

CAPÍTULO 8. REGRESSÃO MÚLTIPLA – TESTES DE HIPÓTESES E INTERVALOS DE CONFIANÇA

PARTE II: TESTES DE HIPÓTESES E INTERVALOS DE CONFIANÇA PARA DIVERSOS β_j 's OU DIVERSAS COMBINAÇÕES $a_i'\beta$

8.5 TESTES SOBRE β_j E PARA UMA COMBINAÇÃO $\alpha'\beta$

Muitas vezes queremos realizar **diversos** testes separados, do tipo $H_0: \beta_j = 0$, ao invés de um **único** teste $H_0: \beta_1 = 0$. Ou então, realizar diversos testes separados, do tipo $H_0: \alpha'_i \beta = 0$, ao invés de um único teste $H_0: C\beta = 0$.

Problema: Quando realizamos diversos testes separados do tipo $H_0: \beta_j = 0$ ou do tipo $H_0: \alpha'_i \beta = 0$, usando um nível de significância $\alpha = 0,05$ para cada teste, pode ocorrer um aumento no nível de significância global, o que pode alterar os resultados das inferências.

8.5.1 Testando um β_j ou uma combinação $\alpha'\beta$

Usando a abordagem **modelo completo versus modelo reduzido.**, para testar $H_0: \beta_j = 0$ utilizamos a estatística:

$$F = \frac{(\hat{\beta}'\mathbf{X}'\mathbf{y} - \hat{\beta}_1^*\mathbf{X}_1'\mathbf{y})}{(\mathbf{y}'\mathbf{y} - \hat{\beta}'\mathbf{X}'\mathbf{y})/(n-k-1)} \quad (8.37)$$

que tem distribuição $F(1, n-k-1)$ se H_0 é verdadeira.

Nesta abordagem, β_j é o último β e é feito um arranjo nas colunas \mathbf{X} de tal forma que $\mathbf{X} = [\mathbf{X}_1 : \mathbf{x}_j]$, onde \mathbf{x}_j é a última coluna de \mathbf{X} .

Para testar se **uma combinação dos β 's** é nula, ou seja, $H_0: \mathbf{a}'\boldsymbol{\beta} = 0$ *versus* $H_a: \mathbf{a}'\boldsymbol{\beta} \neq 0$, usamos o **teste da hipótese linear geral**, com o vetor \mathbf{a}' no lugar da matriz \mathbf{C} em $H_0: \mathbf{C}\boldsymbol{\beta} = \mathbf{0}$, para $q = 1$.

A estatística utilizada é:

$$F = \frac{(\mathbf{a}'\hat{\boldsymbol{\beta}})' [\mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}]^{-1} (\mathbf{a}'\hat{\boldsymbol{\beta}})}{SQResiduo/(n-k-1)} = \frac{(\mathbf{a}'\hat{\boldsymbol{\beta}})^2}{s^2 \mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}} \quad (8.38)$$

onde $s^2 = QMResiduo$. Sob H_0 a estatística F em (8.38) tem distribuição $F(1, n-k-1)$.

Nota: Em modelos de regressão múltipla é pouco comum testar hipóteses sobre combinações lineares dos β 's

Para testar $H_0: \beta_j = 0$ nesta abordagem usamos $\boldsymbol{\alpha}' = [0, \dots, 0, 1, 0, \dots, 0]$, onde o número 1 está na posição $(j+1)$ e a estatística:

$$F = \frac{(\hat{\beta}_j)^2}{s^2 g_{j+1, j+1}} \quad (8.39)$$

onde $g_{j+1, j+1}$ é o $(j+1)$ -ésimo elemento da diagonal de $(\mathbf{X}'\mathbf{X})^{-1}$.

Regra: Rejeitamos H_0 se $F > F(\alpha, 1, n-k-1)$ ou se $p\text{-valor} \leq \alpha$.

