

# Modelo normal linear multivariado: Parte 1

Prof. Caio Azevedo





## Recapitulando: dados das Iris de Fisher (veja)

- 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.
- 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.





# Modelagem dos dados

- Seja  $Y_{ijk}$  : o valor da  $k$ -ésima variável ( $k=1,2,3,4$ ), para a  $j$ -ésima unidade experimental (planta) ( $j=1,\dots,50$ ) do  $i$ -ésimo grupo ( $i = 1, 2, 3$ ).
- Suposição  $\mathbf{Y}_{ij} = (Y_{ij1}, Y_{ij2}, Y_{ij3}, Y_{ij4}) \stackrel{ind.}{\sim} N_4(\boldsymbol{\mu}_i, \boldsymbol{\Sigma})$ .
- Tem-se, portanto, dados balanceados (em relação aos grupos) e homocedasticidade (mesma matriz de variâncias e covariâncias).





# Boxplot das variáveis por grupo







# Histograma das variáveis: iris setosa



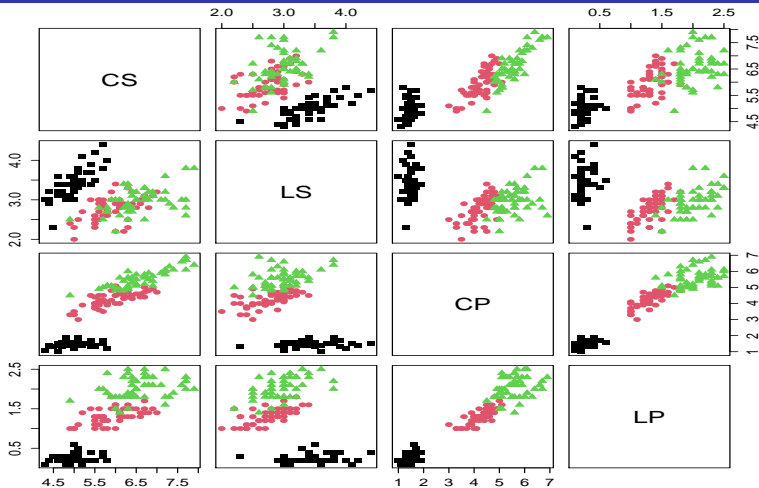
# Histograma das variáveis: iris versicolor



# Histograma das variáveis: iris virginica




Matriz de dispersão: ■ - S, ● - Ver, ▲ - Vir







# Diagrama de dispersão: setosa



# Diagrama de dispersão: versicolor



# Diagrama de dispersão: virginica



Variâncias na diagonal principal (dp), covariâncias abaixo e correlações acima (da dp)

$$\tilde{\Psi}_{\text{setosa}} = \begin{bmatrix} CS & 0,12 & 0,74 & 0,27 & 0,28 \\ LS & 0,10 & 0,14 & 0,18 & 0,23 \\ CP & 0,02 & 0,01 & 0,03 & 0,33 \\ LP & 0,01 & 0,01 & 0,01 & 0,01 \end{bmatrix}$$

$$\tilde{\Psi}_{\text{versicolor}} = \begin{bmatrix} CS & 0,27 & 0,53 & 0,75 & 0,55 \\ LS & 0,08 & 0,10 & 0,56 & 0,66 \\ CP & 0,18 & 0,08 & 0,22 & 0,79 \\ LP & 0,06 & 0,04 & 0,07 & 0,04 \end{bmatrix}$$

$$\tilde{\Psi}_{\text{virginica}} = \begin{bmatrix} CS & 0,40 & 0,46 & 0,86 & 0,28 \\ LS & 0,09 & 0,10 & 0,40 & 0,54 \\ CP & 0,30 & 0,07 & 0,30 & 0,32 \\ LP & 0,05 & 0,05 & 0,05 & 0,07 \end{bmatrix}$$

## Medidas resumo: comprimento da sépala

Espécie	Média	DP	Var	CV(%)	Mín.	Med.	Máx.	CA.	Curt.	n
setosa	5,01	0,35	0,12	7,04	4,30	5,00	5,80	0,11	-0,45	50
versicolor	5,94	0,52	0,27	8,70	4,90	5,90	7,00	0,10	-0,69	50
virginica	6,59	0,64	0,40	9,65	4,90	6,50	7,90	0,11	-0,20	50

## Medidas resumo: largura da sépala

Espécie	Média	DP	Var	CV(%)	Mín.	Med.	Máx.	CA.	Curt.	n
setosa	3,43	0,38	0,14	11,06	2,30	3,40	4,40	0,04	0,60	50
versicolor	2,77	0,31	0,10	11,33	2,00	2,80	3,40	-0,34	-0,55	50
virginica	2,97	0,32	0,10	10,84	2,20	3,00	3,80	0,34	0,38	50

