

Tema 11

Classificação

Não Supervisionada

Professora:
Ariane Machado Lima



Vídeo 1

Introdução



Classificação ou aprendizado não supervisionado

- Dois paradigmas:
 - Aprendizado supervisionado: *aprendizado por exemplos*
 - Aprendizado não supervisionado: *aprendizado por observações*
- 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*)

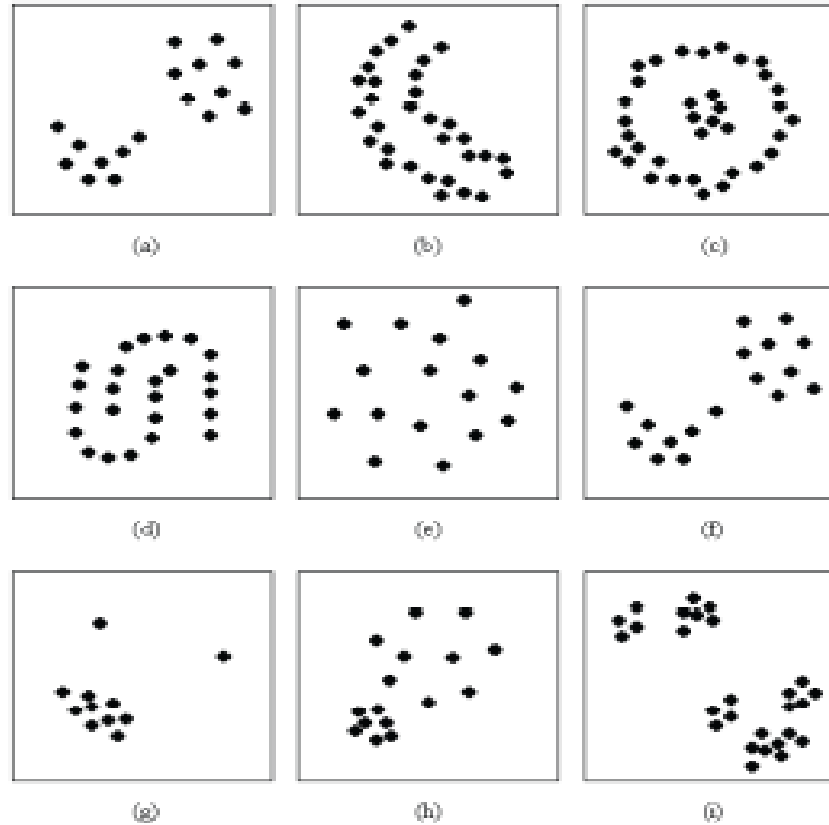
- Realização de partições do espaço com base em um critério

O que é dado?

Os vetores de características dos elementos a serem classificados

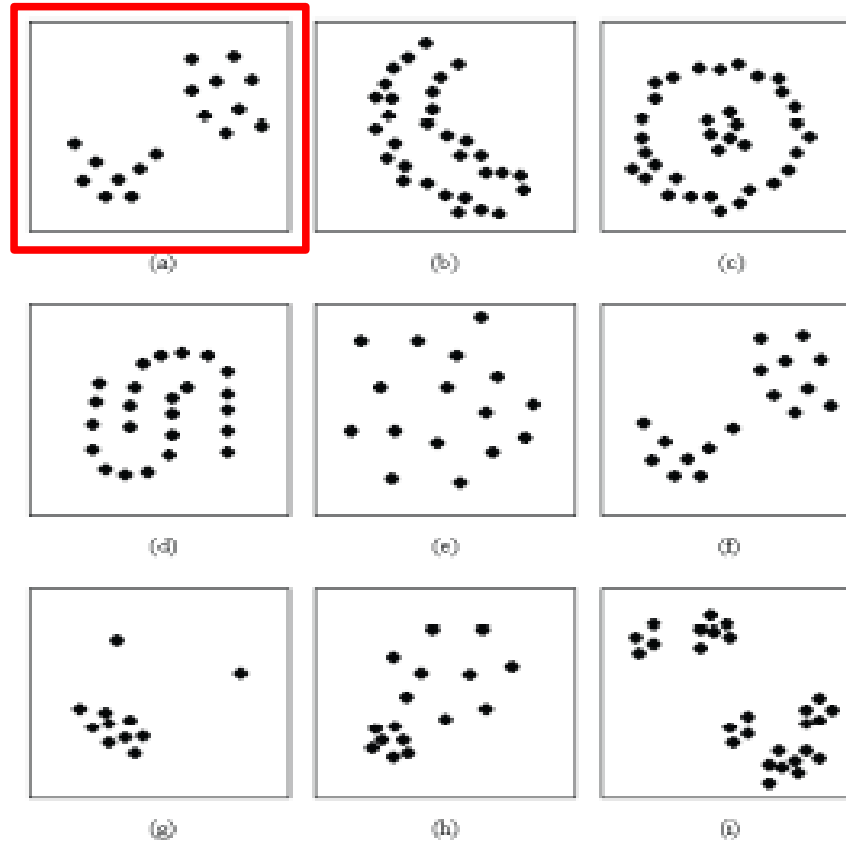
Podem apresentar diferentes distribuições no espaço

Exemplos - como você separaria?



[COSTA& CESAR, 2009]

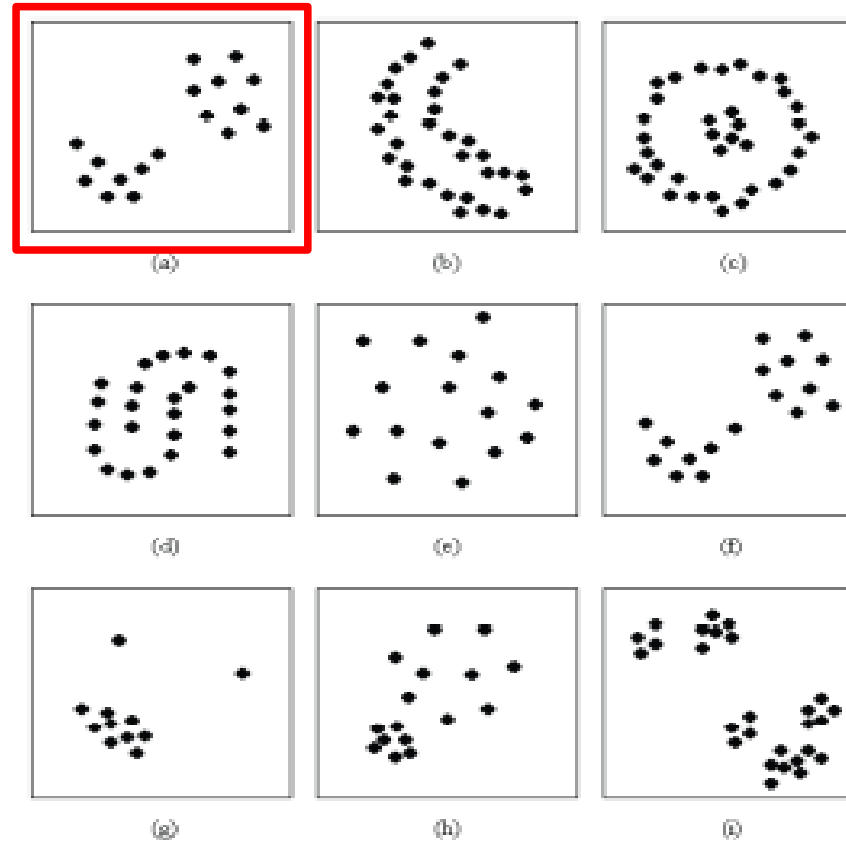
Exemplos



[COSTA& CESAR, 2009]


Exemplos

2 grupos
linearmente
separáveis



[COSTA& CESAR, 2009]

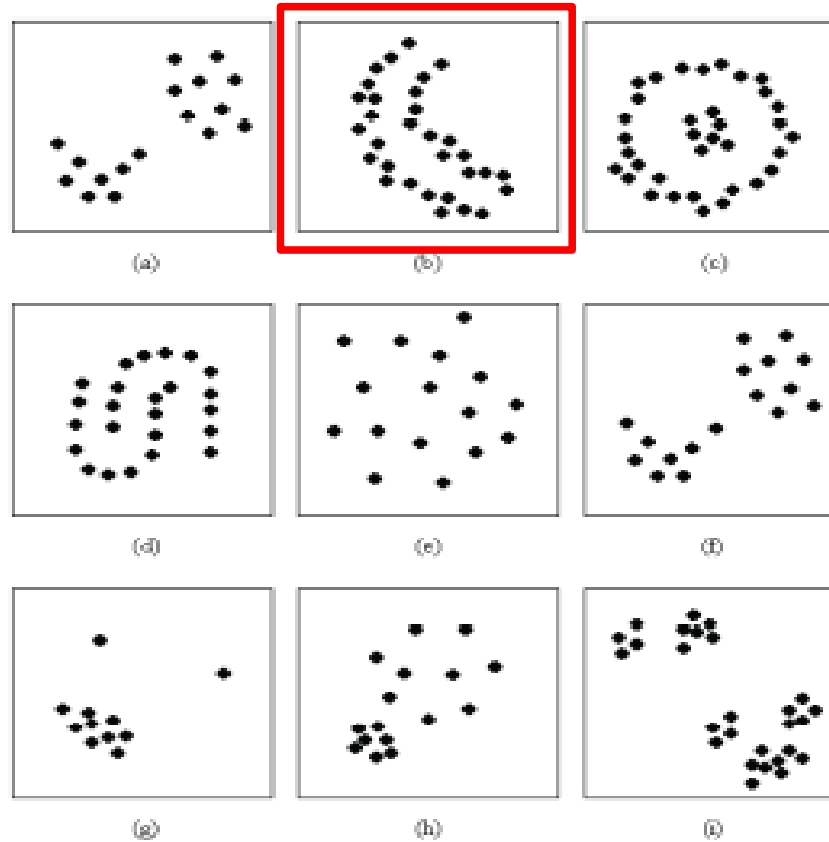
Exemplos



[COSTA& CESAR, 2009]

