

MAE 5776

ANÁLISE MULTIVARIADA

Júlia M Pavan Soler

pavan@ime.usp.br

1º Sem/2020 - IME

Análise Multivariada

$$Y_{n \times p} = (Y_{ij}) \in \mathfrak{R}^{n \times p}$$

Já vimos 😊

- ✓ Estatísticas descritivas multivariadas, Episódios de Concentração, Boxplot Bivariado
- ✓ Distribuição N_p , Distribuições Amostrais (T^2 e W_p)
- ✓ $N_p(\mu_g; \Sigma_g)$: Inferências sobre μ_g (T^2 , MANOVA, ICS, Correções para Múltiplos testes)

Decomposições: SS_T e $Y_{n \times p}$



Técnicas Multivariadas:

Já vimos 😊

- ✓ 1. Análise de Componentes Principais (CP)
- ✓ 2. Escalonamento Multidimensional (CoP)
- ✓ 3. Análise de Correspondência
- ✓ 4. Análise Fatorial
- ✓ 5. Análise Discriminante (MANOVA)

- Análise de Agrupamento 
- Análise de Correlação Canônica

Análise de Agrupamento

Análise Multivariada de Dados

Unidades Amostras	Variáveis					
	1	2	...	j	...	p
1	Y_{11}	Y_{12}		Y_{1j}		Y_{1p}
2	Y_{21}	Y_{22}		Y_{2j}		Y_{2p}
...
i	Y_{i1}	Y_{i2}		Y_{ij}		Y_{ip}
...
n	Y_{n1}	Y_{n2}		Y_{nj}		Y_{np}

Objetivos:

- Formação de grupos de unidades amostrais \Rightarrow agrupamento de observações \Rightarrow grupos homogêneos internamente e heterogêneos externamente
- Identificar similaridades entre Variáveis \Rightarrow agrupamento de variáveis



ANÁLISE DE AGRUPAMENTO (*Cluster*)

*Análise no $\mathbb{R}^{n \times n}$
Redução de dimensionalidade
das unidades amostrais!*

MOTIVAÇÃO

Cães pré-históricos da Tailândia (Manly, 2005).

Grupo	X1	X2	X3	X4	X5	X6
G1	9.7	21.0	19.4	7.7	32.0	36.5
G2	8.1	16.7	18.3	7	30.3	32.9
G3	13.5	27.3	26.8	10.6	41.9	48.1
G4	11.5	24.3	24.5	9.3	40.0	44.6
G5	10.7	23.5	21.4	8.5	28.8	37.6
G6	9.6	22.6	21.1	8.3	34.4	43.1
Cão Pré-h	10.3	22.1	19.1	8.1	32.2	35.0

Coord. Principais:

	\hat{Y}_1	\hat{Y}_2
1	-4.76	-0.28
2	-10.23	-2.78
3	13.90	0.18
4	8.26	-1.68
5	-3.98	4.29
6	2.01	0.00
7	-5.21	0.26

Permite
visualizar a
formação
de grupos

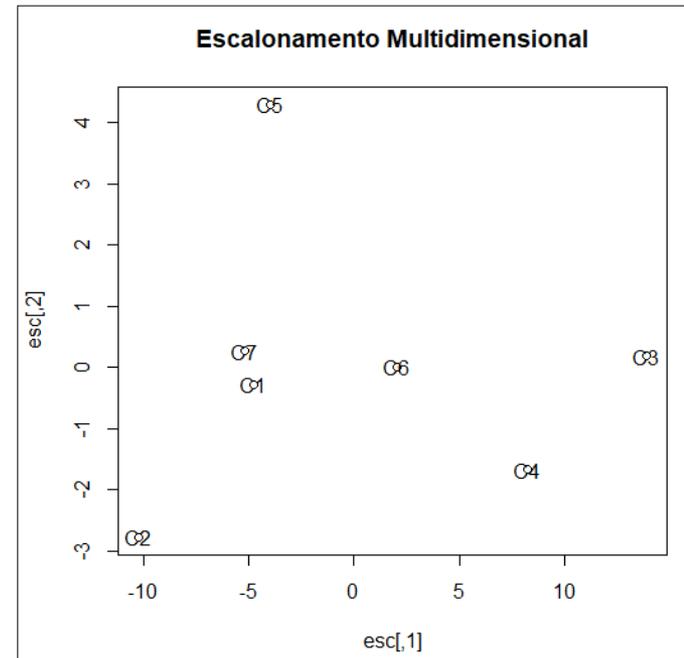
Matrizes de Distância

	1	2	3	4	5	6	7
1	0	6.21	18.70	13.13	4.83	7.43	2.03
2	6.01	0	24.34	18.55	9.44	12.94	6.62
3	18.67	24.31	0	5.99	18.38	12.50	19.20
4	13.10	18.52	5.94	0	13.64	7.26	13.78
5	4.64	9.44	18.35	13.62	0	7.98	5.09
6	6.78	12.55	11.89	6.48	7.36	0	8.67
7	0.70	5.87	19.11	13.61	4.21	7.22	0

D: Euclidiana

$= \hat{D}$

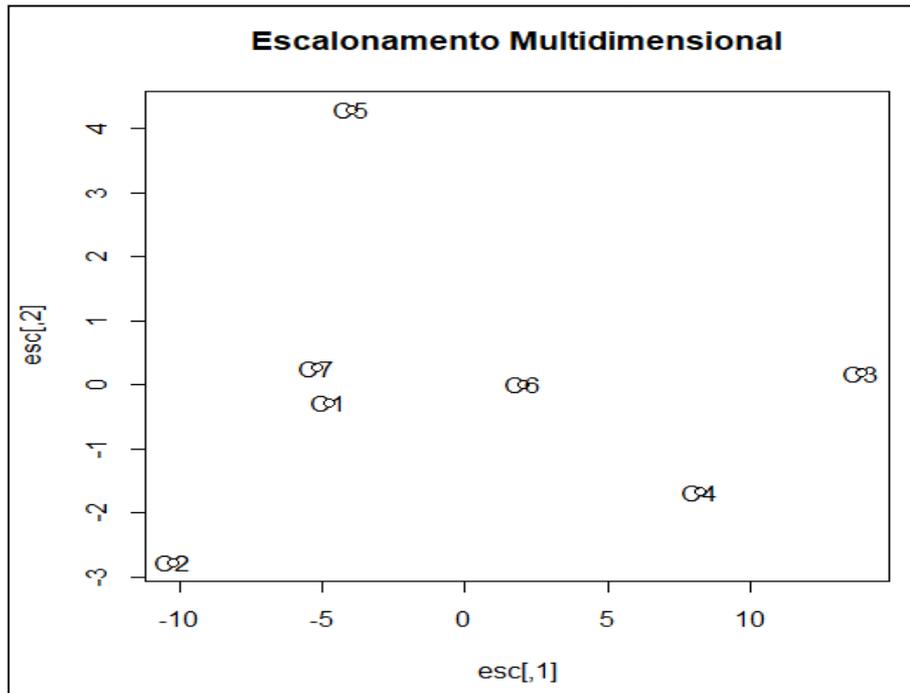
Representação das observações em \mathfrak{R}^2 : soluções equivalentes de **Componentes Principais** e **Escalonamento Multidimensional**