## Medidas resumo: comprimento da pétala

Espécie	Média	DP	Var	CV(%)	Mín.	Med.	Máx.	CA.	Curt.	n
setosa	1,46	0,17	0,03	11,88	1,00	1,50	1,90	0,10	0,65	50
versicolor	4,26	0,47	0,22	11,03	3,00	4,35	5,10	-0,57	-0,19	50
virginica	5,55	0,55	0,30	9,94	4,50	5,55	6,90	0,52	-0,37	50


## Medidas resumo: largura da pétala

Espécie	Média	DP	Var	CV(%)	Mín.	Med.	Máx.	CA.	Curt.	n
setosa	0,25	0,11	0,01	42,84	0,10	0,20	0,60	1,18	1,26	50
versicolor	1,33	0,20	0,04	14,91	1,00	1,30	1,80	-0,03	-0,59	50
virginica	2,03	0,27	0,08	13,56	1,40	2,00	2,50	-0,12	-0,75	50




# Gráficos de quantis-quantis com envelopes: setosa


quantil da distribuição da comprimento da sépala




quantil da distribuição da largura da sépala



quantil da distribuição da comprimento da pétala






quantil da distribuição da largura da pétala







# Gráficos de Q-Q com envelopes: forma quadrática



# Matriz de dados: iris de Fisher

$$Y_{(n \times p)} = \begin{bmatrix} Y_{111} & Y_{112} & Y_{113} & Y_{114} \\ Y_{121} & Y_{122} & Y_{123} & Y_{124} \\ \vdots & \vdots & \ddots & \vdots \\ Y_{1(50)1} & Y_{1(50)2} & Y_{1(50)3} & Y_{1(50)4} \\ \text{---} & \text{---} & \text{---} & \text{---} \\ Y_{211} & Y_{212} & Y_{213} & Y_{214} \\ Y_{221} & Y_{222} & Y_{223} & Y_{224} \\ \vdots & \vdots & \ddots & \vdots \\ Y_{2(50)1} & Y_{2(50)2} & Y_{2(50)3} & Y_{2(50)4} \\ \text{---} & \text{---} & \text{---} & \text{---} \\ Y_{311} & Y_{312} & Y_{313} & Y_{314} \\ Y_{321} & Y_{322} & Y_{323} & Y_{324} \\ \vdots & \vdots & \ddots & \vdots \\ Y_{3(50)1} & Y_{3(50)2} & Y_{3(50)3} & Y_{3(50)4} \end{bmatrix}$$

# Suposições

- Suponha um conjunto de  $G$  populações independentes da qual retiramos  $G$  amostras de tamanho  $n_i$ ,  $i = 1, \dots, G$ ,
- Por suposição, temos que  $\mathbf{Y}_{ij} \sim N_p(\boldsymbol{\mu}_i, \boldsymbol{\Sigma})$ , em que  $i = 1, 2, \dots, G$  (grupo) e  $j = 1, 2, \dots, n_i$  (indivíduo). Notação:  $Y_{ijk}$  observação referente à variável  $k$  do indivíduo  $j$  do grupo  $i$ .
- Homocedasticidades:  $\boldsymbol{\Sigma}_1 = \boldsymbol{\Sigma}_2 = \dots = \boldsymbol{\Sigma}_G = \boldsymbol{\Sigma}$ .
- Assim, temos a seguinte matriz de dados ( $n = \sum_{i=1}^G n_i$ ):

$$\mathbf{Y}_{(n \times p)} = \begin{bmatrix}
 Y_{111} & Y_{112} & \dots & Y_{11p} \\
 Y_{121} & Y_{122} & \dots & Y_{12p} \\
 \vdots & \vdots & \ddots & \vdots \\
 Y_{1n_1 1} & Y_{1n_1 2} & \dots & Y_{1n_1 p} \\
 \hline
 Y_{211} & Y_{212} & \dots & Y_{21p} \\
 Y_{221} & Y_{222} & \dots & Y_{22p} \\
 \vdots & \vdots & \ddots & \vdots \\
 Y_{2n_2 1} & Y_{2n_2 2} & \dots & Y_{2n_2 p} \\
 \hline
 \vdots & \vdots & \ddots & \vdots \\
 \hline
 Y_{G11} & Y_{G12} & \dots & Y_{G1p} \\
 Y_{G21} & Y_{G22} & \dots & Y_{G2p} \\
 \vdots & \vdots & \ddots & \vdots \\
 Y_{Gn_G 1} & Y_{Gn_G 2} & \dots & Y_{Gn_G p}
 \end{bmatrix}$$

# Hipóteses de interesse

- Queremos testar  $H_0 : \mu_1 = \mu_2 = \dots = \mu_G$  vs  $H_1$  : há pelo menos uma diferença.
- Uma abordagem: análise de variância multivariada (MANOVA).
- Comparar médias através do estudo da decomposição da matriz de variâncias-covariâncias total.
- Como resumir a informação das matrizes de covariâncias de interesse? Uma possibilidade: variâncias generalizadas.
- À rigor, a metodologia MANOVA está acomodada na classe de modelos de regressão normais lineares multivariados, a qual é uma extensão dos respectivos modelos univariados ([link](#)).



