

# Inferência para a Distribuição Normal Multivariada: parte 1

Prof. Caio Azevedo

# Introdução

- Estudaremos como realizar Inferência Estatística (estimação pontual, intervalar e testes de hipótese) para os parâmetros da distribuição **normal multivariada**.
- Veremos abordagens para cada componente univariada do vetor de médias ( $\mu$ ) e matriz de variâncias e covariâncias ( $\Sigma$ ), bem como para cada um dos parâmetros.
- Um dos elementos básicos é a **matriz de dados** em que as linhas ( $\mathbf{X}_i = (X_{i1}, \dots, X_{ip})'$ ) são consideradas vetores aleatórios independentes e identicamente distribuídos segundo uma distribuição  $N_p(\mu, \Sigma)$ .

# Matriz de dados (MD)

Indivíduo	Variável 1	Variável 2	...	Variável p
1	$X_{11}$	$X_{12}$	...	$X_{1p}$
2	$X_{21}$	$X_{22}$	...	$X_{2p}$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$
n	$X_{n1}$	$X_{n2}$	...	$X_{np}$

Temos que (cada linha da MD)  $\mathbf{X}_i = (X_{i1}, \dots, X_{ip})' \stackrel{iid}{\sim} N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ ,  
 $i = 1, 2, \dots, n$ .

# Verossimilhança

- Com a suposição de amostra aleatória (aa) da  $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  temos que a verossimilhança pra uma aa de tamanho  $n$  é dada por

$$L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \propto |\boldsymbol{\Sigma}|^{-n/2} \exp \left\{ -0,5 \left[ \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu}) \right] \right\} \quad (1)$$

- Além disso, note que, para a fdp da  $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , temos que

$$\begin{aligned} (\mathbf{x}_i - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu}) &= \text{tr}[(\mathbf{x}_i - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu})] \\ &= \text{tr}[\boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})']. \end{aligned} \quad (2)$$

# Verossimilhança

- Note, agora, que (somando-se e subtraindo-se  $\bar{\mathbf{x}}$  em cada “()” na Equação (1)), temos que (exercício)

$$\sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})' = \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})' + n(\bar{\mathbf{x}} - \boldsymbol{\mu})(\bar{\mathbf{x}} - \boldsymbol{\mu})' \quad (3)$$

em que  $\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i = \frac{1}{n} (\sum_{i=1}^n x_{i1}, \dots, \sum_{i=1}^n x_{ip})' = (\bar{x}_1, \dots, \bar{x}_p)'$   
(note que  $\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij}$ ,  $j=1,2,\dots,p$ )

# Estatística suficiente

- Assim, de (2) e (3) em (1), vem que a verossimilhança pode ser reescrita como:

$$L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \propto |\boldsymbol{\Sigma}|^{-n/2} \exp \left\{ -0,5 \operatorname{tr} \left[ \boldsymbol{\Sigma}^{-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}}) (\mathbf{x}_i - \bar{\mathbf{x}})' \right] + 0,5n \times \operatorname{tr} \left[ \boldsymbol{\Sigma}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}) (\bar{\mathbf{x}} - \boldsymbol{\mu})' \right] \right\}$$

- Assim, pelo **critério da fatoração** temos que

$\mathbf{T} = \left( \sum_{i=1}^n \mathbf{x}_i, \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}}) (\mathbf{x}_i - \bar{\mathbf{x}})' \right)$  é uma estatística suficiente para  $(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  (“abuso de notação”), em que

$$\bar{\mathbf{X}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i = \frac{1}{n} \left( \sum_{i=1}^n X_{i1}, \dots, \sum_{i=1}^n X_{ip} \right)' = (\bar{X}_1, \dots, \bar{X}_p)' \text{ (note que } \bar{X}_j = \frac{1}{n} \sum_{i=1}^n X_{ij}, j = 1, 2, \dots, p).$$

# Estimadores de máxima verossimilhança

- Por outro lado, temos que a log-verossimilhança pode ser escrita como (definindo  $\mathbf{V} = \Sigma^{-1}$ ):

$$l(\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \text{const} + \frac{n}{2} \ln |\mathbf{V}| - 0,5 \left[ \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})' \mathbf{V} (\mathbf{x}_i - \boldsymbol{\mu}) \right] \quad (4)$$

$$= \text{const} + \frac{n}{2} \ln |\mathbf{V}| - 0,5 \text{tr} \left[ \mathbf{V} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu}) (\mathbf{x}_i - \boldsymbol{\mu})' \right] \quad (5)$$