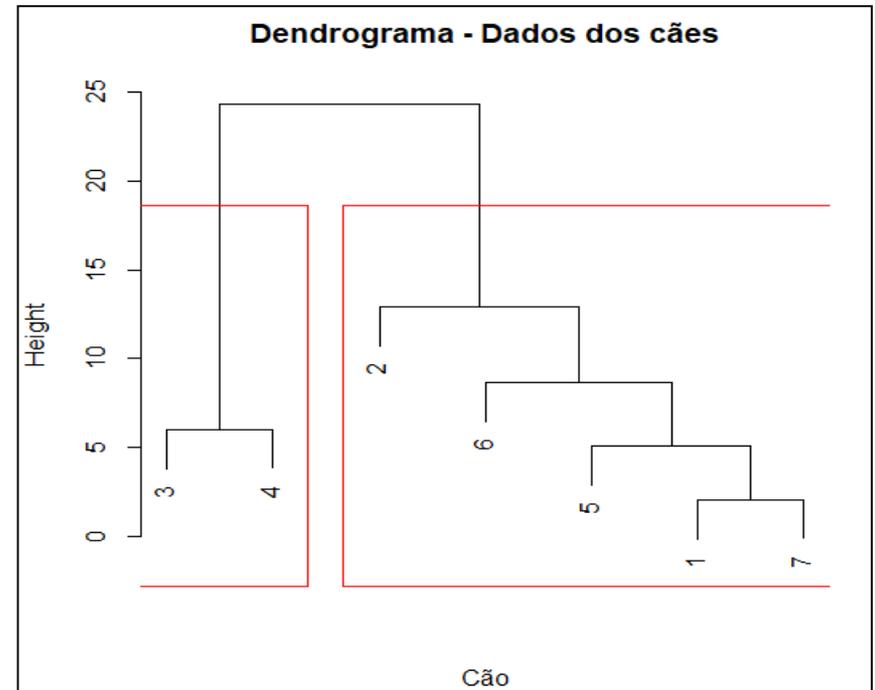
Análise de Agrupamentos

Escalonamento Multidimensional

Coordenadas Principais



Análise de Agrupamento



Como estes agrupamentos foram formados?

Ambas as análises foram realizadas à partir da matriz de distâncias (Euclidiana) entre as observações.

Análise de Agrupamentos

Etapas da Aplicação de uma Análise de Agrupamento:

- **Escolha do Critério de Parecença**: adotar uma medida de distância (ou proximidade) entre pontos (uso de *variáveis originais ou padronizadas*).
- **Definição do Número de Grupos**: decisão a priori ou a posteriori (com base nos resultados da análise)
- **Formação dos grupos**: definir o **algoritmo de formação dos grupos**.
- **Validação do Agrupamento**: é comum supor que cada grupo seja uma amostra aleatória de uma subpopulação e aplicar técnicas inferenciais (comparações de médias dos grupos, por ex.). Algumas técnicas descritivas também são usadas (correlação cofenética e gráfico da silhueta).
- **Interpretação dos grupos**: caracterizar os grupos por meio de estatísticas descritivas e gráficos (radar, perfis de médias)

Análise de Agrupamentos

Medidas de Parecença

- Medidas de Similaridade (Correlação): quanto maior o valor, maior a semelhança entre os objetos.
- Medidas de Dissimilaridade (Distância): quanto maior o valor, mais diferentes são os objetos.

Variáveis quantitativas

$$d_{ik} = \sqrt{(Y_i - Y_k)'(Y_i - Y_k)} = \sqrt{\sum_{j=1}^p (Y_{ij} - Y_{kj})^2}$$

Distância Euclidiana entre observações

$$d_{ik}^A = \sum_{j=1}^p |Y_{ij} - Y_{kj}|$$

Distância de Manhattan (quarteirão)

$$d_{ik}^M = \sqrt[m]{\sum_{j=1}^p |Y_{ij} - Y_{kj}|^m} ; m \geq 1$$

Distância de Minkowsky (mais geral)

Análise de Agrupamentos

Medidas de Parecença

- Variáveis Quantitativas: pode-se utilizar o coeficiente de correlação de Pearson como medida de parecença entre pares de unidades amostrais \Rightarrow quanto mais próximo de 1 (ou -1) maior a similaridade e quanto mais próximo de 0 maior a dissimilaridade.
 \Rightarrow Transformar a correlação em uma medida de dissimilaridade

$$d_{ii'} = (r_{ii} + r_{i'i'} - 2r_{ii'})^{1/2}$$

- Nem sempre é possível adotar a correlação como medida de parecença entre “unidades amostrais” (Ex. Considere o gráfico de dispersão de duas obs.)
- O coeficiente de correlação r é comumente usado como medida de “parecença” entre variáveis (e não entre unidades amostrais)
- A correlação valoriza padrões de forma (tendências) e a distância valoriza mais padrões de tamanho

Análise de Agrupamentos

Algoritmos de Agrupamento

- **Métodos Hierárquicos Aglomerativos**: os agrupamentos hierárquicos partem dos objetos individuais (n) para a formação de um único grupo.
 - Método do Vizinho mais Próximo/Perto (Ligação Simples)
 - Método do Vizinho mais Distante/Longe (Ligação Completa)
 - Método das Médias das Distâncias (Ligação Média)
 - Método da Centróide
 - Método de Ward

- **Métodos de Partição**: os agrupamentos não hierárquicos buscam a partição de n objetos em K grupos.
 - Algoritmo das K-Médias

Análise de Agrupamentos

Algoritmos de Agrupamentos Hierárquicos

- **Método do Vizinho mais Distante (Ligação Completa ou Distância Máxima)**: a distância entre os grupos G_1 e G_2 é dada pela maior distância entre os elementos de cada grupo

$$d(G_1, G_2) = \max_{i \in G_1, k \in G_2} d_{ik} \quad \Rightarrow \text{Forma grupos de alta homogeneidade interna}$$

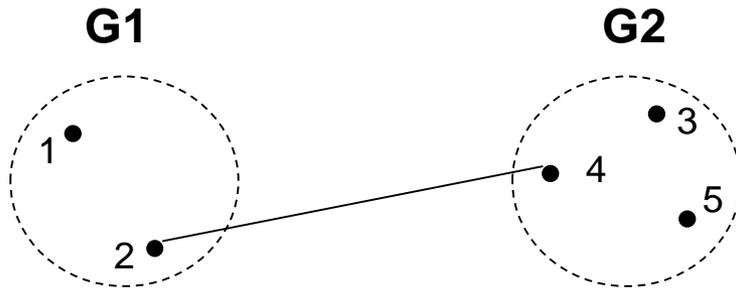
- **Método do Vizinho mais Perto (Ligação Simples ou Distância Mínima)**: a distância entre os grupos G_1 e G_2 é dada pela menor distância entre os elementos de cada grupo

$$d(G_1, G_2) = \min_{i \in G_1, k \in G_2} d_{ik} \quad \Rightarrow \text{Pode não distinguir grupos pobremente separados}$$

- **Método das Médias das Distâncias (Ligação Média)**: a distância entre os grupos é obtida pelo cálculo da média das distâncias entre os elementos de cada grupo