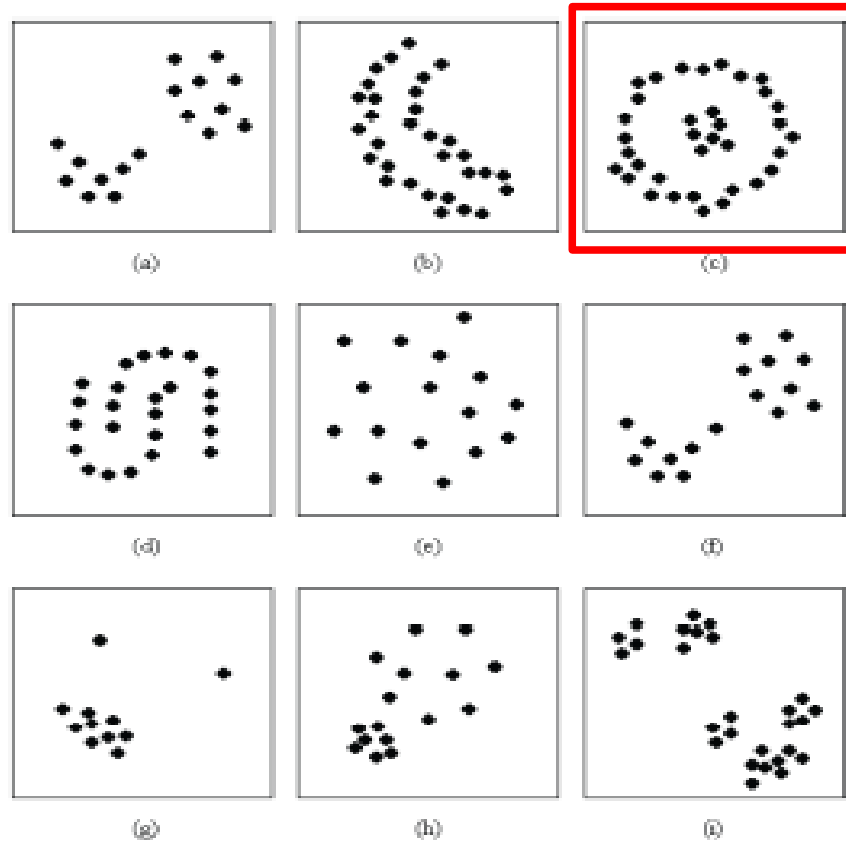
Exemplos

2 grupos
separação
não linear



[COSTA& CESAR, 2009]


Exemplos



[COSTA& CESAR, 2009]

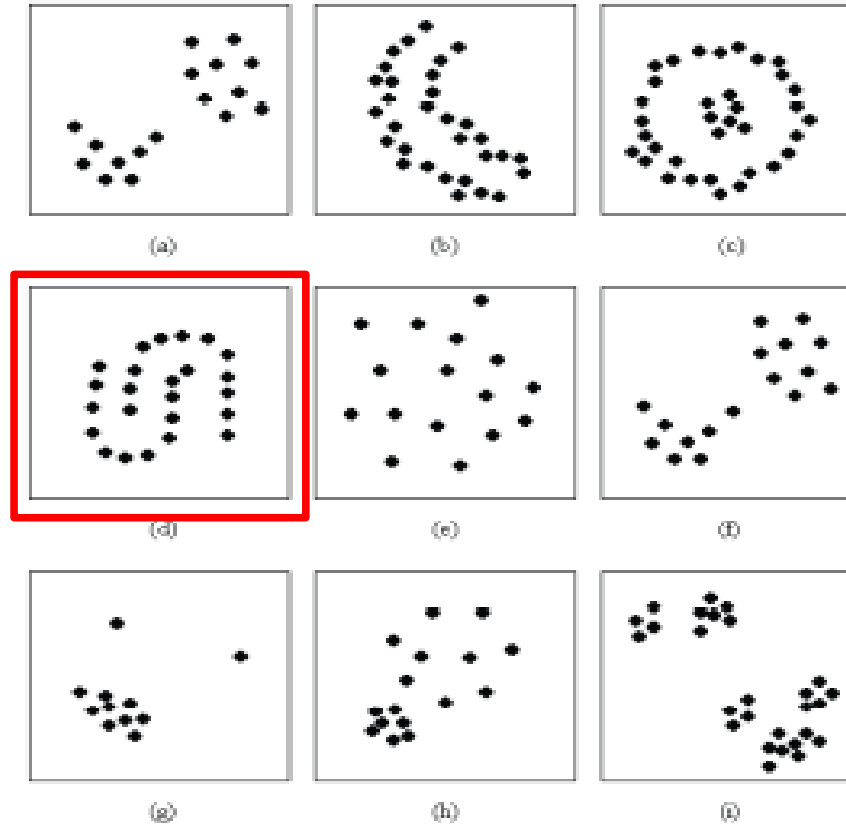
Exemplos

2 grupos
separação
não linear



[COSTA& CESAR, 2009]

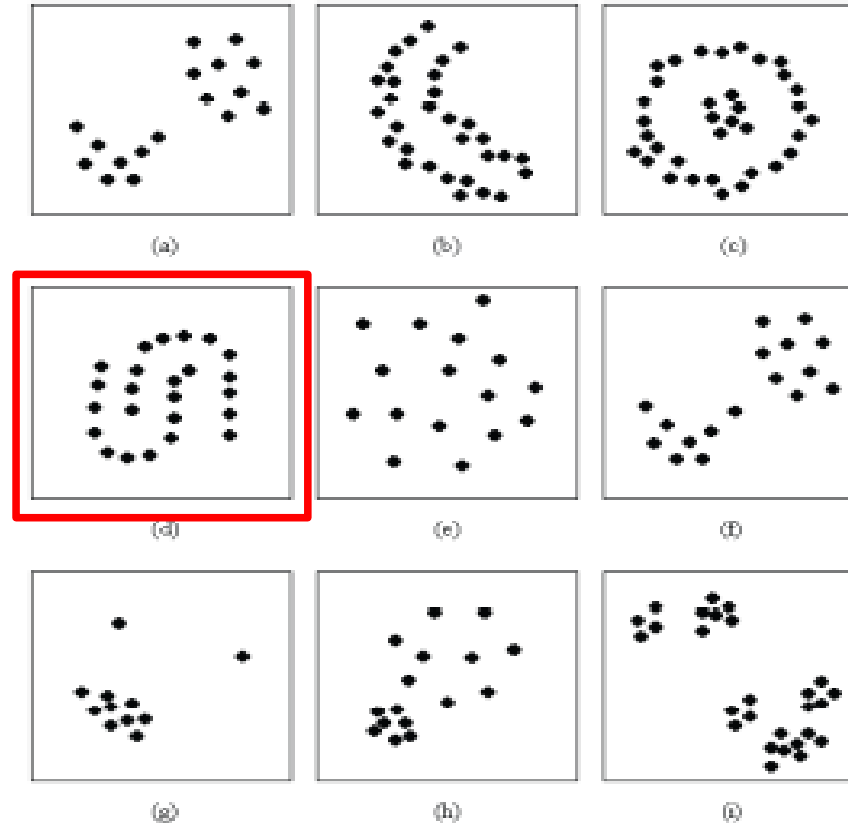
Exemplos



[COSTA& CESAR, 2009]

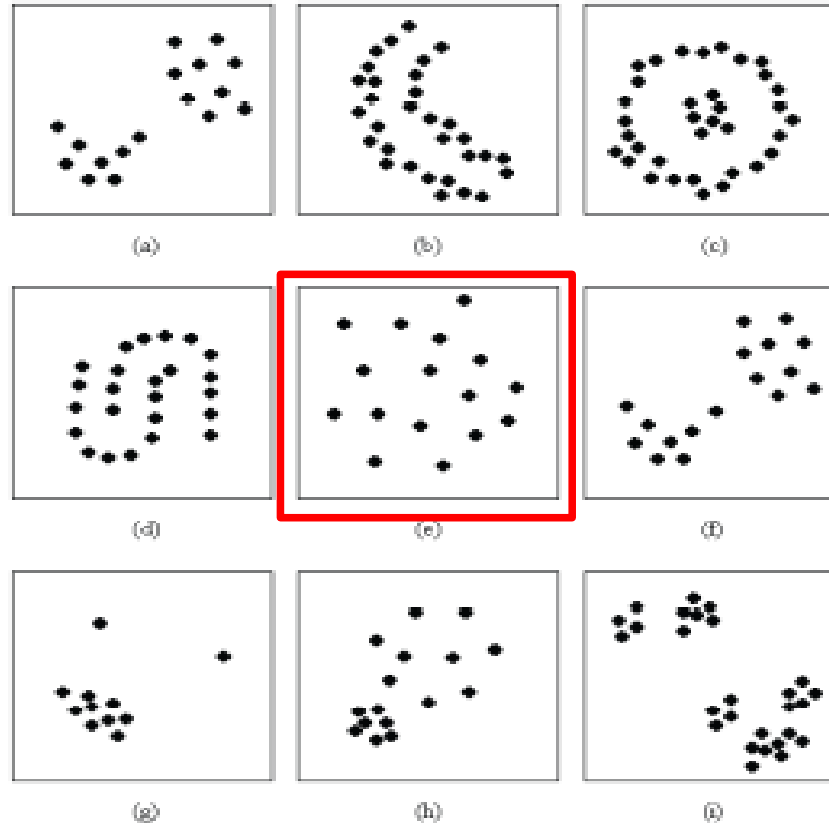
Exemplos

2 grupos
separação
não linear



[COSTA& CESAR, 2009]

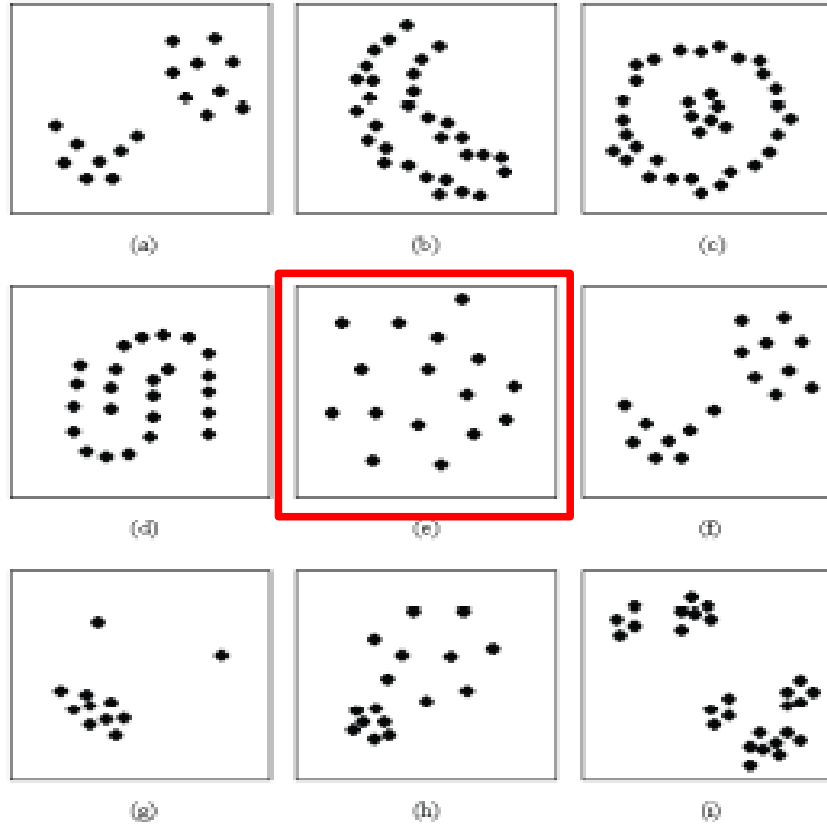
Exemplos



[COSTA& CESAR, 2009]