# Modelo de regressão normal linear multivariado (MRNLM)

$$\mathbf{Y}_{(n \times p)} = \mathbf{X}_{(n \times q)} \mathbf{B}_{(q \times p)} + \boldsymbol{\xi}_{(n \times p)}$$

- $\mathbf{Y}_{(n \times p)}$ : matriz de dados
- $\mathbf{X}_{(n \times q)}$ : matriz de planejamento, conhecida e não-aleatória.
- $\mathbf{B}_{(q \times p)}$ : parâmetros de regressão, desconhecido e não aleatório.
- $\boldsymbol{\xi}_{(n \times p)}$ : matriz de erros, sendo que cada uma das suas linhas corresponde a uma vetor aleatório tal que  $N_p(\mathbf{0}, \boldsymbol{\Sigma})$ , mutuamente independentes.
- Tal estrutura se aplica a diferentes situações, não somente em situação como a dos dados da iris de Fisher.
- Com efeito, qualquer modelo que possa ser escrito sob estrutura, é um MRNLM.

## MRNLM (cont.)

- As suposições do MRNLM são:
  - Em relação aos erros associados a cada unidade amostral/experimental (linhas da matriz de dados):
    - Normalidade multivariada.
    - Matriz de variâncias e covariâncias constante ao longo das observações, conhecida como homocedasticidade.
    - Independência entre elas.
  - Linearidade entre a média  $\mathcal{E}(\mathbf{Y})$  e as covariáveis  $\mathbf{X}$ , ou seja  $\mathcal{E}(\mathbf{Y}) = \mathbf{XB}$ .
- Em geral o MRNLM não é robusto a violação de pelo menos uma das suposições descritas acima ([artigo 1](#), [artigo 2](#))

# Matriz de planejamento de matriz de parâm. de regressão

$$\mathbf{X}_{(n \times q)} = \begin{bmatrix} X_{111} & X_{112} & \dots & X_{11G} \\ X_{121} & X_{122} & \dots & X_{12G} \\ \vdots & \vdots & \vdots & \vdots \\ X_{1n_1 1} & X_{1n_1 2} & \dots & X_{1n_1 G} \\ \text{---} & \text{---} & \text{---} & \text{---} \\ \vdots & \vdots & \vdots & \vdots \\ \text{---} & \text{---} & \text{---} & \text{---} \\ X_{G11} & X_{G12} & \dots & X_{G1G} \\ X_{G21} & X_{G22} & \dots & X_{G2G} \\ \vdots & \vdots & \vdots & \vdots \\ X_{Gn_G 1} & X_{Gn_G 2} & \dots & X_{Gn_G G} \end{bmatrix}; \mathbf{B}_{(q \times p)} = \begin{bmatrix} \mu_{11} & \mu_{12} & \dots & \mu_{1p} \\ \mu_{21} & \mu_{22} & \dots & \mu_{2p} \\ \vdots & \vdots & \vdots & \vdots \\ \mu_{G1} & \mu_{G2} & \dots & \mu_{Gp} \end{bmatrix}$$

$$\xi_{(n \times p)} = \begin{bmatrix} \xi_{111} & \xi_{112} & \dots & \xi_{11p} \\ \xi_{121} & \xi_{122} & \dots & \xi_{12p} \\ \vdots & \vdots & \ddots & \vdots \\ \xi_{1n_11} & \xi_{1n_12} & \dots & \xi_{1n_1p} \\ \hline \xi_{211} & \xi_{212} & \dots & \xi_{21p} \\ \xi_{221} & \xi_{222} & \dots & \xi_{22p} \\ \vdots & \vdots & \ddots & \vdots \\ \xi_{2n_21} & \xi_{2n_22} & \dots & \xi_{2n_2p} \\ \hline \vdots & \vdots & \ddots & \vdots \\ \hline \xi_{G11} & \xi_{G12} & \dots & \xi_{G1p} \\ \xi_{G21} & \xi_{G22} & \dots & \xi_{G2p} \\ \vdots & \vdots & \ddots & \vdots \\ \xi_{Gn_G1} & \xi_{Gn_G2} & \dots & \xi_{Gn_Gp} \end{bmatrix}$$

## Voltando aos dados da Iris de Fisher:

- $G = 3$ ,  $p = 4$  e  $n_i = 50$ ,  $i = 1, 2, 3$  (3 grupos, 4 variáveis e 50 indivíduos por grupo).
- Objetivo: modelar o vetor de médias de cada grupo e compará-los entre si.
- $\mathbf{Y}_{(150 \times 4)}$ .

