



Università degli Studi di Napoli "Parthenope"
Dipartimento di Scienze e Tecnologie

Corso di Telerilevamento

Lezione 10

Classificazione non supervisionata delle immagini telerilevate

Claudio Parente

Classificazione non supervisionata

In alcuni casi, piuttosto che forzare i pixel in una classe basandosi sulla nostra soggettività, può essere utile fare in modo che un software ci dica quali pixel di un'immagine abbiano caratteristiche simili.

Ciò viene fatto usando un *classificatore unsupervised* (senza addestramento).

Classificazione non supervisionata

Le classi delle coperture sono ottenute senza la conoscenza a-priori di modelli reali, cioè senza informazioni in anticipo sulle classi di interesse.

I dati sono esaminati suddividendoli in gruppi spettrali detti cluster, supponendo che corrispondano a classi di copertura.

Successivamente si verifica se ciò è vero utilizzando informazioni sulla regione o conducendo indagini al suolo (ground truth).

La classificazione è detta anche *cluster analysis*.

Gerarchico vs partizionale

PUNTO DI VISTA: il tipo di risultato dell'operazione di clustering

⇒ Clustering Partizionale: il risultato è una singola partizione dei dati (tipicamente il numero di cluster deve essere dato a priori)

⇒ mira ad identificare i gruppi naturali presenti nel dataset

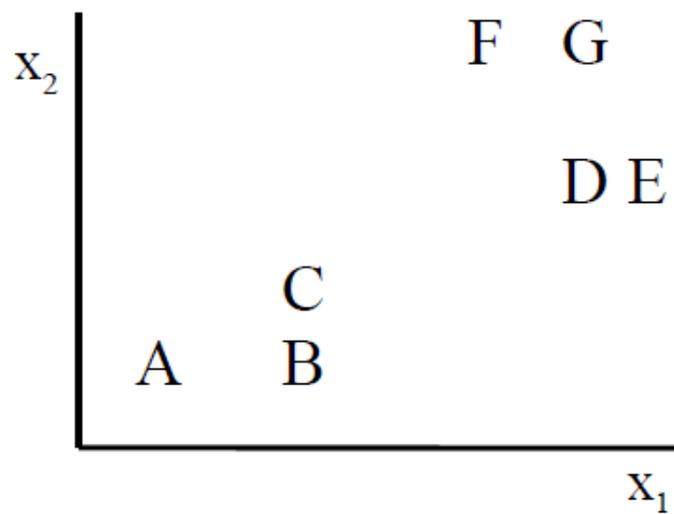
⇒ tipicamente richiede che i dati siano rappresentati in forma vettoriale

⇒ genera una partizione (insieme di cluster disgiunti la cui unione ritorna il data set originale)

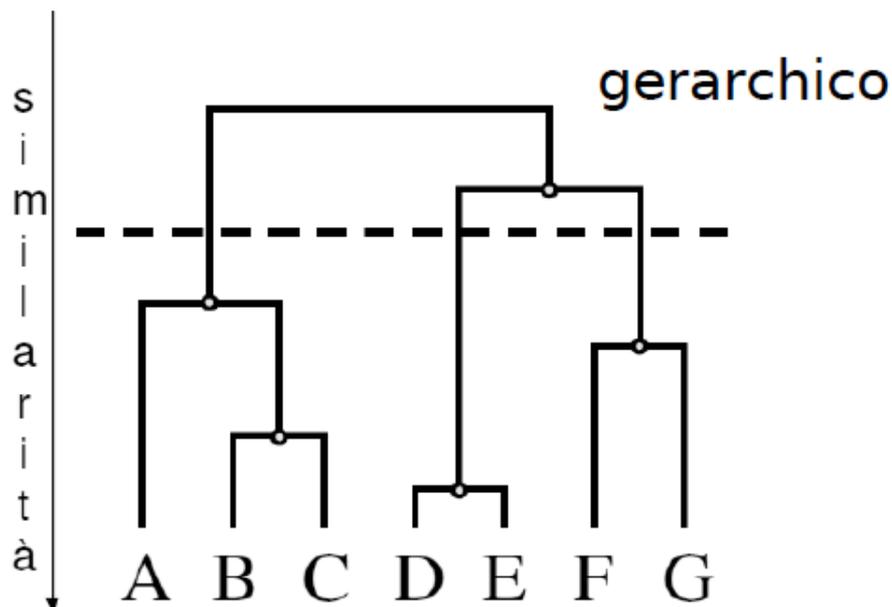
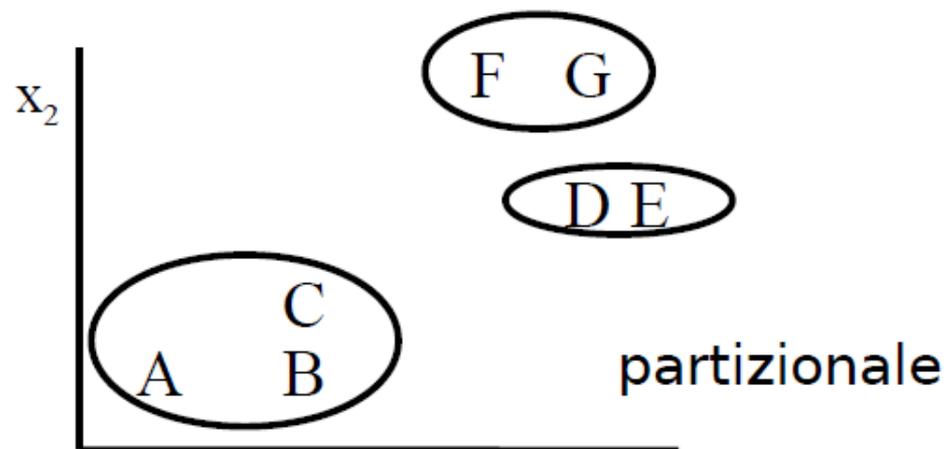
⇒ Clustering Gerarchico: il risultato è una serie di partizioni innestate (un "dendrogramma")

⇒ mira ad evidenziare le relazioni tra i vari pattern del dataset

⇒ tipicamente richiede una matrice di prossimità 5



problema originale



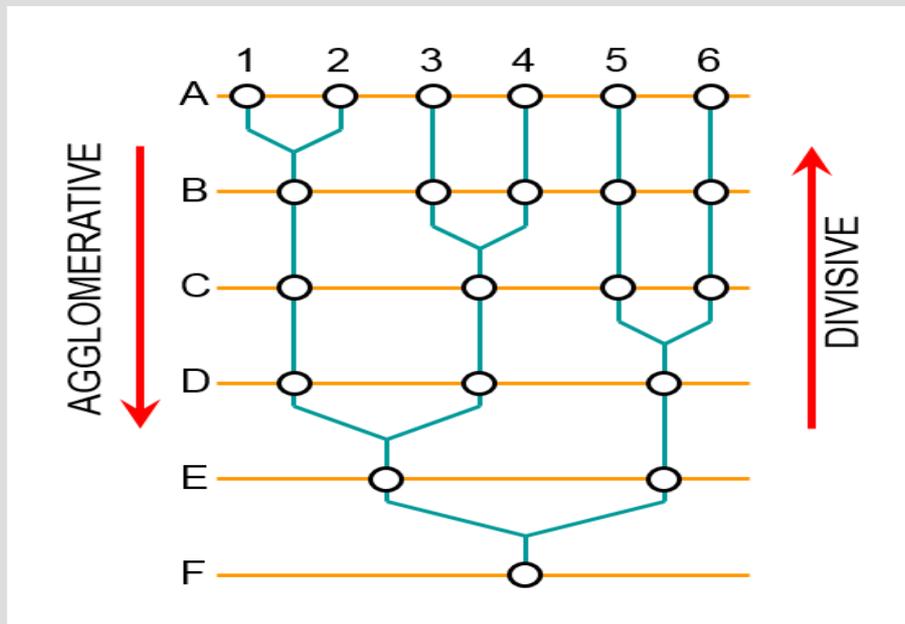
gerarchico

Clusterizzazione

In definitiva, la clusterizzazione può avvenire utilizzando criteri gerarchici.

In tal caso, i cluster via via formati possono essere o accorpati in base a criteri di unione o scissi in base a criteri divisivi.

Clusterizzazione gerarchica



Agglomerativa:

Ad ogni passo vengono uniti i due cluster più vicini

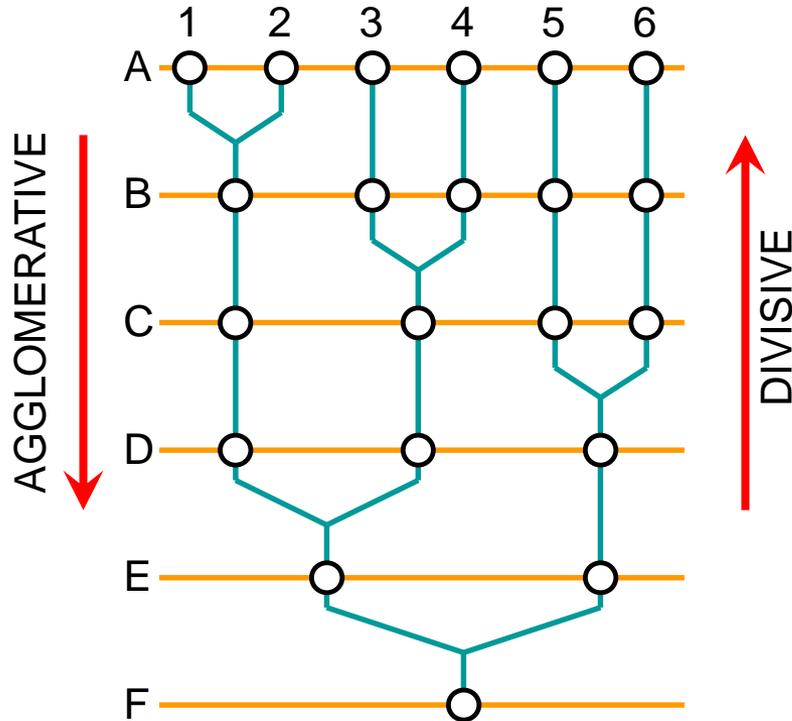
Divisiva:

Ad ogni passo il cluster più disperso viene diviso in due nuovi cluster

Sono necessari:

Criteri di unione.
Criteri di divisione.

Clusterizzazione gerarchica



Agglomerativa:

Ad ogni passo
vengono uniti
i due cluster più vicini

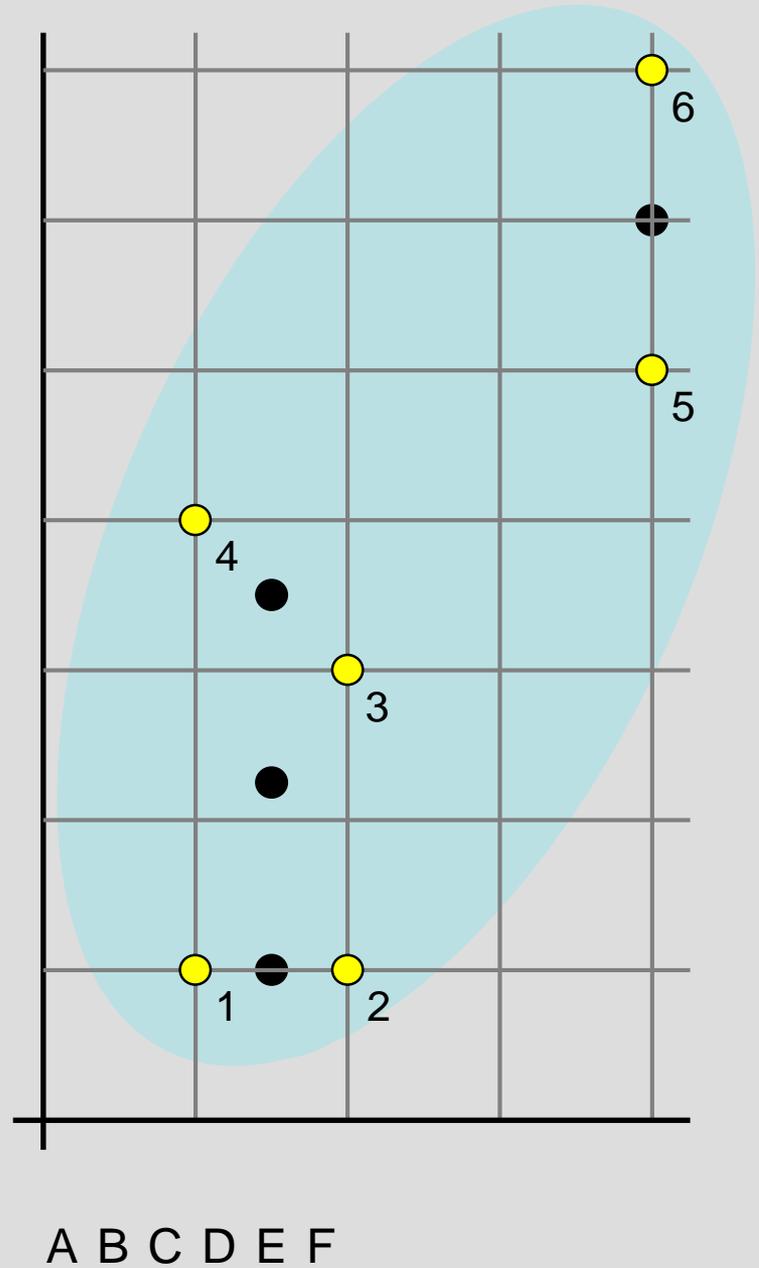
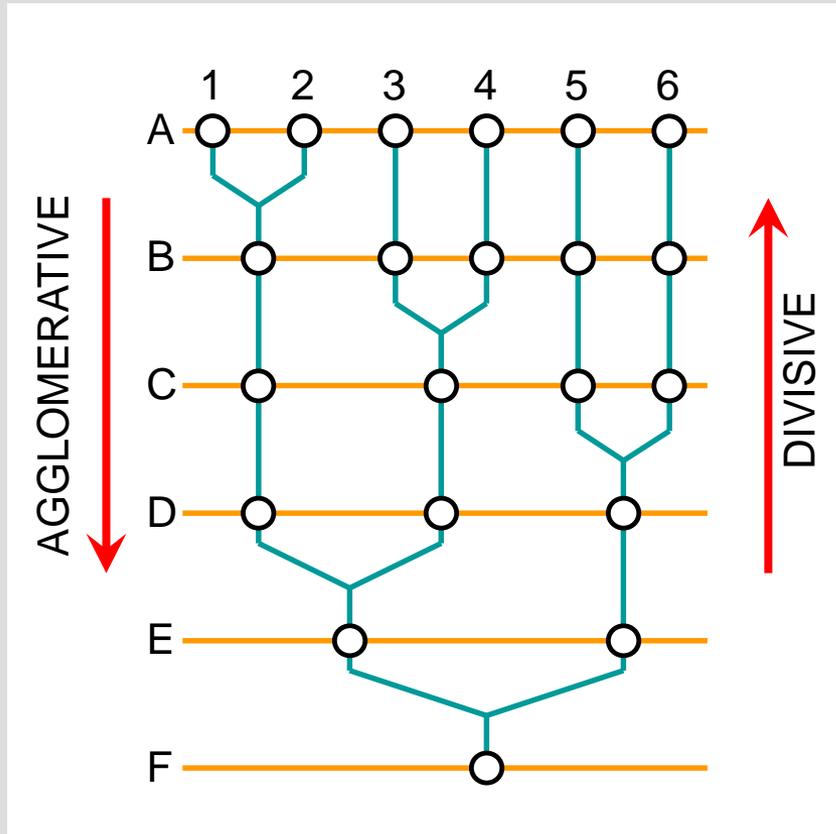
Divisiva:

Ad ogni passo
il cluster più disperso viene
diviso in due nuovi cluster

Sono necessari:

Criteri di unione.
Criteri di divisione.

Clusterizzazione gerarchica



Classificazione non supervisionata

È importante sottolineare che i cluster prodotti non sono classi di informazioni, come nella classificazione supervised, ma solo classi spettrali.

Tecnica possibile: si ricercano, per ogni singola banda, i picchi dell'istogramma (frequenza maggiore).

Ogni pixel viene assegnato al picco più vicino.

La procedura è semplice, ma poco utilizzata perché non può andare oltre le 3 bande (composizione RGB di tre bande originali o delle prime 3 componenti principali su set multispettrali).

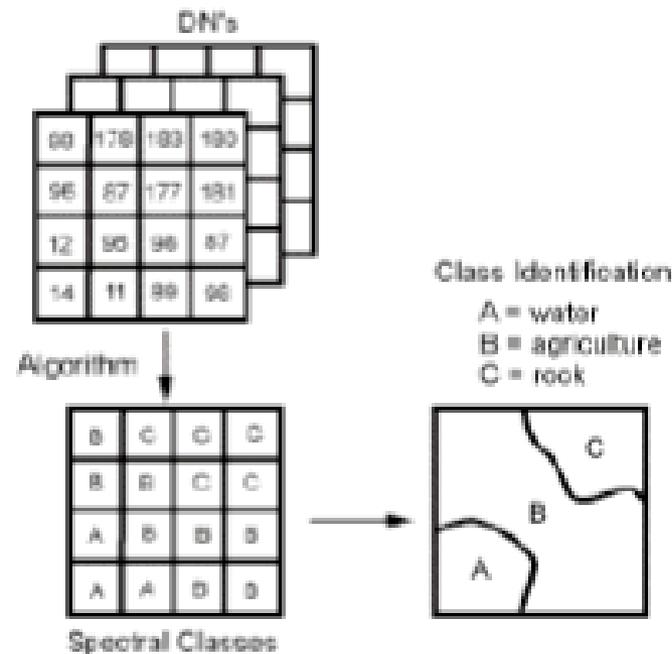
Classificazione non supervisionata

In definitiva, nella classificazione unsupervised non è necessaria la conoscenza della realtà a terra.

Tale classificazione si basa sull'utilizzo di algoritmi che analizzano tutti i pixel e li raggruppano in un certo numero di classi dette cluster tenendo conto unicamente del valore di radianza.

Classificazione non supervisionata

Spesso l'operatore può fissare alcune variabili come il numero dei cluster o il numero minimo di pixel per formare un cluster.



Classificazione non supervisionata

Nel telerilevamento la classificazione supervisionata usa gruppi ovvero cluster di pixel entro un dataset solitamente multispettrale.

Richiede pochi dati di ingresso da parte dell'utente (non ci sono training site!).

Richiede che le classi trovate siano etichettate dopo la classificazione: mentre nella supervisionata si stabilisce sia il numero che il tipo di classe (ad esempio: acqua, suolo nudo e vegetazione), qui si fissa al massimo il solo numero delle classi, poi, dopo la classificazione, si stabilisce a quale copertura del suolo esse possono corrispondere.

Vantaggi della classificazione non supervisionata

Non è richiesta alcuna conoscenza a-priori.

L'errore umano è ridotto.

Le classi sono per forza spettralmente omogenee.

Tutte le classi che hanno caratteristiche «uniche» possono essere identificate

Svantaggi della classificazione non supervisionata

Le classi ottenute non hanno necessariamente un significato fisico, cioè non necessariamente corrispondono a specifici e differenti tipi di copertura del suolo.

L'utente ha un controllo limitato sulla procedura e sui risultati.

Metodo k-means

Esistono più algoritmi e quindi più metodi per realizzare la classificazione senza addestramento.

Un metodo per la classificazione senza addestramento è detto *k-means*: l'utente deve specificare solo il numero k delle classi.

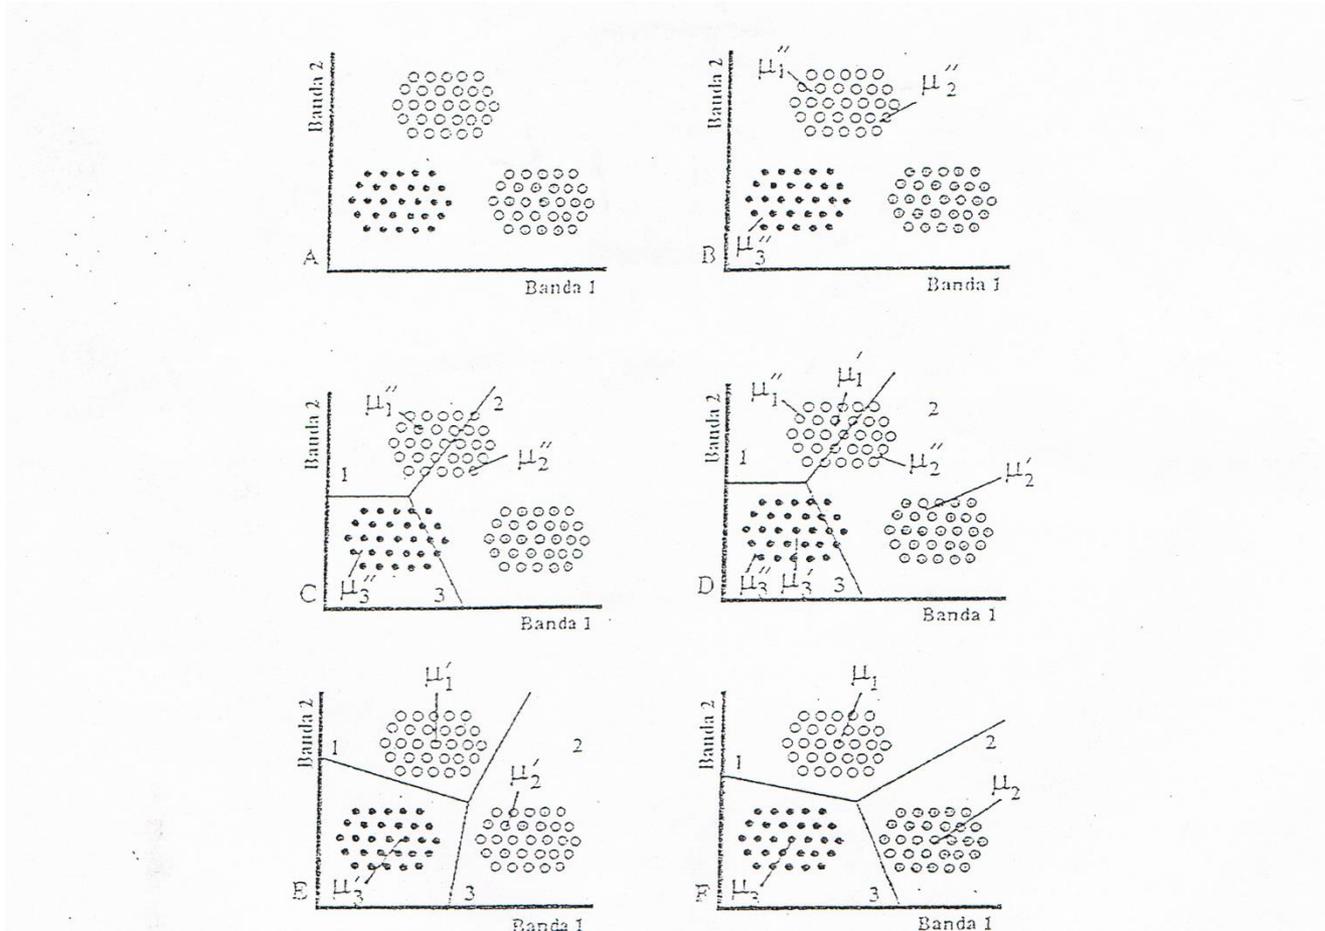
Quindi, l'algoritmo *k-means* tenta di localizzare il vettore delle medie (μ_i) nello spazio spettrale multidimensionale (cioè nelle l bande) per ciascuna delle k classi (cioè per $i=1,2,\dots,k$).

Metodo k-means

Inizialmente si scelgono a caso le stime della localizzazione dei vettori delle medie.

Se indichiamo queste stime iniziali con μ''_i (vedi Figura nella slide successiva), è possibile assegnare tentativamente ciascun pixel ad una classe basandosi su un criterio di minima distanza dalla media, ossia di quanto quel pixel è vicino ad ogni “vettore delle medie” relativo a ciascuna ipotetica classe.

Metodo k-means



Metodo k-means

La media di tutti i pixel assegnati tentativamente alla i -sima classe diventa la nostra nuova stima μ'_i di quella classe.

