

SCC5895 – Análise de Agrupamento de Dados

Algoritmos Hierárquicos: Parte II

Prof. Eduardo Raul Hruschka

PPG-CCMC / ICMC / USP



Créditos

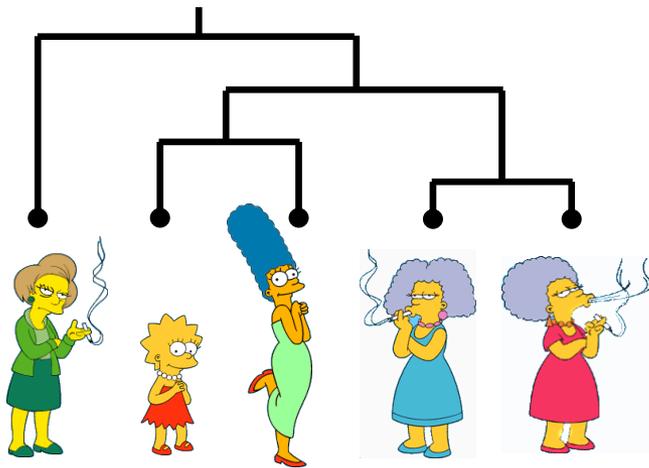
- Parte do material a seguir consiste de adaptações e extensões dos originais:
 - Elaborados por Eduardo R. Hruschka e Ricardo J. G. B. Campello
 - de (Tan et al., 2006)
 - de E. Keogh (SBBD 2003)
- Algumas figuras foram gentilmente cedidas por Lucas Vendramin



Agenda

- Continuação de Algoritmos Hierárquicos
 - Average Linkage (UPGMA)
 - Variantes: WPGMA, UPGMC, WPGMC
 - Método de Ward
 - Esquema de Lance-Williams
 - Métodos Monótonos e Não Monótonos
 - Métodos Divisivos
 - Heurística de MacNaughton-Smith (DIANA)
 - Bisecting k-Means
 - Single Linkage via Árvores Geradoras Mínimas em Grafos
 - Complexidade Computacional

Relembrando Agrupamento Hierárquico...



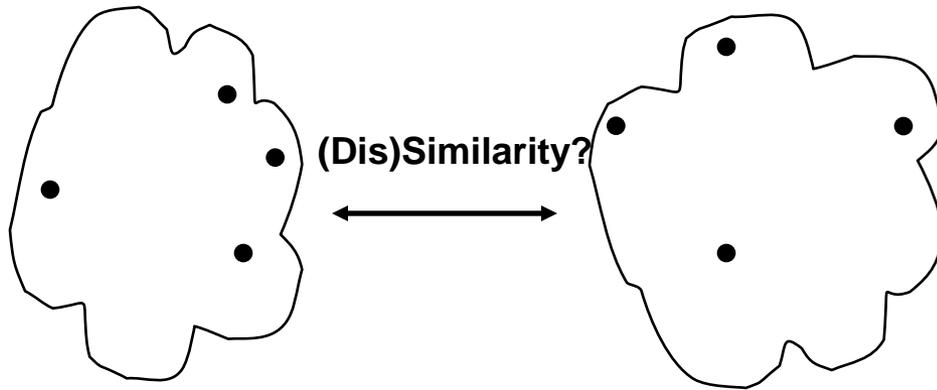
Bottom-Up (métodos aglomerativos):

- Iniciar colocando cada objeto em um *cluster*
- Encontrar o melhor par de *clusters* para unir
- Unir o par de *clusters* escolhido
- Repetir até que todos os objetos estejam reunidos em um só *cluster*

Top-Down (métodos divisivos):

- Iniciar com todos objetos em um único *cluster*
- Sub-dividir o *cluster* em dois novos *clusters*
- Aplicar o algoritmo recursivamente em ambos, até que cada objeto forme um *cluster* por si só

How to Define Inter-Cluster (Dis)Similarity

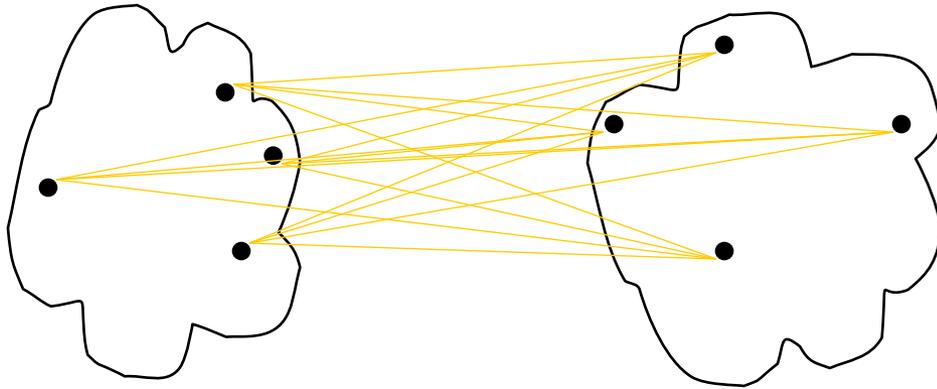


- ❑ MIN (aula anterior)
- ❑ MAX (aula anterior)
- ❑ **Group Average**
- ❑ **Distance Between Centroids**
- ❑ **Other methods**
 - Ward's
 - ...

| | p1 | p2 | p3 | p4 | p5 | ... |
|----|----|----|----|----|----|-----|
| p1 | | | | | | |
| p2 | | | | | | |
| p3 | | | | | | |
| p4 | | | | | | |
| p5 | | | | | | |
| . | | | | | | |
| . | | | | | | |
| . | | | | | | |

Proximity Matrix

How to Define Inter-Cluster (Dis)Similarity



- ❑ MIN
- ❑ MAX
- ❑ **Group Average**
- ❑ Distance Between Centroids
- ❑ Other methods
 - Ward's
 - ...

| | p1 | p2 | p3 | p4 | p5 | ... |
|----|----|----|----|----|----|-----|
| p1 | | | | | | |
| p2 | | | | | | |
| p3 | | | | | | |
| p4 | | | | | | |
| p5 | | | | | | |

· Proximity Matrix

Average Linkage ou Group Average

- Distância entre *clusters* é dada pela distância média entre cada par de objetos (um de cada *cluster*)
- Também conhecido como **UPGMA** :
 - *Unweighted Pair Group Method using Arithmetic averages*
 - “unweighted” → cada par de objetos possui a mesma importância

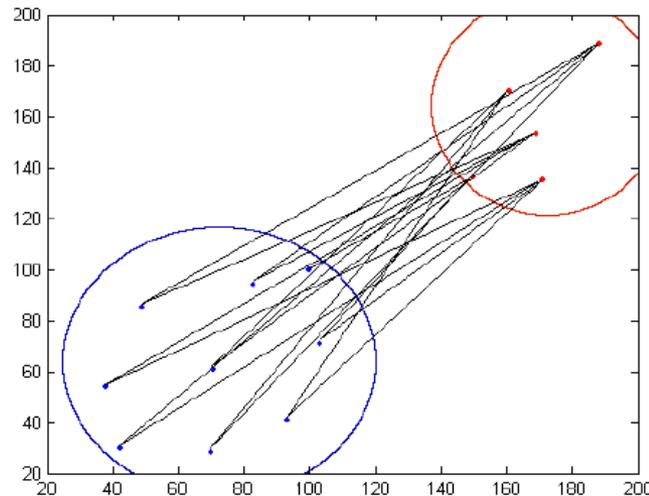


Figura por Lucas Vendramin

Cluster Similarity: Group Average

- Proximity of two clusters is the average of pairwise proximity between points in the two clusters.

