

# Lecture 10

## Clustering

**Mercoledì, 21 Febbraio 2007**

**Giuseppe Manco**

*Readings:*

Chapter 8, Han and Kamber

Chapter 14, Hastie , Tibshirani and Friedman

# Outline

- Introduction
- K-means clustering
- Hierarchical clustering: COBWEB

# Apprendimento supervisionato

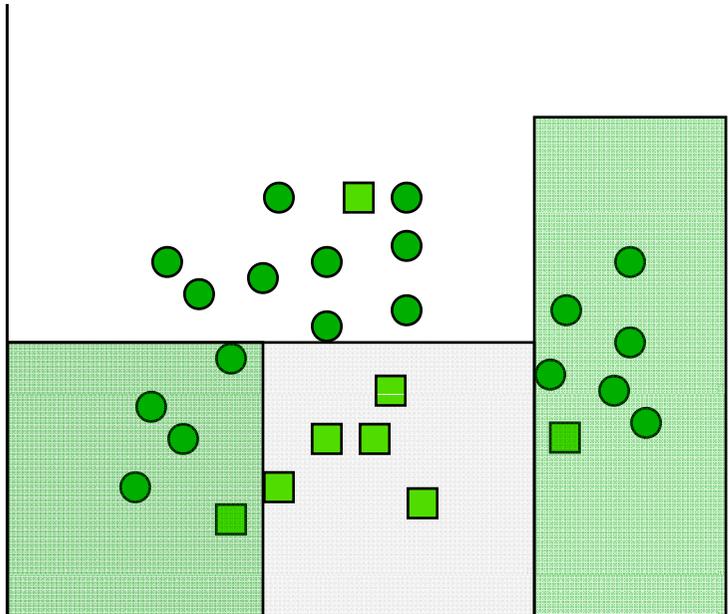
- **Dati**
  - Un insieme  $X$  di istanze su dominio multidimensionale
  - Un funzione target  $c$
  - Il linguaggio delle ipotesi  $H$
  - Un insieme di allenamento  $D = \{ \langle x, c(x) \rangle \}$
  
- **Determinare**
  - L'ipotesi  $h \in H$  tale che  $h(x) = c(x)$  per ogni  $x \in D$
  - Che sia consistente con il training set

# Supervised vs. Unsupervised Learning

- **Supervised learning (classificazione)**
  - Supervisione: il training set contiene l'etichetta che indica la classe da apprendere
  - I nuovi dati sono classificati sulla base di quello che si apprende dal training set
- **Unsupervised learning (clustering)**
  - L'etichetta di classe è sconosciuta
  - Le istanze sono fornite con l'obiettivo di stabilire se vi sono raggruppamenti (classi) tra i dati

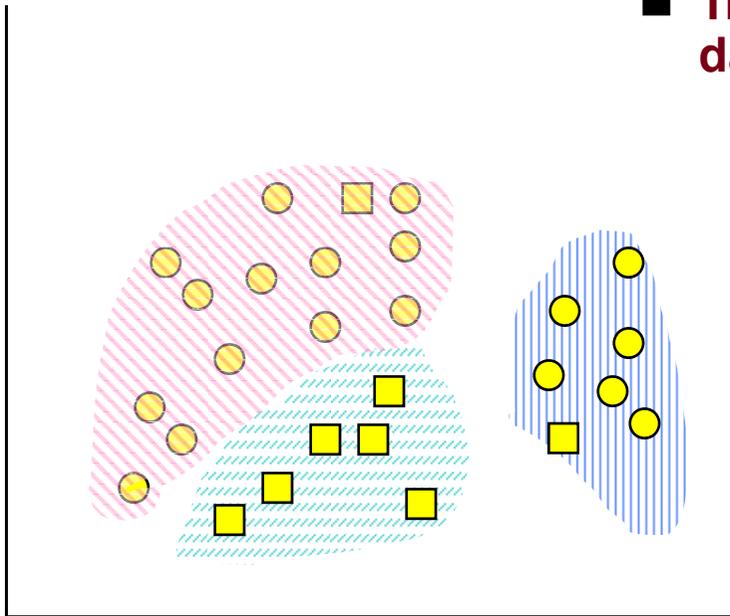
# Classificazione, Clustering

- **Classificazione:** Apprende un metodo per predire la classe dell'istanza da altre istanze pre-classificate



# Clustering

- Trova raggruppamenti “naturali” nei dati non etichettati



- Applicazioni tipiche
  - Tool stand-alone to get insight into data distribution
  - Passo di preprocessing per altri algoritmi

# Clustering, clusters

- **Raggruppamento di dati in classi (clusters) che abbiano una significatività**
  - alta similarità intra-classe
  - Bassa similarità inter-classe
- **Qualità di uno schema di clustering**
  - La capacità di ricostruire la struttura nascosta
    - similarità

# Similarità, distanza

- **Distanza  $d(x,y)$** 
  - Misura la “dissimilarità tra gli oggetti”
- **Similarità  $s(x,y)$** 
  - $S(x,y) \approx 1/d(x,y)$
  - Esempio

$$s(x, y) = e^{-d(x,y)}$$

- **Proprietà desiderabili**

$$d(\mathbf{x}_i, \mathbf{x}_j) \geq 0$$

$$d(\mathbf{x}_i, \mathbf{x}_i) = 0$$

$$d(\mathbf{x}_i, \mathbf{x}_j) = d(\mathbf{x}_j, \mathbf{x}_i)$$

$$d(\mathbf{x}_i, \mathbf{x}_j) \leq d(\mathbf{x}_i, \mathbf{x}_k) + d(\mathbf{x}_k, \mathbf{x}_j)$$

- **Definizione application-dependent**
  - Può richiedere normalizzazione
  - Diverse definizioni per differenti tipi di attributi

# Esempio

Istanza	$X_1$	$X_2$	$X_3$
$I_1$	0	0	0
$I_2$	1	0	0
$I_3$	2	0	0
$I_4$	2.5	2	0
$I_5$	3	0	0
$I_6$	1	2	1
$I_7$	1.5	0	1
$I_8$	2	2	1
$I_9$	3	2	1
$I_{10}$	4	2	1

$$\begin{bmatrix} d(I_1, I_1) & d(I_1, I_2) & \dots & d(I_1, I_{10}) \\ d(I_2, I_1) & d(I_2, I_2) & & \cdot \\ \cdot & & & \cdot \\ \cdot & & \cdot & \cdot \\ \cdot & & & \cdot \\ d(I_{10}, I_1) & d(I_{10}, I_2) & & d(I_{10}, I_{10}) \end{bmatrix}$$

# Similarità e dissimilarità tra oggetti

- La distanza è utilizzata per misurare la similarità (o dissimilarità) tra due istanze
- Distanza di Minkowski (Norma  $L_p$ ):

$$\text{dist}(x, y) = \left( \sum_{i=1}^d |x_i - y_i|^p \right)^{1/p}$$

- Dove  $\underline{x} = (x_1, x_2, \dots, x_d)$  e  $\underline{y} = (y_1, y_2, \dots, y_d)$  sono due oggetti  $d$ -dimensionali, e  $p$  è un numero primo
- se  $p = 1$ ,  $d$  è la distanza Manhattan

$$\text{dist}(x, y) = \sum_{i=1}^d |x_i - y_i|$$

- Se  $p = \infty$

$$\text{dist}(x, y) = \sup_{1 \leq i \leq d} |x_i - y_i|$$

# Similarità e dissimilarità tra oggetti [2]

- se  $p = 2$ ,  $d$  è la distanza euclidea:

$$\text{dist}(x, y) = \sqrt{\sum_{i=1}^d (x_i - y_i)^2}$$

- Proprietà
  - Translation-invariant
  - Scale variant

- Varianti

- Distanza pesata

$$\text{dist}(x, y) = \left( \sum_{i=1}^d w_i |x_i - y_i|^p \right)^{1/p}$$

- Distanza Mahalanobis

$$\text{dist}(x, y) = (x - y)^T \Sigma^{-1} (x - y)$$

# Esempio

Euclidea

0	1	2	3,2016	3	2,4495	1,8028	3	3,7417	4,5826
1	0	1	2,5	2	2,2361	1,118	2,4495	3	3,7417
2	1	0	2,0616	1	2,4495	1,118	2,2361	2,4495	3
3,2016	2,5	2,0616	0	2,0616	1,8028	2,4495	1,118	1,118	1,8028
3	2	1	2,0616	0	3	1,8028	2,4495	2,2361	2,4495
2,4495	2,2361	2,4495	1,8028	3	0	2,0616	1	2	3
1,8028	1,118	1,118	2,4495	1,8028	2,0616	0	2,0616	2,5	3,2016
3	2,4495	2,2361	1,118	2,4495	1	2,0616	0	1	2
3,7417	3	2,4495	1,118	2,2361	2	2,5	1	0	1
4,5826	3,7417	3	1,8028	2,4495	3	3,2016	2	1	0

mahalanobis

0	0,9	3,6	7,65	8,1	4,5	7,65	5,4	8,1	12,6
0,9	0	0,9	5,85	3,6	5,4	5,85	4,5	5,4	8,1
3,6	0,9	0	5,85	0,9	8,1	5,85	5,4	4,5	5,4
7,65	5,85	5,85	0	7,65	7,65	18	5,85	5,85	7,65
8,1	3,6	0,9	7,65	0	12,6	7,65	8,1	5,4	4,5
4,5	5,4	8,1	7,65	12,6	0	7,65	0,9	3,6	8,1
7,65	5,85	5,85	18	7,65	7,65	0	5,85	5,85	7,65
5,4	4,5	5,4	5,85	8,1	0,9	5,85	0	0,9	3,6
8,1	5,4	4,5	5,85	5,4	3,6	5,85	0,9	0	0,9
12,6	8,1	5,4	7,65	4,5	8,1	7,65	3,6	0,9	0

