

SCC5895 – Análise de Agrupamento de Dados

Algoritmos Particionais: Parte I

Prof. Eduardo R. Hruschka

PPG-CCMC / ICMC / USP



Créditos

- Este material consiste de adaptações e extensões dos originais:
 - Elaborados por Eduardo R. Hruschka e Ricardo J.G.B. Campello
 - de (Tan et al., 2006)
 - de E. Keogh (SBBD 2003)
 - de G. Piatetsky-Shapiro (KDNuggets)



Aula de Hoje

- Definições
- Algoritmos Particionais sem Sobreposição
 - k-Means
 - Raízes Históricas e Algoritmo Básico
 - Inicialização e Implementações Eficientes
 - Fundamentação Teórica (perspectiva de otimização)
 - K-Means Paralelo e Distribuído
 - Variantes do k-Means
 - K-Medianas, k-Medóides, ...
 - Estimativa do Número de Grupos k

Definição de Partição de Dados (Revisão)

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

Matriz de Partição

- **Matriz de Partição** é uma matriz com k linhas (no. de grupos) e N colunas (no. de objetos) na qual cada elemento μ_{ij} indica o *grau de pertinência* do j -ésimo objeto (\mathbf{x}_j) ao i -ésimo grupo (\mathbf{C}_i)

$$\mathbf{U}(\mathbf{X}) = \begin{bmatrix} \mu_{11} & \mu_{12} & \cdots & \mu_{1N} \\ \mu_{21} & \mu_{22} & \cdots & \mu_{2N} \\ \vdots & & \ddots & \vdots \\ \mu_{k1} & \mu_{k2} & \cdots & \mu_{kN} \end{bmatrix}$$

- Se essa matriz for **binária**, ou seja, $\mu_{ij} \in \{0,1\}$, e ainda, se a restrição $\sum_i(\mu_{ij}) = 1 \quad \forall j$ for respeitada, então denomina-se:
 - *matriz de partição rígida, exclusiva* ou *sem sobreposição*

Matriz de Partição

- **Exemplo:**

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

$$\mathbf{U}(\mathbf{X}) = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 1 & 1 & 0 & 1 \end{bmatrix}$$

Métodos Particionais (Sem Sobreposição)

- Métodos *particionais* sem sobreposição referem-se a algoritmos de agrupamento que buscam (explícita ou implicitamente) por uma matriz de partição rígida de um conjunto de objetos \mathbf{X}

Encontrar uma Matriz de Partição $U(\mathbf{X})$: Equivale a particionar o conjunto $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ de N objetos em uma coleção $\mathbf{C} = \{\mathbf{C}_1, \mathbf{C}_2, \dots, \mathbf{C}_k\}$ de k grupos disjuntos \mathbf{C}_i tal que $\mathbf{C}_1 \cup \mathbf{C}_2 \cup \dots \cup \mathbf{C}_k = \mathbf{X}$, $\mathbf{C}_i \neq \emptyset$, e $\mathbf{C}_i \cap \mathbf{C}_j = \emptyset$ para $i \neq j$

Particionamento como Problema Combinatório

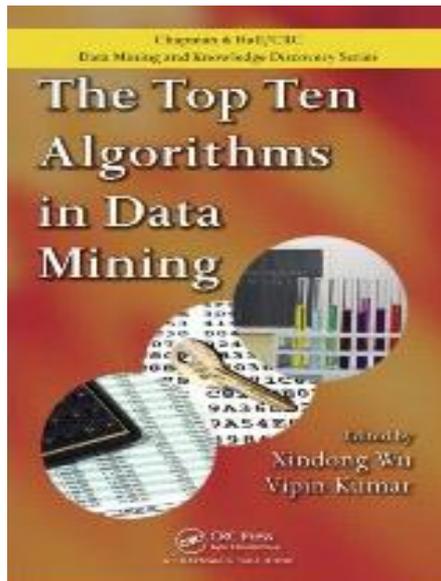
- **Problema:** Assumindo que k seja conhecido, o no. de possíveis formas de agrupar N objetos em k *clusters* é dado por (Liu, 1968):

$$NM(N, k) = \frac{1}{k!} \sum_{i=0}^k (-1)^i \binom{k}{i} (k-i)^N$$

- Por exemplo, $NM(100, 5) \approx 56.6 \times 10^{67}$.
 - Em um computador com capacidade de avaliar 10^9 partições/s, precisaríamos $\approx 1.8 \times 10^{50}$ séculos para processar todas as avaliações
- Como k em geral é desconhecido, problema é ainda maior...
 - **NP-Hard:** Avaliação computacional exaustiva é impraticável...
- **Solução:** formulações alternativas...

Algoritmo k-Means

- ❑ Começaremos nosso estudo com um dos algoritmos mais clássicos da área de **mineração de dados** em geral
 - ❑ algoritmo das **k-médias** ou *k-means*
 - ❑ listado entre os **Top 10 Most Influential Algorithms in DM**



- Wu, X. and Kumar, V. (Editors), *The Top Ten Algorithms in Data Mining*, CRC Press, 2009
- X. Wu et al., "Top 10 Algorithms in Data Mining", *Knowledge and Info. Systems*, vol. 14, pp. 1-37, 2008

Algoritmo k-Means

❑ Referência Mais Aceita como Original:

J. B. MacQueen, *Some methods of classification and analysis of multivariate observations*, In Proceedings 5th Berkeley Symposium on Mathematical Statistics and Probability, Berkeley, California, USA, 1967, 281–297

❑ Porém...

"K-means has a rich and diverse history as it was independently discovered in different scientific fields by Steinhaus (1956), Lloyd (proposed in 1957, published in 1982), Ball & Hall (1965) and MacQueen (1967)" [**Jain, *Data Clustering: 50 Years Beyond K-Means*, *Patt. Rec. Lett.*, 2010**]

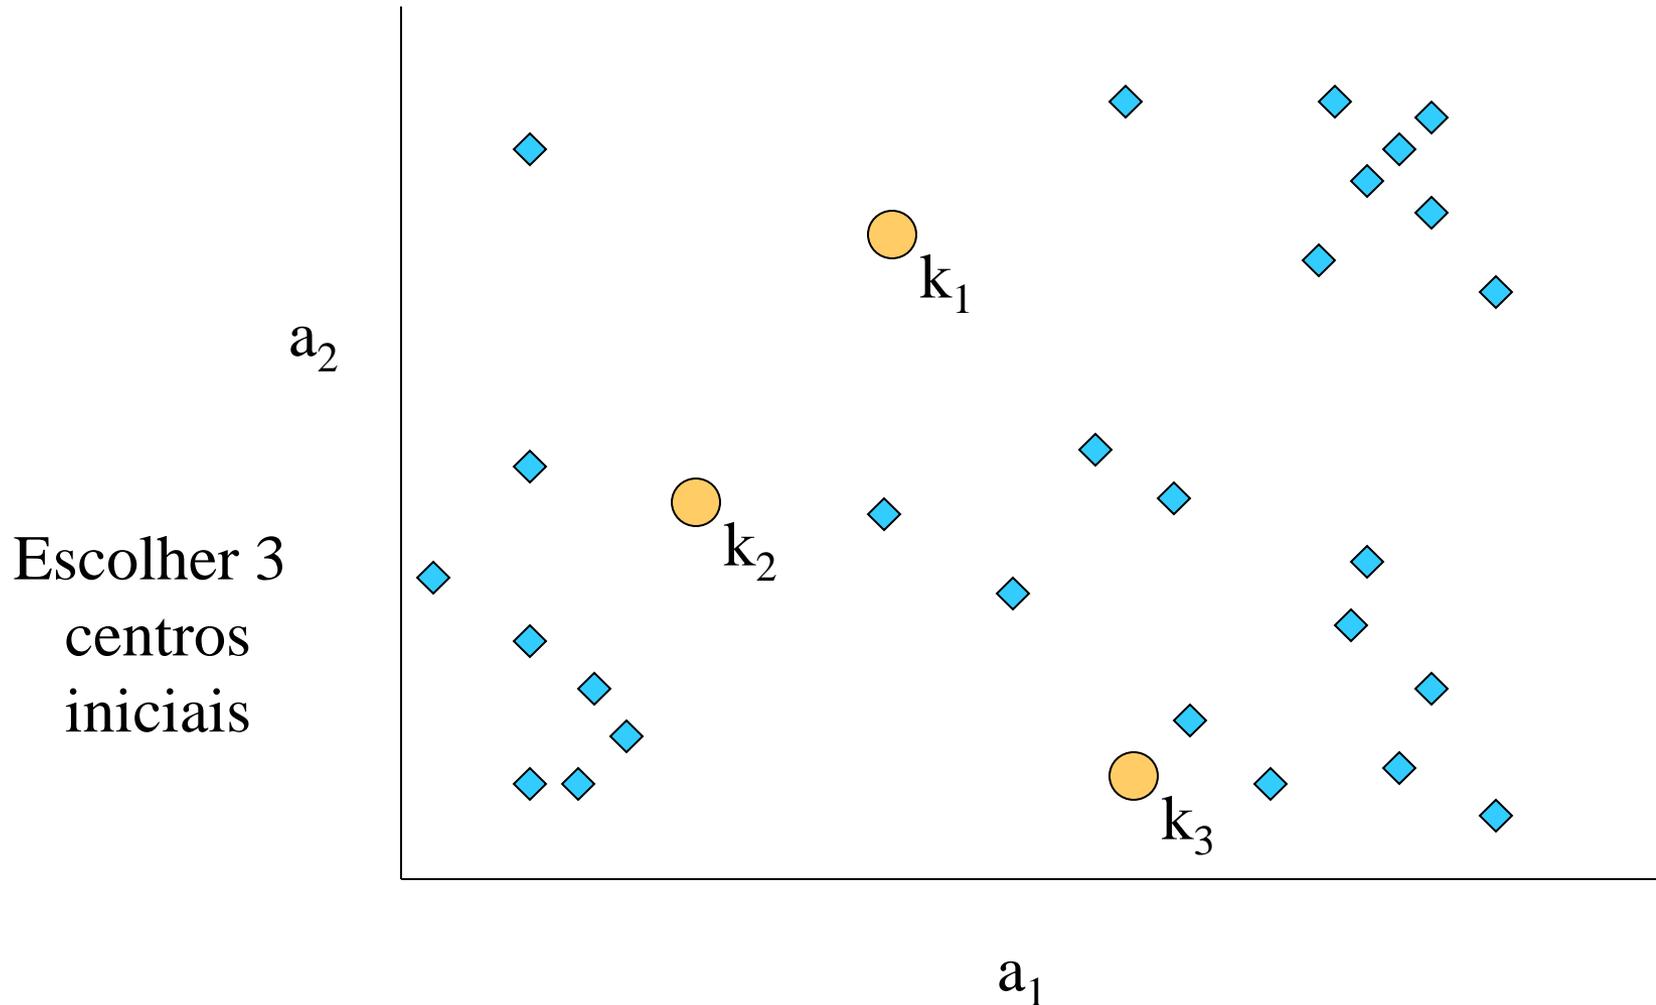
❑ ... e tem sido assunto por mais de meio século !

Douglas Steinley, *K-Means Clustering: A Half-Century Synthesis*, British Journal of Mathematical and Statistical Psychology, Vol. 59, 2006

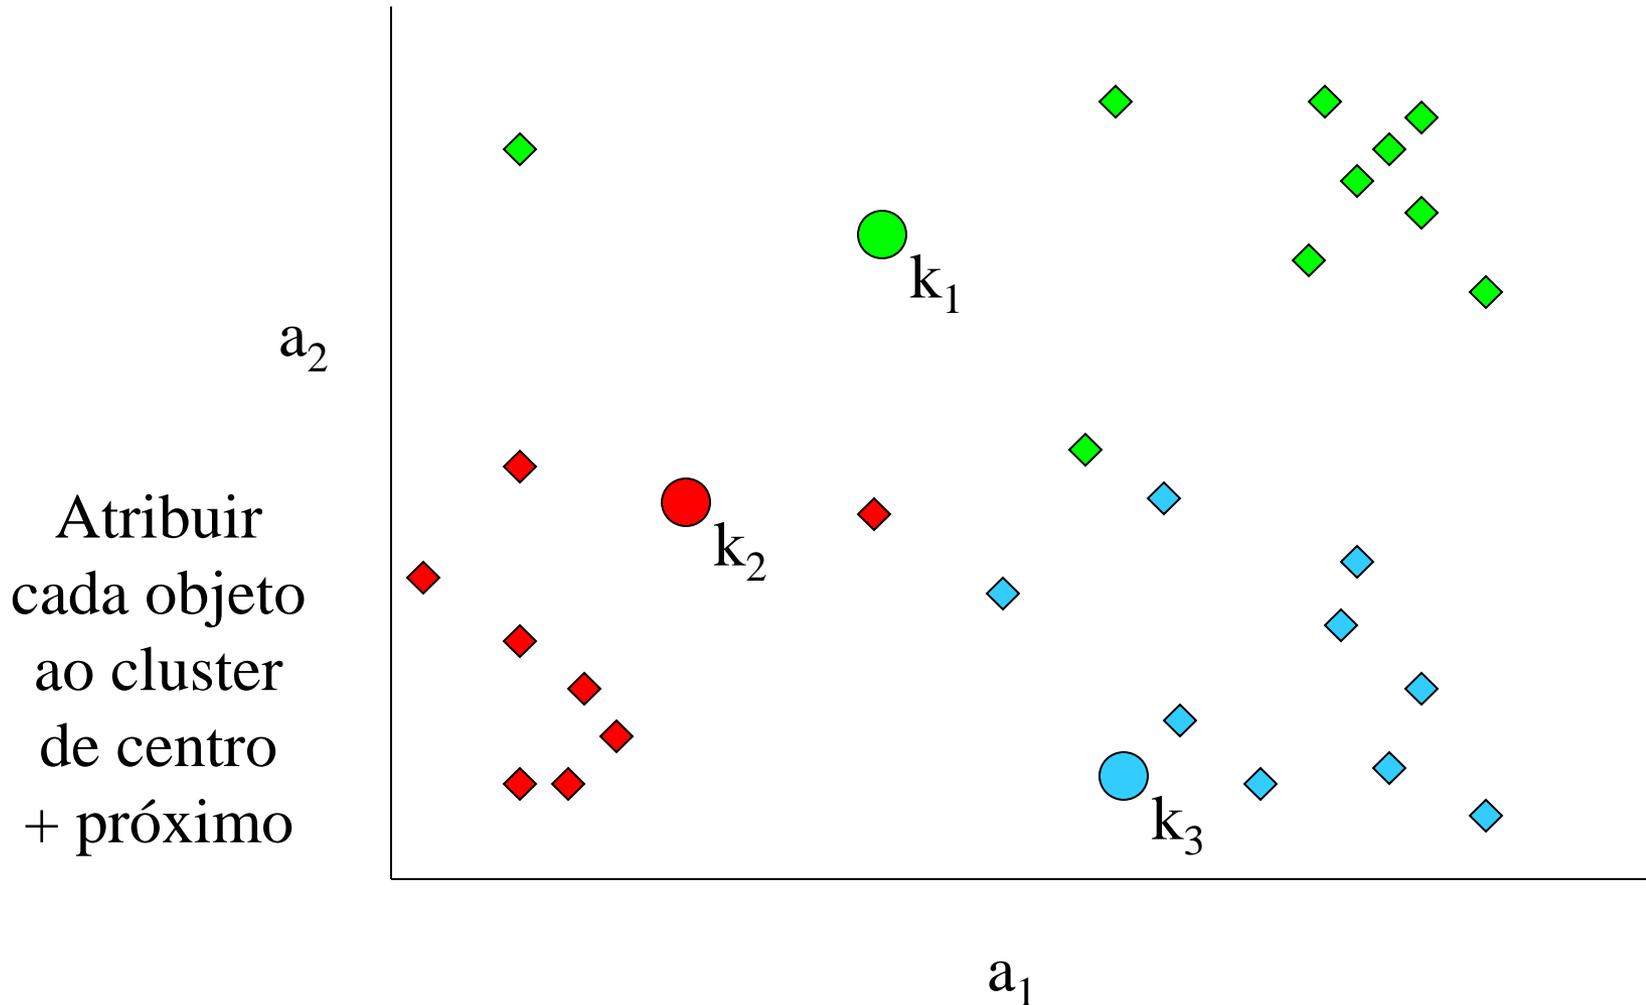
k-Means

- 1) Escolher aleatoriamente um número k de protótipos (centros) para os clusters
- 2) Atribuir cada objeto para o cluster de centro mais *próximo* (segundo alguma distância, e.g. Euclidiana)
- 3) Mover cada centro para a média (centróide) dos objetos do cluster correspondente
- 4) Repetir os passos 2 e 3 até que algum critério de convergência seja obtido:
 - número máximo de iterações
 - limiar mínimo de mudanças nos centróides

k-Means - passo 1:

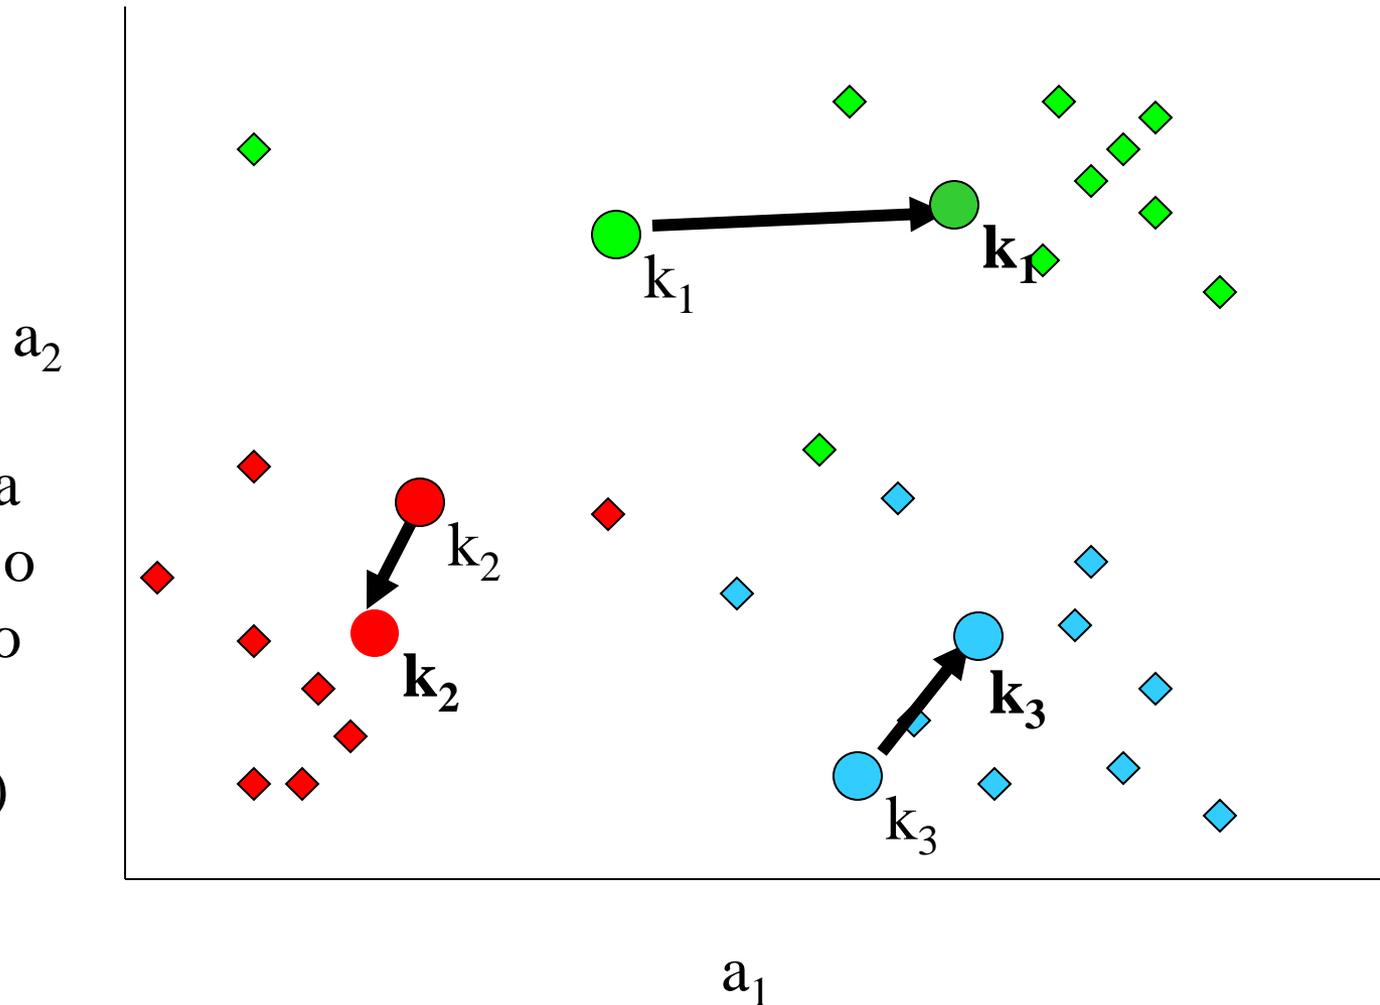


k-Means - passo 2:



k-Means - passo 3:

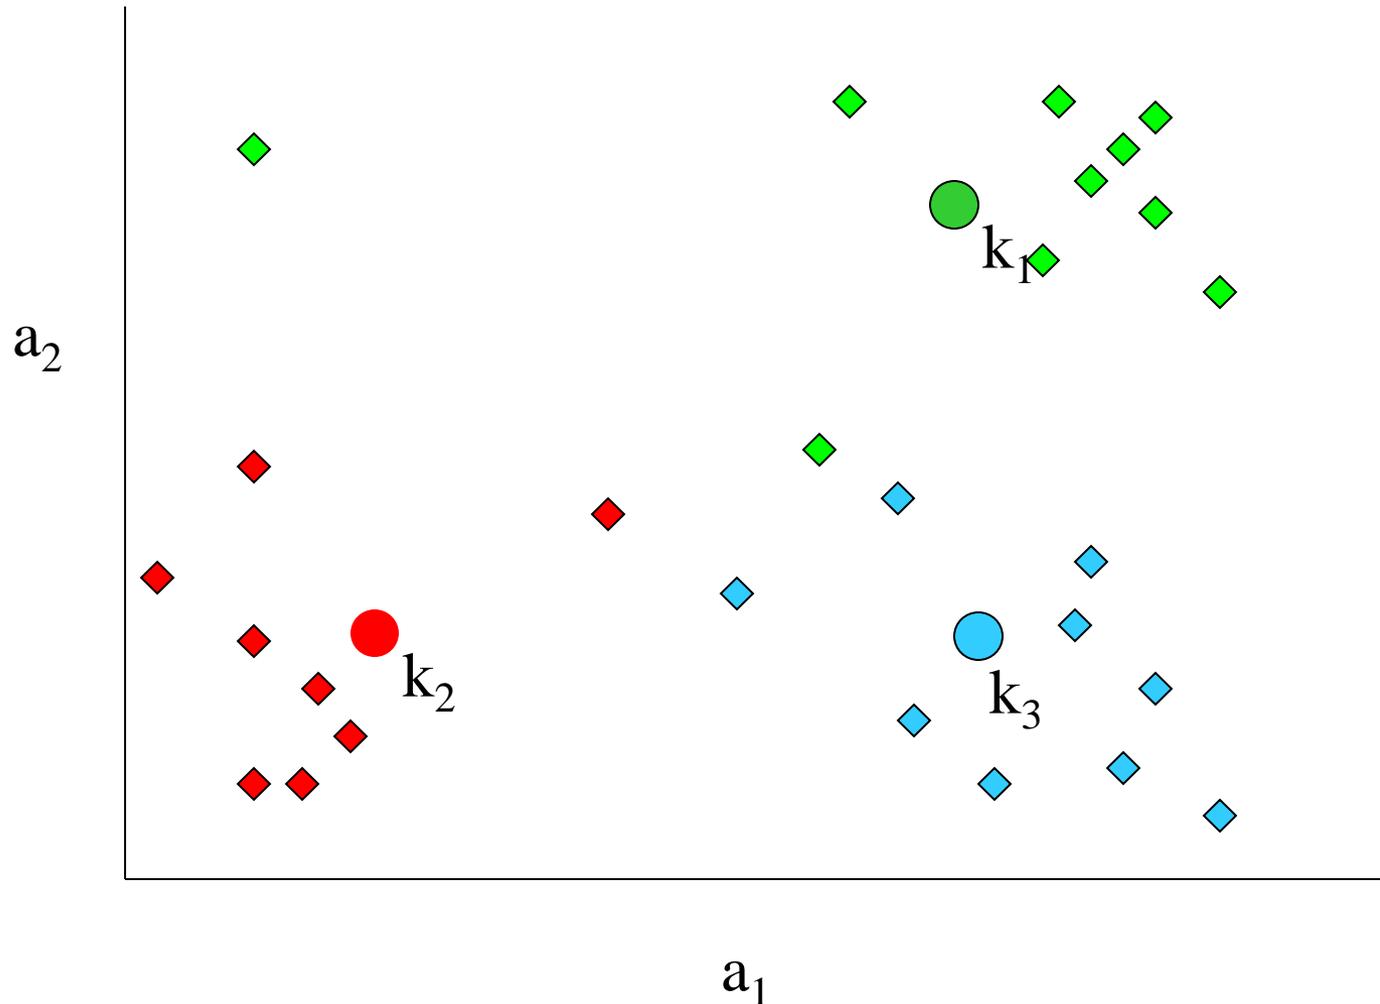
Mover cada centro para o vetor médio do cluster (centróide)



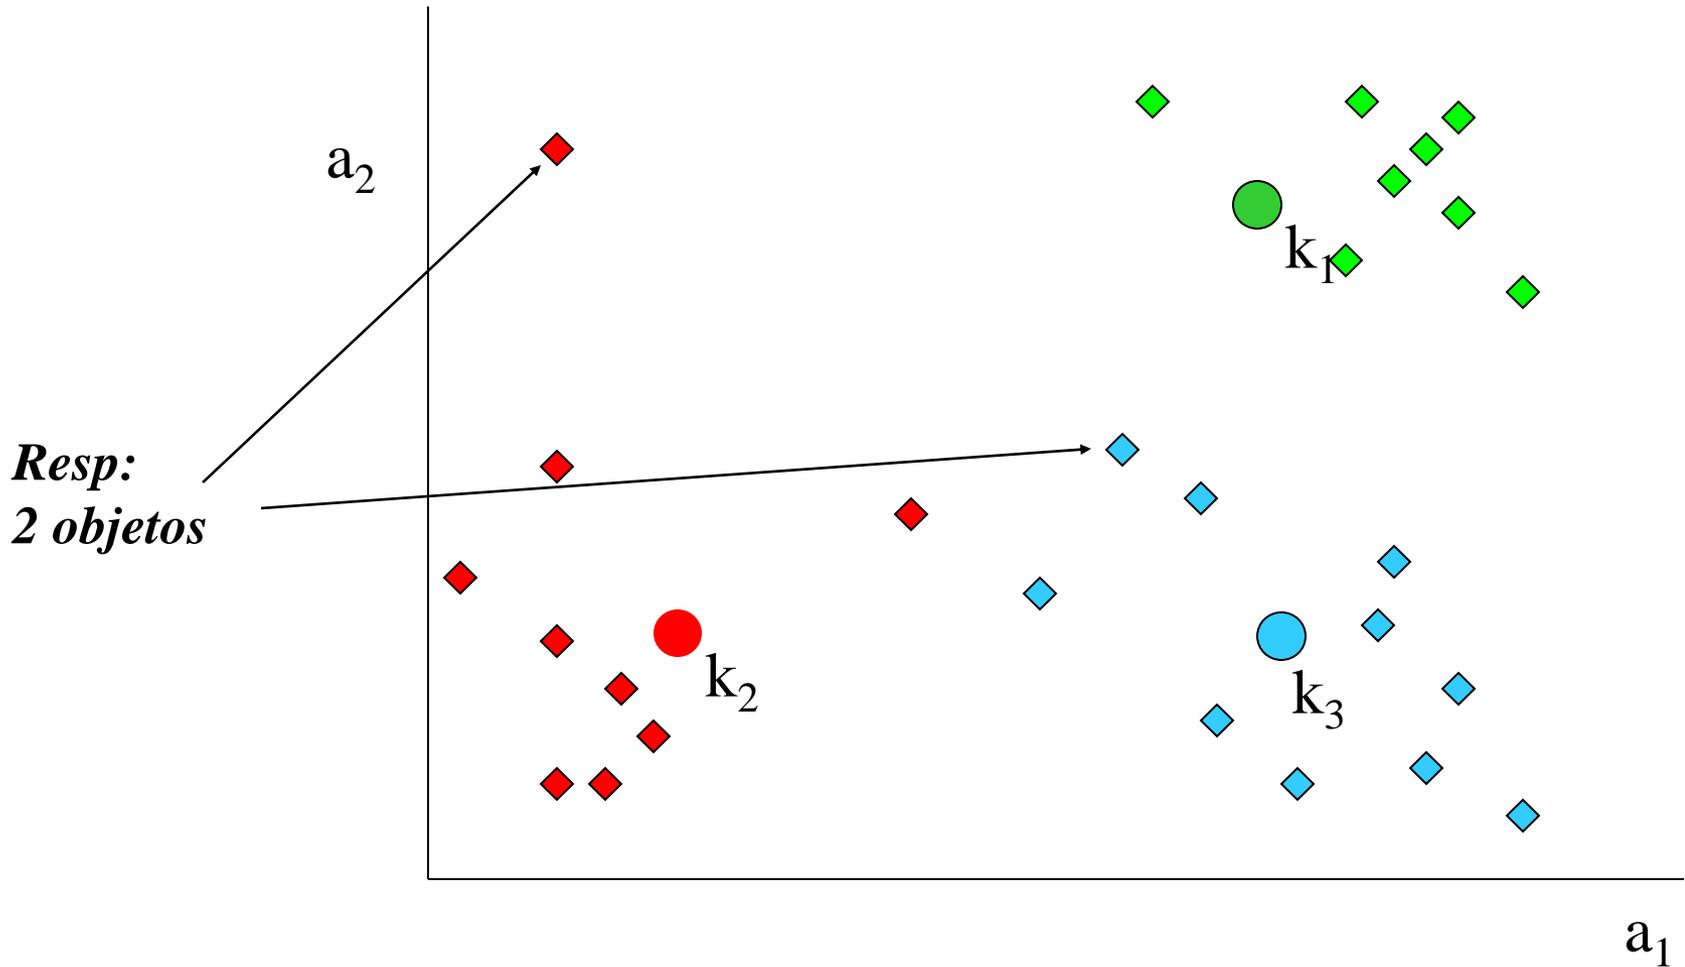
k-Means:

Re-atribuir
objetos aos
clusters de
centróides
mais
próximos

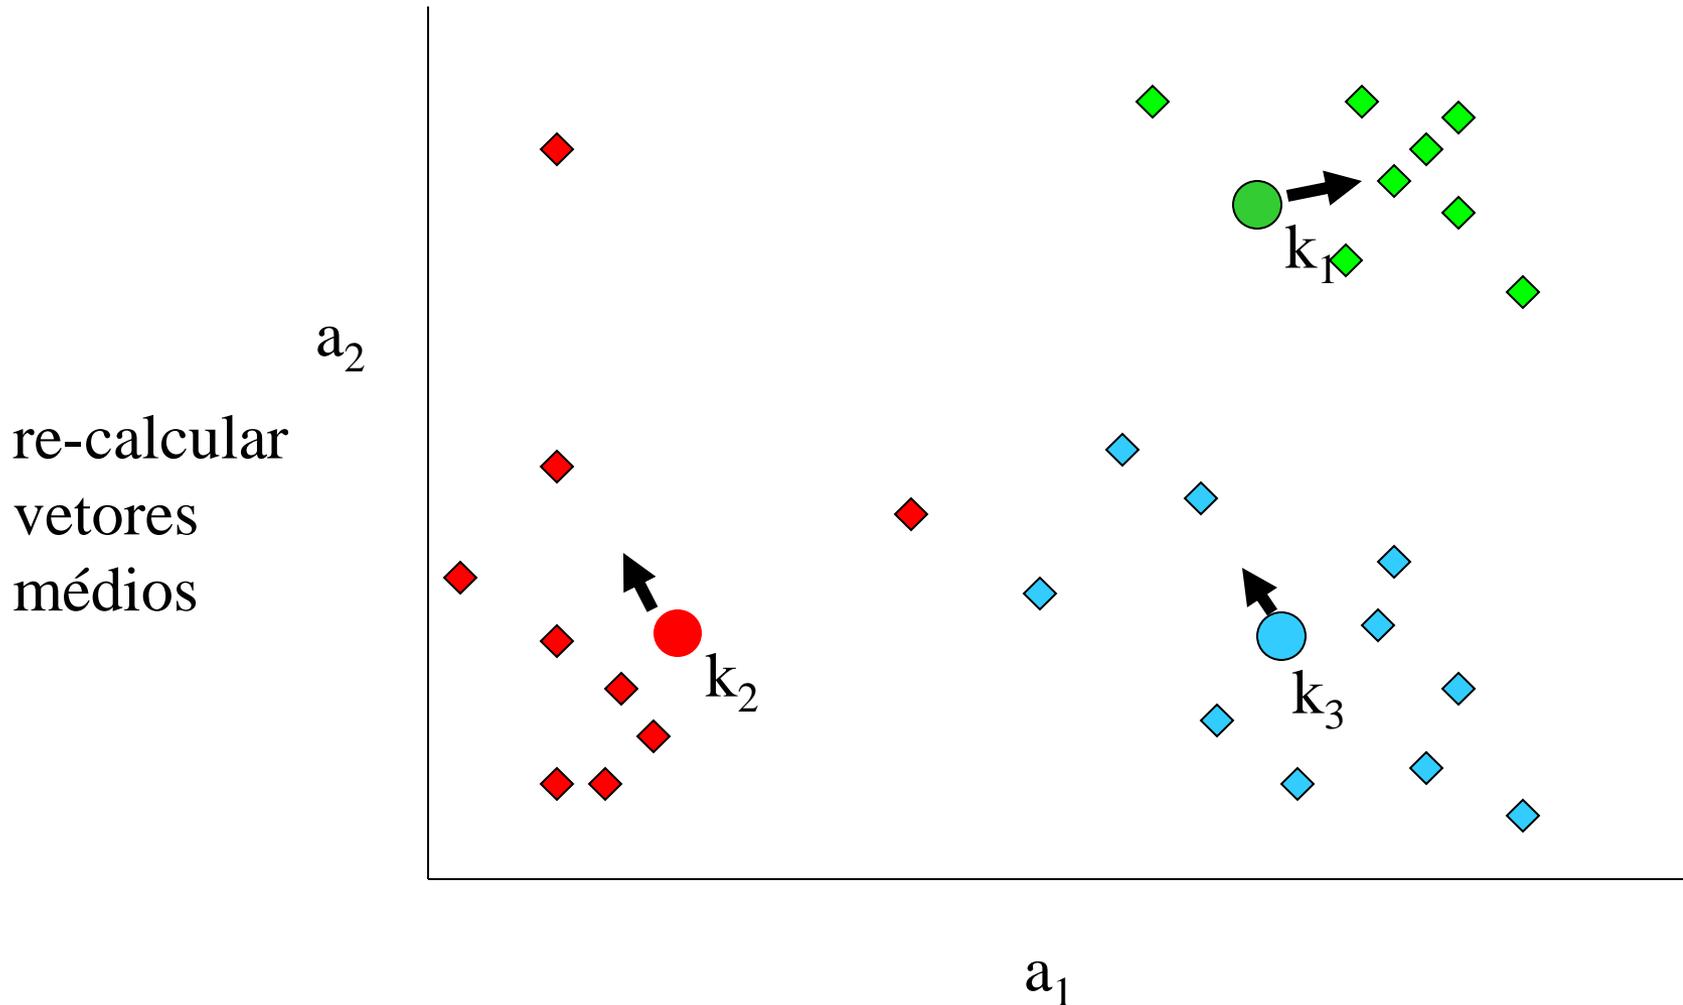
Quais objetos
mudarão de
cluster?



k-Means:

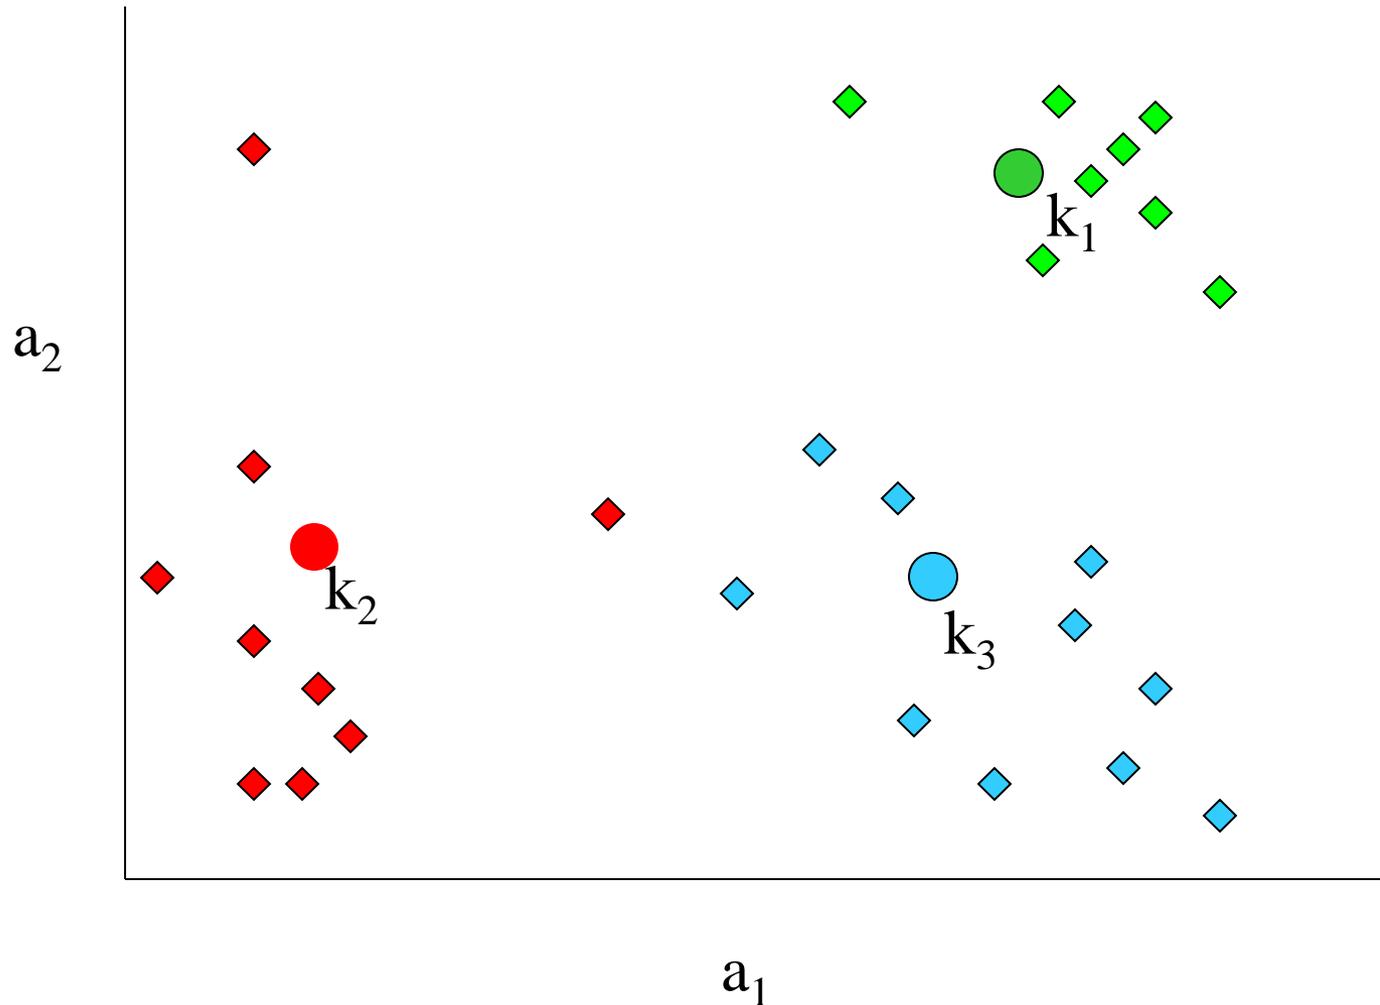


k-Means:



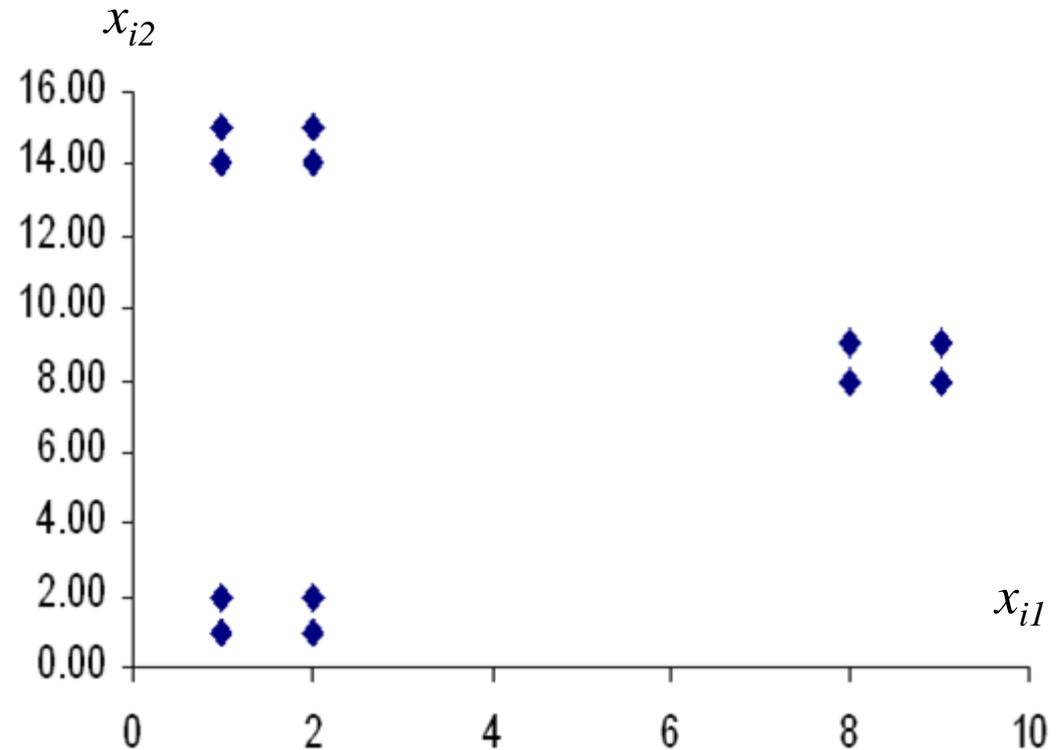
k-Means:

mover
centros dos
clusters...



Exercício

Objeto x_i	x_{i1}	x_{i2}
1	1	2
2	2	1
3	1	1
4	2	2
5	8	9
6	9	8
7	9	9
8	8	8
9	1	15
10	2	15
11	1	14
12	2	14



- Executar k-means com $k=3$ nos dados acima a partir dos protótipos $[6\ 6]$, $[4\ 6]$ e $[5\ 10]$ e outros a sua escolha

K-Means sob Perspectiva de Otimização

- Algoritmo minimiza a seguinte função objetivo:
 - **SSE** = *Sum of Squared Erros* (**variâncias intra-cluster**)

$$J = \sum_{c=1}^k \sum_{\mathbf{x}_j \in \mathbf{C}_c} d(\mathbf{x}_j, \bar{\mathbf{x}}_c)^2$$

onde d = Euclidiana e $\bar{\mathbf{x}}_c$ é o centróide do c -ésimo grupo:

$$\bar{\mathbf{x}}_c = \frac{1}{|\mathbf{C}_c|} \sum_{\mathbf{x}_j \in \mathbf{C}_c} \mathbf{x}_j$$

K-Means sob a Perspectiva de Otimização:

- Assumamos:

- conjunto de objetos $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$

- conjunto de k centróides quaisquer $\{\bar{\mathbf{x}}_1, \bar{\mathbf{x}}_2, \dots, \bar{\mathbf{x}}_k\}$

- Podemos reescrever o critério SSE de forma equivalente como:

$$J = \sum_{j=1}^N \sum_{c=1}^k \mu_{cj} \|\mathbf{x}_j - \bar{\mathbf{x}}_c\|^2 ; \sum_{c=1}^k \mu_{cj} = 1 \quad \forall j ; \mu_{cj} \in \{0,1\}$$

- Desejamos minimizar J com respeito a $\{\bar{\mathbf{x}}_c\}$ e $\{\mu_{cj}\}$

- Pode-se fazer isso via um procedimento iterativo (2 passos):

a) Fixar $\{\bar{\mathbf{x}}_c\}$ e minimizar J com respeito a $\{\mu_{cj}\}$ **(E)**

b) Minimizar J com respeito a $\{\bar{\mathbf{x}}_c\}$, fixando-se $\{\mu_{cj}\}$ **(M)**

K-Means sob a Perspectiva de Otimização:

$$J = \sum_{j=1}^N \sum_{c=1}^k \mu_{cj} \|\mathbf{x}_j - \bar{\mathbf{x}}_c\|^2 ; \sum_{c=1}^k \mu_{cj} = 1 \quad \forall j ; \mu_{cj} \in \{0,1\}$$

a) Fixar $\{\bar{\mathbf{x}}_c\}$ e minimizar J com respeito a $\{\mu_{cj}\}$ (**Passo E**)

- Termos envolvendo diferentes j são independentes
- Logo, pode-se otimizá-los separadamente
- $\mu_{cj}=1$ para c que fornece o menor valor do erro quadrático

*** Atribuir $\mu_{cj}=1$ para o grupo mais próximo.**

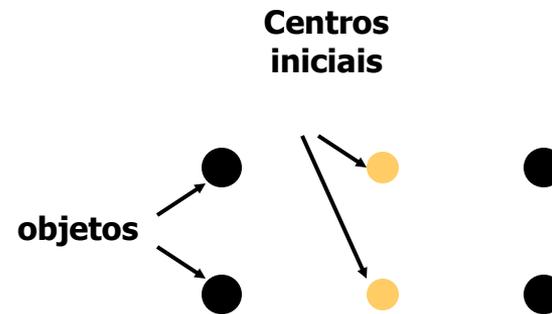
b) Minimizar J com respeito a $\{\bar{\mathbf{x}}_c\}$, fixando-se $\{\mu_{cj}\}$ (**Passo M**)

- Derivar J com respeito a cada $\bar{\mathbf{x}}_c$ e igualar a zero:

$$\nabla_{\bar{\mathbf{x}}_c} J = \sum_{j=1}^N \mu_{cj} \nabla_{\bar{\mathbf{x}}_c} \left[(\mathbf{x}_j - \bar{\mathbf{x}}_c)^T (\mathbf{x}_j - \bar{\mathbf{x}}_c) \right] = 2 \sum_{j=1}^N \mu_{cj} (\bar{\mathbf{x}}_c - \mathbf{x}_j) = \mathbf{0} \rightarrow \bar{\mathbf{x}}_c = \frac{\sum_{j=1}^N \mu_{cj} \mathbf{x}_j}{\sum_{j=1}^N \mu_{cj}}$$

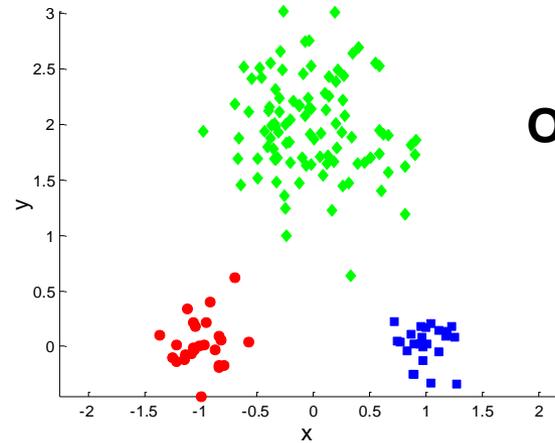
Discussão

- Resultado pode variar significativamente dependendo da escolha das sementes (protótipos) iniciais
- k-means pode “ficar preso” em ótimos locais
 - Exemplo:

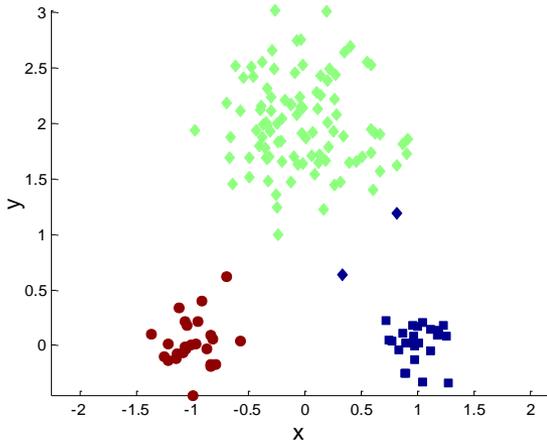


- Como evitar ... ?