$$d(G_1, G_2) = \frac{\sum_i \sum_k d_{ik}}{n_i n_k}$$

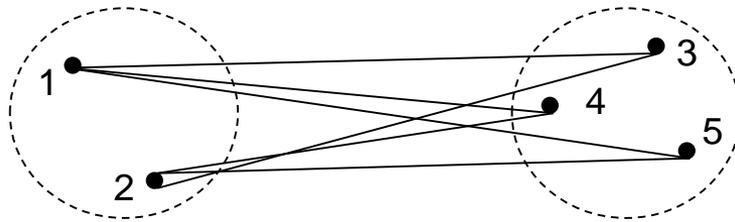
Algoritmos Hierárquicos



Distância entre Grupos

Ligação Simples

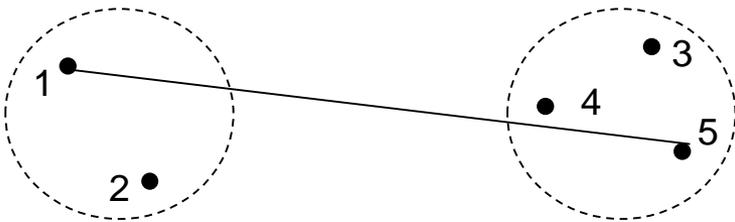
$$d(G_1, G_2) = d_{24}$$



Ligação Média

$$d(G_1, G_2) = \frac{d_{13} + d_{14} + d_{15} + d_{23} + d_{24} + d_{25}}{6}$$

6 ← 2x3

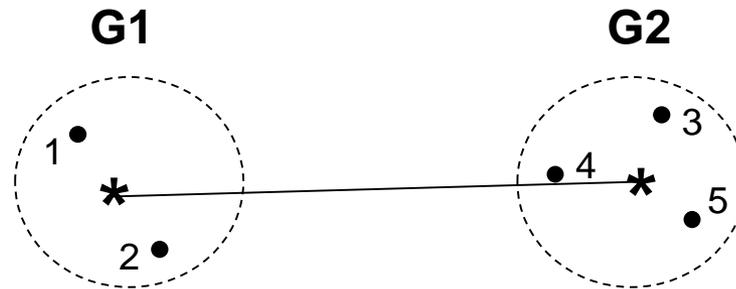


Ligação Completa

$$d(G_1, G_2) = d_{15}$$

Algoritmos Hierárquicos

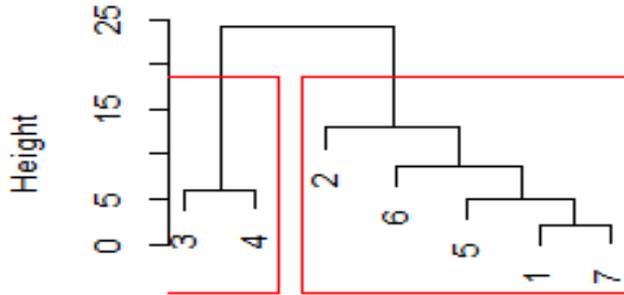
- **Método da Centróide**; este método define a coordenada de cada grupo como sendo a média das coordenadas de seus elementos. Uma vez obtida esta coordenada comum (denominada centróide) a distância entre os grupos G_1 e G_2 é dada pela distância entre as centróides.



Análise de Agrupamento – Dados dos Cães

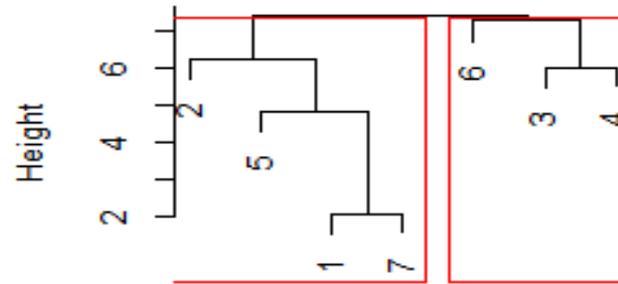
p=6

Dendrograma - Dados dos cães



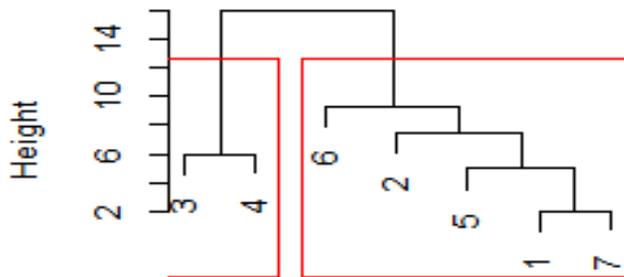
Cão
Lig. Completa - Dist. Euclidiana

Dendrograma - Dados dos cães



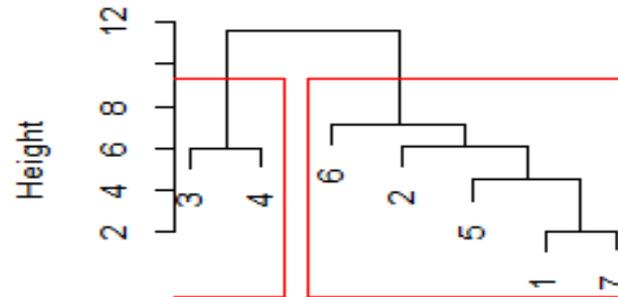
Cão
Lig. Simples - Dist. Euclidiana

Dendrograma - Dados dos cães



Cão
Lig. Média - Dist. Euclidiana

Dendrograma - Dados dos cães



Cão
Lig. Centróide - Dist. Euclidiana

Estabelecer um ponto de corte (no eixo y) para a formação de grupos!
Neste caso, 2 grupos.

Algoritmos Hierárquicos

- **Método de Ward:** é atraente pelo forte apelo estatístico envolvido. Busca formar grupos com máxima homogeneidade interna (DENTRO) e máxima heterogeneidade externa (ENTRE). O procedimento baseia-se na decomposição da Soma de Quadrados Total de uma Análise de Variância (ANOVA).

Considere a formação de L grupos de observações por meio de valores da variável Y1.

Y1			
G1	G2	...	GL
-	-		-
-	-	Y_{i1}	-
-			-
-			-
\bar{Y}_{G_1}	\bar{Y}_{G_2}		\bar{Y}_{G_L}

Como particionar a soma de quadrados total em componentes de variabilidade ENTRE e DENTRO de grupos?

\bar{Y}_1

Algoritmos Hierárquicos

Y1			
G1	G2	...	GL
-	-		-
-	-	Y_{i1}	-
-	-		-
-	-		-
\bar{Y}_{G_1}	\bar{Y}_{G_2}		\bar{Y}_{G_L}
n_{G_1}	n_{G_2}		n_{G_L}
			\bar{Y}_1

Variável Y1

$p = 1$ variável!

$$SQT(1) = SQE(1) + SQD(1)$$

$$\sum_{l=1}^L \sum_{i \in G_l} (Y_{il} - \bar{Y}_1)^2 = \sum_{l=1}^L n_{G_l} (\bar{Y}_{G_l} - \bar{Y}_1)^2 + \sum_{l=1}^L \sum_{i \in G_l} (Y_{il} - \bar{Y}_{G_l})^2$$



Método de Ward \Rightarrow Minimizar SQD (soma de quadrados dentro) e maximizar SQE (soma de quadrados entre)

Algoritmos Hierárquicos

Método de Ward: Para considerar as p variáveis simultaneamente define-se a Soma de Quadrados (Dentro) da Partição como:

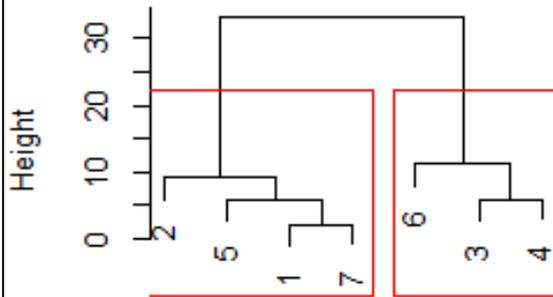
$$SQDP = \sum_{j=1}^p SQD(j)$$

Procedimento:

- Passo 1: Calcular SQDP para os possíveis $(n-1)$ grupos distintos e selecionar o agrupamento com a menor SQDP ($\exists C_2^n$)
- Passo 2: Calcular SQDP para os possíveis $(n-2)$ grupos distintos (fixada a união obtida no Passo 1) e selecionar o agrupamento com a menor SQDP
- Os próximos passos consistem na formação de $(n-3), (n-4), \dots, 1$ grupos, selecionando-se sempre o agrupamento com menor SQDP
- O número de grupos é definido em função dos saltos em cada passo.

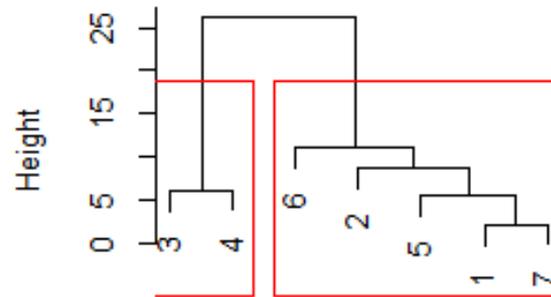
Análise de Agrupamentos – Dados dos Cães

Dendrograma - Dados dos cães



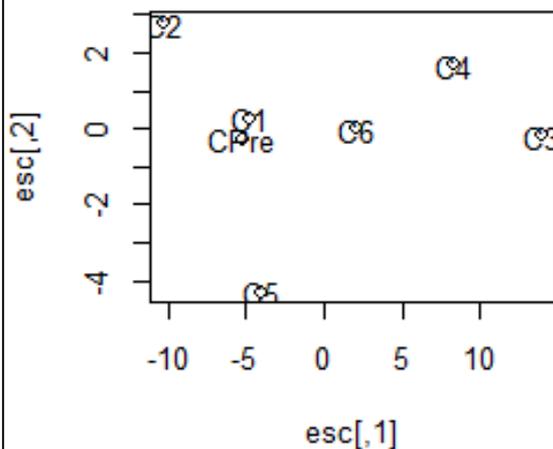
Cão
Ward.D - Dist. Euclidiana

Dendrograma - Dados dos cães



Cão
Ward.D2 - Dist. Euclidiana

Escalonamento Multidimensional



O cão C6 deve pertencer a qual agrupamento?