Istanza	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>
I <sub>1</sub>	0	0	0
I <sub>2</sub>	1	0	0
I <sub>3</sub>	2	0	0
I <sub>4</sub>	2.5	2	0
I <sub>5</sub>	3	0	0
I <sub>6</sub>	1	2	1
I <sub>7</sub>	1.5	0	1
I <sub>8</sub>	2	2	1
I <sub>9</sub>	3	2	1
I <sub>10</sub>	4	2	1

manhattan

0	1	2	4,5	3	4	2,5	5	6	7
1	0	1	3,5	2	3	1,5	4	5	6
2	1	0	2,5	1	4	1,5	3	4	5
4,5	3,5	2,5	0	2,5	2,5	4	1,5	1,5	2,5
3	2	1	2,5	0	5	2,5	4	3	4
4	3	4	2,5	5	0	2,5	1	2	3
2,5	1,5	1,5	4	2,5	2,5	0	2,5	3,5	4,5
5	4	3	1,5	4	1	2,5	0	1	2
6	5	4	1,5	3	2	3,5	1	0	1
7	6	5	2,5	4	3	4,5	2	1	0

Clustering



Consiglio Nazionale delle Ricerche  
Istituto di Calcolo e Reti ad Alte Prestazioni

# Similarità e dissimilarità tra oggetti [3]

- **Similarità del coseno**

$$\text{sim}(x, y) = \frac{x^T y}{\|x\| \|y\|}$$

- Proprietà

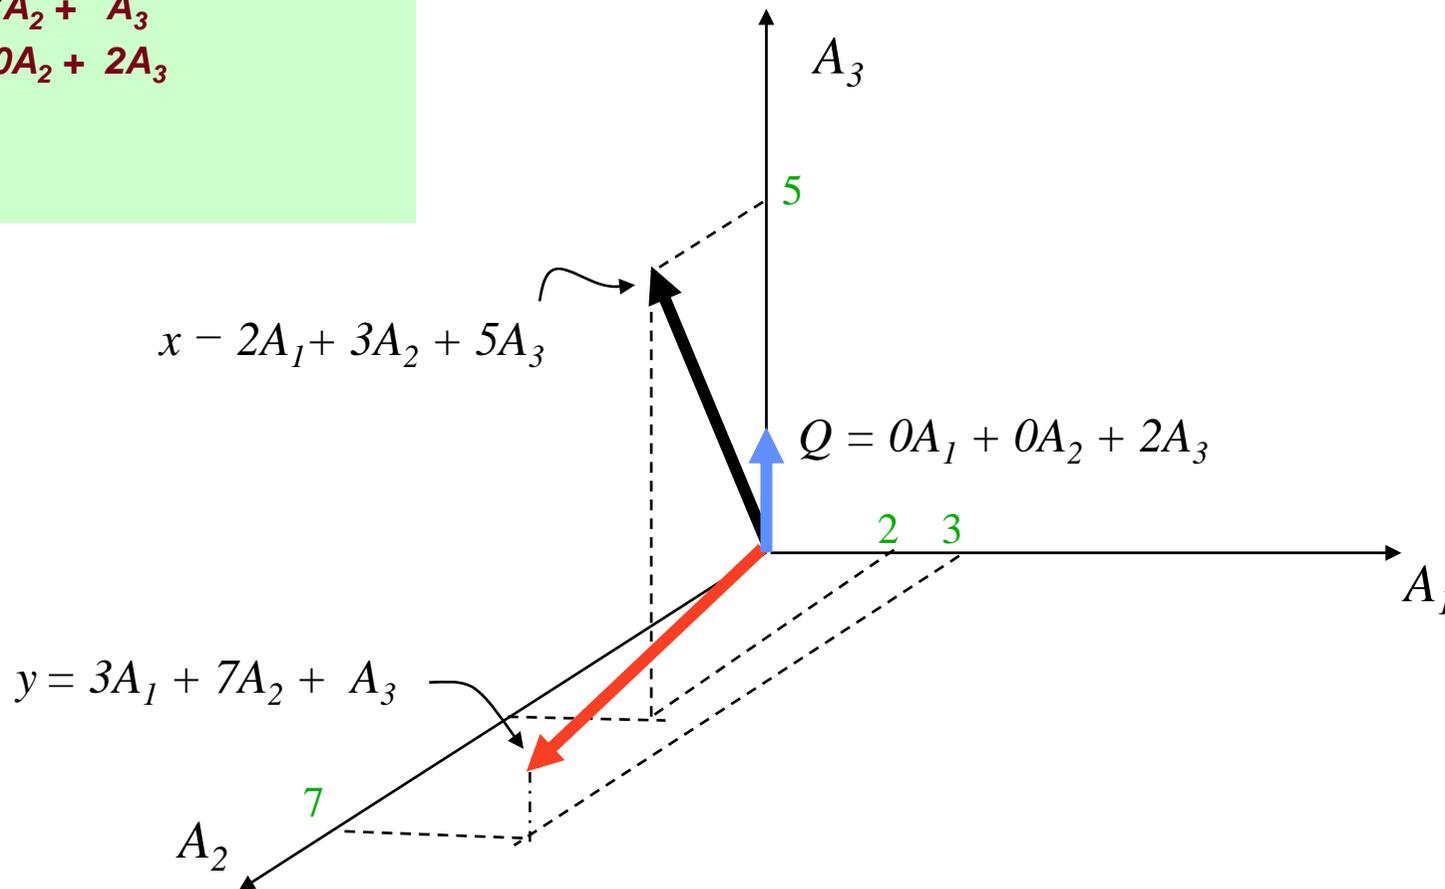
- Translation variant
- Scale invariant

- **Similarità di Jaccard (Tanimoto)**

$$\text{sim}(x, y) = \frac{x^T y}{\|x\|^2 + \|y\|^2 - x^T y}$$

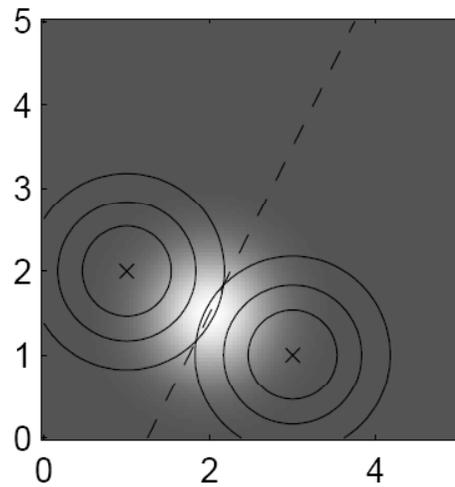
# Rappresentazione grafica

$$\begin{aligned}x &= 2A_1 + 3A_2 + 5A_3 \\y &= 3A_1 + 7A_2 + A_3 \\Q &= 0A_1 + 0A_2 + 2A_3\end{aligned}$$