Exemplos

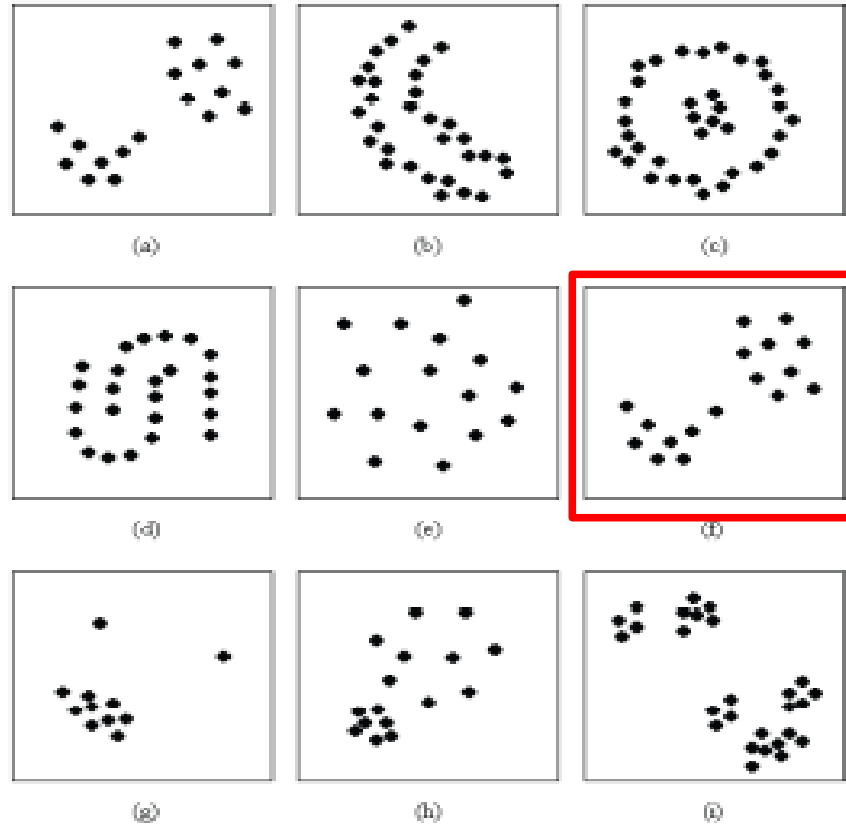
Quantos grupos?
Distribuição
uniforme



[COSTA& CESAR, 2009]

Exemplos

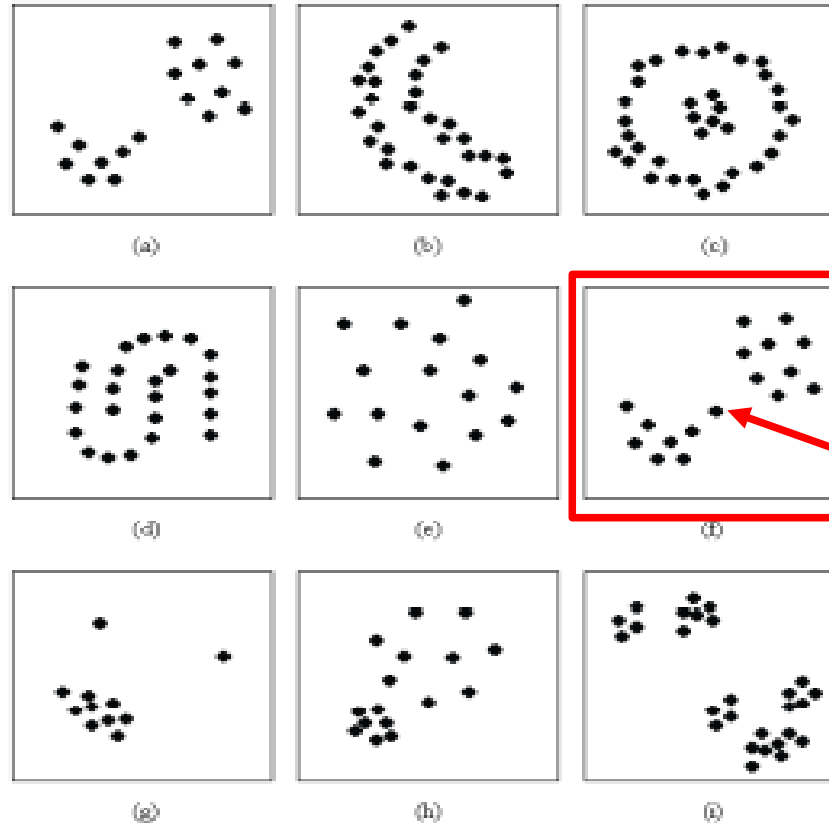
(variação da figura a)



[COSTA& CESAR, 2009]

Exemplos

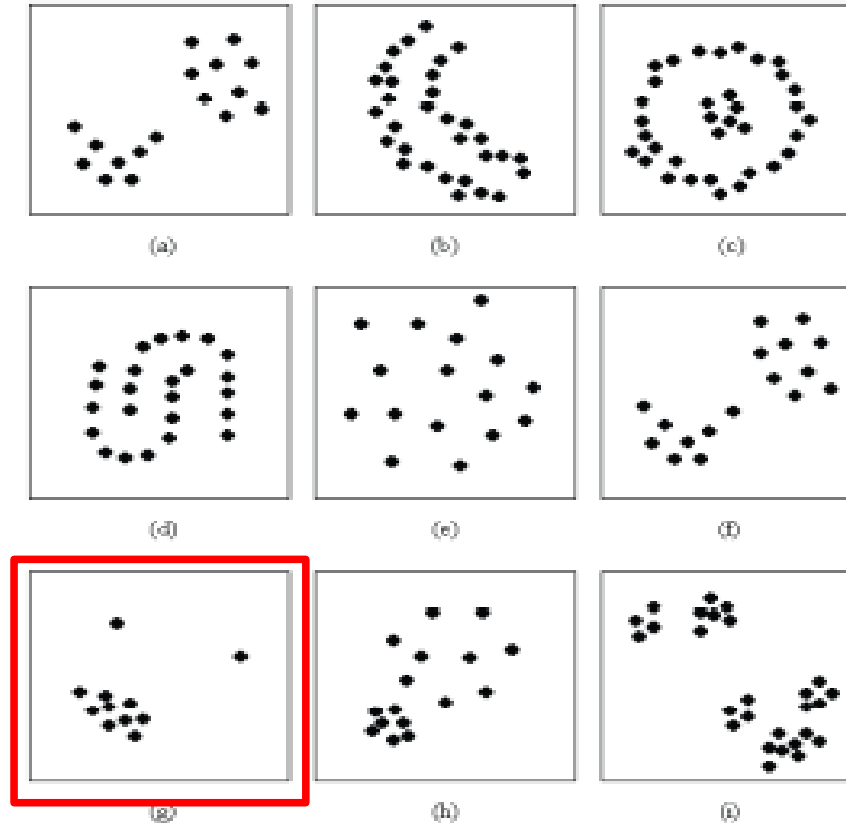
(variação da figura a)
Dependendo do deslocamento de um ponto, podemos imaginar 1 ou 2 grupos



Ponto de ruído ?


[COSTA& CESAR, 2009]

Exemplos



[COSTA& CESAR, 2009]

Exemplos



Outliers?

1, 2 ou 3 grupos?

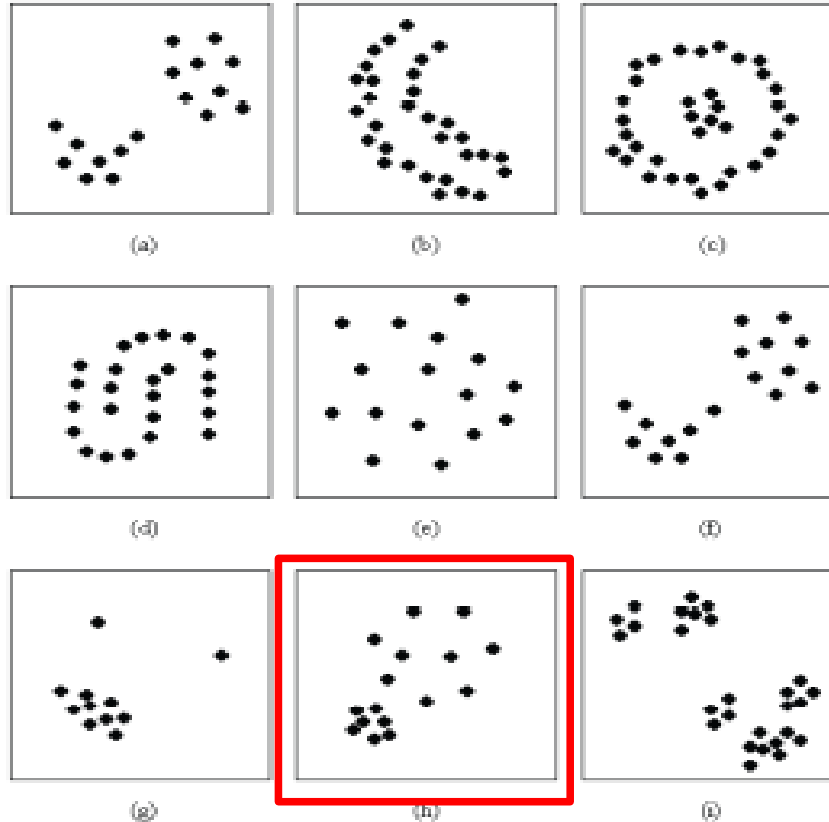
[COSTA& CESAR, 2009]

Exemplos



[COSTA& CESAR, 2009]