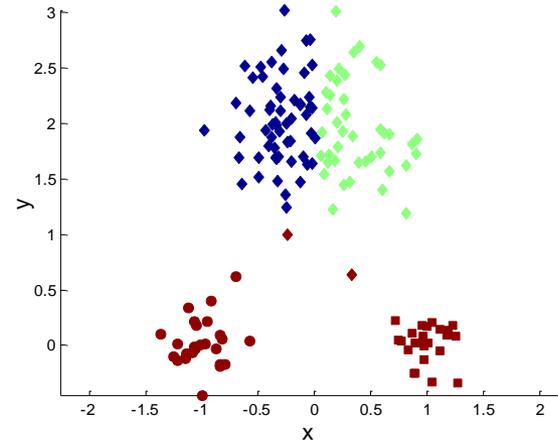
Two different K-means Clusterings



Original Points

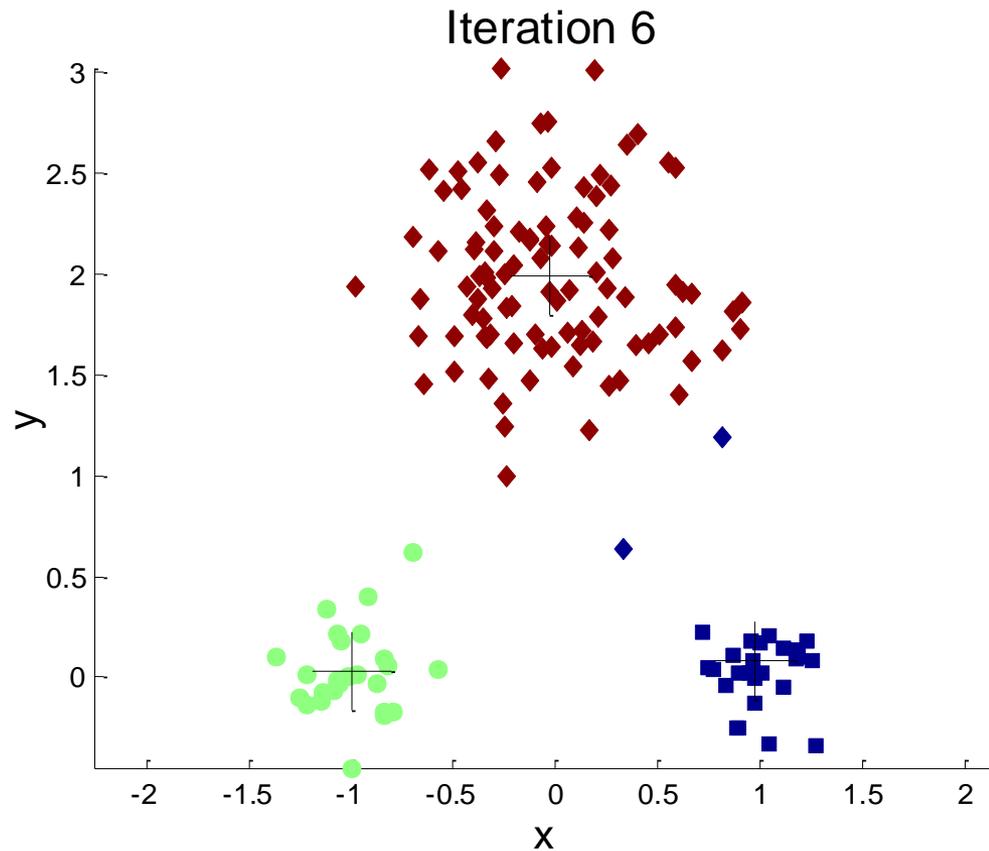


Optimal Clustering

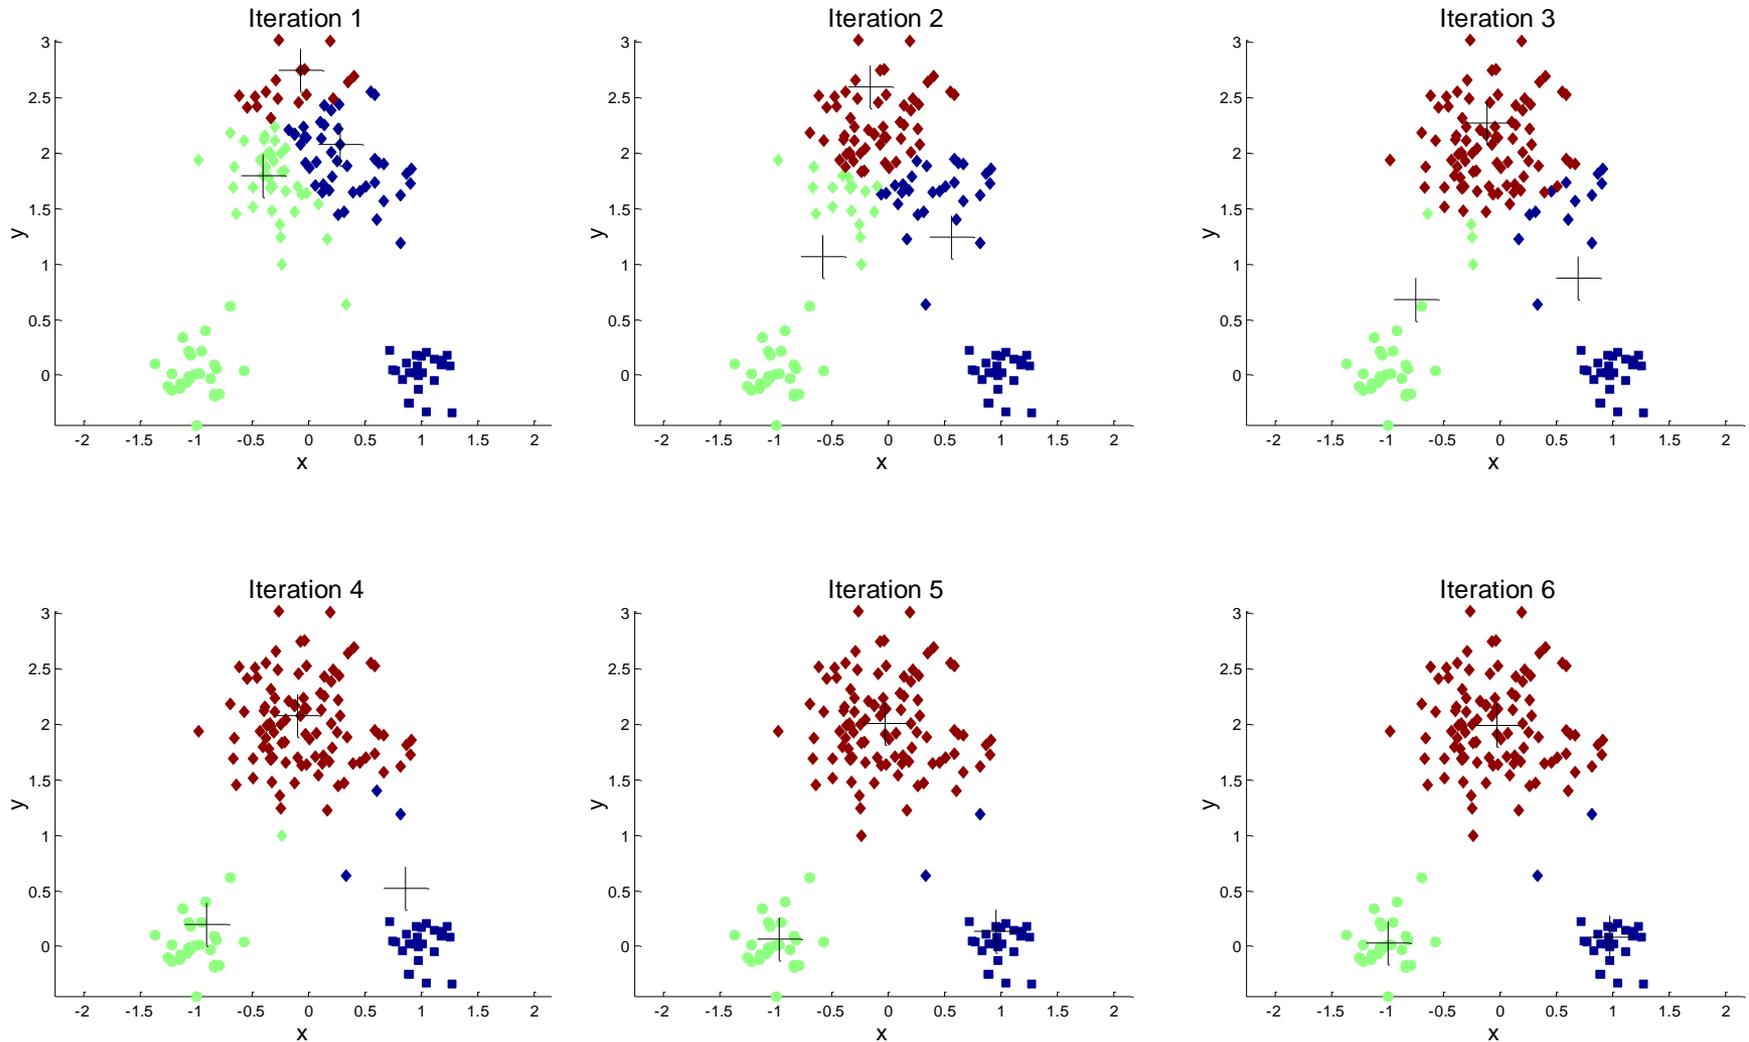


Sub-optimal Clustering

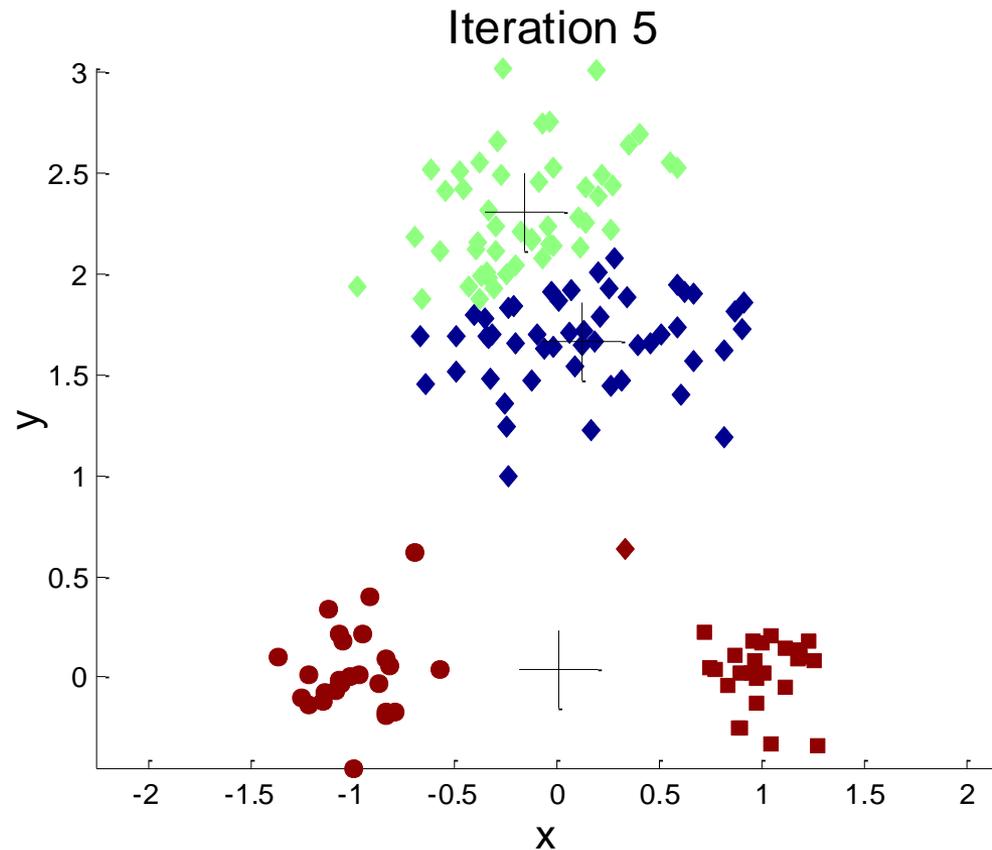
Importance of Choosing Initial Centroids



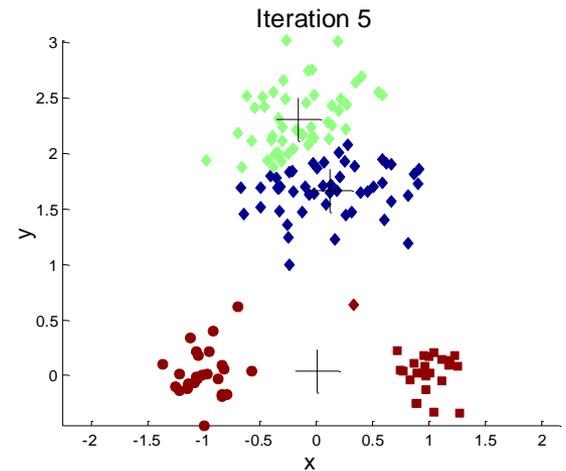
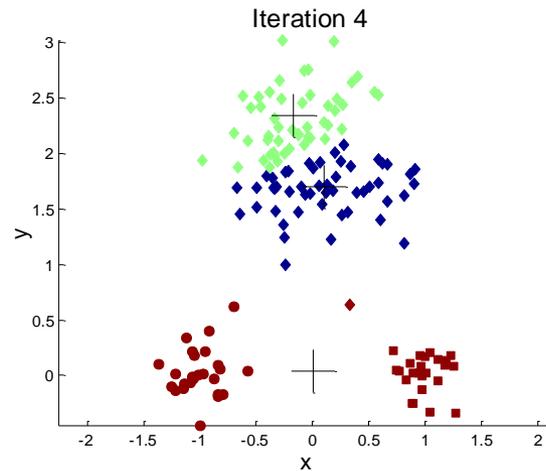
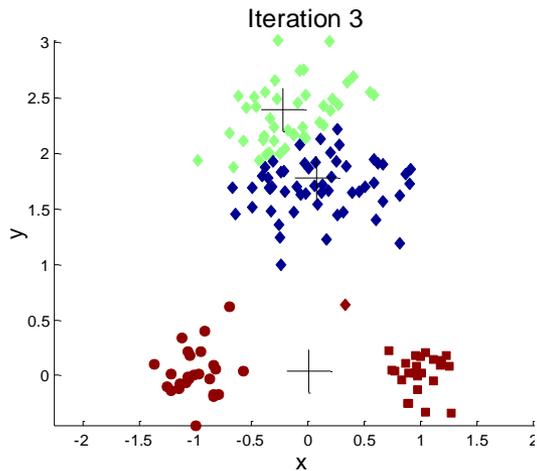
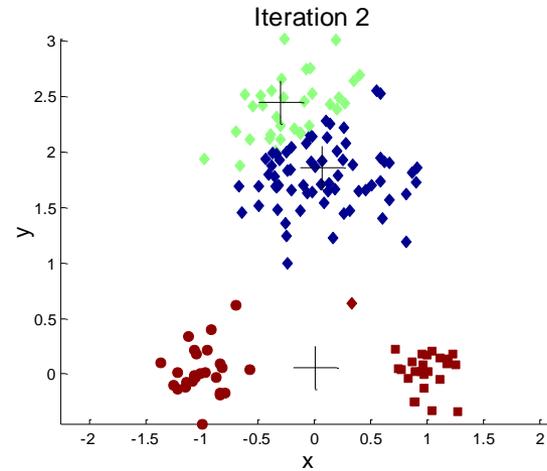
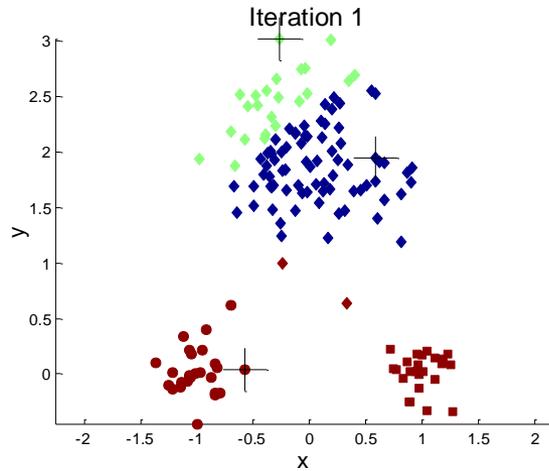
Importance of Choosing Initial Centroids



Importance of Choosing Initial Centroids ...