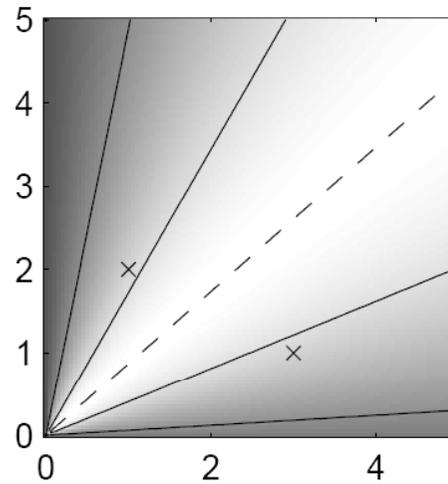


# Rappresentazione grafica

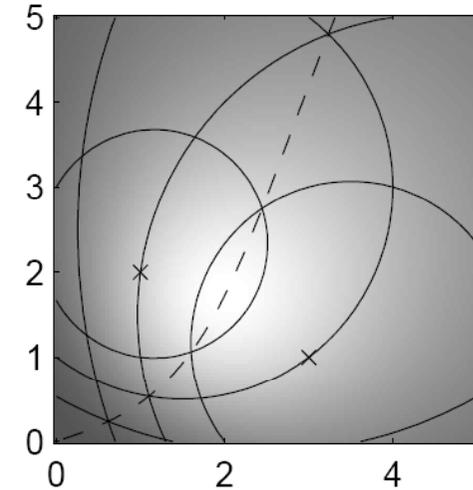
euclidea



Coseno



Jaccard



# Esempio

Euclidea

Coseno

0	1	2	3,2016	3	2,4495	1,8028	3	3,7417	4,5826	0	0	0	0	0	0	0	0	0	0
1	0	1	2,5	2	2,2361	1,118	2,4495	3	3,7417	0	0	0	0,21	0	0,59	0,16	0,33	0,19	0,12
2	1	0	2,0616	1	2,4495	1,118	2,2361	2,4495	3	0	0	0	0,21	0	0,59	0,16	0,33	0,19	0,12
3,2016	2,5	2,0616	0	2,0616	1,8028	2,4495	1,118	1,118	1,8028	0	0,21	0,21	0	0,21	0,17	0,35	0,06	0,03	0,045
3	2	1	2,0616	0	3	1,8028	2,4495	2,2361	2,4495	0	0	0	0,21	0	0,59	0,16	0,33	0,19	0,12
2,4495	2,2361	2,4495	1,8028	3	0	2,0616	1	2	3	0	0,59	0,59	0,17	0,59	0	0,43	0,04	0,12	0,19
1,8028	1,118	1,118	2,4495	1,8028	2,0616	0	2,0616	2,5	3,2016	0	0,16	0,16	0,35	0,16	0,43	0	0,26	0,18	0,15
3	2,4495	2,2361	1,118	2,4495	1	2,0616	0	1	2	0	0,33	0,33	0,06	0,33	0,04	0,26	0	0,022	0,054
3,7417	3	2,4495	1,118	2,2361	2	2,5	1	0	1	0	0,19	0,19	0,039	0,19	0,12	0,18	0,02	0	0,008
4,5826	3,7417	3	1,8028	2,4495	3	3,2016	2	1	0	0	0,12	0,12	0,04	0,12	0,19	0,15	0,054	0,008	0

Istanza	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>
I <sub>1</sub>	0	0	0
I <sub>2</sub>	1	0	0
I <sub>3</sub>	2	0	0
I <sub>4</sub>	2.5	2	0
I <sub>5</sub>	3	0	0
I <sub>6</sub>	1	2	1
I <sub>7</sub>	1.5	0	1
I <sub>8</sub>	2	2	1
I <sub>9</sub>	3	2	1
I <sub>10</sub>	4	2	1

Jaccard

0	0	0	0	0	0	0	0	0	0	0
0	0	0,66667	0,28571	0,42857	0,16667	0,54545	0,25	0,25	0,22222	
0	0,66667	0	0,54054	0,85714	0,25	0,70588	0,44444	0,5	0,47059	
0	0,28571	0,54054	0	0,6383	0,66667	0,38462	0,87805	0,90196	0,81159	
0	0,42857	0,85714	0,6383	0	0,25	0,58065	0,5	0,64286	0,66667	
0	0,16667	0,25	0,66667	0,25	0	0,37037	0,875	0,66667	0,5	
0	0,54545	0,70588	0,38462	0,58065	0,37037	0	0,48485	0,46809	0,4058	
0	0,25	0,44444	0,87805	0,5	0,875	0,48485	0	0,91667	0,76471	
0	0,25	0,5	0,90196	0,64286	0,66667	0,46809	0,91667	0	0,94444	
0	0,22222	0,47059	0,81159	0,66667	0,5	0,4058	0,76471	0,94444	0	

Clustering



Consiglio Nazionale delle Ricerche  
Istituto di Calcolo e Reti ad Alte Prestazioni

# Attributi binari

- **Distanza di Hamming**

$$\text{dist}(x, y) = \sum_{i=1}^d |x_i - y_i| = \sum_{i=1}^d \delta(x_i, y_i)$$

$$\delta(x_i, y_i) = \begin{cases} 1 & \text{se } x_i \neq y_i \\ 0 & \text{altrimenti} \end{cases}$$

- Distanza Manhattan quando i valori possibili sono 0 o 1
- **In pratica, conta il numero di mismatches**

# Attributi binari

- Utilizzando la tabella di contingenza

		Oggetto y		
		1	0	<i>totale</i>
Oggetto x	1	$a$	$b$	$a+b$
	0	$c$	$d$	$c+d$
	<i>totale</i>	$a+c$	$b+d$	$p$

- Coefficiente di matching (invariante, se le variabili sono simmetriche):

$$d(x, y) = \frac{b + c}{a + b + c + d}$$

- Coefficiente di Jaccard (noninvariante se le variabili sono asimmetriche):

$$d(x, y) = \frac{b + c}{a + b + c}$$

## Dissimilarità tra attributi binari

- Esempio

Name	Gender	Fever	Cough	Test-1	Test-2	Test-3	Test-4
Jack	M	Y	N	P	N	N	N
Mary	F	Y	N	P	N	P	N
Jim	M	Y	P	N	N	N	N

- gender è simmetrico
- Tutti gli altri sono asimmetrici
- Poniamo Y e P uguale a 1, e N a 0

$$d(\text{jack}, \text{mary}) = \frac{0 + 1}{2 + 0 + 1} = 0.33$$

$$d(\text{jack}, \text{jim}) = \frac{1 + 1}{1 + 1 + 1} = 0.67$$

$$d(\text{jim}, \text{mary}) = \frac{1 + 2}{1 + 1 + 2} = 0.75$$

# Variabili Nominali

- Generalizzazione del meccanismo di variabili binarie
- Metodo 1: Matching semplice
  - $m$ : # di matches,  $p$ : # di attributi nominali

$$d(x, y) = \frac{p - m}{p}$$

- metodo 2: binarizzazione
- Metodo 3: Jaccard su insiemi

# Combinare dissimilarità

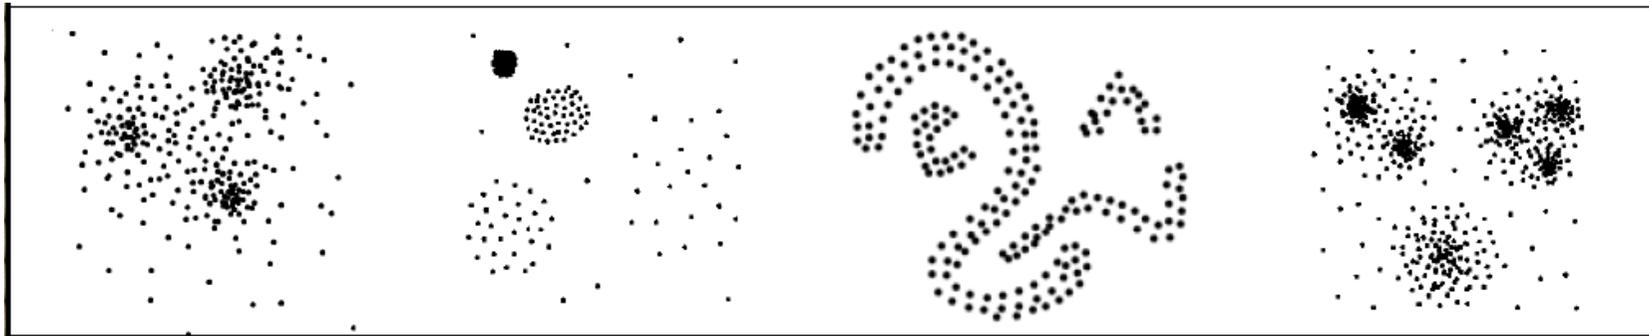
- **x,y**
  - $x_R, y_R$ : attributi numerici
  - $x_n, y_n$ : attributi nominali

$$\text{dist}(x, y) = \alpha \text{dist}(x_R, y_R) + \beta \text{dist}(x_n, y_n)$$

- Va garantita la stessa scala

# Metodi di clustering

- **Una miriade di metodologie differenti:**
  - **Dati numerici/simbolici**
  - **Deterministici/probabilistici**
  - **Partizionali/con overlap**
  - **Gerarchici/piatti**
  - **Top-down/bottom-up**