Exemplos



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

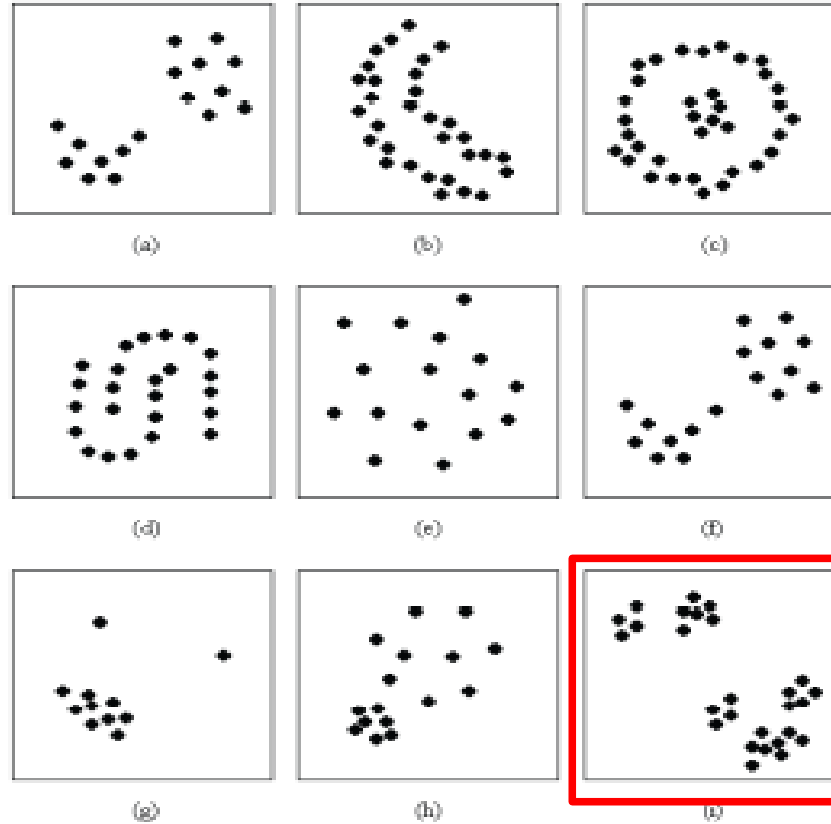
[COSTA& CESAR, 2009]

Exemplos



[COSTA& CESAR, 2009]

Exemplos



*2 ou 5 grupos?
clusters de
clusters*

[COSTA& CESAR, 2009]

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 intraclasse**)
- Elementos de grupos distintos devem apresentar maior dispersão (**alta dispersão interclasse**)




[COSTA& CESAR, 2009]

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 intraclasse**)
- Elementos de grupos distintos devem apresentar maior dispersão (**alta dispersão interclasse**)
- → Temos que nos preocupar em otimizar essas duas medidas?



[COSTA& CESAR, 2009]

Matrizes de Dispersão (*scatter matrices*)

- Suponha que conheçamos as classes...
- 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 $M \times 1$ global (valor médio de cada característica)
- $\vec{\mu}_i$ é o vetor médio $M \times 1$ da classe C_i

Exemplo

$K = 3$ classes:

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

Matriz de dados:

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

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:

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

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

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

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

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:

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

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 :

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

- Matriz de dispersão intraclasse:

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

- Matriz de dispersão interclasse:

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

Matrizes de dispersão

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

As matrizes são simétricas e a posição (i,i) mostra o quadrado da dispersão da característica i

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

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

Matrizes de dispersão

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

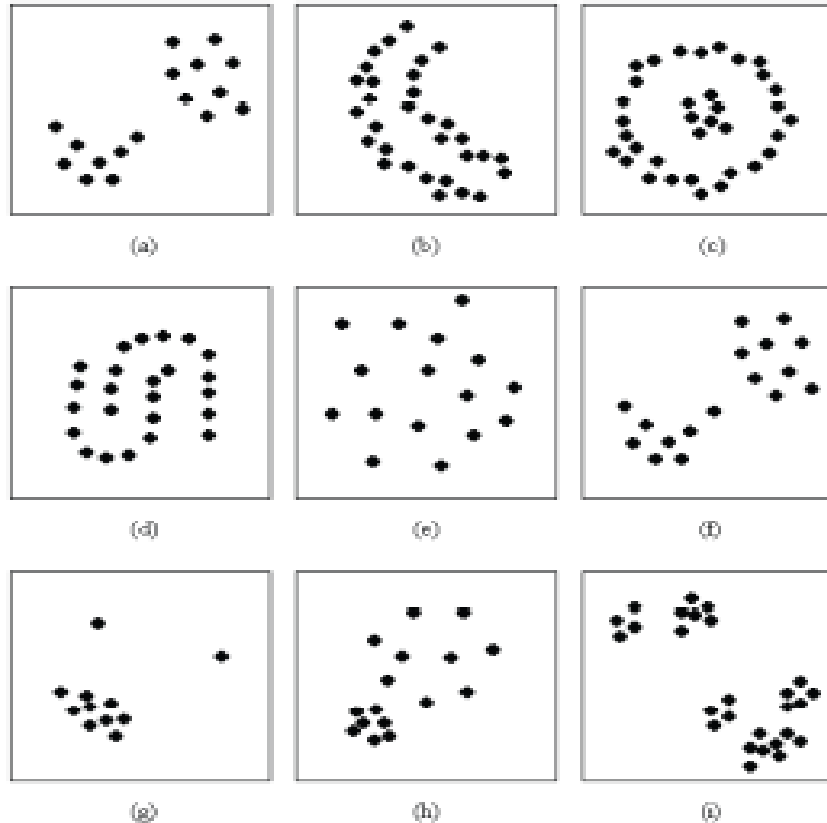
As matrizes são simétricas e a posição (i,i) mostra o quadrado da dispersão da característica i

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

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



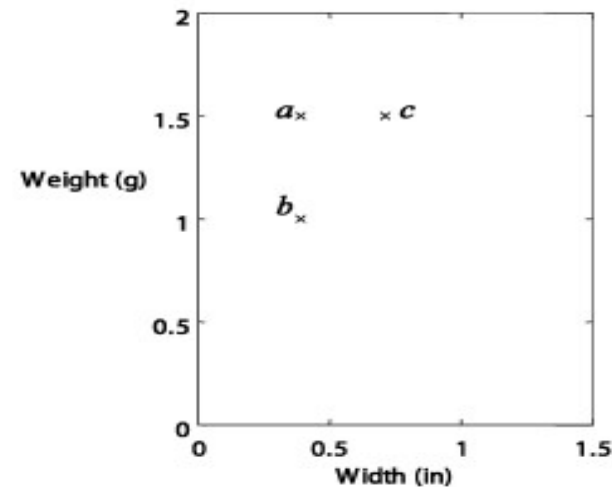

Voltando à nossa intuição... Dispersão? Distância?



[COSTA& CESAR, 2009]

Necessidade de normalização

- A maioria das características são dimensionais (possuem unidade métrica)
- 3 objetos (por exemplo, folhas)
- Unidades de medidas afetam as distâncias entre os objetos no espaço de características



Pré-processamento

- Ainda há o problema da diferença entre as escalas de valores das características
- Para diminuir esse problema, é comum a normalização por z-score:

$$z_f^i = \frac{x_f^i - \bar{x}_f}{S_f}$$

← Média

← Desvio padrão

Pré-processamento

- Ainda há o problema da diferença entre as escalas de valores das características
- Para diminuir esse problema, é comum a normalização por z-score
- Há indicações do uso de um z-score baseado no desvio absoluto médio d_f , a fim de diminuir o efeito de outliers:

$$d_f = 1/n(|x_f^1 - \bar{x}_f| + \dots + |x_f^n - \bar{x}_f|)$$

$$z_f^i = \frac{x_f^i - \bar{x}_f}{d_f}$$

Pré-processamento

- Ainda há o problema da diferença entre as escalas de valores das características
- Para diminuir esse problema, é comum a normalização por z-score
- Há indicações do uso de um z-score baseado no desvio absoluto médio d_f , a fim de diminuir o efeito de outliers
- Ainda há o problema da dimensionalidade (distâncias crescem nas dimensões, tempo de processamento, ...)
 - PCA (redução de dimensionalidade)

Fim do vídeo 1

Introdução



EACH

Vídeo 2

Agrupamento Hierárquico



Técnicas de agrupamentos

- Hierárquico: agrupamento progressivo de elementos (formação de subclasses)
- Particional: grupos obtidos a partir de uma partição do espaço de características com respeito a um número fixo de grupos
- Outros

Técnicas de agrupamentos

- Hierárquico: agrupamento progressivo de elementos (formação de subclasses)
- Particional: grupos obtidos a partir de uma partição do espaço de características com respeito a um número fixo de grupos
- Outros

Agrupamento Hierárquico

- Agrupamentos progressivos de N objetos em classes, de acordo com alguma medida de dissimilaridade (ex: 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 no final quantos grupos vai considerar (número variável de subgrupos - classes)

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 Aglomerativo

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

Agrupamento Hierárquico Aglomerativo




Dendograma

1 2 3 4 5 6

Agrupamento Hierárquico Aglomerativo

Passo 1: cada elemento é um grupo unitário



Dendograma

1 2 3 4 5 6

Agrupamento Hierárquico Aglomerativo

Passos seguintes: a cada passo juntar os dois grupos mais próximos, até que sobre apenas um




Dendograma

1 2 3 4 5 6

Agrupamento Hierárquico Aglomerativo

Passos seguintes: a cada passo juntar os dois grupos mais próximos, até que sobre apenas um


Dendograma



Agrupamento Hierárquico Aglomerativo

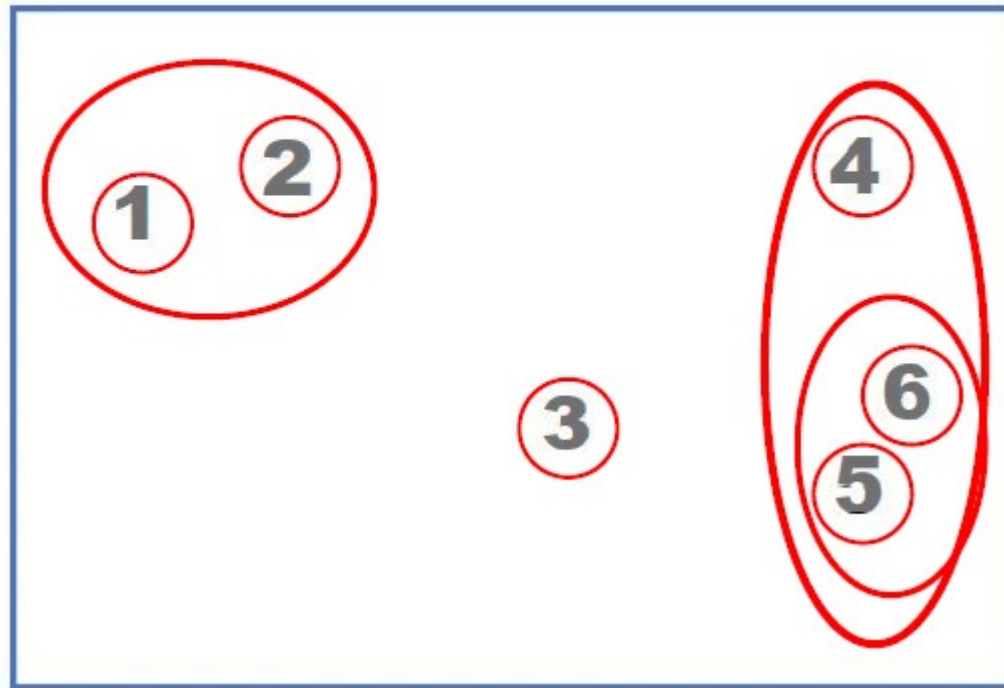
Passos seguintes: a cada passo juntar os dois grupos mais próximos, até que sobre apenas um