No R, a função “hclust” oferece dois algoritmos diferentes que implementam o método de Ward: “ward.D” e “ward.D2”

Escolher o que oferecer melhor interpretação. O gráfico das Coordenadas Principais pode ajudar na decisão!

Método das K-Médias

K-Means: Método de Partição (Não-Hierárquico)

- Passo 1: Formação de uma partição inicial. Em geral, adota-se k observações como sementes do algoritmo para formação de k grupos.
- Passo 2: Percorrer a lista de observações e calcular as distâncias de cada uma delas ao CENTRÓIDE (médias) do grupo. Fazer a re-alocação da observação ao grupo em que ela apresentar menor distância. Re-calcular os centróides dos grupos que ganharam e perderam observações.
- Passo 3: Repetir o Passo 2 até que nenhuma alteração seja feita.
- Passo 4: Adotar uma função objetivo e, em cada passo, calcular seu valor para avaliação da partição. Identificar novas mudanças na formação dos grupos que possam otimizar ainda mais a função objetivo.

Funções objetivo mais comuns a serem minimizadas:

SQDP (Soma de Quadrados Dentro da Partição)

Distância Euclidiana ao quadrado das observações ao centróide

Método das K-Médias

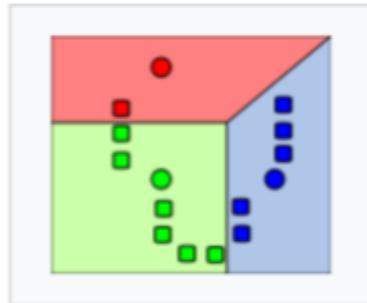
Implementado no R

Algoritmo de Lloyd (ou Forgy):


- Estabelecer K observações como **centróides iniciais** dos grupos, de forma aleatória.
- Atribuir cada uma das observações ao grupo cuja sua **distância** em relação ao centróide é a menor, entre todos os K centróides calculados.
- Quando todas as observações forem alocadas a algum grupo, **recalcular** os K centróides.
- Repetir os dois passos anteriores até que os centróides não sofram mais alterações (ou até um número máximo de iterações).



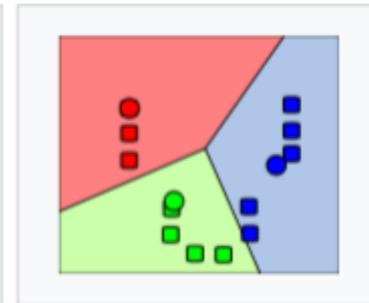
1. k initial "means" (in this case $k=3$) are randomly generated within the data domain (shown in color).



2. k clusters are created by associating every observation with the nearest mean. The partitions here represent the [Voronoi diagram](#) generated by the means.



3. The **centroid** of each of the k clusters becomes the new mean.



4. Steps 2 and 3 are repeated until convergence has been reached.

Método das K-Médias

Implementado no R
(default)

Algoritmo de Hartigan Wong (1979):

- Fazer uma **partição aleatória inicial** das n observações em K grupos.
- Selecionar uma observação, de forma aleatória, **removê-la** do seu grupo e recalculando o respectivo centróide.
- Realocar a observação removida em algum dos grupos, de forma a **minimizar** a quantidade D . Recalculando o respectivo centróide.
- Repetir os dois passos anteriores até a convergência da D , que é necessariamente decrescente nesse processo.



Procedimento K-Médias++ (Arthur e Vassilvitskii, 2007): seleção alternativa das sementes na partição inicial, de forma a garantir maior “espalhamento” dos grupos formados

Método das Partições: K-Médias

Dados dos Cães

Grupos (K=2) - Algorithm "Hartigan-Wong"

C1	C2	C3	C4	C5	C6	C7
2	2	1	1	2	2	2

Tamanho dos Grupos: 2 5

Centróides dos grupos por variável

	X1	X2	X3	X4	X5	X6
1	12.50	25.80	25.65	9.95	40.95	46.35
2	9.68	21.18	19.86	7.92	31.54	37.02

Soma de Quadrados QTotal: 481.72

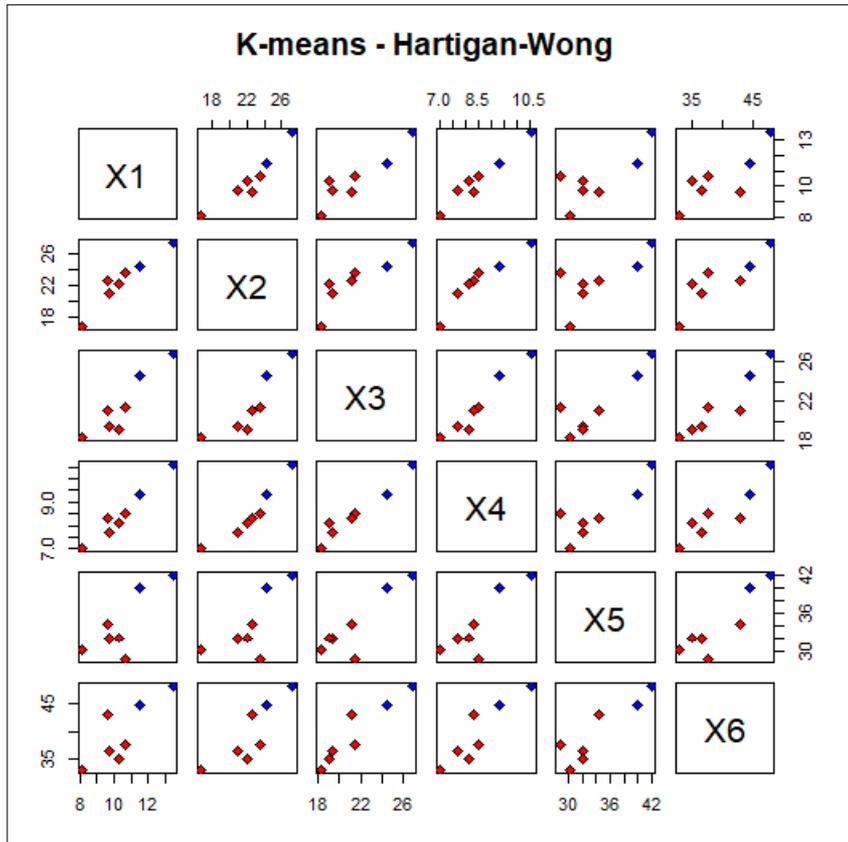
Soma de Quadrados Dentro de Grupos: 17.920 117.316

Soma de Quadrados Entre Grupos: 346.484 **SQE / SQTotal = 71.9%**

Algoritmo "Lloyd":

