

Regressão Linear – Abordagem Inferencial

Regressão Linear - Inferência

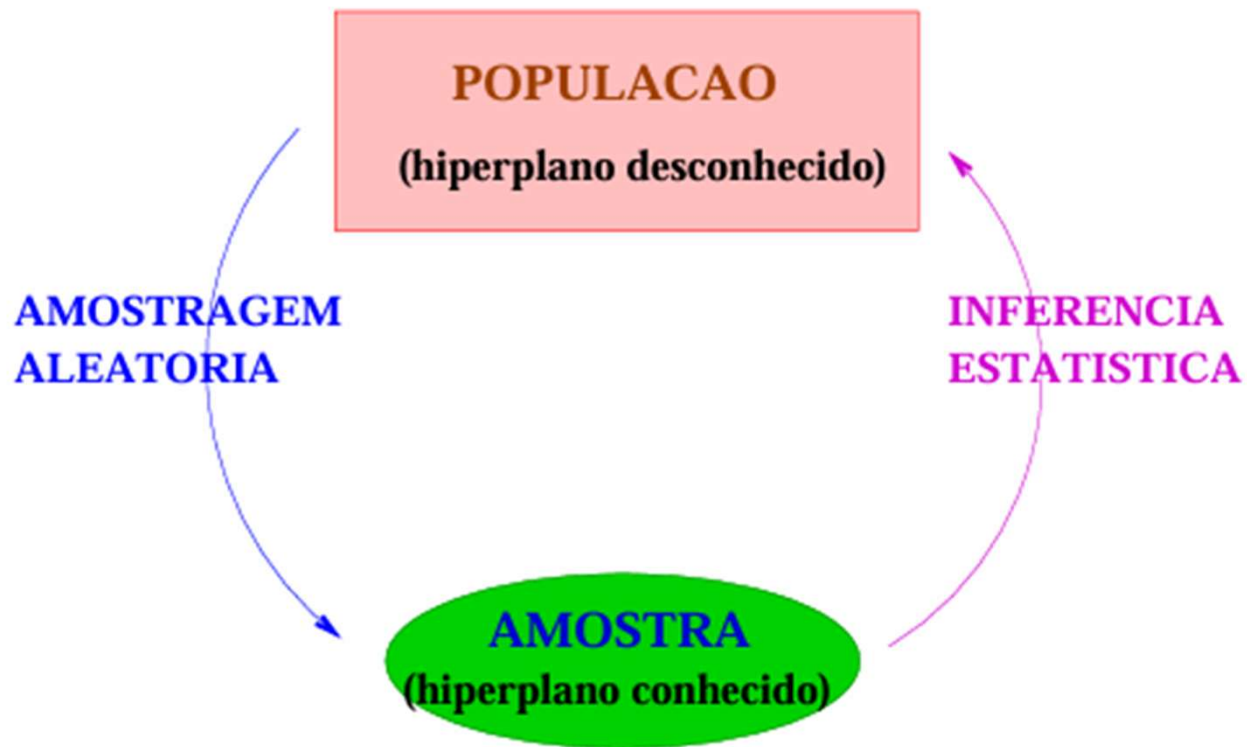
- Até aqui a regressão linear foi usada apenas como **técnica descritiva**. Se as n observações forem a totalidade da população de interesse, pouco mais há a dizer.
- Mas, com frequência, as n observações são apenas uma **amostra aleatória** de uma população maior.
- Um hiperplano ajustado a partir duma dada amostra, $y = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_p x_p$, é apenas uma **estimativa** de um **hiperplano populacional**

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p .$$

Outras amostras dariam hiperplanos ajustados diferentes.

- Coloca-se o problema da **inferência estatística**.

O problema da Inferência Estatística na Reg. Linear



MODELO - Regressão Linear

A fim de se poder fazer inferência sobre o hiperplano populacional, vamos admitir **pressupostos adicionais**.

Y – variável resposta **aleatória**.

x_1, \dots, x_p – variáveis preditoras **não aleatórias** (fixadas pelo experimentador ou trabalha-se **condicionalmente** aos valores de x_1, \dots, x_p)

O modelo será ajustado com base em:

$\{(x_{1(i)}, x_{2(i)}, \dots, x_{p(i)}, Y_i)\}_{i=1}^n$ – n conjuntos de observações **independentes** das variáveis x_1, x_2, \dots, x_p e Y , sobre n **unidades experimentais**.

MODELO RL – Linearidade

Vamos ainda admitir que a **relação de fundo entre Y e x_1, x_2, \dots, x_p , é linear (afim)**, com uma variabilidade aleatória em torno dessa relação, representada por um **erro aleatório ε** . Para todo o $i = 1, \dots, n$:

$$\begin{array}{ccccccccccc} Y_i & = & \beta_0 & + & \beta_1 & x_{1(i)} & + & \dots & + & \beta_p & x_{p(i)} & + & \varepsilon_i \\ \downarrow & & \downarrow & & \downarrow & \downarrow & & & & \downarrow & \downarrow & & \downarrow \\ \text{v.a.} & & \text{cte.} & & \text{cte.} & \text{cte.} & & & & \text{cte.} & \text{cte.} & & \text{v.a.} \end{array}$$

MODELO Regressão Linear – Os erros aleatórios

Vamos ainda admitir que os erros aleatórios ε_j :

- Têm **valor esperado** (valor médio) **nulo**:

$$E[\varepsilon_j] = 0, \quad \forall j = 1, \dots, n$$

(não é hipótese restritiva).

