

# Riconoscimento e recupero dell'informazione per bioinformatica

Clustering: validazione

Manuele Bicego

Corso di Laurea in Bioinformatica  
Dipartimento di Informatica - Università di Verona

## Sommario

- ⇒ Definizione di validazione del clustering
- ⇒ Validazione di gerarchie
- ⇒ Validazione di partizioni
- ⇒ Validazione di cluster
- ⇒ "Clustering tendency"

## Definizione

- ⇒ Validazione del clustering: insieme di procedure che valutano il risultato di un'analisi di clustering in modo quantitativo e oggettivo
  - ⇒ Differente dalla validazione "soggettiva": data dal particolare contesto applicativo, con l'utilizzo della conoscenza a priori sul problema (intesa anche come "interpretazione dei risultati")
  - ⇒ In questa parte: validazione "oggettiva": misura quantitativa della capacità della struttura trovata di spiegare i dati (indipendentemente dal contesto)

3

## Indici di validità

Gli indici possono essere diversi a seconda della struttura analizzata (del tipo di clustering)

- ⇒ Gerarchie: risultato degli algoritmi gerarchici
  - ⇒ Possiamo anche voler valutare una gerarchia esistente, ad esempio un modello teorico
- ⇒ Partizioni: risultato degli algoritmi partizionali
  - ⇒ Si può valutare una partizione esistente derivante da informazioni di categoria
- ⇒ Clusters: sottoinsiemi di patterns
  - ⇒ Derivanti da cluster analysis, informazione di categorie, ...

4

## Indici di validità

Tipi di indici:

⇒ Criteri esterni:

⇒ misurano le performance di un clustering andando a confrontare informazioni a priori

⇒ Esempio: etichette già note a priori

⇒ Criteri interni:

⇒ Misurano le performance di un clustering utilizzando solo i dati (completamente non supervisionato)

⇒ Criteri relativi:

⇒ Confronta due risultati di clustering

5

## Indici di validità

NOTA: differenza tra criterio e indice

⇒ Indice: misura statistica che viene utilizzata per testare la validità

⇒ Criterio: strategia con cui un clustering viene validato

TIPICAMENTE:

⇒ Nel caso di criteri interni o esterni, si va a vedere se il valore di un indice è particolarmente "grande" o particolarmente "piccolo"

6

## Questioni principali

- ⇒ Definizione di un indice:
  - ⇒ Deve avere senso anche da un punto di vista intuitivo
  - ⇒ Deve essere basato su una solida teoria
  - ⇒ Deve essere facilmente calcolabile
- ⇒ Definizione di una baseline
  - ⇒ Distribuzione di base derivante da una popolazione senza struttura
- ⇒ Test per struttura non random
  - ⇒ Come confrontare l'indice con la baseline

7

## Indici di validità per gerarchie

- ⇒ Criteri esterni: verificare se una gerarchia (dendrogramma) calcolata per un dato insieme di dati corrisponde alla gerarchia attesa
- ⇒ Approccio tipico (Hubert's  $\Gamma$  statistics)
- ⇒ Nota: questo problema di validazione non ha ricevuto un grande interesse, in quanto è piuttosto difficile avere una gerarchia "vera" con cui confrontare il clustering

8

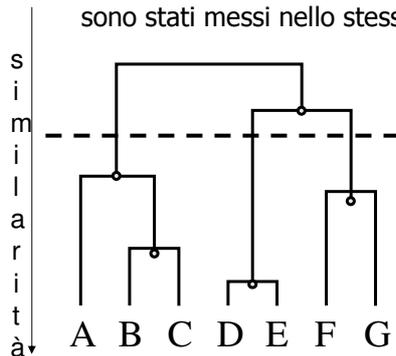
## Criteri interni

⇒ Rispondono alle seguenti domande:

- ⇒ Una gerarchia fitta bene i dati su cui è stata calcolata?
- ⇒ Ci si può fidare di un determinato risultato di clustering gerarchico?

⇒ Un esempio: CPCC (Cophenetic correlation coefficient)

- ⇒ cophenetic distance: il livello di un dendrogramma dove due oggetti sono stati messi nello stesso cluster per la prima volta



$$d(D,A) = 6$$

$$d(D,E) = 1$$

9

## Criteri interni

⇒ la cophenetic distance misura quando sono simili due oggetti "dato l'albero" (cioè la misura di distanza espressa dall'albero)

⇒ CPCC: coefficiente di correlazione normalizzato

$$CPCC = \frac{\frac{1}{M} \sum_{i,j} d(i,j)d_C(i,j) - m_D m_C}{\left[ \frac{1}{M} \sum_{i,j} d^2(i,j) - m_D \right]^{1/2} \left[ \frac{1}{M} \sum_{i,j} d_C^2(i,j) - m_C \right]^{1/2}} \quad (i,j) : 1 \leq i < j \leq n$$

$$m_D = \frac{1}{M} \sum_{i,j} d(i,j)$$

⇒ misura la correlazione tra la distanza derivante dai dati e la distanza derivante dal dendrogramma che spiega i dati

$$m_C = \frac{1}{M} \sum_{i,j} d_C(i,j)$$

⇒ CPCC varia tra -1 e 1: più è vicino a 1 migliore è il clustering

10

## Indici di validità per partizioni

- ⇒ Rispondono alle seguenti domande:
  - ⇒ La partizione ha un buon match con le categorie?
  - ⇒ Quanti cluster ci sono nel dataset?
  - ⇒ Dove deve essere tagliato il dendrogramma?
  - ⇒ Quale tra due partizioni date fitta meglio il dataset?