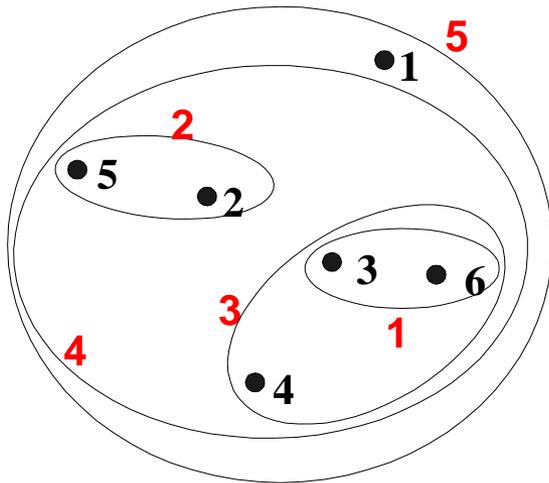
$$\text{proximity}(\text{Cluster}_i, \text{Cluster}_j) = \frac{\sum_{\substack{p_i \in \text{Cluster}_i \\ p_j \in \text{Cluster}_j}} \text{proximity}(p_i, p_j)}{|\text{Cluster}_i| * |\text{Cluster}_j|}$$

- Need to use average connectivity for scalability since total proximity favors large clusters

| | I1 | I2 | I3 | I4 | I5 |
|----|------|------|------|------|------|
| I1 | 1.00 | 0.90 | 0.10 | 0.65 | 0.20 |
| I2 | 0.90 | 1.00 | 0.70 | 0.60 | 0.50 |
| I3 | 0.10 | 0.70 | 1.00 | 0.40 | 0.30 |
| I4 | 0.65 | 0.60 | 0.40 | 1.00 | 0.80 |
| I5 | 0.20 | 0.50 | 0.30 | 0.80 | 1.00 |

Exercício: Gerar a hierarquia.

Hierarchical Clustering: Group Average



Nested Clusters

Exercício: atribua valores de distância entre os pontos ao lado, que sejam condizentes com a figura, e monte o dendrograma.

Hierarchical Clustering: Group Average

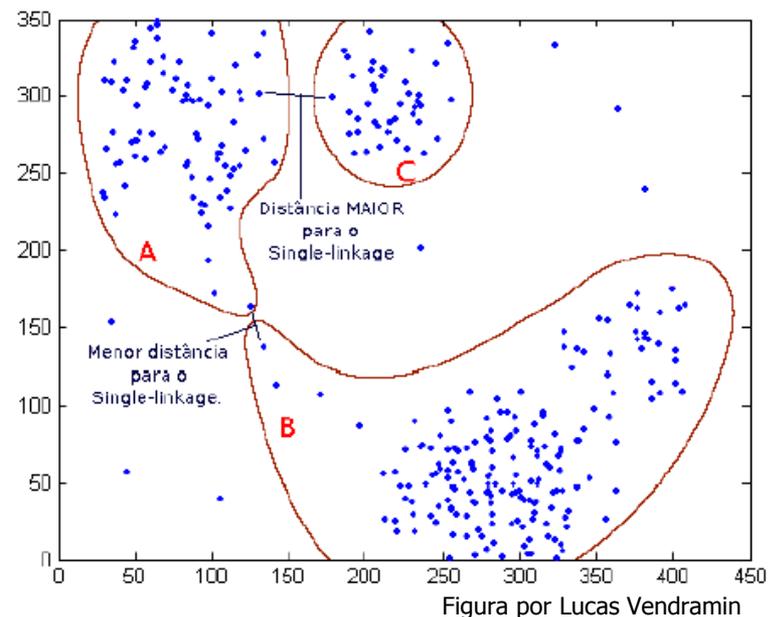
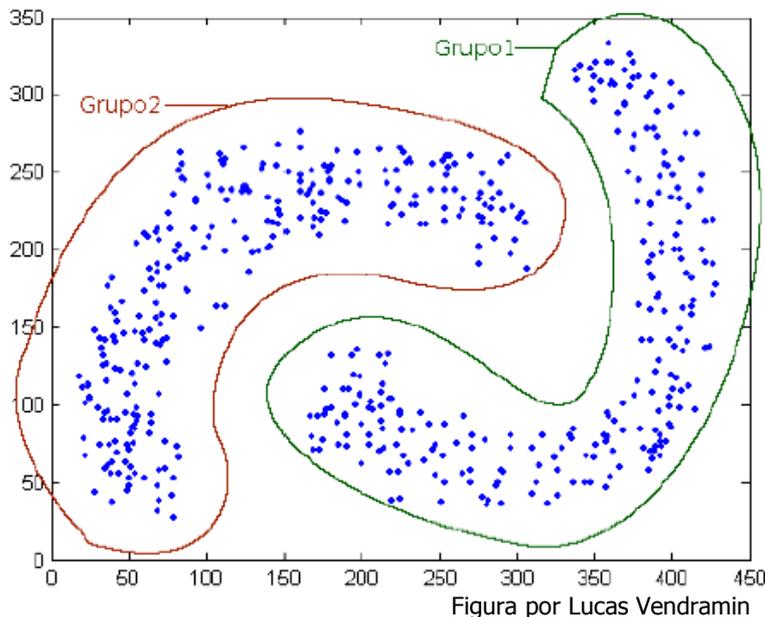
- ❑ **Group Average** represents a compromise between Single and Complete Link
- ❑ **Strengths**
 - Less susceptible to noise and outliers
- ❑ **Limitations**
 - Biased towards globular clusters

Como Comparar os Clusters ?

- **Single x Complete x Average:**

- Single Linkage:

- Capaz de detectar clusters de formas complexas
 - No entanto, muito sensível a ruído nos dados (e.g. "pontes")



Como Comparar os Clusters ?

- **Single x Complete x Average:**

- Complete Linkage:

- Reduz sensibilidade a ruído (e.g. pontes entre clusters)
- No entanto:
 - aumenta risco de separar clusters grandes
 - perde capacidade de detecção de formas complexas
 - favorece clusters globulares

- Average Linkage:

- Também favorece clusters bem comportados (globulares)
- Mas é muito menos sensível (mais robusto) a ruído e outliers.