- Têm **distribuição Normal** (é restritiva, mas bastante geral).
- **Homogeneidade de variâncias**: têm sempre a mesma variância

$$V[\varepsilon_j] = \sigma^2, \quad \forall j = 1, \dots, n$$

(é restritiva, mas conveniente).

- São **variáveis aleatórias independentes**
(é restritiva, mas conveniente).

O Modelo Linear

O modelo **para inferência** na regressão linear é assim:

O Modelo Linear

- 1 $Y_i = \beta_0 + \beta_1 x_{1(i)} + \beta_2 x_{2(i)} + \dots + \beta_p x_{p(i)} + \varepsilon_i, \quad \forall i = 1, \dots, n.$
- 2 $\varepsilon_i \sim \mathcal{N}(0, \sigma^2), \quad \forall i = 1, \dots, n.$
- 3 $\{\varepsilon_i\}_{i=1}^n$ v.a. independentes.

NOTA: Os erros aleatórios são variáveis aleatórias independentes e identicamente distribuídas (i.i.d.).

Dado o modelo, o valor esperado (médio) de Y_i , condicional aos valores x_1, x_2, \dots, x_p dos preditores, é:

$$\mu_i = E[Y_i | x_1, x_2, \dots, x_p] = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p .$$

NOTA: β_j ($j \neq 0$) é a variação **média** em Y , associada a um aumento de uma unidade em x_j , mantendo os restantes preditores constantes.

O estudo do modelo

Um primeiro objectivo da inferência: os $p + 1$ **parâmetros do modelo**, β_j ($j = 0, 1, \dots, p$).

Os **parâmetros ajustados** $\vec{b} = (b_0, b_1, b_2, \dots, b_p)$, são **estimativas** desses parâmetros.

Para ser possível construir **intervalos de confiança** e/ou efectuar **testes de hipóteses** sobre os valores dos **parâmetros populacionais** β_j , há-que:

- Definir **estimadores** $\hat{\beta}_j$ dos parâmetros populacionais;
- conhecer as respectivas **distribuições de probabilidades** (ao abrigo do Modelo);

A validade da inferência depende da validade dos pressupostos do modelo.

A notação matricial/vectorial

$$\begin{array}{rcll} Y_1 & = & \beta_0 + \beta_1 x_{1(1)} + \beta_2 x_{2(1)} + \cdots + \beta_p x_{p(1)} & + \epsilon_1 \\ Y_2 & = & \beta_0 + \beta_1 x_{1(2)} + \beta_2 x_{2(2)} + \cdots + \beta_p x_{p(2)} & + \epsilon_2 \\ Y_3 & = & \beta_0 + \beta_1 x_{1(3)} + \beta_2 x_{2(3)} + \cdots + \beta_p x_{p(3)} & + \epsilon_3 \\ \vdots & & \vdots & \vdots \\ \underbrace{Y_n}_{=\vec{Y}} & = & \underbrace{\beta_0 + \beta_1 x_{1(n)} + \beta_2 x_{2(n)} + \cdots + \beta_p x_{p(n)}}_{=\mathbf{X}\vec{\beta}} & + \underbrace{\epsilon_n}_{=\vec{\epsilon}} \end{array}$$

As n equações correspondem a **uma única equação vectorial**:

$$\vec{Y} = \mathbf{X}\vec{\beta} + \vec{\epsilon},$$

onde:

$$\vec{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ \vdots \\ Y_n \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} 1 & x_{1(1)} & x_{2(1)} & \cdots & x_{p(1)} \\ 1 & x_{1(2)} & x_{2(2)} & \cdots & x_{p(2)} \\ 1 & x_{1(3)} & x_{2(3)} & \cdots & x_{p(3)} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{1(n)} & x_{2(n)} & \cdots & x_{p(n)} \end{bmatrix}, \quad \vec{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix}, \quad \vec{\epsilon} = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

- \vec{Y} e $\vec{\epsilon}$ são vectores **aleatórios**,
- \mathbf{X} é uma matriz **não aleatória** e $\vec{\beta}$ um vector **não-aleatório**.

Modelo Regressão Linear - versão vectorial

O Modelo Linear em notação vectorial

1 $\vec{Y} = X\vec{\beta} + \vec{\varepsilon}.$

2 $\vec{\varepsilon} \sim \mathcal{N}_n(\vec{0}, \sigma^2 \mathbf{I}_n),$ com $\vec{0} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} ; \sigma^2 \mathbf{I}_n = \begin{bmatrix} \sigma^2 & 0 & 0 & \dots & 0 \\ 0 & \sigma^2 & 0 & \dots & 0 \\ 0 & 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & \sigma^2 \end{bmatrix}$

- Cada erro aleatório individual ε_i tem distribuição Normal.
- Cada erro aleatório individual tem média zero: $E[\varepsilon_i] = 0.$
- Cada erro aleatório individual tem variância igual: $V[\varepsilon_i] = \sigma^2.$
- Erros aleatórios diferentes são independentes, porque $Cov[\varepsilon_i, \varepsilon_j] = 0$ se $i \neq j$ e, numa Multinormal, isso implica a independência.

