

REGRESSÃO LINEAR MÚLTIPLA

$$\text{renda} = \beta_1 + \beta_2 \text{educação} + \varepsilon \quad \rightarrow \quad \text{regressão linear simples}$$

$$\text{renda} = \beta_1 + \beta_2 \text{educação} + \beta_3 \text{idade} + \beta_4 \text{idade}^2 + \varepsilon \quad \rightarrow \quad \text{regressão linear múltipla}$$

Forma geral:

$$y_i = \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_K x_{iK} + \varepsilon_i \quad i = 1, \dots, n$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = y \quad \begin{bmatrix} x_{11} \\ x_{21} \\ \vdots \\ x_{n1} \end{bmatrix} = x_1 \quad \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} = \varepsilon$$

$$y = x_1 \beta_1 + x_2 \beta_2 + \dots + x_K \beta_K + \varepsilon$$

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1K} \\ x_{21} & x_{22} & & x_{2K} \\ x_{31} & x_{32} & & x_{3K} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & & x_{nK} \end{bmatrix}_{n \times K}$$

$$\beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix}_{K \times 1}$$

↙
pode ser uma coluna de 1's

$$y = X\beta + \varepsilon$$

Pressuposições do Modelo Linear:

Pressuposição 1 – y é uma função linear (nos parâmetros) de um conjunto específico de variáveis X mais um erro.

Violação: omissão de variável relevante, inclusão de variável irrelevante e não linearidade.

Pressuposição 2 – a esperança do erro é zero

Violação: tendenciosidade da constante

$$y = \alpha + \beta X + \varepsilon \quad E(\varepsilon) = c$$

$$y = \alpha + \beta X + \varepsilon + c - c$$

$$y = \alpha + c + \beta X + \varepsilon - c$$

$$y = \alpha^* + \beta X + \varepsilon^* \quad E(\varepsilon^*) = 0$$

$$E(\boldsymbol{\varepsilon}) = \begin{bmatrix} E(\varepsilon_1) \\ E(\varepsilon_2) \\ \vdots \\ E(\varepsilon_n) \end{bmatrix} = \mathbf{0}$$

o que implica em,

$$E(y) = X\beta$$

Pressuposição 3 – a variância do erro é constante, isto é, não depende de X (homoscedasticidade), e não há correlação entre os erros (não autocorrelação).

$$\varepsilon\varepsilon' = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} \begin{bmatrix} \varepsilon_1 & \varepsilon_2 & \cdots & \varepsilon_n \end{bmatrix} = \begin{bmatrix} \varepsilon_1\varepsilon_1 & \varepsilon_1\varepsilon_2 & \cdots & \varepsilon_1\varepsilon_n \\ \varepsilon_2\varepsilon_1 & \varepsilon_2\varepsilon_2 & & \varepsilon_2\varepsilon_n \\ \vdots & & & \\ \varepsilon_n\varepsilon_1 & \varepsilon_n\varepsilon_2 & \cdots & \varepsilon_n\varepsilon_n \end{bmatrix}$$

$$E(\varepsilon\varepsilon') = \begin{bmatrix} \sigma^2 & 0 & \cdots & 0 \\ 0 & \sigma^2 & \cdots & 0 \\ 0 & 0 & \cdots & \sigma^2 \end{bmatrix} = \sigma^2 I$$

Pressuposição 4 – não há correlação entre o erro e as variáveis x .

Violação: equações simultâneas, erros em variáveis.

$$E(\varepsilon|X) = 0 \Rightarrow \text{cov}(X, \varepsilon) = 0$$

$$C = \alpha + \beta Y + \varepsilon$$

$$Y = C + I$$

Pressuposição 5 – X é uma matriz ($n \times K$) não estocástica com rank K .

Isto implica que devemos ter pelo menos K observações, e que as colunas de X devem ser linearmente independentes.


Violação: multicolinearidade.

Pressuposição 6 – o erro tem distribuição normal

$$\varepsilon \sim N[0, \sigma^2 I]$$

Vetor de Coeficientes por Mínimos Quadrados.