## Cont.: Parametrização de médias

- $\mathbf{X} = \mathbf{I}_{(3 \times 3)} \otimes \mathbf{1}_{(50 \times 1)}$  ( $\otimes$  denota o produto de Kronecker à

esquerda).  $\mathbf{X} = \begin{bmatrix} \mathbf{1}_{(50 \times 1)} & \mathbf{0}_{(50 \times 1)} & \mathbf{0}_{(50 \times 1)} \\ \mathbf{0}_{(50 \times 1)} & \mathbf{1}_{(50 \times 1)} & \mathbf{0}_{(50 \times 1)} \\ \mathbf{0}_{(50 \times 1)} & \mathbf{0}_{(50 \times 1)} & \mathbf{1}_{(50 \times 1)} \end{bmatrix}$

- $\mathbf{B} = \begin{bmatrix} \mu_{11} & \mu_{12} & \mu_{13} & \mu_{14} \\ \mu_{21} & \mu_{22} & \mu_{23} & \mu_{24} \\ \mu_{31} & \mu_{32} & \mu_{33} & \mu_{34} \end{bmatrix}$

- $\mu_{ik}$  : média da variável  $k$  do grupo  $i$ .

## Cont.: Parametrização casela de referência

$$\blacksquare \mathbf{X} = \begin{bmatrix} \mathbf{1}_{(50 \times 1)} & \mathbf{0}_{(50 \times 1)} & \mathbf{0}_{(50 \times 1)} \\ \mathbf{1}_{(50 \times 1)} & \mathbf{1}_{(50 \times 1)} & \mathbf{0}_{(50 \times 1)} \\ \mathbf{1}_{(50 \times 1)} & \mathbf{0}_{(50 \times 1)} & \mathbf{1}_{(50 \times 1)} \end{bmatrix}$$

$$\blacksquare \mathbf{B} = \begin{bmatrix} \mu_{11} & \mu_{12} & \mu_{13} & \mu_{14} \\ \alpha_{21} & \alpha_{22} & \alpha_{23} & \alpha_{24} \\ \alpha_{31} & \alpha_{32} & \alpha_{33} & \alpha_{34} \end{bmatrix}$$

- $\mu_{1k}$  : média da variável  $k$  do grupo 1 (grupo de referência - setosa).
- $\alpha_{ik} = \mu_{ik} - \mu_{1k}$ ,  $i = 2, 3$  : é a diferença entre a média do grupo  $i$  e a média do grupo 1, em relação a variável  $k$ .

# Decomposição da matriz de covariâncias total

- Pode-se demonstrar, para o exemplo em questão, que:

$$\underbrace{\sum_{i=1}^G \sum_{j=1}^{n_i} (\mathbf{Y}_{ij} - \bar{\mathbf{Y}}) (\mathbf{Y}_{ij} - \bar{\mathbf{Y}})'}_{\text{Matriz de SQ Total}} = \underbrace{\sum_{i=1}^G n_i (\bar{\mathbf{Y}}_i - \bar{\mathbf{Y}}) (\bar{\mathbf{Y}}_i - \bar{\mathbf{Y}})'}_{\text{Matriz de SQ do Modelo}} + \underbrace{\sum_{i=1}^G \sum_{j=1}^{n_i} (\mathbf{Y}_{ij} - \bar{\mathbf{Y}}_i) (\mathbf{Y}_{ij} - \bar{\mathbf{Y}}_i)'}_{\text{Matriz de SQ do Erro}}$$
$$\mathbf{T} = \mathbf{M} + \mathbf{E}$$

- De uma forma geral:  $\mathbf{T} = \mathbf{Y}'(\mathbf{I} - n^{-1}\mathbf{J})\mathbf{Y}$ ;  $\mathbf{M} = \mathbf{Y}'(\mathbf{H} - n^{-1}\mathbf{J})\mathbf{Y}$ ;  $\mathbf{E} = \mathbf{Y}'(\mathbf{I} - \mathbf{H})\mathbf{Y}$ ,  $\mathbf{H} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ ,  $\mathbf{J} = \mathbf{1}\mathbf{1}'$ ,  $\mathbf{I}$  é uma matriz identidade de ordem  $n$  e  $\mathbf{1}$  é um vetor coluna unitário de dimensão  $n$ .



# Variância generalizada

- Seja  $\Sigma_{(p \times p)}$  uma matriz de covariâncias.
- Variância generalizada  $|\Sigma|$  (resume a informação contida em  $\Sigma$ ).
- Suponha  $p = 2$ .
- Assim  $|\Sigma| = \sigma_1^2 \sigma_2^2 - \sigma_{11}^2 = \sigma_1^2 \sigma_2^2 - \sigma_1^2 \sigma_2^2 \rho^2 = \sigma_1^2 \sigma_2^2 (1 - \rho^2)$ .
- Estamos supondo que  $\Sigma_1 = \Sigma_2 = \dots = \Sigma_G = \Sigma$  (teste de Box para igualdade de matrizes de covariâncias).

## As quatro estatísticas “tradicionais”

- Lembre-se de que  $\mathbf{T} = \mathbf{M} + \mathbf{E}$ .
- Sejam  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_s$  os autovalores diferentes de zero da matriz  $\mathbf{E}^{-1}\mathbf{M}$ , em que  $s = \min(p, G - 1)$ .