A distribuição de \vec{Y}

Teorema (Primeiras Consequências do Modelo)

Dado o Modelo de Regressão Linear, tem-se:

$$\vec{Y} \sim \mathcal{N}_n(\mathbf{X}\vec{\beta}, \sigma^2 \mathbf{I}_n).$$

De facto, \vec{Y} é soma de vector não aleatório ($\mathbf{X}\vec{\beta}$) e vector aleatório ($\vec{\epsilon}$):

$$\vec{Y} = \underbrace{\mathbf{X}\vec{\beta}}_{=\text{"a"}} + \underbrace{\vec{\epsilon}}_{=\text{"z"}}.$$

- $\vec{\epsilon} \sim \mathcal{N}(\vec{0}, \sigma^2 \mathbf{I}_n)$.
- Somar vector constante ($\mathbf{X}\vec{\beta}$) a um vector aleatório Multinormal ($\vec{\epsilon}$) não destrói a Multinormalidade.
- $E[\vec{Y}] = E[\mathbf{X}\vec{\beta} + \vec{\epsilon}] = \mathbf{X}\vec{\beta} + E[\vec{\epsilon}] = \mathbf{X}\vec{\beta}$.
- $V[\vec{Y}] = V[\mathbf{X}\vec{\beta} + \vec{\epsilon}] = V[\vec{\epsilon}] = \sigma^2 \mathbf{I}_n$.

A distribuição de \vec{Y} (interpretação)

$$\vec{Y} \sim \mathcal{N}_n(\mathbf{X}\vec{\beta}, \sigma^2 \mathbf{I}_n).$$

Tendo em conta as propriedades da Multinormal:

- Cada observação individual Y_i tem distribuição Normal.
- Cada observação individual Y_i tem média
 $\mu_i = E[Y_i] = \vec{\mathbf{x}}_{[i]}^t \vec{\beta} = \beta_0 + \beta_1 x_{1(i)} + \beta_2 x_{2(i)} + \dots + \beta_p x_{p(i)}.$
- Cada observação individual tem variância igual: $V[Y_i] = \sigma^2.$
- Observações diferentes de Y são independentes, porque $Cov[Y_i, Y_j] = 0$ se $i \neq j$ e, numa Multinormal, isso implica a independência.

O vector de estimadores $\hat{\beta}$

O **vector de estimadores** $\vec{\hat{\beta}} = (\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p)^t$ é definido a partir da equação do vector \vec{b} de estimativas, mas substituindo o vector \vec{y} de valores observados de Y pelo **vector aleatório** \vec{Y} .

Estimadores de Mínimos Quadrados dos parâmetros

$$\vec{\hat{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\vec{Y}.$$

O vector $\vec{\hat{\beta}}$ é de dimensão $p+1$. O seu primeiro elemento é o estimador de β_0 , o seu segundo elemento é o estimador de β_1 , etc...

Em geral, o estimador de β_j está na posição $j+1$ do vector $\vec{\hat{\beta}}$.

Os resultados gerais já referidos permitem facilmente determinar a **distribuição de probabilidades do estimador** $\vec{\hat{\beta}}$.

A distribuição do vector de estimadores $\vec{\hat{\beta}}$

Teorema (Distribuição do estimador $\vec{\hat{\beta}}$)

Dado o Modelo de Regressão Linear Múltipla, tem-se:

$$\vec{\hat{\beta}} \sim \mathcal{N}_{p+1}(\vec{\beta}, \sigma^2 (\mathbf{X}^t \mathbf{X})^{-1}).$$

$\vec{\hat{\beta}}$ é produto de matriz não aleatória, $(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t$, e vector aleatório, $\vec{\mathbf{Y}}$:

$$\vec{\hat{\beta}} = \underbrace{(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t}_{\text{"B"}} \underbrace{\vec{\mathbf{Y}}}_{\text{"Z"}}.$$

- $\vec{\mathbf{Y}} \sim \mathcal{N}_n(\mathbf{X}\vec{\beta}, \sigma^2 \mathbf{I}_n)$.
- Multiplicar matriz constante, $(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t$, por um vector aleatório Multinormal ($\vec{\mathbf{Y}}$) não destrói a **Multinormalidade**.
- $E[\vec{\hat{\beta}}] = E[(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{\mathbf{Y}}] = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t E[\vec{\mathbf{Y}}] = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{X} \vec{\beta} = \vec{\beta}$.
- $V[\vec{\hat{\beta}}] = V[(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{\mathbf{Y}}] = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t V[\vec{\mathbf{Y}}] [(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t]^t = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \cdot \sigma^2 \mathbf{I}_n \cdot \mathbf{X} [(\mathbf{X}^t \mathbf{X})^{-1}]^t = \sigma^2 \cdot (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{X} [(\mathbf{X}^t \mathbf{X})^{-1}]^t = \sigma^2 (\mathbf{X}^t \mathbf{X})^{-1}$.

