

Clustering Hierárquico Aglomerativo

- **Matriz de proximidade: $N \times N$**
 - **$D(i,j)$: medida de proximidade ou similaridade entre os padrões i e j**
- 1. Atribuir um padrão por cluster (N clusters)**
 - 2. Encontrar o par de clusters C_i e C_j mais semelhantes na matriz de similaridade e juntá-los num único cluster**
 - 3. Actualizar a matriz de similaridade entre o novo cluster e todos os restantes**
 - 4. Repetir os passos (2) e (3) até que se tenha um único cluster (i.e. $N-1$ vezes)**

Medida de semelhança entre clusters


- A maioria dos métodos de cálculo de similaridade entre clusters pode ser expresso por uma única fórmula que dá a similaridade (ou distância) entre um cluster k e o cluster $i+j$ formado pela junção dos clusters i e j :

$$d(i+j, k) = a_i d(i, k) + a_j d(j, k) + b d(i, j) + c |d(i, k) - d(j, k)|$$


| | |
|--|---|
| Single-link (ligação simples) | $a_i = a_j = 0.5 ; b = 0 ; c = -0.5$ $d(i+j, k) = \min\{d(i, k), d(j, k)\}$ |
| Complete-link (ligação completa) | $a_i = a_j = 0.5 ; b = 0 ; c = 0.5$ $d(i+j, k) = \max\{d(i, k), d(j, k)\}$ |
| Centroide | $a_i = \frac{n_i}{n_i + n_j} \quad a_j = \frac{n_j}{n_i + n_j} \quad b = -\frac{n_i n_j}{(n_i + n_j)^2} \quad c = 0$ $d(i+j, k) = d(\mu_{i+j}, \mu_k)$ |
| Mediana | $a_i = a_j = 0.5 ; b = -0.25 ; c = 0$ |
| Média do Grupo (Average link) | $a_i = \frac{n_i}{n_i + n_j} \quad a_j = \frac{n_j}{n_i + n_j} \quad b = c = 0$ $d(C_i, C_j) = \frac{1}{n_i n_j} \sum_{a \in C_i, b \in C_j} d(a, b)$ |
| Método de Ward (variância mínima) | $a_i = \frac{n_k + n_i}{n_k + n_i + n_j} \quad a_j = \frac{n_k + n_j}{n_k + n_i + n_j}$ $b = -\frac{n_k}{n_k + n_i + n_j} \quad c = 0$ |

Ex: Single-Link $d(C_i, C_j) = \min_{a \in C_i, b \in C_j} \{d(a, b)\}$

| | x | y |
|---|----|----|
| 1 | 4 | 4 |
| 2 | 8 | 4 |
| 3 | 15 | 8 |
| 4 | 24 | 4 |
| 5 | 24 | 12 |




| | 1 | 2 | 3 | 4 | 5 |
|---|------|------|------|-----|------|
| 1 | - | 4 | 11.7 | 20 | 21.5 |
| 2 | 4 | - | 8.1 | 16 | 17.9 |
| 3 | 11.7 | 8.1 | - | 9.8 | 9.8 |
| 4 | 20 | 16 | 9.8 | - | 8 |
| 5 | 21.5 | 17.9 | 9.8 | 8 | - |




| | 1,2 | 3 | 4 | 5 |
|-----|------|-----|-----|------|
| 1,2 | - | 8.1 | 16 | 17.9 |
| 3 | 8.1 | - | 9.8 | 9.8 |
| 4 | 16 | 9.8 | - | 8 |
| 5 | 17.9 | 9.8 | 8 | - |


Clustering




| | 1,2 | 3 | 4,5 |
|-----|-----|-----|-----|
| 1,2 | - | 8.1 | 16 |
| 3 | 8.1 | - | 9.8 |
| 4,5 | 16 | 9.8 | - |




| | 1,2,3 | 4,5 |
|-------|-------|-----|
| 1,2,3 | - | 9.8 |
| 4,5 | 9.8 | - |




Complete-Link $d(C_i, C_j) = \max_{a \in C_i, b \in C_j} \{d(a, b)\}$



| | 1 | 2 | 3 | 4 | 5 |
|---|------|------|------|-----|------|
| 1 | - | 4 | 11.7 | 20 | 21.5 |
| 2 | 4 | - | 8.1 | 16 | 17.9 |
| 3 | 11.7 | 8.1 | - | 9.8 | 9.8 |
| 4 | 20 | 16 | 9.8 | - | 8 |
| 5 | 21.5 | 17.9 | 9.8 | 8 | - |




