

Apprendimento Non Supervisionato

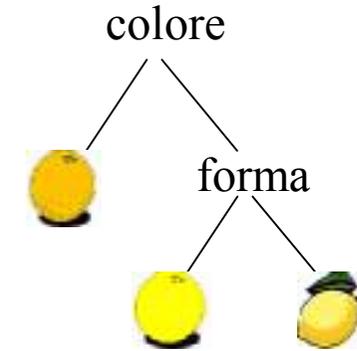
Unsupervised Learning

Supervisione nell'Apprendimento

(arancio, rotondo, classe=)
(giallo, lungo, classe=)
(giallo, rotondo, classe=)
(giallo, lungo, classe=)



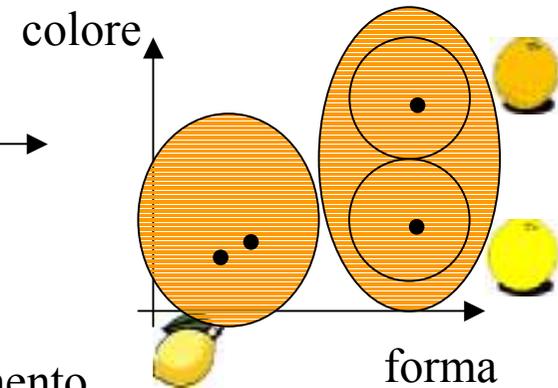
algoritmo di apprendimento
supervisionato



(arancio, rotondo)
(giallo, rotondo)
(giallo, rotondo)
(giallo, lungo)



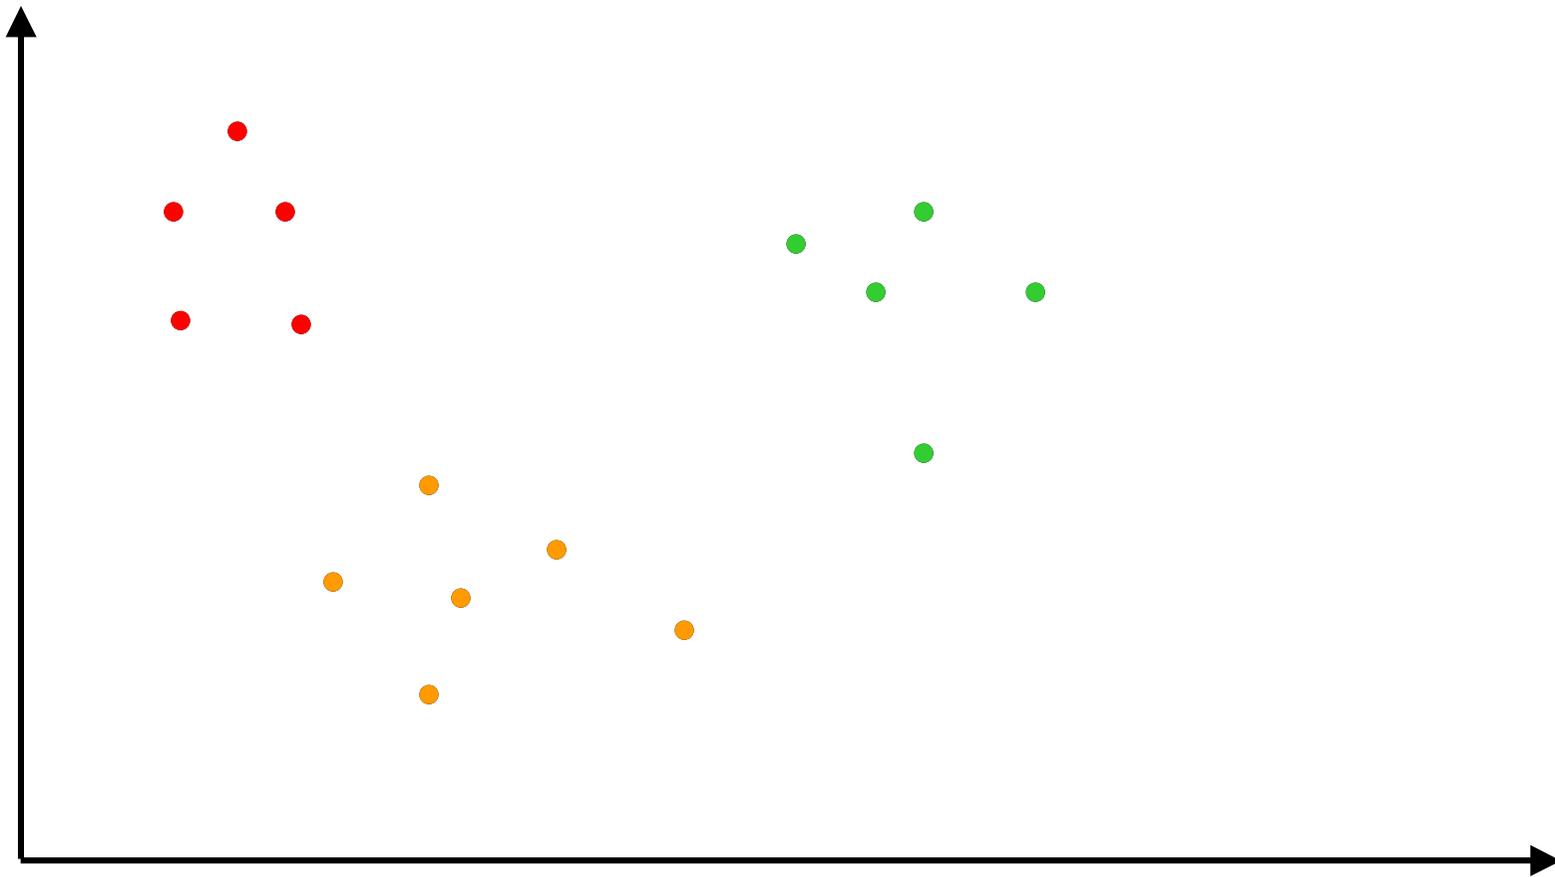
algoritmo di apprendimento
non supervisionato



