

# Clustering con Weka

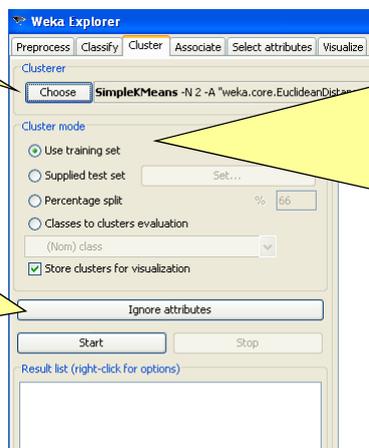
## Soluzioni degli esercizi

Prof. Matteo Golfarelli  
Alma Mater Studiorum - Università di Bologna

### L'interfaccia

Algoritmo utilizzato per il clustering

E' possibile escludere un sottoinsieme degli attributi dal calcolo delle distanze



Modalità di verifica dei risultati: indica il dataset su cui sono calcolati gli indici statistici che può essere diverso da quello in base al quale sono effettivamente costruiti i cluster (es. centroidi di kMeans)

In alternativa è possibile utilizzare un attributo classe per verificare la corrispondenza tra cluster e classe (se questa è nota)



## Il data set Iris

- Il data set Iris modella le caratteristiche di una famiglia di piante
  - ✓ 150 istanze
  - ✓ Nessun dato mancante

Attributo	Descrizione
<b>SepalLength</b>	Lunghezza del sepalo
<b>SepalWidth</b>	Larghezza del sepalo
<b>PetalLength</b>	Lunghezza del petalo
<b>PetalWidth</b>	Larghezza del petalo



## Pre-processing

- Gli algoritmi di clustering necessitano di una misura di distanza, nei casi che vedremo la distanza euclidea.
- Nel caso in cui gli attributi coinvolti abbiano range di valore diversi è sempre necessario normalizzare tali range in modo che ognuno di essi abbia la stessa influenza nel calcolo del risultato
  - ✓ Normalizzare gli attributi numerici utilizzando il filtro Unsupervised → Attribute→Normalize

## Simple K-means: i parametri

- **DisplayStdDev**: mostra la deviazione standard delle distanze dei singoli punti rispetto al centro del cluster. La misura è riportata separatamente per ogni attributo
  - ✓ Minore la StdDev maggiore la coesione del cluster rispetto all'attributo.
  - ✓ Permette di scegliere quali attributi utilizzare nel calcolo della similarità.
- **Distance function**: funzione distanza utilizzata nel calcolo
- **MaxIteration**: numero massimo di iterazioni per ottenere la convergenza
- **NumCluster**: valore di k
- **Seed**: valore random per la scelta dei centroidi iniziali
  - ✓ Cambiandolo cambia il loro posizionamento iniziale

## Simple K-means: i risultati

- Eseguire l'algoritmo ponendo DisplayStdDev=true e NumCluster=3

```

kMeans
*****
Number of iterations: 6
Within cluster sum of squared errors: 6.9981140048267605
Missing values globally replaced with mean/mode

Cluster centroids:
Attribute      Full Data      Cluster#
              (150)          (61)          (50)          (39)
-----
sepalength    0.4287         0.4413         0.1961         0.7073
              +/-0.23        +/-0.1246     +/-0.0979     +/-0.1396

sepalwidth    0.4392         0.3074         0.5908         0.4509
              +/-0.1807     +/-0.1222     +/-0.1588     +/-0.1166

petalength    0.4676         0.5757         0.0786         0.797
              +/-0.2991     +/-0.0693     +/-0.0294     +/-0.068

petalwidth    0.4578         0.5492         0.06           0.8248
              +/-0.318      +/-0.1135     +/-0.0447     +/-0.1171

Clustered Instances
0      61 ( 41%)
1      50 ( 33%)
2      39 ( 26%)
    
```

#iterazioni per la convergenza  
 SSE media per i punti dei cluster  
 Posizione del centroide per il cluster 2 sulla coordinata sepalength  
 DevStd dei punti del cluster 2 sulla coordinata sepalwidth rispetto alla coordinata del centroide  
 Dati per il centroide del clustering  
 Dimensione dei cluster

## Simple K-means: i risultati

- Rieseguire l'algoritmo selezionando Classes to cluster evaluation

```
Class attribute: class
Classes to Clusters:
 0 1 2 <-- assigned to cluster
 0 50 0 | Iris-setosa
 47 0 3 | Iris-versicolor
 14 0 36 | Iris-virginica
```