- Derivando (4) com relação à  $\boldsymbol{\mu}$  e (5) com relação à  $\mathbf{V}$ , vem que (lembrando que  $\frac{\partial}{\partial \mathbf{V}} \ln |\mathbf{V}| = \boldsymbol{\Sigma}$  e  $\frac{\partial}{\partial \mathbf{V}} \text{tr}(\mathbf{V}\mathbf{A}) = \mathbf{A}'$ )

## Estimadores de máxima verossimilhança

$$S(\boldsymbol{\mu}) = \frac{\partial l(\boldsymbol{\mu}, \boldsymbol{\Sigma})}{\partial \boldsymbol{\mu}} = -\frac{1}{2} \sum_{i=1}^n [2\boldsymbol{\Sigma}^{-1}(\mathbf{x}_i - \boldsymbol{\mu})] = n\boldsymbol{\Sigma}^{-1}\boldsymbol{\mu} - n\boldsymbol{\Sigma}^{-1}\bar{\mathbf{x}}$$

$$S(\mathbf{V}) = \frac{n}{2}(\mathbf{V}^{-1})' - \frac{1}{2} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})' = \frac{n}{2}(\mathbf{V}^{-1})' - \frac{1}{2}(n-1)\mathbf{S}^2$$

- Assim, igualando cada uma das derivadas acima à  $\mathbf{0}_{(p \times 1)}$  e  $\mathbf{0}_{(p \times p)}$ , respectivamente, e resolvendo o sistema resultante em relação aos parâmetros, temos:

$$\hat{\boldsymbol{\mu}} = \bar{\mathbf{X}}; \hat{\boldsymbol{\Sigma}} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{X}})(\mathbf{x}_i - \bar{\mathbf{X}})'$$



# Estimadores de máxima verossimilhança

$$\hat{\boldsymbol{\mu}} = \bar{\mathbf{X}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i = \frac{1}{n} \begin{bmatrix} \sum_{i=1}^n X_{i1} \\ \vdots \\ \sum_{i=1}^n X_{ip} \end{bmatrix}$$

$$\hat{\boldsymbol{\Sigma}} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{X}}) (\mathbf{x}_i - \bar{\mathbf{X}})' = \frac{1}{n} \times$$

$$\begin{bmatrix} \sum_{i=1}^n (X_{i1} - \bar{X}_1)^2 & \sum_{i=1}^n (X_{i1} - \bar{X}_1)(X_{i2} - \bar{X}_2) & \dots & \sum_{i=1}^n (X_{i1} - \bar{X}_1)(X_{ip} - \bar{X}_p) \\ \sum_{i=1}^n (X_{i1} - \bar{X}_1)(X_{i2} - \bar{X}_2) & \sum_{i=1}^n (X_{i2} - \bar{X}_2)^2 & \dots & \sum_{i=1}^n (X_{i2} - \bar{X}_2)(X_{ip} - \bar{X}_p) \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^n (X_{i1} - \bar{X}_1)(X_{ip} - \bar{X}_p) & \sum_{i=1}^n (X_{i2} - \bar{X}_2)(X_{ip} - \bar{X}_p) & \dots & \sum_{i=1}^n (X_{ip} - \bar{X}_p)^2 \end{bmatrix}$$

## (Cont.) Distribuições amostrais dos $\hat{\mu}$ e $\mathbf{S}^2$

- Contudo, em geral, utiliza-se

$\mathbf{S}^2 = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{X}_i - \bar{\mathbf{X}}) (\mathbf{X}_i - \bar{\mathbf{X}})' = \frac{n}{n-1} \hat{\Sigma}$  para estimar  $\Sigma$  (por ser não viciado), enquanto que  $\mathcal{E}(\hat{\Sigma}) = \frac{(n-1)}{n} \Sigma$ . Pode-se provar ainda que  $\bar{\mathbf{X}} \perp \mathbf{S}^2$  ([Teorema de Basu](#)).

- Temos que  $\hat{\mu} \sim N_p(\mu, \Sigma/n)$  (exercício).

