


# Análise de componentes principais: parte 2

Prof. Caio Azevedo


# Exemplo 1: dados da íris “de Fisher”

- Recapitulando: quatro variáveis, três grupos, 50 observações por grupo.
- Objetivos: caracterizar os grupos em relação à essas quatro variáveis e compará-los.
- Utilizaremos a **análise de componentes principais** (usando a matriz de correlações) para esse fim.
- Denotaremos por “grupo” os tipo de iris (setosa, versicolor e virginica).

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



# Scree-plot



# Resultados da ACP

- Variâncias de cada componente:

$$\tilde{\lambda}_1 = 2,91, \tilde{\lambda}_2 = 0,91, \tilde{\lambda}_3 = 0,15, \tilde{\lambda}_4 = 0,02.$$

- Variância explicada

	<b>Comp. 1</b>	<b>Comp. 2</b>	<b>Comp. 3</b>	<b>Comp. 4</b>
PVE (%)	72,96	22,85	3,67	0,51
PVEA (%)	72,96	95,81	99,48	100,00

# Resultados da ACP

## ■ Componentes principais

	<b>Comp. 1 (<math>Y_1</math>)</b>	<b>Comp. 2 (<math>Y_2</math>)</b>
CS ( $Z_1$ )	0,52 (0,89)	-0,37 (0,37)
LS ( $Z_2$ )	-0,27 (-0,46)	-0,92 (0,88)
CP ( $Z_3$ )	0,58 (0,99)	-0,02 (0,02)
LP ( $Z_4$ )	0,56 (0,96)	-0,07 (0,07)

- Primeira componente (CP1): constraste entre as variáveis CS, CP e LP e a variável LS.
- Segunda componente (CP2): é uma média ponderada entre as variáveis CS e LS.

# Equações das componentes

- Para  $i = 1, 2, \dots, 150$  (flores)

$$Y_{1i} = 0,52Z_{i1} - 0,27Z_{i2} + 0,58Z_{i3} + 0,56Z_{i4}$$

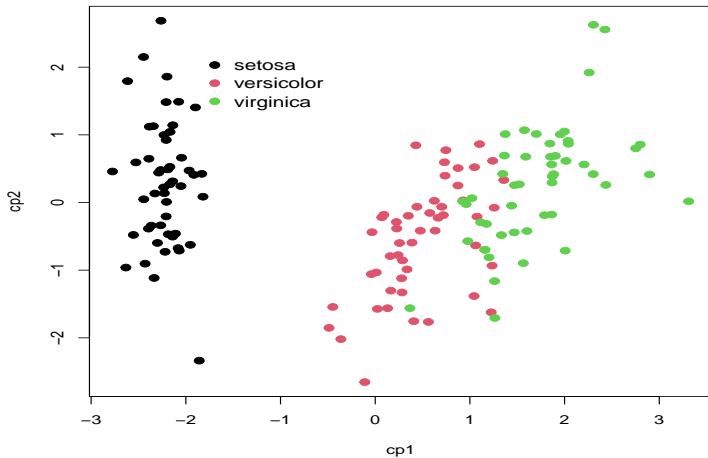
$$Y_{2i} = -0,37Z_{1i} - 0,92Z_{2i}$$

# Interpretações


- Valores positivos para CP1 e CP2:
  - Valores acima da média (CS, CP, LP) e abaixo da média (LS).
- Valores negativos para CP1 e CP2:
  - Valores abaixo da média (CS, CP, LP) e acima da média (LS).
- Valores positivos para CP1 e negativos CP2:
  - Valores acima da média (CS, CP, LP,LS) .
- Valores negativos para CP1 e positivos para CP2:
  - Valores abaixo da média (CS, CP, LP, LS).





# Dispersão entre as duas primeiras componentes, por grupo



## Gráfico anterior, com divisão de quadrantes




# Box plots das duas CP's




# Histogramas da CP1


**CP1 – setosa**






**CP1 – versicolor**



**CP1 – virginica**




# Histogramas da CP2




# QQplot para CP1


setosa, KS = 0.8394



versicolor, KS = 0.8713




virginica, KS = 0.7891




# QQplot para CP2


setosa, KS = 0.8326




versicolor, KS = 0.7441



virginica, KS = 0.4855




# Biplot: duas componentes principais





# Biplot: duas componentes principais



## Comparação de grupos via **modelos lineares**





$$Y_{ijk} = \mu_k + \alpha_{ik} + \xi_{ijk},$$

$i = 1, 2, 3$  (tipo de iris, setosa, versicolor, virginica),  $j = 1, \dots, n_i$ ,


$n_i = 50, \forall i, k = 1, 2$  (componente principal),  $\xi_{ijk} \stackrel{i.i.d}{\sim} N(0, \sigma_k^2)$

- $Y_{ijk}$  : valor da componente principal  $k$ , da planta  $j$ , do tipo de íris  $i$ .
- $\mu_k$  : média da componente principal  $k$  do grupo de referência (setosa).
- $\alpha_{ik}$  : incremento na média da componente principal  $k$ , do grupo  $i$ , em relação ao grupo de referência.
- Utilizou-se o resíduo “studentizado” (veja [aqui](#)), para verificar a qualidade de ajuste do modelo.

# Componente 1: gráficos de diagnóstico



## Componente 1: QQ-plot com envelopes



# Componente 1

Parâmetro	Estimativa	EP	Estat.t	p-valor
$\mu_1$	-2,22	0,06	-35,65	< 0,0001
$\alpha_{21}$	2,72	0,09	30,83	< 0,0001
$\alpha_{31}$	3,95	0,09	44,79	< 0,0001





Há diferença entre o primeiro grupo e os outros dois. Vamos agora testar a igualdade entre as médias dos dois outros grupos através de testes do tipo  $C\beta = M$  (veja mais [aqui](#)).

# Componente 1


- Teste:  $\alpha_{21} = \alpha_{31}$  vs  $\alpha_{21} \neq \alpha_{31}$ ,  $f_c = 194,83 (< 0,0001)$ .
- Médias previstas pelo modelo.

grupo	Estimativa	EP	IC(95%)
setosa	-2,22	0,06	[-2,35 ; -2,10]
versicolor	0,50	0,06	[0,37 ; 0,62]
virginica	1,73	0,06	[1,60 ; 1,85]

## Componente 2: gráficos de diagnóstico



## Componente 2: QQ-plot com envelopes









## Componente 2


Parâmetro	Estimativa	EP	Estat.t	p-valor
$\mu_2$	0,2889	0,1247	-2,32	0,0219
$\alpha_{22}$	-0,8391	0,1764	4,76	<0,0001
$\alpha_{32}$	-0,0277	0,1764	0,16	0,8755

Há diferença entre o primeiro grupo e o segundo e uma equivalência entre aquele e o terceiro. Vamos ajustar um modelo reduzido ( $\alpha_{32} = 0$ ).

# Componente 2: gráficos de diagnóstico



## Componente 2: QQ-plot com envelopes



## Componente 2

- Estimativa dos parâmetros.

Parâmetro	Estimativa	EP	Estat.t	p-valor
$\mu_2$	0,2751	0,0879	-3,13	0,0021
$\alpha_{22}$	-0,8253	0,1523	5,42	<0,0001

- Médias previstas pelo modelo.

grupo	Estimativa	EP	IC(95%)
setosa/virginica	0,28	0,09	[-0,45 ; -0,10 ]
versicolor	-0,55	0,12	[0,30 ; 0,80]