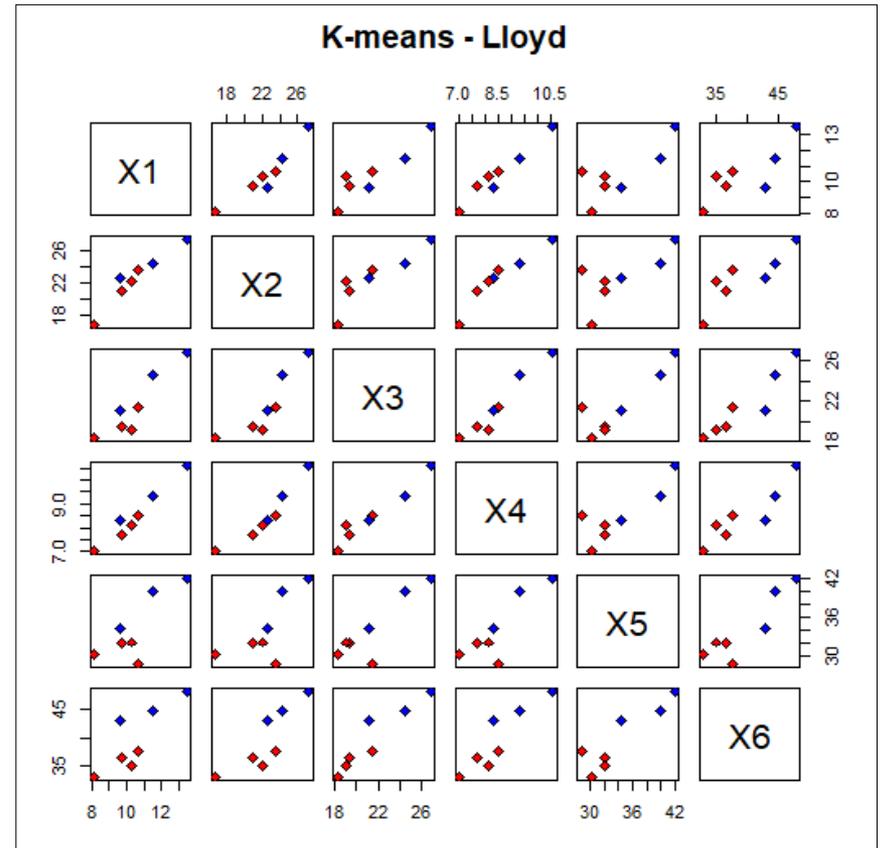
C1	C2	C3	C4	C5	C6	C7	
1	1	2	2	1	2	1	SQE / SQTotal = 71.4%

Método das Partições: K-Médias



Agrupamentos

C1	C2	C3	C4	C5	C6	C7
1	1	2	2	1	1	1



Agrupamentos

C1	C2	C3	C4	C5	C6	C7
1	1	2	2	1	2	1

Análise de Agrupamento

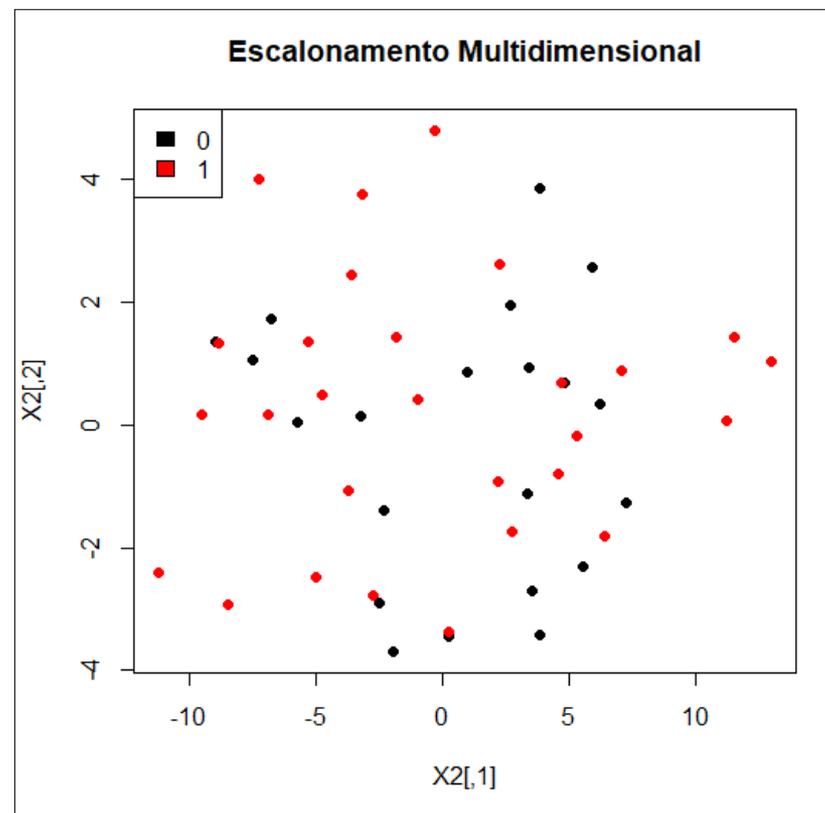
Medidas biométricas (mm) de Pardais fêmea

(Manly, 2005; Hermon Bumps, 1898).

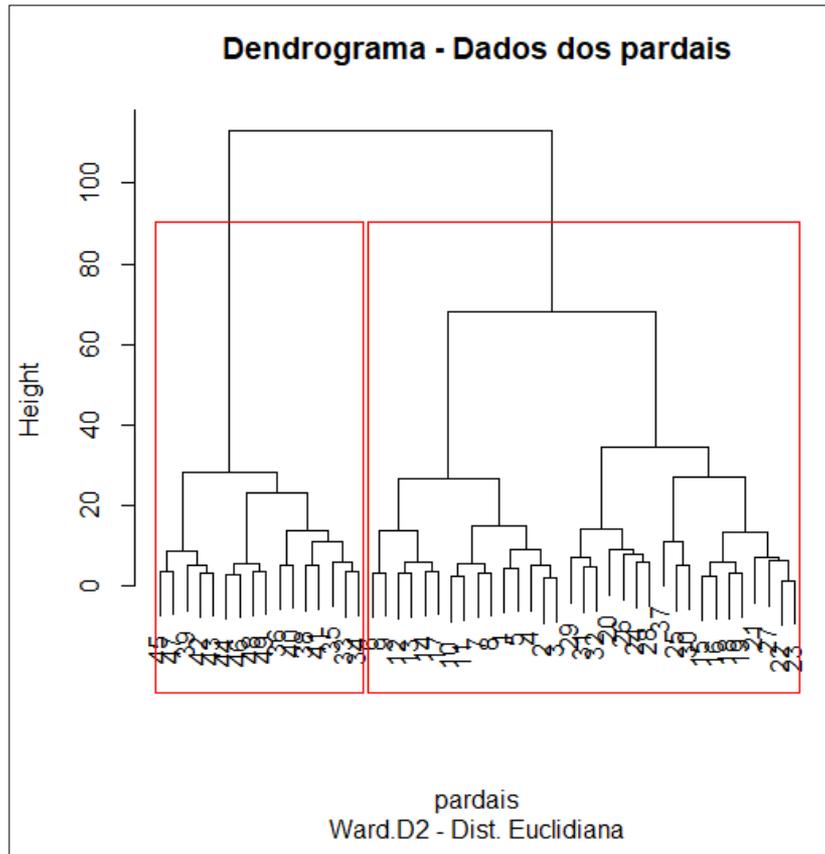
Pardal	Sobrev.	X1	X2	X3	X4	X5
1	S	156	245	31.6	18.5	20.5
...	...					
21	S	159	236	31.5	18.0	21.5
22	N	155	240	31.4	18.0	20.7
...	...					
49	N	164	248	32.3	18.8	20.9

Como os grupos de pardais Sobreviventes (=0) e Não Sobreviventes (=1) podem ser preditos? \Rightarrow Análise Discriminante

As variáveis biométricas (X1 a X5) permitem a classificação dos pardais em Sobreviventes (=0) e Não Sobreviventes (=1)? \Rightarrow Análise de Agrupamento (k=2) e obtenção da matriz de classificação



Análise de Agrupamento



Algoritmo k-Means Lloyd

```
Pred
grup 1 2
      0 13 8
      1 12 16
%correta: 59.2
```

Algoritmo k-Means Hartigan-Wong

```
Pred
grup 1 2
      0 13 8
      1 12 16
%correta: 59.2
```

