

Riconoscimento e recupero dell'informazione per bioinformatica

Rappresentazione dati e visualizzazione

Manuele Bicego

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

Sommario

- ⇒ Rappresentazione dei dati:
 - ⇒ campionamento
 - ⇒ estrazione delle features: tipo di dato e tipo di pattern
 - ⇒ rappresentazione preprocessing (scaling, riduzione del rumore, riduzione della dimensionalità)
 - ⇒ (visualizzazione)

La rappresentazione dei dati

- ⇒ Rappresentazione dei dati: il problema di come rappresentare gli oggetti del problema in esame
 - ⇒ Rappresentazione quantitativa/qualitativa
 - ⇒ Rappresentazione utilizzabile per calcolare la similarità/distanza, per costruire il modello, per fare il testing
 - ⇒ scelta cruciale



3

La rappresentazione dei dati

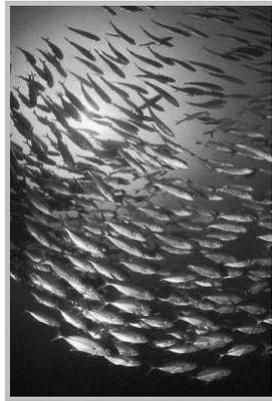
Fasi:

1. campionamento (acquisizione dati)
2. estrazione delle features
3. rappresentazione
4. preprocessing:
 - ⇒ scaling
 - ⇒ riduzione del rumore
 - ⇒ riduzione della dimensionalità
5. (visualizzazione)

4

Fase 1: campionamento

⇒ Esempio 1: modellare pesci



campionamento



immagine (dato grezzo)

⇒ L'immagine può essere vista come un punto in uno spazio $M \times N$ dimensionale (immagine di dimensione $M \times N$)

5

Fase 1: campionamento

⇒ Problemi da tenere in considerazione:

- ⇒ tipo di sensore: caratteristiche tecniche
- ⇒ frequenza di campionamento: capacità di modellare evoluzione temporale
- ⇒ risoluzione (dipende dal sensore): quanti dettagli si riesce a recuperare
- ⇒ capacità di gestire cambiamenti di condizioni al contorno (eg. cambi di illuminazione)

6

Fase 1: campionamento

⇒ Scelta del sensore è la prima scelta cruciale

⇒ Esempio: filogenesi di microrganismi

⇒ l'obiettivo è sequenziare il gene scelto per fare filogenesi nei microrganismi in esame

⇒ far crescere i batteri (scelta del terreno di crescita,...)

⇒ estrarre il DNA e amplificare quello dei geni prescelti per la filogenesi (scelta dei primer, scelta dei parametri della PCR)

⇒ sequenziare

⇒ Esempio: riconoscimento di facce



telecamera a infrarosso:

- funziona anche al buio
- risoluzione bassa



telecamera tradizionale:

- sensibile ai cambi di illuminazione
- alta risoluzione

Fase 2: estrazione delle features

⇒ Trovare una rappresentazione "quantitativa" più compatta e più descrittiva dell'oggetto

⇒ Definizione di feature:

⇒ caratteristica del problema in esame

⇒ rilevante

⇒ discriminante

⇒ quantificabile a partire dai dati grezzi

⇒ (interpretabile)

⇒ La scelta della rappresentazione è chiaramente cruciale

Fase 2: estrazione delle features

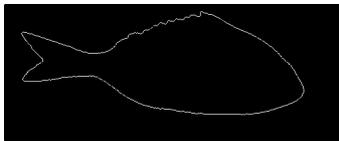
⇒ Opzione 1:



Altezza e
larghezza

Tipo di dato
risultante:
vettore di due
dimensioni $[a,l]$

⇒ Opzione 2:



Contorno
dell'oggetto,
a partire
dalla coda

Tipo di dato
risultante:
sequenza di
vettori di due
dimensioni (le
coordinate di
ogni punto del
contorno)

x_1, y_1
 x_2, y_2
 x_3, y_3
...
 x_n, y_n

9

⇒ Opzione 1: vantaggi:

- ⇒ rappresentazione compatta
- ⇒ ogni oggetto è un punto in uno spazio vettoriale bidimensionale
- ⇒ non è difficile da calcolare