- **Lambda de Wilks:** 
$$\prod_{i=1}^s \frac{1}{1 + \lambda_i} = \frac{|\mathbf{E}|}{|\mathbf{E} + \mathbf{M}|}.$$

- **Traço de Pillai:** 
$$\sum_{i=1}^s \frac{\lambda_i}{1 + \lambda_i} = \text{tr}[\mathbf{M}(\mathbf{M} + \mathbf{E})^{-1}].$$

- **Traço de Lawley-Hotelling:** 
$$\sum_{i=1}^s \lambda_i^{-1} = \text{tr}[\mathbf{M}\mathbf{E}^{-1}].$$

- **Máxima raiz de Roy:** 
$$\frac{\lambda_1}{1 + \lambda_1}.$$

## Cont.

- Quanto menor o valor das estatística de Wilks e maior os valores das estatísticas de Pillai, Lawley-Hotelling e de Roy, mais evidências tem-se contra  $H_0$ .
- Existem aproximações pela distribuição F, para cada uma destas estatísticas ([link manual do SAS](#), livro: [Multivariate Statistics: High-Dimensional and Large-Sample Approximations](#)).

# Aplicação

- Dados da iris: as quatro variáveis apresentadas e os três grupos.
- O teste de Box indica a rejeição da igualdade entre as matrizes de covariâncias (estatística = 140,94 ;  $p\text{valor} < 0,0001$ ).
- Além da heterocedasticidade, a suposição de normalidade não parece ser razoável. Assim, os resultados obtidos podem não ser confiáveis.
- Utilização do pacote *manova* ([manual](#)) implementado na linguagem R (próximos slides).

# Aplicação

- Outras opções de ajuste de modelos lineares multivariados no R:
  - Função apresentada no [Apêndice do Livro: An R Companion to Applied Regression](#).
  - Outras metodologias (funções) apresentadas em [livro: An R Companion to Applied Regression](#).
  - Funções do pacote [car](#), como por exemplo [aqui](#).
  - Veja também o livro: [Modern Multivariate Statistical Techniques Regression, Classification, and Manifold Learning](#).

## Estatísticas calculadas e p-valores

<b>Estatística</b>	<b>Valor</b>	<b>Aproxim. pela dist. F.</b>	<b>p-valor</b>
Wilks	0,02	191,15	$< 0,0001$
Pillai	1,19	53,46	$< 0,0001$
Hotelling-Lawley	32,47	580,53	$< 0,0001$
Roy	32,19	1167,00	$< 0,0001$

A igualdade simultânea dos vetores de médias é rejeitada, de acordo com cada uma das estatísticas. Como realizar outras comparações de interesse?

# Anovas univariadas

CS

FV	g.l.	SQ	QM	Estat. F	p-valor
Espécie	2	63,21	31,61	119,26	< 0,0001
Resíduos	147	38,96	0,27		

LS

FV	g.l.	SQ	QM	Estat. F	p-valor
Espécie	2	11,34	5,67	49,16	< 0,0001
Resíduos	147	16,96	0,12		

# Anovas univariadas

CP

FV	g.l.	SQ	QM	Estat. F	p-valor
Espécie	2	437,10	218,55	1180,16	< 0,0001
Resíduos	147	27,22	0,19		

LP

FV	g.l.	SQ	QM	Estat. F	p-valor
Espécie	2	80,41	40,21	960,01	< 0,0001
Resíduos	147	6,16	0,04		



# Comentários

- Realizar anovas univariadas, desconsidera a estruturas de correlação existente.
- Além disso, não permitem testar hipóteses envolvendo mais de uma variável, de modo simultâneo.
- Uma vez que se decide realizar, desde o início, análises multivariadas, é melhor considerar o MRNLM.
- Em geral, as hipóteses de interesse em MRNLM podem ser descritas como combinações lineares dos parâmetros  $\mathbf{B}$ .

## Forma vetorial (MLNM)

- Considere novamente o modelo:  $\mathbf{Y}_{(n \times p)} = \mathbf{X}_{(n \times q)}\mathbf{B}_{(q \times p)} + \boldsymbol{\xi}_{(n \times p)}$ .  
Portanto, temos que ([propriedades de matrizes](#)):

$$\begin{aligned}\mathbf{Y}'_{(p \times n)} &= \mathbf{B}'_{(p \times q)}\mathbf{X}'_{(q \times n)} + \boldsymbol{\xi}'_{(p \times n)} \\ \text{vec}(\mathbf{Y}') &= (\mathbf{X}_{(n \times q)} \otimes \mathbf{I}_p) \text{vec}(\mathbf{B}') + \text{vec}(\boldsymbol{\xi}') \\ \mathbf{Y}^*_{(np \times 1)} &= \mathbf{X}^*_{(np \times pq)}\boldsymbol{\beta}_{(pq \times 1)} + \boldsymbol{\xi}^*_{(np \times 1)}\end{aligned}$$

pois  $\text{vec}(\mathbf{ABC}) = (\mathbf{C}' \otimes \mathbf{A})\text{vec}(\mathbf{B})$ .