Clustering

- Suddivide esempi non etichettati in sottoinsiemi disgiunti (**cluster**), tali che:
 - Gli esempi in uno stesso gruppo sono “molto” simili
 - Gli esempi in gruppi diversi sono “molto” differenti
- Scopre **nuove categorie** in modo **non supervisionato** (a priori non vengono fornite etichette per le categorie)

Clustering: un esempio

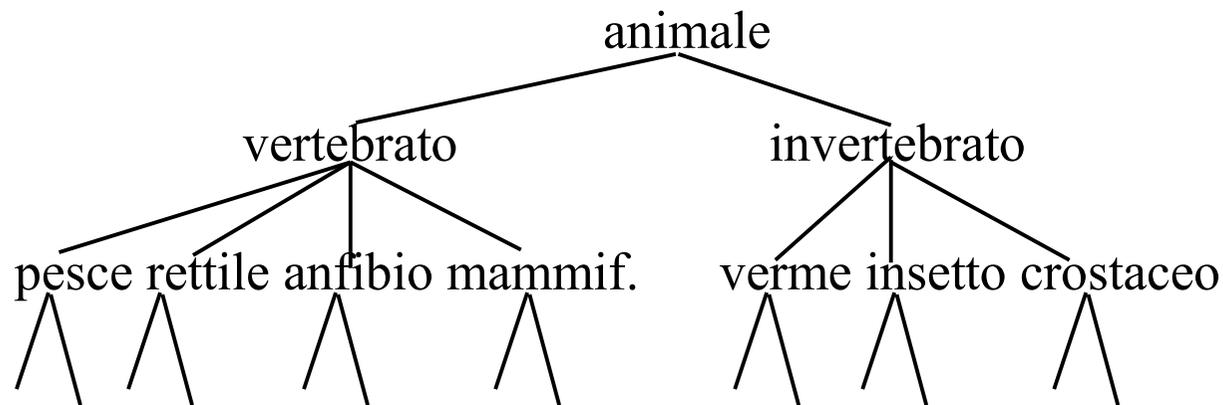


Tipi di Clustering

- Clustering **gerarchico** (hierarchical clustering)
 - Formano cluster iterativamente utilizzando cluster precedentemente costituiti
- Clustering **partitivo** (partitional clustering)
 - Crea una sola partizione degli esempi in cluster minimizzando una certa funzione di costo