⇒ Opzione 1: svantaggi

- ⇒ troppo semplificata: non riesce a modellare la forma del pesce, il colore

⇒ Opzione 2: vantaggi

- ⇒ rappresentazione più ricca, modella la forma del pesce

⇒ Opzione 2: svantaggi

- ⇒ più complicata da calcolare
- ⇒ il pattern risultante è una sequenza (che può essere di dimensione diversa a seconda del pesce). Non siamo quindi più in uno spazio vettoriale

10

Fase 3: Rappresentazione

Due concetti:

⇒ Tipo di dato:

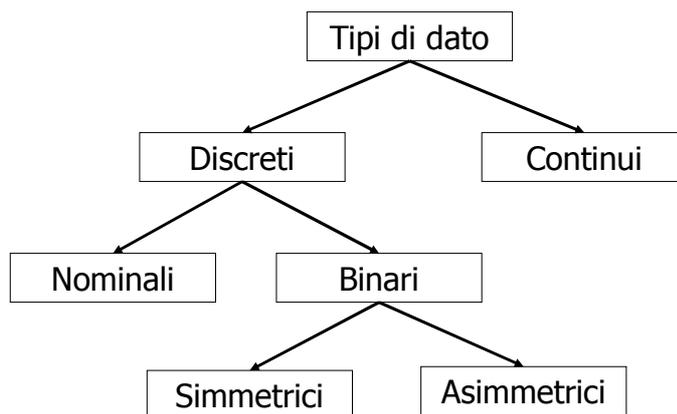
- ⇒ come viene codificata ogni singola feature
- ⇒ Esempio: numero intero, un valore di verità

⇒ Tipo di pattern:

- ⇒ come sono messe assieme le varie feature per un singolo oggetto
- ⇒ Esempio: un vettore di numeri interi (altezza-larghezza)

11

Tipi di dato



12

Tipi di dato

- ⇒ Continui: il valore della feature può assumere un numero infinito di valori (e.g. numeri reali)
 - ⇒ attenzione: campionamento!
- ⇒ Discreti: il valore della feature può essere solo uno di un insieme finito di valori possibili
- ⇒ Nominali: il valore della feature può essere uno di un insieme di nomi (o di simboli) – tipo di dato discreto
- ⇒ EXE: sequenza di DNA:
 - ⇒ T Timina
 - ⇒ A Adenina
 - ⇒ G Guanina
 - ⇒ C Citosina

13

Tipi di dato

- ⇒ Dati binari: dati che possono assumere solo due valori:
 - ⇒ 0/1, vero/falso
- ⇒ Dati binari simmetrici: i due valori sono ugualmente importanti
 - ⇒ esempio: maschio/femmina
- ⇒ Dati binari asimmetrici: uno dei due valori porta più informazione dell'altro
 - ⇒ esempio:
 - ⇒ sì: presenza di un attributo
 - ⇒ no: assenza

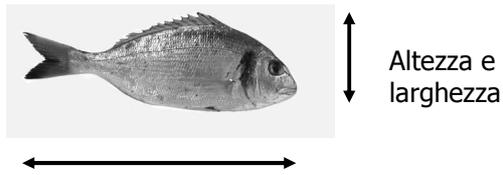
14

Tipi di pattern: i vettori

Dati vettoriali (formato più diffuso)

⇒ per ogni oggetto viene estratto un insieme prefissato di features

⇒ Esempio:



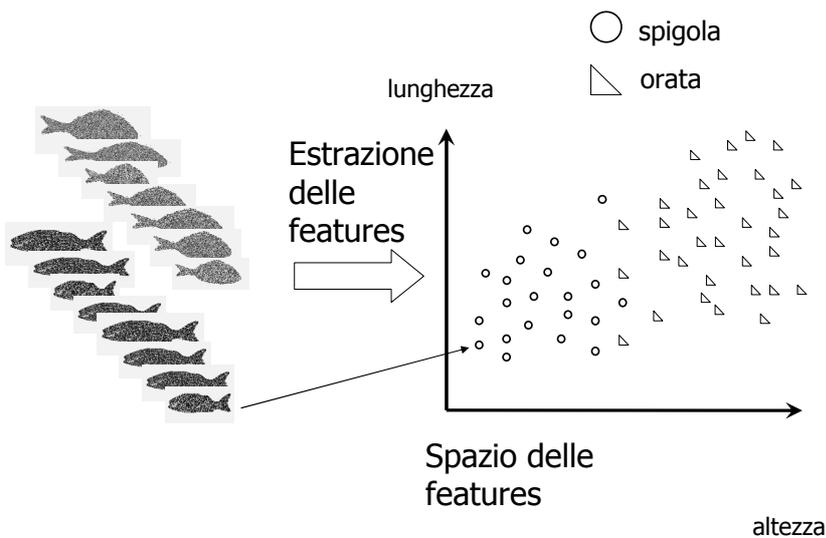
⇒ il vettore è ordinato

⇒ l'oggetto viene proiettato in un punto in uno spazio d-dimensionale, detto "spazio delle features"

