

Seleção e comparação de modelos

Prof. Caio Azevedo

(grande parte do material apresentado foi extraído do livro Modelos de regressão com apoio computacional do Prof. Gilberto A. Paula)

[link](#)

Introdução

- Vimos como verificar se um determinado MLG se ajusta adequadamente aos dados ([aqui](#)).
- Uma outra questão de interesse surge quando se dispõe de diversos modelos (em que todos se ajustam adequadamente aos dados) e respondem às perguntas de interesse, e queremos escolher um como o “mais apropriado”.
- Há diversas técnicas disponíveis para este fim: [aqui](#), [aqui](#), [aqui](#).
- Veremos técnicas baseadas em testes de hipótese e comparação de estatísticas de qualidade de ajuste.

Teste da razão de verossimilhanças ([link](#))

- Sejam M_1 e M_2 dois modelos, em que M_1 está encaixado em M_2 , ou seja, o modelo M_1 é um caso particular de M_2 .
- Por exemplo, M_1 é um modelo linear obtido de M_2 , o qual é um modelo quadrático.
- Neste caso temos que

H_0 : o modelo M_1 é preferível ao modelo M_2 vs H_1 : o modelo M_2 é preferível ao modelo M_1 .

Teste da razão de verossimilhanças (cont.)

- Seja $\hat{\theta}_i$ o estimador de máxima verossimilhança obtido sob o modelo i e $\tilde{\theta}_i$ sua respectiva estimativa.
- Denote por $L_i(\hat{\theta}_i)$ e $l_i(\hat{\theta}_i)$ o máximo da verossimilhança e da log-verossimilhança do modelo i , respectivamente, avaliados nos respectivos estimadores de MV, enquanto que $L_i(\tilde{\theta}_i)$ e $l_i(\tilde{\theta}_i)$ são os respectivos máximos avaliados nas estimativas de MV.
- A estatística do TRV é dada por $\Delta = \frac{L_1(\hat{\theta}_1)}{L_2(\hat{\theta}_2)}$.
- Rejeita-se H_0 se $\Delta \leq \delta_c$, em que δ_c é um valor crítico adequado (geralmente difícil de ser definido de forma exata).

Teste da razão de verossimilhanças (cont.)

- Alternativamente, rejeitamos H_0 se

$$\Lambda = -2 \ln(\Delta) = -2 \left(l_1(\hat{\theta}_1) - l_2(\hat{\theta}_2) \right) \geq \lambda_c,$$

em que $P(Q \geq \lambda_c) = \alpha$, $Q \approx \chi^2_{(\gamma)}$ e $\gamma =$ número de parâmetros do modelo M_2 - número de parâmetros do modelo M_1 (sob a validade das condições de regularidade (iid), (MLG)).

- Nesse caso, p-valor $\approx P(Q \geq \lambda | H_0)$, em que λ é o valor observado da estatística Λ e $Q \sim \chi^2_{(\gamma)}$. Assim, rejeita-se H_0 se p-valor $\leq \alpha$.

Estatísticas de comparação de modelos (critérios de informação)

- O TRV é apropriado na comparação somente de modelos encaixados (o modelo com menor número de parâmetros é um caso particular do modelo com maior número de parâmetros).
- Além disso, ele não leva em consideração (diretamente) o número de parâmetros do modelo (somente na distribuição da estatística).
- Existem várias alternativas, em termos de estatísticas para comparar modelos, que “penalizam” a verossimilhança em relação ao número de parâmetros, tamanho da amostra entre outros fatores.

Cont.

- Veremos as seguintes medidas:
 - AIC (“Akaike Information Criteria” - Critério de Informação de Akaike).
 - BIC (“Bayesian Information Criteria” - Critério de informação Bayesiano, também conhecido como SIC).
 - AIC_c (“Corrected Akaike Information Criteria” - critério de Informação de Akaike corrigido).

Cont.

- (Cont.) Veremos as seguintes medidas:
 - SABIC (“Sample Adjusted BIC” - BIC ajustado pelo tamanho da amostra).
 - HQIC (“Hannan-Quinn information criterion” - Critério de informação de Hanna-Quinn).
 - CAIC (“Consistent AIC” - AIC consistente).

Cont.

- As estatísticas mencionadas anteriormente, para o i -ésimo modelo, são dadas, respectivamente, por:

$$AIC_i = -2l_i(\tilde{\theta}_i) + 2k ; BIC_i = -2l_i(\tilde{\theta}_i) + k \ln(n)$$

$$AIC_{c_i} = AIC_i + \frac{2k(k+1)}{n-k-1} ; SABIC_i = -2l_i(\tilde{\theta}_i) + k \ln\left(\frac{n+2}{24}\right)$$

$$HQIC_i = -2l_i(\tilde{\theta}_i) + 2k \ln(\ln(n)) ; CAIC_i = -2l_i(\tilde{\theta}_i) + k(\ln(n) + 1)$$

que $l_i(\tilde{\theta}_i)$ denota a log-verossimilhança do i -ésimo modelo avaliada em alguma estimativa (p.e. máxima verossimilhança), k é o número de parâmetros e n é o número de observações.

- Portanto, o modelo que apresentar os menores valores será o modelo “melhor ajustado” aos dados.

