

# Mineração de Dados em Biologia Molecular

## Agrupamento de dados

Docente: André C. P. L. F. de Carvalho  
PAE: Victor Hugo Barella



## Tópicos

- Aprendizado de máquina descritivo
- Medidas de distância
- Agrupamento de dados
- Algoritmos de agrupamento
- Validação
- Aplicações

© André de Carvalho - ICMC/USP

2

## Algoritmos de AM descritivos

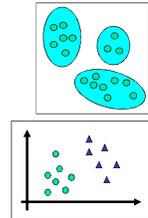
- Descrevem ou resumizam um conjunto de dados
- Indução de modelo (treinamento) usa todo o conjunto de dados
  - Geralmente indução ocorre por aprendizado não supervisionado
    - E.X.: Agrupamento de dados

© André de Carvalho - ICMC/USP

3

## AM e Geometria

- Vários algoritmos de AM são baseados em medidas de distância (MD)
- MD podem ser usadas para:
  - Agrupar dados
    - Ex.: K-médias
  - Prever a classe de novos dados
    - Ex.: K-NN

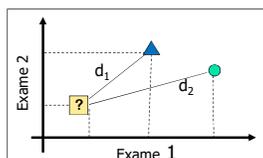


© André de Carvalho - ICMC/USP

4

## Medidas de distância

- Consideram proximidade entre dados
  - Similaridade
  - Dissimilaridade



- Existem várias
  - Euclidiana
  - Norma máxima
  - Bloco-cidade
  - ...

© André de Carvalho - ICMC/USP

5

## Distância de Minkowski

- Medida de distância generalizada
$$dist(p, q) = \left( \sum_{k=1}^m |p_k - q_k|^r \right)^{\frac{1}{r}}$$
- Valor de r leva a diferentes distâncias:
  - 1 ( $L_1$ ): Distância bloco cidade
  - 2 ( $L_2$ ): Distância Euclidiana

© André de Carvalho - ICMC/USP

6

## Medidas de distância

- Distância de norma máxima
  - Menor complexidade e exatidão
$$dist(p, q) = MAX(|p_k - q_k|)$$
- Distância Bloco cidade (Manhattan)
  - Usa  $r = 1$ 

$$dist(p, q) = \sum_{k=1}^m |p_k - q_k|$$
  - Distância de *Hamming*, se valores são binários
    - Ex.  $dist(011, 101)$

© André de Carvalho - ICMC/USP 7

## Medidas de distância

- Distância Euclidiana
  - Usa  $r = 2$
  - Sistema de coordenadas cartesianas
$$dist(p, q) = \sqrt{\sum_{k=1}^m (p_k - q_k)^2}$$
  - Medida de distância mais utilizada

© André de Carvalho - ICMC/USP 8

## Medidas de distância

Distância Manhattan

© André de Carvalho - ICMC/USP 9

## Medidas de distância

Distância Manhattan

© André de Carvalho - ICMC/USP 10

## Medidas de distância

Distância Manhattan

Distância Euclidiana

© André de Carvalho - ICMC/USP 11

## Exercício

- Qual das três medidas resulta na maior e na menor distância entre os exemplos abaixo?
  - Manhattan
  - Euclidiana
  - Norma máxima

Ex1 = (3, 1, 10, 2)

Ex2 = (2, 5, 3, 2)

© André de Carvalho - ICMC/USP 12

## Exercício

- Utilizando distância de Manhattan, qual dos pares das coordenadas abaixo é mais semelhante ?
  - (2, 5, 1), (3, 0, 6), (4, 1, 3)

© André de Carvalho - ICMC/USP 13

## Exercício

- Utilizando distância de Manhattan, definir:
  - Qual par dos valores binários abaixo tem a distância mais semelhante à diferença entre seus valores na base decimal
  - 110000, 111001, 000111, 001011, 100111, 101001

© André de Carvalho - ICMC/USP 14

## Exercício

- Para cada medida de distância
  - Quais são os dois exemplos da tabela abaixo mais próximos e os dois mais distantes?
  - Usar distâncias Euclidiana, bloco cidade e de norma máxima

