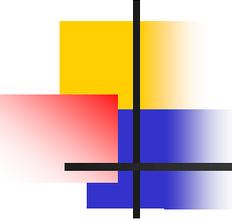


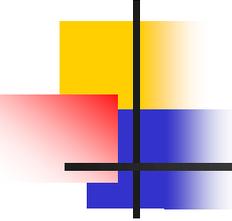
Agrupamento Hierárquico

Prof. Eduardo Raul Hruschka



Créditos

- O material a seguir consiste de adaptações e extensões dos originais:
 - de Eduardo R. Hruschka e Ricardo J. G. B. Campello
 - de (Tan et al., 2006)
 - de E. Keogh (SBBD 2003)



Agenda

- Algoritmos Hierárquicos
 - Conceitos e Definições
 - Dendrogramas
 - Grafos de Proximidade
 - Métodos Aglomerativos
 - *Single Linkage*
 - *Complete Linkage*

Relembrando...

- **Matriz de Dados \mathbf{X} :**

- N linhas (objetos) e n colunas (atributos):

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & & \ddots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{Nn} \end{bmatrix}$$

- Cada **objeto** (linha da matriz) é denotado por um vetor \mathbf{x}_i

- Exemplo:

$$\mathbf{x}_1 = [x_{11} \quad \cdots \quad x_{1n}]$$

Relembrando...

- **Matriz de Proximidade** (Dissimilaridade ou Similaridade):

- N linhas e N colunas:


$$\mathbf{D} = \begin{bmatrix} d(\mathbf{x}_1, \mathbf{x}_1) & d(\mathbf{x}_1, \mathbf{x}_2) & \cdots & d(\mathbf{x}_1, \mathbf{x}_N) \\ d(\mathbf{x}_2, \mathbf{x}_1) & d(\mathbf{x}_2, \mathbf{x}_2) & \cdots & d(\mathbf{x}_2, \mathbf{x}_N) \\ \vdots & & \ddots & \vdots \\ d(\mathbf{x}_N, \mathbf{x}_1) & d(\mathbf{x}_N, \mathbf{x}_2) & \cdots & d(\mathbf{x}_N, \mathbf{x}_N) \end{bmatrix}$$

- Simétrica se proximidade d apresentar propriedade de simetria


Relembrando...

- **Agrupamento Particional:** constrói uma *partição* dos dados
- **Agrupamento Hierárquico:** constrói uma *hierarquia de partições*

Hierárquicos



Particionais



Definição de Partição de Dados

- Consideremos um conjunto de N objetos a serem agrupados: $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$
- **Partição** (rígida): coleção de k grupos não sobrepostos $\mathbf{P} = \{\mathbf{C}_1, \mathbf{C}_2, \dots, \mathbf{C}_k\}$ tal que:

$$\mathbf{C}_1 \cup \mathbf{C}_2 \cup \dots \cup \mathbf{C}_k = \mathbf{X}$$

$$\mathbf{C}_i \neq \emptyset$$

$$\mathbf{C}_i \cap \mathbf{C}_j = \emptyset \text{ para } i \neq j$$

- Exemplo: $\mathbf{P} = \{ (\mathbf{x}_1), (\mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_6), (\mathbf{x}_2, \mathbf{x}_5) \}$

Definição de Hierarquia

➤ Hierarquia (de partições de dados):

➤ Sequência de partições aninhadas

- Uma partição \mathbf{P}_1 está *aninhada* em \mathbf{P}_2 se cada componente (grupo) de \mathbf{P}_1 é um subconjunto de um componente de \mathbf{P}_2

➤ Exemplo:

$$\mathbf{P}_1 = \{ (\mathbf{x}_1), (\mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_6), (\mathbf{x}_2, \mathbf{x}_5) \}$$

$$\mathbf{P}_2 = \{ (\mathbf{x}_1, \mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_6), (\mathbf{x}_2, \mathbf{x}_5) \}$$

➤ Contra-Exemplo:

$$\mathbf{P}_3 = \{ (\mathbf{x}_1, \mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_6), (\mathbf{x}_2, \mathbf{x}_5) \}$$

$$\mathbf{P}_4 = \{ (\mathbf{x}_1, \mathbf{x}_2), (\mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_6), (\mathbf{x}_5) \}$$

Definição de Hierarquia

- Uma hierarquia completa:
 - Inicia ou termina com partição totalmente disjunta
 - *Disjoint clustering*: apenas grupos **atômicos** (*singletons*)
 - Exemplo: $\mathbf{P} = \{ (\mathbf{x}_1), (\mathbf{x}_2), (\mathbf{x}_3), (\mathbf{x}_4), (\mathbf{x}_5), (\mathbf{x}_6) \}$
 - Também denominada “solução trivial”
 - Inicia ou termina com partição totalmente conjunta
 - *Conjoint clustering*: grupo único com todos os objetos
 - Exemplo: $\mathbf{P} = \{ (\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_5, \mathbf{x}_6) \}$


Hierarquias são comumente usadas para organizar informação, como, por exemplo, num portal

Business & Economy
[B2B](#), [Finance](#), [Shopping](#), [Jobs](#)...

