

# Aprendizado de Máquina

## Agrupamento de dados

André C. P. L. F. de Carvalho  
ICMC-USP



# Introdução

- Nem sempre os dados em um conjunto estão rotulados
  - Custo
  - Impossibilidade
- Conhecimento útil e relevante pode ser extraídos de dados não rotulados
  - Grupos de dados similares

© André de Carvalho - ICMC/USP

4

# Tópicos

- Agrupamento de dados
- Dificuldades em agrupamento
- Algoritmos de agrupamento
- Validação
- Aplicações

© André de Carvalho - ICMC/USP

2

# Agrupamento

- Organização de um conjunto de objetos em grupos (clusters)
  - Não existe uma definição precisa
  - Particiona objetos de acordo com alguma relação entre eles
  - Busca partição que maximiza:
    - Similaridade entre objetos de um mesmo grupo e
    - Dissimilaridade entre objetos de grupos diferentes

© André de Carvalho - ICMC/USP

5

# Introdução



© André de Carvalho - ICMC/USP

3

# Agrupamento

- Supor os objetos:



Como particionar?

© André de Carvalho - ICMC/USP

6

## Agrupamento

Forma

Cor

Forma e cor

© André de Carvalho - ICMC/USP 7

## Possíveis formatos

Compacto

Alongado

Elipsoidal

Espiral

© André de Carvalho - ICMC/USP 10

## Agrupamento de dados

Algoritmo de agrupamento

© André de Carvalho - ICMC/USP 8

## Tipos de agrupamento

- Seja  $X = \{x_1, x_2, \dots, x_n\}$  o conjunto de todos os dados
  - Tarefa: colocar cada  $x_i$  em um dos  $k$  clusters  $C_1, C_2, \dots, C_k$
- De acordo com a pertinência dos dados, agrupamentos podem ser de dois tipos:
  - Tipo 1: duro (crisp)
  - Tipo 2: fuzzy

© André de Carvalho - ICMC/USP 11

## Quantos grupos?

Dados originais

2 grupos

4 grupos

6 grupos

© André de Carvalho - ICMC/USP 9

## Tipos de agrupamento

- Agrupamento crisp
  - Cada objeto  $x_i$  pertence ou não a cada cluster  $C_j$ 

$$C_i \neq \emptyset, i = 1, \dots, k \quad \bigcup_{i=1}^k C_i = X$$

$$C_i \cap C_j = \emptyset, i \neq j, i, j \in \{1, 2, \dots, k\}$$
  - Objeto em  $C_i$  é mais semelhante a outros objetos em  $C_i$  do que àqueles em  $C_j, i \neq j$

© André de Carvalho - ICMC/USP 12

## Tipos de agrupamento

- Agrupamento fuzzy
  - Usa uma função de pertinência para definir o quanto um elemento pertence a um grupo
 
$$Pert_j : x_i \rightarrow [0, 1]$$

$Pert_j$  = pertinência ao grupo  $j$   
 $k$  = número de grupos  
 $n$  = número de objetos

$$\sum_{j=1}^k Pert_j(x_i) = 1, i \in \{1, \dots, n\}$$

$$0 < \sum_{i=1}^n Pert_j(x_i) \leq n, j \in \{1, \dots, k\}$$

© André de Carvalho - ICMC/USP 13

## Agrupamento de dados

- Diferentes partições podem ser encontradas
  - Por diferentes algoritmos
    - Utilizam critérios diferentes para buscar uma boa partição
  - Pelo mesmo algoritmo
    - Diferentes inicializações
    - Diferentes números de grupos

© André de Carvalho - ICMC/USP 16


## Objetivo

- Encontrar partição que maximiza similaridade
  - Minimiza dissimilaridade
  - Quanto maior a homogeneidade dentro dos grupos e a diferença entre os grupos, melhor
- Alternativas
  - Busca exaustiva
  - Algoritmos de agrupamento de dados

© André de Carvalho - ICMC/USP 14

## Algoritmos de agrupamento

- Principais abordagens
  - Particionais
    - Protótipos (erro quadrático médio)
    - Densidade
  - Hierárquicos
  - Baseados em grids (grades)
  - Baseados em grafos



© André de Carvalho - ICMC/USP 17


## Busca exaustiva

- Tentar todos os possíveis agrupamentos de  $k$  grupos (para vários valores de  $k$ )
- Números de Stirling do segundo tipo
  - Número de formas de particionar  $n$  dados em  $k$  subconjuntos não vazios
$$\gg \binom{n}{k} \geq \left(\frac{n}{k}\right)^k$$

