

Tema 11

Classificação

Não Supervisionada

Professora:
Ariane Machado Lima



Classificação ou aprendizado não supervisionado

- Objetivo: classificar elementos onde:
 - Não se sabe a classe dos elementos (não há uma amostra de treinamento)
 - Não se conhece sobre o processo de geração dos padrões (das classes)
 - Às vezes não se sabe nem quantas classes estão envolvidas
- Normalmente a única informação são os vetores de características dos elementos



Agrupamentos (*Clustering*)

- Realização de partições do espaço com base em um critério




O que é dado?

Os vetores de características dos elementos a serem classificados

Podem apresentar diferentes distribuições no espaço




Exemplos - como você separaria?




[COSTA & CESAR, 2009]


Exemplos




(A)




(b)




(c)




(d)




(e)




(f)



(g)




(h)




(i)

Exemplos


2 grupos
linearmente
separáveis




(A)




(b)




(c)




(d)




(e)




(f)



(g)




(h)




(i)

Exemplos




Exemplos


2 grupos
separação
não linear




Exemplos




(a)




(b)




(c)




(d)




(e)




(f)



(g)




(h)




(i)

Exemplos

2 grupos
separação
não linear




Exemplos




(a)

(b)


(c)




(d)




(e)




(f)



(g)




(h)




(i)

Exemplos


2 grupos
separação
não linear



Exemplos



Exemplos




(a)

(b)

(c)


Quantos grupos?
Distribuição
uniforme



(d)

(e)

(f)




(g)

(h)

(i)

Exemplos




(a)

(b)

(c)


(variação da figura a)



(d)

(e)

(f)




(g)

(h)

(i)


Exemplos



Ponto de ruído

(variação da figura a)
Dependendo do deslocamento de um ponto, podemos imaginar 1 ou 2 grupos


Exemplos



(a)

(b)


(c)



(d)

(e)

(f)




(g)

(h)

(i)


Exemplos



(a)

(b)

(c)




(d)

(e)

(f)

Outliers?

1, 2 ou 3 grupos?




(g)


(h)

(i)

Exemplos




Exemplos



2 grupos...
... ou 1, se usar uma
escala diferente
(logaritmica)


Exemplos



(a)

(b)


(c)



(d)

(e)

(f)




(g)

(h)

(i)

Exemplos



*2 ou 5 grupos?
clusters de
clusters*

Esteja consciente de que...

- O agrupamento é feito usando características e critérios que podem não ser adequados para a classificação verdadeira
- Qualquer critério vai impor uma estrutura sobre os dados, que pode não ser a real
- POR ISSO: qualquer informação extra que você tenha é VALIOSA (por ex: nr de classes)

Qual critério utilizar?

Considerar vários critérios, e analisar os resultados.

Em geral, os critérios seguem a ideia:

Critério de Similaridade: agrupar elementos de tal forma que

- elementos da mesma classe sejam o mais similares possível entre si
- elementos de classes distintas sejam o mais diferentes possível entre si


Cabe então definir o que é a similaridade utilizada



Critério de similaridade

Uma das formas de formalizar o critério de similaridade é através da dispersão dos dados

- Cada grupo deve conter elementos com uma dispersão mais baixa (**baixa dispersão intraclasses**)
- Elementos de grupos distintos devem apresentar maior dispersão (**alta dispersão interclasses**)



[COSTA& CESAR, 2009]

Matrizes de Dispersão (*scatter matrices*)

- Dada uma matriz dataset $N \times M$ (elementos nas linhas, características nas colunas)
- K classes
- Cada classe C_i com N_i elementos
- Cada elemento f_j é um vetor $M \times 1$
- \vec{M} é o vetor médio $M \times 1$ (valor médio de cada característica)
- $\vec{\mu}_i$ é o vetor médio $M \times 1$ da classe C_i

Exemplo

K = 3 classes:

Matriz de dados:

Object #	Class	Feature 1	Feature 2
1	C_3	9.2	33.2
2	C_2	5.3	21.4
3	C_3	8.8	31.9
4	C_1	2.9	12.7
5	C_3	9.0	32.4
6	C_1	1.5	12.0
7	C_1	1.2	11.5

$$F = \begin{bmatrix} 9.2 & 33.2 \\ 5.3 & 21.4 \\ 8.8 & 31.9 \\ 2.9 & 12.7 \\ 9.0 & 32.4 \\ 1.5 & 12.0 \\ 1.2 & 11.5 \end{bmatrix}$$