A distribuição de $\vec{\hat{\beta}}$ (interpretação)

$$\vec{\hat{\beta}} \sim \mathcal{N}_{p+1}(\vec{\beta}, \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}).$$

Tendo em conta as propriedades da Multinormal

- Cada estimador individual $\hat{\beta}_j$ tem distribuição **Normal**.
- Cada estimador individual tem média $E[\hat{\beta}_j] = \beta_j$, logo é **centrado**
- Cada estimador individual tem variância $V[\hat{\beta}_j] = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}_{(j+1,j+1)}$.
(Note-se o desfasamento nos índices).
- Estimadores individuais diferentes **não** são (em geral) independentes, porque $(\mathbf{X}'\mathbf{X})^{-1}$ não é, em geral, uma matriz diagonal: $Cov[\hat{\beta}_i, \hat{\beta}_j] = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}_{(i+1,j+1)}$.
- Logo, o estimador $\hat{\beta}_j$ de um parâmetro individual β_j tem distribuição $\hat{\beta}_j \sim \mathcal{N}(\beta_j, \sigma_{\hat{\beta}_j}^2)$, com $\sigma_{\hat{\beta}_j}^2 = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}_{(j+1,j+1)}$.

Se $p = 1$, RLS

Estimação dos parâmetros do Modelo RLS

A recta do modelo RLS tem dois parâmetros: β_0 e β_1 .

Definem-se **estimadores** desses parâmetros a partir das expressões amostrais obtidas para b_0 e b_1 pelo Método dos Mínimos Quadrados.

$$\text{Recordar: } b_1 = \frac{\text{COV}_{xy}}{s_x^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1) s_x^2} = \frac{\sum_{i=1}^n (x_i - \bar{x}) y_i}{(n-1) s_x^2} = \sum_{i=1}^n \frac{x_i - \bar{x}}{(n-1) s_x^2} y_i$$

Estimador de β_1

$$\hat{\beta}_1 = \sum_{i=1}^n \frac{x_i - \bar{x}}{(n-1) s_x^2} Y_i = \sum_{i=1}^n c_i Y_i, \quad \text{com } c_i = \frac{x_i - \bar{x}}{(n-1) s_x^2}$$

Nota: O estimador $\hat{\beta}_1$ é combinação linear de Normais independentes, logo tem distribuição Normal.

Se $p = 1$, RLS

Estimação dos parâmetros do Modelo RLS (cont.)

Recordar: $b_0 = \bar{y} - b_1 \bar{x}$.

Estimador de β_0

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X} = \frac{1}{n} \sum_{i=1}^n Y_i - \bar{X} \sum_{i=1}^n c_i Y_i = \sum_{i=1}^n \left(\frac{1}{n} - \bar{X} c_i \right) Y_i = \sum_{i=1}^n d_i Y_i,$$

com

$$d_i = \frac{1}{n} - \bar{X} c_i = \frac{1}{n} - \frac{(x_i - \bar{X}) \bar{X}}{(n-1) S_X^2}.$$

Quer $\hat{\beta}_1$, quer $\hat{\beta}_0$, são combinações lineares das observações $\{Y_i\}_{i=1}^n$, logo são combinações lineares de variáveis aleatórias Normais independentes. Logo, **ambos os estimadores têm distribuição Normal**.

Se $p = 1$, RLS

Distribuição dos estimadores RLS

Distribuição dos estimadores dos parâmetros

Dado o Modelo de Regressão Linear Simples,


$$\begin{aligned} 1 \quad \hat{\beta}_1 &\sim \mathcal{N}\left(\beta_1, \frac{\sigma^2}{(n-1)s_x^2}\right), \\ 2 \quad \hat{\beta}_0 &\sim \mathcal{N}\left(\beta_0, \sigma^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{(n-1)s_x^2}\right]\right) \end{aligned}$$

NOTAS:

- 1 Ambos os estimadores são **centrados**: $E[\hat{\beta}_1] = \beta_1$ e $E[\hat{\beta}_0] = \beta_0$.
- 2 Quanto maior $(n-1)s_x^2$, menor a variância dos estimadores.
- 3 A variância de $\hat{\beta}_0$ também diminui com o aumento de n , e com a maior proximidade de \bar{x} de zero.