$k$  = número de grupos  
 $n$  = número de objetos
- Impraticável


© André de Carvalho - ICMC/USP 15

## Particional X Hierárquico



© André de Carvalho - ICMC/USP 18

## Agrupamento hierárquico



## Algoritmo k-médias

- Supor  $n$  objetos  $x_1, x_2, \dots, x_n$  a serem agrupados em  $k$  clusters,  $k < n$ 
  - Seja  $\mu_i$  a média dos objetos do cluster  $C_i$
  - Seja  $d$  uma medida de distância
    - $x_p \in \text{cluster } C_i$  se  $d(x_p, \mu_i)$  for menor que todas as  $k-1$  distâncias entre  $x_p$  e  $\mu_j$ ,  $j = 1, 2, \dots, k$  e  $i \neq j$

© André de Carvalho - ICMC/USP

22

## Algoritmos particionais

- Principais características
  - Produzem um único agrupamento (partição)
  - A maioria utiliza abordagem "gulosa" (*greedy*)
    - Busca pela melhor alternativa no momento, sem considerar futuras consequências
    - Uma vez tomada uma decisão, não volta atrás
    - Geralmente resultado depende da ordem de apresentação dos exemplos

© André de Carvalho - ICMC/USP

20

## Algoritmo k-médias

Mais formal

- 1 Sugerir  $k$  centros iniciais  $\mu_1, \mu_2, \dots, \mu_k$
  - 2 Repetir
    - Para  $i$  variando de 1 a  $n$  # Numero de objetos  
Colocar objeto  $x_i$  no cluster  $C_i$  com média  $\mu_i$  mais semelhante a ele
    - Para  $i$  variando de 1 a  $K$  # Numero de grupos  
Substituir  $\mu_i$  pela média de todos os objetos do cluster  $C_i$
- Até nenhuma das médias mudar

© André de Carvalho - ICMC/USP

23


## Algoritmos particionais

- K-médias (K-médias ótimo, K-médias sequencial)
- SOM
- FCM
- DENCLUE
- CLICK
- CAST
- SNN

© André de Carvalho - ICMC/USP

21

## Algoritmo k-médias



© André de Carvalho - ICMC/USP

24

## Algoritmo k-médias

- Médias iniciais
  - Objetos (vetores) aleatoriamente gerados
  - Objetos aleatoriamente escolhidos do conjunto de treinamento
  - Objetos bem diferentes entre si

© André de Carvalho - ICMC/USP 25

## Densidades diferentes

Grupos verdadeiros      K-médias (3 grupos)

© André de Carvalho - ICMC/USP 28

## Limitações do k-médias

- Escolha do valor de K
  - Tentativa e erro ou automática
- Algoritmos K-médias tem problemas quando:
  - Grupos têm diferentes densidades
  - Grupos têm formatos não hiper-esféricos
  - Atributos estão em diferentes escalas
- Tem problemas também quando os dados contêm *outliers*

© André de Carvalho - ICMC/USP 26

## Formatos não hiperesféricos

Grupos verdadeiros      K-médias (2 grupos)

© André de Carvalho - ICMC/USP 29

## Grupos encontrados

Grupos verdadeiros      K-médias (3 grupos)

© André de Carvalho - ICMC/USP 27

## Exercício

- Agrupar, utilizando k-médias, os dados abaixo em 2 grupos:
  - $X_1 = 1, 0, 1, 1$
  - $X_2 = 0, 1, 0, 0$
  - $X_3 = 0, 1, 1, 0$
  - $X_4 = 1, 1, 1, 1$
  - $X_5 = 0, 1, 0, 1$

© André de Carvalho - ICMC/USP 30

## Algoritmos hierárquicos

- Utilizam diagrama de árvore (dendograma)
  - Produz uma sequência (hierarquia) de agrupamentos
- Historicamente usados em áreas que trabalham com estruturas hierárquicas
  - Taxonomias
  - Ex.: Biologia e arqueologia

## Esquema Aglomerativo Generalizado (EAG)

```
1 Inicializar  $P_0 = \{\{x_1\}, \dots, \{x_n\}\}$ ,  $t = 0$ 
2 Para  $t = 1$  até  $n - 1$  faça
    Encontrar o par de grupos mais próximos  $(C_i, C_j)$ 
     $P_t = (P_{t-1} - \{C_i, C_j\}) \cup \{\{C_i \cup C_j\}\}$ 
    /* atualiza centro
    /* Número de chamadas a  $d(C_i, C_j)$  é  $O(n^2)$ 
    /* Esse número pode ser reduzido
```

## Algoritmos hierárquicos

- Tipos:
  - Aglomerativos: combinam, repetidamente, dois grupos em um
    - A cada passo, combinam os dois grupos atuais mais próximos em um novo grupo
  - Divisivos: Dividem, repetidamente, um grupo em dois
    - A cada passo, dividem o grupo atual menos homogêneo em dois novos grupos

## Algoritmos hierárquicos


- Existe uma grande variedade de algoritmos hierárquicos
  - Geralmente diferem na forma de calcular distância entre grupos

$$d_{AB} = \min_{\substack{i \in A \\ j \in B}}(d_{ij}) \quad \text{Por ligação simples (single-link)}$$

$$d_{AB} = \max_{\substack{i \in A \\ j \in B}}(d_{ij}) \quad \text{Por ligação completa (complete-link)}$$

$$d_{AB} = \frac{1}{n_A n_B} \sum_{i \in A} \sum_{j \in B} d_{ij} \quad \text{Pela média do grupo (average-link)}$$