Atualização da Matriz de Proximidades

- Para fins de atualização da matriz de (dis)similaridade em **average linkage**, o cálculo da (dis)similaridade entre um novo cluster (dado pela união de outros dois) e os demais deve considerar o no. de objetos em cada cluster envolvido
 - já que average linkage calcula uma média.
- Especificamente, sendo $|\mathbf{C}_i|$ o número de objetos em um cluster \mathbf{C}_i e $d(\mathbf{C}_i, \mathbf{C}_j)$ a (dis)similaridade entre dois clusters \mathbf{C}_i e \mathbf{C}_j , é simples mostrar que (vide Lance-Williams / exercícios):

$$d(\mathbf{C}_i, \mathbf{C}_j \cup \mathbf{C}_k) = \frac{|\mathbf{C}_j|}{|\mathbf{C}_j| + |\mathbf{C}_k|} d(\mathbf{C}_i, \mathbf{C}_j) + \frac{|\mathbf{C}_k|}{|\mathbf{C}_j| + |\mathbf{C}_k|} d(\mathbf{C}_i, \mathbf{C}_k)$$

Exercício:

- Obtenha o dendrograma completo de execução do método average linkage (**UPGMA**) sobre a matriz de distâncias abaixo
 - Mostre passo a passo a matriz atualizada (via fórmula do slide anterior)

$$\mathbf{D}_1 = \begin{matrix} & 1 & 2 & 3 & 4 & 5 \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \end{matrix} & \begin{bmatrix} 0 & & & & \\ 2 & 0 & & & \\ 6 & 5 & 0 & & \\ 10 & 9 & 4 & 0 & \\ 9 & 8 & 5 & 3 & 0 \end{bmatrix} \end{matrix}$$

- Apresente também a *cophenetic matrix* correspondente

Variante de Average Linkage

- Método **WPGMA**:

- *Weighted Pair Group Method using Arithmetic averages*

$$d(\mathbf{C}_i, \mathbf{C}_j \cup \mathbf{C}_k) = \frac{d(\mathbf{C}_i, \mathbf{C}_j) + d(\mathbf{C}_i, \mathbf{C}_k)}{2}$$

- Média aritmética simples das (dis)similaridades entre os grupos
 - não leva em conta as cardinalidades (no. objetos) dos grupos
- Mesma importância aos grupos, independente dos tamanhos
 - equivale a dar maior importância (**peso**) às (dis)similaridades envolvendo os objetos do grupo de menor tamanho (\mathbf{C}_j ou \mathbf{C}_k)
 - reduz o peso dos objetos do grupo de maior tamanho

Método de Ward (1963)

- Método baseado na minimização do **Critério de Erro Quadrático** (variâncias intra-grupos) a cada nova partição:

$$J = \sum_{i=1}^k \sum_{\mathbf{x}_j \in \mathbf{C}_i} d(\mathbf{x}_j, \bar{\mathbf{x}}_i)^2$$

onde d = Euclidiana e $\bar{\mathbf{x}}_i$ é o centróide do i -ésimo cluster:

$$\bar{\mathbf{x}}_i = \frac{1}{|\mathbf{C}_i|} \sum_{\mathbf{x}_i \in \mathbf{C}_i} \mathbf{x}_i$$

Método de Ward

- “Dissimilaridade” entre cada par de grupos C_i e C_j
 - definida como a variação no critério J da partição corrente se esses grupos forem unidos para formar a partição seguinte na sucessão hierárquica
 - unir os 2 grupos mais similares significa minimizar o crescimento das variâncias intra-grupos a cada nível da hierarquia
- Vide fórmula de atualização no esquema Lance-Williams...

Método de Ward

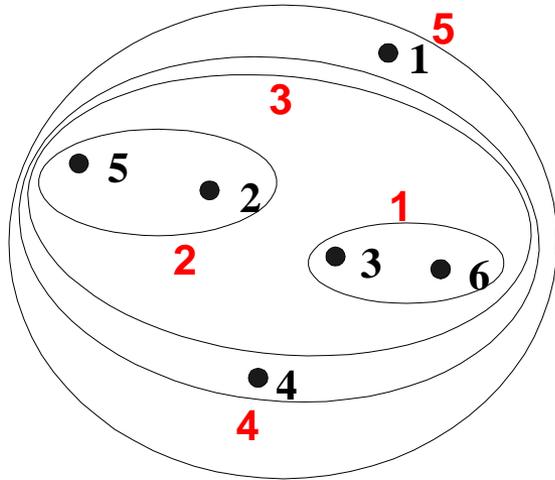
■ Limitações:

- Assim como Average Linkage, tende a gerar clusters globulares
- Fórmula de atualização só possui interpretação para dados descritos por atributos numéricos e distância Euclidiana

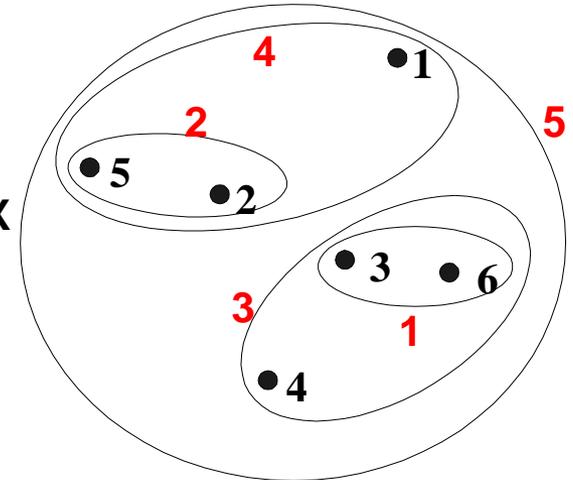
■ Vantagens:

- Similar a Average Linkage em robustez a ruído e outliers
- “Análogo hierárquico” do k-means (mesma função objetivo)
 - pode ser usado para inicializar k-means
- **Jain & Dubes (1988):** “*Several of the comparative studies discussed in Section 3.5.2 conclude that Ward’s method, also called the minimum variance method, outperforms other hierarchical clustering methods*”