Estado	Escolaridade	Altura	Salário	Classe
SP	Médio	180	3000	A
RJ	Superior	174	7000	B
RJ	Fundamental	100	2000	A

© André de Carvalho - ICMC/USP 15

## Similaridade x Dissimilaridade

- Medidas de distância medem dissimilaridade entre objetos
- Alguns algoritmos utilizam similaridade entre objetos
- Quanto mais similares dois objetos, mais distantes e vice-versa
- Ambos calculam a proximidade entre valores

© André de Carvalho - ICMC/USP 16

## Similaridade x Dissimilaridade

- Similaridade
  - Mede o quão semelhantes são dois objetos
    - Quanto mais parecidos, maior o valor
  - Geralmente valor  $\in [0,0, 1,0]$
- Dissimilaridade
  - Mede o quanto dois objetos são diferentes
    - Quanto mais diferentes, maior o valor
  - Geralmente valor  $\in [0,0, X]$
- Medida de proximidade são usadas nos dois casos

© André de Carvalho - ICMC/USP 17

## Proximidade entre valores

- Sejam a e b dois valores de um atributo
  - Nominal
 
$$d(a,b) = \begin{cases} 1, & \text{se } a \neq b \\ 0, & \text{se } a = b \end{cases}$$
    - $s = 1 - d$
  - Ordinal
 
$$d(a,b) = \frac{|pos_a - pos_b|}{n-1} \quad n = \# \text{valores}$$
    - $s = 1 - d$
  - Intervalar ou racional
 
$$d(a,b) = |a - b|$$
    - $s = 1 - d$  ou  $s = 1/(1+d)$

© André de Carvalho - ICMC/USP 18

## Proximidade entre valores

- Sejam  $a$  e  $b$  dois valores de um atributo
  - Nominal
    - $s = 1 - d$
  - Ordinal
    - $s = 1 - d$
  - Intervalar ou racional
    - $s = 1 - d$  ou  $s = 1/(1+d)$

$$d(a,b) = \begin{cases} 1, & \text{se } a \neq b \\ 0, & \text{se } a = b \end{cases}$$

$$d(a,b) = \frac{|pos_a - pos_b|}{n-1} \quad n = \text{\#valores}$$

$$d(a,b) = |a - b|$$

© André de Carvalho - ICMC/USP 19

## Proximidade entre valores

- Sejam  $a$  e  $b$  dois valores de um atributo

Tipo	Diferença	Semelhança
Nominal	$diff = \begin{cases} 1, & \text{se } a \neq b \\ 0, & \text{se } a = b \end{cases}$	$p = 1 - d$
Ordinal	$diff = \frac{ pos_a - pos_b }{n-1}$ <small><math>n = \text{\#valores}</math></small>	
Intervalar/ Racional	$diff =  a - b $	$p = 1 - d$ ou $p = 1/(1+d)$

© André de Carvalho - ICMC/USP 20

## Similaridade entre vetores binários

- Algumas vezes, objetos  $p$  e  $q$  têm apenas valores binários
  - Ex.: 0110 e 1100
- Similaridades podem ser computadas por:
  - $M_{01}$  = número de atributos em que  $p = 0$  e  $q = 1$
  - $M_{10}$  = número de atributos em que  $p = 1$  e  $q = 0$
  - $M_{00}$  = número de atributos em que  $p = 0$  e  $q = 0$
  - $M_{11}$  = número de atributos em que  $p = 1$  e  $q = 1$

© André de Carvalho - ICMC/USP 21

## Similaridade entre vetores binários

- Coefficiente de Casamento Simples
 
$$CCS = (M_{11} + M_{00}) / (M_{01} + M_{10} + M_{11} + M_{00})$$
- Coefficiente Jaccard
 
$$J = (M_{11}) / (M_{01} + M_{10} + M_{11})$$
- Validação de agrupamento de dados

© André de Carvalho - ICMC/USP 22

## Exercício

- Que medida de similaridade binária gera o maior valor de similaridade entre vetores  $p$  e  $q$ ?