## Exemplo



## Validação de agrupamentos

- Como avaliar os clusters gerados por um algoritmo de agrupamento?
  - Especialista no domínio dos dados
    - Demorado para grandes conjuntos de dados
    - Subjetivo
  - Existem várias medidas de validação para agrupamento de dados
    - Julgam aspectos diferentes

## Medidas de validação

- Podem ser divididas em três grupos
  - Índices ou critérios internos
    - Medem a qualidade da partição obtida sem considerar informações externas
  - Índices ou critérios relativos
    - Usados para comparar duas partições ou grupos
  - Índices ou critérios externos
    - Medem o quanto os rótulos dos grupos coincidem com a classe verdadeira

© André de Carvalho - ICMC/USP 37

## Silhueta

- Para cada objeto  $x_i$  de um conjunto de dados
  - $a(x_i)$ : distância média de  $x_i$  aos outros objetos de seu cluster
  - $b(x_i)$ : min (distância média de  $x_i$  a todos os objetos nos outros clusters)
$$s(x_i) = \begin{cases} 1 - a(x_i)/b(x_i), & \text{se } a(x_i) < b(x_i) \\ 0, & \text{se } a(x_i) = b(x_i) \\ b(x_i)/a(x_i) - 1, & \text{se } a(x_i) > b(x_i) \end{cases}$$
  - Largura média da silhueta
    - Média de  $s(x)$  de todos os objetos do conjunto de dados
    - Valor entre -1 e 1 (quanto mais próximo de 1, melhor)

© André de Carvalho - ICMC/USP 40

## Medidas internas

- Muitas são baseadas em:
  - Coesão de clusters
    - Mede o quão próximos estão os objetos dentro de um cluster
  - Separação de clusters
    - Mede o quão separado cada cluster está dos demais clusters

© André de Carvalho - ICMC/USP 38

## Exemplo

- Agrupar, utilizando k-médias, os dados abaixo em 2 grupos e em 3 grupos:
  - $X_1 = 1, 0, 1, 1$
  - $X_2 = 0, 1, 0, 0$
  - $X_3 = 0, 1, 1, 0$
  - $X_4 = 1, 1, 1, 1$
  - $X_5 = 0, 1, 0, 1$
- Calcular valor da silhueta para as duas partições

© André de Carvalho - ICMC/USP 41

## Silhueta

- Combina coesão com separação
- Calculada para cada objeto que faz parte de um agrupamento
  - Baseada em:
    - Distância entre os objetos de um mesmo cluster e
    - Distância dos objetos de um cluster ao cluster mais próximo

© André de Carvalho - ICMC/USP 39

## Exercício

- Seja o seguinte cadastro de pacientes:

Nome	Febre	Enjôo	Manchas	Dores	Diagnóstico
João	sim	sim	pequenas	sim	doente
Pedro	não	não	grandes	não	saudável
Maria	sim	sim	pequenas	não	saudável
José	sim	não	grandes	sim	doente
Ana	sim	não	pequenas	sim	saudável
Leila	não	não	grandes	sim	doente

© André de Carvalho - ICMC/USP 42

## Exercício

- Agrupar os dados em grupos usando o algoritmo K-médias e medida de silhueta
  - Usar  $k = 2$  e  $k = 3$
  - Informação sobre a classe não deve ser usada
  - Usar distância bloco-cidade
- Em que grupos seriam colocados os exemplos abaixo?
  - (Luis, não, não, pequenas, sim)
  - (Laura, sim, sim, grandes, sim)

© André de Carvalho - ICMC/USP

43

## Considerações finais

- Agrupamento de dados é umas das principais tarefas de AM
  - Várias definições de agrupamento
  - Diversos algoritmos
- Validação das partições encontradas
- Custo de rotular exemplos
  - Aprendizado semi-supervisionado
  - Aprendizado ativo

© André de Carvalho - ICMC/USP

46

## Exercício

- Agrupar os dados usando o algoritmo hierárquico aglomerativo visto em aula
  - Usar distância bloco-cidade
  - Informação sobre a classe não deve ser usada
- Em que grupos das partições com 2 e 3 grupos ficariam os exemplos abaixo?
  - (Luis, não, não, pequenas, sim)
  - (Laura, sim, sim, grandes, sim)

© André de Carvalho - ICMC/USP

44

## Perguntas



© André de Carvalho - ICMC/USP

47

## Tarefa

- Usando o algoritmo de agrupamento hierárquico aglomerativo, construir um equivalente, só que divisivo
- Aplicar k-médias e um algoritmo de agrupamento hierárquico ao conjunto de dados do kaggle usado nas tarefas anteriores

© André de Carvalho - ICMC/USP

45