| | 1,2 | 3 | 4 | 5 |
|-----|------|------|-----|------|
| 1,2 | - | 11.7 | 20 | 21.5 |
| 3 | 11.7 | - | 9.8 | 9.8 |
| 4 | 20 | 9.8 | - | 8 |
| 5 | 21.5 | 9.8 | 8 | - |




| | 1,2 | 3 | 4,5 |
|-----|------|------|------|
| 1,2 | - | 11.7 | 21.5 |
| 3 | 11.7 | - | 9.8 |
| 4,5 | 21.5 | 9.8 | - |


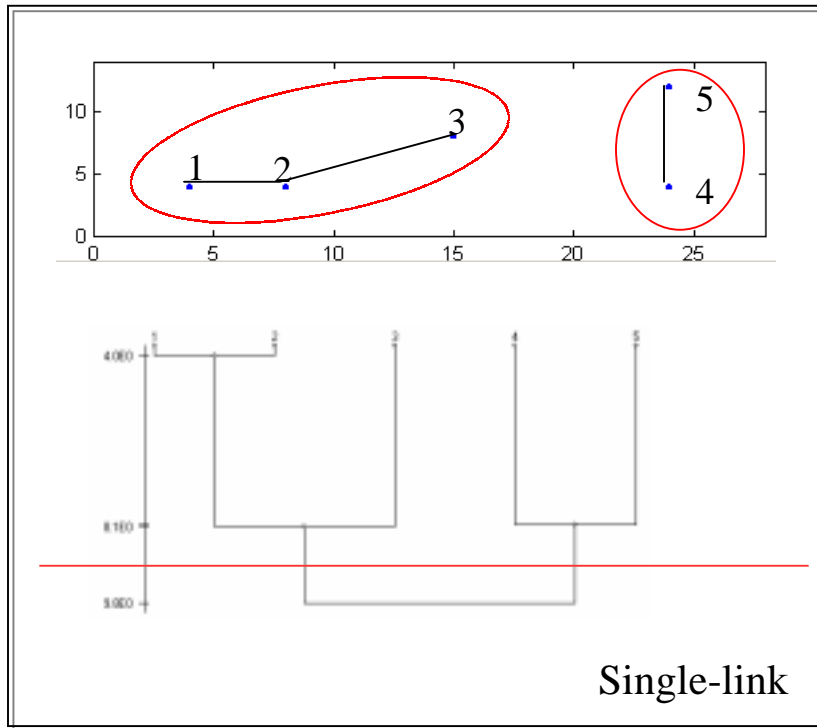
Clustering



| | 1,2,3 | 4,5 |
|-------|-------|------|
| 1,2,3 | - | 21.5 |
| 4,5 | 21.5 | - |



Clustering



Técnicas Particionais de Clustering

• Algoritmo de Lloyd-Max Generalizado

- $x \in \mathfrak{R}^d$, com f.d.p. $p(x)$ conhecida
- Pretende-se calcular uma partição $\{R_1, \dots, R_c\}$ de \mathfrak{R}^d sendo cada classe representada por um vector $\hat{x}_i \in \mathfrak{R}^d$ designado por centroide
- A escolha dos centroides e da partição é feita por forma a minimizar a funcional de custo

$$D = E\{d(x, q(x))\}$$

com

- » $q(x)$ uma função que transforma cada vector x no centroide da sua classe, $\hat{x}_i \in \mathfrak{R}^d$
- » $d(.,.)$ – medida de distância em \mathfrak{R}^d

- Seja P_i a função característica do conjunto i

$$P_i(x) = \begin{cases} 1 & \text{se } x \in R_i \\ 0 & \text{caso contrário} \end{cases}$$

$$\therefore D = E\left\{\sum_{i=1}^c P_i(x)d(x, \hat{x}_i)\right\}$$

- O classificador obtém-se calculando uma partição e um conjunto de representantes que minimizem D

• **Decomposição do problema em dois problemas mais simples:**

1. Admite-se conhecida a partição do espaço e calcula-se o conjunto óptimo de centroides
2. Admitem-se conhecidos os centroides e calcula-se a partição óptima do espaço