11

## Indici di validità per partizioni

Criteri esterni:

- ⇒ Tipicamente si va a confrontare due partizioni:
  - ⇒ Una deriva dal clustering
  - ⇒ Una deriva dall'informazione a priori (etichette)
- ⇒ Diversi indici Rand, Jaccard, Fowlkes and Mallows,  $\Gamma$  statistic

12

## Indici di validità per partizioni

⇒ Idea: ho due partizioni U e V da confrontare

⇒ U: risultato del clustering

⇒ V: clustering "vero" (deriva dalle etichette note a priori)

⇒ Definizione di due funzioni Indicatrici

⇒  $I_U(i,j)$  vale 1 se gli oggetti i e j sono nello stesso cluster secondo il clustering U

⇒  $I_V(i,j)$  vale 1 se gli oggetti i e j sono nello stesso cluster secondo il clustering V

⇒ Definizione della "tabella di contingenza"

		$I_V$	
		1	0
$I_U$	1	a	b
	0	c	d

a = numero di coppie di oggetti che sono nello stesso gruppo in tutte e due le partizioni

13

## Indici di validità per partizioni

Altre definizioni

⇒  $m_1$  = numero di coppie nello stesso gruppo in U

⇒  $m_1 = a+b$

⇒  $m_2$  = numero di coppie nello stesso gruppo in V

⇒  $m_2 = c+d$

⇒  $M = a+b+c+d$

14

## Indici di validità per partizioni

I diversi indici sono definiti a partire da queste quantità

⇒ Rand 
$$\frac{a + d}{\binom{n}{2}}$$

⇒ Jaccard 
$$\frac{a}{a + b + c}$$

⇒ Fowlkes & Mallows 
$$\frac{a}{(m_1 m_2)^{1/2}}$$

⇒  $\Gamma$  statistic 
$$\frac{Ma - m_1 m_2}{(m_1 m_2 (M - m_1)(M - m_2))^{1/2}}$$

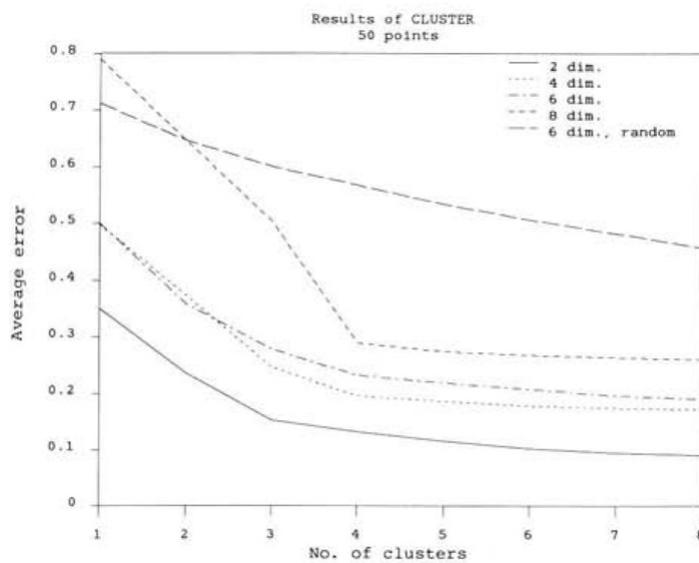
15

## Indici di validità per partizioni

Criteria interni:

- ⇒ Difficili da stimare: devono misurare il fitting tra una partizione data e il dataset
- ⇒ Problema fondamentale: stimare il numero di clusters
- ⇒ Molti metodi (esempio metodi di model selection per modelli probabilistici)
- ⇒ Ma molte difficoltà:
  - ⇒ Stima della baseline (campionamento di molti dataset + stima di un indice interno --- ma quale modello per campionare i dati?)
  - ⇒ Gli indici interni dipendono strettamente dai parametri del problema:
    - ⇒ Numero di features, numero di patterns, numero di clusters ...