Importante: Como em (8.39) $F \sim F(1; n-k-1)$ graus de liberdade, para testar $H_0: \beta_j = 0$, podemos usar de **forma equivalente**, a estatística $t = \sqrt{F}$ definida como:

$$t_j = \frac{\hat{\beta}_j}{s\sqrt{g_{j+1,j+1}}} \quad (8.40)$$

Neste caso, rejeitamos $H_0: \beta_j = 0$ se $|t_j| > t(\alpha/2, n-k-1)$ ou, equivalentemente, se $p\text{-valor} \leq \alpha$.

Vale notar que para um teste bilateral $H_0: \beta_j = 0$ *versus* $H_a: \beta_j \neq 0$,

$$p\text{-valor} = 2P(t > |t_j|)$$

onde t_j é o valor da estatística de teste calculado em (8.40).

8.5.2 Testar diversos β_j 's ou diversas combinações $\mathbf{a}_i'\boldsymbol{\beta}$

Quando testamos diversas hipóteses $H_0: \beta_j = 0$ ou $H_0: \mathbf{a}_i'\boldsymbol{\beta} = 0$, existem dois níveis de significância (α) diferentes envolvidos nas comparações:

- nível de significância geral ou *familywise α level* (α_f)
- nível de significância para cada comparação (α_c) ou *comparison-wise α level*.

Alguns testes controlam o nível de significância geral (α_f) e outros, o nível de significância para cada comparação (α_c)

- 1) O teste de regressão global (ou geral) $H_0: \boldsymbol{\beta}_1 = \mathbf{0}$ em que $\boldsymbol{\beta}_1 = [\beta_1, \beta_2, \dots, \beta_k]'$ é feito utilizando um nível α de significância geral ou *familywise α level* (α_f).
- 2) Vamos testar $H_0: \beta_j = 0$, para $j = 1, 2, \dots, k$.

Seja α_c = “nível de significância por comparação ou para cada teste” ou *comparison-wise α level*.

Problema: Se o teste $H_0: \beta_j = 0$ for executado k vezes ao nível α_c de significância em cada teste ocorrerá um **aumento** do nível α -geral (α_f). Probabilisticamente tem-se:

$$\alpha_f = 1 - (1 - \alpha_c)^k$$

Exemplo: Realizar diversos testes $H_0: \beta_j = 0$, fixando um nível de significância $\alpha_c = 0,05$ para cada teste:

# testes	1	2	4	6	8
α_f	0,05	0,0975	0,1855	0,2649	0,3366

Note que o nível de significância geral (α_f) aumenta bastante com o aumento do número de testes

- O método de Bonferroni e o de Scheffé, foram desenvolvidos para proteger contra essa inflação do nível α -global quando diversos testes são realizados.

Vamos assumir que os testes para $H_0: \beta_j = 0$ serão executados **sem considerar** se a hipótese global $H_0: \boldsymbol{\beta}_1 = \mathbf{0}$ foi rejeitada.

MÉTODO DE BONFERRONI

Suponhamos que sejam executados k testes de hipóteses do tipo $H_0: \beta_j = 0$, para $j = 1, 2, \dots, k$.

- Para assegurar que o nível α_f seja menor ou igual a um valor desejado, $\alpha_f \leq \alpha^*$, basta assumir em cada um dos k testes, um nível de significância

$$\alpha_c = \frac{\alpha^*}{k}$$

- É comum fixar $\alpha^* = 0,05$.
- A tabela de Bonferroni de valores críticos $t(\alpha^*/2k)$ pode ser encontrada em Rencher (1995, pág. 499-500), dentre outros.

Para testar $H_0: \beta_j = 0$ versus $H_a: \beta_j \neq 0$, para $j = 1, 2, \dots, k$ a um nível de significância $\alpha_j = \alpha^*/k$ usamos a estatística:

$$t_j = \frac{\hat{\beta}_j}{s\sqrt{g_{j+1,j+1}}} \quad (8.42)$$

Rejeitamos H_0 se $|t_j| > t(\alpha^*/2k, n-k-1)$ ou se $p\text{-valor} \leq \alpha^*/2k$.