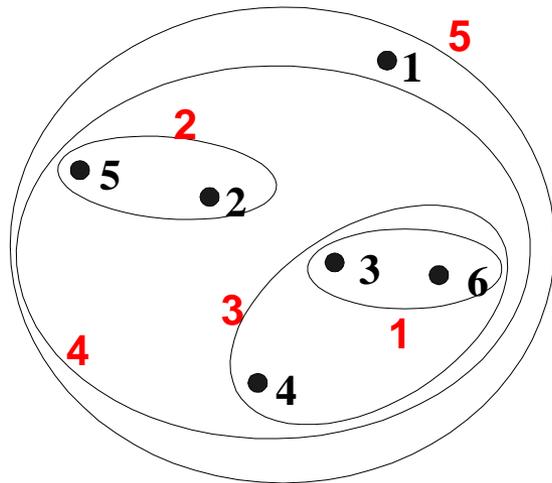
Hierarchical Clustering: Comparison



MIN

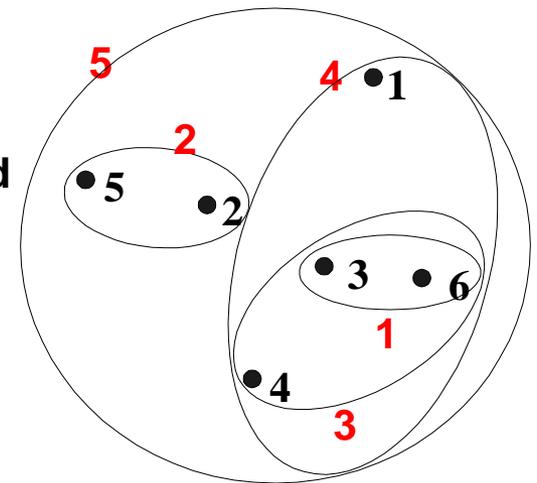


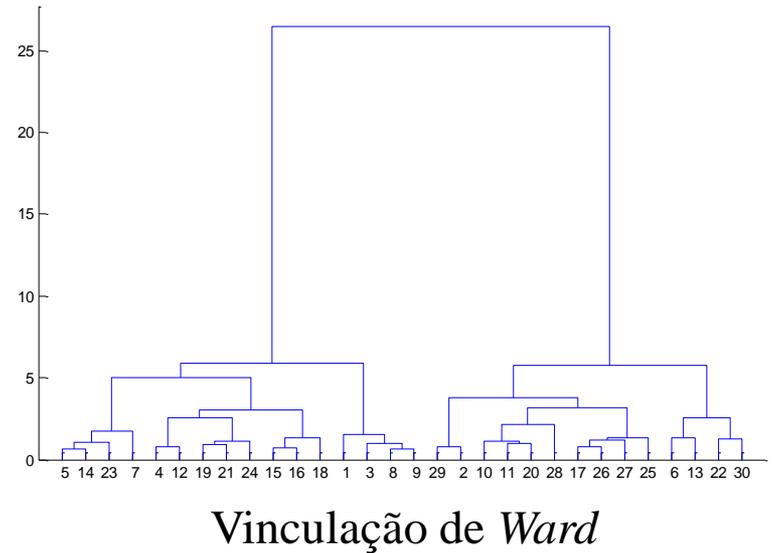
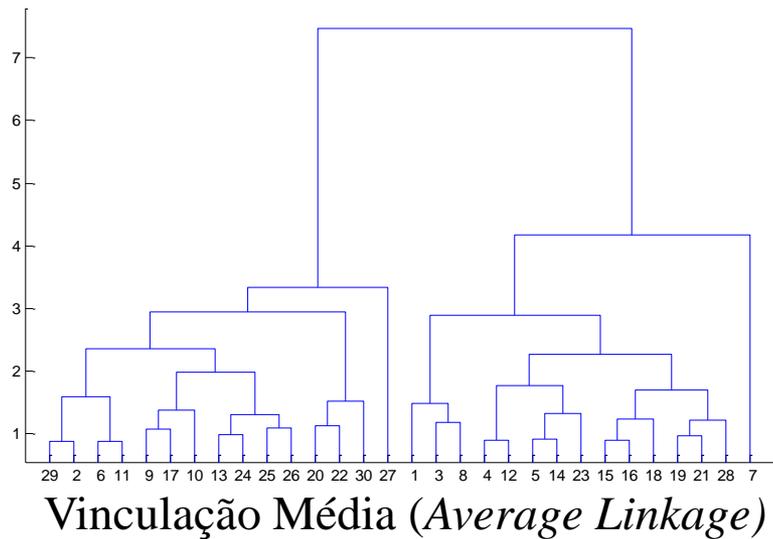
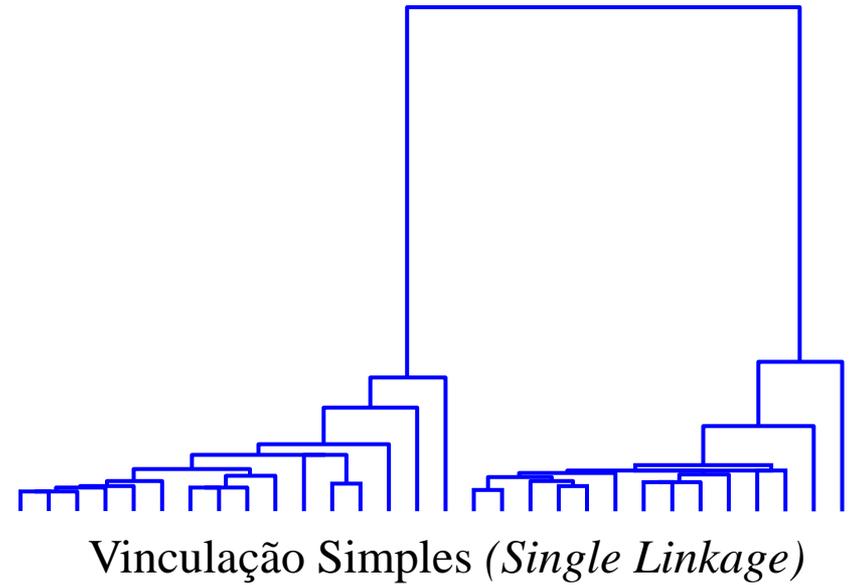
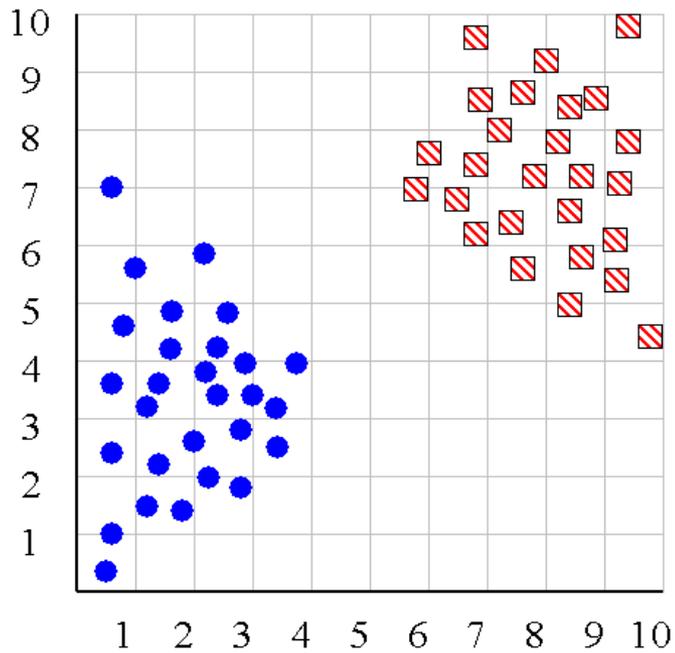
MAX



Group Average

Ward's Method





Esquema de Lance-Williams (1967)

- **Formulação Parametrizada** que abrange todos os métodos vistos anteriormente

$$d(\mathbf{C}_i, \mathbf{C}_j \cup \mathbf{C}_k) = \alpha_j d(\mathbf{C}_i, \mathbf{C}_j) + \alpha_k d(\mathbf{C}_i, \mathbf{C}_k) + \beta d(\mathbf{C}_j, \mathbf{C}_k) + \gamma |d(\mathbf{C}_i, \mathbf{C}_j) - d(\mathbf{C}_i, \mathbf{C}_k)|$$

onde $|\cdot|$ significa valor absoluto

- Algoritmo aglomerativo unificado
 - atualização configurável da matriz de proximidades

Esquema de Lance-Williams (1967)

| | α_j | α_k | β | γ |
|-------------------------|-----------------------------------|-----------------------------------|------------------------------|----------|
| Single-Linkage | 1/2 | 1/2 | 0 | -1/2 |
| Complete-Linkage | 1/2 | 1/2 | 0 | 1/2 |
| UPGMA | $N_j / (N_j + N_k)$ | $N_k / (N_j + N_k)$ | 0 | 0 |
| WPGMA | 1/2 | 1/2 | 0 | 0 |
| UPGMC | $N_j / (N_j + N_k)$ | $N_k / (N_j + N_k)$ | $-(N_j N_k) / (N_j + N_k)^2$ | 0 |
| WPGMC | 1/2 | 1/2 | -1/4 | 0 |
| Ward's | $(N_j + N_i) / (N_j + N_k + N_i)$ | $(N_k + N_i) / (N_j + N_k + N_i)$ | $-N_i / (N_j + N_k + N_i)$ | 0 |

□ NOTAS:

- N_i , N_j e N_k são as quantidades de objetos nos grupos C_i , C_j e C_k , respectivamente
- Métodos de centróides (UPGMC e WPGMC) subsumem dist. Euclidiana ao quadrado

Hierarchical Clustering: Time and Space requirements

- ❑ $O(N^2)$ **space** since it uses the proximity matrix
 - N is the number of points

