo está mal ajustado (Deviance Grande)

- ▶ O teste é da forma:
 - ▶ se $D < \chi_C^2$ o modelo está bem ajustado;
 - ▶ se $D > \chi_C^2$ o modelo está mal ajustado (Rejeita H_0).
- ▶ Rejeita para valores grandes da Deviance.
- ▶ Teste unilateral à direita.
- ▶ Considerando $\alpha = 5\%$, o valor crítico é

$$\chi_C^2 = 0,014 \quad \text{pois } P(\chi_7^2 < 0,014) = 0,95 .$$

Exemplo:

- ▶ A figura a seguir mostra a densidade da χ^2_7 com os valores observados e crítico em destaque.
- ▶ Rejeita-se H_0 .

Exemplo:

- ▶ O código em R usado para fazer o gráfico encontra-se a seguir.

```
curve(dchisq(x, 7), from=0, to=20, ylab=expression(t
, xlab=expression(f(theta)))
abline(v=1.8947, col='red')
abline(v=0.014, col='blue')
legend("topright", c("Valor observado", "Valor crítico"),
, fill=c("red", "blue"))
```

Observação

- ▶ Além de testarmos o ajuste do modelo, podemos testar a significância dos parâmetros individualmente.
- ▶ Isso é feito usando a distribuição assintótica

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

- ▶ Veremos como fazer esse teste no R na próxima aula..