# Clustering per enumerazione

- Utilizzando come criterio

$$w(C) = \sum_{x \in C} \sum_{y \in C} dist(x, y)$$

- Il numero di possibili clusterings sarebbe

$$S(n, k) = \frac{1}{k!} \sum_{i=1}^k (-1)^{k-i} \binom{k}{i} \times i^n$$

- $S(10,4)=34.105$

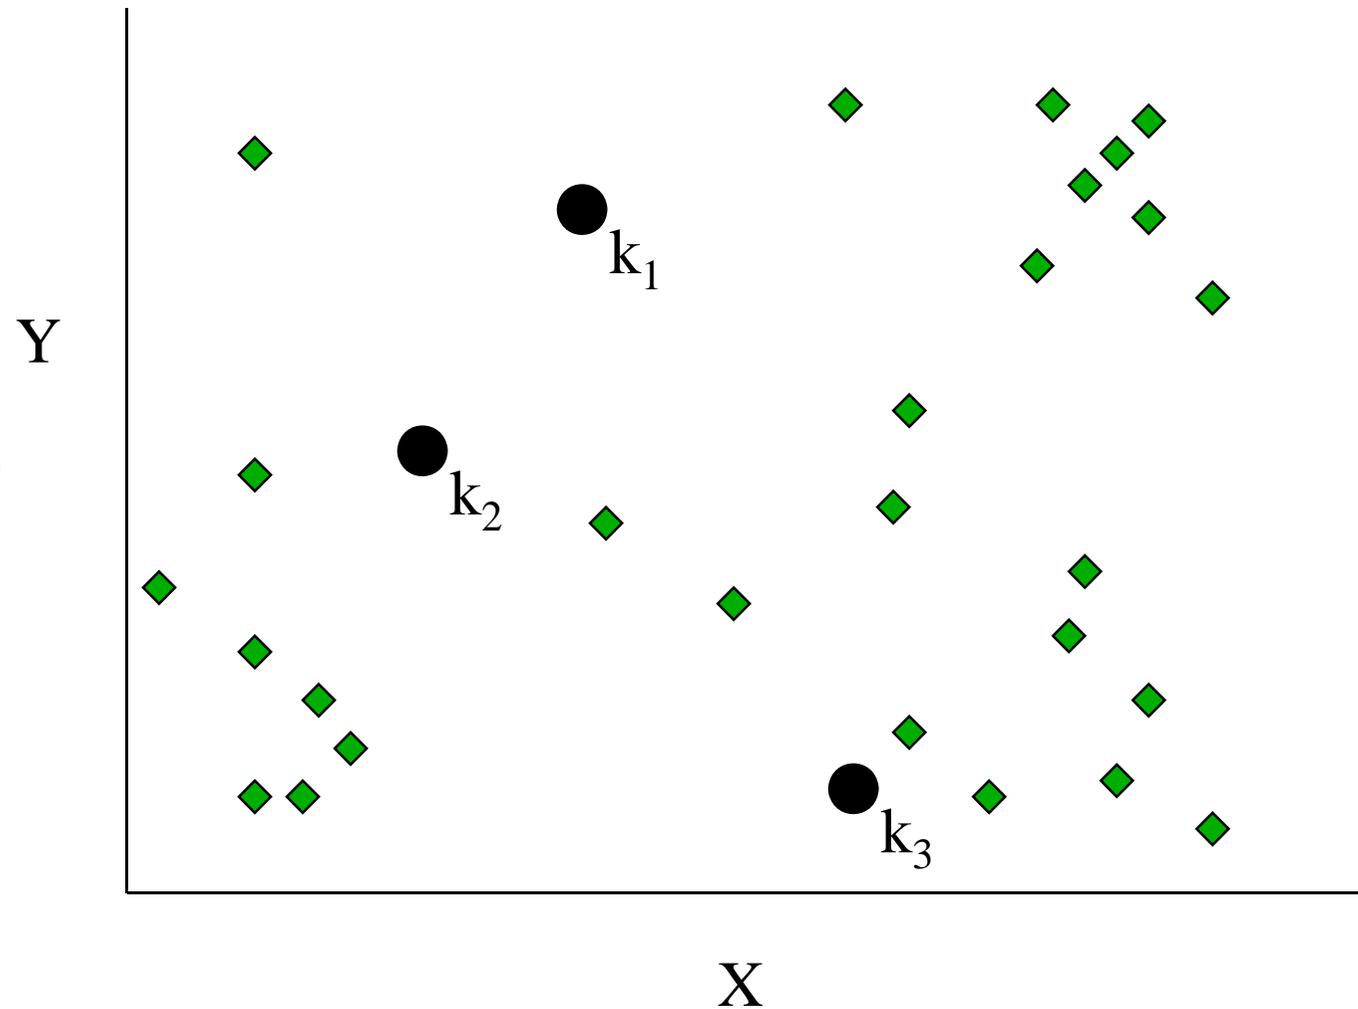
# L'algoritmo più semplice: K-means

- **Algorithm *K-Means*(*D*, *k*)**

- $m \leftarrow D.size$  // numero di istanze
- FOR  $i \leftarrow 1$  TO  $k$  DO
  - $\mu_i \leftarrow \text{random}$  // scegli un punto medio a caso
- WHILE (condizione di terminazione) // calcolo del cluster
  - FOR  $j \leftarrow 1$  TO  $m$  DO
    - membership
    - $h \leftarrow \text{argmin}_{1 \leq i \leq k} \text{dist}(x_j, \mu_i)$
    - $C[h] \leftarrow x_j$
  - FOR  $i \leftarrow 1$  TO  $k$  DO
    - $\mu_i \leftarrow \frac{1}{n_i} \sum_{x_j \in C[i]} x_j$
- RETURN *Make-Predictor* ( $w$ ,  $P$ )

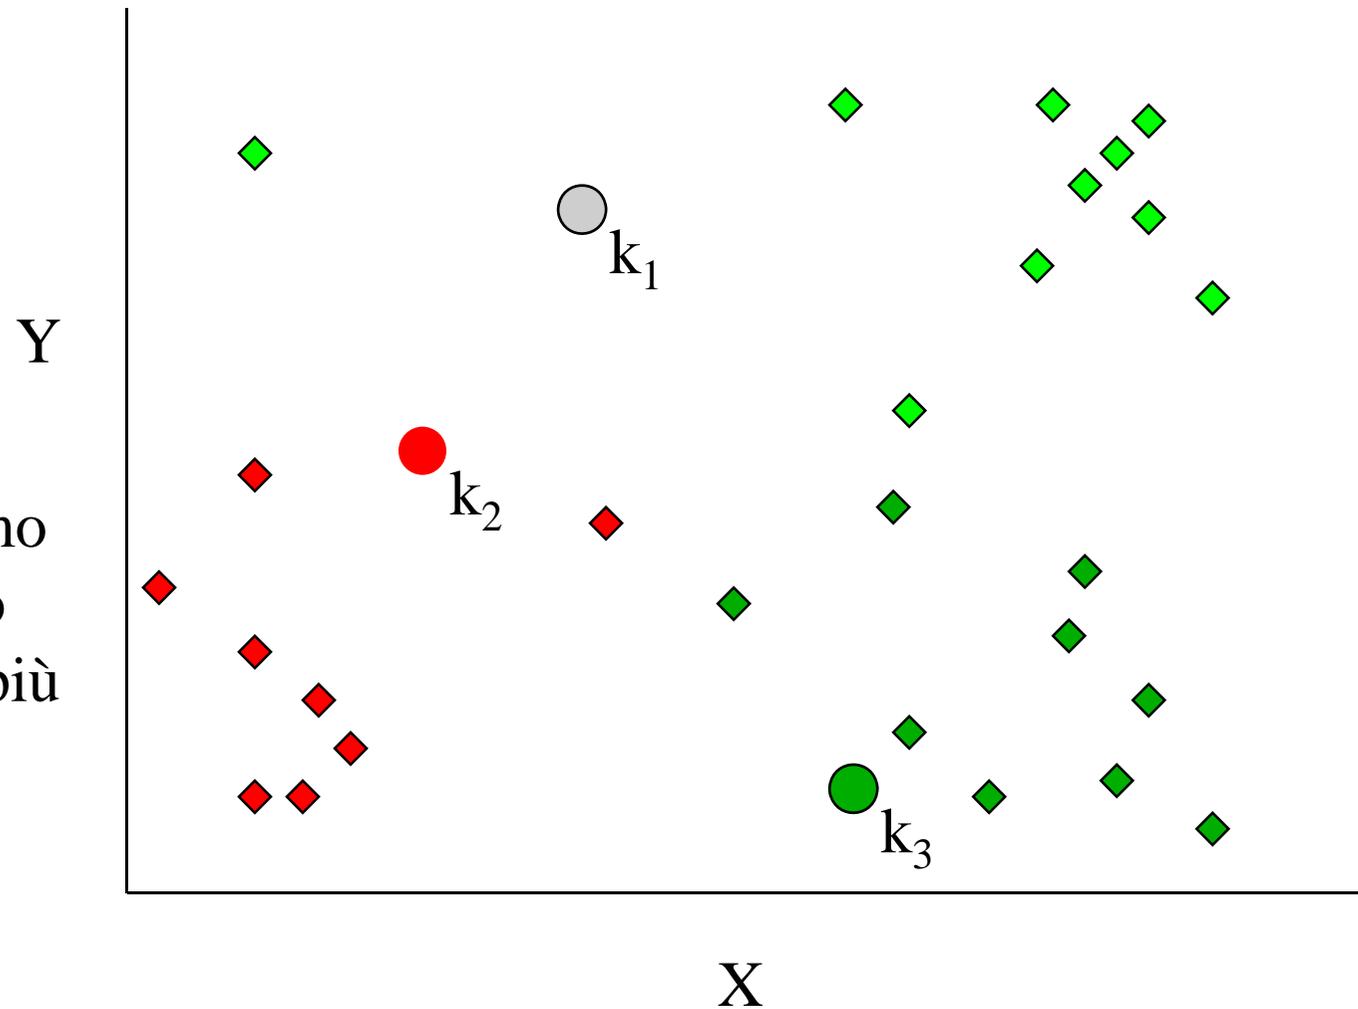
# Esempio [1]