Clustering Gerarchico

- Costruisce una tassonomia gerarchica ad albero a partire da un insieme di esempi non etichettati



- L'applicazione ricorsiva di un algoritmo di clustering può produrre un clustering gerarchico
- Distinguiamo due tipi di clustering gerarchico:
 - **Agglomerativo** (bottom-up)
 - **Divisivo** (top-down)

Clustering Partitivo

- I metodi di **clustering partitivo** ottengono una **singola partizione** dei dati, invece di una struttura di clustering (es. albero di clustering)
- Richiedono di specificare il numero di cluster k desiderati
- Il numero di cluster k può essere determinato automaticamente generando esplicitamente clustering per diversi valori di k e scegliendo il miglior risultato secondo la funzione di valutazione del clustering

Clustering Gerarchico Agglomerativo

- Assume l'esistenza di una **funzione di similarità** per determinare la similarità di due istanze
- Algoritmo:
 - Parti con un cluster per ogni istanza
 - Finché** non c'è un solo cluster:
 - Determina i due cluster c_i e c_j più simili
 - Sostituisci c_i e c_j con un singolo cluster $c_i \cup c_j$
- La “storia” di fusione costituisce un albero binario o gerarchia di clustering (**dendrogramma**)

Metriche per determinare la distanza

- Nota: se la distanza è normalizzata tra 0 e 1, la similarità $sim(x, y)$ è data da $1-d(x, y)$
- Distanza euclidea (norma L_2):

$$L_2(\vec{x}, \vec{y}) = \sqrt{\sum_{i=1}^m (x_i - y_i)^2}$$

- Norma L_1 :

$$L_1(\vec{x}, \vec{y}) = \sum_{i=1}^m |x_i - y_i|$$

- Cosine Similarity (trasformata in una distanza sottraendo da 1):

$$1 - \frac{\vec{x} \cdot \vec{y}}{|\vec{x}| \cdot |\vec{y}|} = 1 - \frac{\sum_{i=1}^m x_i y_i}{\sqrt{\sum_{i=1}^m x_i^2 \sum_{i=1}^m y_i^2}}$$

Misurare la Similarità tra Cluster

- Nel clustering gerarchico agglomerativo, utilizziamo una **funzione di similarità** che determina la similarità tra due istanze: $sim(x, y)$
- Come calcolare la similarità di due cluster c_i e c_j sapendo come calcolare la similarità tra due istanze nei due cluster?
 - **Single Link**: Similarità dei due membri più simili
 - **Complete Link**: Similarità dei due membri meno simili
 - **Group Average**: Similarità media tra i membri