Para testar $H_{0i}: \mathbf{a}_i' \boldsymbol{\beta} = 0$, para $i = 1, 2, \dots, d$, usamos a estatística:

$$F_i = \frac{(\mathbf{a}_i' \hat{\boldsymbol{\beta}})' [\mathbf{a}_i' (\mathbf{X}' \mathbf{X})^{-1} \mathbf{a}_i]^{-1} (\mathbf{a}_i' \hat{\boldsymbol{\beta}})}{s^2} = \frac{(\mathbf{a}_i' \hat{\boldsymbol{\beta}})^2}{s^2 \mathbf{a}_i' (\mathbf{X}' \mathbf{X})^{-1} \mathbf{a}_i} \quad (8.43)$$

e rejeitamos H_{0i} se $F_i > F(\alpha^*/d, 1, n-k-1)$ ou se $p\text{-valor} \leq \alpha^*/d$.

Observações importantes:

- O α -global do procedimento para testar d combinações dos β 's, $H_{0i}: \mathbf{a}_i' \boldsymbol{\beta} = 0, i = 1, 2, \dots, d$, é válido somente se os coeficientes dos vetores $\mathbf{a}_1, \dots, \mathbf{a}_d$ forem **especificados *a priori***, ou seja, se forem escolhidos antes de olhar as estimativas dos β 's.
- Se desejarmos fixar os coeficientes \mathbf{a}_i das combinações dos β 's, *a posteriori*, depois de olhar os dados ou as estimativas dos β 's, devemos usar o **método de Scheffé**, que será apresentado a seguir.

MÉTODO DE SCHEFFÉ

O procedimento de Scheffé para controlar α_f produz testes simultâneos de $H_0: \mathbf{a}'\boldsymbol{\beta} = 0$ (ou $H_0: \mathbf{a}'\boldsymbol{\beta} = t$) para **todo vetor \mathbf{a}** definido *a priori* ou *a posteriori*.

Para encontrar um valor crítico grande o suficiente que possa ser usado para comparar todos os possíveis vetores \mathbf{a} , a distribuição do $\max_{\mathbf{a}}(F)$ é utilizada.

Para testar a hipótese $H_0: \mathbf{a}'\boldsymbol{\beta} = 0$ é usada a estatística

$$F = \frac{(\mathbf{a}'\hat{\boldsymbol{\beta}})^2}{s^2 \mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}} \quad (8.44)$$

e rejeitamos H_0 se $F > (k + 1) F(\alpha^*, k + 1, n - k - 1)$.

Para testar $H_{0j}: \beta_j = 0$ individuais usando Scheffé, tomamos $\mathbf{a}' = [0, \dots, 0, 1, 0, \dots, 0]$, com o número 1 na $(j+1)$ -ésima posição.

A raiz quadrada da estatística F é $t_j = \hat{\beta}_j / \sqrt{s^2 g_{j+1, j+1}} \sim t_{(n-k-1)}$ como em (8.42).

\Rightarrow Rejeitamos $H_0: \mathbf{a}'\boldsymbol{\beta} = \beta_j = 0$ se

$$|t_j| \geq \sqrt{(k+1) F(\alpha^*, k+1, n-k-1)}$$

Observações:

- Os testes de Bonferroni para β_j 's individuais em (8.42) são **conservadores** e **mais poderosos** que os testes de Scheffé.
- Teste conservativo ou conservador: controla bem a ocorrência do erro tipo I, que consiste em rejeitar erroneamente H_0 .
- Teste mais poderoso: maior probabilidade de rejeitar corretamente H_0 .
- Para um **grande número de combinações lineares** $\alpha' \beta$ o teste de Scheffé é melhor, porque para qualquer número de escolhas de $\alpha' \beta$ pode ser testado contra um **único valor crítico**:

$$(k + 1) F(\alpha^*, k + 1, n - k - 1)$$

enquanto o valor crítico para o teste de Bonferroni em (8.43) $F(\alpha^*/d, 1; n - k - 1)$ aumenta com o número de testes, d .

- Podemos usar o teste de Scheffé para combinações lineares $\mathbf{a}'\boldsymbol{\beta}$ escolhidas **depois de olhar os dados** (*post hoc*), o que não é possível com o método de Bonferroni.