- ❑ $O(N^3)$ **time** in many cases
 - There are N steps and, at each step, the proximity matrix must be updated and searched
 - Complexity can be reduced for some approaches

Métodos Divisivos

- Iniciam com um único *cluster*, que é sub-dividido em 2
- Recursivamente sub-divide cada um dos 2 *clusters*
 - Até que cada objeto constitua um **singleton**
- Em geral, são menos usados que os aglomerativos
 - É mais simples unir 2 *clusters* do que dividir...
 - número de modos para dividir N objetos em 2 *clusters* é $(2^{N-1} - 1)$. Por exemplo, para N=50 existem 5.63×10^{14} maneiras de se obter dois *clusters* !
- Questão:
 - *Como dividir um cluster ?*

■ Heurística de **MacNaughton-Smith et al.** (1964):

- Para um dado *cluster*, escolher o objeto mais distante dos demais
 - Este formará o *novo cluster*
- Para cada objeto, calculam-se as distâncias médias deste aos objetos do *cluster* original e aos objetos do *novo cluster*
- O objeto mais próximo do *novo cluster* e mais distante do *cluster* original é transferido para o *novo cluster*; repete-se o processo

■ Exemplo (Everitt et al., 2001):

$$\mathbf{D} = \begin{matrix} & 1 & 2 & 3 & 4 & 5 & 6 & 7 \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \\ 7 \end{matrix} & \begin{bmatrix} 0 & & & & & & \\ 10 & 0 & & & & & \\ 7 & 7 & 0 & & & & \\ 30 & 23 & 21 & 0 & & & \\ 29 & 25 & 22 & 7 & 0 & & \\ 38 & 34 & 31 & 10 & 11 & 0 & \\ 42 & 36 & 36 & 13 & 17 & 9 & 0 \end{bmatrix} & \end{matrix}$$

- Para este exemplo, objeto "1" é o mais distante (*novo cluster* – A)
- Demais objetos permanecem no *cluster principal* (*cluster* – B)
- *Clusters* obtidos: $A=\{1\}$ e $B=\{2,3,4,5,6,7\}$
- Sejam D_A e D_B as distâncias médias de um objeto de B em relação aos objetos de A e B, respectivamente:

| | Objetos B | D_A | D_B | $D_B - D_A$ |
|----------------------------------|-----------|-------|-------|-------------|
| Mais próximos de A do que de B → | 2 | 10 | 25 | 15,0 |
| | 3 | 7 | 23,4 | 16,4 |
| | 4 | 30 | 14,8 | -15,2 |
| | 5 | 29 | 16,4 | -12,6 |
| | 6 | 38 | 19,0 | -19,0 |
| | 7 | 42 | 22,2 | -19,8 |

Objeto escolhido para mudar de *cluster*

Desta forma, obtemos os *clusters* $\{1,3\}$ e $\{2,4,5,6,7\}$

Repetindo o processo temos ...

| Objetos B | D_A | D_B | $D_B - D_A$ |
|-----------|-------|-------|-------------|
| 2 | 8,5 | 29,5 | 12,0 |
| 4 | 25,5 | 13,2 | -12,3 |
| 5 | 25,5 | 15,0 | -10,5 |
| 6 | 34,5 | 16,0 | -18,5 |
| 7 | 39,0 | 18,7 | -20,3 |

*Mudar
para A*

Novos *clusters*: $\{1,3,2\}$ e $\{4,5,6,7\}$.

Próximo passo: todos $(D_B - D_A)$ negativos;

Pode-se então repetir o processo em cada *cluster* acima, separadamente...

Heurística de MacNaughton-Smith

■ Exercício:

- Aplicar o algoritmo hierárquico divisivo com heurística de MacNaughton-Smith et al. na seguinte base de dados:

$$\mathbf{D} = \begin{matrix} & 1 & & & & & \\ & 2 & & & & & \\ \mathbf{D} = & 3 & & & & & \\ & 4 & & & & & \\ & 5 & & & & & \end{matrix} \begin{bmatrix} 0 & & & & & \\ & 2 & 0 & & & \\ & 6 & 5 & 0 & & \\ & 10 & 9 & 4 & 0 & \\ & 9 & 8 & 5 & 3 & 0 \end{bmatrix}$$

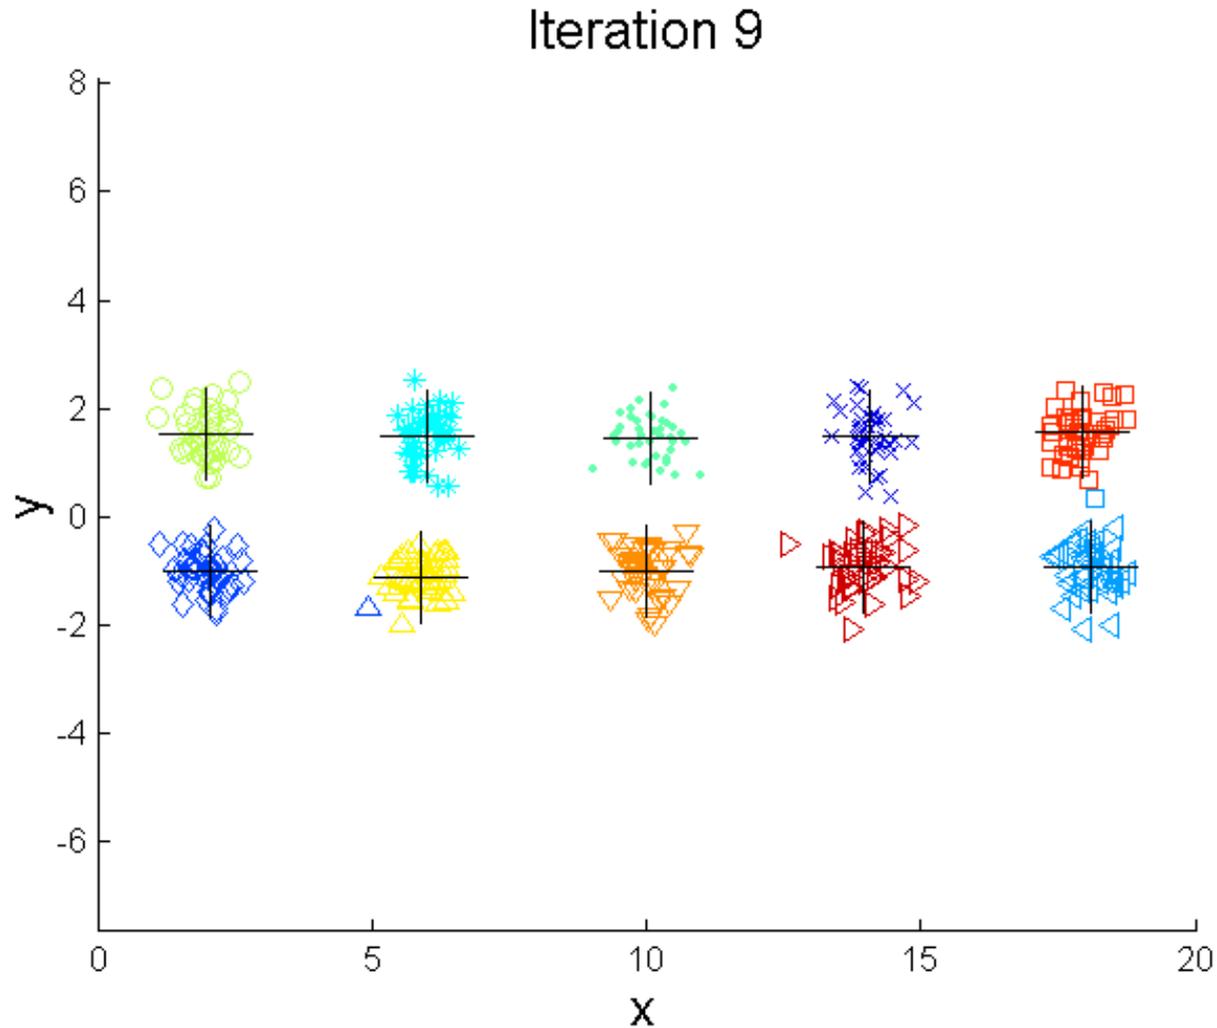
Bisecting K-means

- Bisecting K-means algorithm
 - Variant of **K-means** that can produce a **partitional** or a **hierarchical** clustering

