

# CLARANS

Diego Raphael Amancio

## Resumo

- Introdução
- PAM
- CLARA
- Modelagem como grafo
- CLARANS
- Comparação de eficiência
- Conclusão

2

## Artigo de Referência [1]

### **Efficient and Effective Clustering Methods for Spatial Data Mining**

Raymond T. Ng  
Department of Computer Science  
University of British Columbia  
Vancouver, B.C., V6T 1Z4, Canada  
rng@cs.ubc.ca

Jiawei Han  
School of Computing Sciences  
Simon Fraser University  
Burnaby, B.C., V5A 1S6, Canada  
han@cs.sfu.ca

*Imagem do artigo original intitulado "Efficient and Effective Clustering Methods for Spatial Data Mining (1994)*

3

## Introdução

- Algoritmo projetado para trabalhar com dados espaciais
  - Banco de dados espaciais geralmente são muito grandes
- Algoritmos tradicionais não são projetados para trabalhar com grandes banco de dados
- Pode ser aplicado para base de dados com outros tipos de atributos, mas só usa os atributos espaciais

4

## Características Gerais

- Baseado em busca aleatória
- Motivado por dois outros algoritmos:
  - PAM
  - CLARA
- Baseado em k-medóides
  - Pode ser empregado em bases relacionais
  - Robusto à outliers
- É mais eficiente que os anteriores

5

## PAM

- Para encontrar  $k$  clusters, determina um objeto representativo para cada cluster (medóide)
  - Medóide deve ser o objeto mais ao centro do cluster
- Após a escolha dos medóides, outros objetos são agrupados em torno do medóide mais próximo
- A qualidade das partições obtidas é dada como a média de todas as dissimilaridades de objetos aos seus respectivos medóides

6


## PAM – Idéia Geral

- Os primeiros  $k$  medóides são escolhidos aleatoriamente
- A cada passo é feita uma troca entre medóide e objeto não selecionado, supondo que a troca melhore a qualidade do agrupamento
- Seja:
  - $O_i \rightarrow$  medóide
  - $O_h \rightarrow$  objeto não selecionado como medóide
  - $C_{jih} \rightarrow$  custo para objeto  $O_j$  de trocar medóide  $O_i$  por objeto  $O_h$
- Quatros tipos de definições para  $C_{jih}$

7

## PAM – Idéia Geral

- Primeiro Caso
  - Condição 1:  $O_j$  no cluster de  $O_i$
  - Condição 2:  $O_j$  é **mais** similar a  $O_{j,2}$  (segundo medóide mais similar a  $O_j$ ) do que a  $O_h$
  - Conclusão: se a substituição de  $O_i$  por  $O_h$ , então  $O_j$  deve pertencer a  $O_{j,2}$




$$C_{jih} = d(O_j, O_{j,2}) - d(O_j, O_i).$$

8

## PAM – Idéia Geral

### ■ Segundo Caso

- Condição 1:  $O_j$  no cluster de  $O_i$
- Condição 2:  $O_j$  é **menos** similar a  $O_{j,2}$  (segundo medóide mais similar a  $O_j$ ) do que a  $O_h$
- Conclusão: se a substituição de  $O_i$  por  $O_h$ , então  $O_j$  deve pertencer a  $O_h$




$$C_{jih} = d(O_j, O_h) - d(O_j, O_i).$$

9

## PAM – Idéia Geral

### ■ Terceiro Caso

- Condição 1:  $O_j$  está em outro cluster: não em  $O_i$
- Condição 2:  $O_j$  é **mais** similar a  $O_{j,2}$  (medóide de  $O_j$ ) do que a  $O_h$
- Conclusão: se a substituição de  $O_i$  por  $O_h$ , então  $O_j$  deve continuar a pertencer  $O_{j,2}$




$$C_{jih} = 0.$$

10

## PAM – Idéia Geral

### ■ Quarto Caso

- Condição 1:  $O_j$  está em outro cluster: não em  $O_i$
- Condição 2:  $O_j$  é **menos** similar a  $O_{j,2}$  (medóide de  $O_j$ ) do que a  $O_h$
- Conclusão: se a substituição de  $O_i$  por  $O_h$ , então  $O_j$  deve pertencer a  $O_h$



$$C_{jih} = d(O_j, O_h) - d(O_j, O_{j,2}),$$

11

## PAM – Idéia Geral

### ■ Custo final da troca:

$$TC_{ih} = \sum_j C_{jih}$$

12

## PAM – O algoritmo

1. Selecionar  $k$  medóides aleatórios
2. Calcular  $TC_{ih}$  para todos os pares de objetos, onde  $O_i$  é medóide e  $O_h$  é objeto
3. Selecionar o par com valor mínimo de custo  $TC_{ih}$ . Se o custo é negativo, fazer a substituição e voltar ao passo 2
4. Caso contrário, para cada objeto não selecionado, encontrar o objeto mais próximo