Minimizar a soma de quadrados dos erros, isto é, minimizar



$$S = \varepsilon' \varepsilon$$

$$S = (y - X\beta)' (y - X\beta)$$

$$S = y'y - y'X\beta - \beta'X'y + \beta'X'X\beta$$

$$S = y'y - 2\beta'X'y + \beta'X'X\beta$$

Condição necessária para mínimo:

$$\frac{\partial S}{\partial \beta} = -2X'y + 2X'X\beta = 0$$

Deixe b ser a solução, então b satisfaz a equação acima.

$$X'Xb = X'y$$

Da pressuposição de rank total, $(X'X)^{-1}$ existe. Então,

$$b = (X'X)^{-1} X'y$$

Aspectos Algébricos:

As equações normais são:

$$X'Xb - X'y = -X'(y - Xb) = -X'e = 0$$

Isto significa que para cada coluna x_k de X ,

$$x_k'e = 0$$

Em particular, se a primeira coluna de X é uma coluna de 1's, a soma dos resíduos será zero.

Implicações:

1) O hiperplano de regressão passa pelas médias dos dados.

$$\bar{y} = b' \bar{X}$$

$$y = \underbrace{a + bx}_{\hat{y}} + e$$
$$\sum y = na + b \sum x + \sum e$$

$$\bar{y} = a + b\bar{x}$$

2) A média do valor ajustado da regressão iguala a média do valor atual, isto é,

$$\bar{\hat{y}} = \bar{y}$$

$$\hat{y} = a + bx$$

$$\sum \hat{y} = na + b \sum x$$

$$\bar{\hat{y}} = a + b\bar{x} = \bar{y}$$

Isto segue de 1, pois os valores ajustados são:

$$\hat{y} = Xb$$

Estes resultados não precisam necessariamente ocorrer em modelos sem constante.

Por definição, o vetor de resíduos de mínimos quadrados é:

$$\begin{aligned} e &= y - Xb = y - X(X'X)^{-1} X'y \\ &= (I - X(X'X)^{-1} X')y = My \end{aligned}$$

M é uma matriz ($n \times n$), simétrica ($M=M'$) e idempotente ($M=MM$).

M pode ser interpretada como uma matriz que quando pré-multiplica qualquer vetor y , produz um vetor de resíduos da regressão de y em função de X . Segue imediatamente que:

$$MX = (I - X(X'X)^{-1} X')X = X - X \underbrace{(X'X)^{-1} X'X}_I = 0$$

uma forma de interpretar este resultado é que a regressão de X em função de X fornece um ajustamento perfeito e, portanto, os resíduos serão zero.

Formas úteis de soma de quadrado dos resíduos:

$$e'e = y'MMy = y'My = y'e$$

$$e'e = y'e = y'(y - Xb) = y'y - y'Xb = y'y - b'X'y$$

$$e'e = y'y - b'X'Xb$$

$$e'e = (y - Xb)'(y - Xb) = y'y - 2b'X' \underbrace{(Xb + e)}_y + b'X'Xb = y'y - 2b'X'Xb - 2b'X'e + b'X'Xb$$

Regressão Parcial

Que cálculos estão envolvidos para obter, isoladamente, os coeficientes de um conjunto de variáveis na regressão múltipla? Por exemplo, o coeficiente de educação, na regressão de renda em função de educação e idade.

Suponha que a regressão envolve dois conjuntos de variáveis, X_1 e X_2 . Então,

$$y = X\beta + \varepsilon = X_1\beta_1 + X_2\beta_2 + \varepsilon$$

Qual é a solução algébrica de b_2 ? As equações normais são:

$$\begin{bmatrix} X_1' \\ X_2' \end{bmatrix} \begin{bmatrix} X_1 & X_2 \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \end{bmatrix} = \begin{bmatrix} X_1'X_1 & X_1'X_2 \\ X_2'X_1 & X_2'X_2 \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \end{bmatrix} = \begin{bmatrix} X_1'y \\ X_2'y \end{bmatrix}$$

$$(X_1'X_1)b_1 + (X_1'X_2)b_2 = X_1'y \quad \rightarrow$$

$$b_1 = (X_1'X_1)^{-1} X_1'y - (X_1'X_1)^{-1} X_1'X_2b_2$$

$$b_1 = (X_1'X_1)^{-1} X_1'(y - X_2b_2)$$

$$(X_2'X_1)b_1 + (X_2'X_2)b_2 = X_2'y$$



$$(X_2'X_1)(X_1'X_1)^{-1} X_1'y - (X_2'X_1)(X_1'X_1)^{-1} X_1'X_2b_2 + (X_2'X_2)b_2 = X_2'y$$