Rispetto a quest'ultima i pixel vengono riassegnati usando lo stesso criterio della minima distanza e la procedura viene reiterata finché non si osserva alcuna variazione significativa delle medie.

Metodo k-means

Alla fine di questo processo, le medie-tentativo finali vengono assunte essere delle buone stime dei vettori delle medie μ_i che vengono, poi, inserite in un classificatore *hard*, quale il classificatore MDM, il classificatore a parallelepipedo o il classificatore GML.

In questi ultimi due casi i pixel assegnati nell'ultima iterazione alla *i*-sima classe vengono utilizzati per generare stime di altre statistiche per quella classe (ad esempio la deviazione standard o la matrice di covarianza).

Metodo k-means

In definitiva, il metodo k-means è un metodo iterativo che richiede di raffinarne ripetutamente il centro dei cluster.

Si parte con posizioni arbitrarie distribuite sulla nuvola dei dati (nello spazio multispettrale ad n dimensioni).

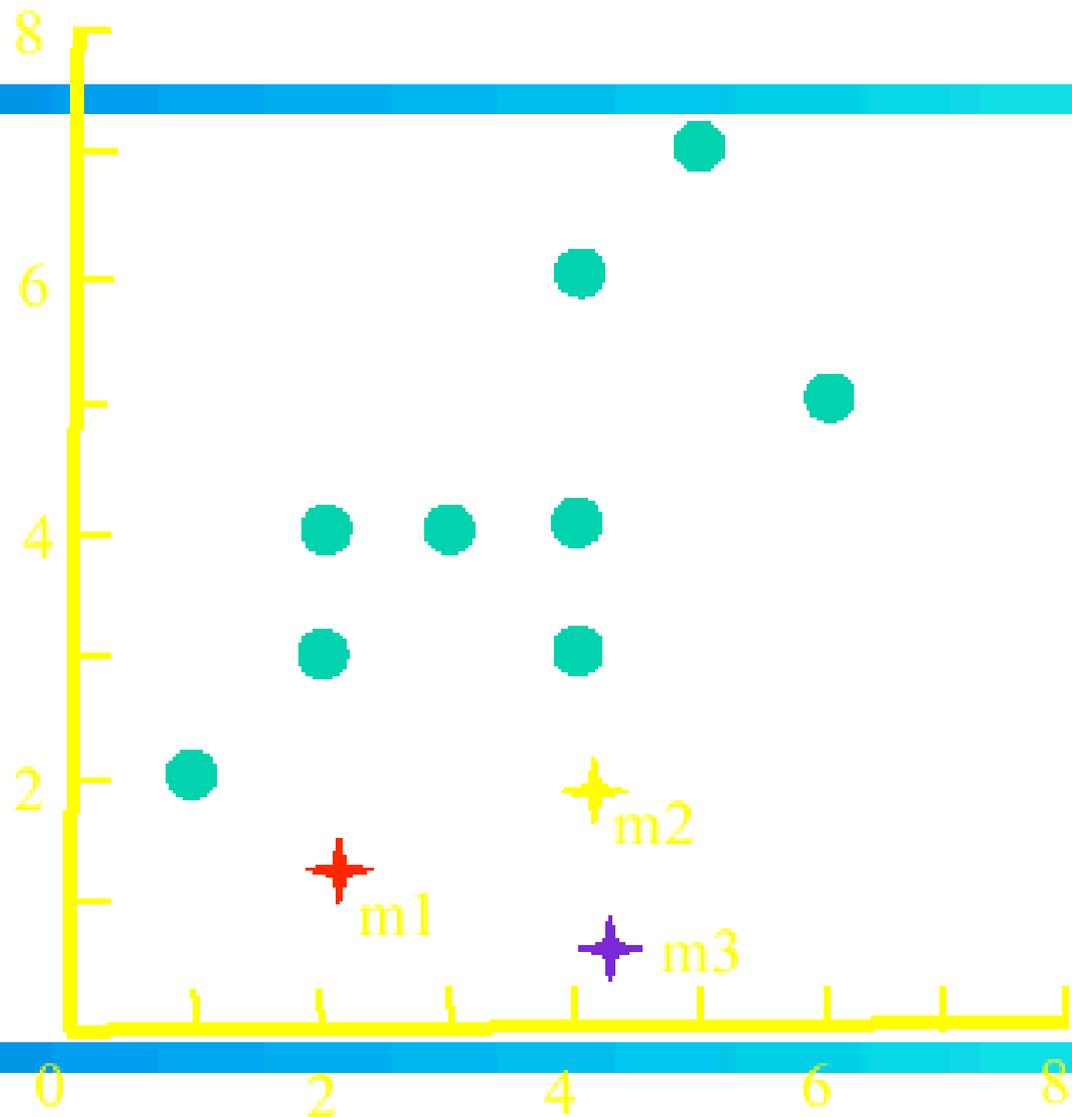
Si aggiusta iterativamente considerando i risultati che di volta in volta si ottengono.

Il processo si arresta quando non cambia più nulla da un passo al successivo (ovvero non ci sono più variazioni in termini di allocazione dei centri e dei confini dei cluster).

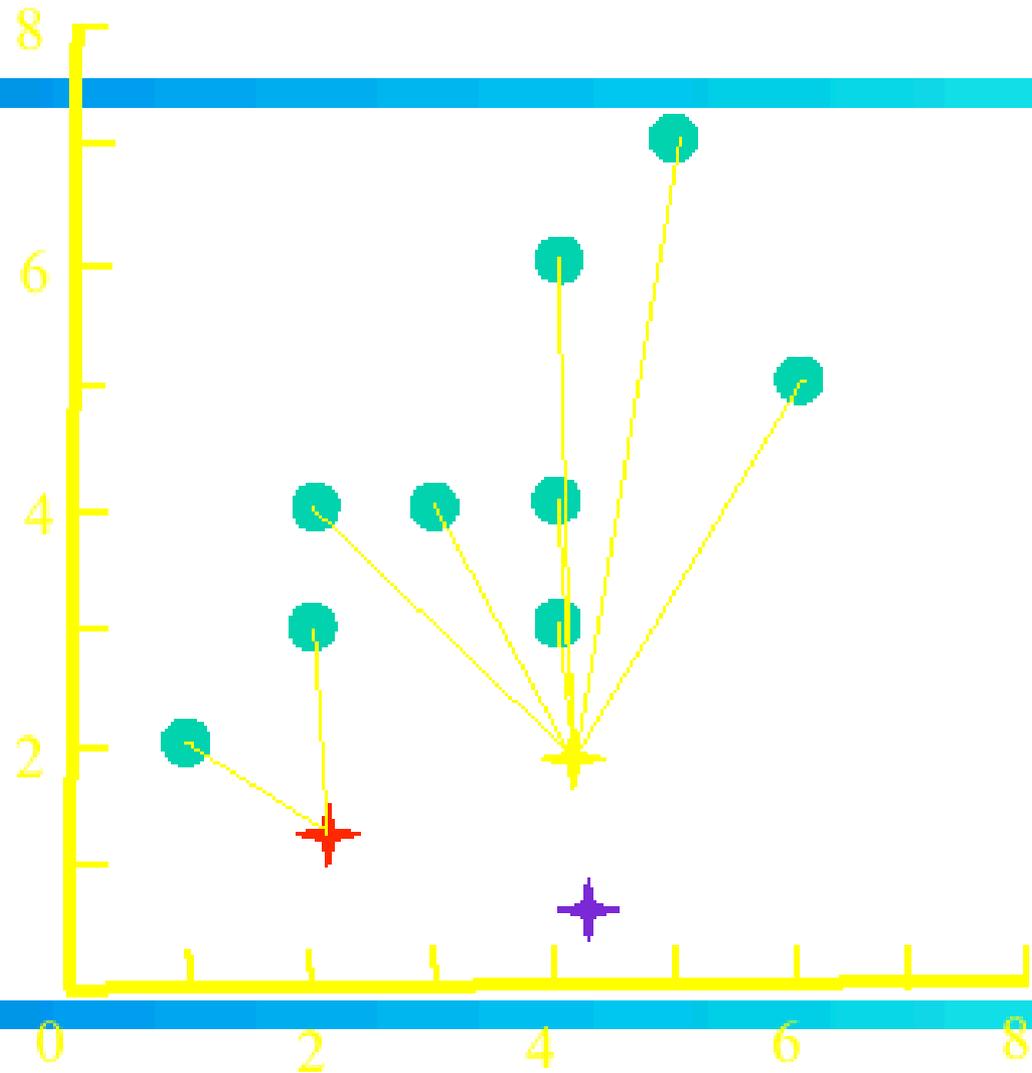
Metodo k-means

Nelle slide che seguono, viene mostrato, con pochi dati e a scopo esemplificativo, l'operatività del metodo k-means.