- Assim,  $\hat{\mu}_j \sim N(\mu_j, \sigma_j^2/n), j = 1, 2, \dots, p$ , em que  $\hat{\mu}_j = \bar{X}_j = \frac{1}{n} \sum_{i=1}^n X_{ij}$ .

- Temos ainda que  $(n-1)\mathbf{S}^2 \sim W_p(n-1, \Sigma)$  ([link](#) com demonstrações e referências a respeito).

- Assim,  $\frac{(n-1)S_j^2}{\sigma_j^2} \sim \chi_{(n-1)}^2, j = 1, 2, \dots, p$ , em que

$S_j^2 = \frac{1}{n-1} \sum_{i=1}^n (X_{ij} - \hat{\mu}_j)^2$ , é o  $j$ -ésimo elemento da diagonal principal de  $\mathbf{S}^2$ .

## (Cont.) Distribuições amostrais dos $\hat{\mu}$ e $\mathbf{S}^2$

- Densidade da distribuição de Wishart ( $\Sigma \sim W_p(n, \mathbf{V})$ ), (pesquisar sobre ela):

$$f(\Sigma) = \frac{|\Sigma|^{\frac{n-p-1}{2}} e^{-\frac{\text{tr}(\mathbf{V}^{-1}\Sigma)}{2}}}{2^{\frac{np}{2}} |\mathbf{V}|^{\frac{n}{2}} \Gamma_p\left(\frac{n}{2}\right)}$$

em que  $\Gamma_p(k) = \pi^{p(p-1)/4} \prod_{j=1}^p \Gamma(k + (1-p)/2)$  é a função gama  $p$ -variada.

- Seja  $\mathbf{X}_i \stackrel{i.i.d.}{\sim} N(\mathbf{0}, \mathbf{V})$  e defina  $\Sigma = \sum_{i=1}^n \mathbf{X}_i \mathbf{X}_i'$ , então  $\Sigma \sim W_p(n, \mathbf{V})$  (obs: esta matriz  $\mathbf{V}$  não é a mesma definida anteriormente).

# Inferência para cada componente: intervalos de confiança

- $IC(\theta, \gamma)$  representa um intervalo de confiança com coeficiente de confiança  $\gamma$  para o parâmetro  $\theta$ .
- (médias)  $IC(\mu_j, \gamma) = \left[ \bar{X}_j - t_{\frac{1+\gamma}{2}} \sqrt{\frac{S_j^2}{n}}, \bar{X}_j + t_{\frac{1+\gamma}{2}} \sqrt{\frac{S_j^2}{n}} \right]$ , em que  $P(T \leq t_{\frac{1+\gamma}{2}}) = \frac{1+\gamma}{2}$ ,  $T \sim t_{(n-1)}$ .
- (variâncias)  $IC(\sigma_j^2, \gamma) = \left[ \frac{(n-1)S_j^2}{q_{\frac{1+\gamma}{2}}}, \frac{(n-1)S_j^2}{q_{\frac{1-\gamma}{2}}} \right]$ , em que  $P(Q \leq q_{\frac{1+\gamma}{2}}) = \frac{1+\gamma}{2}$ , e  $P(Q \leq q_{\frac{1-\gamma}{2}}) = \frac{1-\gamma}{2}$   $Q \sim \chi_{(n-1)}^2$ .

## Inferência para cada componente: intervalos de confiança

- (correlações,  $i \neq j$ )  $IC(\rho_{ij}, \gamma) = [\tanh(z'_1); \tanh(z'_2)]$ , em que

$$z'_1 = z' - \frac{z_{1+\gamma}}{\sqrt{n-3}} \text{ e } z'_2 = z' + \frac{z_{1+\gamma}}{\sqrt{n-3}},$$

$$z' = 0,5 \ln \left( \frac{1+\hat{\rho}_{ij}}{1-\hat{\rho}_{ij}} \right),$$

$$\hat{\rho}_{ij} = \frac{\frac{1}{n} \sum_{k=1}^n X_{ki} X_{kj} - \bar{X}_i \bar{X}_j}{\sqrt{S_i^2 S_j^2}}$$