1: Seja $\{R_1, \dots, R_C\}$ uma partição do espaço. Pretende-se calcular $\hat{x}_1, \hat{x}_2, \dots, \hat{x}_C$ por forma a minimizar D . Admitindo que D é diferenciável, uma condição necessária para o mínimo é:

$$\frac{\partial D}{\partial \hat{x}_p} = 0, \quad p = 1, \dots, C$$

Como as funções de pertença só dependem da partição, vem:

$$\frac{\partial D}{\partial \hat{x}_p} = \frac{\partial}{\partial \hat{x}_p} E \left\{ \sum_{i=1}^C P_i(x) d(x, \hat{x}_i) \right\} = E \left\{ P_p(x) \frac{\partial}{\partial \hat{x}_p} d(x, \hat{x}_p) \right\} = 0$$

ou seja

$$\int_{R_p} p(x) \frac{\partial}{\partial \hat{x}_p} d(x, \hat{x}_p) dx = 0 \quad p = 1, \dots, C$$

- No caso em que $d(.,.)$ é o quadrado da norma Euclideana

$$d(x, \hat{x}) = (x - \hat{x})^T (x - \hat{x})$$

tem-se

$$\int_{R_p} p(x) \frac{\partial}{\partial \hat{x}_p} (x - \hat{x}_p)^T (x - \hat{x}_p) dx = \int_{R_p} -2p(x)(x - \hat{x}_p) dx = 0$$

$$\int_{R_p} p(x) \hat{x}_p dx = \int_{R_p} xp(x) dx$$

$$\hat{x}_p = \frac{\int_{R_p} xp(x) dx}{\int_{R_p} p(x) dx}$$

2: Suponhamos agora que os centroides são conhecidos. Qual a partição que minimiza D ?

$$D = E \left\{ \sum_{i=1}^c P_i(x) d(x, \hat{x}_i) \right\}$$

A minimização de D pode ser feita minimizando a função integrada em cada ponto x

$$D_x = \sum_{i=1}^c P_i(x) d(x, \hat{x}_i)$$

Esta função é minimizada se x for classificada na classe do centroide mais próximo:

$$\omega_k : k = \arg \min_i d(x, \hat{x}_i)$$

- A resolução simultânea das equações anteriores não é fácil. A solução adoptada consiste em estimar alternadamente os centroides e a partição do espaço.

Algoritmo de Lloyd-Max Generalizado I

- Hipótese: $p(x)$ conhecido

1. Inicialização

Escolha o nº C de classes e inicialize os centroides de cada classe de acordo com algum critério

2. Cálculo da partição

Calcule a partição de \mathfrak{R}^d associando cada ponto à região com centroide mais próximo

$$x \in R_k : k = \arg \min_{i=1,\dots,C} d(x, \hat{x}_i)$$

3. Actualização dos centroides

Calcule novos centroides para cada uma das classes através da equação

$$\int_{R_p} p(x) \frac{\partial}{\partial \hat{x}_p} d(x, \hat{x}_p) dx = 0 \quad p = 1, \dots, C$$

- Se $d(.,.)$ é o quadrado da norma Euclideana

$$\hat{x}_p = \frac{\int_{R_p} xp(x)dx}{\int_{R_p} p(x)dx} \quad p = 1, \dots, C$$

4. Voltar ao ponto 2 até se verificar um critério de paragem

- Na prática, raramente se conhece a f.d.p $p(x)$
- Um procedimento muito utilizado consiste em substituir a esperança matemática pela média sobre todos os padrões de treino, ou seja

$$D = \sum_{x \in X} d(x, q(x))$$

- Os algoritmos de Forgy e k-médias têm por objectivo minimizar o quadrado do erro para um número fixo de clusters

$$D = \sum_{i=1}^C \sum_{j=1}^{N_i} (x_j - \mu_i)^T (x_j - \mu_i)$$

Algoritmo de Lloyd-Max Generalizado II

- **Hipótese: X conhecido**

1. Inicialização

Escolha o nº C de classes e inicialize os centroides de cada classe de acordo com algum critério