Observação:

Se os k testes $H_0: \beta_j = 0, j = 1, 2, \dots, k$ forem realizados usando, por exemplo, a estatística

$$t_j = \hat{\beta}_1 / s \sqrt{g_{j+1,j+1}}, \text{ em (8.42)}$$

somente se $H_0: \boldsymbol{\beta}_1 = \mathbf{0}$ foi rejeitada usando F em (8.5), **o que é bastante comum**, a taxa de erro global é reduzida e os valores críticos

$$t(\alpha^*/2k, n-k-1) \text{ e } \sqrt{(k+1) F(\alpha^*, k+1, n-k-1)}$$

serão ainda **mais conservativos**.

Conclusão: Se a hipótese $H_0: \boldsymbol{\beta}_1 = \mathbf{0}$ foi rejeitada, podemos usar α^* em cada teste $H_0: \beta_j = 0$ ou $H_0: \mathbf{a}'\boldsymbol{\beta} = 0$ que o $\alpha_f \cong \alpha^*$

Exemplo 8.5.2. Testar $H_{01}: \beta_1 = 0$ e $H_{02}: \beta_2 = 0$ para os dados da Tabela 7.1. Já sabemos que:

$$\hat{\boldsymbol{\beta}} = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = \begin{bmatrix} 5.3754 \\ 3.0118 \\ -1.2855 \end{bmatrix} \quad s^2 = 2.8288$$

$$\widehat{cov}(\hat{\boldsymbol{\beta}}) = s^2 \begin{bmatrix} 0.97476 & 0.24290 & -0.22871 \\ 0.24290 & 0.16207 & -0.11120 \\ -0.22871 & -0.11120 & 0.08360 \end{bmatrix}$$

Usando a estatística t_j em (8.42) temos:

$$t_1 = \frac{\hat{\beta}_1}{s\sqrt{g_{2,2}}} = \frac{3.0118}{\sqrt{2.8288}\sqrt{0.16207}} = 4.4482$$

$$t_2 = \frac{\hat{\beta}_2}{s\sqrt{g_{3,3}}} = \frac{-1.2855}{\sqrt{2.8288}\sqrt{0.08360}} = -2.6435$$

a) Usando um nível de significância $\alpha = 5\%$ para cada teste, **rejeitaremos** H_{01} e H_{02} porque $t(0.025, 9) = 2.262$.

Os p -valores (**bilaterais**) para t_1 e t_2 são:

$$p\text{-valor}_1 = 2P(t > |t_1|) = 2P(t > |4.4482|) = 0.0016$$

$$p\text{-valor}_2 = 2P(t > |t_2|) = 2P(t > |-2.6435|) = 0.0268$$

b) Usando o método de Bonferroni: 2 testes $\Rightarrow \alpha_c = 0,05/2 = 0,025$
para cada teste \Rightarrow **não rejeitaríamos** $H_{02}: \beta_2 = 0$ porque

$$p\text{-valor}_2 = 0,0268 > 0,025$$

Note que:

Usual: $t(0,025; 9 \text{ gl}) = 2,2622$

Bonferroni: $t(0,0125; 9 \text{ gl}) = 2,6850$

Scheffé: $t(0,025; 9 \text{ gl}) = 3,4041$

8.6 INTERVALOS DE CONFIANÇA E INTERVALOS DE PREDIÇÃO

Vamos considerar intervalos de confiança para β_j , $\mathbf{a}'\boldsymbol{\beta}$, $E(y)$ e σ^2 , além de intervalos de predição para futuras observações.

8.6.1 Região de confiança para $\boldsymbol{\beta}$

(Detalhes no livro do Rencher)

Uma região de $100(1 - \alpha)\%$ confiança para $\beta_0, \beta_1, \dots, \beta_k$ consiste de todos os valores de $\boldsymbol{\beta}$ que satisfazem:

$$(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})' \mathbf{X}' \mathbf{X} (\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}) \leq (k + 1)F(\alpha, k+1, n-k-1) \quad (8.46)$$

Se $k = 1$ variável regressora: a região de confiança é uma elipse em duas dimensões. Para mais de uma variável regressora a região é um elipsoide, difícil de visualizar e interpretar.