$$(X_2'X_2)b_2 - (X_2'X_1)(X_1'X_1)^{-1} (X_1'X_2)b_2 = X_2'y - (X_2'X_1)(X_1'X_1)^{-1} X_1'y$$

$$X_2'(I - X_1(X_1'X_1)^{-1} X_1')X_2b_2 = X_2'(I - X_1(X_1'X_1)^{-1} X_1')y$$

$$b_2 = \left[X_2' (I - X_1 (X_1' X_1)^{-1} X_1') X_2 \right]^{-1} X_2' (I - X_1 (X_1' X_1)^{-1} X_1') y$$

$$b_2 = \left[X_2' M_1 X_2 \right]^{-1} X_2' M_1 y$$

Neste caso, $M_1 X_2$ é uma matriz de resíduos. Cada coluna de $M_1 X_2$ é um vetor de resíduos da regressão da correspondente coluna de X_2 em função das variáveis em X_1

Como M_1 é uma matriz simétrica e idempotente podemos escrever.


$$b_2 = \left[X_2' M_1' M_1 X_2 \right]^{-1} \left[X_2' M_1' M_1 y \right]$$

$$b_2 = (X_2^{*'} X_2^*)^{-1} (X_2^{*'} y^*)$$

Portanto, b_2 é o conjunto de coeficientes obtido quando é feita a regressão dos resíduos da regressão de y em função de X_1 com os resíduos da regressão de X_2 em função de X_1

No exemplo, poderíamos obter o coeficiente de educação fazendo a regressão de renda em função da idade (resíduo 1) e de educação em função da idade (resíduo 2) e, então, fazendo a regressão do resíduo 1 em função do resíduo 2.

Este processo é freqüentemente chamado de partição e por esta razão os coeficientes da regressão múltipla são chamados de coeficientes parciais de regressão.



Propriedades Estatísticas dos Estimadores

$$b = (X'X)^{-1} X'y = (X'X)^{-1} X'(X\beta + \varepsilon) = (X'X)^{-1} X'X\beta + (X'X)^{-1} X'\varepsilon$$

$$b = \beta + (X'X)^{-1} X'\varepsilon = \beta + A\varepsilon = Ay$$

onde $A = (X'X)^{-1} X'$

Se X é não estocástico ou se $E(X'\varepsilon) = 0$ então $E(b) = \beta$

Portanto b é um estimador não tendencioso de β .

$$\begin{aligned} \text{Var}(b) &= E[(b - \beta)(b - \beta)'] = E\left[(X'X)^{-1} X'\varepsilon\varepsilon'X(X'X)^{-1}\right] \\ &= (X'X)^{-1} X'E(\varepsilon\varepsilon')X(X'X)^{-1} = (X'X)^{-1} X'(\sigma^2 I)X(X'X)^{-1} = \sigma^2 (X'X)^{-1} \end{aligned}$$

$$\text{Var}(b) = E(A\varepsilon)(A\varepsilon)' = E(A\varepsilon\varepsilon'A') = AE(\varepsilon\varepsilon')A' = \sigma^2 AA'$$

Pelo teorema de Gauss-Markov b é o estimador linear não tendencioso mais eficiente de β .

Prova:

Deixe $\tilde{b} = Cy$ ser qualquer outro estimador linear não tendencioso de β , onde C é uma matriz ($K \times n$). Se é não tendencioso, então,

$$E(Cy) = E(CX\beta + C\varepsilon) = \beta$$

o que implica $CX = I$

$$\text{Var}(\tilde{b}) = E[(\tilde{b} - \beta)(\tilde{b} - \beta)'] = E[C\varepsilon\varepsilon'C'] = \sigma^2 CC'$$

$$C = A + (C - A)$$

$$\sigma^2 CC' = \sigma^2 (A + (C - A))(A + (C - A))'$$

$$\sigma^2 CC' = \sigma^2 AA' + \sigma^2 A(C - A)' + \sigma^2 (C - A)A' + \sigma^2 (C - A)(C - A)'$$

$$(C - A)A' = [C - (X'X)^{-1} X']X(X'X)^{-1} = CX(X'X)^{-1} - (X'X)^{-1} = (\cancel{CX} \overset{I}{-} I)(X'X)^{-1} = 0$$

Portanto,

$$\sigma^2 CC' = \sigma^2 AA' + \sigma^2 (C - A)(C - A)'$$

$\text{Var}(\tilde{b}) = \text{Var}(b) +$ matriz semi-definida positiva

Portanto,

$$\text{Var}(\tilde{b}) \geq \text{Var}(b)$$

Testando hipóteses sobre os coeficientes.