A distribuição na amostragem de $\hat{\beta}_j$ (interpretação)

$$\hat{\beta}_j \sim \mathcal{N}(\beta_j, \sigma_{\hat{\beta}_j}^2) \quad \text{com} \quad \sigma_{\hat{\beta}_j}^2 = \sigma^2 (\mathbf{X}'\mathbf{X})_{(j+1,j+1)}^{-1}.$$

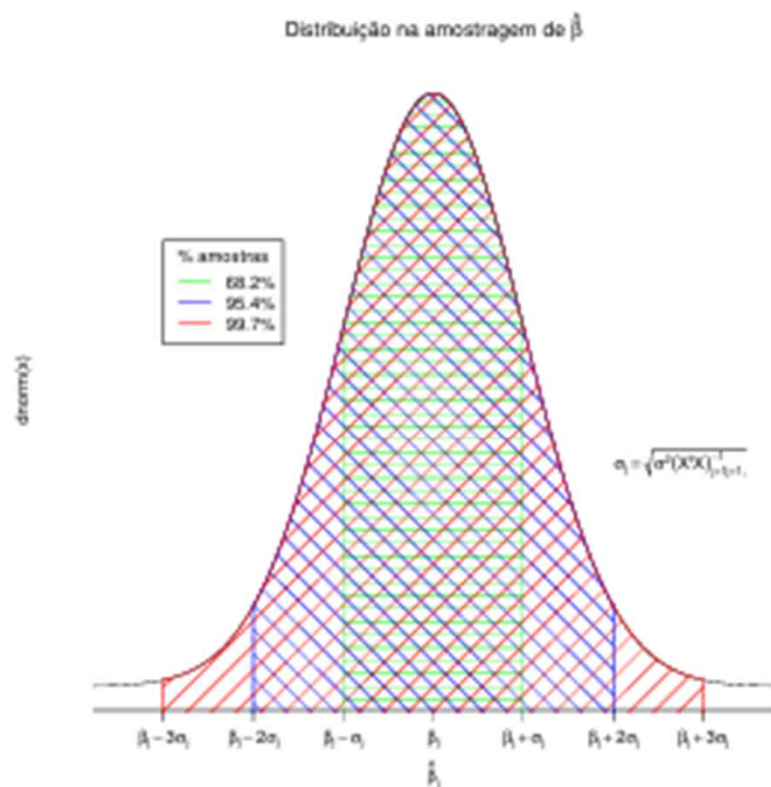


O conjunto de todas as possíveis amostras de dimensão n designa-se o **Universo de Amostragem**

A distribuição de probabilidades de $\hat{\beta}_j$ pode ser vista como a distribuição dos valores de b_j ao longo do Universo de Amostragem.

A distribuição na amostragem de $\hat{\beta}_j$ (interpretação)

$$\hat{\beta}_j \sim \mathcal{N}(\beta_j, \sigma_{\hat{\beta}_j}^2) \quad \text{com} \quad \sigma_{\hat{\beta}_j}^2 = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}_{(j+1,j+1)} .$$



A distribuição dum estimador individual

Como se viu, tem-se, $\forall j = 0, 1, \dots, p$:

$$\hat{\beta}_j \sim \mathcal{N}(\beta_j, \sigma^2 (\mathbf{X}'\mathbf{X})_{(j+1,j+1)}^{-1})$$
$$\Leftrightarrow \frac{\hat{\beta}_j - \beta_j}{\sigma_{\hat{\beta}_j}} \sim \mathcal{N}(0, 1),$$

com $\sigma_{\hat{\beta}_j} = \sqrt{\sigma^2 (\mathbf{X}'\mathbf{X})_{(j+1,j+1)}^{-1}}$.

Este resultado distribucional permitiria construir intervalos de confiança ou fazer testes a hipóteses sobre os parâmetros $\vec{\beta}$, não fosse o desconhecimento da variância σ^2 dos erros aleatórios.

Se $p = 1$, RLS

Distribuição dos estimadores RLS

Distribuição dos estimadores (cont.)

Dado o Modelo de Regressão Linear Simples,

$$1 \quad \frac{\hat{\beta}_1 - \beta_1}{\sigma_{\hat{\beta}_1}} \sim \mathcal{N}(0, 1), \quad \text{com } \sigma_{\hat{\beta}_1} = \sqrt{\frac{\sigma^2}{(n-1)S_x^2}} = \frac{\sigma}{\sqrt{(n-1)S_x^2}}$$

$$2 \quad \frac{\hat{\beta}_0 - \beta_0}{\sigma_{\hat{\beta}_0}} \sim \mathcal{N}(0, 1), \quad \text{com } \sigma_{\hat{\beta}_0} = \sqrt{\sigma^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{(n-1)S_x^2} \right]} = \sigma \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{(n-1)S_x^2}}$$

NOTAS:

- O desvio padrão dum estimador designa-se **erro padrão** (em inglês, *standard error*).
- Não confundir os erros padrão dos estimadores, $\sigma_{\hat{\beta}_1}$ e $\sigma_{\hat{\beta}_0}$, com o desvio padrão σ dos erros aleatórios.

O problema de σ^2 desconhecido

Para poder utilizar um estimador $\hat{\beta}_j$ na inferência, é preciso conhecer a sua distribuição de probabilidades, sem a presença de quantidades não-amostrais desconhecidas, além de β_j .

Para ultrapassar este problema é preciso:

- obter um estimador para σ^2 ; e
- ver o que acontece à distribuição de $\hat{\beta}_j$ quando σ^2 é substituído pelo seu estimador.

Como $\sigma^2 = V(\varepsilon_i)$, $\forall i$, e como os erros aleatórios ε_i são desconhecidos, é natural procurar um estimador de σ^2 através dos resíduos.