Regional
[Countries](#), [Regions](#), [US States](#)...

Computers & Internet
[Internet](#), [WWW](#), [Software](#), [Games](#)...


Society & Culture
[People](#), [Environment](#), [Religion](#)...



Métodos Clássicos para Agrupamento Hierárquico

Bottom-Up (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 (divisivos):

- Iniciar com todos os 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

Algoritmos hierárquicos
podem operar somente sobre
uma matriz de distâncias: são
(ou podem ser) **relacionais**.


$$D(\text{Mrs. Muntz}, \text{Lisa Simpson}) = 8$$

$$D(\text{Mrs. Krabappel}, \text{Mrs. Krabappel}) = 1$$


| | | | | |
|---|---|---|---|---|
| 0 | 8 | 8 | 7 | 7 |
| | 0 | 2 | 4 | 4 |
| | | 0 | 3 | 3 |
| | | | 0 | 1 |
| | | | | 0 |

Bottom-Up (aglomerativo):


Iniciando com cada objeto em seu próprio cluster, encontrar o melhor par de *clusters* para unir em um novo *cluster*. Repetir até que todos os *clusters* sejam fundidos em um único *cluster*.




Considerar todas as uniões possíveis ...




Escolher a melhor




Considerar todas as uniões possíveis ...



Escolher a melhor




Considerar todas as uniões possíveis ...



Escolher a melhor



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**

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**

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

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**

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**

Como Comparar os Clusters?

- ***Single Linkage***, Min, ou Vizinho mais Próximo :
 - Dissimilaridade entre *clusters* é dada pela menor dissimilaridade entre 2 objetos (um de cada *cluster*)



single link (Florek, 1951; Sneath, 1957)

Originalmente baseado em **Grafos**:
menor aresta entre dois vértices
de subconjuntos distintos

Propriedade Útil

- Propriedade da Função Mínimo (min):
 - $\min\{\mathbf{D}\} = \min\{ \min\{\mathbf{D}_1\} , \min\{\mathbf{D}_2\} \}$
 - \mathbf{D} , \mathbf{D}_1 e \mathbf{D}_2 são conjuntos de valores reais tais que $\mathbf{D}_1 \cup \mathbf{D}_2 = \mathbf{D}$
 - Exemplo:
 - $\min\{10, -3, 0, 100\} = \min \{ \min\{10, -3\}, \min\{0, 100\} \} = -3$
 - Propriedade vale recursivamente (para $\min\{\mathbf{D}_1\}$ e $\min\{\mathbf{D}_2\}$)
- Utilidade para *Single-Linkage*
 - Dada a distância entre os grupos \mathbf{A} e \mathbf{B} e entre \mathbf{A} e \mathbf{C}
 - É trivial calcular a distância entre \mathbf{A} e $(\mathbf{B} \cup \mathbf{C})$.

Exemplo de Single Linkage: Método de Johnson (1967)

- Consideremos a seguinte matriz de distâncias iniciais (\mathbf{D}_1) entre 5 objetos $\{1,2,3,4,5\}$. Qual par de objetos será escolhido para formar o 1º *cluster*?

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

- A menor distância entre objetos é $d_{12}=d_{21}=2$, indicando que estes dois objetos serão unidos em um *cluster*. Na seqüência, calcula-se:

$$d_{(12)3} = \min\{d_{13}, d_{23}\} = d_{23} = 5;$$

$$d_{(12)4} = \min\{d_{14}, d_{24}\} = d_{24} = 9;$$

$$d_{(12)5} = \min\{d_{15}, d_{25}\} = d_{25} = 8;$$

- Desta forma, obtém-se uma nova matriz de distâncias (\mathbf{D}_2), que será usada na próxima etapa do agrupamento hierárquico:

$$\mathbf{D}_2 = \begin{matrix} & 12 & \begin{bmatrix} 0 \\ 3 & 5 & 0 \\ 4 & 9 & 4 & 0 \\ 5 & 8 & 5 & \boxed{3} & 0 \end{bmatrix} \end{matrix}$$

- Qual o novo *cluster* a ser formado?
- Unindo os objetos **4** e **5** obtemos três clusters: {1,2}, {4,5}, {3}
- Como $d_{(12)3}$ já está calculada, calculamos na sequência:

$$d_{(12)(45)} = \min\{d_{(12)(4)}, d_{(12)(5)}\} = d_{(12)(5)} = 8$$

$$d_{(45)3} = \min\{d_{43}, d_{53}\} = d_{43} = 4$$

obtendo a seguinte matriz:

$$\mathbf{D}_3 = \begin{matrix} & 12 & \begin{bmatrix} 0 \\ 3 & 5 & 0 \\ 45 & 8 & \boxed{4} & 0 \end{bmatrix} \end{matrix}$$

* Unir *cluster* {3} com {4,5};

* Finalmente, unir todos os *clusters* em um único *cluster*

- A sequência de partições obtidas neste exemplo é, portanto:

$$\{ (1), (2), (3), (4), (5) \} \rightarrow \{ (1, 2), (3), (4), (5) \} \rightarrow$$

$$\{ (1, 2), (3), (4, 5) \} \rightarrow \{ (1, 2), (3, 4, 5) \} \rightarrow \{ (1, 2, 3, 4, 5) \}$$