⇒ "d" è il numero delle features

15

Tipi di pattern: i vettori



16

Commenti su spazi vettoriali

- ⇒ La scelta delle features è cruciale
- ⇒ Utilizzando molte features gli spazi diventano estremamente grandi
 - ⇒ problema della curse of dimensionality
 - ⇒ problema di visualizzare i dati
- ⇒ Esistono metodi che riducono la dimensionalità di questi spazi (vedremo in seguito)
- ⇒ Il problema della "scalatura" dello spazio

17

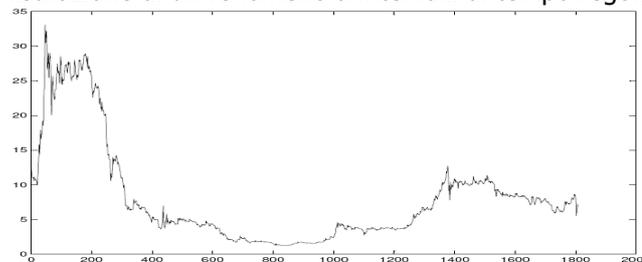
Tipi di pattern: le sequenze

- ⇒ Sequenze: dati che si presentano in forma ordinata e sequenziale (uno dopo l'altro): è importante l'ordine

$X_1, X_2, X_3, X_4 \dots X_T$

- ⇒ Sequenze temporali:

- ⇒ sequenza di features (di diverso tipo) che rappresentano la misurazione di un fenomeno a intervalli di tempo regolari



Esempio 1: indici di mercato (DowJones)

18

Tipi di pattern: le sequenze

⇒ Sequenze non temporali:

⇒ sequenze dove l'ordine non è dato dal tempo

⇒ Esempio 1:

⇒ sequenze nucleotidiche

```
atgcatcgatcgatcgatcgatcaggcgcgctacgagcggcgagga  
cctcatcatcgatcag
```

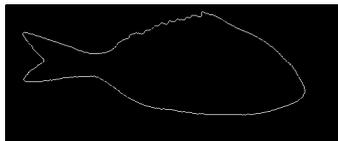
⇒ sequenze aminoacidiche

```
MRPQAPGSLVDPNEDELRMAPWYWGRISREEAKSILHGKPDGSFLVRDALSMKGEYTLTLMK  
DGCEKLIKICHMDRKYGFIEITDLFNSVEMINYKENSLSMYNKTLDITLSNPIVRAREDEE  
SQPHGDLCLLSNEFIRTCQLLQNLQNLNKRNSFNAREELQEKKLHQSVFGNTEKIFRNQ  
IKLNESEFMKAPADA.....
```

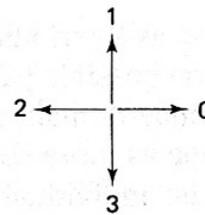
21

Tipi di pattern: le sequenze

⇒ Esempio 2: codifica di un contorno di una forma 2D



contorno della forma



Chain code: specifica la direzione del contorno ad ogni punto di edge

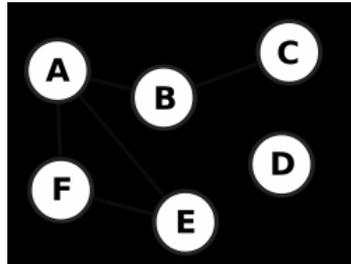
le direzioni sono quantizzate in 4/8 valori

Rappresentazione: coordinate del punto iniziale e una sequenza di chain code che segue il contorno.