- Note, assim, que as observações dos indivíduos foram concatenadas (uma abaixo da outra), nos vetores  $\mathbf{Y}^*$  e  $\boldsymbol{\xi}^*$ .

## Cont.

- Portanto (**propriedades da DNM**), temos que  $\mathbf{Y}^* \sim N_{pn}(\mathbf{X}^* \boldsymbol{\beta}, \boldsymbol{\Sigma}^*)$ , em que  $\boldsymbol{\Sigma}^* = \mathbf{I}_n \otimes \boldsymbol{\Sigma}_{(p \times p)}$ .
- O estimador de **mínimos quadrados generalizados** de  $\boldsymbol{\beta}$  é obtido minimizando-se

$$(\mathbf{Y}^* - \mathbf{X}^* \boldsymbol{\beta})' \boldsymbol{\Sigma}^{*-1} (\mathbf{Y}^* - \mathbf{X}^* \boldsymbol{\beta}).$$

- O que implica que  $\hat{\boldsymbol{\beta}} = \left( \mathbf{X}^{*'} \boldsymbol{\Sigma}^{*-1} \mathbf{X}^* \right)^{-1} \mathbf{X}^{*'} \boldsymbol{\Sigma}^{*-1} \mathbf{Y}^*$ .
- Exercício: obtenha o estimador de MQO de  $\mathbf{B}$ .

## Cont.

- Note que

$$\begin{aligned}\hat{\beta} &= \left[ (\mathbf{X} \otimes \mathbf{I})' (\mathbf{I} \otimes \Sigma)^{-1} (\mathbf{X} \otimes \mathbf{I}) \right]^{-1} (\mathbf{X} \otimes \mathbf{I})' (\mathbf{I} \otimes \Sigma)^{-1} \mathbf{Y}^* \\ &= \left[ (\mathbf{X}'\mathbf{X} \otimes \Sigma^{-1}) \right]^{-1} [\mathbf{X}' \otimes \Sigma^{-1}] \mathbf{Y}^* \\ &= \left[ (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \otimes \mathbf{I} \right] \mathbf{Y}^* \\ &= \mathbf{A} \mathbf{Y}^*\end{aligned}\tag{1}$$

- Por outro lado, temos que

$$\mathcal{E}(\hat{\beta}) = \left[ (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \otimes \mathbf{I} \right] [\mathbf{X} \otimes \mathbf{I}] \beta = \beta.$$

- Além disso,

$$\text{Cov}(\hat{\beta}) = \left[ (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \otimes \mathbf{I} \right] [\mathbf{I} \otimes \Sigma] \left[ \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \otimes \mathbf{I} \right] = (\mathbf{X}'\mathbf{X})^{-1} \otimes \Sigma$$

## Cont.

- Logo,  $\hat{\beta} \sim N_{pq}(\beta, \Sigma_\beta)$ , em que  $\Sigma_\beta = (\mathbf{X}'\mathbf{X})^{-1} \otimes \Sigma$ .
- Portanto, se  $\Sigma$  for conhecido (e conseqüentemente, o for  $\Sigma_\beta$ ), então

$$(\hat{\beta} - \beta)' (\Sigma_\beta)^{-1} (\hat{\beta} - \beta) \sim \chi^2_{(qp)}$$

- Por outro lado, **de modo semelhante ao caso univariado**, a grande maioria das hipóteses de interesse, podem ser escritas na forma

$$H_0 : \mathbf{C}_{(r \times q)} \mathbf{B}_{(q \times p)} \mathbf{U}_{(p \times s)} = \mathbf{M}_{(r \times s)} \text{ vs } H_1 : \mathbf{CBU} \neq \mathbf{M}$$

em que  $r \leq q$  e  $s \leq p$ .

## Cont.

- Note agora que  $H_0 : \mathbf{U}'\mathbf{B}'\mathbf{C}' = \mathbf{M}'$  e, assim, temos que:

$$\text{vec}(\mathbf{U}'\mathbf{B}'\mathbf{C}') - \underbrace{\text{vec}(\mathbf{M}')}_{\mathbf{M}^*} = \underbrace{(\mathbf{C} \otimes \mathbf{U}')}_{\mathbf{C}^*} \boldsymbol{\beta} - \mathbf{M}^* = \mathbf{C}^* \boldsymbol{\beta} - \mathbf{M}^*.$$

- Logo, podemos escrever as hipóteses anteriores como:

$$H_0 : \mathbf{C}^* \boldsymbol{\beta} - \mathbf{M}^* = \mathbf{0} \text{ vs } H_1 : \mathbf{C}^* \boldsymbol{\beta} - \mathbf{M}^* \neq \mathbf{0}.$$