Algoritmo kNN(6) K-Vizinhos mais Próximos

```
Pred
true 0 1
      0 13 8
      1 10 18
%correta: 63.3
```

```
Pred
grup 1 2
      0 21 0
      1 12 16
%correta: 75.5
```

Método de k Vizinhos mais Próximos - kNN

- É uma **Técnica de Predição** na qual para qualquer ponto Y que desejamos prever, é construída uma “vizinhança” com os k pontos mais próximos de Y , e então uma média desses pontos é tomada como estimativa.
- **kNN é um dos algoritmos**, dentre muitos, utilizado para prever Y .
- De maneira geral, problemas de Predição podem ser divididos em Y como variável contínua ou categórica, sendo que, independentemente da classificação de Y , a função de predição é baseada na **Esperança Condicional de Y dado Preditores X** :

$$Y \text{ categórico (binário): } f(x) = P(Y = 1 | X = x) = E(Y | X = x)$$

$$Y \text{ contínuo: } f_{Y|X}(x) = E(Y | X = x)$$

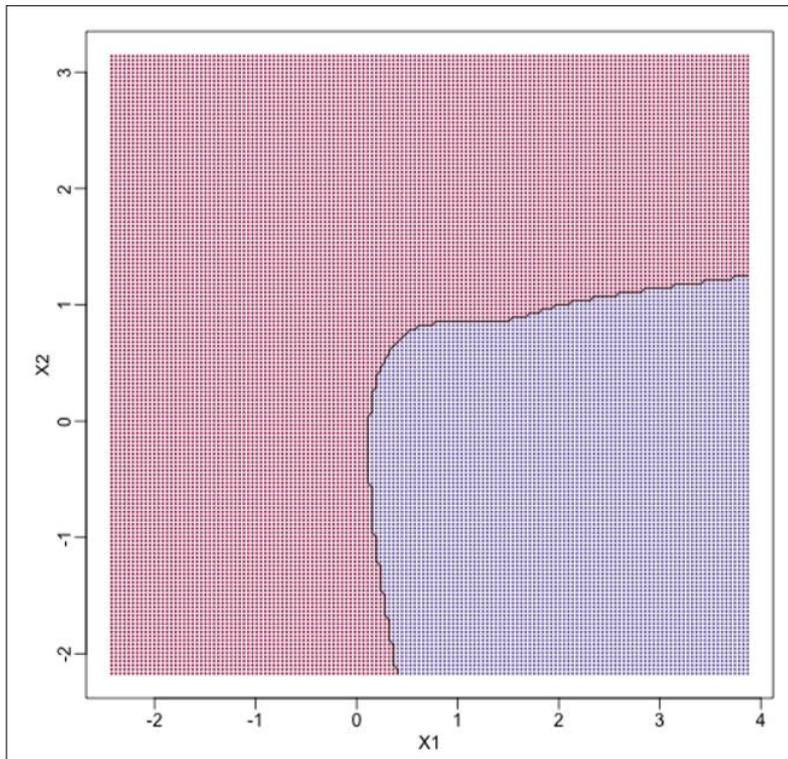
- Em geral, o valor esperado da função de predição é obtido por minimizar a distância esperada entre o preditor e Y :

$$res = E\left(\left(\hat{Y} - Y\right)^2 | X = x\right)$$

Método de k Vizinhos mais Próximos - kNN

- Problemas de Predição têm sido abordados sob a denominação de “*Machine Learning*”. Algoritmos baseados no ajuste de modelos de regressão bem como no método kNN são bastante utilizados nessa área para finalidade de predição.

$$f(x_1, x_2) = E(Y | X_1 = x_1, X_2 = x_2)$$



Exemplo de função de predição simulada (Irizarry e Love, 2015, tal que:

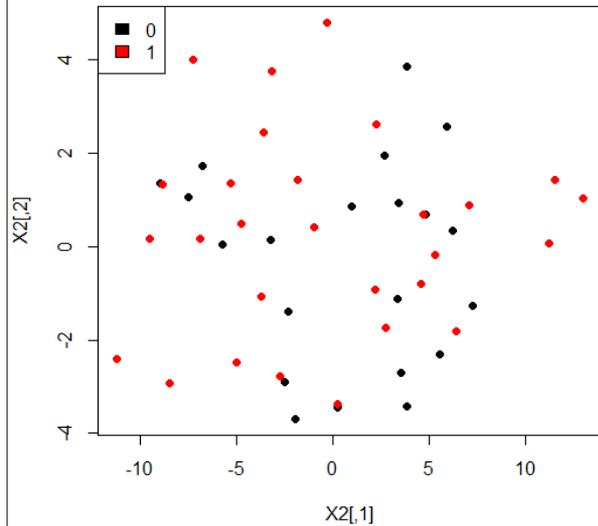
$$E(Y | x_1, x_2) \geq 0.5 \rightarrow \text{Grupo 1 (vermelho)}$$

$$E(Y | x_1, x_2) < 0.5 \rightarrow \text{Grupo 2 (azul)}$$

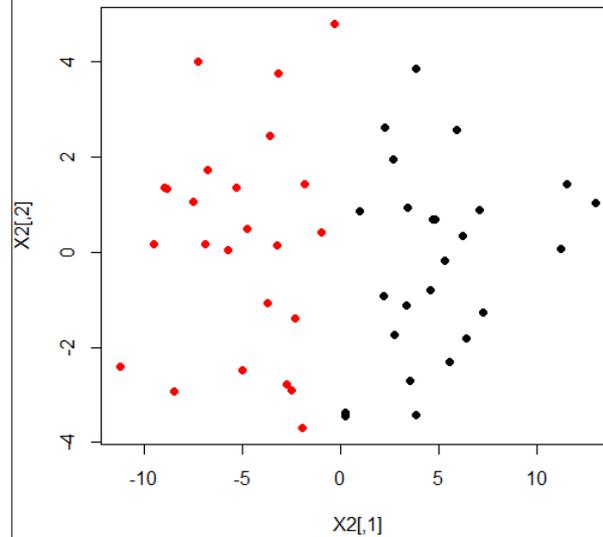
O **algoritmo kNN** encontra a função de predição em um problema de predição por meio do ajuste de curvas suavizadas (do tipo Loess).

Método de k Vizinhos mais Próximos - kNN

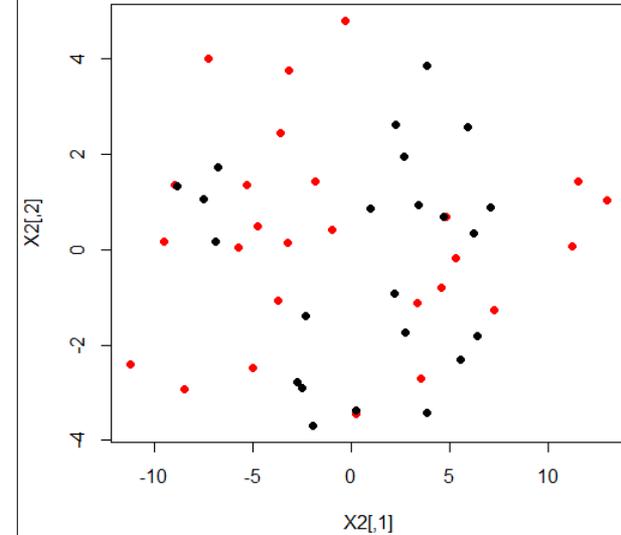
Escalonamento Multidimensional



K-Means-Lloyd



nKK(6)



kNN com k=6

**Algoritmo k-Means
Lloyd**

```
          Pred
grup  1  2
  0  13  8
  1  12 16
%correta: 59.2
```

**Algoritmo kNN(6)
K-Vizinhos mais
Próximos**

```
          Pred
true  0  1
     0 13  8
     1 10 18
%correta: 63.3
```