8.6.2. Intervalos de confiança para β_j

Se $\beta_j \neq 0$ em (8.40) nós podemos escrever que:

$$P \left[-t_{\alpha/2, n-k-1} \leq \frac{\hat{\beta}_j - \beta_j}{s\sqrt{g_{j+1, j+1}}} \leq t_{\alpha/2, n-k-1} \right] = 1 - \alpha$$

Resolvendo para β_j , temos:

$$P \left[\hat{\beta}_j - t_{\alpha/2}(s)\sqrt{g_{j+1, j+1}} \leq \beta_j \leq \hat{\beta}_j + t_{\alpha/2}(s)\sqrt{g_{j+1, j+1}} \right] = 1 - \alpha$$

Podemos escrever que:

$$\hat{\beta}_j \pm t_{\alpha/2, n-k-1}(s)\sqrt{g_{j+1, j+1}} \quad (8.47)$$

são os limites do **intervalo de confiança** $100(1 - \alpha)\%$ para β_j .

Dizemos que “o intervalo obtido em (8.47) contém o verdadeiro valor de β_j com $100(1-\alpha)\%$ de confiança”.

Vale observar que o coeficiente de confiança $(1-\alpha)$ vale para um **único intervalo de confiança** para um dos β_j 's.

Para calcular intervalos de confiança para todos os β_j 's, com coeficiente de confiança global de $(1-\alpha)$, veja a Seção 8.6.7.

Exemplo 8.6.2. Vamos calcular o $IC(95\%)$ para cada β_j usando y_2 no conjunto de dados apresentados na Tabela 7.4.

São dados: $s = 4,0781$, $t_{0,025;15} = 2,1314$.

$$(\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} 65.3755 & -0.3388 & -0.3125 & -0.0204 \\ -0.3388 & 0.0018 & 0.0013 & -0.0004 \\ -0.3125 & 0.0013 & 0.0041 & -0.0018 \\ -0.0204 & -0.0004 & -0.0018 & 0.0216 \end{bmatrix}$$

$$\hat{\beta} = \begin{bmatrix} -26.0353 \\ 0.4046 \\ 0.2930 \\ 1.0338 \end{bmatrix}$$

Para β_1 , obtemos por (8.47):

$$\begin{aligned} \hat{\beta}_1 \pm t_{0.025;15}(s)\sqrt{g_{2,2}} &= 0.4046 \pm (2.1314)(4.0781)\sqrt{0.0018} \\ &= 0.4046 \pm 0.3723 \\ \Rightarrow IC(\beta_1, 95\%) &= (0.0322; 0.7769) \end{aligned}$$

Para os outros β_j 's temos:

$$\begin{aligned} \beta_0: -26.0353 \pm 70.2812 &\Rightarrow IC(\beta_0, 95\%) = (-96.3165; 44.2459) \\ \beta_2: 0.2930 \pm 0.5551 &\Rightarrow IC(\beta_2, 95\%) = (-0.2621; 0.8481) \\ \beta_3: 1.0338 \pm 1.2777 &\Rightarrow IC(\beta_3, 95\%) = (-0.2439; 2.3115) \end{aligned}$$

Vale observar que:

- O coeficiente de confiança de 95% vale somente para um dos quatro intervalos de confiança.
- Para mais de um I.C. ver Exemplo 8.6.7.

8.6.3 Intervalo de confiança para $\mathbf{a}'\boldsymbol{\beta}$

Se $\mathbf{a}'\boldsymbol{\beta} \neq 0$ em (8.44) e pelo Problema 5.12, podemos escrever que os limites do **intervalo de confiança** $(1-\alpha)$ para **um único $\mathbf{a}'\boldsymbol{\beta}$** como:

$$\mathbf{a}'\hat{\boldsymbol{\beta}} \pm t_{\alpha/2, n-k-1}(s) \sqrt{\mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}} \quad (8.49)$$

8.6.4 Intervalo de confiança para $E(y)$

- Seja $\mathbf{x}_0 = [1, x_{01}, x_{02}, \dots, x_{0k}]'$ uma escolha particular de $\mathbf{x} = [1, x_1, x_2, \dots, x_k]'$, que não precisa ser uma linha da matriz \mathbf{X} .
- Se \mathbf{x}_0 estiver muito fora da região coberta pela amostra, a previsão baseada em \mathbf{x}_0 será pobre.