Importance of Choosing Initial Centroids ...



Análise da Seleção dos Protótipos Iniciais

- ❑ **Premissa:** Uma boa seleção de k protótipos iniciais em uma base de dados com k grupos naturais é tal que cada protótipo é um objeto de um grupo diferente
- ❑ No entanto, a chance de se selecionar um protótipo de cada grupo é pequena, especialmente para k grande...
- ❑ Assumamos grupos balanceados, com uma mesma quantidade $g = N / k$ de objetos cada:
 - Podemos calcular a probabilidade de selecionar 1 protótipo de cada grupo diferente como:

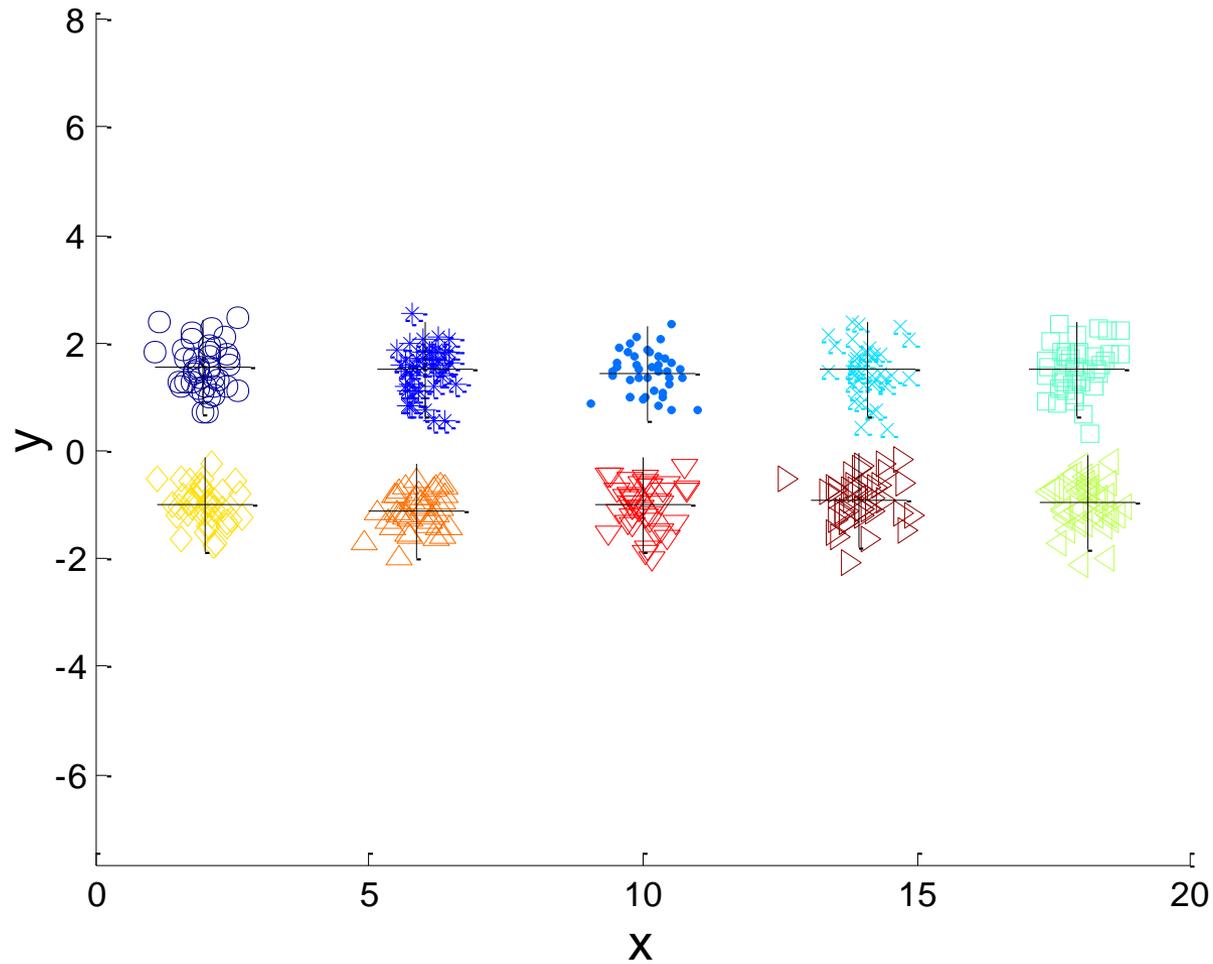
$$P = \frac{\text{no. de maneiras de selecionar 1 objeto de cada grupo (com } N / k \text{ objetos)}}{\text{no. de maneiras de selecionar } k \text{ dentre } N \text{ objetos}}$$

Análise da Seleção dos Protótipos Iniciais

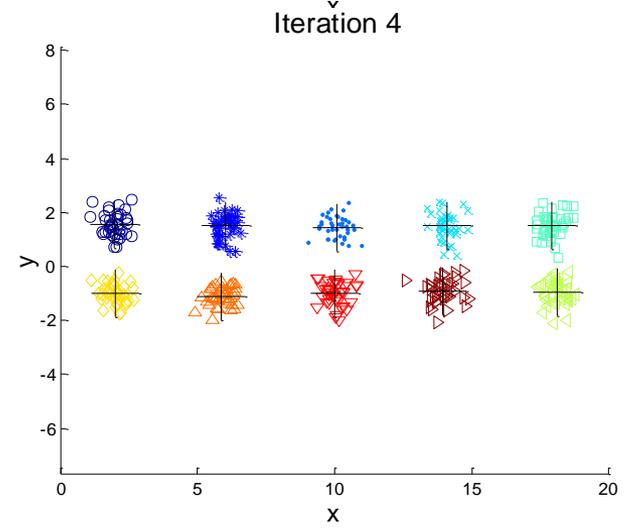
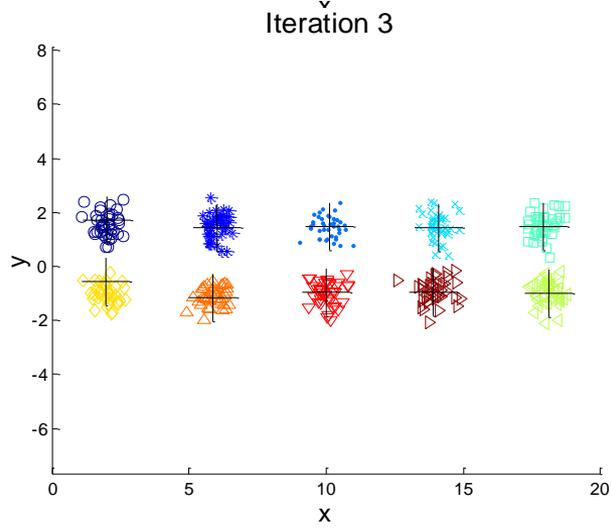
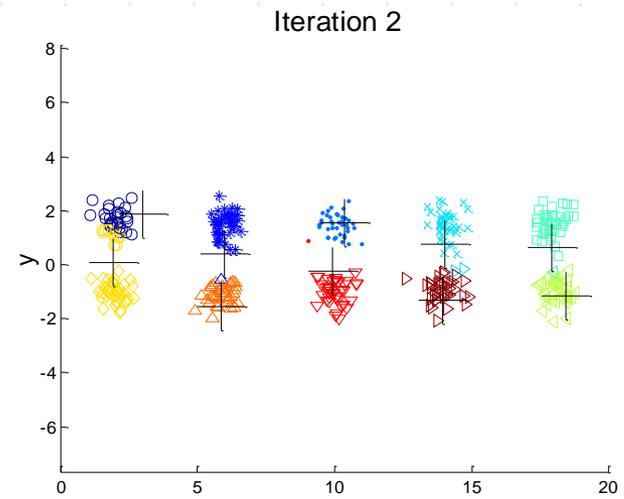
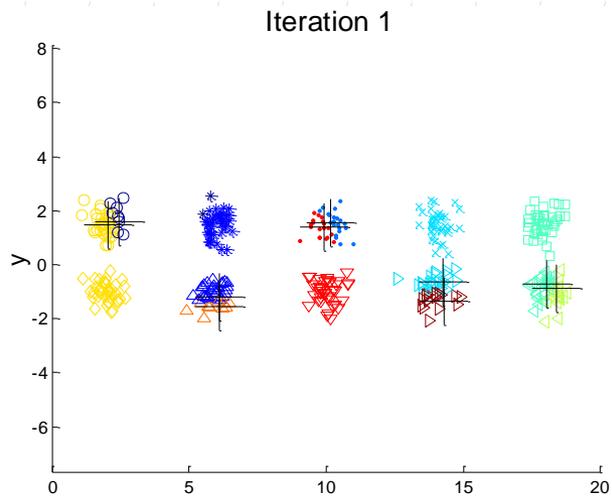
- ❑ N° de formas de selecionar k protótipos (denominador)
 - ❑ cada um dos $N = k \cdot g$ objetos pode ser selecionado em cada um dos k sorteios, com reposição, logo tem-se $(k \cdot g)^k$ formas
- ❑ N° de formas de escolher 1 protótipo por grupo (numerador)
 - ❑ No 1° sorteio, qualquer um dos $N = k \cdot g$ objetos pode ser selecionado. No 2° sorteio, qualquer objeto exceto aqueles g do mesmo grupo do 1° sorteio podem ser selecionados, ou seja, $k \cdot g - g = (k - 1) \cdot g$ podem ser selecionados, e assim por diante. Logo, tem-se $k \cdot g \times (k - 1) \cdot g \times \dots \times g = k!g^k$
- ❑ Portanto, tem-se $P = k!g^k / k^k g^k \rightarrow P = k! / k^k$
- ❑ Exemplo: se $k = 10$, $P = 0.00036$

Exemplo: Iniciando com 2 centróides iniciais em um grupo de cada par...

Iteration 4

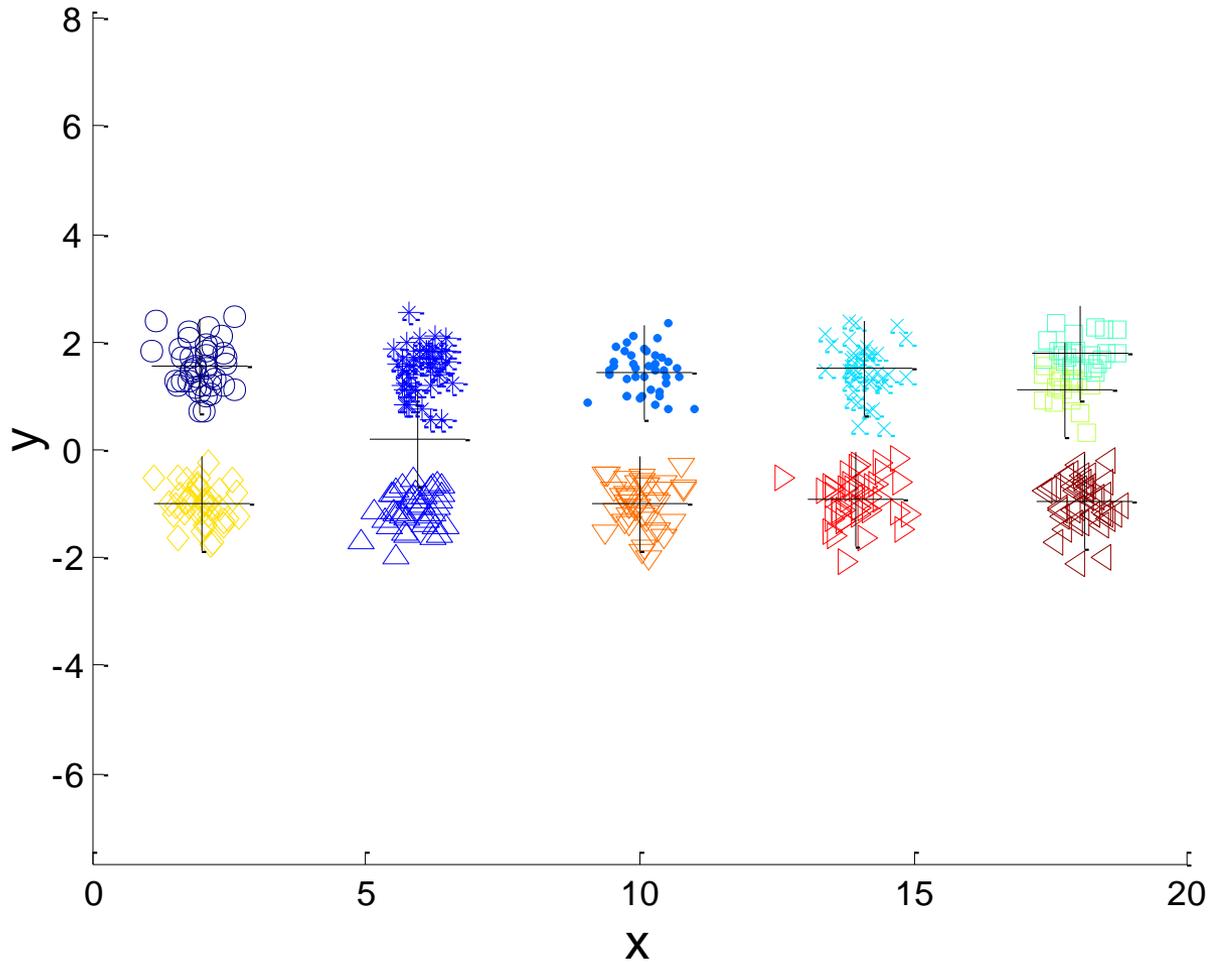


Ilustrando Todas as Iterações:

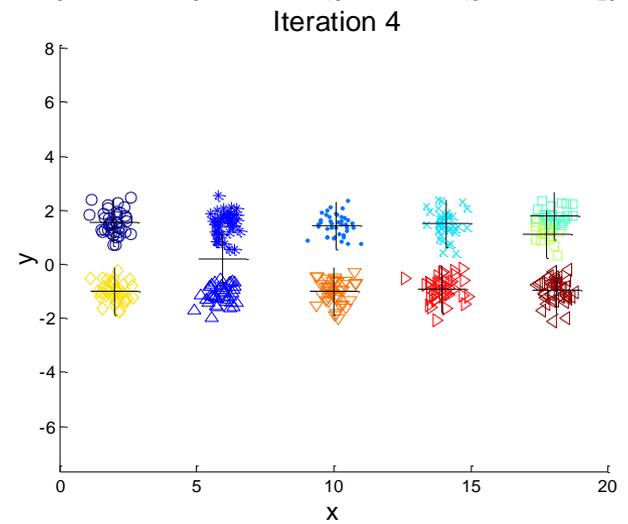
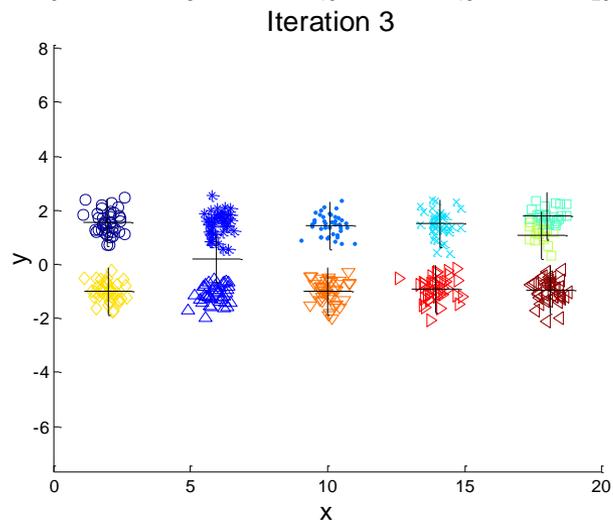
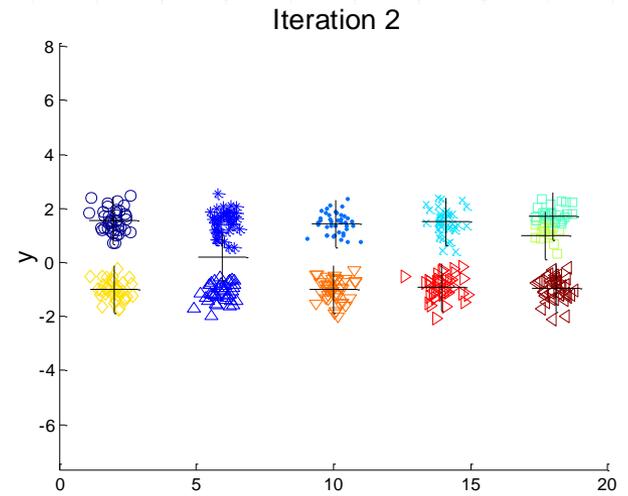
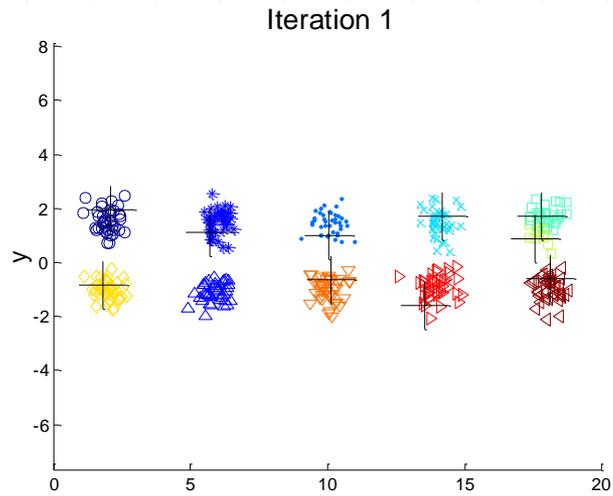