Método de k Vizinhos mais Próximos - kNN

Dados dos Pardais

$n=21+28=49$

Amostra Treinamento e Teste do algoritmo iguais

kNN (1)

```
      Pred
true  0  1
      0 21  0
      1  0 28
```

%correta: 1.0

kNN (6)

```
      Pred
true  0  1
      0 12  9
      1  9 19
```

%correta: 55.1

kNN (49)

```
      Pred
true  0  1
      0  0 21
      1  0 28
```

%correta: 57.1

Validação Cruzada

$n=21+28=49$

k=10 Folds (balanceados)

```
Fold 01 02 03 04 05 06 07 08 09 10
      5  5  5  5  5  4  5  5  5  5
```

kNN (6)

Amostra Treinamento Dados (-Fold01)

Amostra Teste Dados (Fold10)

```
      Pred
true  0  1
      0  0  2
      1  2  1
```

```
Fold
[1] "1) error rate: 0.8"
[1] "2) error rate: 0.8"
[1] "3) error rate: 0.2"
[1] "4) error rate: 0.6"
[1] "5) error rate: 0.8"
[1] "6) error rate: 0.75"
[1] "7) error rate: 0.6"
[1] "8) error rate: 0.6"
[1] "9) error rate: 0.8"
[1] "10) error rate: 0.6"
```

Método de k Vizinhos mais Próximos - kNN

kNN (1) kNN (2) ... kNN (49)

↓ k=1

Validação Cruzada

n=21+28=49

k=10 Folds (balanceados)

Fold	01	02	03	04	05	06	07	08	09	10
	5	5	5	5	5	4	5	5	5	5

k = 1, ..., 10

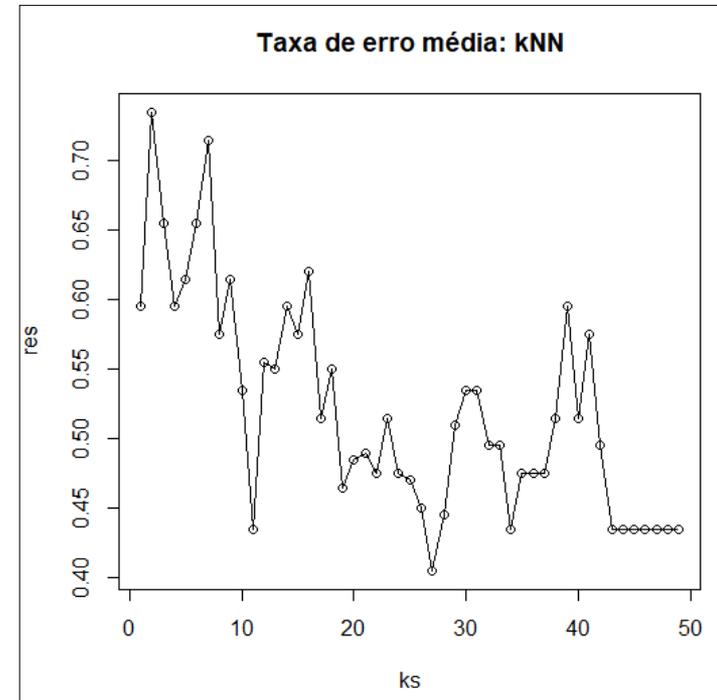
↓ k=1

Amostra Treinamento Dados (-Fold(k))
Amostra Teste Dados (Fold(k))
%Classificação errada
Média da %Classificação errada