Um **intervalo de confiança** $100(1-\alpha)\%$ para $E(y_0) = \mathbf{x}_0'\boldsymbol{\beta}$ de (8.49), que é a média da distribuição dos valores y correspondente a \mathbf{x}_0 é dado por:

$$\mathbf{x}_0'\hat{\boldsymbol{\beta}} \pm t_{\alpha/2, n-k-1}(s)\sqrt{\mathbf{x}_0'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}_0} \quad (8.52)$$

Garante a confiança de $1-\alpha$ para uma **única** escolha do vetor \mathbf{x}_0 .

Para I.C.'s cobrindo todas as escolhas de \mathbf{x}_0 's, veja a Seção 8.6.7.

Para o caso especial de uma **regressão linear simples**, temos que o intervalo de confiança para $E(y_0)$ é dado por:

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm t_{\alpha/2, n-2}(s) \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \quad (8.58)$$

Vale notar que o tamanho do intervalo em (8.58) depende de quão longe x_0 está de \bar{x} .

8.6.5. Intervalo de predição para uma observação futura

Um **intervalo de confiança** para uma **observação futura** y_0 correspondente a um x_0 é chamado **intervalo de predição**, porque y_0 é uma **observação individual**, uma **variável aleatória** ao invés de um parâmetro.

O **intervalo de predição** para uma observação futura (\mathbf{x}_0, y_0) é dado por:

$$\mathbf{x}_0' \hat{\boldsymbol{\beta}} \pm t_{\alpha/2, n-k-1}(s) \sqrt{1 + \mathbf{x}_0' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0} \quad (8.61)$$

Nota: O intervalo de predição de y_0 deverá ser mais largo que o intervalo de confiança para o parâmetro $E(y_0)$.

Para o caso da regressão linear simples, a expressão (8.61) se reduz a:

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm t_{\alpha/2, n-2}(s) \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \quad (8.63)$$

Exemplo 8.6.5. Usando os dados da Tabela 6.2 vamos calcular um intervalo de predição 95% para $x_0 = 80$, usando (8.63):

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm t_{0.025;16}(s) \sqrt{1 + \frac{1}{18} + \frac{(80-58.056)^2}{19530.944}}$$

$$80.5386 \pm 2.11998(13.8547)(1.0393)$$

$$80.5386 \pm 30.5258$$

Então, o intervalo $[50.0128; 111.0644]$ contém o verdadeiro valor de y correspondente a $x_0 = 80$, com 95% de confiança.

8.6.6 Intervalo de confiança para σ^2

(ver detalhes no livro do Rencher)

O intervalo de confiança $100(1-\alpha)\%$ para a variância é dado por:

$$\frac{(n-k-1)s^2}{\chi_{\alpha/2;n-k-1}^2} \leq \sigma^2 \leq \frac{(n-k-1)s^2}{\chi_{(1-\alpha/2);n-k-1}^2} \quad (8.65)$$

em que $\chi_{1-\alpha/2;n-k-1}^2$ é o percentil (superior) de ordem $1-\alpha/2$ e $\chi_{\alpha/2;n-k-1}^2$ é o percentil (inferior) de ordem $\alpha/2$.

O intervalo de confiança $(1-\alpha)$ para o **desvio padrão** é dado por

$$\sqrt{\frac{(n-k-1)s^2}{\chi_{\alpha/2;n-k-1}^2}} \leq \sigma \leq \sqrt{\frac{(n-k-1)s^2}{\chi_{1-\alpha/2;n-k-1}^2}} \quad (8.66)$$

8.6.7 Intervalos simultâneos

O coeficiente de confiança $(1-\alpha)$ para os intervalos obtidos nas Seções 8.6.1-8.6.6 é **válido para um único intervalo** em cada caso.

Para intervalos múltiplos adaptamos os métodos da Seção 8.5.2.