- **Nota:** Para *single link*, a dissimilaridade entre 2 clusters pode ser computada naturalmente a partir da matriz atualizada na iteração anterior, sem necessidade da matriz original


- Isso vale devido à propriedade da função *min* vista anteriormente

- No nosso exemplo, simplificamos o cálculo de $d_{(12)(45)}$ como $\min\{d_{(12)(4)}, d_{(12)(5)}\}$ fazendo uso daquela propriedade:

- $\min\{d_{(12)(4)}, d_{(12)(5)}\} = \min\{9, 8\} = \min\{d_{14}, d_{24}, d_{15}, d_{25}\}$

Dendrograma

Dendrograma: Hierarquia + Dissimilaridades entre Clusters




* A dissimilaridade entre dois clusters (possivelmente **singletons**) é representada como a altura do nó interno mais baixo compartilhado


Exemplo de Dendrograma

$$\mathbf{D} = \begin{bmatrix} 1 & 0 & 2 & 7 & 13 \\ 2 & 2 & 0 & 5 & 10 \\ 3 & 7 & 5 & 0 & 4 \\ 4 & 13 & 10 & 4 & 0 \end{bmatrix}$$

Figura por Lucas Vendramin




Dendrograma




uma das partições aninhadas

Outro Exemplo de Dendrograma



Nested Clusters



Dendrogram

Exercício:

- Obtenha o dendrograma completo para o exemplo visto de execução do *single linkage* (matriz de distâncias abaixo)

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


Dendrogramas e Partições

- Partições são obtidas via **cortes** no dendrograma
 - cortes horizontais
 - no. de grupos da partição = no. de interseções


➤ Exemplos:

$$P_2 = \{ (\mathbf{x}_1, \mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_6), (\mathbf{x}_2, \mathbf{x}_5) \}$$

$$P_1 = \{ (\mathbf{x}_1), (\mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_6), (\mathbf{x}_2, \mathbf{x}_5) \}$$




Pode-se examinar o dendrograma para tentar estimar o número *mais natural* de clusters. No caso abaixo, existem duas sub-árvores bem separadas, sugerindo dois grupos de dados. Infelizmente, na prática, as distinções não são tão simples...




Pode-se usar o dendrograma para tentar detectar *outliers*:

Ramo isolado sugere que o objeto é muito diferente dos demais.




Outlier



Voltando ao Single Linkage (Min)...


- Similarity of two clusters is based on the two most similar (closest) points in the clusters
 - Determined by **one pair of points**
 - i.e., by **one link** in the **proximity graph**

| | 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 |




Strength of MIN

- Can handle non-elliptical shapes



Main Limitations of MIN

- Sensitive to noise and outliers



Original Points

Two Clusters

Como Comparar os Clusters?

- ***Complete Linkage***, Max, ou Vizinho mais Distante:
 - Dissimilaridade entre *clusters* é dada pela maior dissimilaridade entre dois objetos (um de cada *cluster*)




Figura por Lucas Vendramin

complete link (Sorensen, 1948)

Originalmente baseado em **Grafos**:
maior aresta entre dois vértices de subconjuntos distintos

Propriedade Útil

- Propriedade da Função Máximo (max):
 - $\max\{\mathbf{D}\} = \max\{ \max\{\mathbf{D}_1\} , \max\{\mathbf{D}_2\} \}$
 - \mathbf{D} , \mathbf{D}_1 e \mathbf{D}_2 são conjuntos de valores reais tais que $\mathbf{D}_1 \cup \mathbf{D}_2 = \mathbf{D}$
 - Exemplo:
 - $\max\{10, -3, 0, 100\} = \max\{ \max\{10, -3\}, \max\{0, 100\} \} = 100$
 - Propriedade vale recursivamente (para $\max\{\mathbf{D}_1\}$ e $\max\{\mathbf{D}_2\}$)
- Utilidade para *Complete-Linkage*
 - Dada a distância entre os grupos \mathbf{A} e \mathbf{B} e entre \mathbf{A} e \mathbf{C}
 - É trivial calcular a distância entre \mathbf{A} e $(\mathbf{B} \cup \mathbf{C})$.

- Seja a seguinte matriz de distâncias iniciais (\mathbf{D}_1) entre 5 objetos :


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

- Exercício: executar o *complete linkage* através de sucessivas atualizações da matriz de distâncias (método de Johnson).


Cluster Similarity: MAX or Complete Linkage

- Similarity of two clusters is based on the two least similar (most distant) points in the clusters
 - Determined by **one pair of points**


| | 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 |



Hierarchical Clustering: MAX




Nested Clusters




Dendrogram

Strength of MAX



Original Points




Two Clusters


- **Less susceptible to noise and outliers**

Main Limitations of MAX

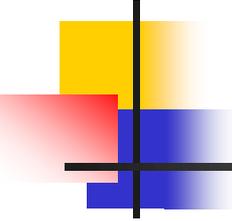
Original Points



Two Clusters



- **Tends to break large clusters**
- **Biased towards globular clusters**



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