Exemplo

$$F = \begin{bmatrix} 9.2 & 33.2 \\ 5.3 & 21.4 \\ 8.8 & 31.9 \\ 2.9 & 12.7 \\ 9.0 & 32.4 \\ 1.5 & 12.0 \\ 1.2 & 11.5 \end{bmatrix}$$

$$\vec{M} = \begin{bmatrix} 5.4143 \\ 22.1571 \end{bmatrix}$$

$$\vec{f}_1 = \begin{bmatrix} 9.2 \\ 33.2 \end{bmatrix};$$

$$\vec{f}_2 = \begin{bmatrix} 5.3 \\ 21.4 \end{bmatrix};$$

$$\vec{f}_3 = \begin{bmatrix} 8.8 \\ 31.9 \end{bmatrix};$$

$$\vec{f}_4 = \begin{bmatrix} 2.9 \\ 12.7 \end{bmatrix};$$

$$\vec{f}_5 = \begin{bmatrix} 9.0 \\ 32.4 \end{bmatrix};$$

$$\vec{f}_6 = \begin{bmatrix} 1.5 \\ 12.0 \end{bmatrix};$$

$$\vec{f}_7 = \begin{bmatrix} 1.2 \\ 11.5 \end{bmatrix}$$

Exemplo

Matrizes de dados para as classes 1, 2 e 3:

$$F_1 = \begin{bmatrix} 2.9 & 12.7 \\ 1.5 & 12.0 \\ 1.2 & 11.5 \end{bmatrix}; \quad F_2 = [5.3 \quad 21.4]; \quad F_3 = \begin{bmatrix} 9.2 & 33.2 \\ 8.8 & 31.9 \\ 9.0 & 32.4 \end{bmatrix}$$

$$\vec{\mu}_1 = \begin{bmatrix} 1.8667 \\ 12.0667 \end{bmatrix};$$

$$\vec{\mu}_2 = \begin{bmatrix} 5.3 \\ 21.4 \end{bmatrix};$$

$$\vec{\mu}_3 = \begin{bmatrix} 9.0 \\ 32.5 \end{bmatrix}$$

Matrizes de dispersão

- Matriz de dispersão total:

$$S = \sum_{i=1}^N (\vec{f}_i - \vec{M})(\vec{f}_i - \vec{M})^T$$

Matrizes de dispersão

- Matriz de dispersão total:

$$S = \sum_{i=1}^N (\vec{f}_i - \vec{M})(\vec{f}_i - \vec{M})^T$$

No nosso exemplo:

$$\begin{aligned} &= \begin{bmatrix} 9.2 - 5.4143 \\ 33.20 - 22.1571 \end{bmatrix} \begin{bmatrix} 9.2 - 5.4143 & 33.20 - 22.1571 \end{bmatrix} + \dots + \\ &+ \begin{bmatrix} 1.2 - 5.4143 \\ 11.5 - 22.1571 \end{bmatrix} \begin{bmatrix} 1.2 - 5.4143 & 11.5 - 22.1571 \end{bmatrix} \\ &= \begin{bmatrix} 78.0686 & 220.0543 \\ 220.0543 & 628.5371 \end{bmatrix}. \end{aligned}$$

Matrizes de dispersão

- Matriz de dispersão total:

$$S = \sum_{i=1}^N (\vec{f}_i - \vec{M})(\vec{f}_i - \vec{M})^T$$

- Matriz de dispersão da classe C_i :

$$S_i = \sum_{i \in C_i} (\vec{f}_i - \vec{\mu}_i)(\vec{f}_i - \vec{\mu}_i)^T$$

Matrizes de dispersão

- Matriz de dispersão total:

$$S = \sum_{i=1}^N (\vec{f}_i - \vec{M})(\vec{f}_i - \vec{M})^T$$

- Matriz de dispersão da classe C_i :

$$S_i = \sum_{i \in C_i} (\vec{f}_i - \vec{\mu}_i)(\vec{f}_i - \vec{\mu}_i)^T$$

- Matriz de dispersão intraclasse:

$$S_{\text{intra}} = \sum_{i=1}^K S_i$$

Matrizes de dispersão

- Matriz de dispersão total:

$$S = \sum_{i=1}^N (\vec{f}_i - \vec{M})(\vec{f}_i - \vec{M})^T$$

- Matriz de dispersão da classe C_i :

$$S_i = \sum_{i \in C_i} (\vec{f}_i - \vec{\mu}_i)(\vec{f}_i - \vec{\mu}_i)^T$$

- Matriz de dispersão intraclasses:

$$S_{\text{intra}} = \sum_{i=1}^K S_i$$

- Matriz de dispersão interclasses:

$$S_{\text{inter}} = \sum_{i=1}^K N_i (\vec{\mu}_i - \vec{M})(\vec{\mu}_i - \vec{M})^T$$

Matrizes de dispersão

- $S = S_{\text{intra}} + S_{\text{inter}}$

Matrizes de dispersão

- $S = S_{intra} + S_{inter}$

As matrizes são simétricas e a posição ii mostra o quadrado da dispersão de f_i

- Trace(S): soma da diagonal principal de S
 $\text{trace}(S) = \text{trace}(S_{intra}) + \text{trace}(S_{inter})$

Consequência:



Matrizes de dispersão

- $S = S_{intra} + S_{inter}$

As matrizes são simétricas e a posição ii mostra o quadrado da dispersão de f_i

- Trace(S): soma da diagonal principal de S
 $\text{trace}(S) = \text{trace}(S_{intra}) + \text{trace}(S_{inter})$

Consequência: pode-se atentar a apenas diminuir S_{intra} ou aumentar S_{inter}

Técnicas de agrupamentos

- Particional (ou não hierárquico)
 - Grupos obtidos a partir de uma partição do espaço de características com respeito a um número fixo de grupos
- Hierárquico
 - Agrupamento progressivo de elementos (formação de subclasses)

Agrupamento Particional

- Um algoritmo possível baseado nas dispersões (para um dado número fixo de classes):

Ideia: um bom agrupamento deveria exibir

- Baixa dispersão intraclasse
- Alta dispersão interclasse



Agrupamento Particional

- Um algoritmo possível baseado nas dispersões (para um dado número fixo de classes):

Associe aleatoriamente uma classe a cada objeto

Enquanto não satisfizer o critério de parada

 Selecione aleatoriamente um objeto

 Mude a classe desse objeto (aleatoriamente, mas sem deixar classes vazias)

 Se $\text{trace}(S_{\text{intra}}^{\text{nova}}) > \text{trace}(S_{\text{intra}}^{\text{anterior}})$

 Volte o objeto à sua classe anterior



Agrupamento Particional Simples


- Critério de parada:
 - quando os grupos estabilizarem, por exemplo, quando o número de interações sem alteração de classificação for acima de um limiar



Agrupamento Particional Simples

- Critério de parada:
 - quando os grupos estabilizarem, por exemplo, quando o número de interações sem alteração de classificação for acima de um limiar
- Note a importância do número de grupos ser fixo! Caso contrário haveria uma tendência a aumentar o número de grupos (grupos menores tendem a ter menores dispersões intraclasse)

Agrupamento Particional Simplex - Ex: (apenas situações intermediárias de decréscimo de S_{intra})



[COSTA & CESAR, 2009]

Agrupamento Particional Simples

- Rápida convergência mas...
- Sofre do problema de mínimos locais




Agrupamento Particional

K-Médias

- Número de classes pré-definido (K)
- Distância entre pontos (objetos)
 - Matriz de Distâncias ao invés de Matriz de Dispersão
- K pontos iniciais para representar cada classe (sementes)
 - Não necessariamente pontos de objetos
 - Oportunidade para conhecer algum conhecimento a priori (senão, seleção aleatória)

Agrupamento Particional K-Médias

- Centróide: centro de massa



- Cada centróide define uma área de influência
 - Pontos mais próximos dele do que de qualquer outro centróide

Agrupamento Particional

K-Médias

Escolha os K pontos protótipos iniciais (sementes) e guarde-os na lista W

Enquanto não satisfizer o critério de parada

Calcule todas as distâncias entre cada objeto e os pontos protótipos P_i (matriz D $K \times N$)