Agora Vejamos Outra Inicialização:

Iteration 4



Ilustrando Todas as Iterações:



Alternativas para Inicialização

- ❑ Múltiplas Execuções (inicializações aleatórias):
 - ❑ funciona bem em muitos problemas.
 - ❑ mas em bases de dados complexas, pode demandar um no. enorme de execuções.
 - ❑ em particular para no. de grupos grande.
 - ❑ especialmente dado que k é, em geral, desconhecido
- ❑ Agrupamento Hierárquico:
 - ❑ agrupa-se uma amostra dos dados
 - ❑ tomam-se os centros da partição com k grupos

Alternativas para Inicialização

❑ Seleção “Informada” :

- ❑ toma-se o 1º protótipo como um objeto aleatório
 - ou como o centro dos dados (*grand mean*)
- ❑ sucessivamente escolhe-se o próximo protótipo
 - como o objeto mais distante dos protótipos correntes
- ❑ **Nota:** para reduzir o esforço computacional e minimizar a probabilidade de seleção de outliers
 - processa-se apenas uma amostra dos dados

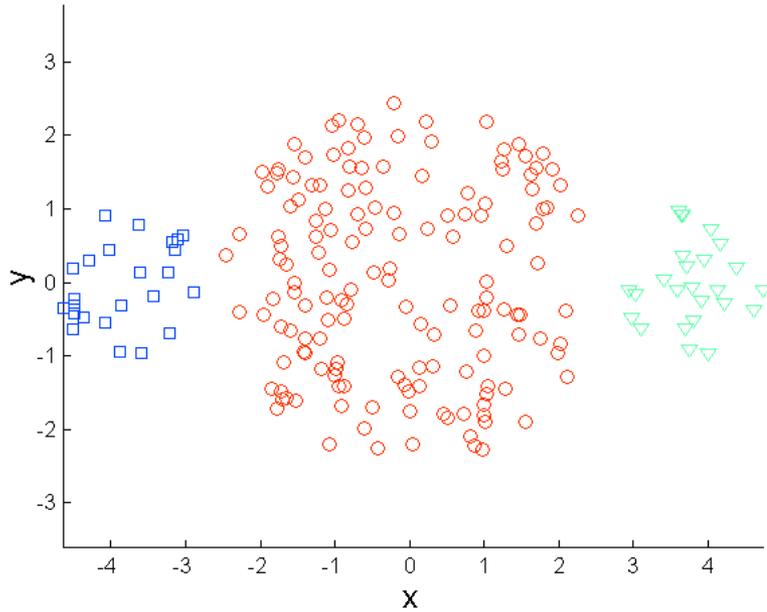
❑ Busca Guiada:

- ❑ **X-means, k-means evolutivo, ...**

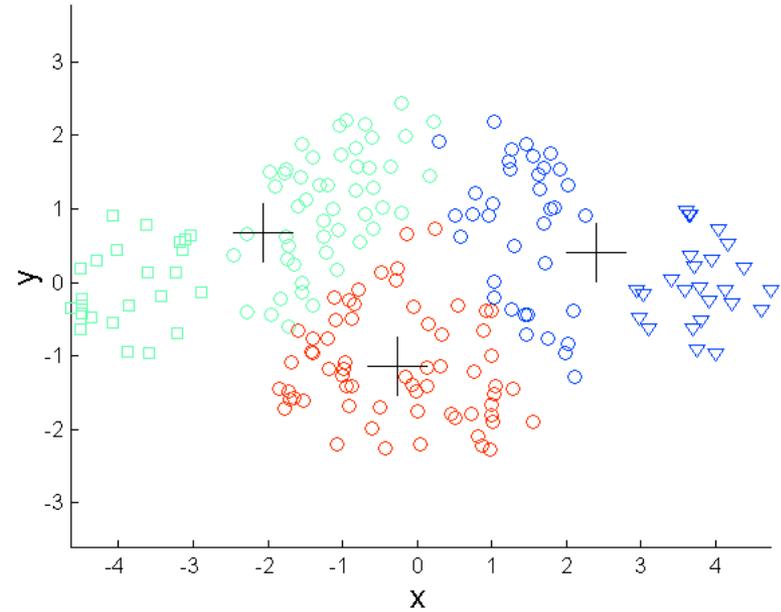
Discussão

- k-means é mais susceptível a problemas quando clusters são de diferentes
 - Tamanhos
 - Densidades
 - Formas não-globulares

Differing Sizes

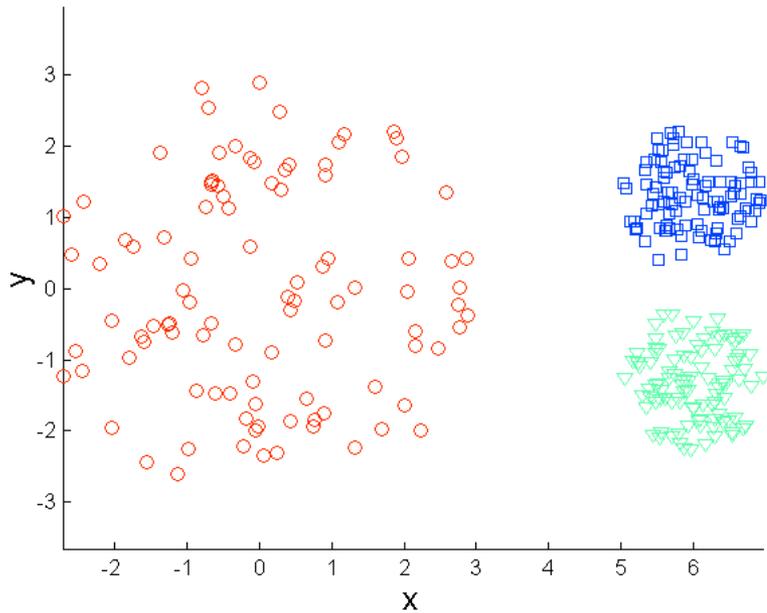


Original Points

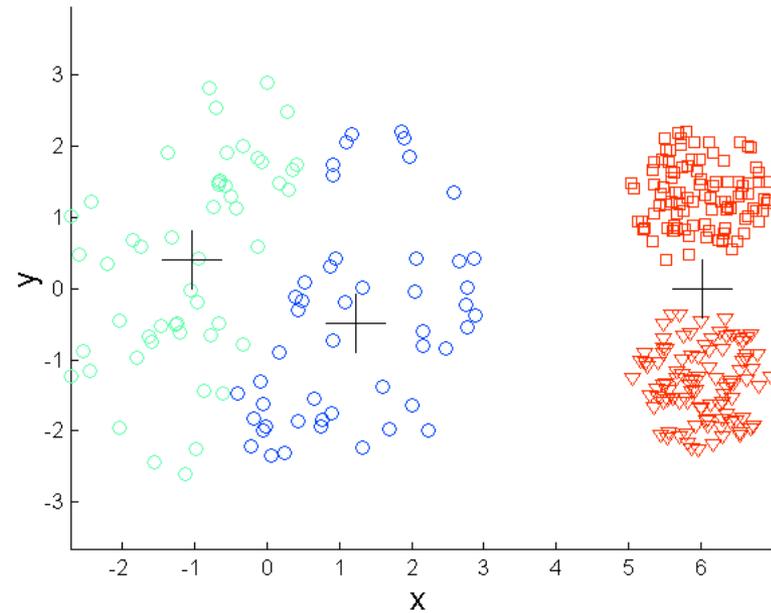


K-means (3 Clusters)

Differing Density



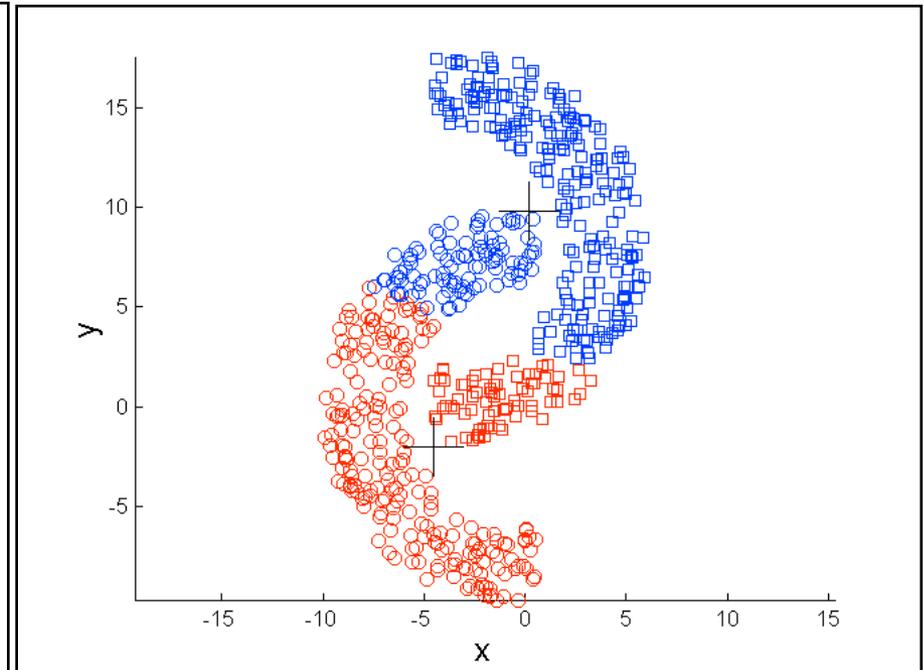
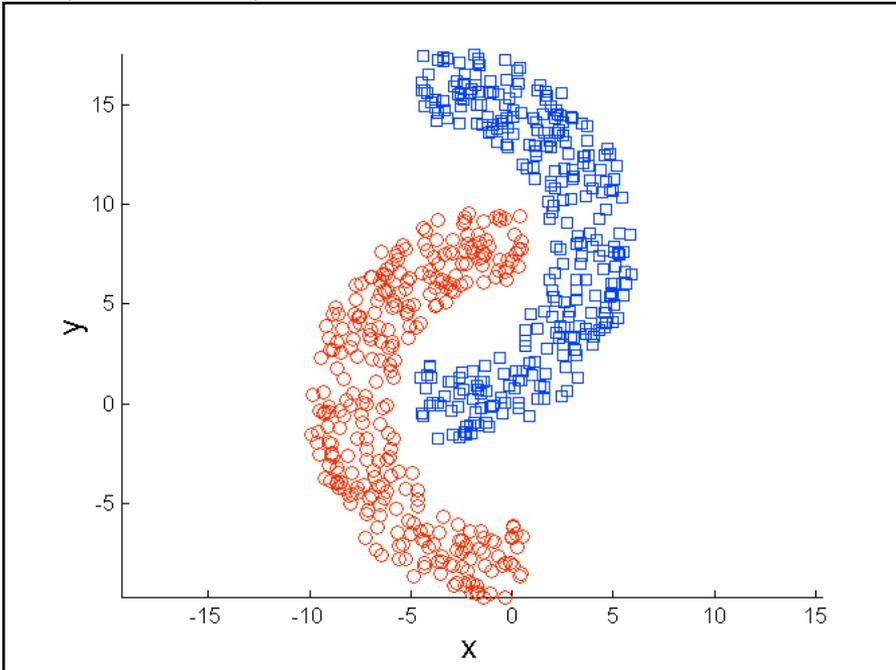
Original Points



K-means (3 Clusters)

Formas Não-Globulares

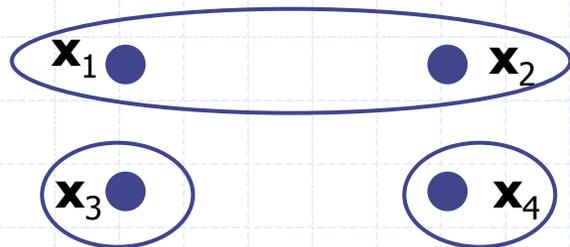
Tan, Steinbach, Kumar



- **Nota:** na prática, esse problema em geral não é crítico, i.e., há pouco interesse na maioria das aplicações de mundo real
 - Grandes BDs (muitos objetos & atributos) e necessidade de interpretação dos resultados (e.g. segmentação de mercado...)

Manipulando Grupos Vazios

- ❑ k-means pode gerar **grupos vazios**
 - ❑ Por inicialização em pontos “dominados” do espaço
 - ❑ protótipos não representativos: nenhum objeto mais próximo
 - ❑ inicialização como objetos ao invés de pontos aleatórios resolve
 - ❑ Pela inicialização de grupos
 - ❑ cujos protótipos são não representativos; por exemplo:



Grupos iniciais

$k = 3$

- ❑ Ao longo das iterações

Manipulando Grupos Vazios

□ Estratégias para contornar o problema:

- Eliminar os protótipos não representativos (reduz k)
 - viável se o número inicial de grupos, k , puder ser reduzido
 - pode ser útil para ajustar valores superestimados de k
- Substituir cada protótipo não representativo (mantém k)
 - pelo objeto que mais contribui para o SSE da partição
 - por um dos objetos do grupo com maior MSE
 - visa dividir o grupo com maior erro quadrático médio
 - **Nota:** a execução do algoritmo prossegue após a substituição

Implementações Eficientes

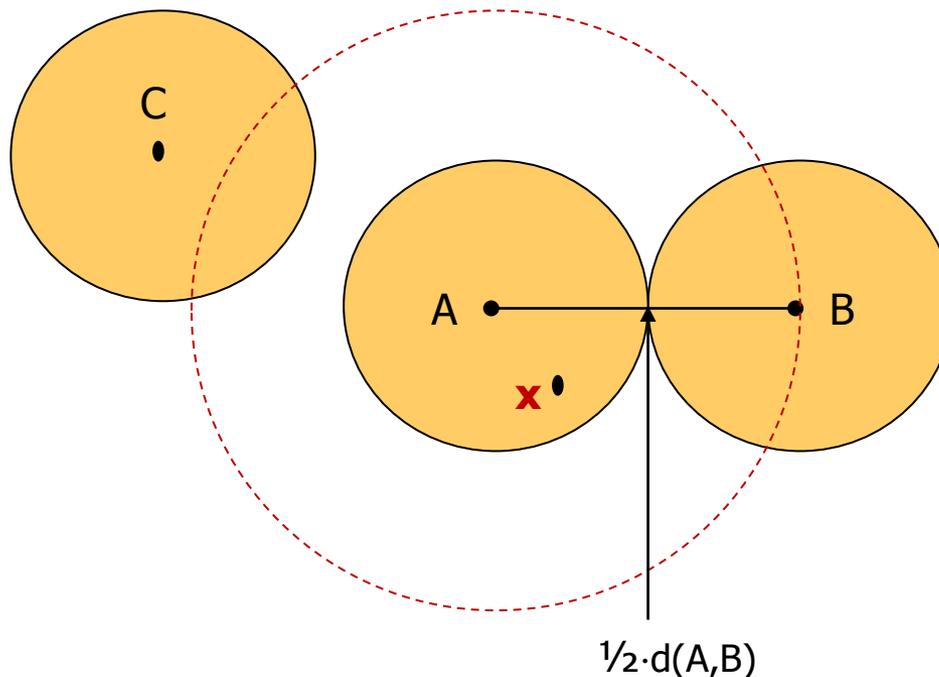
- Desempenho computacional pode ser melhorado...
 - **Estruturas de Dados**, e.g.
 - **kd-trees** (seminários...)
 - **Algoritmos**, e.g.
 - **Atualização recursiva dos centróides**
 - Cálculo dos centróides só depende dos valores anteriores, dos nos. de objetos dos grupos e dos objetos que mudaram de grupo
 - Não demanda recalcular tudo novamente
 - **Exercício:** a partir da equação do cálculo do centróide, escrever a equação de atualização recursiva descrita acima.
 - **Uso da desigualdade triangular** (vide discussão a seguir)
 - **Paralelização** (vide discussão a seguir)

Uso da Desigualdade Triangular

- **Lema:** Se $d(x,A) \leq d(A,B)/2$ então $d(x,B) \geq d(x,A)$.