é a correlação amostral de Pearson e

$$P(Z \leq z_{\frac{1+\gamma}{2}}) = \frac{1+\gamma}{2}, Z \sim N(0, 1).$$

# Testes de hipótese (TH) para cada componente de $\mu$ e $\Sigma$

- Para as componente  $\mu_j$  e  $\sigma_j^2$ ,  $j = 1, 2, \dots, p$  temos diversos resultados aqui apresentados:
  - Aulas teóricas (ME414): [TH1](#), [TH2](#) e [TH3](#).
  - Aulas práticas (ME414): [TH1](#), [TH2](#).
- Para testar  $H_0 : \rho_{ij} = 0$  vs  $H_1 : \rho_{ij} \neq 0$ , podemos usar a estatística do teste  $Z_t = \frac{\hat{\rho}_{ij}\sqrt{n-2}}{\sqrt{1-\hat{\rho}_{ij}^2}}$ , rejeitando  $H_0$  se  $|z_t| > z_c$  ou se  $p\text{-valor} = P(Z > z_t | H_0) > \alpha$ , em que  $z_t$  é o valor calculado da estatística do teste,  $\alpha$  é o nível de significância,  $Z \sim N(0, 1)$  e  $P(Z < z_c | H_0) = \frac{1-\alpha}{2}$ .

# Inferência para combinações lineares do vetor de médias

- Defina  $\theta = \mathbf{R}_{(1 \times p)} \boldsymbol{\mu}$  em que  $\mathbf{R}$  é um vetor não aleatório.
- Temos que  $\hat{\theta} = \mathbf{R} \hat{\boldsymbol{\mu}} \sim N(\mathbf{R} \boldsymbol{\mu}, \mathbf{R} \boldsymbol{\Sigma} \mathbf{R}' / n)$  (exercício).

- Assim, analogamente ao caso anterior, temos que

$$IC(\theta, \gamma) = \left[ \mathbf{R} \bar{\mathbf{X}} - t_{\frac{1+\gamma}{2}} \sqrt{\frac{\mathbf{R} \mathbf{S}^2 \mathbf{R}'}{n}}, \mathbf{R} \bar{\mathbf{X}} + t_{\frac{1+\gamma}{2}} \sqrt{\frac{\mathbf{R} \mathbf{S}^2 \mathbf{R}'}{n}} \right], \text{ em que}$$

$$P(T \leq t_{\frac{1+\gamma}{2}}) = \frac{1+\gamma}{2}, T \sim t_{(n-1)}.$$

## Região de confiança (RC) para $\mu$

- Pode-se provar que :

- $(\mathbf{X} - \mu)' \Sigma^{-1} (\mathbf{X} - \mu) \sim \chi_{(p)}^2$  e  $Q = n(\bar{\mathbf{X}} - \mu)' \Sigma^{-1} (\bar{\mathbf{X}} - \mu) \sim \chi_{(p)}^2$   
(prova:fgm).

- $T = n(\bar{\mathbf{X}} - \mu)' (\mathbf{S}^2)^{-1} (\bar{\mathbf{X}} - \mu) \sim T_{(p, n-1)}^2$  de Hotelling e  
 $F = \frac{n-p}{(n-1)p} T \sim F_{(p, n-p)}$ .

- Definição  $\mathbf{X} \sim N_p(\mu, \Sigma)$  e  $\mathbf{W} \sim W_p(k, \Sigma)$ ,  $\mathbf{X} \perp \mathbf{W}$ . Assim


$$Y = (\mathbf{X} - \mu)' (\mathbf{W}/k)^{-1} (\mathbf{X} - \mu) \sim T_{(p, k)}^2 \text{ de Hotelling e}$$

$$F = \frac{k-p+1}{pk} Y \sim F_{(p, k-p+1)} \text{ (veja site do curso e referências).}$$

- Portanto, uma região de confiança é um conjunto, digamos  $R(\mu, \gamma)$ , contido em  $\mathcal{R}^p$ , tal que  $P(R(\mu, \gamma) \leq q_\gamma) = \gamma$ , em que  $q_\gamma$  é um quantil apropriado da distribuição associada à  $R(\mu, \gamma)$ .