22

Tipi di pattern: i grafi

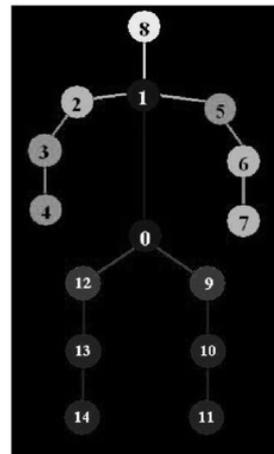
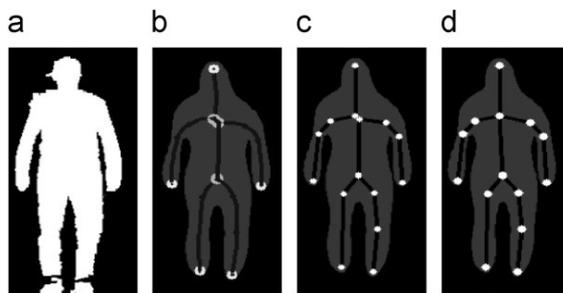
- ⇒ I grafi (e gli alberi) rappresentano un insieme di nodi collegati da archi (vedi il corso di Algoritmi)
- ⇒ Codificano la relazione tra parti
 - ⇒ esempio: vicinanza, connettività, etc



25

Tipi di pattern: i grafi

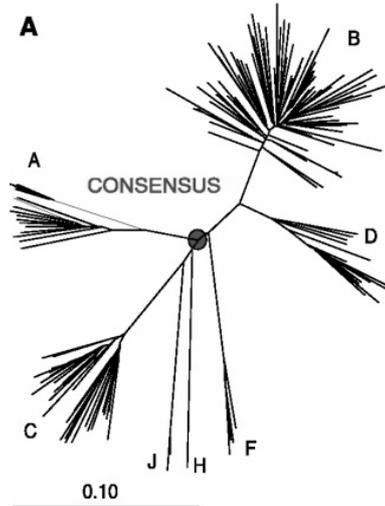
- ⇒ Esempio 1: modellare le diverse parti di un corpo umano



26

Tipi di pattern: i grafi

- ⇒ ESEMPIO 2: alberi filogenetici (sono un tipo particolare di grafo):
 - ⇒ si può cercare di trovare l'albero "consenso" tra un insieme elevato di alberi
 - ⇒ ognuno è un pattern si cerca il modello migliore



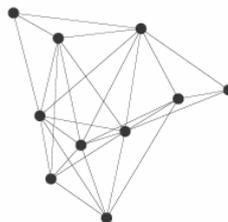
27

Tipi di pattern: i grafi

- ⇒ Esempio 3: Protein-Protein Interaction Networks
- ⇒ Grafi dove vengono visualizzate le interazioni tra le proteine
 - ⇒ fondamentali in biologia

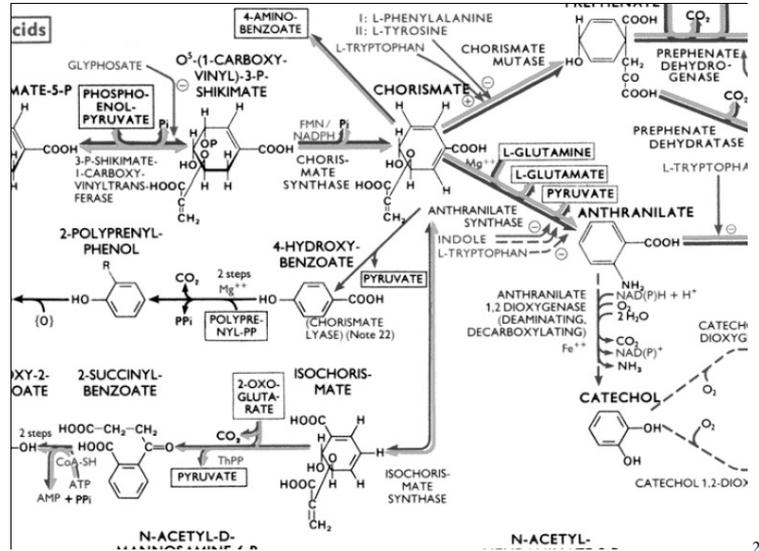
- list of N proteins (nodes)
- list of protein pairs (edges)

This is an **undirected, unweighted graph**



28

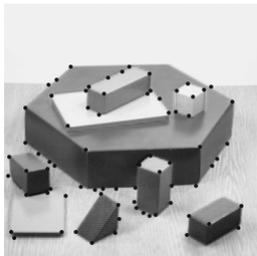
⇒ Esempio 4: percorsi metabolici: insieme di reazioni di composti chimici per svolgere un processo cellulare