Matrice di confusione

```
Cluster 0 <-- Iris-versicolor
Cluster 1 <-- Iris-setosa
Cluster 2 <-- Iris-virginica
```

```
Incorrectly clustered instances : 17.0 11.3333 %
```

Numero e percentuale degli errori commessi in base alla corrispondenza cluster-classi

Corrispondenza tra cluster e classi determinata in base al numero di elementi del cluster che appartengono alla classe

## K-means: analisi del risultato

- Visualizzare il risultato del clustering per le diverse coppie di attributi e discutere il risultato in base al posizionamento dei centroidi e alla dispersione dei punti. Come è possibile migliorare il risultato?
- Risulta evidente che:
  - ✓ Il cluster 1 è meglio separato dagli altri visto il posizionamento dei suoi centroidi e i relativi valori di dispersione
  - ✓ I cluster 0 e 2 risultano poco separati sugli attributi sepalwidth e sepalwidth
    - $0.4413+0.1246=0.5659 \approx 0.7073-0.1396=0.5677$
    - $0.3074+0.1222=0.4296 \approx 0.4509/0.1166=0.3353$
- Per migliorare il risultato si possono eliminare gli attributi scarsamente informativi
  - ✓ Verificare l'efficacia attivando la verifica mediante le classi

## Il Data set FoodNutrients

- Contiene le informazioni nutrizionali di 25 alimenti
  - ✓ [Caricare il file FoodNutrients.arff](#)

Attributo	Descrizione
<b>EnergyCal</b>	Calorie per 100 gr
<b>ProteinGram</b>	Proteine per 100 gr
<b>FatGram</b>	Grassi per 100gr
<b>CalciumMG</b>	Calcio in milligrammi per 100 gr
<b>IronMG</b>	Ferro in milligrammi per 100gr

- Normalizzare i dati e clusterizzarli utilizzando k-means per valori crescenti di k [2,6]
- Analizzare i risultati facendo ipotesi sul significato delle classi in base alle caratteristiche dei centroidi e alle StdDev dei cluster

## Il Data set FoodNutrients

Number of iterations: 2  
 Within cluster sum of squared errors: 5.069321339929419  
 Missing values globally replaced with mean/mode

Attribute	Full Data (27)	Cluster#	
		0 (9)	1 (18)
EnergyCal	0.4331 +/-0.2699	0.763 +/-0.1442	0.2681 +/-0.1233
ProteinGram	0.6316 +/-0.2238	0.6316 +/-0.0912	0.6316 +/-0.2696
FatGram	0.3285 +/-0.2962	0.6988 +/-0.1701	0.1433 +/-0.108
CalciumMG	0.1076 +/-0.2156	0.0104 +/-0.0018	0.1562 +/-0.2521
IronMG	0.3421 +/-0.2657	0.3576 +/-0.0386	0.3343 +/-0.3272

Number of iterations: 3  
 Within cluster sum of squared errors: 4.077107647192327  
 Missing values globally replaced with mean/mode

Attribute	Full Data (27)	Cluster#		
		0 (8)	1 (12)	2 (7)
EnergyCal	0.4331 +/-0.2699	0.7917 +/-0.1236	0.3367 +/-0.102	0.1886 +/-0.1376
ProteinGram	0.6316 +/-0.2238	0.6184 +/-0.0878	0.7982 +/-0.1286	0.3609 +/-0.1908
FatGram	0.3285 +/-0.2962	0.7336 +/-0.1438	0.1908 +/-0.125	0.1015 +/-0.1035
CalciumMG	0.1076 +/-0.2156	0.0104 +/-0.002	0.1192 +/-0.2862	0.1989 +/-0.1691
IronMG	0.3421 +/-0.2657	0.3523 +/-0.0376	0.3379 +/-0.2607	0.3377 +/-0.4237

- C0 è ben caratterizzato per valori elevati di EnergyCal e FatGram
- Nella soluzione a 3 cluster il C0 rimane invariato mentre la caratterizzazione tra C1 e C2 è rilevante solo per ProteinGram
- In entrambe le soluzioni IronMG è poco caratterizzante