-
- 1: Initialize the list of clusters to contain the cluster containing all points.
 - 2: **repeat**
 - 3: Select a cluster from the list of clusters
 - 4: **for** $i = 1$ to *number_of_iterations* **do**
 - 5: Bisect the selected cluster using basic K-means
 - 6: **end for**
 - 7: Add the two clusters from the bisection with the lowest SSE to the list of clusters.
 - 8: **until** Until the list of clusters contains K clusters
-

$$SSE(\mathbf{C}_i) = \sum_{\mathbf{x}_j \in \mathbf{C}_i} d(\mathbf{x}_j, \bar{\mathbf{x}}_i)^2 \quad \rightarrow \quad \text{Sum of Squared Errors (para o grupo } \mathbf{C}_i)$$

Bisecting K-means Example



Bisecting K-Means

- Note que fazendo $K = N$ (no. total de objetos) no passo 8 do algoritmo, obtemos uma hierarquia completa
- No passo 3, a seleção do grupo a ser bi-seccionado pode ser feita de diferentes maneiras
 - Utiliza-se algum critério de avaliação de qualidade dos grupos, para eleger o “pior”. Por exemplo:
 - Diâmetro máximo (sensível a outliers)
 - SSE normalizado pelo no. de objetos do grupo (mais robusto)
 - Critérios de avaliação de grupos individuais que consideram os objetos nos demais grupos (veremos posteriormente no curso)

Bisecting K-Means

■ Complexidade Computacional

- k-means roda em $O(Nkn)^*$, mas, como $k = 2$, tem-se $O(Nn)$
- Assumimos por simplicidade que *no_of_iterations* = 1 no passo 4
- **Pior Caso:** cada divisão separa apenas 1 objeto dos demais
 - $O(Nn + (N-1)n + (N-2)n + \dots + 2n) \rightarrow \mathbf{O(N^2n)}$
- **Melhor Caso:** cada divisão separa o grupo de forma balanceada
 - Árvore binária com $\log_2 N$ níveis, cada um somando N objetos
 - $\mathbf{O(n N \log_2 N)}$

* Assumindo distância com complexidade linear no no. de atributos

Bisecting K-Means

- Um problema deste algoritmo é que as divisões via execução de k-means (discutido posteriormente no curso) com $k = 2$ grupos podem “quebrar” grupos naturais
 - Essas quebras não poderão ser corrigidas. Exemplo:

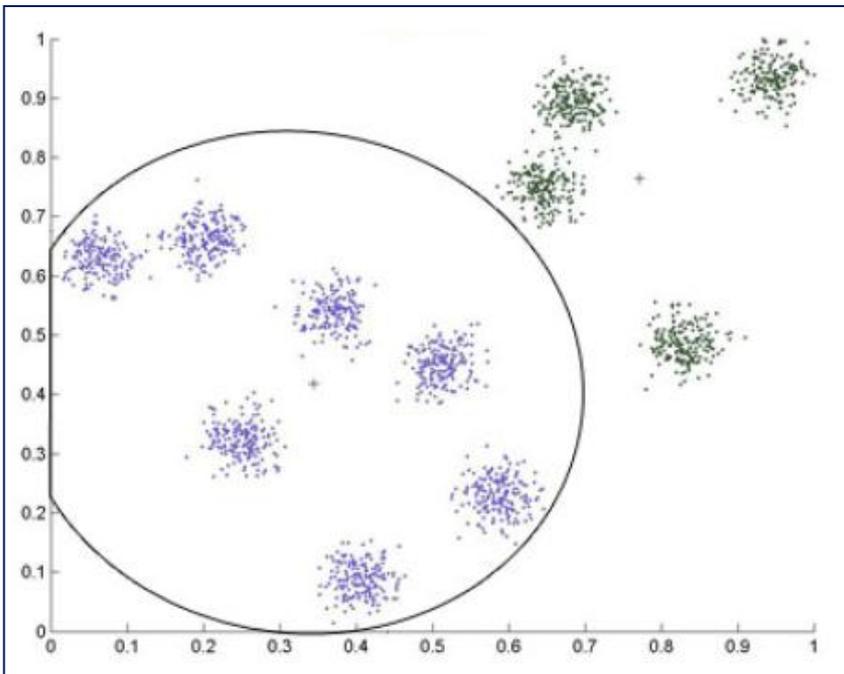


Figura por André Fontana

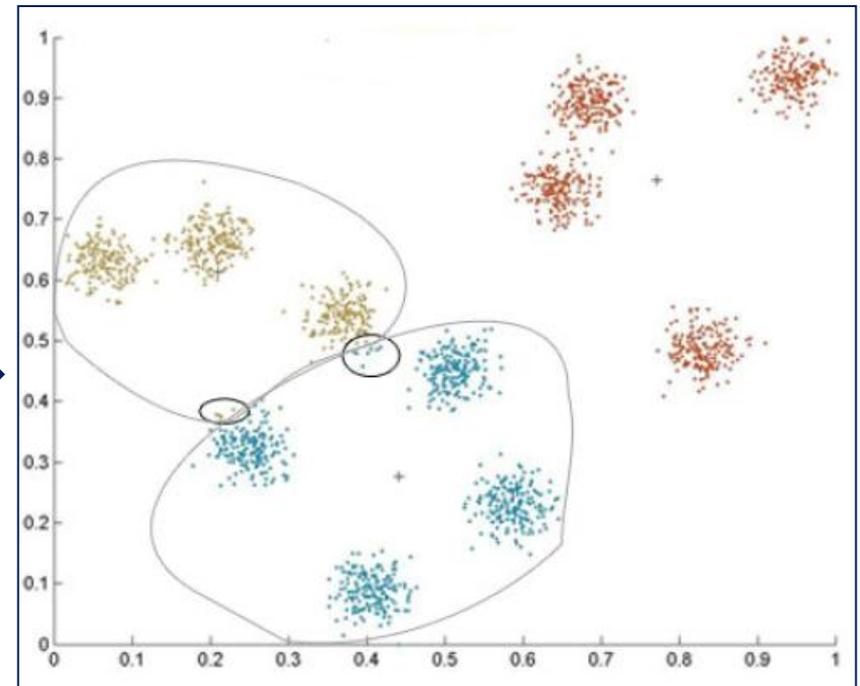
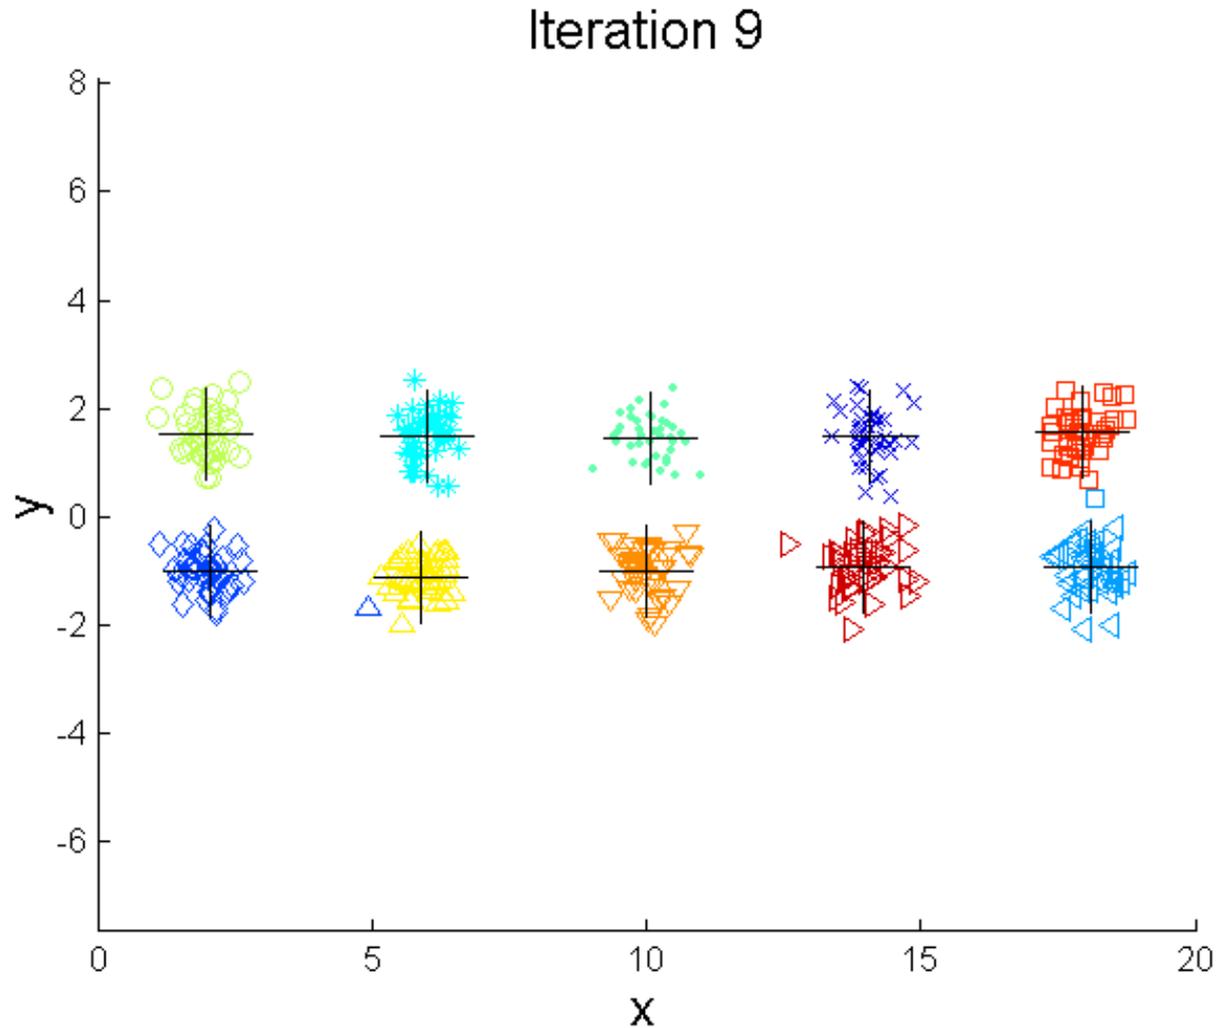


Figura por André Fontana

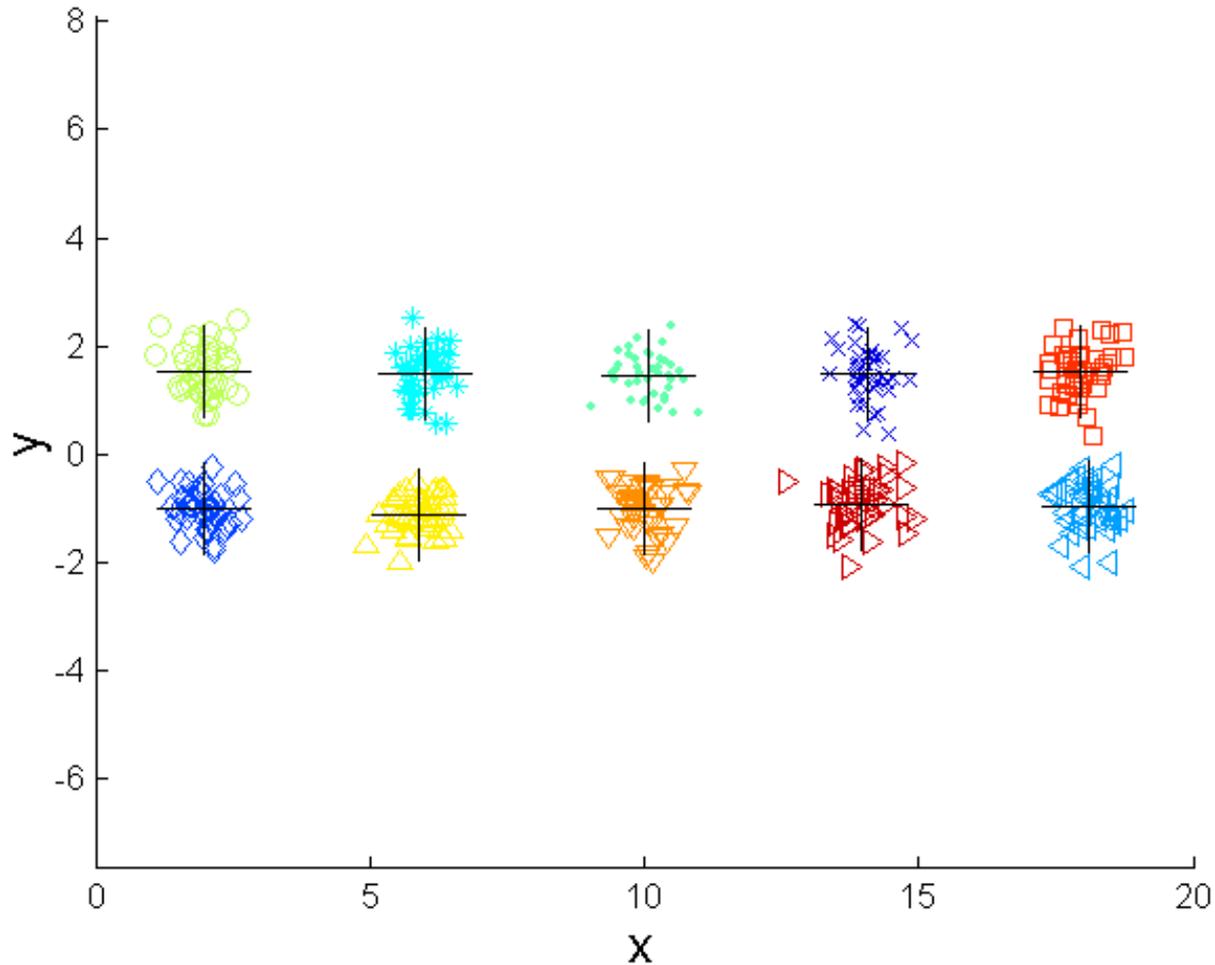
Bisecting K-Means

- **Nota:** se queremos uma partição com k' grupos:
 - ao invés da hierarquia
 - podemos refinar a solução obtida com k' grupos
 - executando o próprio k-means com $k = k'$
- No exemplo anterior:
 - refinar a solução com 10 grupos executando k-means com $k = 10$
 - protótipos iniciais iguais aos finais obtidos via bisecting k-means
 - vide figuras a seguir