Estimando σ^2

Erros aleatórios (variáveis aleatórias – não observáveis)

$$\varepsilon_i = Y_i - (\beta_0 + \beta_1 x_{1(i)} + \beta_2 x_{2(i)} + \dots + \beta_p x_{p(i)})$$

Resíduos (variáveis aleatórias – observáveis)

$$E_i = Y_i - \underbrace{(\hat{\beta}_0 + \hat{\beta}_1 x_{1(i)} + \hat{\beta}_2 x_{2(i)} + \dots + \hat{\beta}_p x_{p(i)})}_{= \hat{Y}_i}$$

Resíduos (observados)

$$e_i = y_i - (b_0 + b_1 x_{1(i)} + b_2 x_{2(i)} + \dots + b_p x_{p(i)})$$

Quadrado Médio Residual (QMRE)

Define-se o **Quadrado Médio Residual** como

$$QMRE = \frac{SQRE}{n - (p + 1)} = \frac{\sum_{i=1}^n E_i^2}{n - (p + 1)}$$

Dado o Modelo Linear, $\hat{\sigma}^2 = QMRE$ é um **estimador centrado da variância comum dos erros aleatórios**, $\sigma^2 = V[\varepsilon_i]$:

$$E[QMRE] = \sigma^2 .$$

O Quadrado Médio Residual tem como **unidades de medida** o quadrado das unidades de Y .

Quantidades fulcrais para a inferência sobre β_j

A estimação dos erros padrão com o QMRE transforma as distribuições normais em distribuições *t-Student*

Teorema (Distribuições para a inferência sobre β_j)

Dado o Modelo de Regressão Linear Múltipla, tem-se

$$\frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\hat{\beta}_j}} \sim t_{n-(p+1)}, \quad \forall j=0, 1, \dots, p$$

$$\text{com } \hat{\sigma}_{\hat{\beta}_j} = \sqrt{\text{QMRE} \cdot (\mathbf{X}^t \mathbf{X})_{(j+1, j+1)}^{-1}}.$$

Este Teorema dá-nos os resultados que servem de base à construção de intervalos de confiança e testes de hipóteses para os parâmetros β_j do modelo populacional.

Se $p = 1$, RLS

Quantidades centrais para a inferência sobre β_0 e β_1

A **estimação dos erros padrão com o QMRE** transforma as distribuições normais em **distribuições *t-Student***

Distribuições *t-Student* para a inferência sobre β_0 e β_1


Dado o Modelo de Regressão Linear Simples, prova-se que:

$$\begin{aligned} \textcircled{1} \quad \frac{\hat{\beta}_1 - \beta_1}{\hat{\sigma}_{\hat{\beta}_1}} &\sim t_{n-2}, \quad \text{com } \hat{\sigma}_{\hat{\beta}_1} = \sqrt{\frac{QMRE}{(n-1)S_x^2}} \\ \textcircled{2} \quad \frac{\hat{\beta}_0 - \beta_0}{\hat{\sigma}_{\hat{\beta}_0}} &\sim t_{n-2}, \quad \text{com } \hat{\sigma}_{\hat{\beta}_0} = \sqrt{QMRE \left[\frac{1}{n} + \frac{\bar{x}^2}{(n-1)S_x^2} \right]} \end{aligned}$$

Este Teorema é crucial, pois dá-nos os resultados que servirão de base à construção de **intervalos de confiança** e **testes de hipóteses** para os parâmetros da recta populacional, β_0 e β_1 .

Dedução de intervalo de confiança para β_j

Sabemos que $\frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\hat{\beta}_j}} \sim t_{n-(p+1)}$. Logo,



$$P \left[-t_{\frac{\alpha}{2}} < \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\hat{\beta}_j}} < t_{\frac{\alpha}{2}} \right] = 1 - \alpha$$

Dedução IC para β_j (cont.)

Trabalhar a dupla desigualdade até isolar β_j :

$$P \left[-t_{\frac{\alpha}{2}} < \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\hat{\beta}_j}} < t_{\frac{\alpha}{2}} \right] = 1 - \alpha$$

$$\begin{aligned} & -t_{\frac{\alpha}{2}} \cdot \hat{\sigma}_{\hat{\beta}_j} < \hat{\beta}_j - \beta_j < t_{\frac{\alpha}{2}} \cdot \hat{\sigma}_{\hat{\beta}_j} \\ \Leftrightarrow & t_{\frac{\alpha}{2}} \cdot \hat{\sigma}_{\hat{\beta}_j} > \beta_j - \hat{\beta}_j > -t_{\frac{\alpha}{2}} \cdot \hat{\sigma}_{\hat{\beta}_j} \\ \Leftrightarrow & \hat{\beta}_j - t_{\frac{\alpha}{2}} \cdot \hat{\sigma}_{\hat{\beta}_j} < \beta_j < \hat{\beta}_j + t_{\frac{\alpha}{2}} \cdot \hat{\sigma}_{\hat{\beta}_j} . \end{aligned}$$