$$p = 100110101110$$

$$q = 010011001011$$

© André de Carvalho - ICMC/USP 23

## Similaridade cosseno

- Muito usado quando dados são textos
  - Bag of words
    - Grande número de atributos
    - Vetores esparsos
- Sejam  $p$  e  $q$  vetores representando documentos
  - $simcos(p, q) = ||p|| ||q|| \cos\theta = (p \cdot q) / (||p|| ||q||)$ 
    - $\cdot$ : vector produto interno entre vetores
    - $||p||$ : é o tamanho (norma) do vetor  $p$

© André de Carvalho - ICMC/USP 24

## Distância cosseno

- Distância angular entre dois vetores
  - Invariante a escala dos atributos
  - 1 – similaridade cosseno

$$dist_{\text{cosseno}} = 1 - \frac{\sum_{k=1}^m p_k \cdot q_k}{\sqrt{\sum_{k=1}^m p_k^2 \cdot \sum_{k=1}^m q_k^2}}$$

© André de Carvalho - ICMC/USP

25

## Distância de Pearson

- Muito usada em bioinformática e séries temporais
  - 1 – correlação entre dois vetores


$$dist_{\text{Pearson}} = 1 - \frac{\sum_{k=1}^m (p_k - \bar{p}) \cdot (q_k - \bar{q})}{\sqrt{\sum_{k=1}^m (p_k - \bar{p})^2 \cdot \sum_{k=1}^m (q_k - \bar{q})^2}}$$

© André de Carvalho - ICMC/USP

26

## Agrupamento

- Organização de um conjunto de objetos em grupos (clusters)
  - Particionar objetos de acordo com alguma relação entre eles

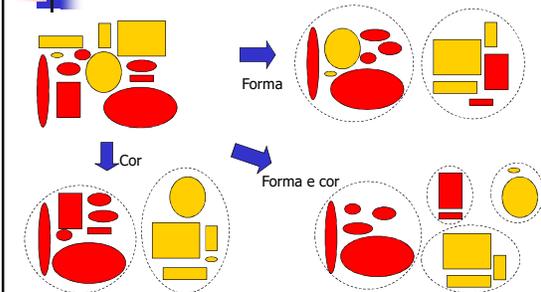


Como particionar?

© André de Carvalho - ICMC/USP

27

## Agrupamento



© André de Carvalho - ICMC/USP

28

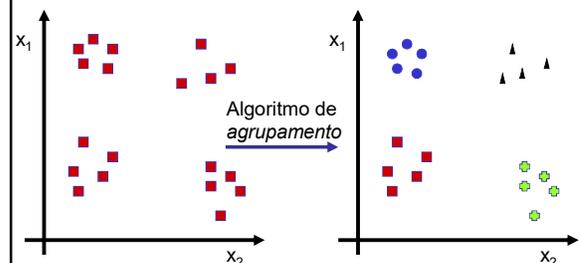
## Agrupamento de dados

- Definição do que é um agrupamento
  - Imprecisa
  - Depende de:
    - Natureza dos dados
    - Resultados desejados
  - Existem várias
  - Partições
    - Grupos ou clusters

© André de Carvalho - ICMC/USP

29

## Agrupamento de dados



© André de Carvalho - ICMC/USP

30

## Possíveis números de clusters

Dados originais

2 clusters

4 clusters

6 clusters

© André de Carvalho - ICMC/USP 31

## Possíveis formatos de clusters

Compacto

Alongado

Elipsoidal

Espiral

© André de Carvalho - ICMC/USP 32

## 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 33

## 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 34

## 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 35

## 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 36

## 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

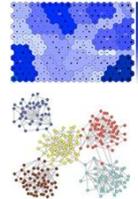
$$\gg \left\{ \begin{matrix} n \\ k \end{matrix} \right\} \geq \left( \frac{n}{k} \right)^k$$