16



⇒ Misura dell'errore medio del k-means

17

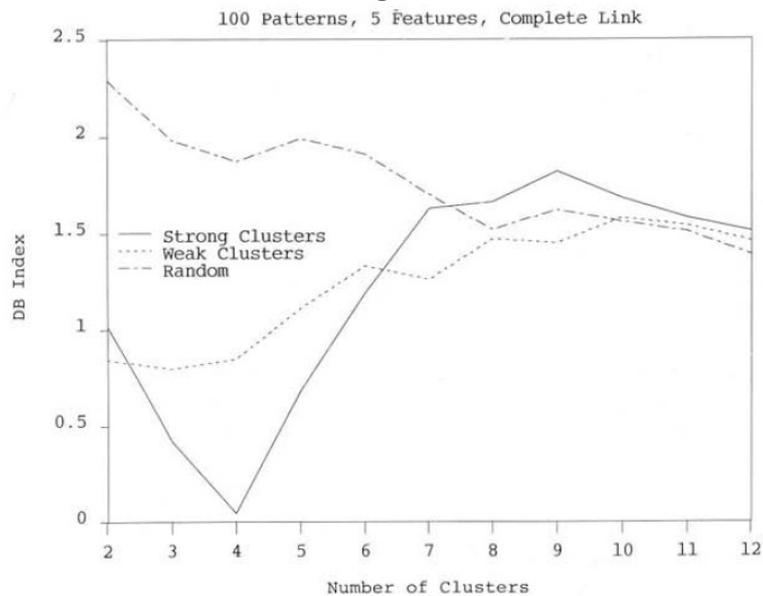
## Un particolare indice

L'indice di Davies-Bouldin (1979)

- ⇒ Inizialmente utilizzato per decidere quando fermare un clustering sequenziale
- ⇒ L'indice viene calcolato al variare del numero di clusters
- ⇒ Il miglior clustering corrisponde al valore minimo
- ⇒ (definizione alla lavagna)

18

Può anche essere utilizzato per determinare la presenza di una struttura di clustering



## Validità di singoli cluster

⇒ Criteri basati su due proprietà:

⇒ Compattezza

⇒ Isolamento

⇒ Compattezza: misura la coesione interna tra gli oggetti del cluster (quanto sono vicini tra di loro)

⇒ Isolamento: misura la separazione tra un cluster e tutti gli altri pattern.

⇒ Cluster valido: compatto e isolato.

Come misurare compattezza e isolamento?

Diversi indici complessi (vedi Cap 4.5 Libro Jain Dubes)

## Clustering tendency

- ⇒ Problema: gli algoritmi di clustering producono sempre un output, indipendentemente dal dataset
- ⇒ Definizione: identificare, senza effettuare il clustering, se i dati hanno una predisposizione ad aggregarsi in gruppi naturali
  
- ⇒ Operazione preliminare cruciale:
  - ⇒ Previene dall'applicare elaborate metodologie di clustering e di validazione a dati in cui i cluster sono sicuramente degli artefatti degli algoritmi di clustering

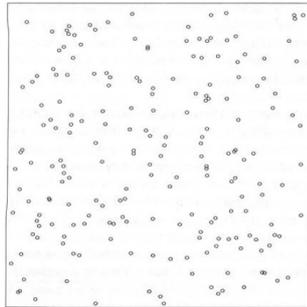
21

## Clustering tendency

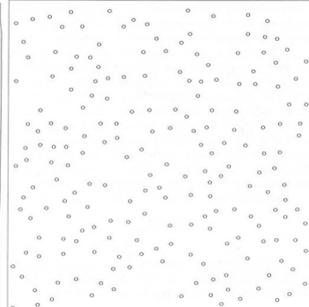
- ⇒ IDEA: studio dello spazio delle features in modo da identificare tre possibili situazioni:
  1. I pattern sono sistemati in modo casuale (spatial randomness)
  2. I pattern sono aggregati, cioè esibiscono una mutua attrazione
  3. I pattern sono spazati regolarmente, cioè esibiscono una mutua repulsione
  
- ⇒ Nei casi 1 e 3 non ha senso effettuare il clustering

22

## Cluster tendency



random



regular



cluster

23

## Cluster tendency

IDEA: effettuare alcuni test in modo da determinare se esiste o meno una struttura (e.g. test per una distribuzione uniforme in una finestra detta sampling window)

ESEMPI:

⇒ Scan tests:

- ⇒ Contare il numero di pattern presenti nella sottoregione più popolosa
- ⇒ Se il numero è inusualmente grande allora esiste un clustering
- ⇒ PROBLEMI: come definire le sottoregioni, cosa vuol dire "inusualmente grande"

24

# Cluster tendency

## ESEMPI

### ⇒ Quadrat analysis:

- ⇒ Partizionare la sampling window in rettangoli di dimensione uguale
- ⇒ Contare il numero di punti in ogni rettangolo
- ⇒ In caso di distribuzione randomica, l'insieme di conteggi segue una distribuzione nota
- ⇒ La randomicità viene attestata con un test di similarità tra distribuzioni (e.g. il test del chi quadro)

### ⇒ PROBLEMI:

- ⇒ dimensione dei sottorettangoli (si può anche fare multiscala)
- ⇒ Funziona solo per un numero limitato di features (altrimenti la maggior parte dei rettangoli sono vuoti)

25