- **Prova:** $d(A,B) \leq d(A,x) + d(x,B)$; ...

- **Interpretação Geométrica:**



K-Means Paralelo / Distribuído

- Dados distribuídos em múltiplos *data sites* ou processadores
- **Algoritmo:**
 - Mesmos protótipos iniciais são distribuídos a cada sítio de dados
 - Cada sítio executa (em paralelo) uma iteração de k-means
 - Protótipos locais e nos. de objetos dos grupos são comunicados
 - Protótipos globais são calculados e retransmitidos aos sítios
 - Repete-se o processo

Exercício

Objeto x_i	x_{i1}	x_{i2}	Processador
1	1	2	A
2	2	1	B
3	1	1	A
4	2	2	B
5	8	9	A
6	9	8	B
7	9	9	B
8	8	8	A
9	1	15	B
10	2	15	A
11	1	14	B
12	2	14	A

Executar k-means paralelo nos dados ao lado, com $k=3$, a partir dos protótipos iniciais $[6\ 6]$, $[4\ 6]$ e $[5\ 10]$

Resumo do k-means

Vantagens

- Simples e intuitivo
- Complexidade computacional **linear** em todas as variáveis críticas: $O(N n k)$
 - quadrático apenas se $n \approx N \dots$
- Eficaz em muitos cenários de aplicação e produz resultados de interpretação relativamente simples
- Considerado um dos 10 mais influentes algoritmos em Data Mining (Wu & Kumar, 2009).

Desvantagens

- $k = ?$
- Sensível à inicialização dos protótipos (mínimos locais de J)
- Limita-se a encontrar clusters volumétricos / globulares
- Cada item deve pertencer a um único cluster (**partição rígida**, ou seja, sem sobreposição)
- Limitado a atributos numéricos
- Sensível a *outliers*

Generalização:

- Banerjee et al. (*Clustering with Bregman Divergences*, JMLR, 2005) apresentam uma visão unificada para a classe de algoritmos de agrupamento baseados em centróides (*ao estilo k-means*);
- Estudo teórico minucioso baseado em Divergentes de Bregman:

$$d_{\phi}(\mathbf{x}, \mathbf{y}) = \phi(\mathbf{x}) - \phi(\mathbf{y}) - \langle \mathbf{x} - \mathbf{y}, \nabla \phi(\mathbf{y}) \rangle$$

- Distância Euclidiana ao quadrado, Mahalanobis, KL, perda quadrática, perda logística, etc.;
- Exemplo: $\phi(\mathbf{x}) = \mathbf{x}^T \mathbf{x}$ é estritamente convexa e diferenciável em \mathcal{R}^n ...
- Algoritmos derivados mantêm simplicidade, garantias teóricas e escalabilidade do k-médias;
- Aplicável a diferentes tipos de atributos --- diferentes funções convexas escolhidas para diferentes subconjuntos de atributos.

Algumas Variantes do k-means

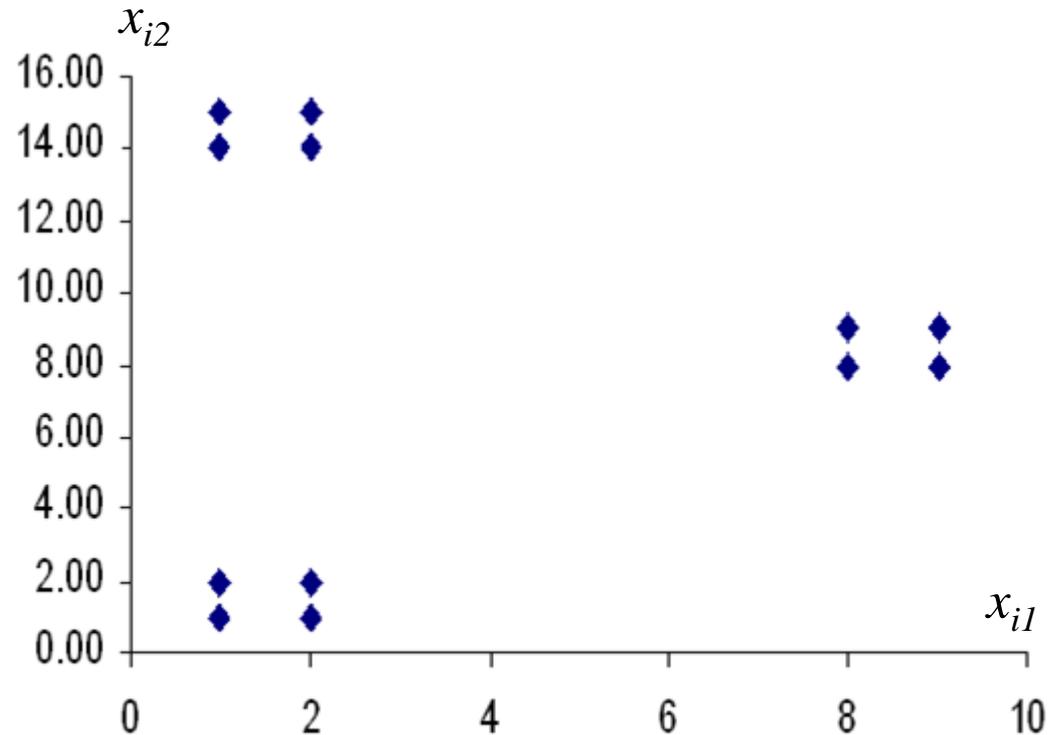
- **K-medianas:** Substituir as médias pelas medianas
 - Média de 1, 3, 5, 7, 9 é **5**
 - Média de 1, 3, 5, 7, 1009 é **205**
 - Mediana de 1, 3, 5, 7, 1009 é **5**
 - **Vantagem:** menos sensível a outliers*
 - **Desvantagem:** implementação mais complexa
 - cálculo da mediana em cada atributo...
- Pode-se mostrar que minimiza a soma das **distâncias de Manhattan** dos objetos aos centros (medianas) dos grupos

Algumas Variantes do k-means

- **K-medóides:** Substituir cada centróide por um objeto representativo do cluster, denominado **medóide**
 - Medóide = objeto mais próximo aos demais objetos do cluster
 - mais próximo em média (empates resolvidos aleatoriamente)
 - **Vantagens:**
 - menos sensível a outliers
 - permite cálculo relacional (apenas matriz de distâncias)
 - logo, pode ser aplicado a bases com atributos categóricos
 - convergência assegurada com qualquer medida de (dis)similaridade
 - **Desvantagem:** Complexidade quadrática com nº. de objetos (N)

Exercício

Objeto x_i	x_{i1}	x_{i2}
1	1	2
2	2	1
3	1	1
4	2	2
5	8	9
6	9	8
7	9	9
8	8	8
9	1	15
10	2	15
11	1	14
12	2	14



- Executar k-medóides com $k=3$ nos dados acima, com medóides iniciais dados pelos objetos 5, 6 e 8

Algumas Variantes do k-means

- **K-means para Fluxos de Dados (Data Streams):**
 - Em geral, usa conceito de vizinhos mais próximos (K-NN)
 - Objetos dinamicamente incorporados ao cluster mais próximo
 - Atualização do centróide do cluster pode ser **incremental**
 - centróide atualizado a cada novo objeto incorporado
 - mas isso introduz dependência de ordem dos dados...
 - Heurísticas podem ser usadas para criar e/ou remover clusters
 - Ver Silva, Faria, Barros, Hruschka, de Carvalho, Gama, *Data Stream Clustering: A Survey*, **ACM Computing Surveys**, to appear.

Algumas Variantes do k-means

- **Métodos de Múltiplas Execuções de k-means:**
 - Executam k-means repetidas vezes a partir de diferentes valores de k e de posições iniciais dos protótipos
 - Ordenado: n_p inicializações de protótipos para cada $k \in [k_{\min}, k_{\max}]$
 - Aleatório: n_T inicializações de protótipos com k sorteado em $[k_{\min}, k_{\max}]$
 - Tomam a melhor partição resultante de acordo com algum critério de qualidade (**critério de validade de agrupamento**)
 - **Vantagens:** Estimam k e são menos sensíveis a mínimos locais
 - **Desvantagem:** Custo computacional pode ser elevado

Questão...

- J poderia ser utilizada como medida de qualidade para escolher a melhor partição dentre um conjunto de candidatas ?
 - Resposta é sim se todas têm o mesmo no. k de clusters (fixo)
 - Mas e se k for desconhecido e, portanto, variável ?
- Para responder, considere, por exemplo, que as partições são geradas a partir de múltiplas execuções do algoritmo:
 - com protótipos iniciais aleatórios
 - com no. variável de grupos $k \in [k_{\min}, k_{\max}]$

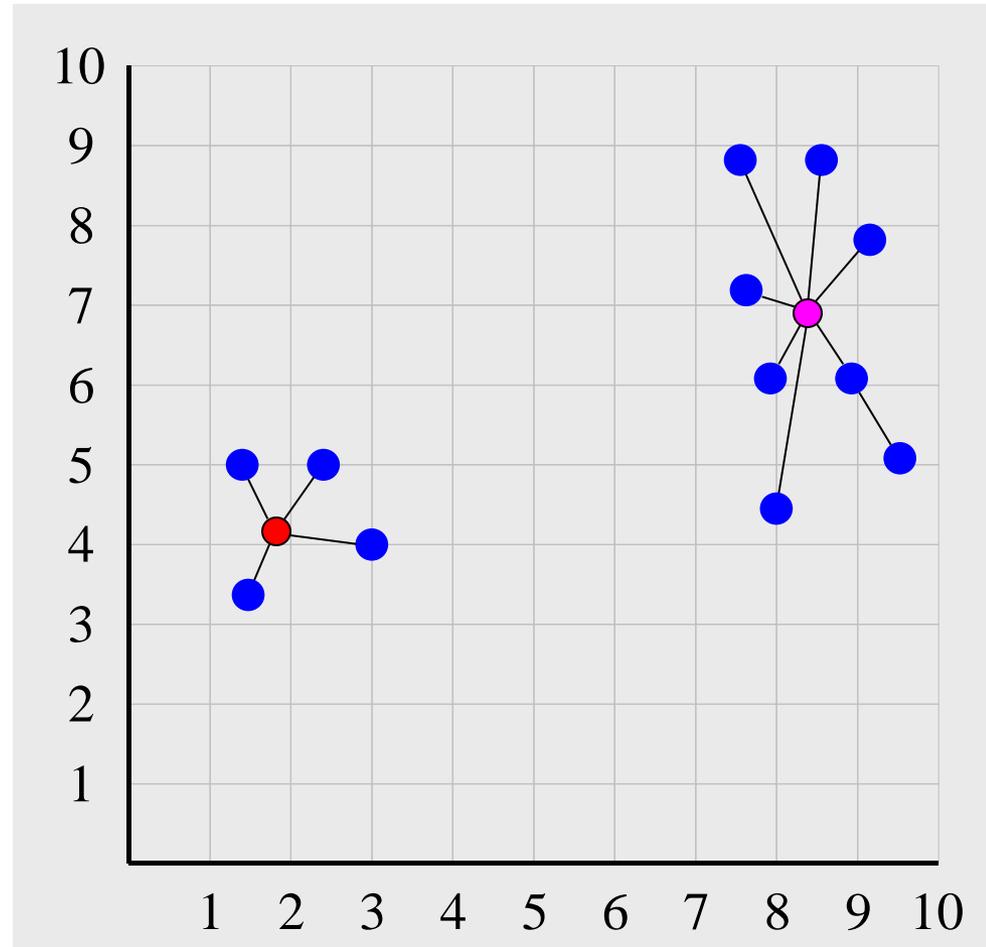
Questão...

- Para tentar responder a questão anterior, vamos considerar o método de múltiplas execuções ordenadas de k-means, com uso da função objetivo J

Erro Quadrático:

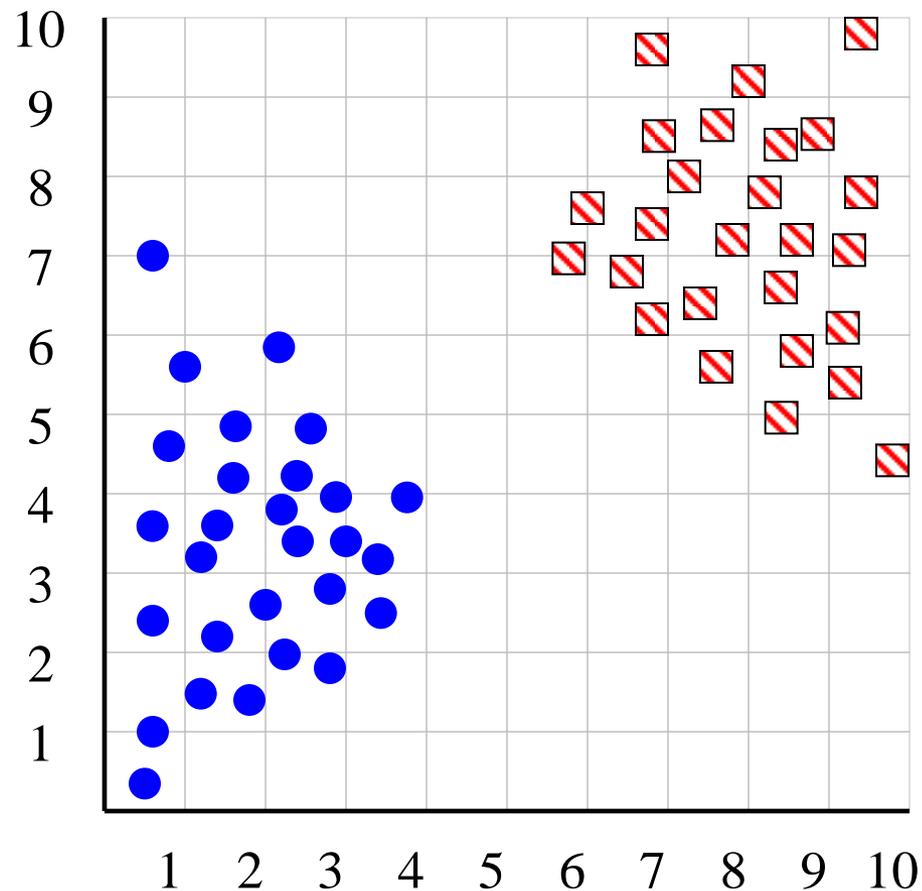
$$J = \sum_{i=1}^k \sum_{\mathbf{x}_j \in C_i} d(\mathbf{x}_j, \bar{\mathbf{x}}_i)^2$$

↑
Função Objetivo

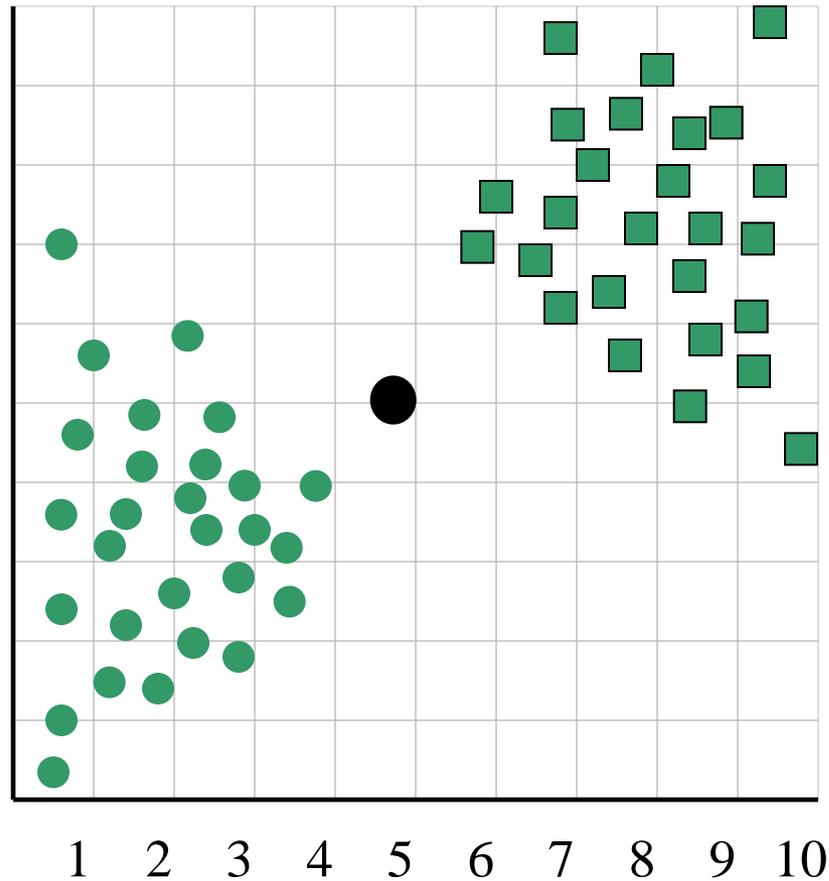


Questão...