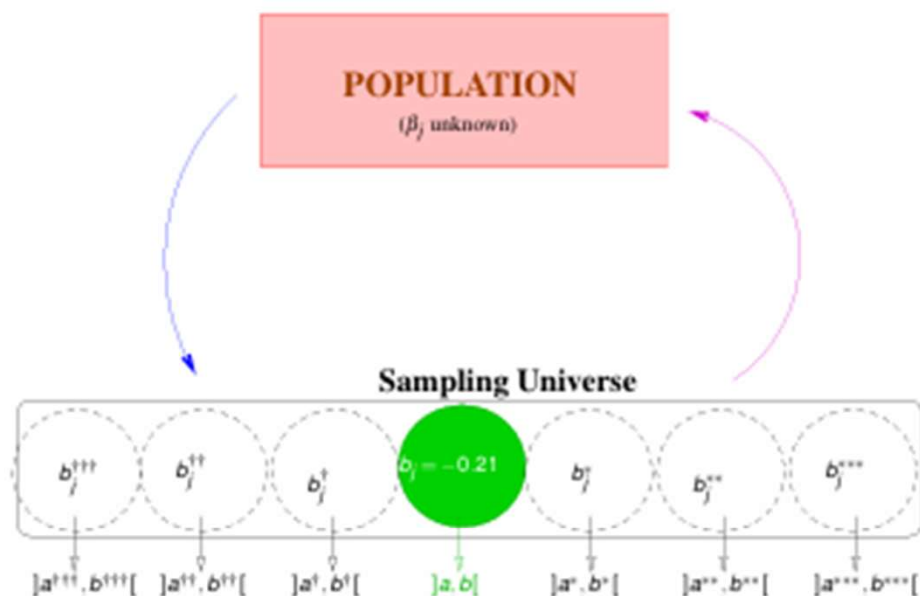
O intervalo aleatório

$$\left[\hat{\beta}_j - t_{\frac{\alpha}{2}} \cdot \hat{\sigma}_{\hat{\beta}_j} , \hat{\beta}_j + t_{\frac{\alpha}{2}} \cdot \hat{\sigma}_{\hat{\beta}_j} \right]$$

contém β_j com probabilidade $1 - \alpha$.

Intervalo aleatório para β_j (interpretação)

$$\left] \hat{\beta}_j - t_{\frac{\alpha}{2}} \cdot \hat{\sigma}_{\hat{\beta}_j}, \hat{\beta}_j + t_{\frac{\alpha}{2}} \cdot \hat{\sigma}_{\hat{\beta}_j} \left[$$



Cada amostra no **Universo de Amostragem** gera um **intervalo concreto**, chamado **Intervalo de Confiança**.

Uma proporção $1 - \alpha$ desses intervalos contém o verdadeiro valor de β_j . Os restantes α não contêm β_j .

Intervalo de confiança para β_j

Intervalo de Confiança a $(1 - \alpha) \times 100\%$ para β_j

Dado o Modelo de Regressão Linear Múltipla e uma amostra, eis o **intervalo a $(1 - \alpha) \times 100\%$ de confiança para o parâmetro β_j** :

$$\left[b_j - t_{\frac{\alpha}{2}[n-(p+1)]} \cdot \hat{\sigma}_{\hat{\beta}_j} , b_j + t_{\frac{\alpha}{2}[n-(p+1)]} \cdot \hat{\sigma}_{\hat{\beta}_j} \right],$$

sendo:

- b_j o elemento $j+1$ do vector das estimativas $\vec{\mathbf{b}}$
- $t_{\frac{\alpha}{2}[n-(p+1)]}$ o quantil de ordem $1 - \frac{\alpha}{2}$ da distribuição $t_{n-(p+1)}$;
- $\hat{\sigma}_{\hat{\beta}_j} = \sqrt{QMRE \cdot (\mathbf{X}'\mathbf{X})^{-1}_{(j+1,j+1)}}$ (com o valor de QMRE na nossa amostra).

NOTA: A amplitude do IC aumenta com QMRE e o valor diagonal da matriz $(\mathbf{X}'\mathbf{X})^{-1}$ correspondente ao parâmetro β_j .

Se $p = 1$, RLS

Intervalo de confiança para β_1

Intervalo de Confiança a $(1 - \alpha) \times 100\%$ para β_1

Dado o Modelo RLS, um intervalo a $(1 - \alpha) \times 100\%$ de confiança para o declive β_1 da recta de regressão populacional é dado por:

$$\left] b_1 - t_{\frac{\alpha}{2}[n-2]} \hat{\sigma}_{\hat{\beta}_1} \ , \ b_1 + t_{\frac{\alpha}{2}[n-2]} \hat{\sigma}_{\hat{\beta}_1} \left[\ , \right.$$

tendo $t_{\frac{\alpha}{2}[n-2]}$, b_1 e $\hat{\sigma}_{\hat{\beta}_1}$ sido definidos em acetatos anteriores.