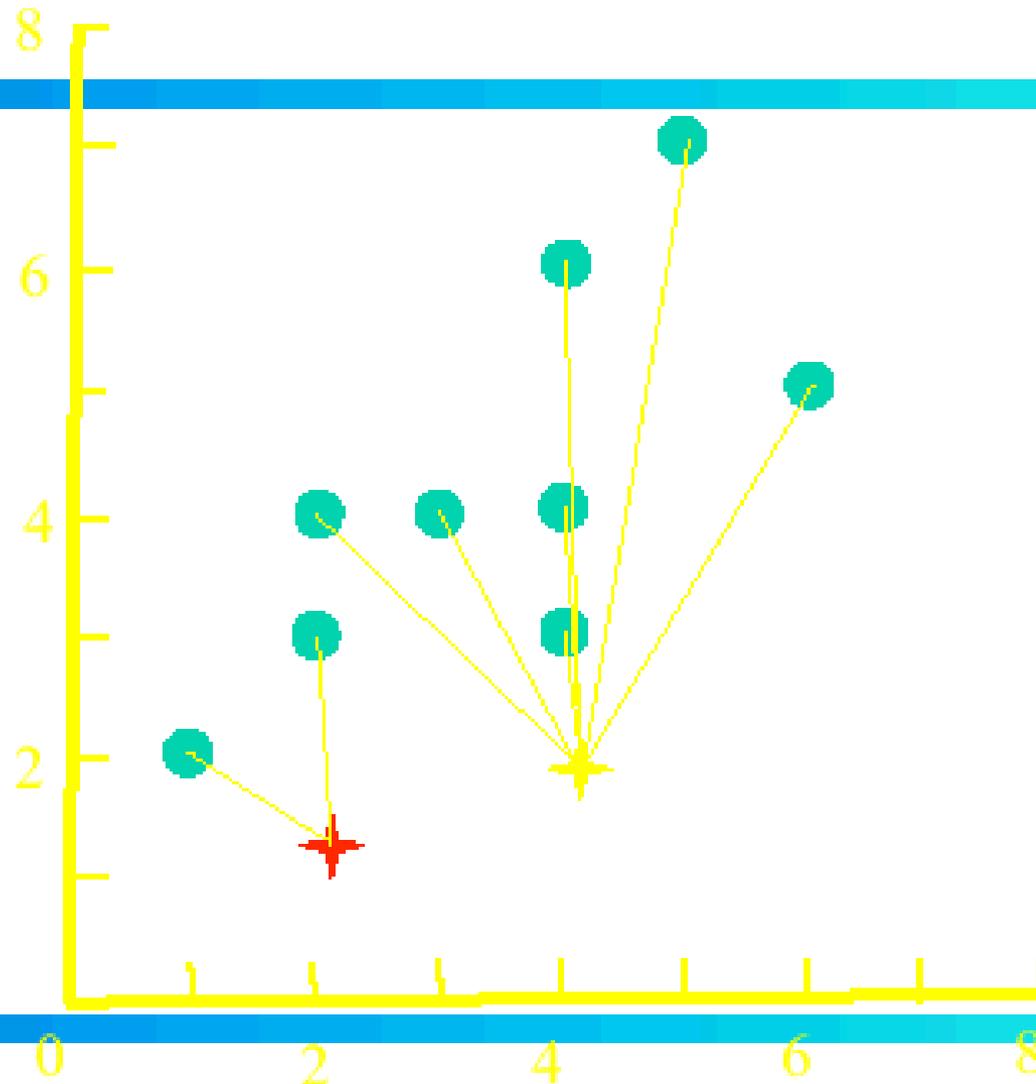
Metodo k-means



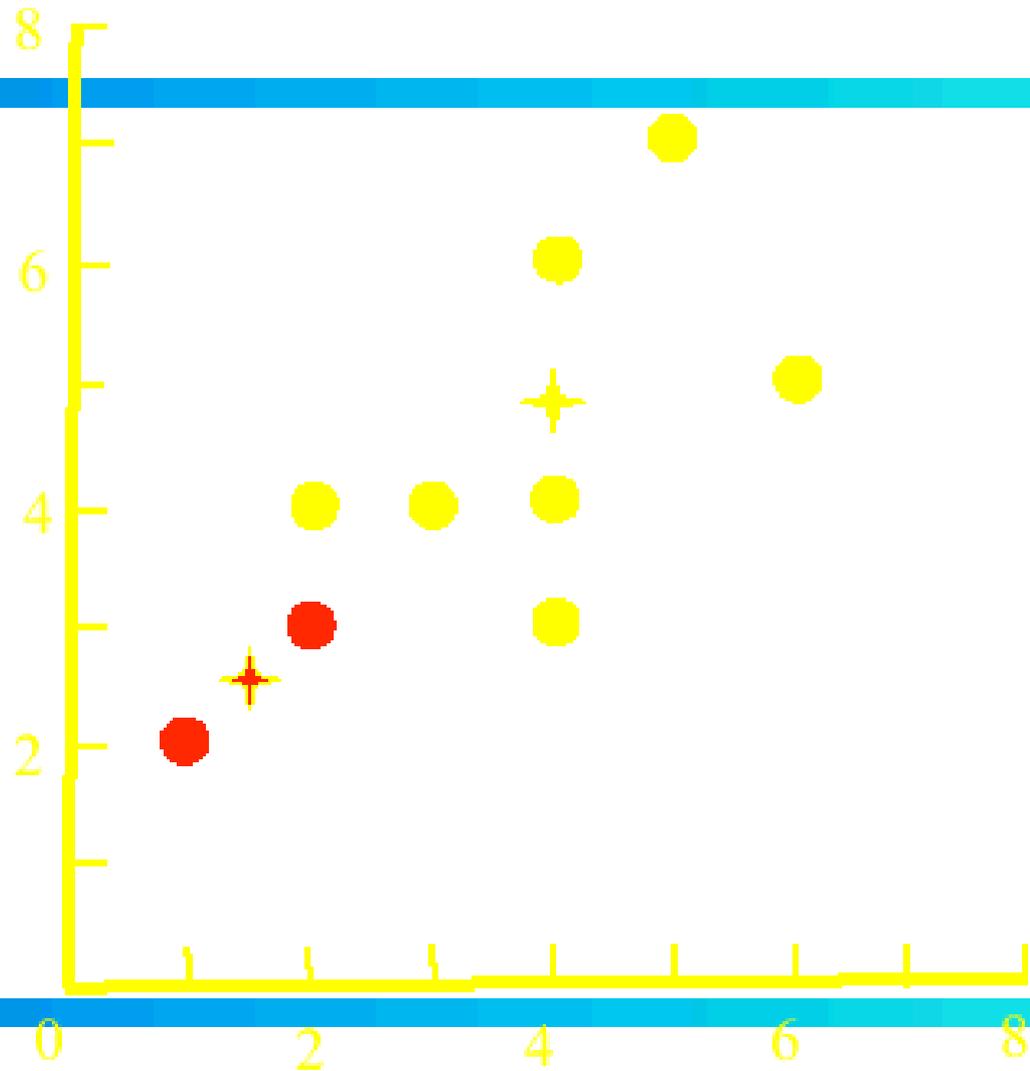
Metodo k-means



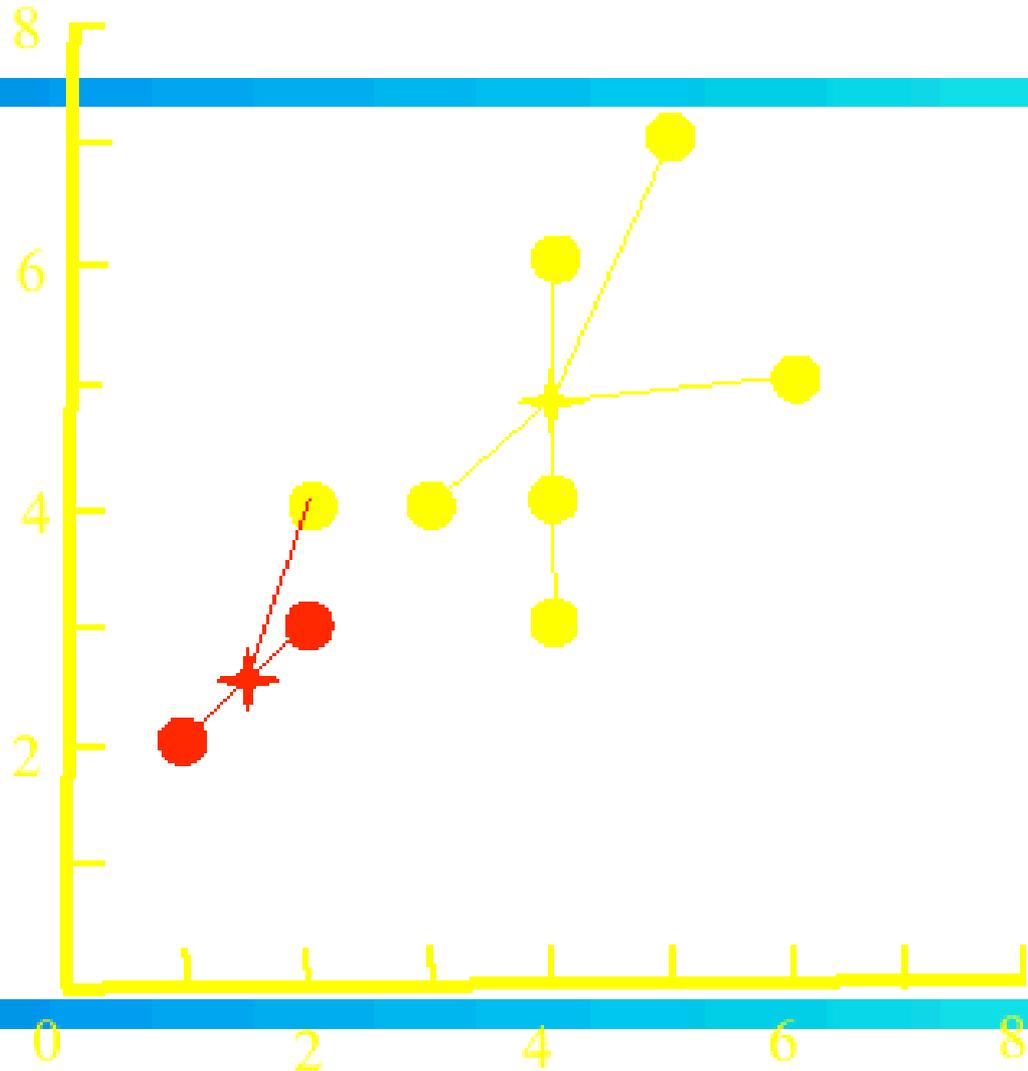
Metodo k-means



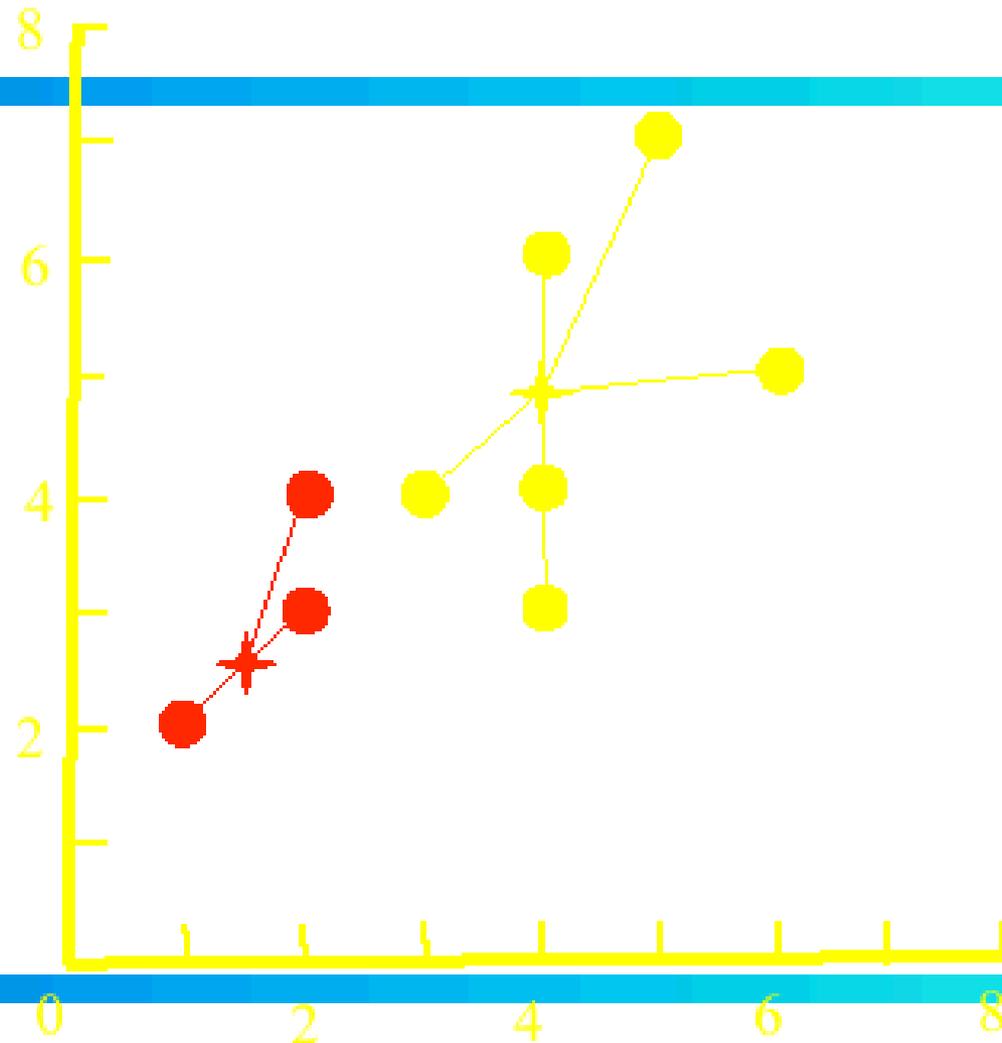
Metodo k-means



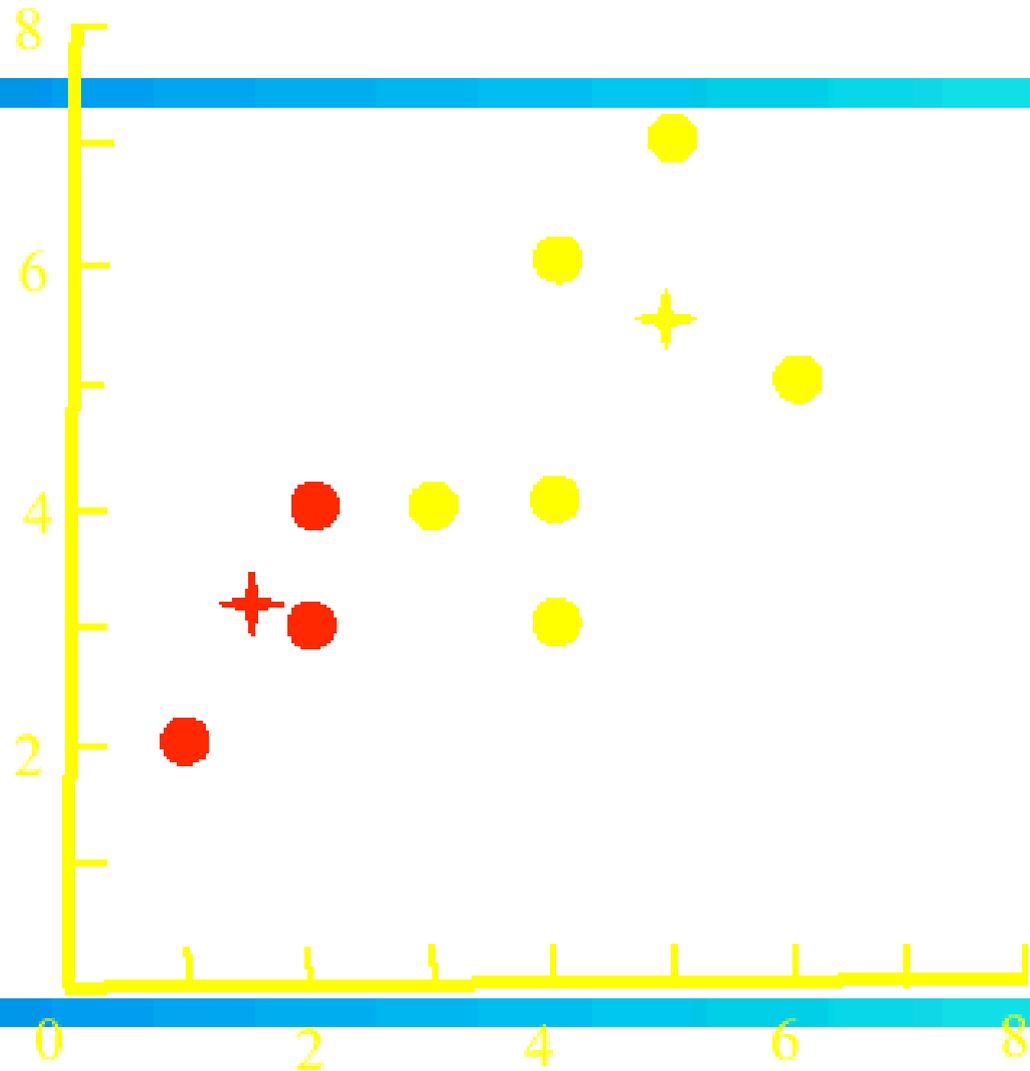
Metodo k-means



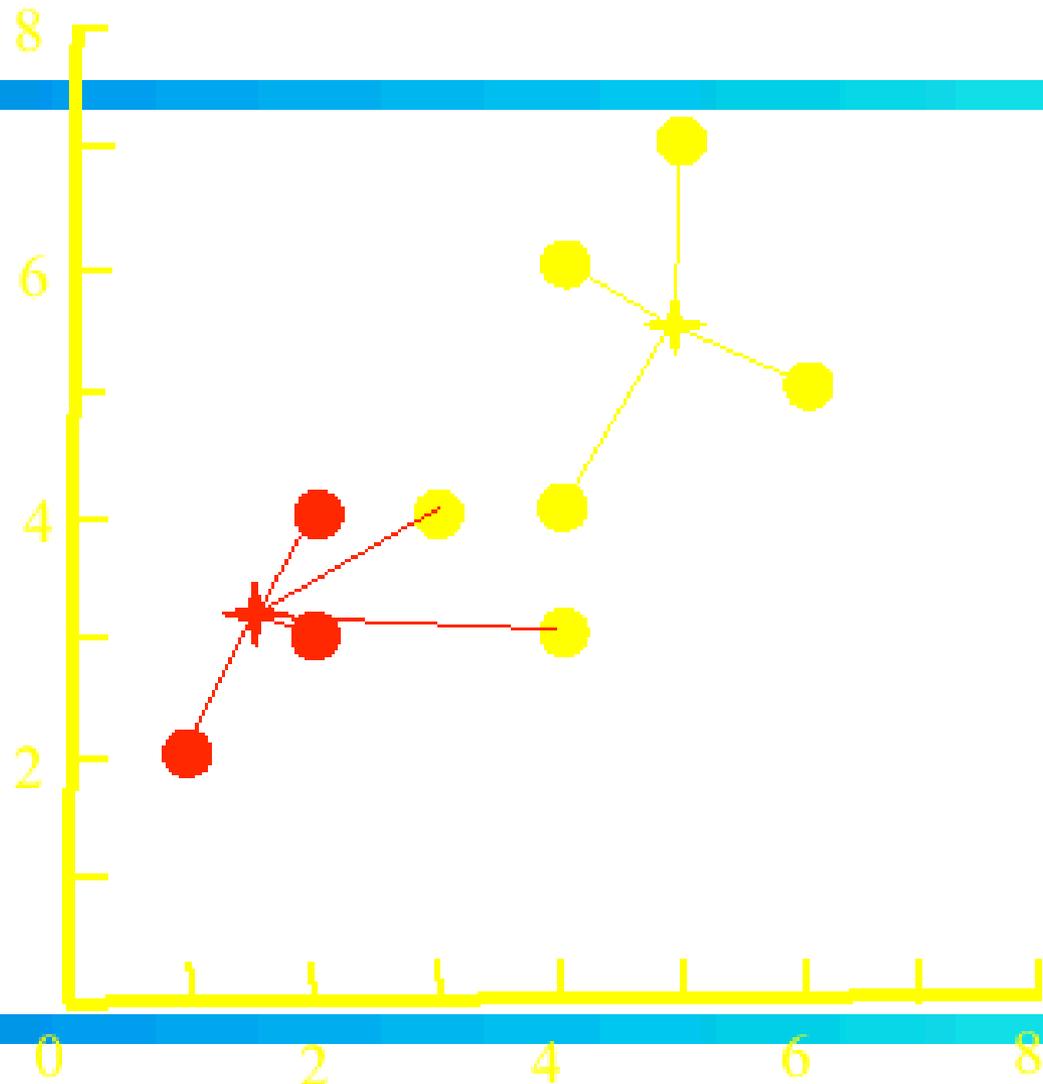
Metodo k-means



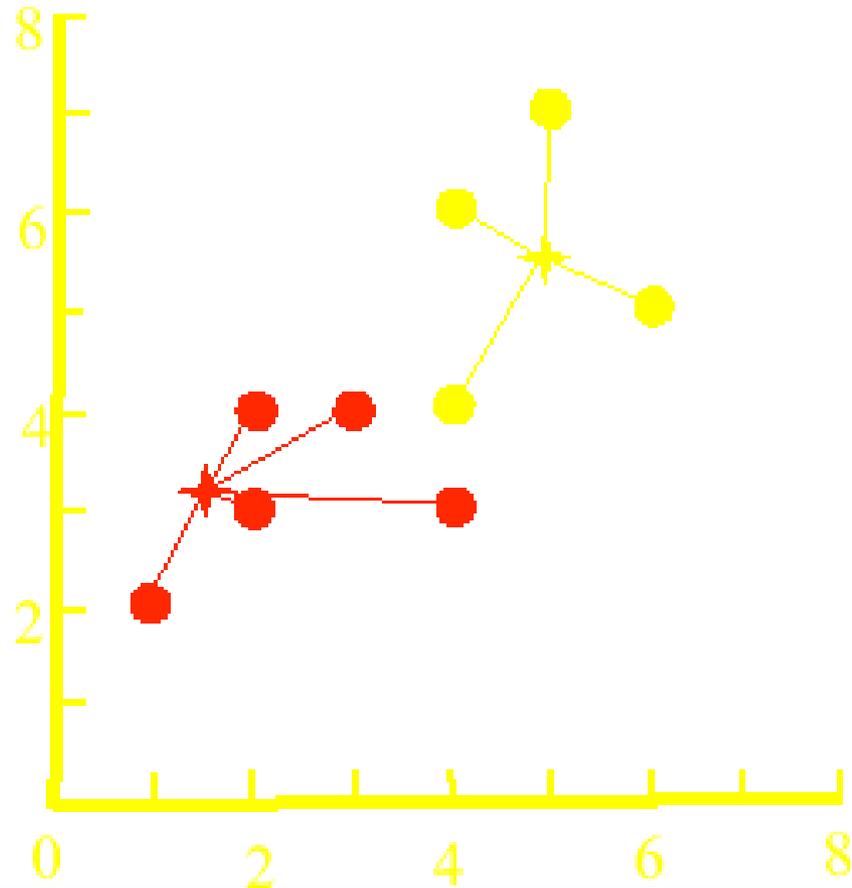
Metodo k-means



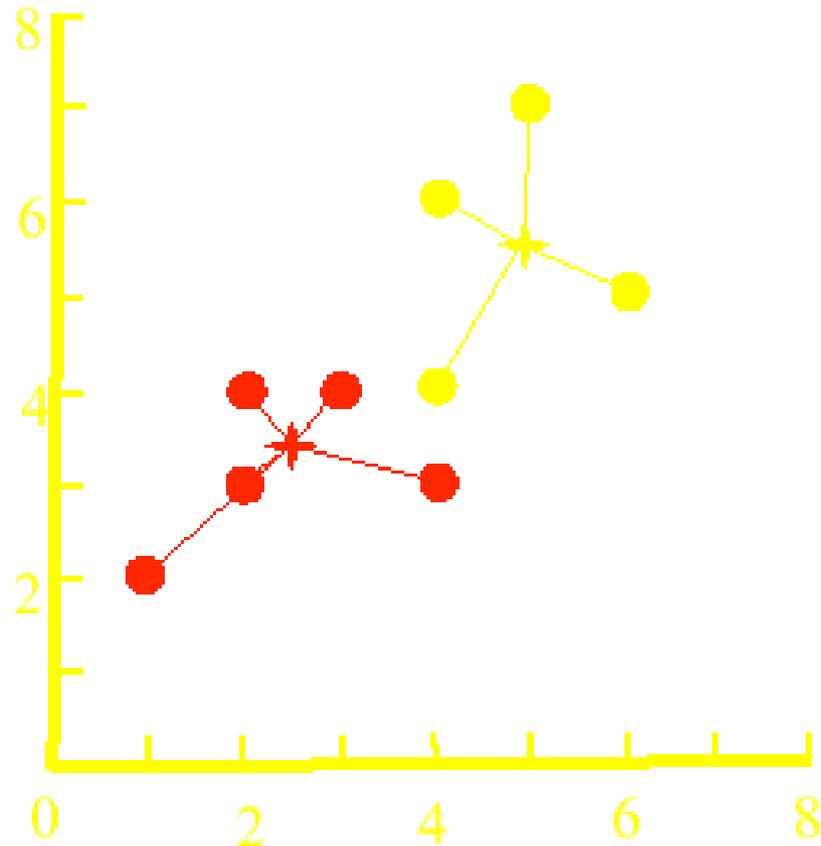
Metodo k-means