Utilizando o método de Bonferroni, intervalos de confiança para $\beta_1, \beta_2, \dots, \beta_k$ são dados por:

$$\hat{\beta}_j \pm t_{\alpha^*/(2k), n-k-1}(s) \sqrt{g_{j+1, j+1}} \quad (8.67)$$

Para d funções lineares $\mathbf{a}'_1\boldsymbol{\beta}, \mathbf{a}'_2\boldsymbol{\beta}, \dots, \mathbf{a}'_d\boldsymbol{\beta}$ escolhidas *a priori* os intervalos de confiança de Bonferroni são dados por:

$$\mathbf{a}'_i\hat{\boldsymbol{\beta}} \pm t_{\alpha^*/(2d), n-k-1}(s) \sqrt{\mathbf{a}'_i(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}_i} \quad (8.68)$$

para $i = 1, 2, \dots, d$.

Esses IC 's asseguram uma **confiança simultânea** de, no mínimo, $(1 - \alpha^*)$; isto é, garantem uma confiança de $100(1 - \alpha^*)\%$ que cada um dos d intervalos contenha o verdadeiro valor do parâmetro.

Intervalos de Bonferroni para construir IC 's para $E(y_0) = \mathbf{x}'_0 \boldsymbol{\beta}$ para poucos valores de \mathbf{x}_0 , digamos $\mathbf{x}_{01}, \mathbf{x}_{02}, \dots, \mathbf{x}_{0d}$:

$$\mathbf{x}'_{0i} \hat{\boldsymbol{\beta}} \pm t_{\alpha^*/2d, n-k-1}(s) \sqrt{\mathbf{x}'_{0i} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_{0i}} \quad (8.69)$$

para $i = 1, 2, \dots, d$.

Intervalos de predição de Bonferroni para d novas observações $y_{01}, y_{02}, \dots, y_{0d}$ em d valores de \mathbf{x}_0 , digamos $\mathbf{x}_{01}, \mathbf{x}_{02}, \dots, \mathbf{x}_{0d}$:

$$\mathbf{x}'_{0i} \hat{\boldsymbol{\beta}} \pm t_{\alpha^*/2d, n-k-1}(s) \sqrt{1 + \mathbf{x}'_{0i} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_{0i}} \quad (8.70)$$

para $i = 1, 2, \dots, d$.

Os intervalos obtidos por (8.70) terão um coeficiente de confiança global de, no mínimo, $(1-\alpha)$.

Os limites dos intervalos de confiança (conservativos) de Scheffé para **todas** as possíveis funções lineares $\mathbf{a}'\boldsymbol{\beta}$ (escolhidas *a priori* ou não) são dados por:

$$\mathbf{a}'\hat{\boldsymbol{\beta}} \pm (s)\sqrt{(k+1) F_{\alpha^*; k+1, n-k-1} \mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}} \quad (8.71)$$

- Intervalos construídos desta forma têm um **coeficiente de confiança global** de, no mínimo, $100(1-\alpha^*)\%$.
- Para poucas funções lineares, os intervalos em (8.68) serão mais estreitos, mas para um número grande de funções lineares, os intervalos em (8.69) serão mais estreitos.

Limites de confiança para $E(y_0) = \mathbf{x}'_0 \boldsymbol{\beta}$, para todos os possíveis \mathbf{x}_0 , nós usamos (8.71):

$$\mathbf{x}'_0 \hat{\boldsymbol{\beta}} \pm (s) \sqrt{(k+1) F_{\alpha^*; k+1, n-k-1} \mathbf{x}'_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0} \quad (8.72)$$

Os limites dos intervalos de predição de Scheffé para $y_{01}, y_{02}, \dots, y_{0d}$, são calculados por:

$$\mathbf{x}'_{0i} \hat{\boldsymbol{\beta}} \pm (s) \sqrt{d F_{\alpha^*; k+1, n-k-1} [1 + \mathbf{x}'_{0i} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_{0i}]} \quad (8.73)$$

para $i = 1, 2, \dots, d$.

Esses d intervalos de predição asseguram um coeficiente de confiança global de $(1 - \alpha^*)$, no mínimo.