Scegliamo  
3 centri  
iniziali



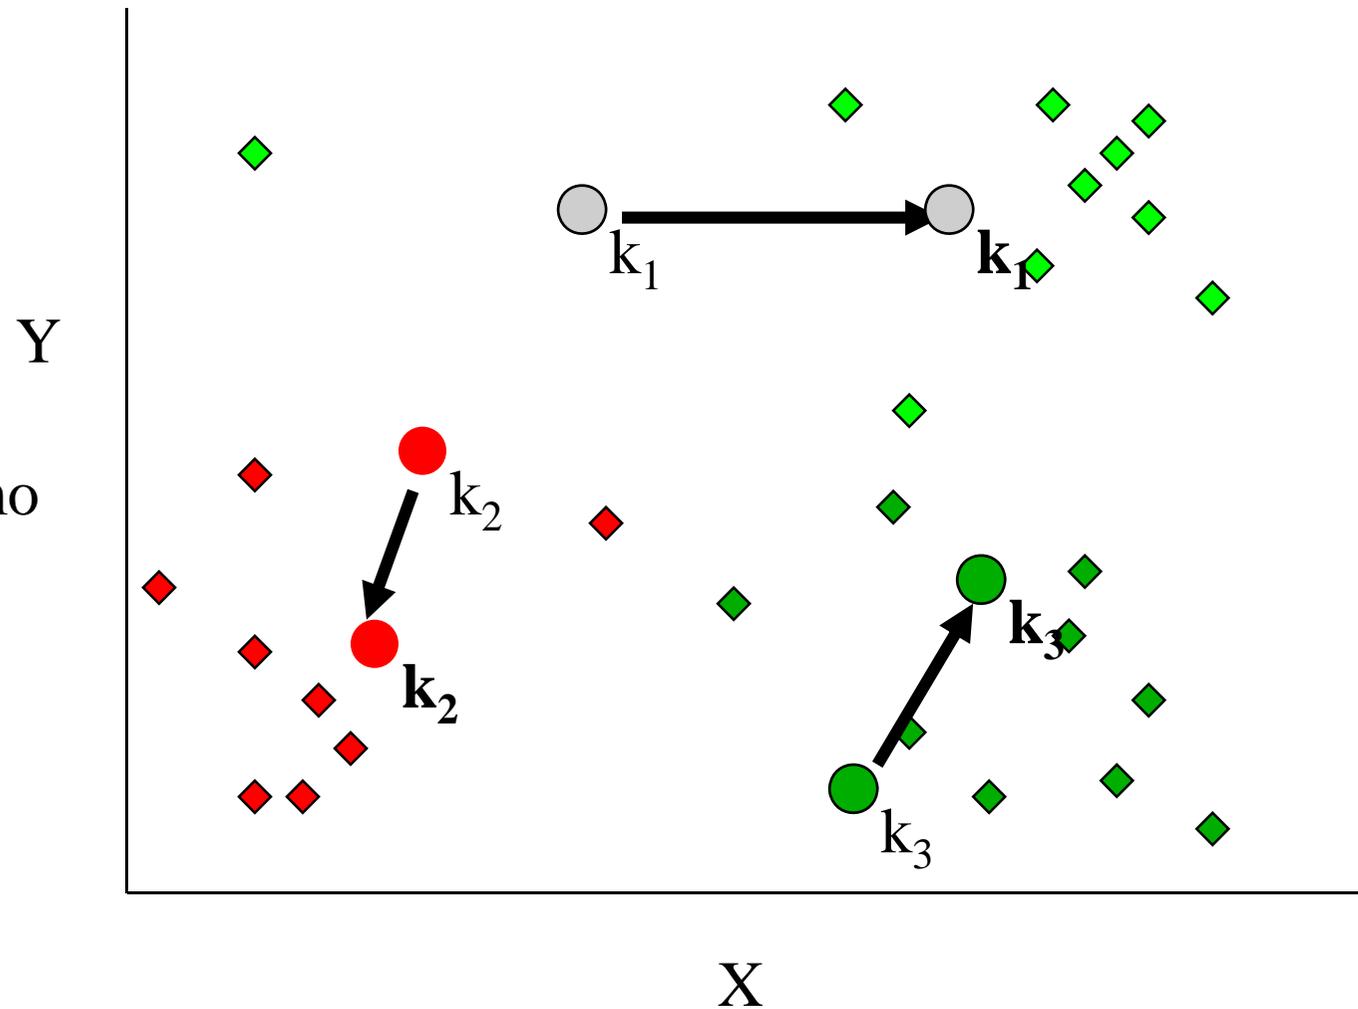
# Esempio [2]