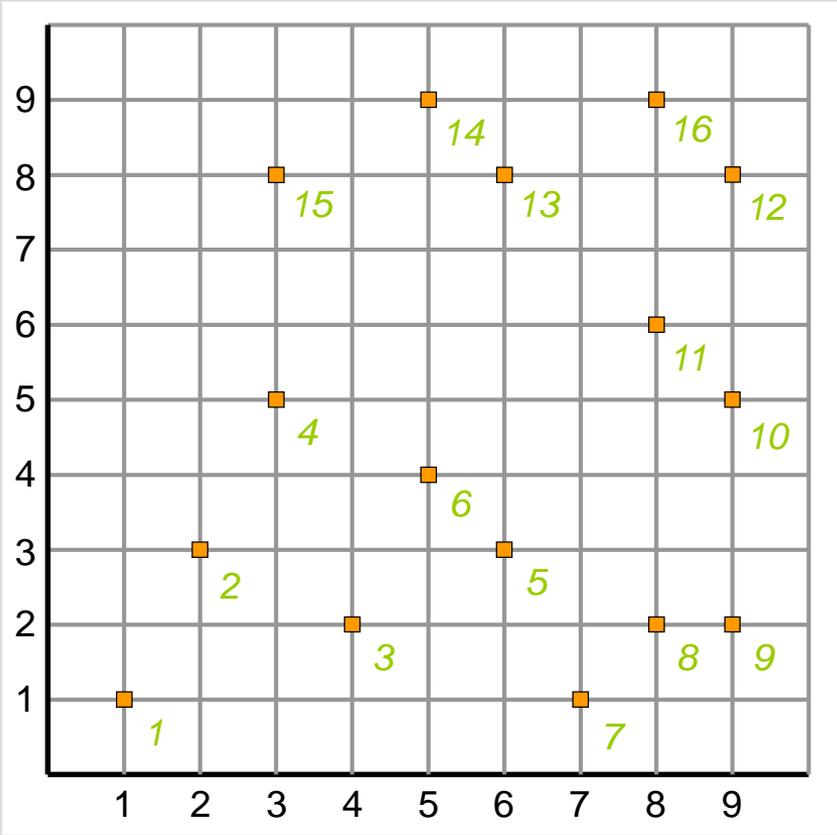
Metodo k-means



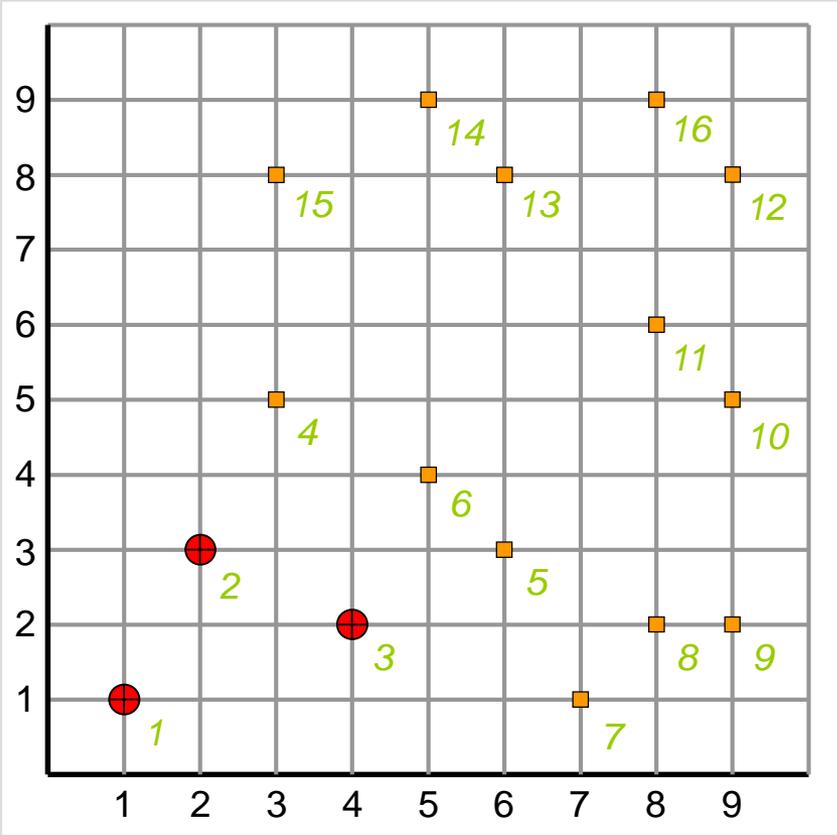
Metodo k-means



Un altro esempio di applicazione dell'algoritmo K-means



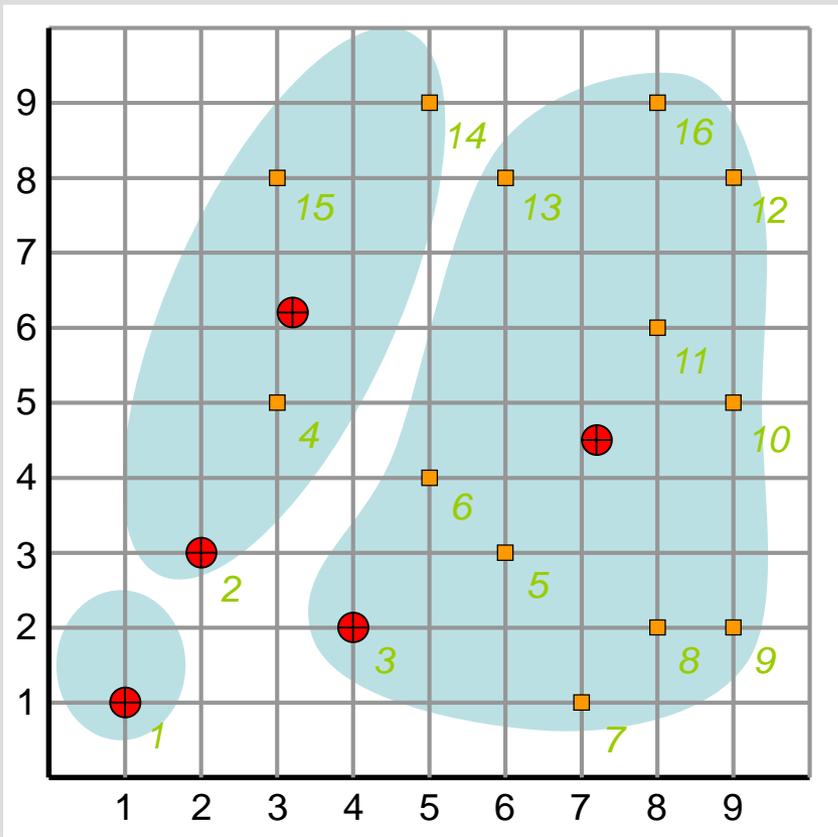
L'algoritmo K-means (o delle medie mobili)



Passo 0:

Selezione di $K = 3$ pixel
come posizioni iniziali delle medie

L'algoritmo K-means (o delle medie mobili)

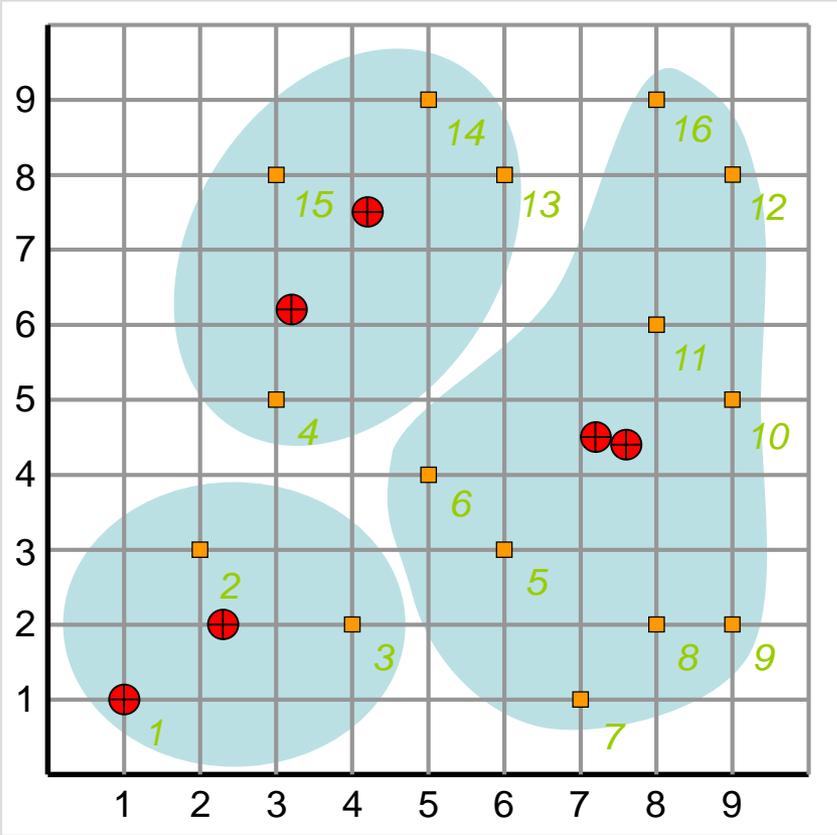


Passo 1:

Assegnazione di ogni altro pixel al cluster con la media più vicina.