Como b é uma função linear de ε . Se pressupormos que ε tem distribuição normal multivariada, então:

$$b \sim N\left[\beta, \sigma^2 (X'X)^{-1}\right]$$

Assim, cada elemento de b é normalmente distribuído.

$$b_k \sim N\left[\beta_k, \sigma^2 (X'X)^{-1}_{kk}\right]$$

Seja s^{kk} o k -ésimo elemento da diagonal de $(X'X)^{-1}$, então:

$$Z_k = \frac{b_k - \beta_k}{\sqrt{\sigma^2 s^{kk}}} \sim N(0,1)$$

tem distribuição normal padronizada. Se σ^2 fosse conhecido, a inferência estatística sobre β_K poderia ser baseada em Z_K . Entretanto, σ^2 terá que ser estimado e Z_K não será usado.

Voltando aos resíduos

$$e = y - Xb = y - X(X'X)^{-1}X'y = My = M(X\beta + \varepsilon) = M\varepsilon$$

já que
$$MX = 0$$

Um estimador de σ^2 será baseado na soma de quadrados dos resíduos.

$$e'e = \varepsilon'M'M\varepsilon = \varepsilon'M\varepsilon$$

$$e'e = \varepsilon'M\varepsilon$$

$$E(e'e) = E(\varepsilon'M\varepsilon)$$

$\varepsilon'M\varepsilon$ é um escalar (1x1) e assim, é igual ao seu traço.

$$E[tr(\varepsilon'M\varepsilon)] = E[tr(M\varepsilon\varepsilon')]$$

Como M é fixo

$$tr[ME(\varepsilon\varepsilon')] = tr(M\sigma^2 I) = \sigma^2 tr(M)$$

O traço de M é

$$tr(I_n - X(X'X)^{-1}X') = tr(I_n) - tr[(X'X)^{-1}X'X] = tr(I_n) - tr(I_K) = n - K$$

Portanto,

$$E(e'e) = (n - K)\sigma^2$$

e um estimador não tendencioso de σ^2 é

$$s^2 = \frac{e'e}{n - K} \quad \text{Var}\hat{b} = s^2(X'X)^{-1}$$

Lembre-se que:

O traço de uma matriz quadrada é igual a soma dos elementos da diagonal principal. \Rightarrow $\text{tr}(A) = \sum_i a_{ii}$

Propriedades:

$$\text{tr}(A+B) = \text{tr}(A) + \text{tr}(B)$$

$$\text{tr}(AB) = \text{tr}(BA)$$

$$\text{tr}(ABCD) = \text{tr}(BCDA) = \text{tr}(CDAB) = \text{tr}(DABC)$$

Lembre-se que:

$$X_i \sim N(\mu, \sigma^2) \quad Z_i = \frac{X_i - \mu}{\sigma} \sim N(0,1) \quad \sum_{i=1}^n Z_i^2 = \chi^2(n)$$

$$\begin{cases} X \sim N(0,1) \\ Y \sim \chi^2(K) \end{cases} \quad \frac{X}{\sqrt{Y/K}} \sim t(K) \quad \text{com } X \text{ e } Y \text{ independentes}$$

$$\begin{cases} Y_1 \sim \chi^2(K_1) \\ Y_2 \sim \chi^2(K_2) \end{cases} \quad \frac{Y_1/K_1}{Y_2/K_2} \sim F(K_1, K_2) \quad \text{com } Y_1 \text{ e } Y_2 \text{ independentes}$$

$$\varepsilon \sim \text{Normal} \Rightarrow b_k \sim N(\beta_k, \sigma^2 (X'X)_{kk}^{-1})$$

$$\frac{b_k - \beta_k}{\sqrt{\sigma^2 s^{kk}}} \sim N(0,1)$$

$$e'e = \varepsilon' M \varepsilon$$

$$\frac{e'e}{\sigma^2} = \left(\frac{\varepsilon'}{\sigma} \right) M \left(\frac{\varepsilon}{\sigma} \right) \sim \chi^2(n - K) \quad \text{com número de graus de liberdade igual ao rank de } M.$$

$$\frac{\varepsilon}{\sigma} \sim N(0, I) \quad \text{Var} \left(\frac{\varepsilon_i}{\sigma} \right) = \frac{1}{\sigma^2} \text{Var}(\varepsilon_i) = 1$$