Single Link

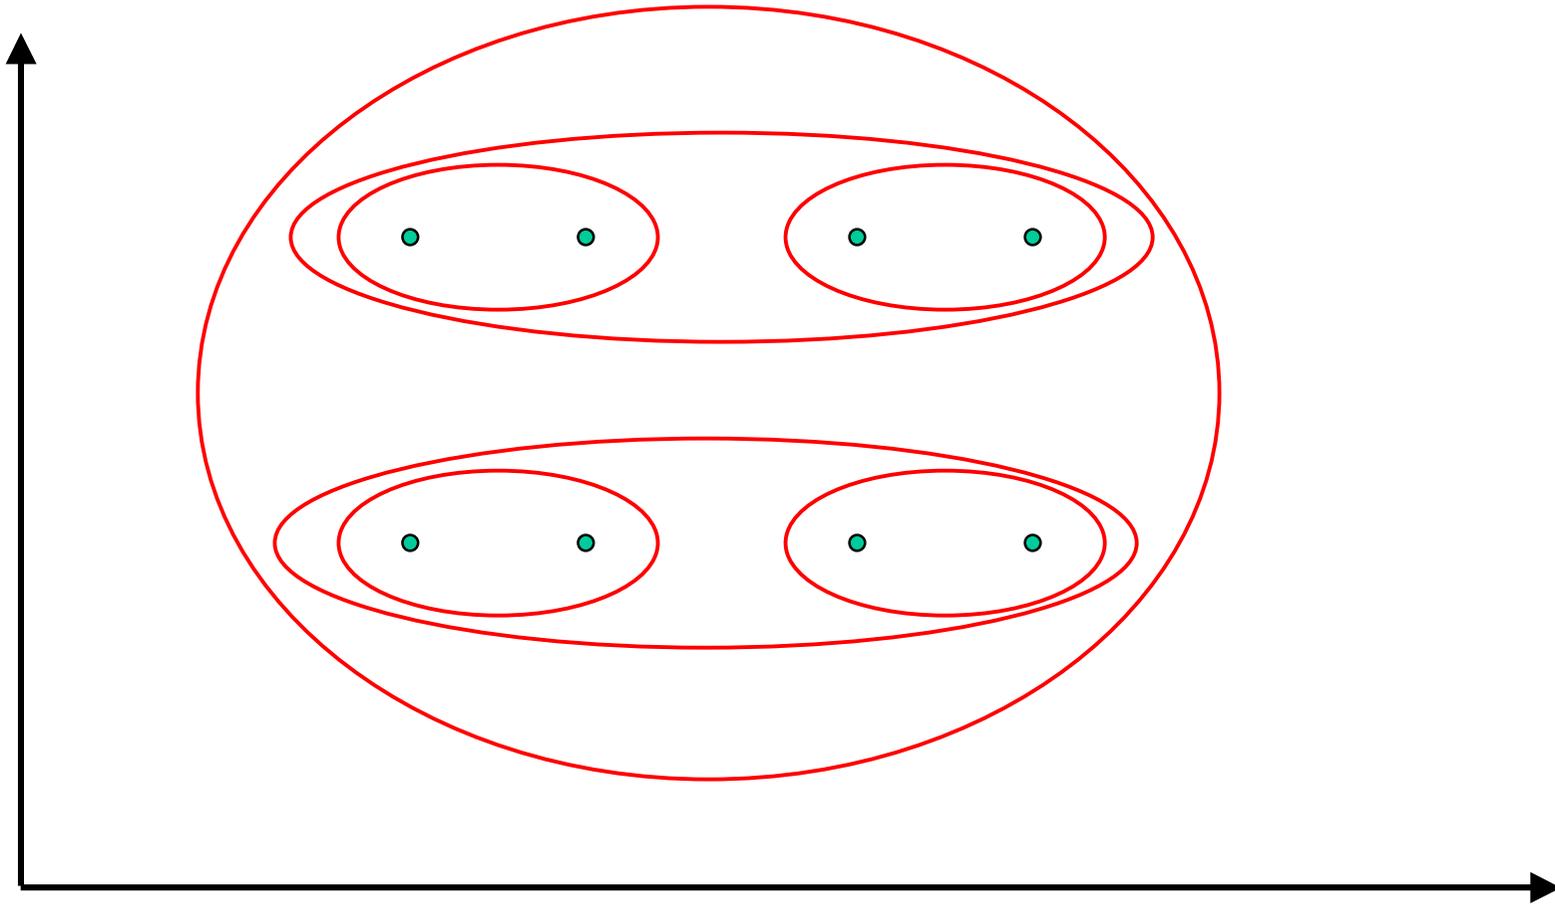
Agglomerative Clustering

- Utilizziamo la similarità massima tra coppie di istanze:

$$sim(c_i, c_j) = \max_{x \in c_i, y \in c_j} sim(\vec{x}, \vec{y})$$

- A causa di un effetto concatenamento, può restituire cluster “lunghi e fini”
 - Adeguato in certi domini, come il raggruppamento di isole