Ricalcolo delle nuove medie per ogni cluster.

L'algoritmo K-means (o delle medie mobili)

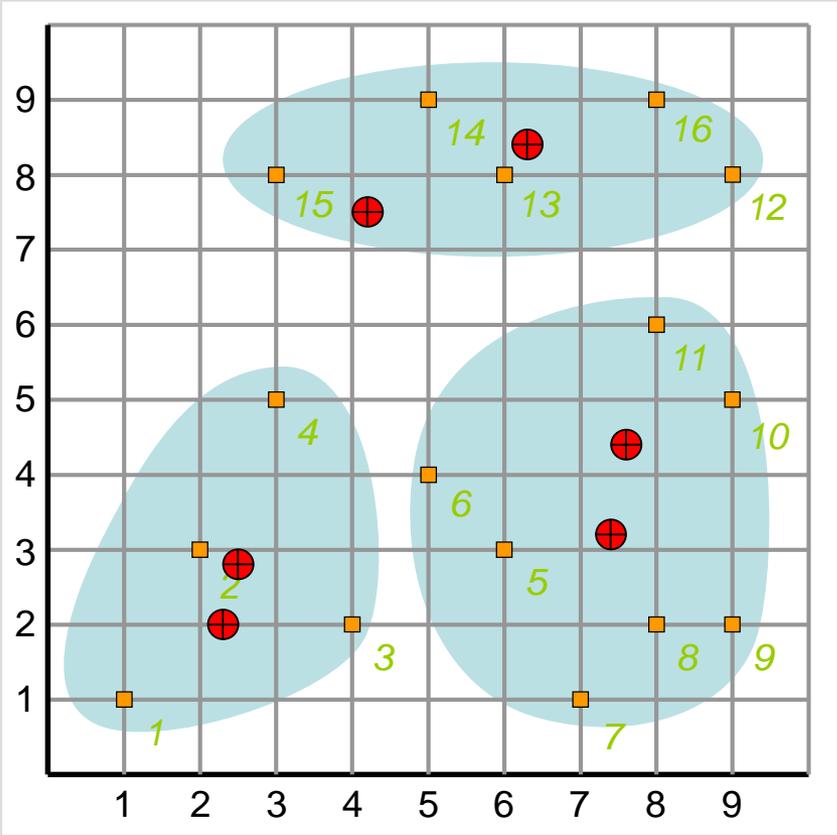


Passo 2:

Riassegnazione di ogni pixel al cluster con la media più vicina.

Ricalcolo delle nuove medie per ogni cluster.

L'algoritmo K-means (o delle medie mobili)

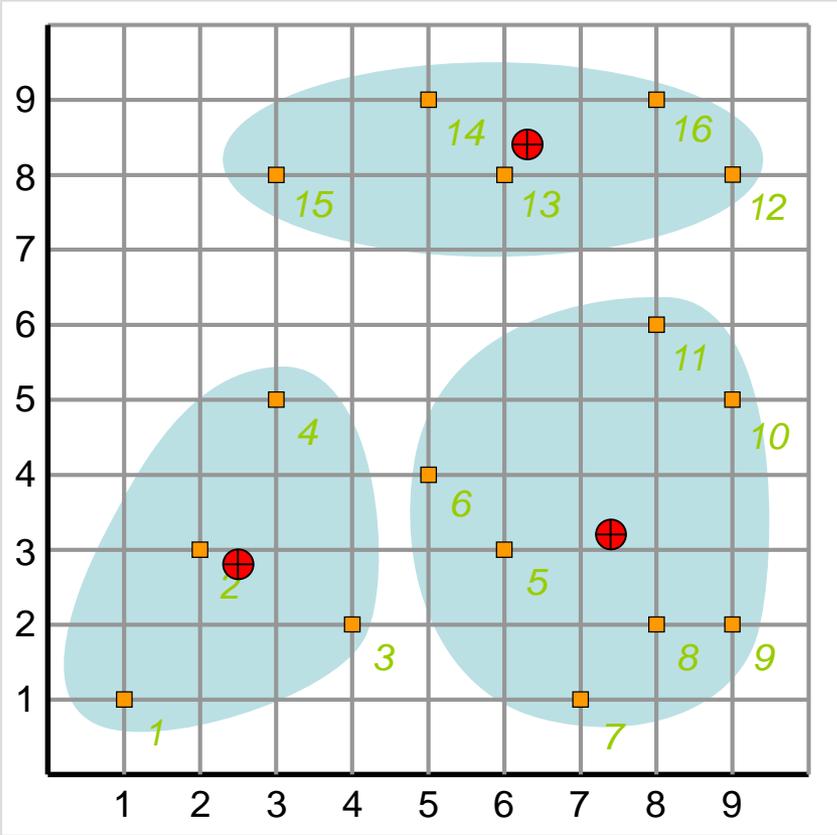


Passo 3:

Riassegnazione di ogni pixel al cluster con la media più vicina.

Ricalcolo delle nuove medie per ogni cluster.