Dendograma



Agrupamento Hierárquico Aglomerativo

Passos seguintes: a cada passo juntar os dois grupos mais próximos, até que sobre apenas um

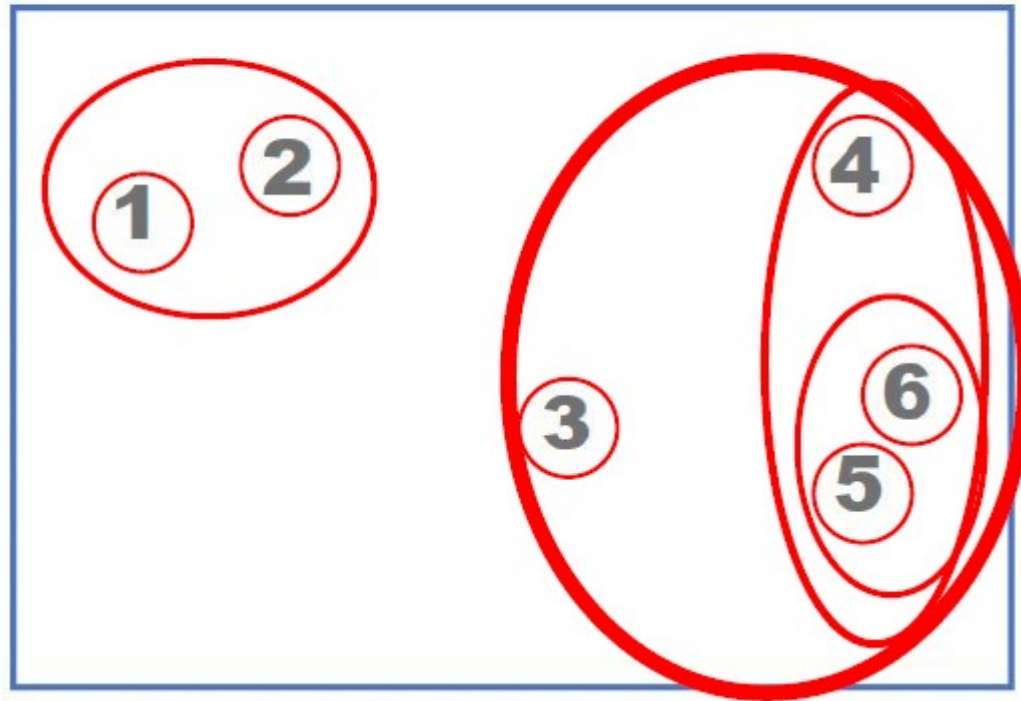


Dendograma



Agrupamento Hierárquico Aglomerativo

Passos seguintes: a cada passo juntar os dois grupos mais próximos, até que sobre apenas um




Dendograma




Agrupamento Hierárquico Aglomerativo

Passos seguintes: a cada passo juntar os dois grupos mais próximos, até que sobre apenas um




Dendograma




Agrupamento Hierárquico Aglomerativo

- 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 Aglomerativo

- 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?



EACH

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
 - Ward's linkage (NÃO usa distância “geométrica”)

Ward's linkage

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

$x_{l,j,k}$: valor para a variável p na observação j pertencente ao cluster l

SS_l : soma dos erros quadrados dentro do cluster l

$$SS_l = \sum_{k=1}^{n_l} \sum_{j=1}^p (x_{l,k,j} - \bar{x}_{l,\bullet,j})^2, \quad \bar{x}_{l,\bullet,j} = \frac{1}{n_l} \sum_{k=1}^{n_l} x_{l,k,j}$$

$SST_{l,i}$: soma total dos erros quadrados (agrupando os clusters l e i)

$$SST_{l,i} = \sum_{k=1}^{n_l} \sum_{j=1}^p (x_{l,k,j} - \bar{x}_j)^2 + \sum_{k=1}^{n_i} \sum_{j=1}^p (x_{i,k,j} - \bar{x}_j)^2,$$

$$\bar{x}_j = \frac{1}{n_l + n_i} \left(\sum_{k=1}^{n_l} x_{l,k,j} + \sum_{k=1}^{n_i} x_{i,k,j} \right)$$


$$d(C_l, C_i) = SST_{l,i} - (SS_l + SS_i)$$

$$= \frac{n_l n_i}{n_l + n_i} \sum_{j=1}^p (\bar{x}_{l,\bullet,j} - \bar{x}_{i,\bullet,j})^2$$




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



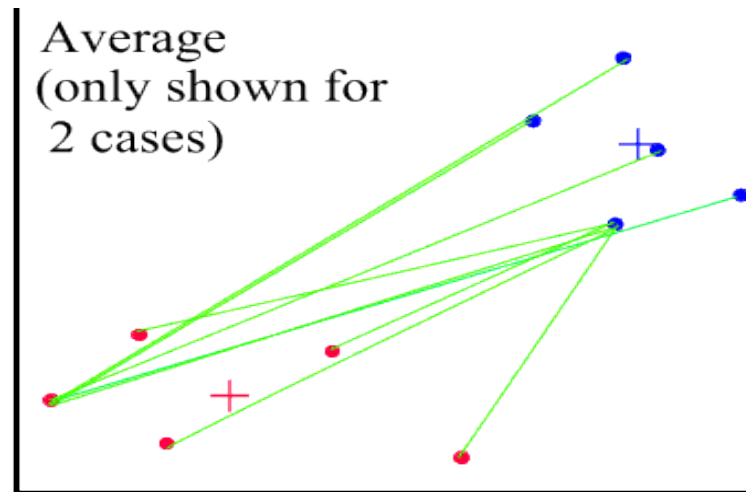
Complete Linkage

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



Average Linkage

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




Centróide

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

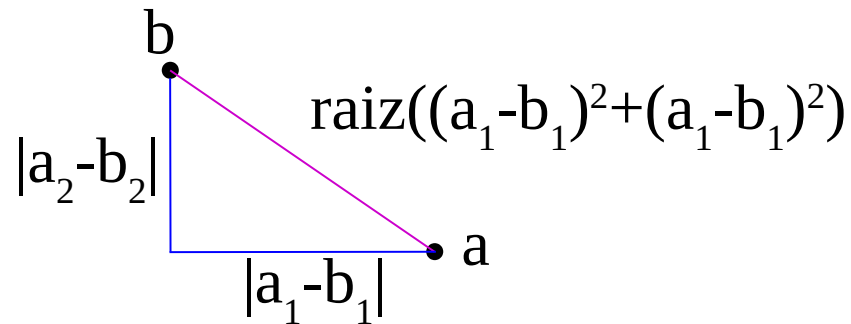
$C^A[i]$ é a média dos componentes i dos pontos do grupo A

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



Distâncias entre pontos

- E ainda é preciso definir a medida de distância entre dois pontos **(a,b)**:
 - Distância euclidiana ou norma L2 = $\text{raiz}(\sum_{i=1..n} (a_i - b_i)^2)$
 - Distância Manhattan, city block ou norma L1 = $\sum_{i=1..n} |a_i - b_i|$



Distâncias entre pontos

- E ainda é preciso definir a medida de distância entre dois pontos **(a,b)**:
 - Distância euclidiana ou norma L2 = $\text{raiz}(\sum_{i=1..n} (a_i-b_i)^2)$
 - Distância Manhattan, city block ou norma L1 = $\sum_{i=1..n} |a_i-b_i|$
 - Distância Minkovski ou norma Lp = $(\sum_{i=1..n} |a_i-b_i|^p)^{1/p}$
 - Distâncias ponderadas, ex: $(\sum_{i=1..n} w_i |a_i-b_i|^p)^{1/p}$
 - Distância chessboard = $\max_i (|a_i-b_i|)$
 - Distância Mahalanobis = $((\mathbf{a}-\mathbf{b})^T \mathbf{S}^{-1} (\mathbf{a}-\mathbf{b}))^{1/2}$
 - S : matriz de covariância do dataset
 - é uma distância “normalizada”- atenua a diferença entre as escalas
 - Quando S é diagonal, é chamada distância euclidiana normalizada: $\text{raiz}(\sum_{i=1..n} ((a_i-b_i)^2/s_i^2))$, s_i é o desvio padrão da característica i no dataset
- Lembram da ideia de executar o PCA antes?

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

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

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

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

$$C_6 \leftarrow C_2 \cup C_5$$

Exemplo - Single Linkage (cont.)

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

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

$$C_7 \leftarrow C_1 \cup C_3$$

Exemplo - Single Linkage (cont.)

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

$n = 3$, 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.)

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

$C_6 \leftarrow C_2 \cup C_5$

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

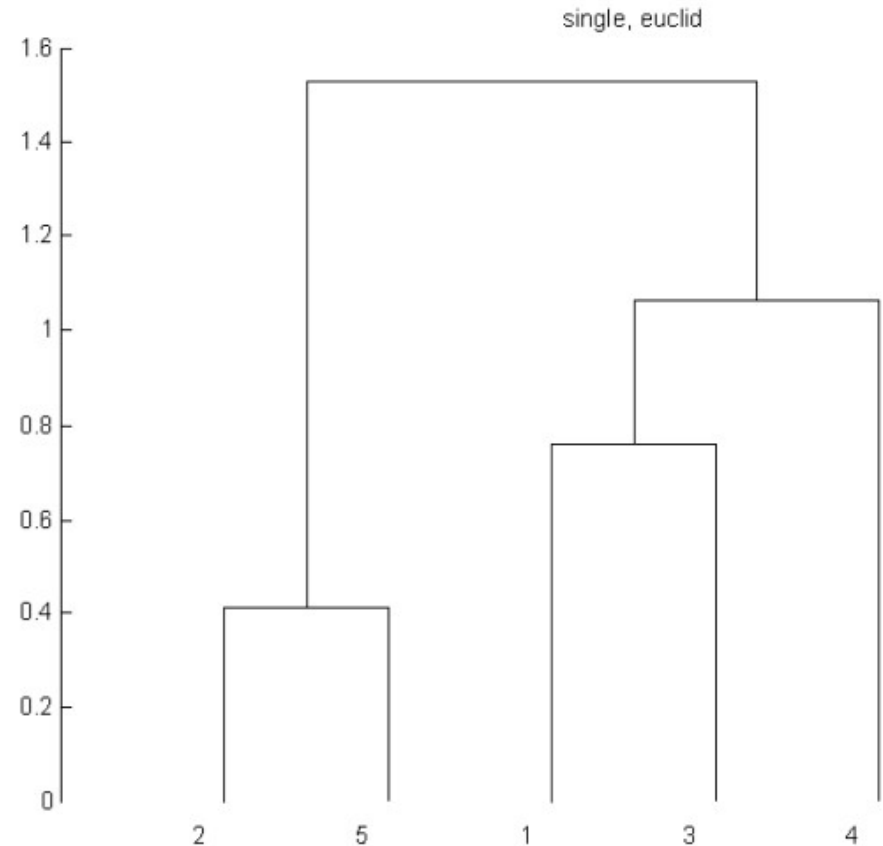
$C_7 \leftarrow C_1 \cup C_3$

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

$C_8 \leftarrow C_7 \cup C_4$



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

$C_9 \leftarrow C_8 \cup C_6$




Comparação entre métodos hierárquicos

- Single Linkage:
 - Tendência de *chaining*, o que implica na união de grupos 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 no caso geral



Comparação entre métodos hierárquicos



EACH

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

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
 - Outros comentários no final do último vídeo

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: indicação de 2 grupos





Figure 8.34: *The obtained dendrogram.*

Determinando a relevância e o número de grupos

- Dica 2: olhar para o maior salto entre as distâncias em que houve união de algum grupo (se acima de um limiar). Ex:



Number of clusters	Distance	Distance jump
4	0.4123	0.3493
3	0.7616	0.3014
2	1.0630	0.4643
1	1.5264	—

Figure 8.34: The obtained dendrogram.