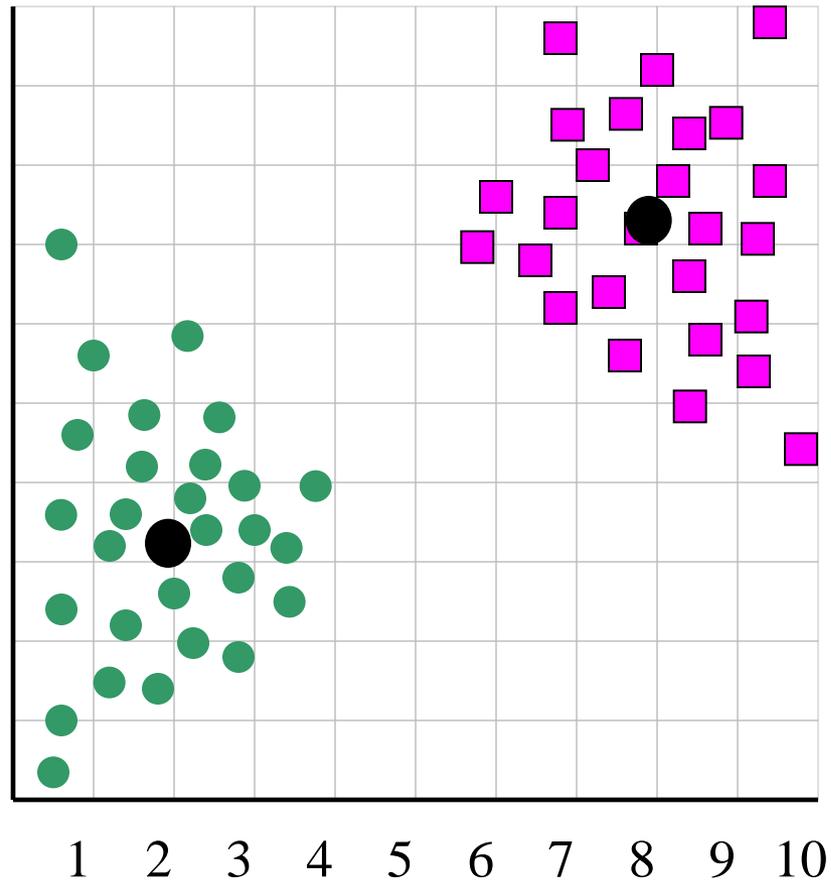
- Considere o seguinte exemplo:



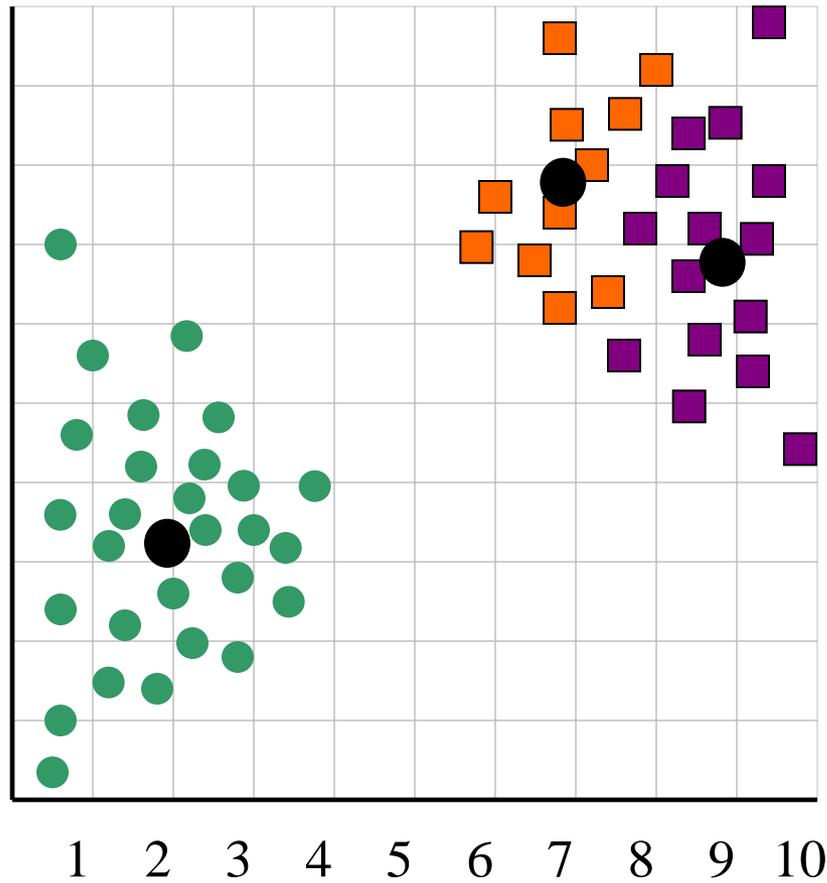
Para $k = 1$, o valor da função objetivo é 873,0



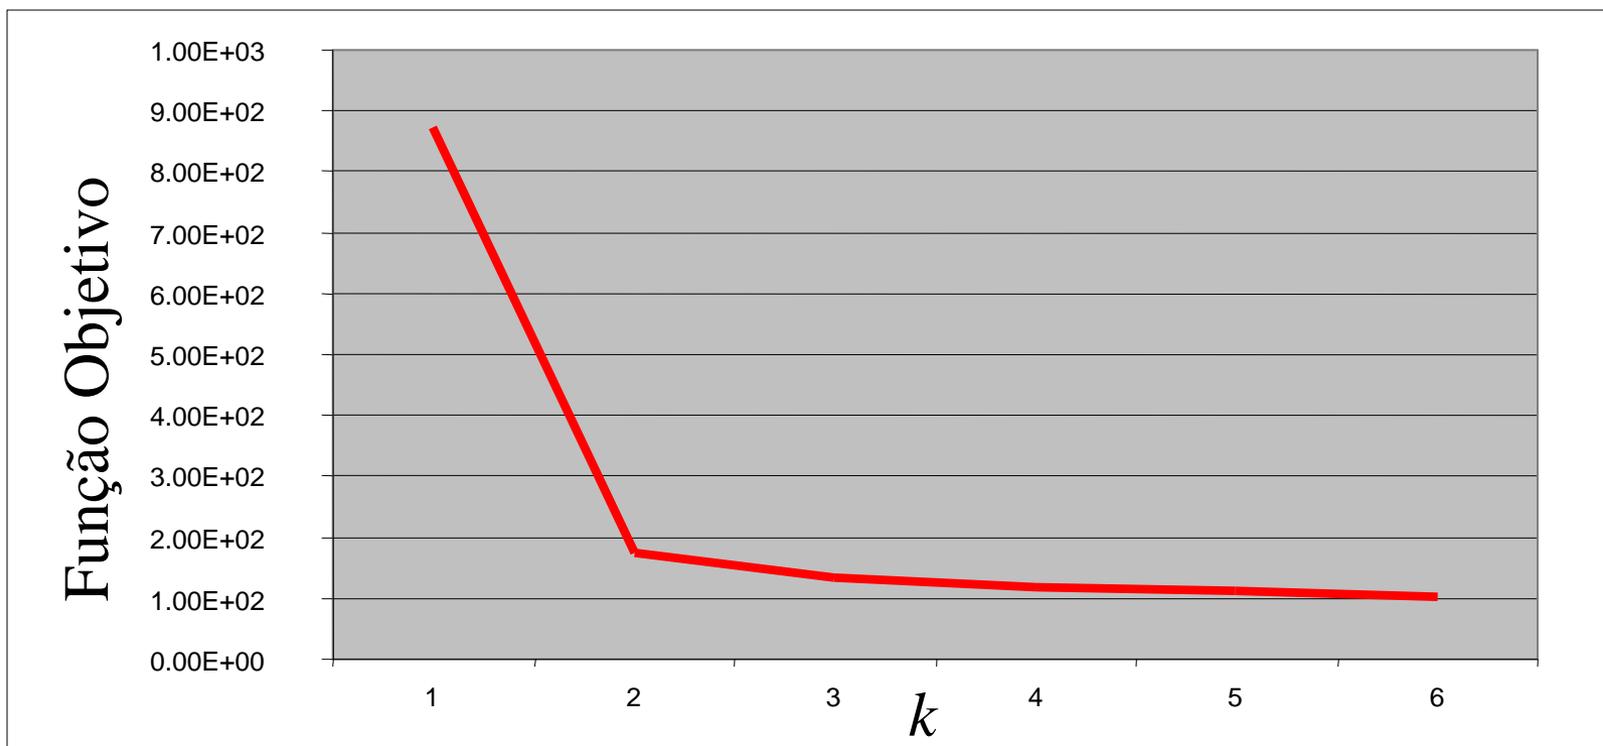
Para $k = 2$, o valor da função objetivo é 173,1



Para $k = 3$, o valor da função objetivo é 133,6

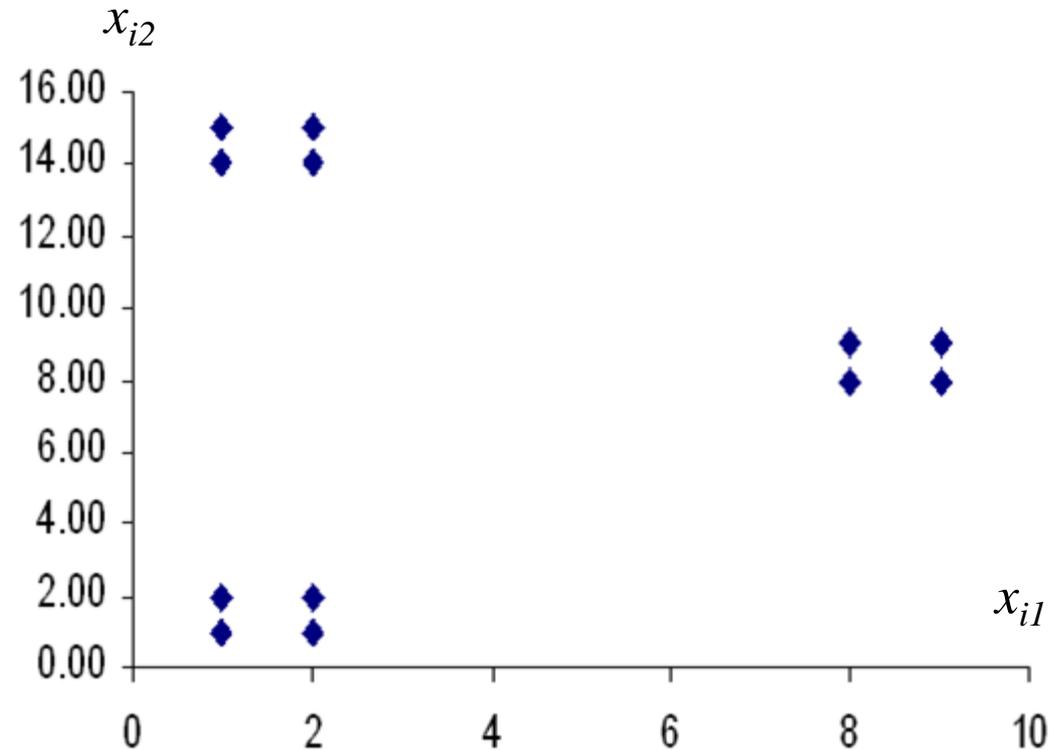


Podemos então repetir este procedimento e plotar os valores da função objetivo J para $k = 1, \dots, 6, \dots$ e tentar identificar um “joelho” :



Exercício

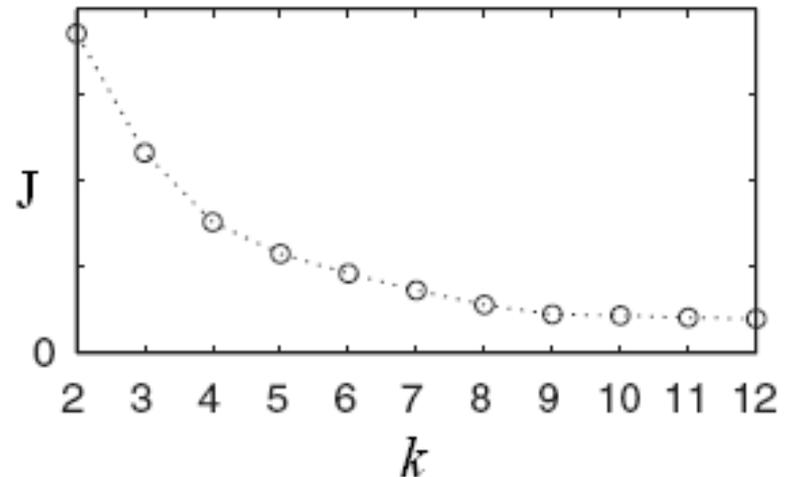
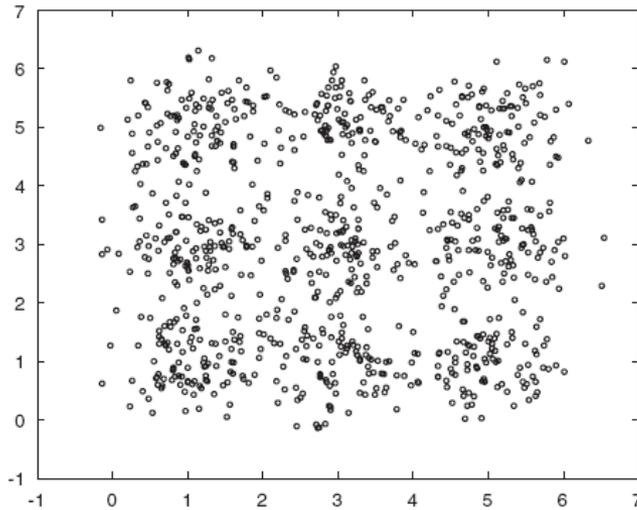
Objeto x_i	x_{i1}	x_{i2}
1	1	2
2	2	1
3	1	1
4	2	2
5	8	9
6	9	8
7	9	9
8	8	8
9	1	15
10	2	15
11	1	14
12	2	14



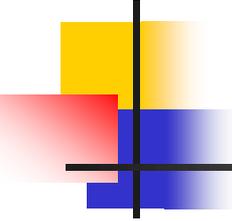
- Executar k-means com $k=2$ até $k=5$ nos dados acima e representar graficamente a f. objetivo J em função de k

Questão...

- Infelizmente os resultados não são sempre tão claros quanto no exemplo anterior... Vide exemplo abaixo...



- Além disso, como utilizar essa metodologia em variantes baseadas em busca guiada, que otimizam k ?
 - X-means, k-means evolutivo, ...
- Solução: vide aulas de **validação de agrupamento** !



Referências

- Jain, A. K. and Dubes, R. C., Algorithms for Clustering Data, Prentice Hall, 1988
- Kaufman, L., Rousseeuw, P. J., Finding Groups in Data – An Introduction to Cluster Analysis, Wiley, 2005.
- Tan, P.-N., Steinbach, M., and Kumar, V., *Introduction to Data Mining*, Addison-Wesley, 2006
- Wu, X. and Kumar, V., *The Top Ten Algorithms in Data Mining*, Chapman & Hall/CRC, 2009
- D. Steinley, *K-Means Clustering: A Half-Century Synthesis*, British J. of Mathematical and Stat. Psychology, V. 59, 2006