Assegniamo  
ogni punto  
al cluster più  
vicino



# Esempio [3]

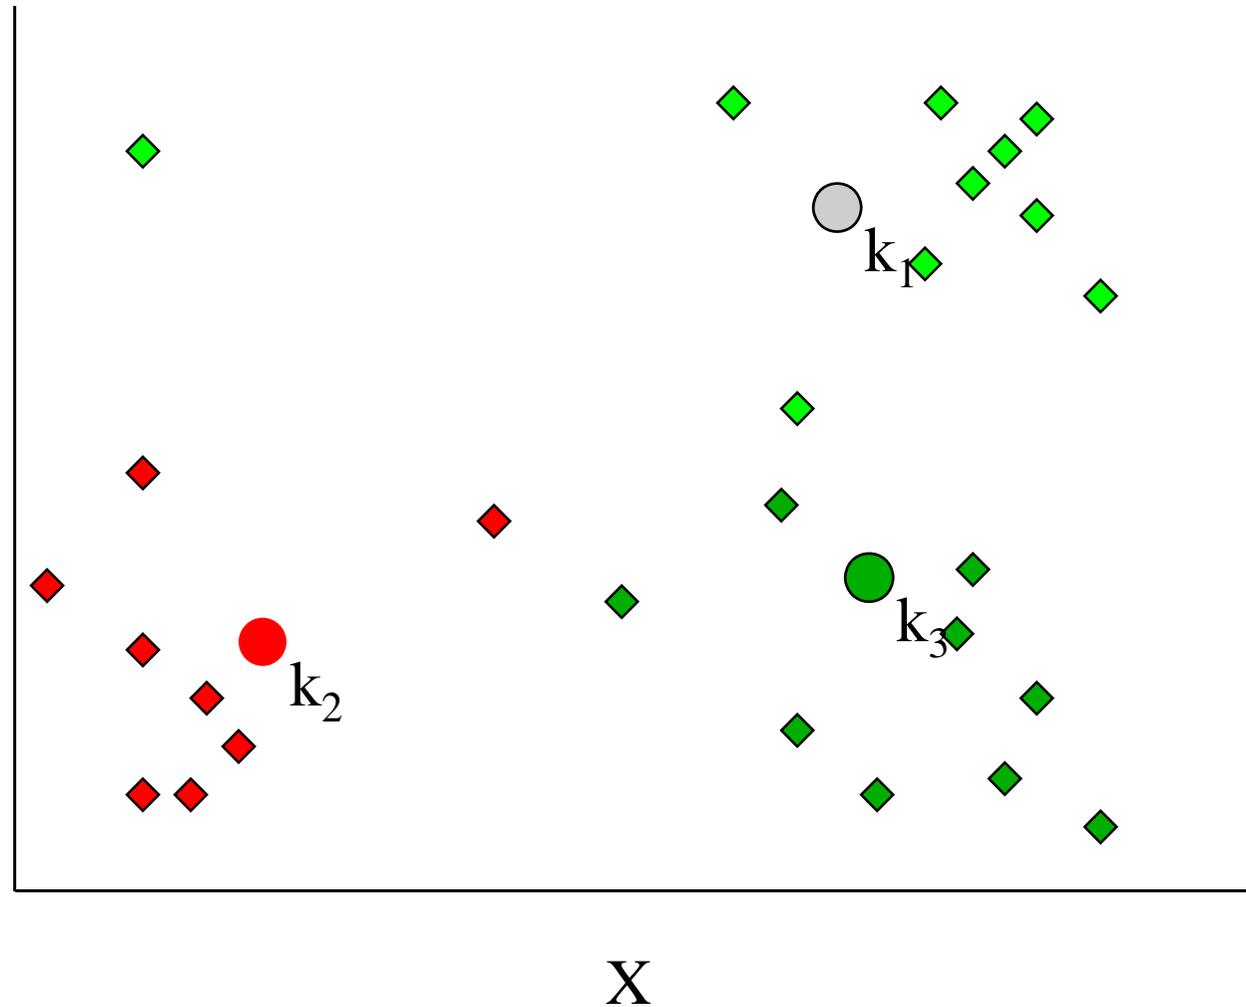
Ricalcoliamo  
il centroide



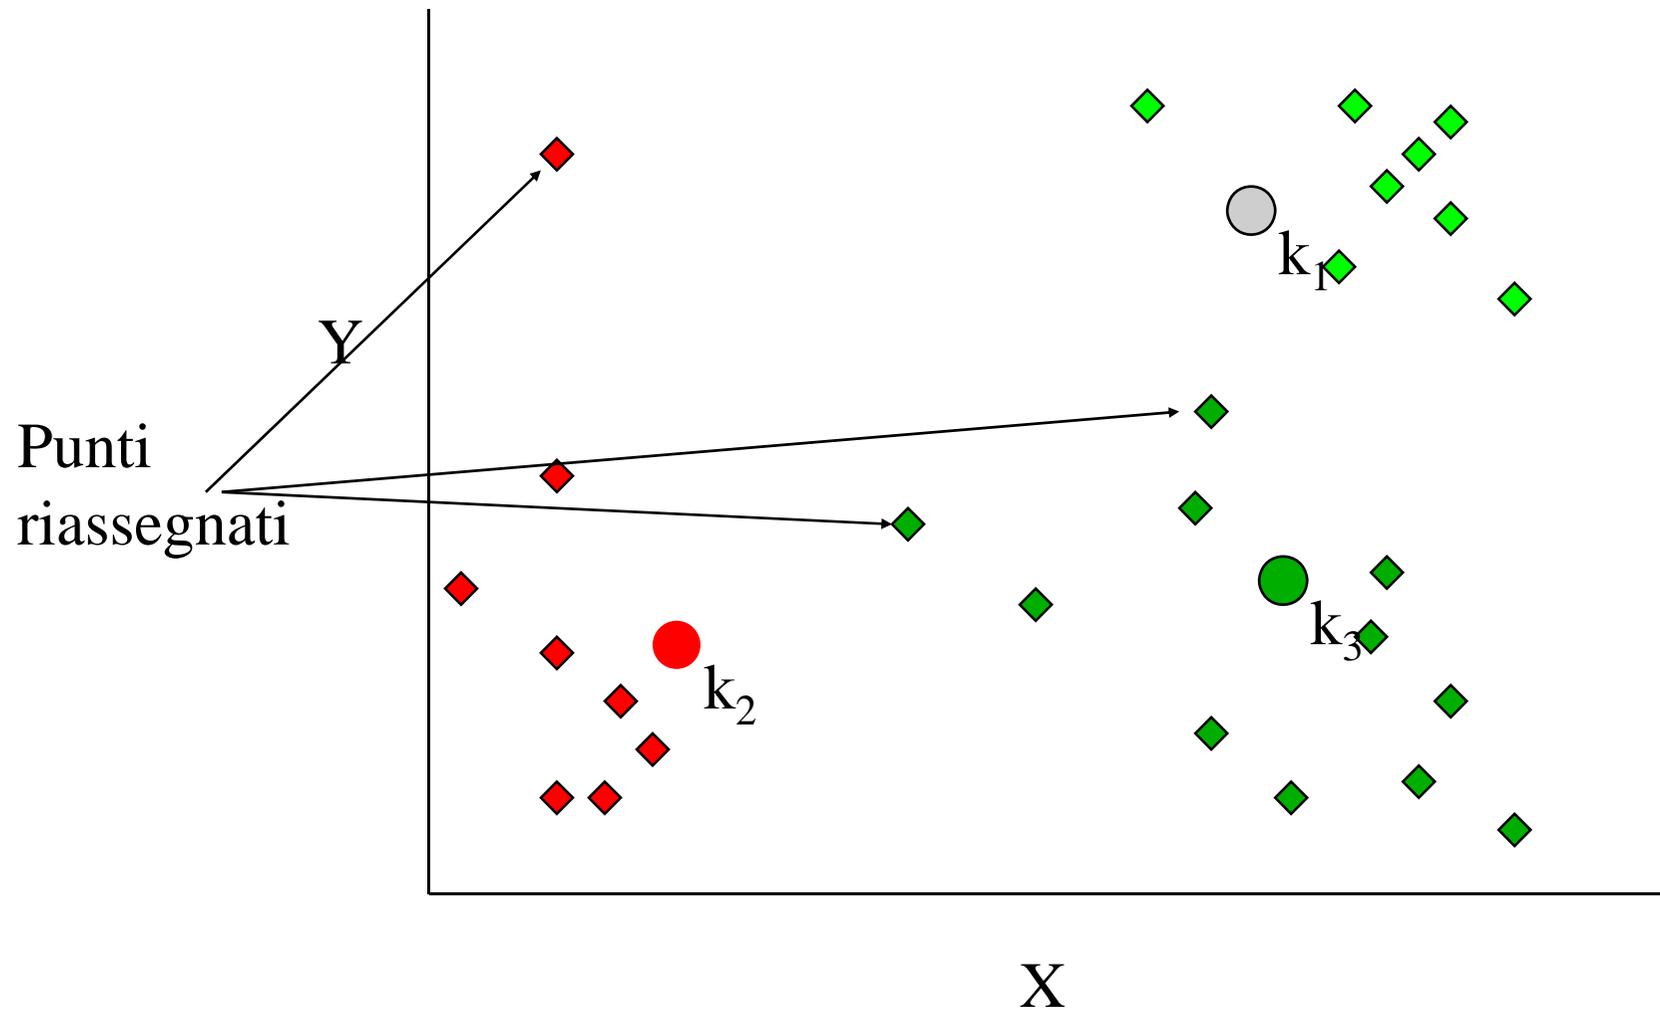
# Esempio [4]