Use a matriz D para identificar os objetos mais próximos de cada protótipo P_i

Guarde-los na lista L_i

Obtenha como novos protótipos os centróides dos objetos de L_i

Agrupamento Particional

K-Médias

- Critério de parada:
 - Ex: Deslocamento de cada centróide é menor que um limiar

Agrupamento Particional

K-Médias

- Critério de parada:
 - Ex: Deslocamento de cada centróide é menor que um limiar
- No final, os objetos mais próximos de um centróide pertencem à sua classe

Agrupamento Particional

K-Médias

- Critério de parada:
 - Ex: Deslocamento de cada centróide é menor que um limiar
- No final, os objetos mais próximos de um centróide pertencem à sua classe
- Note que um grupo pode ficar vazio!
 - Possíveis soluções:
 - Reconhecer que há uma classe a menos
 - Escolher outra semente para aquela classe e re-rodar o algoritmo (a partir do loop enquanto)

Agrupamento Particional


K-Médias - Exemplo

Object	Feature 1	Feature 2
X_1	1	1
X_2	3	4
X_3	5	4

Protótipos iniciais:

$$P_1 = (0,0) \text{ e } P_2 = (3,3)$$

Critério de Parada: maior deslocamento de centróide $m < 0,25$




Agrupamento Particional K-Médias - Exemplo

Object	Feature 1	Feature 2
X_1	1	1
X_2	3	4
X_3	5	4

Protótipos iniciais:

$P_1 = (0,0)$ e $P_2 = (3,3)$

$$D = \begin{bmatrix} \sqrt{2} & 5 & \sqrt{41} \\ 2\sqrt{2} & 1 & \sqrt{5} \end{bmatrix}$$



protótipos

Agrupamento Particional

K-Médias - Exemplo


Object	Feature 1	Feature 2
X_1	1	1
X_2	3	4
X_3	5	4

Protótipos iniciais:

$P_1 = (0,0)$ e $P_2 = (3,3)$

$$D = \begin{bmatrix} \sqrt{2} & 5 & \sqrt{41} \\ 2\sqrt{2} & 1 & \sqrt{5} \end{bmatrix}$$


$L_1 = (X_1)$ and $L_2 = (X_2, X_3)$



Agrupamento Particional

K-Médias - Exemplo

Object	Feature 1	Feature 2
X_1	1	1
X_2	3	4
X_3	5	4



Protótipos iniciais:

$$P_1 = (0,0) \text{ e } P_2 = (3,3)$$

$$D = \begin{bmatrix} \sqrt{2} & 5 & \sqrt{41} \\ 2\sqrt{2} & 1 & \sqrt{5} \end{bmatrix}$$

$$L_1 = (X_1) \text{ and } L_2 = (X_2, X_3)$$

Protótipos novos:

$$P'_1 = \text{média } \{X_1\} = (1,1) \text{ e}$$

$$P'_2 = \text{média } \{X_2, X_3\} = (4,4)$$

Agrupamento Particional

K-Médias - Exemplo

Protótipos iniciais:

$$P_1 = (0,0) \text{ e } P_2 = (3,3)$$

Protótipos novos:

$$P'_1 = \text{média } \{X_1\} = (1,1) \text{ e}$$

$$P'_2 = \text{média } \{X_2, X_3\} = (4,4)$$

$$m = \max \{ \|P'_1 - P_1\|, \|P'_2 - P_2\| \}$$
$$= \max \{ \text{raiz}(2), \text{raiz}(2) \} > 0.25$$

CONTINUA!




Agrupamento Particional

K-Médias - Exemplo

Object	Feature 1	Feature 2
X_1	1	1
X_2	3	4
X_3	5	4

Protótipos:

$$P_1 = (1,1) \text{ e } P_2 = (4,4)$$




Agrupamento Particional K-Médias - Exemplo

Object	Feature 1	Feature 2
X_1	1	1
X_2	3	4
X_3	5	4

Protótipos:

$P_1 = (1,1)$ e $P_2 = (4,4)$

$$D = \begin{bmatrix} 0 & \sqrt{13} & 5 \\ \sqrt{18} & 1 & 1 \end{bmatrix}$$



Agrupamento Particional

K-Médias - Exemplo


Object	Feature 1	Feature 2
X_1	1	1
X_2	3	4
X_3	5	4

Protótipos:

$P_1 = (1,1)$ e $P_2 = (4,4)$

$$D = \begin{bmatrix} 0 & \sqrt{13} & 5 \\ \sqrt{18} & 1 & 1 \end{bmatrix}$$


$L_1 = (X_1)$ and $L_2 = (X_2, X_3)$



Agrupamento Particional

K-Médias - Exemplo

Object	Feature 1	Feature 2
X_1	1	1
X_2	3	4
X_3	5	4



Protótipos:

$$P_1 = (1,1) \text{ e } P_2 = (4,4)$$

$$D = \begin{bmatrix} 0 & \sqrt{13} & 5 \\ \sqrt{18} & 1 & 1 \end{bmatrix}$$

$$L_1 = (X_1) \text{ and } L_2 = (X_2, X_3)$$

Protótipos novos:

$$P'_1 = \text{média } \{X_1\} = (1,1) \text{ e}$$

$$P'_2 = \text{média } \{X_2, X_3\} = (4,4)$$

Agrupamento Particional

K-Médias - Exemplo

Protótipos anteriores:

$$P_1 = (1,1) \text{ e } P_2 = (4,4)$$

Protótipos novos:

$$P'_1 = \text{média } \{X_1\} = (1,1) \text{ e}$$

$$P'_2 = \text{média } \{X_2, X_3\} = (4,4)$$

$$m = \max \{ \|P'_1 - P_1\|, \|P'_2 - P_2\| \}$$
$$= \max \{ 0, 0 \} < 0.25$$

TERMINA!

Agrupamento Particional

K-Médias

- A convergência para a menor dispersão não é garantida
- Alternativas:
 - várias rodadas (com diferentes sementes) e escolher a configuração com menor matriz de dispersão intraclasse
 - Juntar grupos de centróides próximos e partir em 2 grupos com alta dispersão

Agrupamento Hierárquico

- Agrupamentos progressivos de N objetos em classes, de acordo com algum critério (similaridade ou distância)
- Objetos mais próximos são agrupados em subgrupos antes de objetos mais distantes
- No final
 - todos os objetos pertencem a um único e grande grupo
 - Você define qual partição usar (número variável de subgrupos - classes)

Agrupamento Hierárquico

- Abordagem aglomerativa: parte de elementos individuais e vai agrupando subgrupos
- Abordagem divisiva: parte do grande grupo (contendo todos os elementos) e vai dividindo em subgrupos

Agrupamento Hierárquico


- **Abordagem aglomerativa:** parte de elementos individuais e vai agrupando subgrupos
 - Vamos ver aqui
- **Abordagem divisiva:** parte do grande grupo (contendo todos os elementos) e vai dividindo em subgrupos

Agrupamento Hierárquico

- Inicialmente cada objeto é um grupo
- Em cada iteração:
 - Matriz de distâncias entre os grupos correntes
 - Une os dois grupos mais próximos


Agrupamento Hierárquico

- Inicialmente cada objeto é um grupo
- Em cada iteração:
 - Matriz de distâncias entre os grupos correntes
 - Une os dois grupos mais próximos
- Dendograma: vários possíveis números de classes



Agrupamento Hierárquico

- Inicialmente cada objeto é um grupo
- Em cada iteração:
 - Matriz de distâncias entre os grupos correntes
 - Une os dois grupos mais próximos
- Dendograma: vários possíveis números de classes




4 classes

Agrupamento Hierárquico

- Como definir distâncias entre grupos?
- Diferentes formas de se medir essa distância implicam em diferentes tipos de agrupamentos hierárquicos
 - Single linkage
 - Complete linkage
 - Group average
 - Centroid


Agrupamento Hierárquico Single Linkage

- $\text{dist}(A,B) = \min \text{dist}(a,b), a \in A, b \in B$
- Distância mínima entre qualquer ponto da classe A e qualquer ponto da classe B



Agrupamento Hierárquico Complete Linkage


- $\text{dist}(A,B) = \max \text{dist}(a,b), a \in A, b \in B$
- Distância máxima entre qualquer ponto da classe A e qualquer ponto da classe B