## Exemplo de RC para $\mu$ com $p = 2$



## Região de confiança para $\mu$

- Então, se  $f_\gamma$  for um quantil da distribuição  $F_{(p,n-p)}$ , tal que  $P(F \leq f_\gamma) = \gamma$ , uma região de confiança  $\gamma$  para  $\mu$  é o conjunto de todas as  $p$ -uplas, digamos  $\mu^*$ , tais que

$$n(\bar{\mathbf{x}} - \mu^*)' (\mathbf{s}^2)^{-1} (\bar{\mathbf{x}} - \mu^*) \leq \frac{p(n-1)}{(n-p)} f_\gamma$$

- Para uma dada amostra (matriz de dados observada) basta calcular a forma quadrática acima (para todas as  $p$ -uplas) e ver quais satisfazem à inequação.
- Mais detalhes (incluindo  $p \geq 3$ ): [Johnson and Wichern \(2018\)](#). No R: função “ellipse” do pacote “ellipse”: [página](#), [manual](#).

## Simulação de um vetor aleatório $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$

- Seja  $\mathbf{X} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ ,  $\boldsymbol{\mu} \in \mathcal{R}^p$ ,  $\boldsymbol{\Sigma}$  positiva definida.
- Sabemos que  $\mathbf{X} = \boldsymbol{\Psi}\mathbf{Z} + \boldsymbol{\mu}$ ,  $\boldsymbol{\Psi} = \text{Cholesky}(\boldsymbol{\Sigma})$ ,  
 $\mathbf{Z} = (Z_1, \dots, Z_p)$ ,  $Z_i \stackrel{i.i.d.}{\sim} N(0, 1)$ ,  $i = 1, \dots, p$  (exercício).
- Ou seja,  $\mathbf{x} = \boldsymbol{\Psi}\mathbf{F}_Z^{-1}(\mathbf{u}) + \boldsymbol{\mu}$ ,  $\mathbf{u} = (u_1, \dots, u_p)'$ ,  
 $u_i \stackrel{iid}{\sim} U(0, 1)$ ,  $i = 1, 2, \dots, p$ , em que  
 $\mathbf{F}^{-1}(\mathbf{u}) = (F_Z^{-1}(u_1), \dots, F_Z^{-1}(u_p))'$  (vetor coluna),  $Z \sim N(0, 1)$ .

# No pacote R

- Código genérico:

```
m.u = cbind(runif(n)); m.z = qnorm(m.u)
```

```
for (i in 2:p){m.u = cbind(runif(n))
```

```
m.z = cbind(m.z,qnorm(m.u))};
```

```
m.x = t(chol(m.sigma)%*%t(m.z) + matrix(v.mu,p,n))
```

- Também no R, de forma mais simples: função “mvrnorm” do pacote “MASS”:

```
mvrnorm(n=“tamanho da amostra”, mu=“vetor de médias”,
```

```
Sigma=“matriz de covariâncias”)
```

# Verificação da normalidade multivariada de uma matriz de dados

- $X_{ij} \sim N(\mu_j, \sigma_j^2), j = 1, 2, \dots, p, i = 1, \dots, n$ , ou seja:  $\mathbf{X}_i \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ .
- $n(\mathbf{X}_i - \bar{\mathbf{X}})'(\mathbf{S}^2)^{-1}(\mathbf{X}_i - \bar{\mathbf{X}}) \approx \chi_p^2$ , para  $n$  suficientemente grande.
- Construir histogramas e/ou gráficos de quantis-quantis com envelope para cada variável e para a forma quadrática, bem como a utilização de testes não paramétricos (p.e., [Kolmogorov-Smirnov](#)).

# Procedimento para se gerar o gráfico de envelopes (quantil-quantil)

- 1) Simule  $n$  variáveis aleatórias independentes de interesse ( $N(0, 1)$  ou  $\chi^2_{(p)}$ , por exemplo). Repita este processo  $m$  vezes.
- 2) Ao final teremos uma matriz com valores simulados dessas variáveis aleatórias, digamos  $V_{ij}$ ,  $i=1, \dots, n$ , (tamanho da amostra)  $j=1, \dots, m$  (réplica).

$$\mathbf{V} = \begin{bmatrix} V_{11} & V_{12} & \dots & V_{1m} \\ V_{21} & V_{22} & \dots & V_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ V_{n1} & V_{n2} & \dots & V_{nm} \end{bmatrix}$$