M é uma matriz idempotente \Rightarrow o rank de $M =$ traço de M

Se $\text{cov}(X, Y) = 0 \Rightarrow X$ e Y são independentes se X e $Y \sim \text{Normal}$

$$\begin{aligned} \text{cov}(b, e) &= E\left[(b - \beta)(e - 0)'\right] = E\left[(X'X)^{-1} X' \varepsilon \varepsilon' M\right] = \sigma^2 (X'X)^{-1} X' M = \\ &= \sigma^2 (X'X)^{-1} X' (I - X(X'X)^{-1} X') = \sigma^2 (X'X)^{-1} X' - \sigma^2 (X'X)^{-1} \underbrace{X'X(X'X)^{-1}}_I X' = 0 \end{aligned}$$

Então b e e são independentes e,

$$\frac{\frac{b_k - \beta_k}{\sqrt{\sigma^2 s^{kk}}}}{\sqrt{\frac{e'e / \sigma^2}{n - K}}} \sim t(n - K)$$

ou

$$\frac{\frac{b_k - \beta_k}{\sqrt{\sigma^2 s^{kk}}}}{\sqrt{\frac{e'e + \sigma^2}{n - K}}} = \frac{b_k - \beta_k}{\sqrt{\frac{(n - K) s^2 s^{kk}}{n - K}}} \sim t(n - K) \quad \text{substituindo } e'e = (n - K) s^2$$

$$t_k = \frac{b_k - \beta_k}{\sqrt{s^2 s^{kk}}} = \frac{b_k - \beta_k}{s(b_k)}$$

Intervalo de confiança:

$$b_k - t_0 s(b_k) < \beta_k < b_k + t_0 s(b_k)$$

Testando uma Restrição Linear

$$H_0 : r_1 \beta_1 + r_2 \beta_2 + \dots + r_K \beta_K = r' \beta = q$$

Geralmente, alguns r 's serão zero. A estimativa amostral será:

$$r_1 b_1 + r_2 b_2 + \dots + r_K b_K = r' b = \hat{q}$$

Exemplo:

$$H_0 : \beta_1 - \beta_2 = 0$$

Se \hat{q} difere significativamente de q , concluímos que os dados da amostra não são consistentes com a hipótese.

$$t(n-K) = \frac{r'b - q}{\sqrt{\frac{r'[\sigma^2(X'X)^{-1}]r}{\frac{e'e/\sigma^2}{n-k}}}} = \frac{r'b - q}{\sqrt{\text{var}(\hat{q})}}$$

\hat{q} é uma função linear de b e a $\text{var}(b) = s^2(X'X)^{-1}$

$$E(\hat{q}) = E(r'b) = r_1 E(b_1) + \dots + r_K E(b_K) = r_1 \beta_1 + \dots + r_K \beta_K = r'\beta$$

$$\begin{aligned} \text{var}(\hat{q}) &= \text{var}(r'b) = E[r'b - r'\beta]^2 = E\left[(r'b - r'\beta)(r'b - r'\beta)'\right] \\ &= E\left[r'(b - \beta)(b - \beta)'r\right] = r' \text{var}(b)r \end{aligned}$$

$$\text{var}(\hat{q}) = r'[\sigma^2(X'X)^{-1}]r$$

Considere J restrições lineares na forma:

$$H_0 : R_{(J \times K)} \beta = q$$

1) $\beta_j = 0$

$$R = [00\dots10\dots0] \quad \text{e} \quad q = 0$$

2) $\beta_k = \beta_j$

$$R = [001\dots-1\dots0] \quad \text{e} \quad q = 0$$

3) $\beta_2 + \beta_3 + \beta_4 = 1$

$$R = [0 \ 1 \ 1 \ 1 \ 0 \ \dots] \quad \text{e} \quad q = 1$$

4) $\beta_1 = 0, \beta_2 = 0, 2\beta_3 = 1$

$$R = \begin{bmatrix} 1 & 0 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & 0 & \dots & 0 \\ 0 & 0 & 2 & 0 & \dots & 0 \end{bmatrix} \quad \text{e} \quad q = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}$$

$$5) \beta_2 + \beta_3 = 1, \beta_4 + \beta_6 = 0 \text{ e } \beta_5 + \beta_6 = 0$$

$$\begin{bmatrix} 0 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 1 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \\ \beta_4 \\ \beta_5 \\ \beta_6 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}$$