Riassegniamo  
i punti ai  
clusters

Y

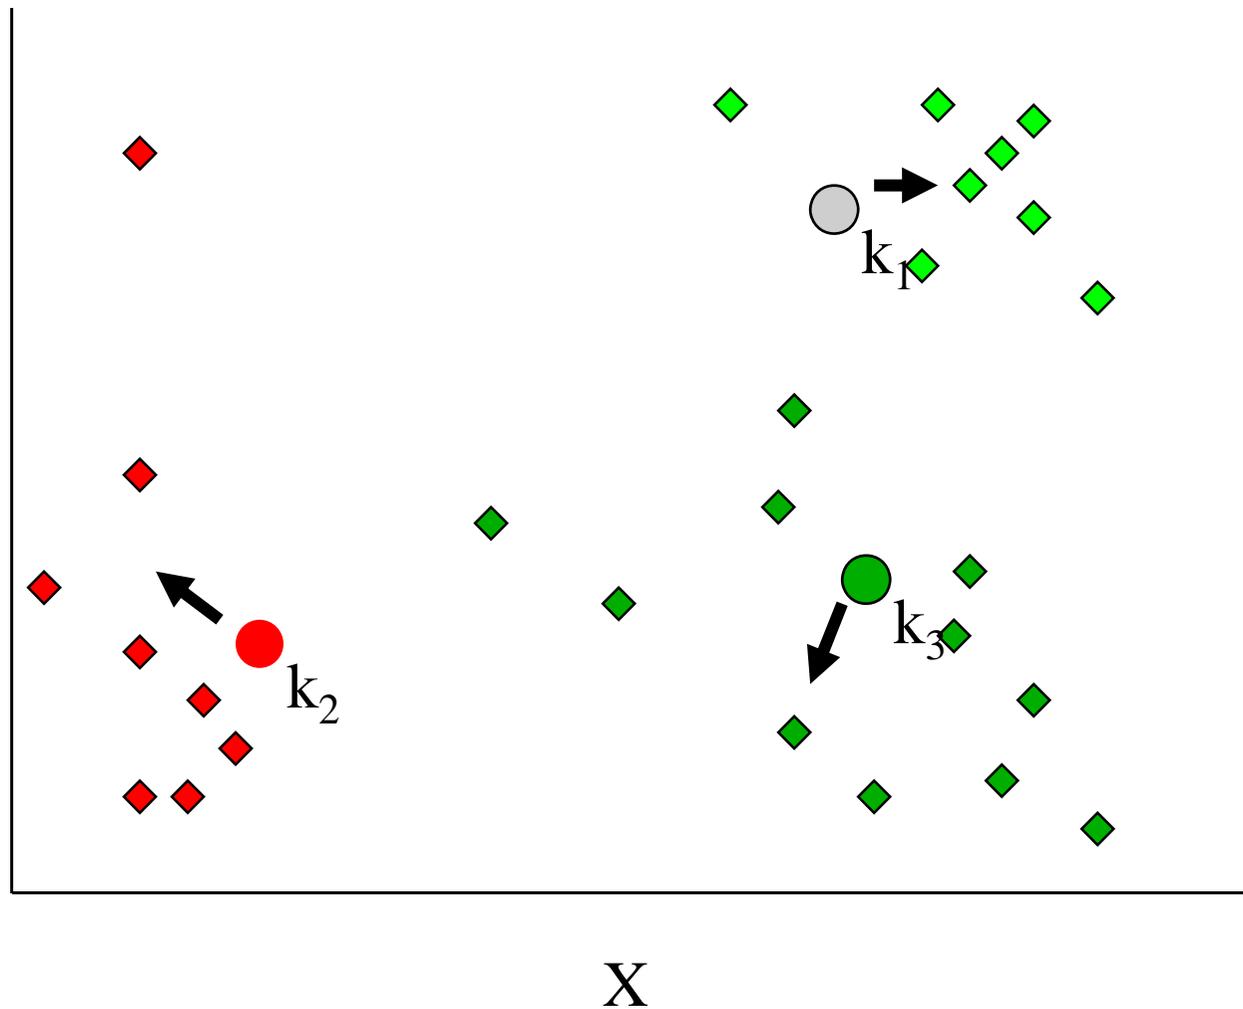


# Esempio [5]

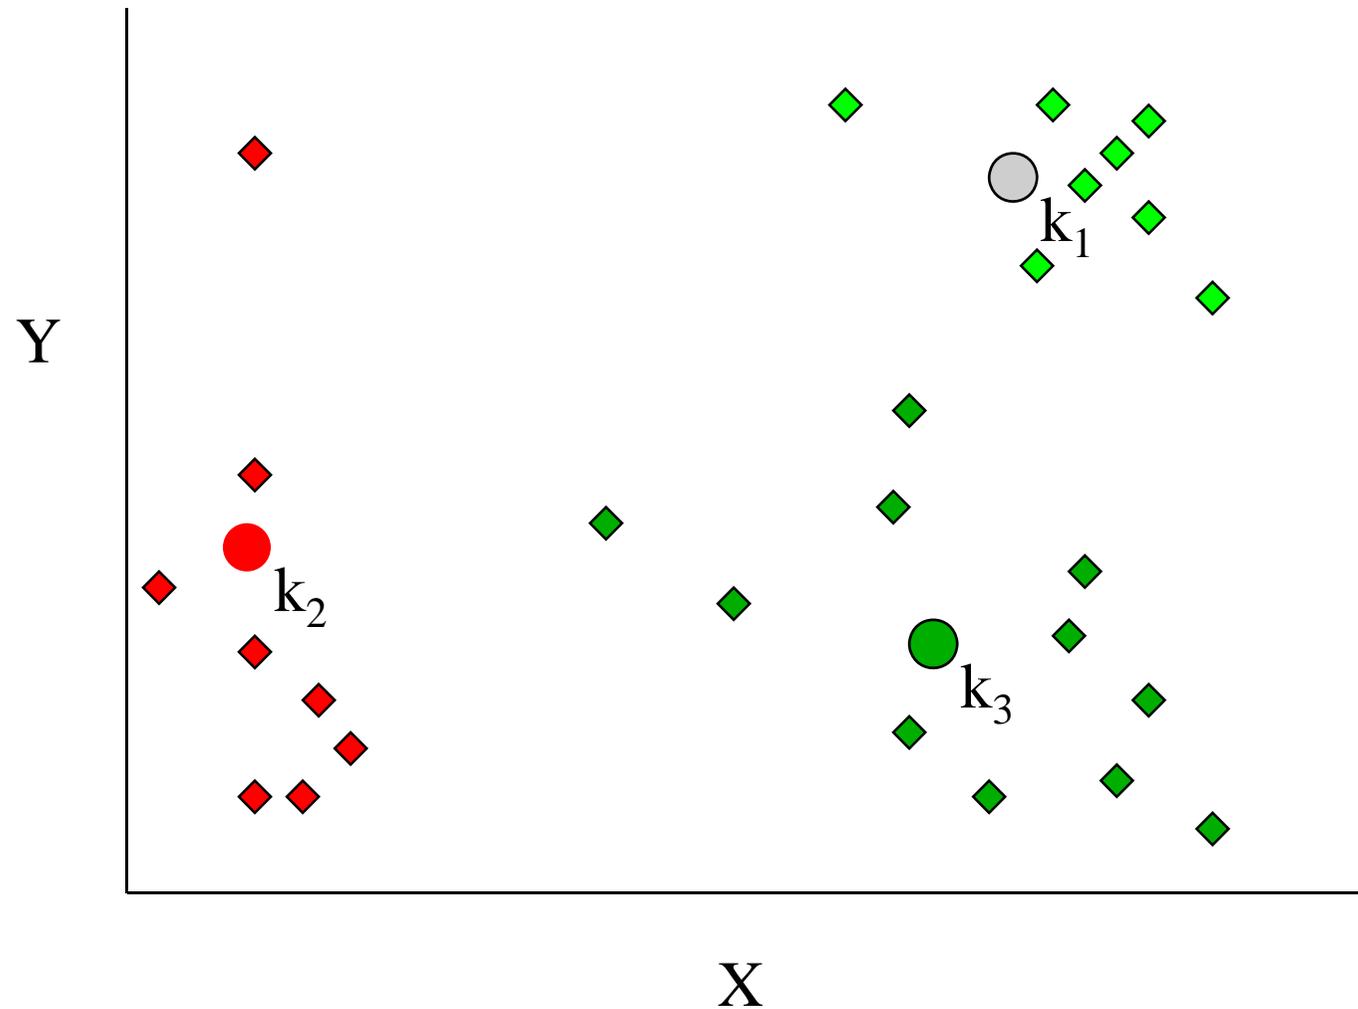


# Esempio [5]

Y  
Ricalcoliamo  
i centroidi



# Esempio [7]



# Quale criterio di stop?

- **Cos'è il centroide?**

$$\mu_c = \arg \min_{y \in X} \sum_{x \in C} \text{dist}(x, y)$$

- **Misura della compattezza di un cluster**

$$\text{cost}(C) = \sum_{x \in C} \text{dist}(x, \mu_c)$$

- **Misura della compattezza del clustering**

$$\text{cost}(S = [C_1, \dots, C_k]) = \sum_{C_i \in S} \text{cost}(C_i)$$

- **Teorema**

- Ad una generica iterazione  $t$ ,

$$\text{cost}(S^t) \geq \text{cost}(S^{t+1})$$

# Il metodo K-Means

- Vantaggi: *Relativamente efficiente*:  $O(tkn)$ , dove  $n$  è il numero di oggetti,  $k$  il numero di clusters e  $t$  il numero di iterazioni. Di solito,  $k, t \ll n$ .
  - Al confronto: PAM:  $O(k(n-k)^2)$ , CLARA:  $O(ks^2 + k(n-k))$
- Converge ad un ottimo locale. L'ottimo globale può essere trovato ricorrendo a varianti (ad esempio, basati su algoritmi genetici)
- Punti critici
  - Applicabile solo quando il punto medio ha senso
    - Attributi nominali?
  - K va dato in input
    - Qual'è il numero ottimale?
  - Incapace di gestire outliers e rumore
  - Non adatto a scoprire forme non convesse

# Varianti

- Selezione dei centri iniziali
- Strategie per calcolare i centroidi
- L'algoritmo *k-modes* (Huang'98)
  - Dati categorici
  - Usiamo le mode invece dei centroidi
  - Usiamo Hamming
  - L'update si basa sul cambiamento di frequenze
  - Modelli misti: *k-prototype*

# Varianti

- K-medoids – invece del centroide, usa il punto mediano

- La media di 1, 3, 5, 7, 9 è
- La media di 1, 3, 5, 7, 1009 è
- La mediana di 1, 3, 5, 7, 1009 è



- Problema: come calcolare il medoide?

$$m_c = \arg \min_{y \in C} \sum_{x \in C} dist(x, y)$$

# Algoritmo PAM

1. Seleziona  $k$  oggetti  $m_1, \dots, m_k$  arbitrariamente da  $D$ 
  - $m_1, \dots, m_k$  rappresentano i medoidi
2. Assegna ogni oggetto  $x \in D$  al cluster  $j$  ( $1 \leq j \leq k$ ) che ne minimizza la distanza dal medoide
  - Calcola  $\text{cost}(S)_{\text{current}}$
3. Per ogni coppia  $(m, x)$ 
  1. Calcola  $\text{cost}(S)_{x \leftrightarrow m}$
4. Seleziona la coppia  $(m, x)$  per cui  $\text{cost}(S)_{x \leftrightarrow m}$  è minimale
5. Se  $\text{cost}(S)_{x \leftrightarrow m} < \text{cost}(S)_{\text{current}}$ 
  - Scambia  $m$  con  $x$
6. Ritorna al passo 3 (2)