8.7 TESTES DA RAZÃO DE VEROSSIMILHANÇAS

(Para maiores detalhes: Rencher, pág. 204)

Os testes desenvolvidos nas Seções 8.1 e 8.2 foram derivados utilizando métodos **informais** baseados em características de SQ 's que têm distribuição de quiquadrado e são independentes.

Esses mesmos testes podem ser obtidos de maneira **mais formal**, através de uma abordagem de razão de verossimilhanças.

Vamos apresentar os principais resultados do **teste da razão de verossimilhanças** (TRV) no contexto simples de testar

$$H_0: \boldsymbol{\beta} = \mathbf{0} \text{ versus } H_1: \boldsymbol{\beta} \neq \mathbf{0}.$$

A função de verossimilhança – $L(\boldsymbol{\beta}, \sigma^2)$ – foi definida na Seção 7.6.2 como a densidade conjunta dos y 's. Assumindo $\mathbf{y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \mathbf{I}\sigma^2)$

$$L(\boldsymbol{\beta}, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-(\mathbf{y}-\mathbf{X}\boldsymbol{\beta})'(\mathbf{y}-\mathbf{X}\boldsymbol{\beta})/2\sigma^2}$$

O teste da razão de verossimilhanças consiste em comparar o máximo valor de $L(\boldsymbol{\beta}, \sigma^2)$ restrito por $H_0: \boldsymbol{\beta} = \mathbf{0}$, com o máximo valor de $L(\boldsymbol{\beta}, \sigma^2)$ sob a hipótese $H_1: \boldsymbol{\beta} \neq \mathbf{0}$, que não é restrita, através da razão de verossimilhanças:

$$LR = \frac{\max_{H_0} L(\boldsymbol{\beta}, \sigma^2)}{\max_{H_1} L(\boldsymbol{\beta}, \sigma^2)} = \frac{\max L(\mathbf{0}, \sigma^2)}{\max L(\boldsymbol{\beta}, \sigma^2)} \quad (8.75)$$

É claro que $0 \leq LR \leq 1$, porque o máximo de LR restrito a $\boldsymbol{\beta} = \mathbf{0}$ não pode exceder o máximo irrestrito.

Como pequenos valores de LR favorecem a hipótese alternativa, H_1 , e grandes valores de LR favorecem H_0 , nós rejeitamos H_0 se $LR \leq c$, em que c é escolhido de tal forma que $P(LR \leq c) = \alpha$, se H_0 é verdadeira.

Wald (1943) mostrou que, sob H_0 e para n grande,

$$-2\ln(LR) \sim \chi^2(v),$$

onde v é o número de parâmetros estimados sob H_1 menos o número de estimativas sob H_0 .

No caso de $H_0: \boldsymbol{\beta} = \mathbf{0}$ versus $H_1: \boldsymbol{\beta} \neq \mathbf{0}$ nós temos $v = (k+2)-1 = k+1$, porque os coeficientes de regressão ($\boldsymbol{\beta}$) e a variância (σ^2) são estimados sob H_1 , enquanto somente a variância (σ^2) é estimada sob H_0 .

Teorema 8.7A Se $\mathbf{y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \mathbf{I}\sigma^2)$ o teste da razão de verossimilhanças para $H_0: \boldsymbol{\beta} = \mathbf{0}$ versus $H_1: \boldsymbol{\beta} \neq \mathbf{0}$ pode ser baseado em

$$F = \frac{\hat{\boldsymbol{\beta}}' \mathbf{X}' \mathbf{y} / (k+1)}{(\mathbf{y}' \mathbf{y} - \hat{\boldsymbol{\beta}}' \mathbf{X}' \mathbf{y}) / (n-k-1)}$$

Rejeitamos H_0 se $F > F_{(\alpha; k+1, n-k-1)}$.

Teorema 8.7B Se $\mathbf{y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \mathbf{I}\sigma^2)$ então o teste- F para $H_0: \mathbf{C}\boldsymbol{\beta} = \mathbf{0}$ no Teorema 8.4A é **equivalente** ao Teste da Razão de Verossimilhanças.