## Il Data set FoodNutrients

```

Number of iterations: 3
Within cluster sum of squared errors: 3.229030897655616
Missing values globally replaced with mean/mode

Cluster centroids:
Attribute      Full Data      Cluster#
                (27)          0          1          2          3
                (8)          (11)       (7)          (1)
-----
EnergyCal      0.4331      0.7917      0.3345      0.1886      0.36
                +/-0.2699  +/-0.1236  +/-0.1067  +/-0.1376  +/-0

ProteinGram    0.6316      0.6184      0.799       0.3609      0.7895
                +/-0.2238  +/-0.0878  +/-0.1348  +/-0.1908  +/-0

FatGram        0.3285      0.7336      0.189       0.1015      0.2105
                +/-0.2962  +/-0.1438  +/-0.131   +/-0.1035  +/-0

CalciumMG      0.1076      0.0104      0.0392      0.1989      1
                +/-0.2156  +/-0.002   +/-0.0739  +/-0.1691  +/-0

IronMG         0.3421      0.3523      0.3355      0.3377      0.3636
                +/-0.2657  +/-0.0376  +/-0.2733  +/-0.4237  +/-0
    
```

- L'aggiunta di C3 permette di caratterizzare meglio la differenza tra C1 e C2 in termini di CalciumMG
- C3 è composto da un solo elemento
- IronMG rimane poco caratterizzante

## Il Data set FoodNutrients

```

Number of iterations: 4
Within cluster sum of squared errors: 2.750432407251998
Missing values globally replaced with mean/mode

Cluster centroids:
Attribute      Full Data      Cluster#
                (27)          0          1          2          3          4
                (7)          (8)          (6)          (1)          (5)
-----
EnergyCal      0.4331      0.821       0.2883      0.1533      0.36      0.472
                +/-0.2699  +/-0.0991  +/-0.0781  +/-0.1108  +/-0     +/-0.0831

ProteinGram    0.6316      0.609       0.8553      0.3421      0.7895    0.6211
                +/-0.2238  +/-0.0904  +/-0.1043  +/-0.2018  +/-0     +/-0.1012

FatGram        0.3285      0.7669      0.125       0.0746      0.2105    0.3684
                +/-0.2962  +/-0.1171  +/-0.0805  +/-0.0822  +/-0     +/-0.093

CalciumMG      0.1076      0.0103      0.0518      0.2279      1          0.0105
                +/-0.2156  +/-0.0021  +/-0.0844  +/-0.1651  +/-0     +/-0.0092

IronMG         0.3421      0.3481      0.3545      0.3697      0.3636    0.2764
                +/-0.2657  +/-0.0385  +/-0.3115  +/-0.4547  +/-0     +/-0.1462
    
```

- C4 raccoglie gli alimenti con valori medi di EnergyCal, ProteinGram, FatGram
- Per quanto riguarda CalciumMG C4 è molto simile a C0
- IronMG rimane poco caratterizzante

## Il Data set FoodNutrients

Number of iterations: 4  
 Within cluster sum of squared errors: 1.5257151920333285  
 Missing values globally replaced with mean/mode

Cluster centroids:

Attribute	Full Data (27)	Cluster#					5 (4)
		0 (7)	1 (8)	2 (2)	3 (1)	4 (5)	
EnergyCal	0.4331 +/-0.2699	0.821 +/-0.0991	0.2883 +/-0.0781	0.0333 +/-0.0471	0.36 +/-0	0.472 +/-0.0831	0.2133 +/-0.073
ProteinGram	0.6316 +/-0.2238	0.609 +/-0.0904	0.8553 +/-0.1043	0.1053 +/-0.1489	0.7895 +/-0	0.6211 +/-0.1012	0.4605 +/-0.0662
FatGram	0.3285 +/-0.2962	0.7669 +/-0.1171	0.125 +/-0.0805	0 +/-0	0.2105 +/-0	0.3684 +/-0.093	0.1118 +/-0.0756
CalciumMG	0.1076 +/-0.2156	0.0103 +/-0.0021	0.0518 +/-0.0844	0.2017 +/-0.0156	1 +/-0	0.0105 +/-0.0092	0.241 +/-0.2113
IronMG	0.3421 +/-0.2657	0.3481 +/-0.0385	0.3545 +/-0.3115	0.9455 +/-0.0771	0.3636 +/-0	0.2764 +/-0.1462	0.0818 +/-0.1055

- Con l'aggiunta del nuovo cluster C0, C1 e C4 rimangono invariati
- Gli elementi di C5 sembrano provenire da C2 che si caratterizza ora per valori bassi per calorie, proteine e grassi e valori alti per il calcio e il ferro

## FoodNutrients: ricapitolando....

Clust	Caratterizzazione
C0	cibi grassi altamente proteici ed energetici
C1	cibi proteici ma con pochi grassi e calorie
C2	cibi leggeri ma ricchi di calcio
C3	un solo elemento
C4	C4 cibi con apporto medio di grassi proteine e calorie
C5	cibi leggeri in termini di calorie e grassi ma ricchi di proteine, calcio e ferro