Métodos de seleção “dinâmicos” ou automatizados

- Existem métodos que selecionam modelos, fixados alguns critérios, de modo “dinâmico” (automatizado).
- Veremos os métodos “forward”, “backward” e “stepwise”.
- Tais métodos são particularmente úteis quando se dispões de muitas covariáveis.
- Sem perda de generalidade, vamos considerar um determinado modelo (p.e., normal linear homocedástico) tal que o preditor linear é dado por

$$\eta_{ij} = \beta_0 + \sum_{j=1}^{p-1} \beta_j x_{ij}.$$

Método “forward”

- Primeiramente, ajustamos um modelo com somente o intercepto, ou seja $\eta_{ij} = \beta_0$. Ajustamos então, para cada variável explicativa, um modelo

$$\eta_{ij} = \beta_0 + \beta_j x_{ij}, j = 1, 2, \dots, p - 1.$$

- Testa-se $H_0 : \beta_j = 0$ vs $H_1 : \beta_j \neq 0$, $j=1,2,\dots,p-1$ (usando-se algum teste como o TRV, teste $C\beta$, ou alguma estatística de comparação de modelos).
- Seja P o menor nível descritivo entre os $p - 1$ testes. Se $P \leq P_E$ a variável correspondente entra no modelo (caso contrário, o processo é interrompido).

Métodos “forward” (cont.)

- Vamor supor que a variável x_1 foi escolhida. Então, no passo seguinte, ajustamos os modelos

$$\eta_{ij} = \beta_0 + \beta_1 x_{1j} + \beta_j x_{ij}, j = 2, \dots, p - 1.$$

- Testa-se $H_0 : \beta_j = 0$ vs $H_1 : \beta_j \neq 0$, $j=2, \dots, p-1$ (usando-se algum teste como TRV, teste $C\beta$, ou alguma estatística de comparação de modelos).
- Seja P o menor nível descritivo entre os $p - 2$ testes. Se $P \leq P_E$ a variável correspondente entra no modelo. Repetimos o procedimento até que ocorra $P > P_E$.

Método “backward”

- Primeiramente, ajustamos o seguinte modelo:

$$\eta_{ij} = \beta_0 + \sum_{j=1}^{p-1} \beta_j x_{ij}.$$

- Testa-se $H_0 : \beta_j = 0$ vs $H_1 : \beta_j \neq 0$, $j=1,2,\dots,p-1$ (usando-se algum teste como o TRV, teste $\mathbf{C}\beta$, ou alguma estatística de comparação de modelos).
- Seja P o maior nível descritivo entre os $p - 1$ testes. Se $P > P_S$ a variável correspondente sai do modelo (caso contrário, o processo é interrompido).

Método “backward” (cont.)

- Vamos supor que x_1 tenha saído do modelo. Então ajustamos o seguinte modelo

$$\eta_{ij} = \beta_0 + \sum_{j=2}^{p-1} \beta_j x_{ij}.$$

- Testa-se $H_0 : \beta_j = 0$ vs $H_1 : \beta_j \neq 0$, $j=2, \dots, p-1$ (usando-se algum teste como TRV, teste $\mathbf{C}\beta$, ou alguma estatística de comparação de modelos).
- Seja P o maior nível descritivo entre os $p - 2$ testes. Se $P > P_S$ a variável correspondente sai do modelo. Repetimos o procedimento até que ocorra $P \leq P_S$.

Método “stepwise”

- É uma mistura dos dois procedimentos anteriores.
- Iniciamos o processo com o modelo $\eta_{ij} = \beta_0$. Após duas variáveis terem sido incluídas no modelo, verificamos se a primeira sai ou não do modelo.
- O processo continua até que nenhuma variável seja incluída ou retirada do modelo.
- Geralmente adotamos $0,15 \leq P_E \leq P_S \leq 0,25$. Outra possibilidade é usar $P_E = P_S = 0,20$.
- Pode-se também começar pelo modelo completo e verificar se, após a exclusão de duas variáveis, se a primeira volta ou não ao modelo.

Métodos anteriores usando algum critério de Informação

- Para qualquer um dos métodos anteriores, se usarmos alguma estatística de comparação de modelos, procedemos da seguinte forma
 - Sempre escolhemos o modelo (retirar/incluir a variável) que apresentar o menor valor da estatística.
 - O processo é interrompido quando as estatísticas para todos os modelos possíveis aumentarem em relação ao modelo corrente.
- Outros métodos de seleção de covariáveis: **LASSO**, **LASSO generalizado**, **spike and slab**, **spike and slab LASSO**.

Análise do desvio

- Suponha que $\beta_{(p \times 1)} = (\beta_1', \beta_2')'$ de tal forma que $\beta_{1(q \times 1)}$ e que desejamos testar $H_0 : \beta_1 = \mathbf{0}$ vs $H_1 : \beta_1 \neq \mathbf{0}$.
- Defina

$$Q_{AD} = \frac{(D(\mathbf{y}; \hat{\mu}^{(0)}) - D(\mathbf{y}; \hat{\mu})) / q}{D(\mathbf{y}; \hat{\mu}) / (n - p)},$$

em que $D(\mathbf{y}; \hat{\mu}^{(0)})$ e $D(\mathbf{y}; \hat{\mu})$ representam, respectivamente, o desvio associado ao modelo ajustado sob H_0 e ao modelo ajustado sem a restrição.

Análise do desvio

- Sob H_0 e para n suficientemente grande, temos que $Q_{AD} \approx F_{(q, n-p)}$.
- Note que para se utilizar tal estatística não é necessário estimar ϕ .
- Assim, rejeita-se H_0 se p -valor $\leq \alpha$, em que p -valor $\approx P(X \geq q_{AD} | H_0)$, $X \sim F_{(q, n-p)}$ e

$$q_{AD} = \frac{(D(\mathbf{y}; \tilde{\boldsymbol{\mu}}^{(0)}) - D(\mathbf{y}; \tilde{\boldsymbol{\mu}})) / q}{D(\mathbf{y}; \tilde{\boldsymbol{\mu}}) / (n - p)},$$

($\tilde{(\cdot)}$ representa a respectiva estimativa).