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

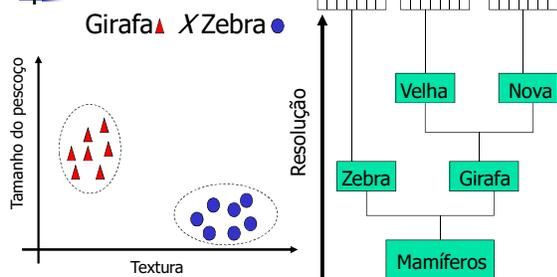
- Impraticável

## Algoritmos de agrupamento

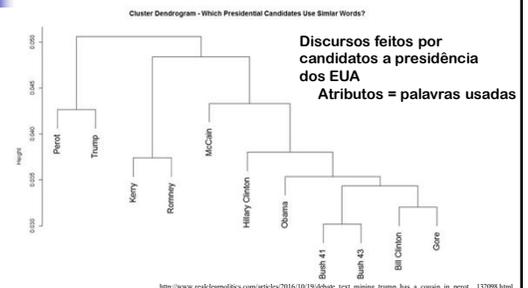
- Principais abordagens
  - Particionais
    - Protótipos (erro quadrático médio)
    - Densidade
  - Hierárquicos
  - Baseados em grids (grades)
  - Baseados em grafos



## Particional X Hierárquico



## Agrupamento hierárquico



## 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

## Algoritmos particionais

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

## 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  $i \neq j$ 
      - $x_p$  é colocado no cluster mais próximo

## 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  $n$ 
    Colocar objeto  $x_i$  no cluster  $C_i$  com
    média  $\mu_i$  mais semelhante a ele
  Para  $i$  variando de 1 a  $K$ 
    Substituir  $\mu_i$  pela média de todos os
    objetos do cluster  $C_i$ 
  Até nenhuma das médias mudar
```

## Algoritmo k-médias

Mais informal

```
1 Sugerir centros iniciais  $\mu_1, \mu_2, \dots, \mu_k$ 
2 Repetir
  Usar as médias sugeridas para colocar
  cada objeto no cluster  $C_i$  mais próximo
  Substituir  $\mu_i$  de cada cluster  $C_i$  pela
  média de todos os objetos de  $C_i$ 
  Até nenhuma das médias mudar
```

## Algoritmo k-médias

- Médias iniciais
  - Objetos (vetores) aleatórios
  - Objetos aleatoriamente escolhidos do conjunto de treinamento
  - Objetos bem diferentes

## Limitações do k-médias

- Escolha do valor de  $K$
- K-médias tem problemas quando:
  - Grupos têm diferentes densidades
  - Grupos possuem formatos não hiper-esféricos
  - Conjunto de dados contém *outliers*

## Exercício

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

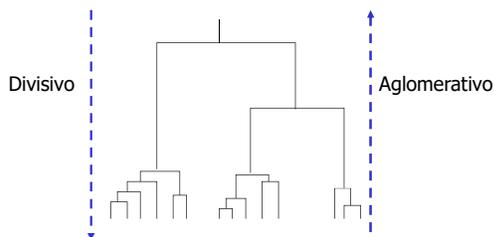
## Algoritmos hierárquicos

- Utilizam diagrama de árvore (dendograma)
  - Produz uma seqüência (hierarquia) de agrupamentos
- Historicamente usados em áreas que empregam estrutura hierárquica
  - Ex.: Biologia e arqueologia

## Algoritmos hierárquicos

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

## Exemplo



## 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 centros
/* Número de chamadas a  $d(C_i, C_j)$  é  $O(n^3)$ 
/* Esse número pode ser reduzido
    
```

## Algoritmos hierárquicos

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

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

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

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

## 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

55

## Medidas internas

- 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

56

## 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

57

## 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  $s$  de todos os objetos do conjunto de dados
    - Valor entre -1 e 1 (quanto mais próximo de 1, melhor)

© André de Carvalho - ICMC/USP

58

## 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

59

## 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

60

## Exercício

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

© André de Carvalho - ICMC/USP

61

## 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

62

## Perguntas?



© André de Carvalho - ICMC/USP

63