Dado o estimador de mínimos quadrados b , nosso interesse se centra na discrepância entre Rb e q . É improvável que seja exatamente 0. Queremos saber então se a diferença entre Rb e q pode ser atribuída a erro de amostragem ou se é significativa. Uma vez que b tem distribuição normal e Rb é uma função linear de b , Rb também tem distribuição normal.

$$X \sim N(\mu, \sigma^2) \quad Z = \frac{X - \mu}{\sigma} \sim N(0,1) \quad \sum_{i=1}^n Z_i^2 = \chi^2(n)$$

$$X \sim N(\mu, \Sigma) \quad \Sigma^{-1/2}(X - \mu) \sim N(0, I)$$
$$(X - \mu)' \Sigma^{-1}(X - \mu) \sim \chi^2(n)$$

$$H_0 : R\beta = q$$

Se $b \sim \text{Normal}$ então $Rb \sim \text{Normal}$

$$E(Rb) = RE(b) = R\beta$$

$$\begin{aligned} \text{var}(Rb) &= E[Rb - q]^2 = E[(Rb - R\beta)(Rb - R\beta)'] = \\ E\left[R(b - \beta)(b - \beta)' R' \right] &= RE\left[(b - \beta)(b - \beta)' \right] R' = R \text{var}(b) R' = \sigma^2 R(X'X)^{-1} R' \end{aligned}$$

Se H_0 é verdadeira,

$$W = (Rb - q)' \left[\sigma^2 R(X'X)^{-1} R' \right]^{-1} (Rb - q) \sim \chi^2(J)$$

onde J é o número de graus de liberdade

Como não conhecemos σ^2 não podemos utilizar este teste, mas utilizamos F com s^2

$$F_{(J, n-K)} = \frac{(Rb - q)' \left[\sigma^2 R(X'X)^{-1} R' \right]^{-1} (Rb - q) / J}{\frac{(n-K)s^2 / \sigma^2}{n-K}} = \frac{\frac{\chi^2(J)}{J}}{\frac{\chi^2(n-K)}{n-K}}$$

$$F_{(J, n-K)} = \frac{(Rb - q)' \left[s^2 R(X'X)^{-1} R' \right]^{-1} (Rb - q)}{J}$$

O intervalo de confiança para um único coeficiente é baseado no conjunto de valores para os quais o teste t é menor que o valor crítico especificado. É o conjunto de valores para os quais, a um dado nível de significância, nós não rejeitaríamos a hipótese de que β se iguala a um determinado valor.


No modelo de regressão múltipla, a região conjunta de confiança para um conjunto de coeficientes seria o conjunto de valores para os quais a hipótese de que o conjunto dos verdadeiros coeficientes simultaneamente iguais a determinados valores não poderia ser rejeitada.

O teste F para dois coeficientes seria:

$$F(2, n - K) = \frac{1}{2} (b - \beta)' (est. \text{ var}(b))^{-1} (b - \beta)$$

$$\frac{1}{2} \begin{bmatrix} b_1 - \beta_1 \\ b_2 - \beta_2 \end{bmatrix}' \begin{bmatrix} V(b_1) & \text{cov}(b_1, b_2) \\ \text{cov}(b_2, b_1) & V(b_2) \end{bmatrix}^{-1} \begin{bmatrix} b_1 - \beta_1 \\ b_2 - \beta_2 \end{bmatrix} = F(2, 10)$$

$$\frac{1}{2} \begin{bmatrix} b_1 - \beta_1 \\ b_2 - \beta_2 \end{bmatrix}' \begin{bmatrix} V(b_1) & \text{cov}(b_1, b_2) \\ \text{cov}(b_2, b_1) & V(b_2) \end{bmatrix}^{-1} \begin{bmatrix} b_1 - \beta_1 \\ b_2 - \beta_2 \end{bmatrix} < F(2, 10)$$



Se testar $H_0 : \beta_1 = x_0$ não rejeito H_0

Se testar $H_0 : \beta_2 = y_0$ não rejeito H_0

Se testar $H_0 : \beta_1 = x_0$ e $\beta_2 = y_0$ simultaneamente rejeito H_0

Ao testar separadamente não se leva em consideração a covariância entre b_1 e b_2 . Se a covariância for negativa, por exemplo, então dificilmente quando b_1 é grande b_2 também será, por isso cai fora da elipse.