- Além disso,  $\hat{\boldsymbol{\theta}} = \mathbf{C}^* \hat{\boldsymbol{\beta}} - \mathbf{M}^* \sim N_{rs} \left( \mathbf{C}^* \boldsymbol{\beta} - \mathbf{M}^*, \mathbf{C}^* \boldsymbol{\Sigma}_{\boldsymbol{\beta}} \mathbf{C}^{*'} \right)$ .
- Se  $\boldsymbol{\Sigma}_{\boldsymbol{\beta}}$  for conhecido, temos que, sob  $H_0$

$$\hat{\boldsymbol{\theta}}' \left( \mathbf{C}^* \boldsymbol{\Sigma}_{\boldsymbol{\beta}} \mathbf{C}^{*'} \right)^{-1} \hat{\boldsymbol{\theta}} \sim \chi^2_{(rs)}$$

## Cont.

- Seja, então,  $\widehat{\Sigma}$ , um **estimador consistente** de  $\Sigma$  ( $\widehat{\Sigma} \xrightarrow[n \rightarrow \infty]{P} \Sigma$ ).  
Logo  $\widehat{\Sigma}_\beta = (\mathbf{X}'\mathbf{X})^{-1} \otimes \widehat{\Sigma}$  o será para  $\Sigma_\beta$ .
- $\widehat{\Sigma} = \frac{1}{n-q} (\mathbf{Y} - \mathbf{X}\widehat{\mathbf{B}})' (\mathbf{Y} - \mathbf{X}\widehat{\mathbf{B}})$ , em que  $\widehat{\mathbf{B}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}$ .
- Assim, pelo **Teorema de Slutsky**,

$$Q = \widehat{\boldsymbol{\theta}}' \left( \mathbf{C}^* \widehat{\Sigma}_\beta \mathbf{C}^{*'} \right)^{-1} \widehat{\boldsymbol{\theta}} \xrightarrow[n \rightarrow \infty]{D} \chi_{(rs, \delta)}^2,$$

em que

$$\delta = (\mathbf{C}^* \boldsymbol{\beta} - \mathbf{M}^*)' \left( \mathbf{C}^* \Sigma_\beta \mathbf{C}^{*'} \right)^{-1} (\mathbf{C}^* \boldsymbol{\beta} - \mathbf{M}^*).$$

- Sob  $H_0$  tem-se que  $\delta = 0$ .

## Cont.

- Nível descritivo:  $P(Q > q_{calc} | H_0)$ , em que  $Q \approx \chi^2_{(rs)}$ , para  $n$  suficientemente grande e  $q_{calc}$  é o valor calculado da estatística  $Q$ .
- Função poder:  $P(Q > q_c | H_1, \alpha)$ , em que  $Q \approx \chi^2_{(rs)}$  para  $n$  suficientemente grande e  $q_c$  é o valor crítico para um dado  $\alpha$  (nível de significância).
- Assim, o poder estimado do teste é dado por:  $P(\tilde{Q} > q_c | H_1, \alpha)$ , em que  $\tilde{Q} \approx \chi^2_{(rs, \tilde{\delta})}$  para  $n$  suficientemente grande,  $q_c$  é o valor crítico para um dado  $\alpha$  (nível de significância),  
$$\tilde{\delta} = \left( \mathbf{C}^* \tilde{\beta} - \mathbf{M}^* \right)' \left( \mathbf{C}^* \tilde{\Sigma}_{\beta} \mathbf{C}^{*'} \right)^{-1} \left( \mathbf{C}^* \tilde{\beta} - \mathbf{M}^* \right)$$
 e “ $\tilde{\sim}$ ” representa a respectiva estimativa.



## Cont.

- Voltando ao exemplo da íris, se quisermos testar se as médias entre os grupos, em relação à variável CS (que é a variável 1), são simultaneamente iguais, teríamos (parametrização de médias):

$$\mathbf{C} = \begin{bmatrix} 1 & -1 & 0 \\ 1 & 0 & -1 \end{bmatrix}$$
$$\mathbf{U} = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}; \mathbf{M} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}; \mathbf{CBU} = \begin{bmatrix} \mu_{11} - \mu_{21} \\ \mu_{11} - \mu_{31} \end{bmatrix}$$

## Cont.

- Voltando ao exemplo da íris, se quisermos testar se as médias entre os grupos, em relação à variável CS (que é a variável 1), são simultaneamente iguais, teríamos (parametrização casela de referências):

$$\mathbf{C} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$
$$\mathbf{U} = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}; \mathbf{M} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}; \mathbf{CBU} = \begin{bmatrix} \alpha_{21} \\ \alpha_{31} \end{bmatrix}$$

# Comparações múltiplas

- Comparações de interesse (para  $k = 1, 2, 3, 4$ )

$$H_0 : \mu_{1k} = \mu_{2k} \text{ vs } H_1 : \mu_{1k} \neq \mu_{2k}$$

$$H_0 : \mu_{1k} = \mu_{3k} \text{ vs } H_1 : \mu_{1k} \neq \mu_{3k}$$

$$H_0 : \mu_{2k} = \mu_{3k} \text{ vs } H_1 : \mu_{2k} \neq \mu_{3k}$$

# Resultados

- Estatística do teste e p-valor entre parênteses.
- Variável CS:
  - Setosa x Versicolor: 81,59 ( $< 0,0001$ ).
  - Setosa x Virginica: 236,10 ( $< 0,0001$ ).
  - Versicolor x Virgínica: 40,10 ( $< 0,0001$ ).
- Variável LS:
  - Setosa x Versicolor: 93,81 ( $< 0,0001$ ).
  - Setosa x Virginica: 44,60 ( $< 0,0001$ ).
  - Versicolor x Virgínica: 9,02 ( $0,0027$ ).