13

## CLARA

- Clustering Large Applications
- Em vez de encontrar os medóides considerando todos os objetos, faz uma amostragem e aplica o PAM
- Resultados experimentais mostram que 5 amostras de tamanho  $40 + 2k$  são suficientes

14

## CLARA – O algoritmo

- Repetir para  $i = 1$  até 5
  - Amostrar com tamanho  $40 + 2k$  e encontrar  $k$  medóides com PAM
  - Para cada objeto do banco inteiro, determinar o medóide mais próximo
  - Encontrar a qualidade do cluster obtido no passo anterior usando o banco inteiro.
  - Se a qualidade é a melhor encontrada até o momento, armazenar

15


## Modelagem como grafo

- Modelagem de PAM e CLARA como grafo
  - Cada vértice é representado pelo conjunto de  $k$  medóides atuais
    - Ex.:  $v_1 = \{O_{m1}, O_{m2}, \dots, O_{mk}\}$
  - Dois vértices são vizinhos se o conjunto de medóides diferem por apenas um elemento
    - Ex.:  $v_2 = \{O_{mx}, O_{m2}, \dots, O_{mk}\}$  é vizinho de  $v_1$

16

## Modelagem como grafo

- Exemplo com  $n=4$  e  $k=3$



17

## Modelagem como grafo

- Visão de Grafo

- Cada vértice possui  $k(n-k)$  vizinhos
- Cada vértice representa um resultado de clustering, já que define quem são os medóides

18

## Modelagem como grafo

- PAM

- A cada passo, todos os vizinhos do vértice atual são analisados
- O próximo vizinho é escolhido como aquele que mais diminui o custo, até que o mínimo seja obtido
- Se  $n$  e  $k$  é alto, é custoso analisar  $k(n-k)$  vizinhos a cada passo

19

## Modelagem como grafo

- CLARA

- Restringe a busca em subgrafos menores
- Diminui  $n$  e depois constrói o grafo
- Problema: o subgrafo é restringido apenas aos objetos pertencentes à amostra
- Se um dado vértice  $M$  é mínimo é a amostragem não considerou tal vértice, nunca o melhor caso será encontrado

20

# CLARANS

## ■ Características

- Não restringe a busca a um subgrafo
- Exatamente igual ao PAM, mas analisa apenas uma amostra dos vizinhos
- Enquanto CLARA faz amostragem no começo do método, CLARANS faz amostragens a cada passo da busca

21

# O algoritmo

- Parâmetros:
  - *Numlocal* – número de iterações de busca
  - *Maxneighbor* – número máximo de vizinhos analisados a cada passo
- *mincost* (custo atual da melhor partição)  $\leftarrow$  infinito
- 1.  $i \leftarrow 1$  (primeira iteração de busca)
- 2. Setar *current* para um vértice arbitrário
- 3.  $j \leftarrow 1$  (primeiro vizinho analisado)
- 4. Escolher um vizinho aleatório e calcular custo diferencial
- 5. Se vizinho tem custo menor, *current* é setado como vizinho e volta ao passo 3
- 6. Senão,  $j++$ . Se  $j < \text{maxneighbor}$ , vai para passo 4
- 7. Armazena *current* como *bestnode* e custo como *mincost*
- $i++$ . Se  $i > \text{numlocal}$ , retorna *bestnode* como saída, senão retorna ao passo 2

22

# Parâmetros

## ■ *Maxneighbor*

- Quanto maior, mais próximo o algoritmo se torna do PAM

## ■ Experimentos mostram um valor satisfatório para [2]:


- *Numlocal* – 2
- *Maxneighbor* –  $\max\{0.0125 * k (n - k), 250\}$

23

# Comparação de Eficiência

## ■ CLARANS x PAM

- Qualidade dos grupos é semelhante (5 grupos)




24

## Comparação de Eficiência

### ■ CLARANS x CLARA

- Para o mesmo tempo de processamento



25

## Conclusão

- CLARANS é um método baseado em busca em grafo
- Busca é limitada a um subconjunto de vizinhos
  - Eficiência de tempo com relação a PAM
  - Eficiência de qualidade com relação a CLARA

26

## Referências

- [1] Ng, Raymond T and Han, Jiawei. Efficient and Effective Clustering Methods for Spatial Data Mining, 1994.
- [2] G. Piatetsky-Shapiro and W.J. Frawley. Knowledge Discovery in Databases, AAAI/MIT Press, 1991.

27