NOTAS:

- O intervalo é **centrado em b_1** .
- A **amplitude do intervalo** é $2 \times t_{\frac{\alpha}{2}[n-2]} \hat{\sigma}_{\hat{\beta}_1}$.
- A amplitude **aumenta com QMRE** e **diminui com n e s_x^2** : $\hat{\sigma}_{\hat{\beta}_1} = \sqrt{\frac{QMRE}{(n-1)S_x^2}}$
- A amplitude do IC **aumenta para maiores graus de confiança $1 - \alpha$** .

Se $p = 1$, RLS

Intervalo de confiança para β_0

Intervalo de Confiança a $(1 - \alpha) \times 100\%$ para β_0

Dado o Modelo de Regressão Linear Simples, um intervalo a $(1 - \alpha) \times 100\%$ de confiança para a ordenada na origem, β_0 , da recta populacional é:

$$\left] b_0 - t_{\frac{\alpha}{2}[n-2]} \cdot \hat{\sigma}_{\hat{\beta}_0} \quad , \quad b_0 + t_{\frac{\alpha}{2}[n-2]} \cdot \hat{\sigma}_{\hat{\beta}_0} \left[, \right.$$

onde $t_{\frac{\alpha}{2}[n-2]}$, b_0 e $\hat{\sigma}_{\hat{\beta}_0}$ foram definidos em acetatos anteriores.

NOTAS:

- O intervalo é centrado em b_0 .
- A amplitude do intervalo é $2 \times t_{\frac{\alpha}{2}[n-2]} \hat{\sigma}_{\hat{\beta}_0}$.
- A amplitude aumenta com $QMRE$ e com \bar{x}^2 e diminui com n e s_x^2 :

$$\hat{\sigma}_{\hat{\beta}_0} = \sqrt{QMRE \cdot \left[\frac{1}{n} + \frac{\bar{x}^2}{(n-1)S_x^2} \right]}$$

- A amplitude do IC aumenta para maiores graus de confiança $1 - \alpha$.

Ainda o exemplo dos lírios

RLM

```
proc reg data=iris;
    model PetalWidth = SepalLength SepalWidth PetalLength/clb;
run;
```

Parameter Estimates							
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	95% Confidence Limits	
Intercept	1	-0.24031	0.17837	-1.35	0.1800	-0.59283	0.11221
SepalLength	1	-0.20727	0.04751	-4.36	<.0001	-0.30115	-0.11338
SepalWidth	1	0.22283	0.04894	4.55	<.0001	0.12611	0.31955
PetalLength	1	0.52408	0.02449	21.40	<.0001	0.47568	0.57249

b_j

$$\hat{\sigma}_{\hat{\beta}_j} = \sqrt{QMRE \cdot (X'X)^{-1}_{(j+1,j+1)}}$$

As estimativas dos desvios padrão associados à estimação de cada um dos parâmetros

Exemplo b_1 : na nossa amostra estima-se que, em média, a largura da pétala diminui 0.20727 cm por cada aumento de 1 cm no comprimento da sépala (mantendo-se as outras medições constantes).

Como $t_{0.025(146)}=1.976346$, o IC a 95% para β_1 é:

$$](-0.20727) - (1.976346)(0.04751) , (-0.20727) + (1.976346)(0.04751)[$$

$$\Leftrightarrow]-0.30115, -0.11338[$$

Temos 95% de confiança em como o verdadeiro valor de β_1 (na população) está compreendido entre -0.30115 e -0.11338 .

Ainda o exemplo dos lírios

```

RLS  proc reg data=iris;
        model PetalWidth = SepalLength/clb;
        run;
    
```

Parameter Estimates							
Variable	DF	Parameter Estimate	Standard Error	t Value	Pr > t	95% Confidence Limits	
Intercept	1	-3.20022	0.25689	-12.46	<.0001	-3.70785	-2.69258
SepalLength	1	0.75292	0.04353	17.30	<.0001	0.66690	0.83894

Um IC a 95% de confiança para o declive da recta populacional é] 0.66690, 0.83894[.



$$\hat{\sigma}_{\hat{\beta}_j} = \sqrt{QMRE \cdot (\mathbf{X}'\mathbf{X})^{-1}_{(j+1,j+1)}}$$

$$\hat{\sigma}_{\hat{\beta}_0} = \sqrt{QMRE \left[\frac{1}{n} + \frac{\bar{x}^2}{(n-1)s_x^2} \right]}$$

$$\hat{\sigma}_{\hat{\beta}_1} = \sqrt{\frac{QMRE}{(n-1)s_x^2}}$$

Nota: O coeficiente associado ao preditor *Sepal.Length* na regressão linear simples agora ajustada é positivo, $b_1 = 0.75292$. No modelo de regressão linear múltipla obteve-se um resultado diferente, pois contém, além do preditor comprimento da sépala, outros dois preditores (largura da sépala e comprimento da pétala), que contribuem para a formação dos valores ajustados. Na presença desses dois preditores, a contribuição do comprimento da sépala teve um sinal negativo. Esta aparente contradição sublinha uma ideia importante: *a introdução (ou exclusão) de preditores numa regressão linear têm efeitos sobre todos os parâmetros, não sendo possível prever qual será a equação ajustada sem refazer as contas do ajustamento.*