Agrupamento Hierárquico

Group Average

- $\text{dist}(A,B) = 1/(N_A N_B) \sum \text{dist}(a,b), a \in A, b \in B$
- Distância média de todos os pares de pontos das classes A e B




Agrupamento Hierárquico

Centróide

$$\text{dist}(A,B) = \text{dist}(C^A, C^B)$$

- Onde C^A_i é a média dos componentes i dos pontos do grupo A

Distância entre os centros de massa (centróides) da classe A (C^A) e da classe B (C^B)



Agrupamento Hierárquico

Definido pelo tipo de distância utilizada e a métrica de distância (ex: Euclidiana, chessboard, etc.)

- Distância euclidiana (\mathbf{a}, \mathbf{b}) = raiz($\sum_{i=1..n} (a_i - b_i)^2$)

- Distância chessboard (\mathbf{a}, \mathbf{b}) = $\max_i (|a_i - b_i|)$

...

Agrupamento Hierárquico

Algoritmo

Construa uma matriz de distâncias D $N \times N$
para n de 1 até $N-1$

- (a) Determine a distância mínima em D , e os grupos C_j e C_k ($j < k$) que determinam essa distância
- (b) $C_{N+n} \leftarrow C_j \cup C_k$
- (c) Atualize a matriz, agora sem a linha e coluna k , e considerando que a linha e coluna j correspondem agora ao grupo C_{N+n}

Exemplo - Single Linkage

N = 5 objetos

$$F = \begin{bmatrix} 1.2 & 2.0 \\ 3.0 & 3.7 \\ 1.5 & 2.7 \\ 2.3 & 2.0 \\ 3.1 & 3.3 \end{bmatrix}$$

$$D^{(1)} = \begin{array}{cccccc} \begin{array}{c} 0 \\ 2.4759 \\ 0.7616 \\ 1.1000 \\ 2.3022 \end{array} & \begin{array}{c} 0 \\ 1.8028 \\ 1.8385 \\ 0.4123 \end{array} & \begin{array}{c} 0 \\ 1.0630 \\ 1.7088 \end{array} & \begin{array}{c} 0 \\ 1.5264 \end{array} & \begin{array}{c} 0 \\ 0 \end{array} & \begin{array}{c} C_1 \\ C_2 \\ C_3 \\ C_4 \\ C_5 \end{array} \end{array}$$

$n = 1$, e $d_{\min} = 0.4123$ ($j = 2$ e $k = 5$)

$C_6 \leftarrow C_2 \cup C_5$

Exemplo - Single Linkage (cont.)

$$D^{(2)} = \begin{array}{c|cccc} & 0 & & & \\ \hline & 2.3022 & 0 & & \\ & 0.7616 & 1.7088 & 0 & \\ & 1.1000 & 1.5264 & 1.0630 & 0 \end{array} \begin{array}{l} C_1 \\ C_2 C_5 = C_6 \\ C_3 \\ C_4 \end{array}$$

$n = 2$, e $d_{\min} = 0.7616$ ($j = 1$ e $k = 3$)

$$C_7 \leftarrow C_1 \cup C_3$$

Exemplo - Single Linkage (cont.)

$$D^{(2)} = \begin{bmatrix} 0 & & & \\ 1.7088 & 0 & & \\ 1.0630 & 1.5264 & 0 & \\ & & & \end{bmatrix} \begin{array}{l} C_1 C_3 = C_7 \\ C_2 C_5 = C_6 \\ C_4 \end{array}$$

$n = 3$, e $d_{\min} = 1.0630$ ($j = 1$ e $k = 3$)

$$C_8 \leftarrow C_7 \cup C_4$$

Exemplo - Single Linkage (cont.)

$$D^{(2)} = \begin{bmatrix} 0 & \\ 1.5264 & 0 \end{bmatrix} \begin{array}{l} C_1 C_3 C_4 = C_8 \\ C_2 C_5 = C_6 \end{array}$$

$n = 4$, e $d_{\min} = 1.5264$ ($j = 1$ e $k = 2$)

$C_9 \leftarrow C_8 \cup C_6$

Exemplo - Single Linkage (cont.)