Esempio di Single Link



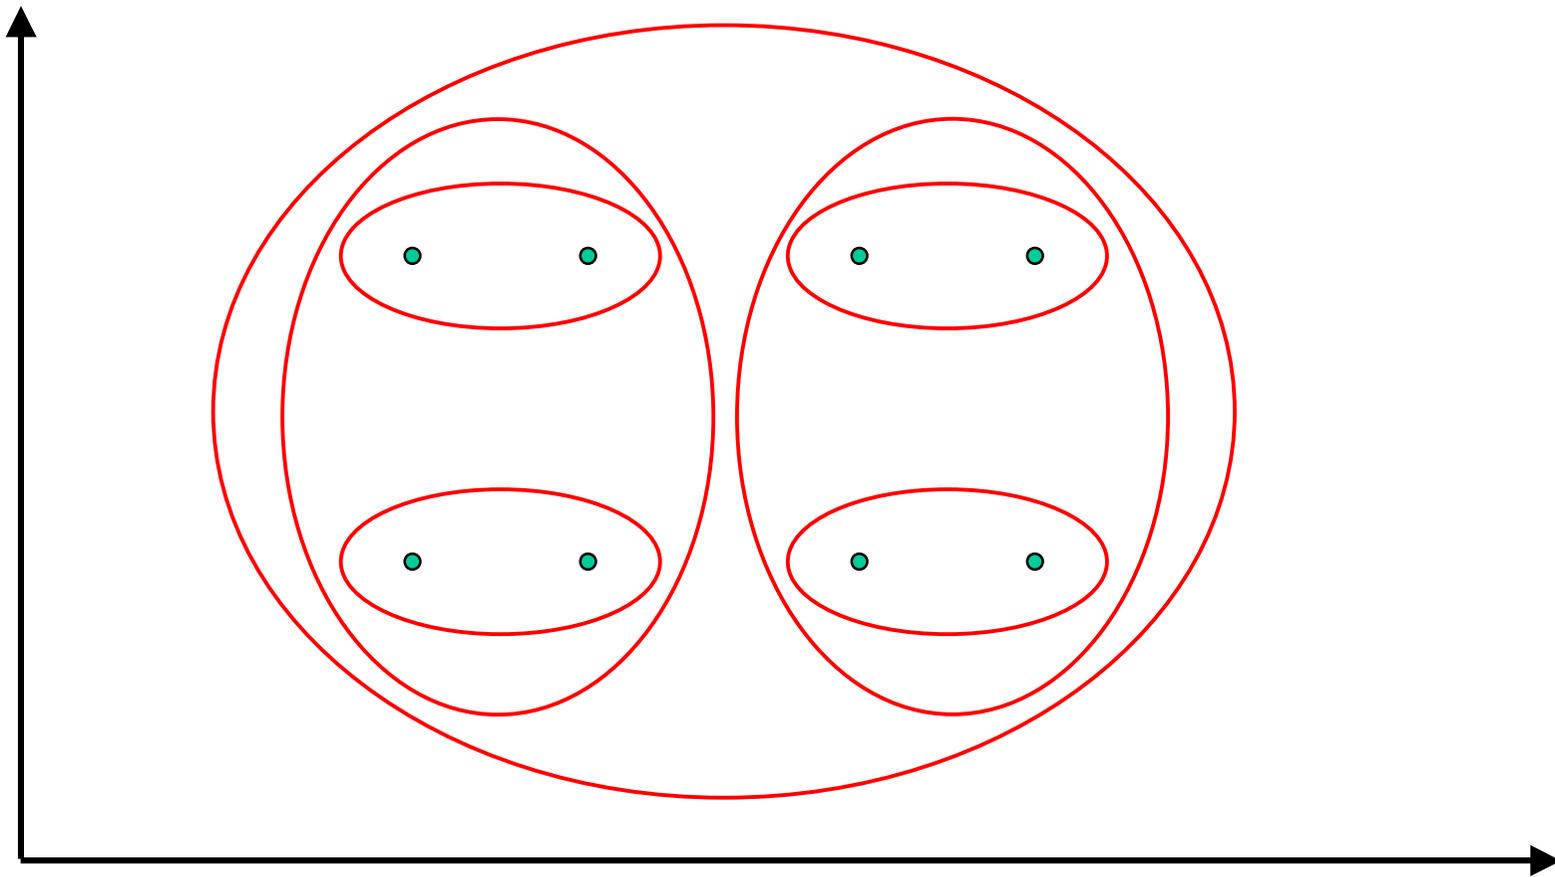
Complete Link Agglomerative Clustering

- Basato sulla minima similarità tra coppie di istanze:

$$sim(c_i, c_j) = \min_{x \in c_i, y \in c_j} sim(\vec{x}, \vec{y})$$

- Crea cluster più sferici, normalmente preferibili

Esempio di Complete Link



Calcolare la Similarità tra Cluster

- Dopo aver fuso i cluster c_i e c_j , la similarità del clustering ottenuto rispetto a un altro cluster arbitrario c_k può essere calcolata come segue:

- Single Link:

$$\text{sim}((c_i \cup c_j), c_k) = \max(\text{sim}(c_i, c_k), \text{sim}(c_j, c_k))$$

- Complete Link:

$$\text{sim}((c_i \cup c_j), c_k) = \min(\text{sim}(c_i, c_k), \text{sim}(c_j, c_k))$$

Group Average Agglomerative Clustering

- Per determinare la similarità tra c_i e c_j usa la similarità media su tutte le coppie nell'unione di c_i e c_j .

$$sim(c_i, c_j) = \frac{1}{|c_i \cup c_j|(|c_i \cup c_j| - 1)} \sum_{\vec{x} \in (c_i \cup c_j)} \sum_{\vec{y} \in (c_i \cup c_j): \vec{y} \neq \vec{x}} sim(\vec{x}, \vec{y})$$

- Compromesso tra single e complete link.
- Se si vogliono cluster più sferici e netti, si deve determinare la similarità media tra coppie ordinate di istanze nei due cluster (invece che tra coppie di istanze nell'unione)

Clustering Partitivo

- Si deve fornire il numero desiderato di cluster k
- Si scelgono k istanze a caso, una per cluster, chiamate **semi (seeds)**
 - Si formano i k cluster iniziali sulla base dei semi
- Itera, riallocando tutte le istanze sui diversi cluster per migliorare il clustering complessivo
- Ci si ferma quando il clustering converge o dopo un numero prefissato di iterazioni

k-Means

- Assume istanze a valori reali
- I cluster sono basati su **centroidi** o media dei punti in un cluster c :

$$\mu(c) = \frac{1}{|c|} \sum_{\vec{x} \in c} \vec{x}$$

- Le istanze vengono riassegnate ai cluster sulla base della distanza rispetto ai centroidi dei cluster attuali

Algoritmo k-means

k-means(distanza d , insieme delle istanze X)

Seleziona k istanze a caso $\{s_1, s_2, \dots, s_k\} \subseteq X$ come **semi**.

Finché clustering non converge o si raggiunge criterio di stop:

Per ogni istanza $x \in X$:

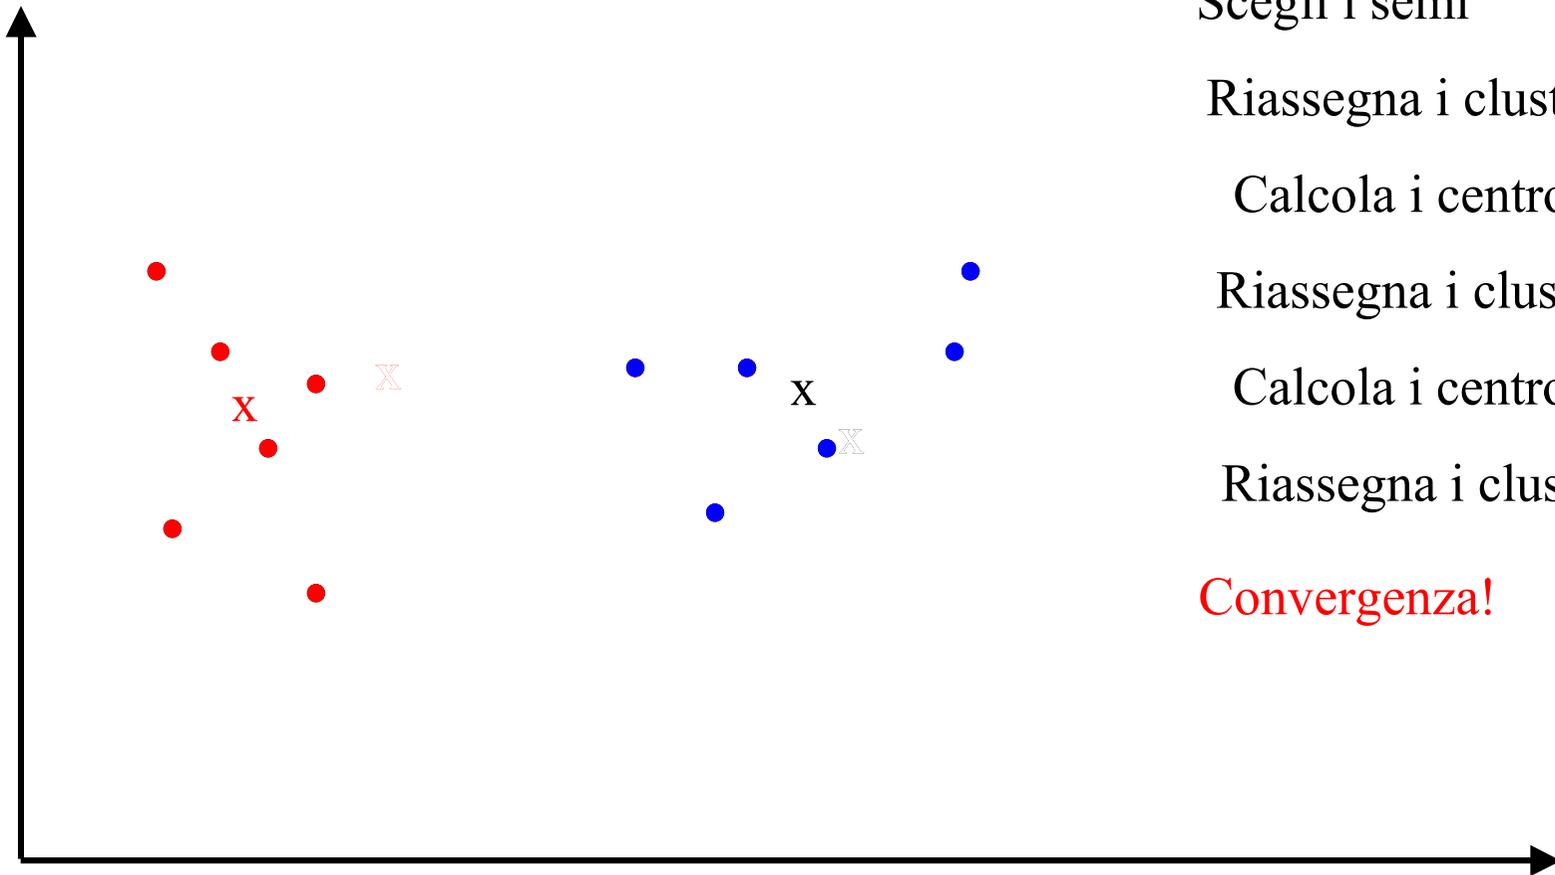
Assegna x al cluster c_j tale che $d(x, s_j)$ è minimale

Aggiorna i semi al centroide di ogni cluster, ovvero

per ogni cluster c_j :

$$s_j = \mu(c_j)$$

k-Means: Esempio (k=2)



Scegli i semi

Riassegna i cluster

Calcola i centroidi

Riassegna i cluster

Calcola i centroidi

Riassegna i cluster

Convergenza!