2. Cálculo da partição

Calcule a partição $\{X_1, X_2, \dots, X_C\}$ de \mathcal{R}^d associando cada ponto à região com centroide mais próximo

$$x \in X_k : k = \arg \min_{i=1, \dots, C} d(x, \hat{x}_i)$$

3. Actualização dos centroides

Calcule novos centroides para cada uma das classes através da equação

$$\sum_{x \in X_p} \frac{\partial}{\partial \hat{x}_p} d(x, \hat{x}_p) = 0 \quad p = 1, \dots, C$$

em que X_p designa o conj. de pontos atribuídos à p -ésima classe

- **Se $d(.,.)$ é o quadrado da norma Euclideana**

$$\hat{x}_p = \frac{1}{N_p} \sum_{x \in X_p} x \quad p = 1, \dots, C$$


4. Voltar ao ponto 2 até se verificar um critério de paragem

Técnicas Particionais de Clustering

- **Algoritmo de Forgy**
- **Input:**
 - C: número de clusters
 - C padrões seleccionados aleatoriamente, designados pontos semente
- 1. Inicializar os centroides dos clusters nos pontos semente
- 2. Para cada amostra, determinar o centroide mais próximo. Colocar a amostra nesse cluster
- 3. Se nenhuma amostra mudou de cluster no passo 2, parar
- 4. Calcular os centroides dos clusters resultantes e voltar ao passo 2.


Ex: Algoritmo de Forgy

| | x | y |
|---|----|----|
| 1 | 4 | 4 |
| 2 | 8 | 4 |
| 3 | 15 | 8 |
| 4 | 24 | 4 |
| 5 | 24 | 12 |



Fixe $C=2$

| | Centroide mais próximo |
|---|------------------------|
| 1 | (4,4) |
| 2 | (8,4) |
| 3 | (8,4) |
| 4 | (8,4) |
| 5 | (8,4) |




Cálculo do novo centroide para o 2º cluster:

$$\mu_2 = (\bar{x}, \bar{y})$$

$$\bar{x} = \frac{8+15+24+24}{4} = 17.75 \quad \bar{y} = \frac{4+8+4+12}{4} = 7.0$$

Nova iteração:

| | Centroide mais próximo |
|---|------------------------|
| 1 | (4,4) |
| 2 | (4,4) |
| 3 | (17.75,7) |
| 4 | (17.75,7) |
| 5 | (17.75,7) |




Uma vez que algumas amostras mudaram de cluster, repetir o cálculo dos centroides e prosseguir:

$$\mu_1 = \left(\frac{4+8}{2}, 4 \right) = (6,4)$$

$$\mu_2 = \left(\frac{15+24+24}{3}, \frac{8+4+12}{3} \right) = (21,8)$$

Nova iteração:

| | Centroide mais próximo |
|---|------------------------|
| 1 | (6,4) |
| 2 | (6,4) |
| 3 | (21,8) |
| 4 | (21,8) |
| 5 | (21,8) |




- **Algoritmo k-médias**
- **Diferença em relação ao Forgy:**
 - Os centroides dos clusters são recalculados logo que uma amostra é adicionada a um luster
 - Só executa dois passos sobre os dados
- **Input:**
 - C: número de clusters
 - C padrões seleccionados aleatoriamente, designados pontos semente
- 1. **Começar com C clusters, cada um com uma amostra semente. Para cada uma das N-C amostras restantes, encontrar o centroide mais próximo. Colocar a amostra nesse cluster e recalculando o centroide do cluster alterado.**
- 2. **Ir ao longo de todas as amostras uma segunda vez. Para cada amostra, encontrar o centroide mais próximo e colocá-la nesse cluster (neste passo não são recalculados os centroides).**

Clustering k-médias: C=2


Começar por ex. com os clusters $\{(8,4)\}$ e $\{(24,4)\}$

| | x | y |
|---|----|----|
| 2 | 8 | 4 |
| 4 | 24 | 4 |
| 3 | 15 | 8 |
| 1 | 4 | 4 |
| 5 | 24 | 12 |




| Cluster | Centroide |
|---------|-----------|
| (8,4) | (8,4) |
| (24,4) | (24,4) |

Ponto seguinte: (15,8) -> está mais perto de (8,4)




| Cluster | Centroide |
|-------------|-----------|
| (8,4)(15,8) | (11.5,6) |
| (24,4) | (24,4) |

Ponto seguinte: (4,4) -> está mais perto de (11.5,6)



| Cluster | Centroide |
|------------------|-----------|
| (8,4)(15,8)(4,4) | (9,5.3) |
| (24,4) | (24,4) |

Ponto seguinte: (24,12) -> está mais perto de (24,4)



| Cluster | Centroide |
|------------------|-----------|
| (8,4)(15,8)(4,4) | (9,5.3) |
| (24,4)(24,12) | (24,8) |

Passo 2: não há necessidade de alteração dos clusters.