## Cont.

- 3) Dentro de cada amostra (coluna), ordena-se, de modo crescente, os valores simulados, obtendo-se  $v_{(i)j}^*$  ( $i$ -ésima estatística de ordem da  $j$ -ésima amostra):

$$\mathbf{V}^* = \begin{bmatrix} v_{(1)1} & v_{(1)2} & \cdots & v_{(1)m} \\ v_{(2)1} & v_{(2)2} & \cdots & v_{(2)m} \\ \vdots & \vdots & \ddots & \vdots \\ v_{(n)1} & v_{(n)2} & \cdots & v_{(n)m} \end{bmatrix}$$

- 4) Pode-se obter os limites  $v_{(i)l} = \min_{1 \leq j \leq m} v_{(i)j}$  e  $v_{(i)s} = \max_{1 \leq j \leq m} v_{(i)j}$ .

## Cont.

- 5) Porém, na prática considera-se  $v_{(i)l} = \frac{v_{(i)(2)} + v_{(i)(3)}}{2}$  e  $v_{(i)s} = \frac{v_{(i)(m-2)} + v_{(i)(m-1)}}{2}$  (para se gerar limites de confiança), em que  $v_{(i)(r)}$  é a  $r$ -ésima estatística de ordem dentro de cada linha,  $i = 1, 2, \dots, n$ .


- Além disso, consideramos como a linha de referência

$$v_{(i)} = \frac{1}{m} \sum_{j=1}^m v_{(i)j}, i = 1, 2, \dots, n.$$



# Dados da íris “de Fisher”


- Os dados consistem de 50 unidades amostrais de três espécies (setosa, virginica, versicolor) de íris (uma espécie de planta), ou seja, temos um total de 150 unidades amostrais ([Fisher \(1936\)](#) e [Anderson \(1935\)](#)).
- De cada uma delas mediu-se quatro variáveis: comprimento e largura da sépala (CS, LS) e comprimento e largura da pétala (CP,LP).
- Objetivo original: quantificar a variação morfológica em relação à essas espécies com bases nas quatro variáveis de interesse.
- Banco de dados default no R, sob o nome de “iris”.



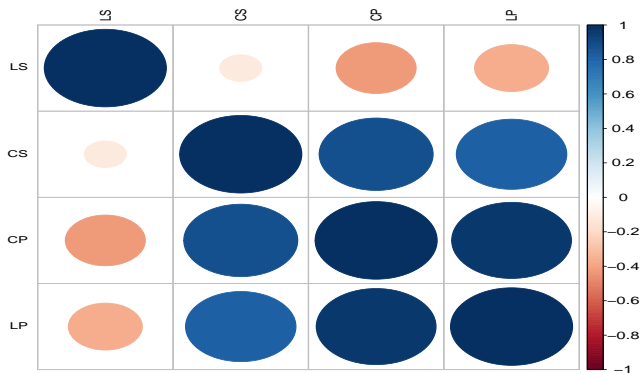
## Cont.

- Seja  $Y_{ijk}$  : o valor da  $k$ -ésima variável ( $k=1,2,3,4$ ), para a  $j$ -ésima flor ( $j=1,\dots,50$ ) do  $i$ -ésimo grupo ( $i = 1, 2, 3$ ).
- Por enquanto, vamos desconsiderar as espécies de Íris, ou seja, vamos considerar que  $\mathbf{Y}_j = (Y_{j1}, Y_{j2}, Y_{j3}, Y_{j4})' \stackrel{ind.}{\sim} N_4(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , na seguinte ordem: comprimento e largura da sépala (CS, LS) e comprimento e largura da pétala (CP,LP).


# Gráficos de dispersão múltipla







# Matriz de correlações









# Box-plot das variáveis



# Histogramas das variáveis







# Elipsóides de 95% confiança para cada par de variáveis






# Gráficos QQ plot para cada variável



# Gráficos QQ plot para a forma quadrática



- Testes de Kolmogorov-Smirnov (p-valor entre parênteses):
  - CS:  $D = 0,089$  ( $p = 0,1891$ ).
  - LS:  $D = 0,106$  ( $p = 0,0723$ ).
  - CP:  $D = 0,198$  ( $p < 0,0001$ ).
  - LP:  $D = 0,173$  ( $p < 0,0003$ ).
- Teste de Kolmogorov-Smirnov (p-valor entre parênteses) para a forma quadrática:
  - $D = 1$  ( $p < 0,0001$ ).