# Problemi con PAM

- **Più robusto del k-means in presenza di rumore e outliers**
  - Un medoide è meno influenzato del centroide dalla presenza di outliers
- **Efficiente su pochi dati, non scala su dati di grandi dimensioni.**
  - $O(k(n-k)^2)$  per ogni iterazione
- **Alternative basate sul campionamento**
  - CLARA(Clustering LARge Applications)
  - CLARANS

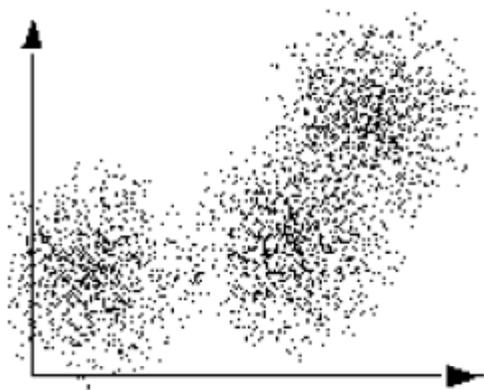
# Varianti al K-Medoid

- **CLARA [Kaufmann and Rousseeuw, 1990]**
  - Parametro addizionale: *numlocal*
  - Estrae *numlocal* campioni dal dataset
  - Applica PAM su ogni campione
  - Restituisce il migliore insieme di medoidi come output
  - Svantaggi:
  - L'efficienza dipende dalla dimensione del campione
  - Non necessariamente un clustering buono sul campione rappresenta un clustering buono sull'intero dataset
    - Sample bias
- **CLARANS [Ng and Han, 1994]**
  - Due ulteriori parametri: *maxneighbor* e *numlocal*
  - Vengono valutate al più *maxneighbor* coppie (m,x)
  - La prima coppia (m,x) per cui  $\text{cost}(S)_{x \leftrightarrow m} < \text{cost}(S)_{\text{current}}$  è scambiata
    - Evita il confronto con la coppia minimale
  - Si ripete la procedura *numlocal* volte per evitare il minimo locale.
- **$\text{runtime}(\text{CLARANS}) < \text{runtime}(\text{CLARA}) < \text{runtime}(\text{PAM})$**

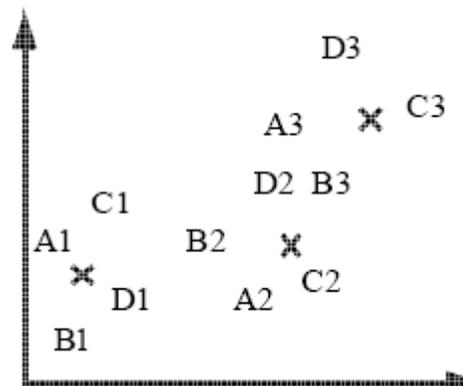
# Scelta dei punti iniziali

- [Fayyad, Reina and Bradley 1998]
  - costruisci  $m$  campioni differenti da  $D$
  - Clusterizza ogni campione, fino ad ottenere  $m$  stime per i  $k$  rappresentanti
    - $A = (A_1, A_2, \dots, A_k), B = (B_1, B_2, \dots, B_k), \dots, M = (M_1, M_2, \dots, M_k)$
  - Clusterizza  $DS = A \cup B \cup \dots \cup M$   $m$  volte
    - utilizzando gli insiemi  $A, B, \dots, M$  come centri iniziali
- Utilizza il risultato migliore come inizializzazione sull'intero dataset

# Inizializzazione



D



Centri su 4 campioni

✕ Centri effettivi

# Scelta del parametro k

- **Iterazione**
  - Applica l’algoritmo per valori variabili di k
    - $K=1, 2, \dots$
  - Scegli il clustering “migliore”
- **Come scegliere il clustering migliore?**
  - La funzione  $\text{cost}(S)$  è strettamente decrescente
    - $K_1 > K_2 \Rightarrow \text{cost}(S_1) < \text{cost}(S_2)$
- **Indici di bontà di un cluster**

# Indici di bontà

- In generale, si valuta intra-similarità e intersimilarità

$$\gamma \sum_{C_i} \sum_{x \in C_i} \sum_{y \in C_i} dist(x, y) + (1 - \gamma) \sum_{\substack{x \in C_i \\ i \neq j}} \sum_{y \in C_j} dist(x, y)$$

- $a(x)$ : distanza media di  $x$  dagli oggetti del cluster  $A$  cui  $x$  appartiene
- $b(x)$ : distanza media di  $x$  dagli oggetti del secondo cluster  $B$  più prossimo a  $x$
- Coefficiente su  $x$

$$s_x = \frac{a(x) - b(x)}{\max\{a(x), b(x)\}}$$

- $s_x = -1$ :  $x$  è più prossimo agli elementi di  $B$
  - $s_x = 0$ : non c'è differenza tra  $A$  e  $B$
  - $s_x = 1$ :  $x$  è stato clusterizzato bene
- Generalizzazione  $s_c$ 
    - Media dell'indice su tutti gli oggetti
    - Valori bassi: clustering debole
    - Valori alti: clustering robusto

# Minimum description Length

- **Il principio del Minimum Description Length**
  - **Rasoio di Occam: le ipotesi più semplici sono più probabili**

$$\Pr(M, D) = \Pr(D | M) \Pr(M)$$

$$\Pr(M | D) = \frac{\Pr(D | M) \Pr(M)}{\Pr(D)}$$

$$\Pr(M | D) \approx \Pr(D | M) \Pr(M)$$

- **(Il termine  $\Pr(D)$  non dipende da  $M$  e può essere ignorato)**
- **Più alto è  $\Pr(M|D)$ , migliore è il modello**

# Minimum Description Length, Numero ottimale di clusters

- Fissiamo un range possibile di valori per  $k$ 
  - $k = 1 \dots K$  (con  $K$  abbastanza alto)
- Calcoliamo  $\Pr(M_k|D)$  per ogni  $k$ 
  - Il valore  $k$  che esibisce il valore più alto è il migliore
- Problema: Come calcoliamo  $\Pr(M_k|D)$ ?

# Bayesian Information Criterion e Minimum Description Length

- **Problema: calcolare**

$$\Pr(D | M) \Pr(M)$$

- **Idea: adottiamo il trick del logaritmo**

$$\log[\Pr(D | M) \Pr(M)] = \log[\Pr(D | M)] + \log[\Pr(M)]$$

- **Cosa rappresentano i due termini?**

- $\log[\Pr(D | M)]$  = accuratezza del modello
- $\log[\Pr(M)]$  = complessità del modello

# Bayesian Information Criterion

–  $\log[\Pr(D | M)]$  = accuratezza del modello

- **Assunzione: algoritmo K-Means, distanza euclidea**

$$\log[\Pr(D | M)] = \log\left[\prod_i p(x_i | M)\right] = \sum_i \log[p(x_i | M)] \approx -Cost(D | M)$$

- **La giustificazione è data dall'interpretazione "gaussiana" del clustering K-Means**

$$p(x_i | M) = \frac{1}{\sqrt{2\pi}\sigma_k} \exp\left(\frac{-d(x_i, \mu_k)^2}{\sigma_k^2}\right) \text{ t.c. } x_i \in C_k$$

$$\sigma_k^2 = \sum_{x \in C_k} d(x_i, \mu_k)^2$$

$$\log[p(x_i | M)] \approx -\sum_k \sum_{x \in C_k} d(x_i, \mu_k)$$

# Bayesian Information Criterion

- $\log[\Pr(M)]$  = **complessità del modello**
  - Intuitivamente, quanti più cluster ci sono, più il clustering è complesso
    - E quindi, meno è probabile
  - Adottando un criterio basato sull'encoding (in bit) dell'informazione relativa ai clusters, otteniamo

$$\log[\Pr(M)] \approx n \log k$$

- Per ogni tuple nel dataset, codifichiamo a quale cluster appartiene

# Bayesian Information Criterion

$$BIC(M) = Cost(D | M) - \alpha n \log k$$

- **Codifica il costo di un clustering M fatto di k clusters**
  - **Direttamente proporzionale al costo del clustering dei dati**
    - Più i cluster sono omogenei, meno costoso è il clustering
  - **Inversamente proporzionale al costo del modello**
    - Quanti meno clusters ci sono, meno costoso è il clustering
    - $\alpha$  è una costante di normalizzazione
      - (serve a confrontare valori che potrebbero avere scale diverse)