Bisecting K-means Example

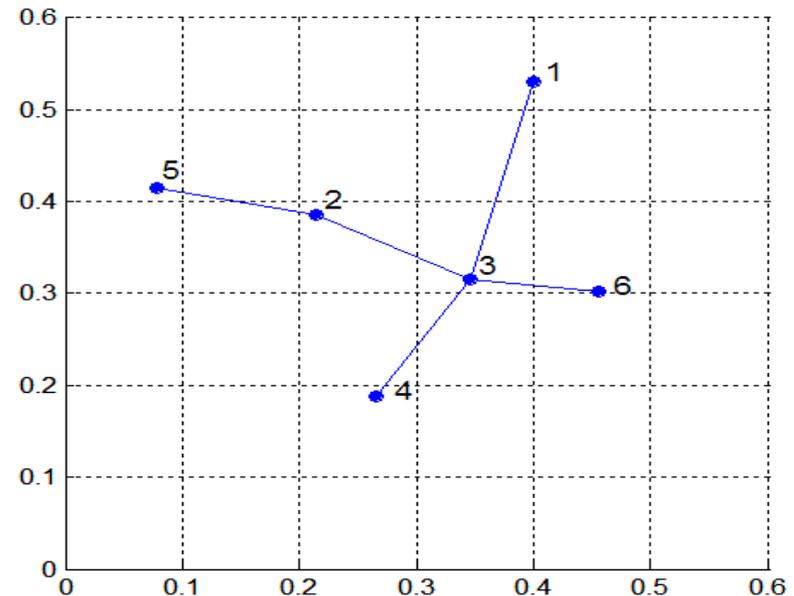
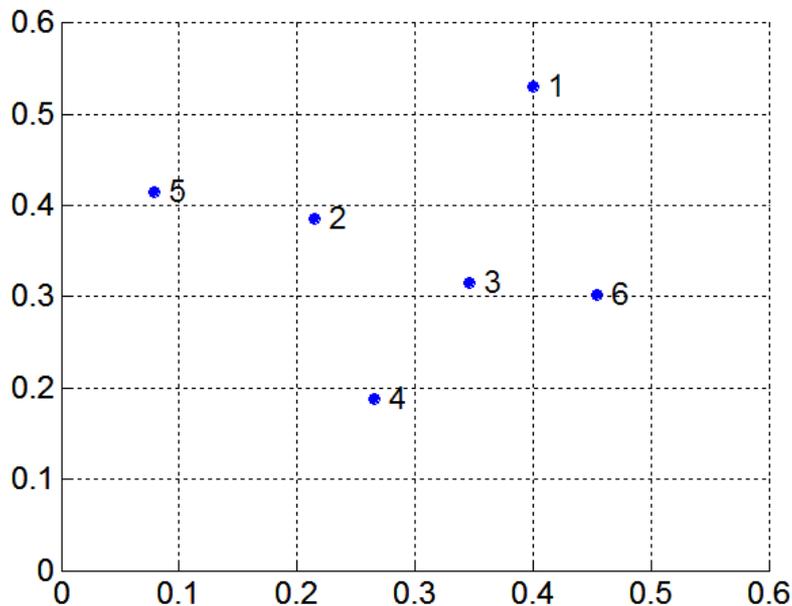


Bisecting K-Means Example



MST: Divisive Single-Linkage Clustering

- Build MST (Minimum Spanning Tree) for the **proximity graph**
 - Start with a tree that consists of any point
 - In successive steps, look for the closest pair of points (p, q) such that one point (p) is in the current tree but the other (q) is not
 - Add q to the tree and put an edge between p and q



MST: Divisive Single-Linkage Clustering

- Use MST for constructing hierarchy of clusters

Algorithm 7.5 MST Divisive Hierarchical Clustering Algorithm

- 1: Compute a minimum spanning tree for the proximity graph.
 - 2: **repeat**
 - 3: Create a new cluster by breaking the link corresponding to the largest distance (smallest similarity).
 - 4: **until** Only singleton clusters remain
-

Single-Linkage via MSTs

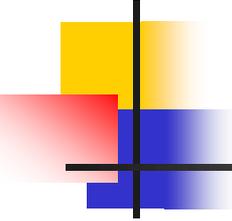
- O método para construção de Árvores Geradoras Mínimas (MSTs) descrito anteriormente é chamado de **Algoritmo de Prim**
- Outro método similar que também pode ser utilizado é o **Algoritmo de Kruskal**
 - Comece com cada objeto sendo uma MST
 - Forme uma nova MST conectando as duas MSTs mais próximas através da menor aresta entre elas
 - Repita até que se tenha uma única MST

Single-Linkage via MSTs

- Observe a relação direta entre o algoritmo de Kruskal para MSTs e o algoritmo *single-linkage*
- De fato, o procedimento divisivo subsequente à construção da MST é desnecessário nesse caso
 - MSTs parciais correspondem a grupos
 - Aresta mínima entre duas MSTs unidas a cada passo corresponde à distância entre dois grupos unidos
- Armazenando as MSTs parciais e as arestas de ligação, obtemos o **single-linkage aglomerativo**
 - torna mais evidente a relação entre single-linkage e MSTs

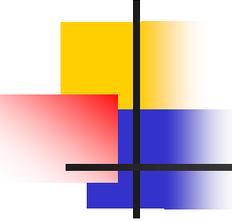
Sumário dos Métodos Hierárquicos

- **No. de Clusters:** não necessitam especificar o número de clusters *a priori*, mas de qualquer forma é necessário selecionar *a posteriori* ...
- **Procedimento Guloso:** não se pode reparar o que foi feito num passo anterior – não necessariamente leva à solução ótima
- **Escalabilidade:** complexidade de tempo $\Omega(N^2)$; N = no. de objetos
- **Interpretabilidade:** Produz uma hierarquia, que é aquilo desejado em muitas aplicações (e.g. taxonomia), e permite análise de outliers
- **Cálculo Relacional:** Não demandam matriz de dados original



Leitura Sugerida

- Seções 3.1 e 3.2 de (Jain & Dubes, 1988)



Referências

- Jain, A. K. and Dubes, R. C., *Algorithms for Clustering Data*, Prentice Hall, 1988
- Everitt, B. S., Landau, S., and Leese, M., *Cluster Analysis*, Arnold, 4th Edition, 2001
- Tan, P.-N., Steinbach, M., and Kumar, V., *Introduction to Data Mining*, Addison-Wesley, 2006
- Gan, G., Ma, C., and Wu, J., *Data Clustering: Theory, Algorithms and Applications*, ASA SIAM, 2007
- Gordon, A. D., "Hierarchical Classification", Em Arabie et al. (Eds.), *Clustering and Classification*, World Scientific, 1996