Fim do vídeo 2

Agrupamento Hierárquico



EACH

Vídeo 3

Agrupamento Particional



EACH

Técnicas de agrupamentos

- Hierárquico: agrupamento progressivo de elementos (formação de subclasses)
- Particional: grupos obtidos a partir de uma partição do espaço de características com respeito a um número fixo de grupos
- Outros

Agrupamento Particional – algoritmo simples

- 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
- Função custo: $\text{trace}(S_{\text{intra}})$

Agrupamento Particional - algoritmo simples

Entrada: dataset (matriz dos dados - vetores de características)
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 – algoritmo simples

Entrada: dataset (matriz dos dados - vetores de características)

Associe aleatoriamente uma classe a cada objeto

Enquanto não satisfizer o critério de parada (ex: quando os grupos estabilizarem, por exemplo, quando o número de interações sem alteração de classificação for acima de um limiar)

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 – algoritmo simples

- 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 Simple - Ex:(apenas situações intermediárias de decréscimo de S_{intra})



[COSTA& CESAR, 2009]

Agrupamento Particional – algoritmo simples

- Equivalente a métodos baseados em erro quadrático
- Rápida convergência mas...
- Sofre do problema de mínimos locais


Agrupamento Particional

K-Médias (k-means)

- Algoritmo mais famoso dessa categoria
- Também sofre de mínimos locais
- Número de classes pré-definido (K)
- Distância entre pontos (objetos) → Matriz de Distâncias ao invés de Matriz de Dispersão como medida de dissimilaridade
- 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

Entrada: k , dataset (matriz dos dados – vetores de caract.)

Agrupamento Particional

K-Médias



1. Você define k grupos (ex: $k = 2$)

Agrupamento Particional K-Médias



1. Você define k grupos (ex: $k = 2$)
2. Escolha aleatoriamente dois pontos representantes dessa classe (sementes) quaisquer (se tiver algum palpite acerca dos grupos use-o!)

Agrupamento Particional

K-Médias

3. Classifique todos os seus dados de acordo com a semente mais próxima



Agrupamento Particional

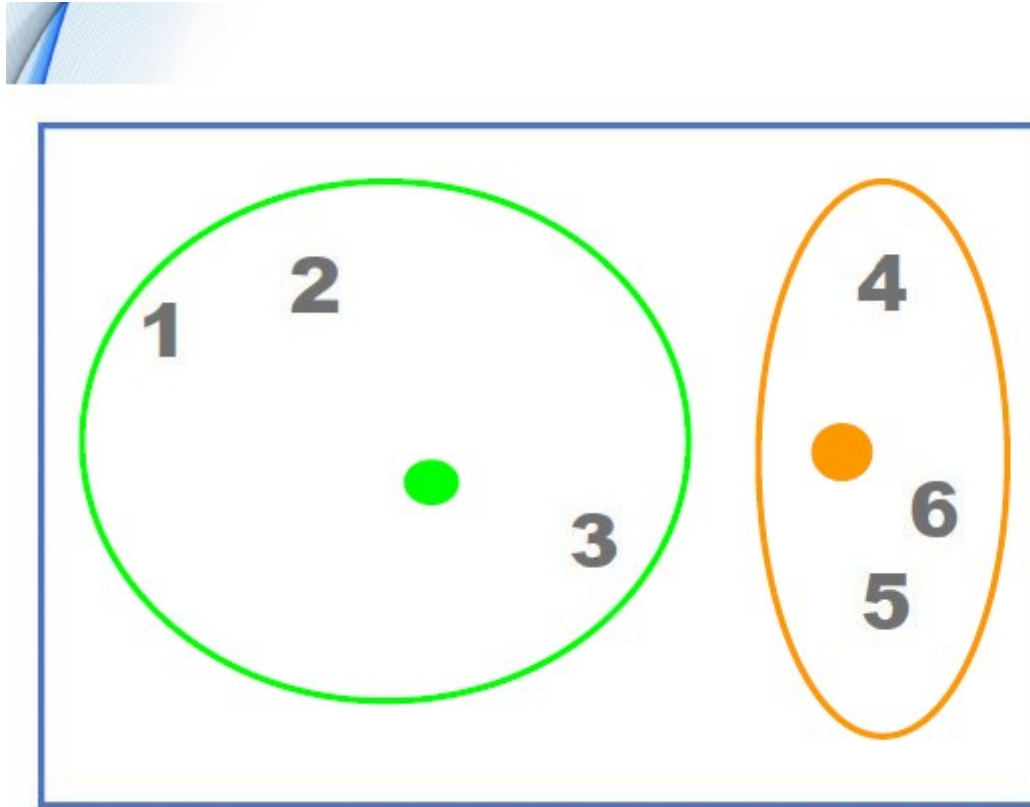
K-Médias



3. Classifique todos os seus dados de acordo com a semente mais próxima

Agrupamento Particional

K-Médias

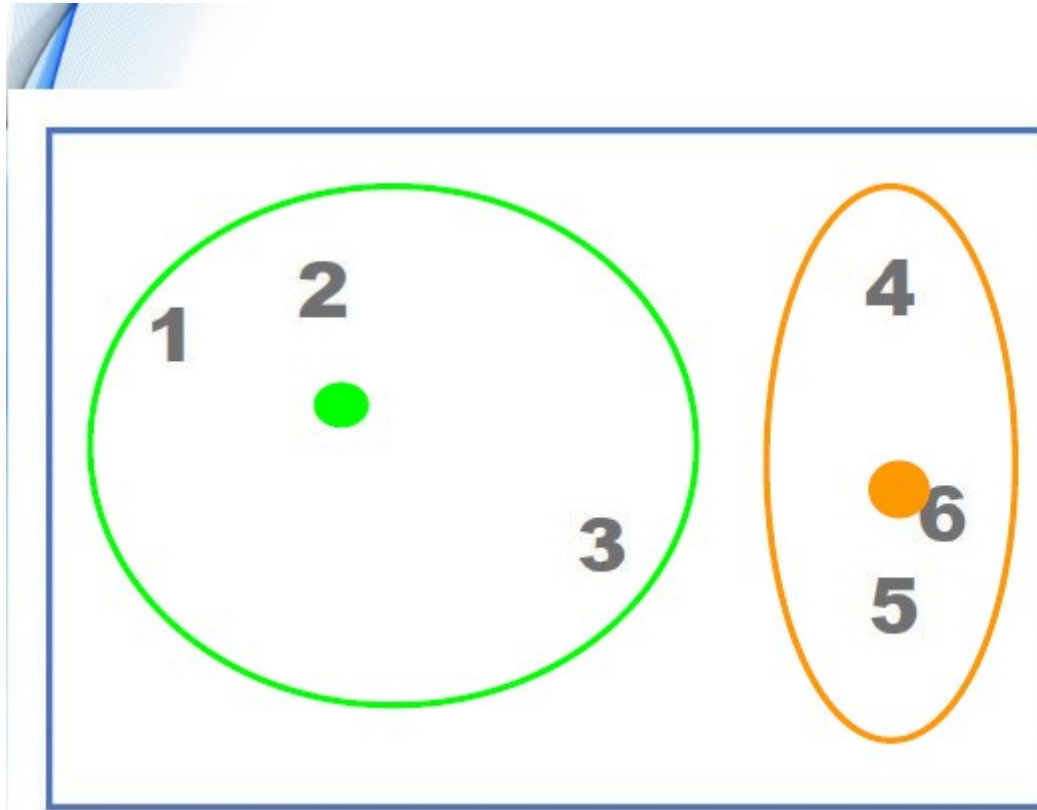


3. Classifique todos os seus dados de acordo com a semente mais próxima

4. Defina a nova semente no centro (de massa)

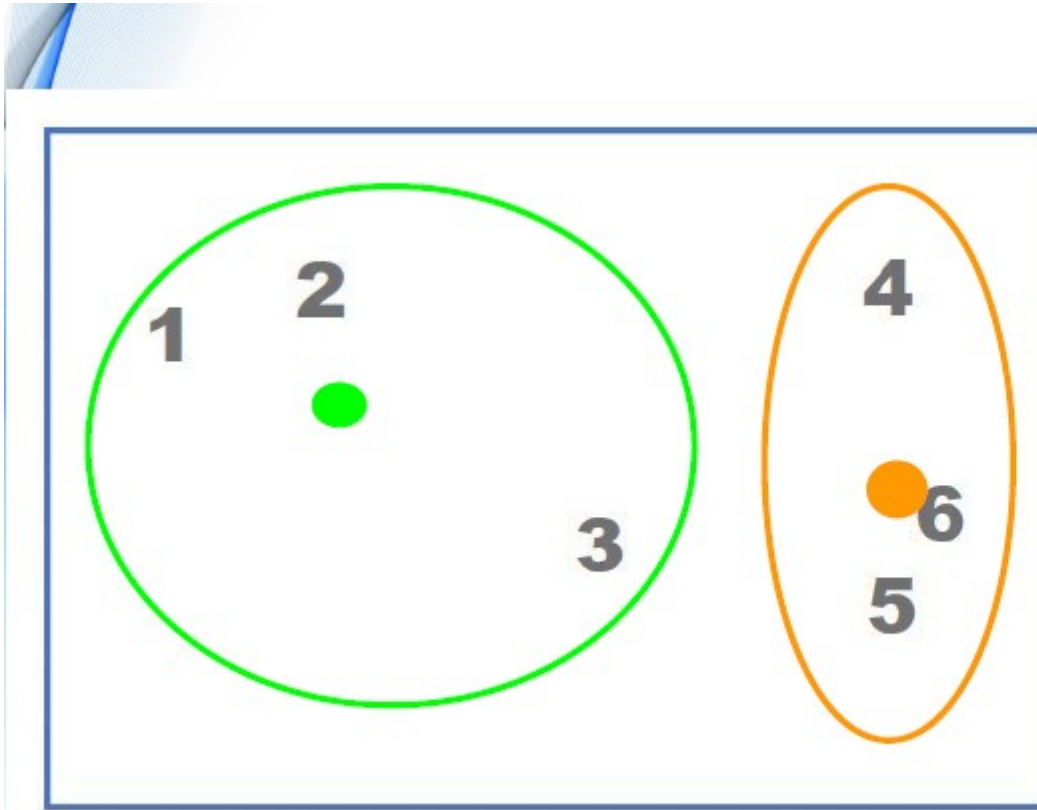
Agrupamento Particional

K-Médias



3. Classifique todos os seus dados de acordo com a semente mais próxima
4. Defina a nova semente no centro (de massa)

Agrupamento Particional K-Médias



3. Classifique todos os seus dados de acordo com a semente mais próxima

4. Defina a nova semente no centro (de massa)

5. Repita 3 e 4 até que a classificação dos pontos não mude mais

Agrupamento Particional

K-Médias




3. Classifique todos os seus dados de acordo com a semente mais próxima

4. Defina a nova semente no centro (de massa)

5. Repita 3 e 4 até que a classificação dos pontos não mude mais

Agrupamento Particional


K-Médias



3. Classifique todos os seus dados de acordo com a semente mais próxima
4. Defina a nova semente no centro (de massa)
5. Repita 3 e 4 até que a classificação dos pontos não mude mais