Figure 8.34: *The obtained dendrogram.*

Agrupamento Hierárquico Baseado em Dispersão

- Ao invés de unir os dois grupos mais próximos une os dois grupos que menos aumentam a dispersão intraclasses
- Ward's linkage

Comparação entre métodos hierárquicos

- Single Linkage:
 - Tendência de *chaining*, o que implica na união de grupo bem separados mas conectados por alguns poucos pontos
 - Não adequado para dados gaussianos (BAYNE, 1980)
 - Menos afetado por *outliers*
 - Um dos poucos que funcionam bem para dados não elipsoides
 - Desempenho pobre



Comparação entre métodos hierárquicos

- Complete linkage:
 - Procura por grupos compactos, elipsoides
 - Pobre desempenho quando há alta densidade de grupos

Comparação entre métodos hierárquicos

- Complete linkage:
 - Procura por grupos compactos, elipsoides
 - Pobre desempenho quando há alta densidade de grupos
- Group average linkage:
 - Tende a produzir resultados parecidos com o do complete linkage
 - Resultados piores na presença de *outliers*

Comparação entre métodos hierárquicos

- Centroid linkage:
 - Sugerido apenas para distância Euclidiana
 - Adequado para tratar grupos de diferentes tamanhos

Comparação entre métodos hierárquicos

- Ward's linkage (baseado em dispersão):
 - Procura grupos elipsoides e compactos
 - Melhores resultados quando os grupos são de mesmo tamanho (grupos maiores tendem a absorver grupos menores)
 - Piores resultados na presença de *outliers*
 - Considerado um dos melhores

Comparação entre métodos hierárquicos

- Conclusão:
 - Nenhum é o melhor para todos os casos
 - Solução: testar vários métodos e escolher aquele mais compatível com o esperado

Determinando a relevância e o número de grupos

- Agrupamento hierárquico permite a escolha de K grupos, $1 \leq K \leq N$
- Qual K escolher?

Determinando a relevância e o número de grupos

- Agrupamento hierárquico permite a escolha de K grupos, $1 \leq K \leq N$
- Qual K escolher?
- Nenhuma regra de ouro
- Mas há dicas para tentar ter uma idéia da relevância de certos grupos...

Determinando a relevância e o número de grupos

- Dica 1: olhar para os grupos com maior tempo de vida - intervalo de distância entre a criação de um grupo e sua união com outro grupo
- Ex: $\{1,3,4\}$ x $\{1,3\} \cup \{4\}$




Figure 8.34: *The obtained dendrogram.*

Determinando a relevância e o número de grupos

- Dica 2: olhar para o maior salto entre as distâncias mínimas entre grupos de uma dada escolha de K (se acima de um limiar)
- Ex:




Figure 8.34: The obtained dendrogram.

Number of clusters	Distance	Distance jump
4	0.4123	0.3493
3	0.7616	0.3014
2	1.0630	0.4634
1	1.5264	—

Validação

- Como avaliar os resultados?



Validação

- Como avaliar os resultados?
- Uma simples e possível alternativa é **replicação**
 - Testa com vários subconjuntos
 - Testa com vários algoritmos de agrupamentos
 - Espera-se obter uma certa concordância de grupos

Agrupamento

- É uma técnica de classificação
 - Supervisionada ou não supervisionada?



Agrupamento

- É uma técnica de classificação
 - Supervisionada ou **não supervisionada**?



Agrupamento

- É uma técnica de classificação
 - Supervisionada ou **não supervisionada**?
 - Paramétrica ou não paramétrica?



Agrupamento

- É uma técnica de classificação
 - Supervisionada ou **não supervisionada**?
 - Paramétrica ou **não paramétrica**?
 - Porém há versões que se utilizam das distribuições condicionais das classes (paramétricas)

R

- Diferentes algoritmos de agrupamentos hierárquicos (pacote stats)
 - hclust
- kmeans

Referências

- BAYNE, C. K. *et al.* Monte Carlo comparisons of selected clustering procedures. **Pattern Recognition**, v. 12, p.51-62, 1980
- COSTA, L. F.; CESAR Jr, R. B. **Shape Classification and Analysis: Theory and Practice**. CRC Press, 2009, 2 ed. (Cap. 8.3)
- JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical Pattern Recognition: A Review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22 n. 1 p. 4-37, 2000 (seção 8).