Obiettivo di k-Means

- L'obiettivo di k-means è di **minimizzare la somma del quadrato della distanza** di ciascun punto in X **rispetto al centroide del cluster** cui è assegnato:

$$\sum_{i=1}^k \sum_{x \in c_i} d(\vec{x}, \mu_i)^2$$

- Così come per gli algoritmi genetici, trovare il minimo globale è un problema NP-hard
- E' garantito che l'algoritmo k-means converga a un minimo locale

Scelta dei Semi

- I risultati possono variare notevolmente sulla base della selezione dei semi
- Alcuni semi possono portare a un basso tasso di convergenza o a convergere su clustering sub-ottimali
- Si possono selezionare buoni semi usando euristiche o come risultato di un altro metodo

Text Clustering

- I metodi di clustering possono essere applicati a documenti di testo in modo semplice
- Tipicamente, si rappresenta un documento mediante **vettori TF*IDF (term frequency*inverse document frequency) normalizzati** e si utilizza la **similarità del coseno**
- Applicazioni:
 - Durante la fase di recupero dei documenti di un sistema di Information Retrieval (IR), si possono fornire documenti nello stesso cluster di quello inizialmente recuperato per aumentare la recall del sistema
 - I risultati di un sistema di IR possono essere presentati per gruppi
 - Produzione automatizzata di tassonomie gerarchiche di documenti per scopi di navigazione (stile Yahoo & DMOZ).

Hard vs. Soft Clustering

- Tipicamente il clustering assume che ogni istanza sia assegnata a un solo cluster
 - Questo non permette di esprimere l'incertezza riguardo l'appartenenza di un'istanza a più cluster
- Il **soft clustering** fornisce una distribuzione di probabilità per ogni istanza rispetto all'appartenenza a ciascun cluster
 - Le probabilità di appartenenza di ogni istanza su tutti i cluster devono sommare a 1

Fuzzy Clustering

- Approccio di soft clustering
- Si definisce un grado di appartenenza $u_i(x)$ dell'istanza x all' i -esimo cluster, tale che:

$$\sum_{i=1}^k u_i(\vec{x}) = 1$$

– dove k è il numero di cluster

- In **fuzzy k-means**, il centroide di un cluster c_i è calcolato come la media di tutti i punti, ciascuno pesato rispetto al suo grado di appartenenza a c_i

$$\vec{\mu}(c_i) = \frac{\sum_{\vec{x} \in X} u_i(\vec{x})^m \vec{x}}{\sum_{\vec{x} \in X} u_i(\vec{x})^m}, \quad m > 1$$

– m è **l'esponente di fuzziness** (es. $m=2$)

Fuzzy k-means

- Definiamo il grado di appartenenza di x a c_i :

$$u_i(\vec{x}) = \frac{1}{\sum_{j=1}^k \left(\frac{d(\vec{x}, \vec{c}_i)}{d(\vec{x}, \vec{c}_j)} \right)^{\frac{2}{m-1}}}$$

- L'algoritmo è simile a k-means:

Fuzzy k-means(distanza d , insieme delle istanze X)

Inizializza i coefficienti $u_i(x)$ per ogni $i \in \{1, \dots, k\}$ e $x \in X$

(casualmente o sulla base di un'applicazione di k-means)

Finché non si raggiunge criterio di stop:

Calcola i centroidi per ogni cluster c_i

Aggiorna i coefficienti $u_i(x)$ di x di essere nel cluster c_i

Problemi nell'Apprendimento Non Supervisionato

- Come valutare il clustering?
 - Valutazione interna:
 - Separazione netta dei cluster (ad es., l'obiettivo di k-means)
 - Corrispondenza con un modello probabilistico dei dati
 - Valutazione esterna
 - Confronta i cluster con etichette di classe note su dati di benchmark
- Clustering sovrapponibili
- Metodi semi-supervisionati
 - Si utilizzano pochi esempi annotati a mano e moltissimi esempi non annotati