- Verifichiamo caricando il data set FoodNutrientClassified.arff che contiene la classificazione dei cibi in Tipi e Super tipi
  - ✓ Si attivi Classes to cluster evaluation

## FoodNutrients: ricapitolando....

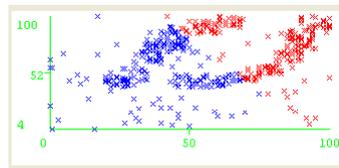
Clust	Caratterizzazione	Super tipo	Tipo
C0	cibi grassi altamente proteici ed energetici	Meat	Pork
C1	cibi proteici ma con pochi grassi e calorie	Meat	Beef
C2	cibi leggeri ma ricchi di calcio	Fish	Clams
C3	un solo elemento	Fish	No class
C4	cibi con apporto medio di grassi proteine e calorie	Meat	Lamb
C5	cibi leggeri in termini di calorie e grassi ma ricchi di proteine, calcio e ferro	Fish	Fish

## Il Data set Coordinates

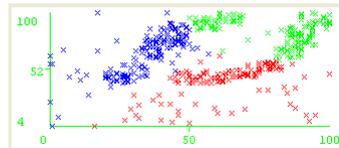
- Contiene le coordinate geografiche di 480 punti
  - ✓ [Caricare il file Coordinates.arff](#)
- Classificare i dati utilizzando k-means con un numero di cluster compreso tra 2 e 6
  - ✓ [Come varia SSE?](#)
  - ✓ [A partire da quale valore di k SSE si stabilizza?](#)
  - ✓ [K-means è in grado di catturare i cluster naturali?](#)
    - Perché?

## Coordinates con K-means

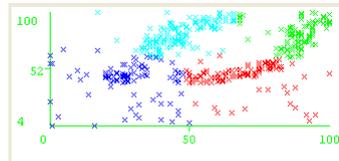
K=2  
SSE=29.39



K=3  
SSE=19.89

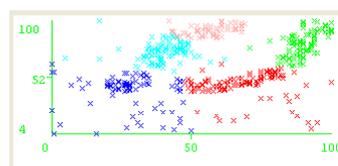


K=4  
SSE=12.09

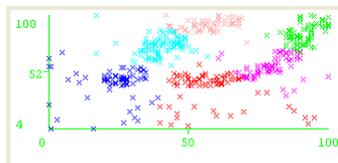


## Coordinates con K-means

K=5  
SSE=9.54



K=6  
SSE=7.87



- SSE si stabilizza con K=5 perché i cluster individuati sono tutte scomposizioni dei singoli cluster naturali
- K-means non è adatto a questo data set poiché la forma allungata dei cluster naturali non può essere catturata

**E' preferibile utilizzare DBSCAN**

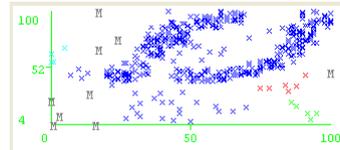
## Coordinates con DBSCAN

- Valutare il risultato della classificazione con DBSCAN
- Identificare i corretti valori per epsilon e minpoints

Eps=0.1

MinPts=4

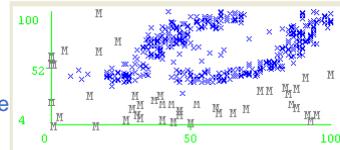
- ✓ I parametri non catturano correttamente il rumore e le separazioni tra i cluster: tutte le zone risultano dense! E' necessario ricercare aree a maggiore densità



Eps=0.1

MinPts=8

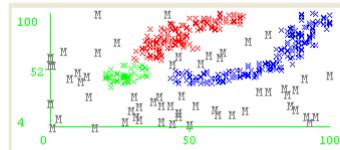
- ✓ Aumentare la densità permette di identificare meglio i punti di rumore ma non consente di differenziare i due cluster naturali



Eps=0.05

MinPts=4

- ✓ Raggio insufficiente

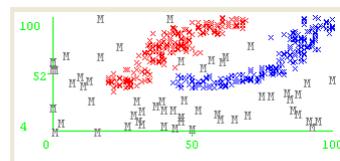


## Coordinates con DBSCAN

- Valutare il risultato della classificazione con DBSCAN
- Identificare i corretti valori per epsilon e minpoints

Eps=0.06

MinPts=8



Eps=0.06

MinPts=3

- ✓ Incorretta individuazione dei punti di rumore