Agrupamento Particional

K-Médias



3. Classifique todos os seus dados de acordo com a semente mais próxima

4. Defina a nova semente no centro (de massa)

5. Repita 3 e 4 até que a classificação dos pontos não mude mais

Agrupamento Particional

K-Médias



3. Classifique todos os seus dados de acordo com a semente mais próxima
4. Defina a nova semente no centro (de massa)
5. Repita 3 e 4 até que a classificação dos pontos não mude mais

Agrupamento Particional K-Médias



3. Classifique todos os seus dados de acordo com a semente mais próxima
4. Defina a nova semente no centro (de massa)
- 5. Repita 3 e 4 até que a classificação dos pontos não mude mais**

Agrupamento Particional K-Médias



3. Classifique todos os seus dados de acordo com a semente mais próxima
4. Defina a nova semente no centro (de massa)
5. Repita 3 e 4 até que a classificação dos pontos não mude mais

Agrupamento Particional

K-Médias

- Entrada:** k , dataset D (matriz dos dados - vetores de caract.)
- 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-os na lista L_i)
 - Obtenha como novos protótipos os centróides de cada 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

- No final, os objetos mais próximos de um centróide P_i pertencem à sua classe C_i
- Distância utilizada: euclidiana
 - Isso equivale a usar uma função custo baseada em erro quadrático

$$E = \arg \min_C \sum_{i=1}^k \sum_{\mathbf{x} \in C_i} \|\mathbf{x} - P_i\|^2$$

Agrupamento Particional

K-Médias

- Note que um grupo pode ficar vazio!
 - Possíveis soluções:
 - Reconhecer que há uma classe a menos
 - Escolher outra semente para aquela classe e re-executar 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 $P_2 = (3,3)$



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:

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

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


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



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:

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


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

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



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 intraclasses
 - Juntar grupos de centróides próximos e subdividir grupos com alta dispersão intra-classe

Agrupamento Particional

K-Médias

- Sensibilidade à escolha inicial dos protótipos:



A Genetic Rule-Based Data Clustering Toolkit
I Sarafis, AMS Zalzal and P W Trinder

Agrupamento Particional

K-Médias

- Opções quanto à escolha inicial dos protótipos:
 - Totalmente aleatório
 - K pontos bem espaçados (ideia do kmeans++)
 - Com base em conhecimento a priori
 - M execuções (com protótipos diferentes): escolher o resultado com menor erro quadrático
 - Executar um agrupamento hierárquico, e escolher um protótipo para cada classe

Variações baseadas em K-Médias

- Escolha dos k protótipos iniciais
- Cálculo de dissimilaridade
- Estratégia para calcular o protótipo de cada classe

Variações baseadas em K-Médias

- Escolha dos k protótipos iniciais
 - Ex: k-means++
 - Cada objeto i tem um peso w_i (pesos inicialmente iguais)

Para $j = 1$ até k

sorteia protótipo P_j com base nos pesos w_i

para cada objeto o_i que não é protótipo

atualiza $w_i = (\min_l d(o_i, P_l))^2$ (l protótipos já definidos)

Variações baseadas em K-Médias

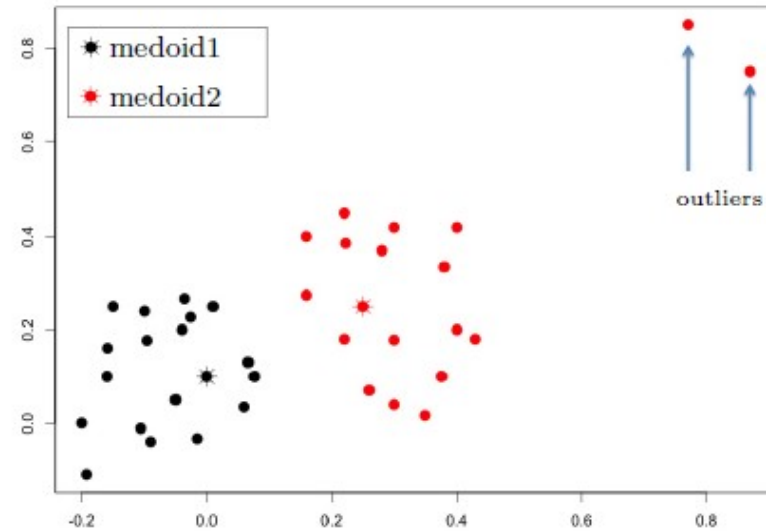

- **K-medoids** ou **PAM (partitioning around medoids)**:
 - protótipo deve ser um objeto da classe (para diminuir sensibilidade a outliers)

Variações baseadas em K-Médias

- **K-medoids** ou **PAM (partitioning around medoids)**:
 - protótipo deve ser um objeto da classe (para diminuir sensibilidade a outliers)
 - Função custo (erro absoluto):
(também diminui efeito de outliers)
$$E = \sum_{i=1}^k \sum_{\mathbf{x} \in C_i} |\mathbf{x} - P_i|$$
a cada iteração, verifica se é possível diminuir o custo total ao substituir algum protótipo por um objeto aleatório o_{random}
 - Mais robusto na presença de outliers porém custoso que o k-means
 - CLARA e variantes: para datasets grandes (subamostragem)

Variações baseadas em K-Médias

- **K-medoids** ou **PAM (partitioning around medoids)**:



Generalized k -means based clustering
for temporal data under time warp
Saeid SOHEILY-KHAH

- Mais robusto na presença de outliers porém custoso que o k -means
- CLARA e variantes: para datasets grandes (subamostragem)

Variações baseadas em K-Médias

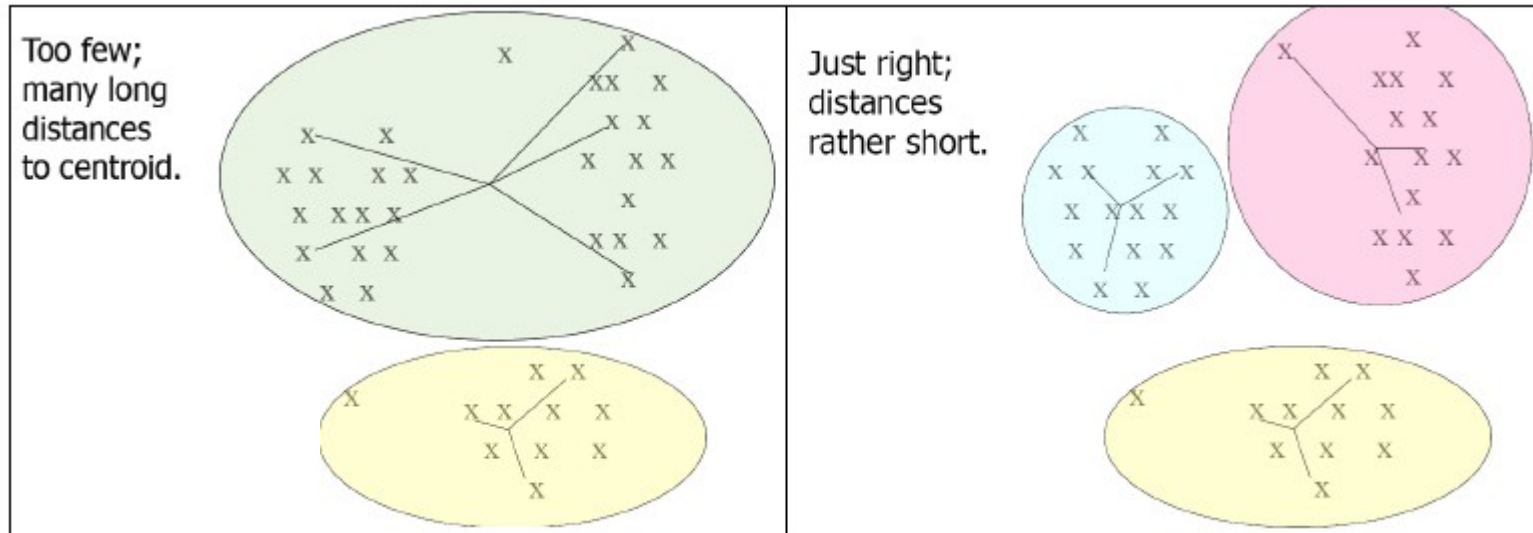

- K-mode para variáveis categóricas
- K-prototypes para datasets mistos (mistura de variáveis numéricas e categóricas)
- Fuzzy k-médias (cada objeto tem um probabilidade de pertencer a uma classe)

E se eu não sei o k?

- Pode ir direto para outros métodos (hierárquicos)
- Conseguir pistas do k:
 - Interpretação dos resultados de agrupamentos hierárquicos

E se eu não sei o k ?