↓ k=k+1

↓ k=k+1

Dados dos Pardais

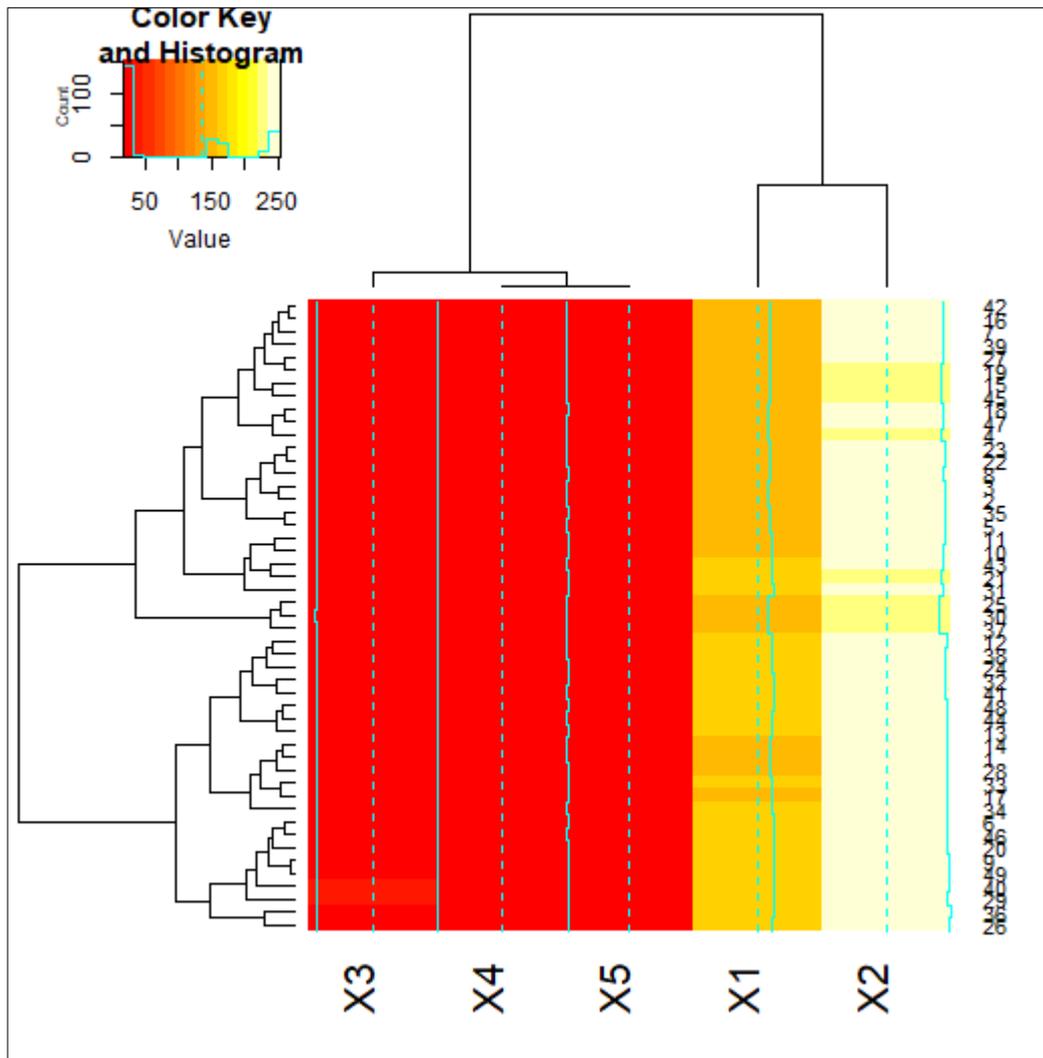


K=47

%Média Erro classificação=0.405

Análise de Agrupamento

Aplicação: Heatmap



Dados dos Pardais

Representação simultânea das unidades amostrais e das variáveis

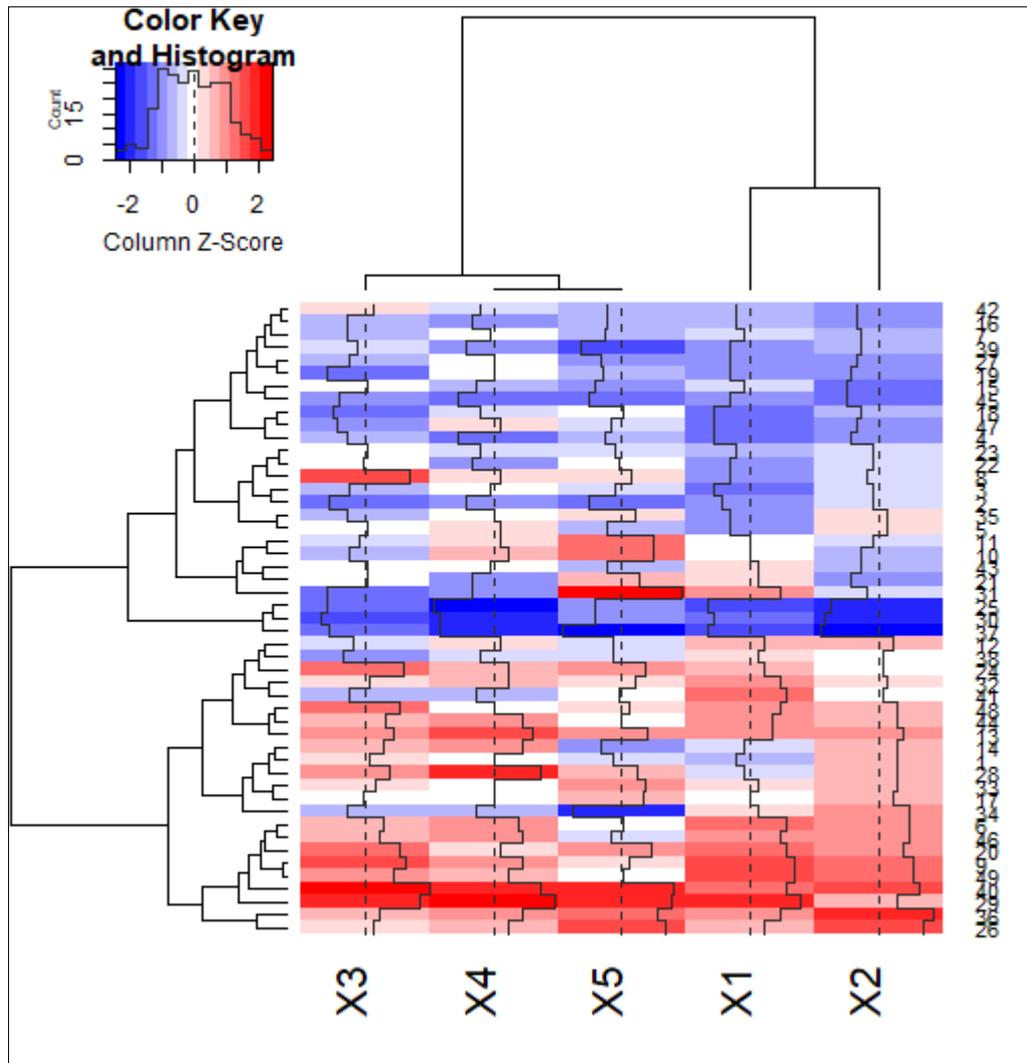
Agrupamento hierárquico (Ligação Completa) das unidades amostrais e das variáveis.

As distâncias Euclidianas definem as cores.

As variáveis X1 e X2 mais discriminam os grupos formados, os quais são homogêneos para as variáveis X3, X4 e X5.

Análise de Agrupamento

Aplicação: Heatmap



Dados dos Pardais

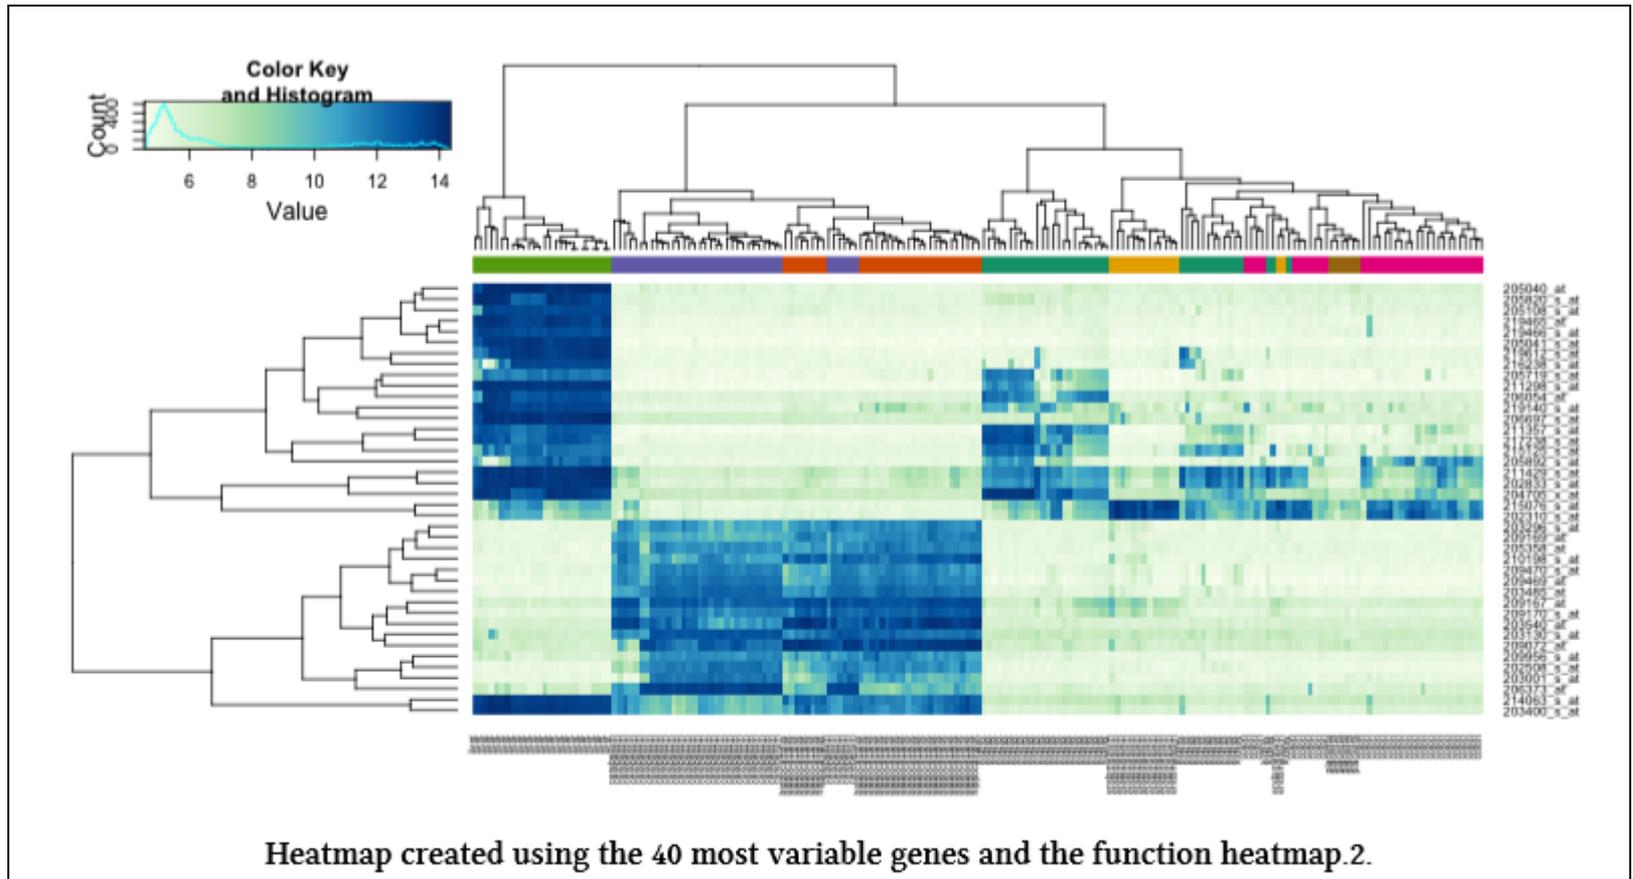
Agrupamento hierárquico (Ligação Completa) das unidades amostrais e das variáveis.

Os escores z das colunas definem as cores.

Para todas as variáveis, supondo a formação de dois grupos, o primeiro é caracterizado pelos maiores valores do escorez para todas as variáveis.

Análise de Agrupamento

Aplicação: Heatmap



Irizarry and Love (2015)

Dados de expressão gênica log-transformados (cores)

Linhas: representação de 40 genes

Colunas: representação de 189 amostras (tecidos cancerosos)