L'algoritmo K-means (o delle medie mobili)



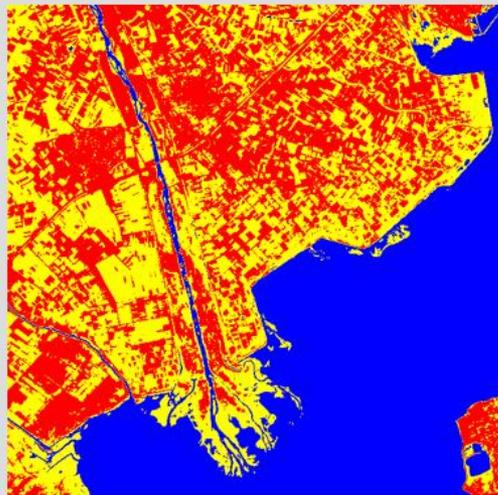
Passo 4:

Riassegnazione di ogni pixel al cluster con la media più vicina.

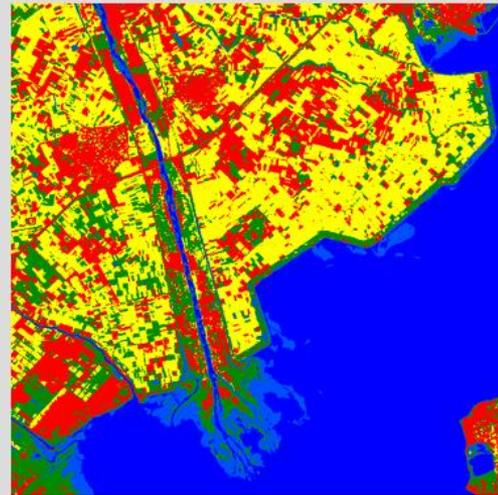
Tutti i pixel rimangono nella classe in cui erano. Le medie non cambiano.

Fine della clusterizzazione !

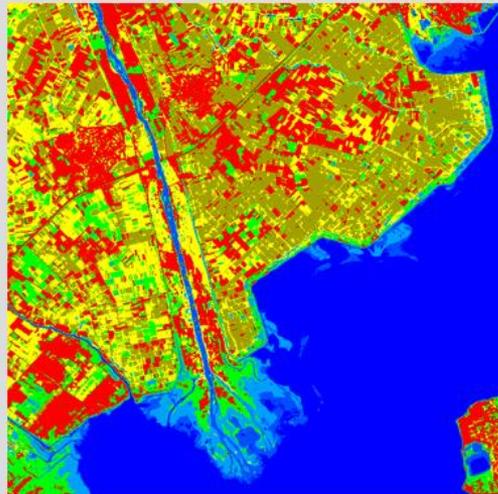
Esempi di classificazioni con il Metodo k-means



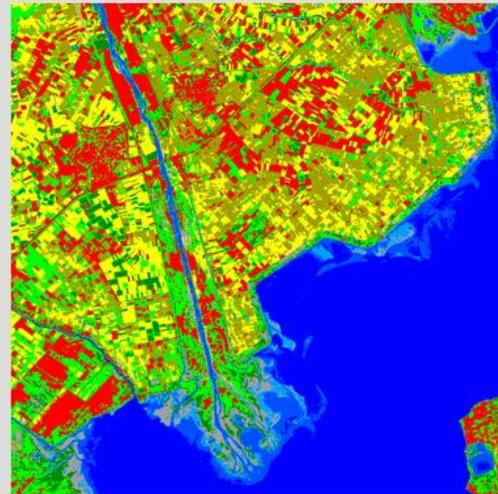
K-means: 3 classi



K-means: 5 classi



K-means: 7 classi

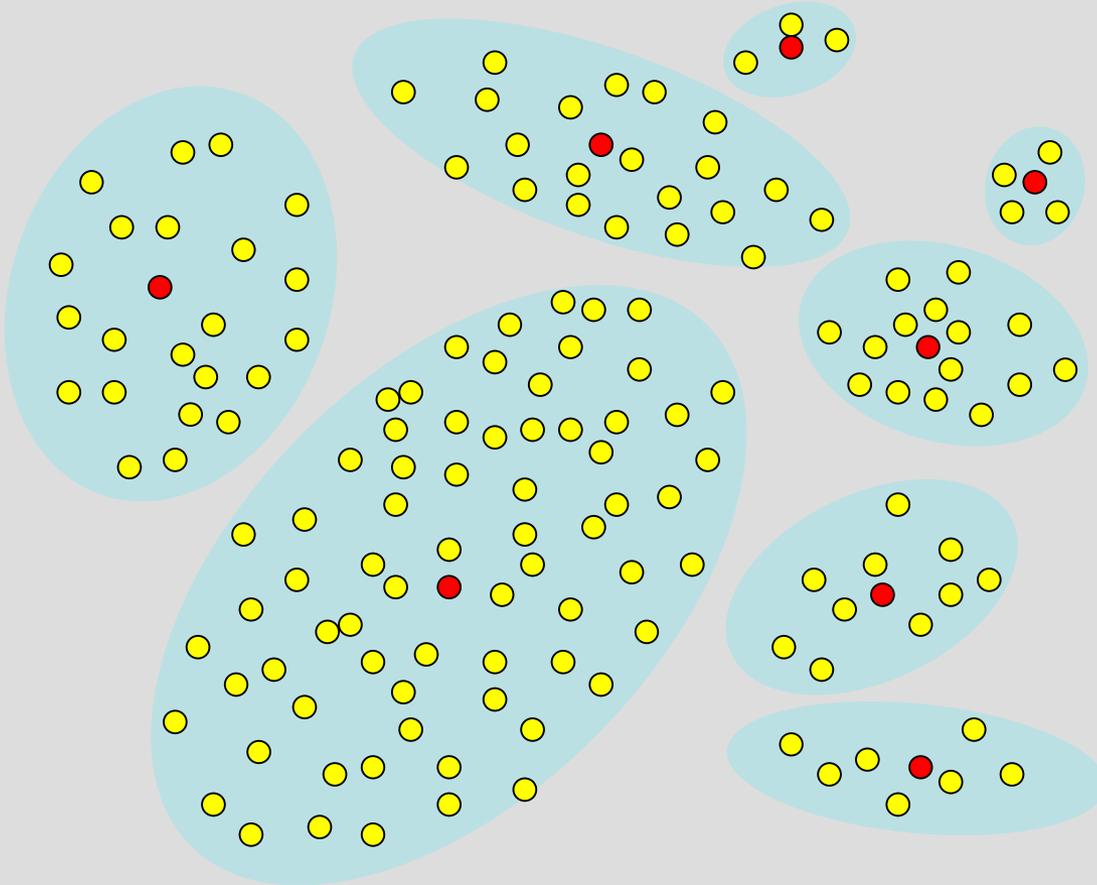


K-means: 9 classi

L'algoritmo Isodata

Una variante di quello K means.

Ad ogni passo una delle 3 seguenti procedure:



1. **ELIMINAZIONE**

Elimina cluster
con pochi pixel

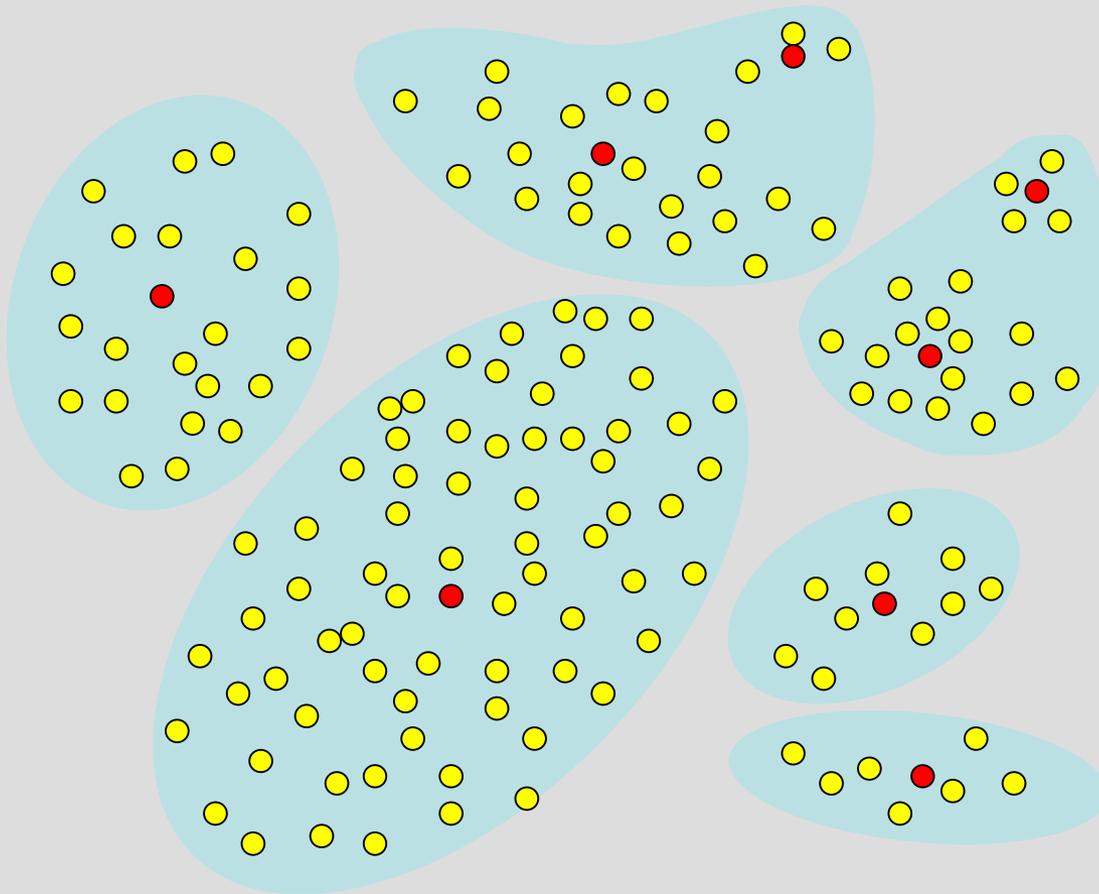
2. **UNIONE**

Unisci coppie di cluster
reciprocamente vicini

3. **DIVISIONE**

Dividi cluster
dispersi in due nuovi
cluster

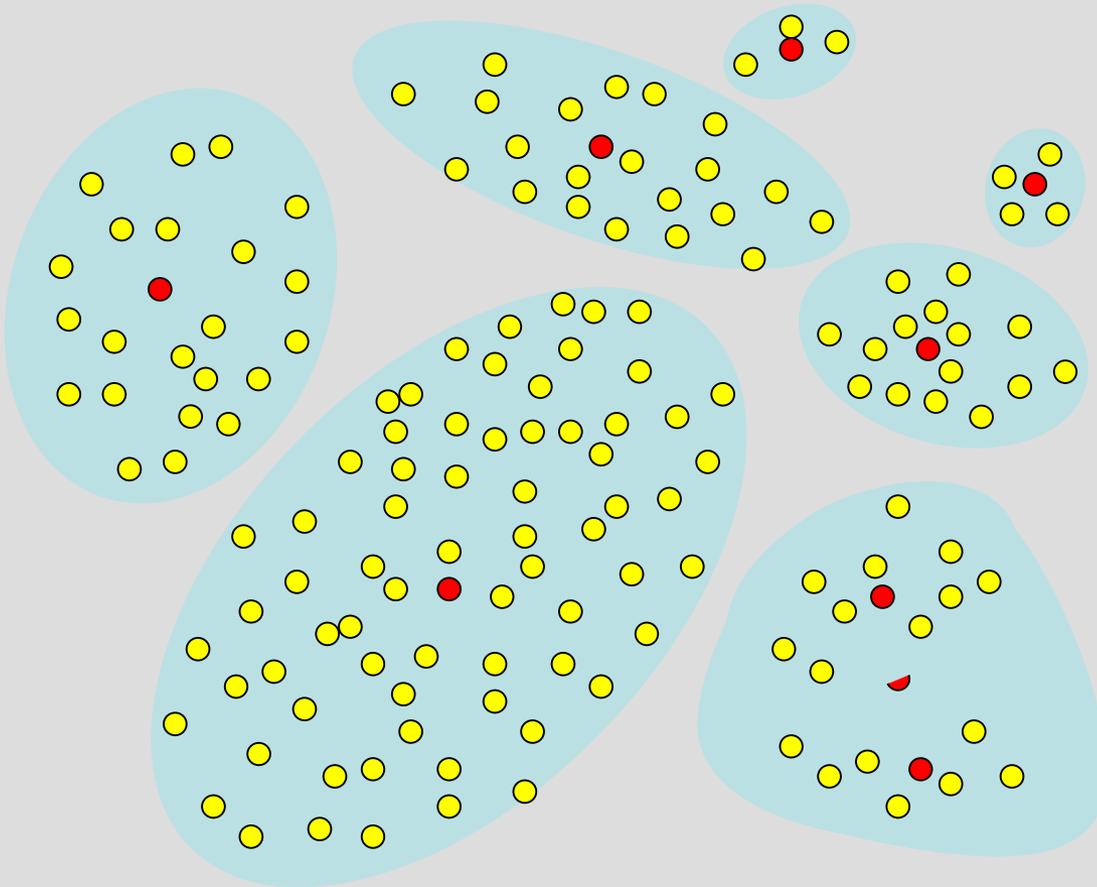
L'algoritmo Isodata



1. ELIMINAZIONE

Elimina cluster
con pochi pixel

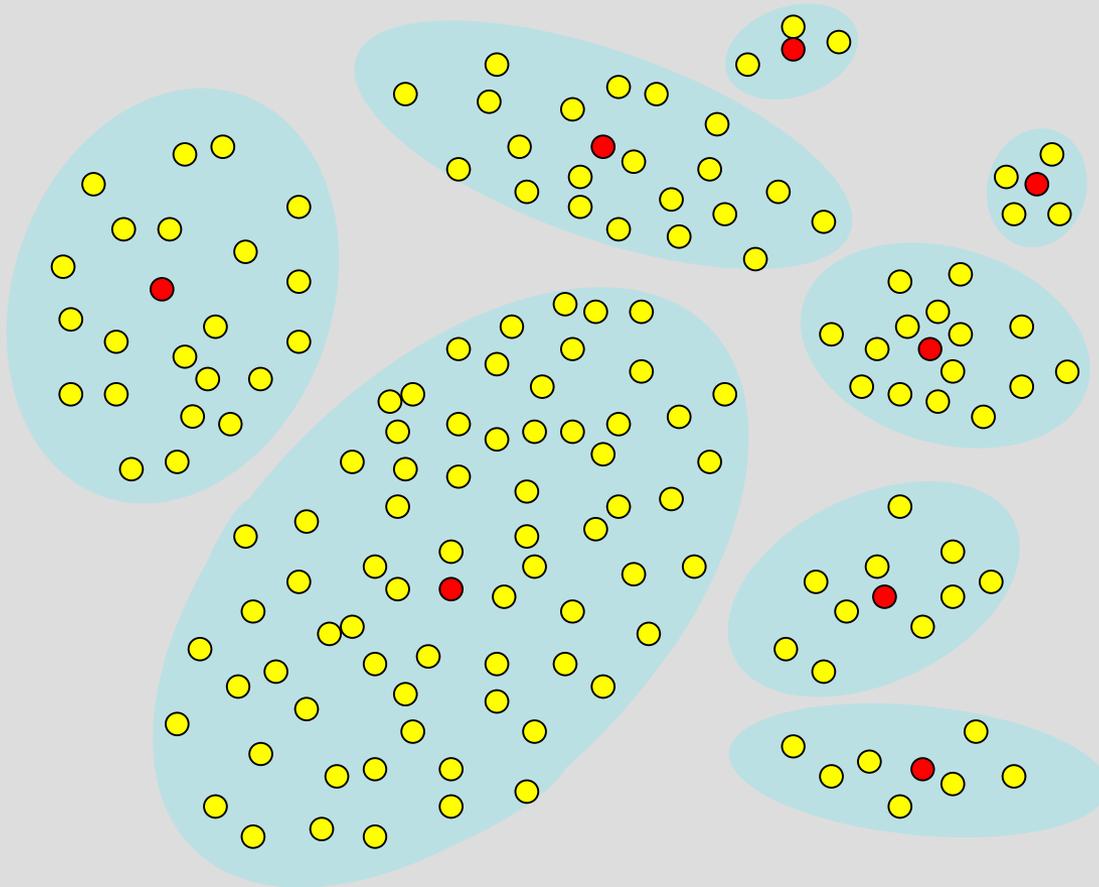
L'algoritmo Isodata



2. UNIONE

Unisci coppie di cluster
reciprocamente vicini

L'algoritmo Isodata

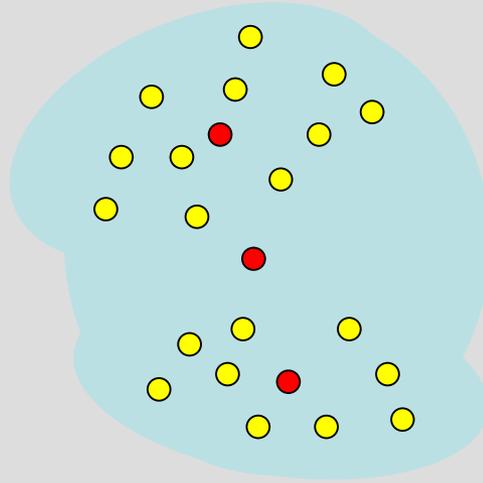


3. DIVISIONE

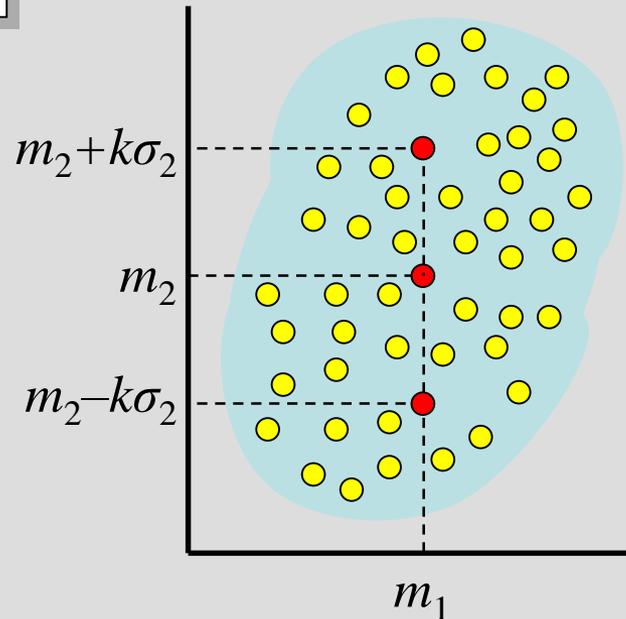
Dividi cluster
dispersi in due nuovi
cluster

L'algoritmo Isodata

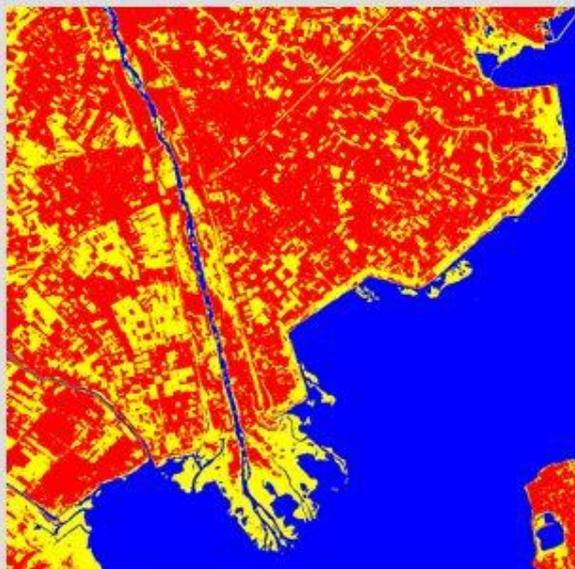
Il processo di unione



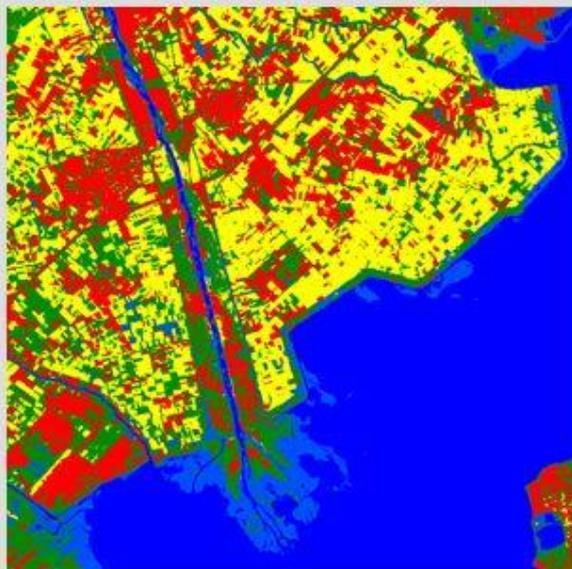
Il processo di divisione



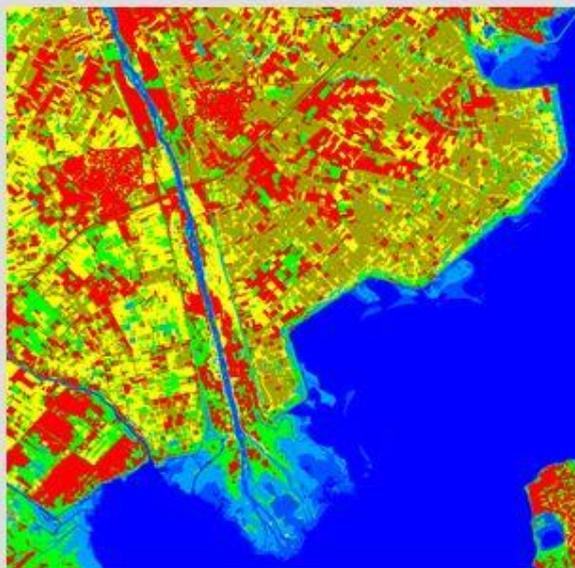
Esempi di
classificazione:
l'algoritmo ISODATA



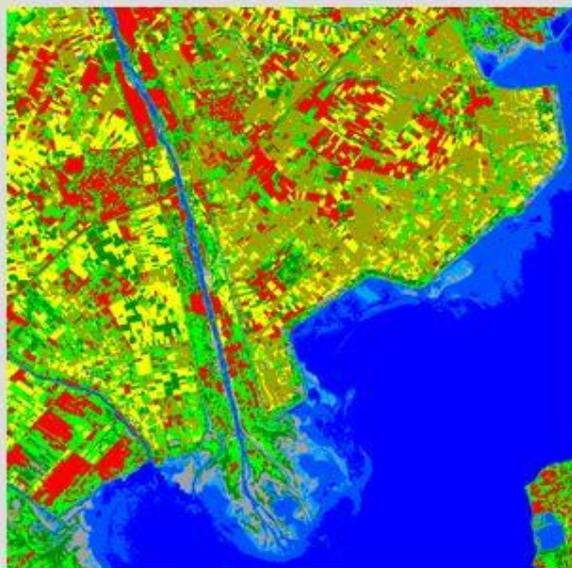
ISODATA: 3 classi



ISODATA: 5 classi



ISODATA: 7 classi



ISODATA: 9 classi

Classificazione non supervisionata

Nella classificazione non supervisionata, a prescindere dal metodo utilizzato, le classi risultanti saranno indicative dei cluster spettrali naturali presenti nei dati.

Essi possono o non possono corrispondere ad effettive coperture o a classi di materiali come normalmente le immaginiamo ed in alcuni casi può anche succedere che si vengano a formare classi con nessuna ovvia caratteristica.

Classificazione non supervisionata

A causa di questi limiti, una classificazione unsupervised è spesso usata come una preelaborazione per altri algoritmi.

Per esempio, quando tentiamo di localizzare le regioni di *training sites* per una classificazione supervised, è spesso utile sapere dove si verificano raggruppamenti spettrali naturali.

Classificazione non supervisionata

A tale scopo è bene ricordare che se un classificatore unsupervised delinea, ad esempio, la foresta presente sul versante est e su quello ovest come due classi separate, nel passaggio ad un classificatore supervised è opportuno continuare a considerare due *training sites* separati, ed eventualmente fondere, come già accennato, le due classi dopo la classificazione

Classificazione non supervisionata

Allo stesso modo una classificazione unsupervised potrebbe identificare, ad esempio, due classi separate riferibili una all'asfalto e l'altra al cemento che l'analista potrebbe, successivamente, raggruppare per creare un'unica classe di informazione chiamata «pavimentazione».