# Resultados

- Estatística do teste e p-valor entre parênteses.
- Variável CP:
  - Setosa x Versicolor: 1056,87 ( $< 0,0001$ ).
  - Setosa x Virginica: 2258,26 ( $< 0,0001$ ).
  - Versicolor x Virgínica: 225,35 ( $< 0,0001$ ).
- Variável LP:
  - Setosa x Versicolor: 696,25 ( $< 0,0001$ ).
  - Setosa x Virginica: 1891,28 ( $< 0,0001$ ).
  - Versicolor x Virgínica: 292,49 ( $< 0,0001$ ).





# Análise de resíduos

- Veja, para o caso univariado: [link](#).
- Resíduo ordinário:  $\mathbf{R}^* = \mathbf{Y} - \mathbf{X}\hat{\mathbf{B}}$ . (distribuição de referência:  $N(0,a)$ , exata, em que “a” depende de  $\Sigma$  e  $\mathbf{X}$ ).
- Resíduo padronizado:  $\mathbf{R} = \mathbf{R}^* \mathbf{D}^{-1}$ , em que  $\mathbf{D} = \sqrt{(\text{diag}(\hat{\Sigma}))}$ . (distribuição de referência:  $N(0,1)$ , assintótica)
- Resíduo studentizado (RS):  $\mathbf{R}_s = \mathbf{R} ./ \sqrt{(\mathbf{1}_{(n \times p)} - \mathbf{h}_{(n \times p)})}$ , em que  $./$  denota a divisão elemento por elemento,  $\mathbf{h}$  é uma matriz em que cada coluna corresponde à diagonal principal da matriz  $\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ . (distribuição de referência:  $N(0,1)$ , assintótica)

# Análise de resíduos





- Resíduo multivariado (RM) :  $\mathbf{R}_s^{(m)} = \mathbf{R}^*(\text{chol}(\widehat{\Sigma}))^{-1}$ . (distribuição de referência:  $N(0,1)$ , assintótica)
- Resíduo baseado na distância de Mahalanobis (via RM):  
 $(\mathbf{R}_i^*)' \widehat{\Sigma}^{-1} \mathbf{R}_i^*$ , em que  $\mathbf{R}_i^* = \mathbf{Y}_i - \mathbf{X}_i \widehat{\mathbf{B}}$ ,  $i = 1, 2, \dots, n$  é a  $i$ -ésima linha da matriz  $\mathbf{R}^*$ .
- Podemos também considerar uma combinação do RS e do RM, ou seja  $\mathbf{R}_s^{*(m)} = \mathbf{R}_s^{(m)} ./ \sqrt{(\mathbf{1}_{(n \times p)} - \mathbf{h}_{(n \times p)})}$  (resíduo studentizado multivariado).
- Exercício: escrever os valores individuais, para cada um dos resíduos acima .

# Análise de resíduos (RS) - comprimento da sépala













# Análise de resíduos (RS) - largura da sépala




# Análise de resíduos (RS) - comprimento da pétala




# Análise de resíduos (RS) - largura da pétala




# Envelopes (RS) - comprimento da sépala




# Envelopes (RS) - largura da sépala







# Envelopes (RS) - comprimento da pétala



# Envelopes (RS) - largura da pétala







# Análise de resíduos (RM) - comprimento da sépala













# Análise de resíduos (RM) - largura da sépala




# Análise de resíduos (RM) - comprimento da pétala




# Análise de resíduos (RM) - largura da pétala




# Envelopes (RM) - comprimento da sépala




## Envelopes (RM) - largura da sépala




# Envelopes (RM) - comprimento da pétala



# Envelopes (RM) - largura da pétala







# Envelopes (RM) - distância de Mahalanobis





# Médias observadas e previstas e respectivos IC(95%)



# Comentários

- Os gráficos de resíduos acusam:
  - Heterocedasticidade dos erros (para cada uma das variáveis).
  - Não normalidade dos erros (para cada uma das variáveis).
  - Independência entre as observações de diferentes flores (iris).
- Assim, podemos concluir que o modelo não está bem ajustado
- Lembrando que o MRNLM é, em geral, sensível (não robusto) à ausência das suposições sobre os erros, conclui-se que os resultados não são confiáveis.