- Testar diferentes valores de k e calcular a distância média dos objetos aos seus respectivos centróides




Comentários gerais

- Esses são algoritmos de realocação iterativa (um tipo de EM - Expectation-Maximization)
 - Achar a solução ótima (garantida) é NP-difícil


Comentários gerais

- Tendem a formar agrupamentos compactos (fronteiras convexas)

Conjunto convexo



Conjunto não convexo




https://en.wikipedia.org/wiki/Convex_set


Comentários gerais

- Tendem a formar agrupamentos compactos (fronteiras convexas)
 - Pode ser bom ou não, depende da distribuição dos dados


(A) Original spiral data



(B) k-means clusters





(C) Spectral clusters



k-means

single-linkage

<https://bradleyboehmke.github.io/HOML/kmeans.html>



← *single-linkage*



Fim do vídeo 3

Agrupamento Particional



EACH

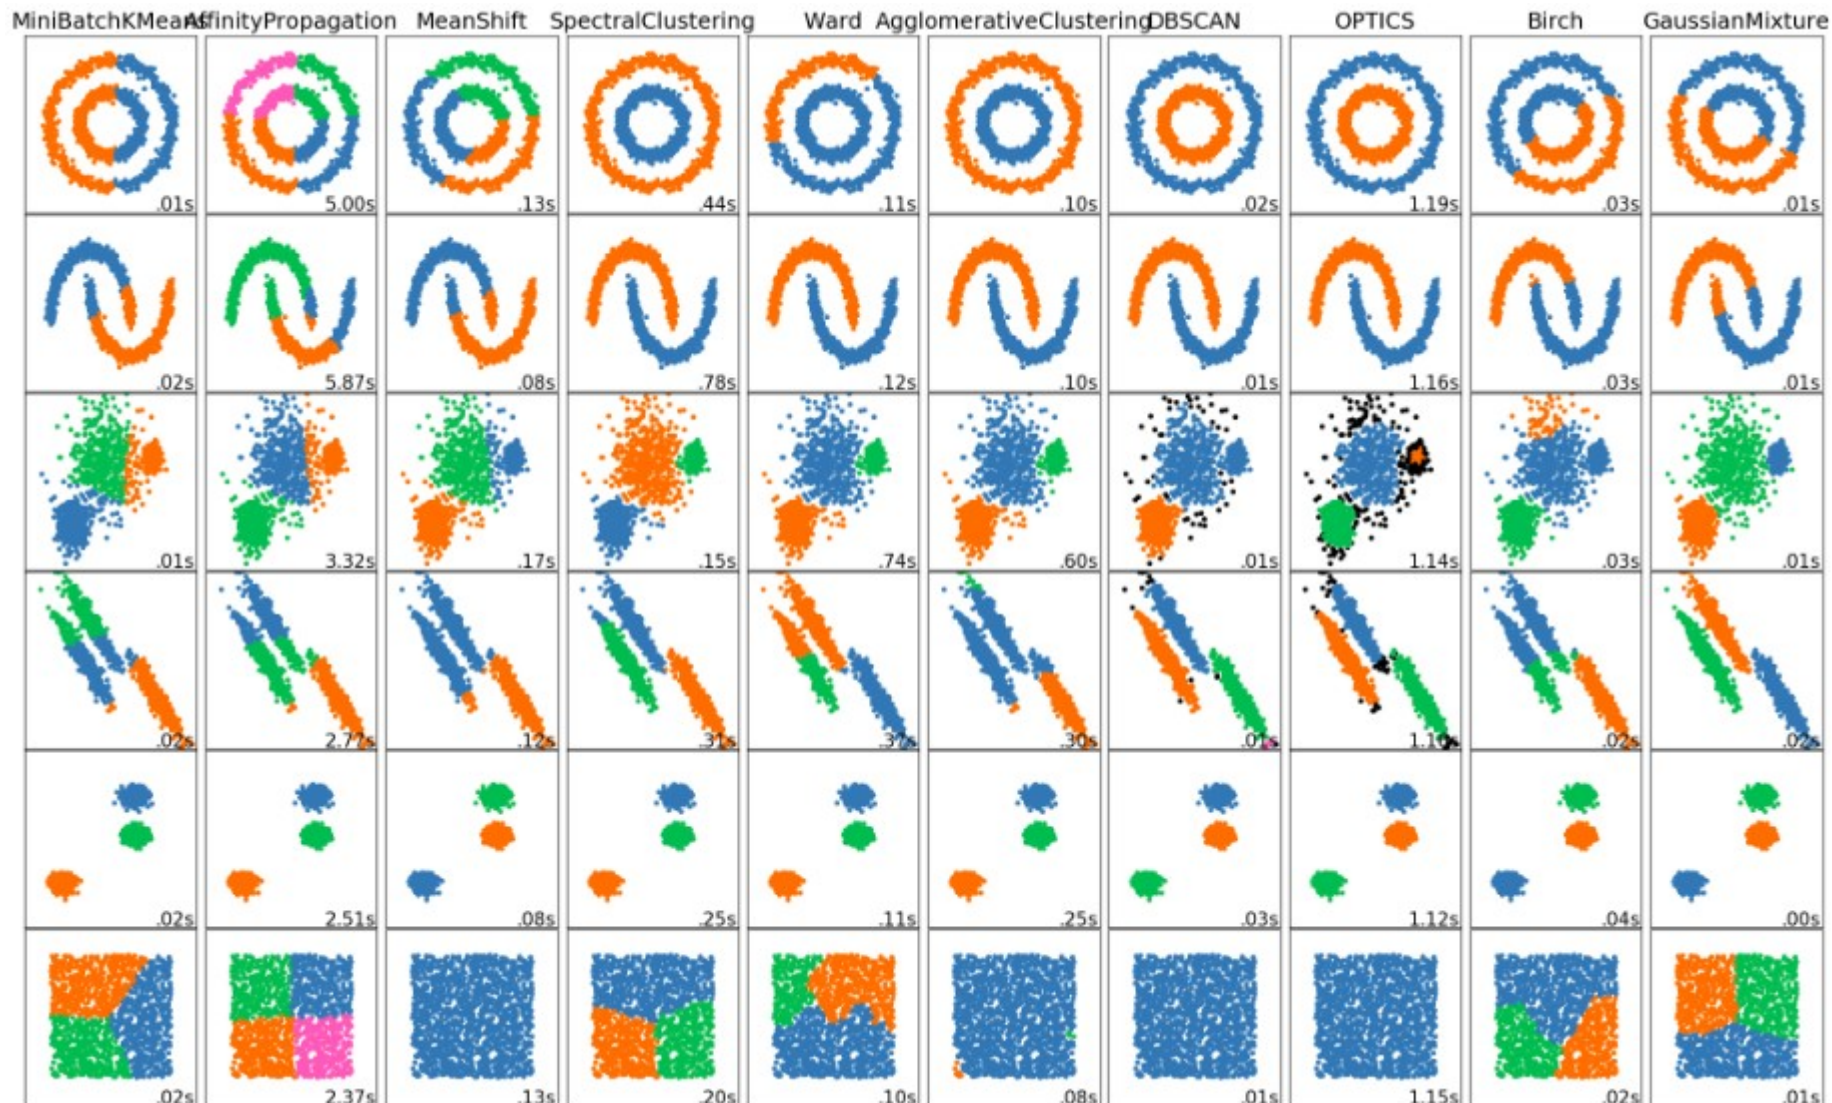
Vídeo 4

Outras técnicas, validação e comentários finais



Técnicas de agrupamentos

- **Hierárquico:** agrupamento progressivo de elementos (formação de subclasses) (ex: BIRCH, Chameleon, ROCK – para atributos categóricos)
- **Particional:** grupos obtidos a partir de uma partição do espaço de características com respeito a um número fixo de grupos
- **Baseados em densidades:** não assumem um formato dos grupos, mas que há grupos densos separados por regiões de baixa densidade (ex: DBSCAN, OPTICS, DENCLUE)
- **Baseados em modelos** matemáticos/estatísticos: otimizam o ajuste dos grupos aos modelos (ex: mclust (R))
- **Baseados em grafos** (agrupamento **spectral**): grafo de similaridade dos objetos; redução de dimensionalidade baseado nos autovalores da matriz de similaridade
- **Baseados em redes neurais:** procuram aprender um protótipo de cada classe – cada objeto é classificado de acordo com o protótipo mais próximo ou similar
- **Baseados em grid:** dividem o espaço em um grid (multiresolução) e aplica operações sobre ele (ex: STING, WaveCluster)
- **Baseados em restrições:** encontram grupos que satisfazem restrições definidas pelo usuário ou pela aplicação. Ex: tamanho min/max dos grupos, nr min/max de grupos, objetos com determinadas características devem ser agrupados em um mesmo grupo, diferentes pesos/distâncias para determinadas características
- **Outros**



<https://scikit-learn.org/stable/modules/clustering.html#spectral-clustering>



Tendência de agrupamento

- Na verdade, antes mesmo de executar um algoritmo de agrupamento, é importante avaliar a tendência de agrupamento dos dados (se são agrupáveis)
- Estatísticas para medir tendência
 - Ex: Hopkins - quanto mais próximo de 1 mais agrupável é o conjunto

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

Validação

A estrutura C (partição dos pontos) resultante de um algoritmo pode ser avaliada por três tipos de critérios:

- **Critérios externos:** avaliação de aspectos anteriores à execução de agrupamentos. Ex: o que sabe-se sobre a estrutura do problema? C confirma essa estrutura?
- **Critérios internos:** compara medidas baseadas nos dados. Ex: comparar C com a matriz de proximidade dos objetos
- **Critérios relativos:** comparar diferentes agrupamentos (mesmo algoritmo com diferentes parâmetros ou diferentes algoritmos)

Pode-se ainda avaliar a validade de um grupo específico.

Tudo isso discutido no cap 16 de (THEODORIDIS & KOUTROUMBAS, 2003): uso de teste de hipóteses

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?
 - Depende... Vimos nos vídeos 2 e 3 métodos não paramétricos, mas há métodos que se utilizam de famílias específicas de distribuições (métodos paramétricos)

Agrupamento

- É uma técnica de classificação
 - Supervisionada ou **não supervisionada**?
 - Paramétrica ou não paramétrica?
 - Depende... Vimos nos vídeos 2 e 3 métodos não paramétricos, mas há métodos que se utilizam de famílias específicas de distribuições (métodos paramétricos)
- Bastante utilizado para identificação de *outliers* (HAN & KAMBER, 2006), seção 7.11

Aprendizado semi-supervisionado

- Mistura de dados rotulados e não rotulados
- Classificação semi-supervisionada: usar os dados rotulados para rotular os dados não rotulados, e então aplicar aprendizado supervisionado
- Clustering semi-supervisionado: usar os dados rotulados para auxiliar os agrupamentos
- Dissertação de mestrado
https://teses.usp.br/teses/disponiveis/55/55134/tde-12102003-140536/publico/Dissertacao_MKS.pdf

Referências

- AHMAD, A.; KHAN, S. S. Survey of the state-of-the-art mixed data clustering algorithms. **IEEE Access** vol 7, p. 31883-31902, 2019
- 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)
- HAN, J; KAMBER, M. Data Mining: Concepts and Techniques. 2 ed. Elsevier. 2006. Cap 7
- 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).
- THEODORIDIS, S.; KOUTROUMBAS, K. Pattern Recognition, 2 ed. Elsevier. 2003. Cap 11 a 16.

Fim do vídeo 4

Outras técnicas, validação e comentários finais



EACH