Tipi di pattern: gli insiemi

⇒ insiemi: collezione non ordinata di dati a cardinalità variabile
 ⇒ insieme di descrittori tutti relativi alla stessa entità, ma non ordinati

⇒ Esempio 1: angoli in un'immagine

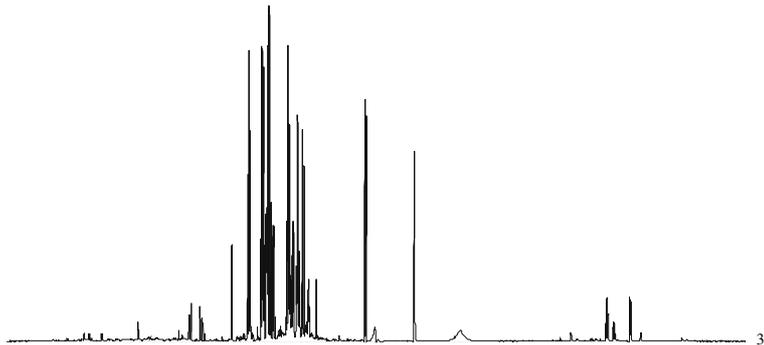


non c'è un ordine
 in ogni immagine ce
 ne può essere un
 numero variabile

Tipi di pattern: gli insiemi

⇒ Esempio 2: picchi in uno spettro NMR:

- ⇒ numero di picchi può essere diverso in due diversi spettri
- ⇒ i picchi non sono ordinati (si possono forse ordinare per ampiezza, o per ppm, ma in generale questo non è possibile)



Altri tipi di pattern

Transactions

- ⇒ Dato un insieme di oggetti, una transaction è un sottoinsieme di questi oggetti
- ⇒ Esempio 1: market basket analysis
 - ⇒ analisi dei prodotti acquistati da un consumatore
 - ⇒ dati N prodotti disponibili
 - ⇒ solo M ($M < N$) vengono acquistati
- ⇒ Esempio 2: dato l'insieme di geni, caratterizziamo quelli espressi ("attivati") in una determinata condizione (attenzione, livello di espressione)
- ⇒ tipicamente rappresentati da un vettore binario lungo N
 - ⇒ 0 indica l'assenza dell'oggetto
 - ⇒ 1 indica la presenza di un oggetto

32

Problema

- ⇒ Molte delle tecniche di Pattern Recognition Statistica funzionano nel caso di spazi vettoriali
- ⇒ In caso di dati non vettoriali la maggior parte delle assunzioni non vale
- ⇒ Soluzioni:
 - ⇒ creazione di metodi di classificazione/clustering che lavorano con questi tipi di dato
 - ⇒ definizione di misure di similarità che riescano a tenere in considerazione la struttura del pattern
 - ⇒ incapsulamento (embedding) in uno spazio vettoriale

33

Dettagli

- ⇒ Metodi di classificazione/clustering capaci di lavorare con questi tipi di dato
 - ⇒ metodi che non assumono uno spazio vettoriale
 - ⇒ definizione di misure di similarità che riescano a tenere in considerazione la struttura non vettoriale del pattern
 - ⇒ Esempio: distanza dynamic time warping per riconoscimento del parlato
- ⇒ incapsulamento (embedding) in uno spazio vettoriale:
 - ⇒ L'idea è quella di riportare il problema in uno spazio vettoriale

34

Dettagli

Primo metodo: estrazione di un insieme predeterminato di features dall'oggetto non vettoriale

ESEMPIO

⇒ Sequenza nucleotidica

⇒ Metodo di estrazione di features: si conta la frequenza di A, T, C, G

```
atgcatcgatcgatcgatcgatcagggcgctacg
agcggcgaggacctcatcatcgatcag
```



[14,10,17,18]

Adesso ogni sequenza è un punto in uno spazio 4-dimensionale

Vantaggi: spazio vettoriale, facile

Svantaggi: che feature occorre estrarre? Quanta informazione si perde?

Dettagli

Secondo metodo: incapsulamento in uno spazio dove vengono preservate le caratteristiche geometriche degli oggetti

ESEMPIO: Multidimensional Scaling

⇒ si calcolano le distanze tra gli oggetti non vettoriali

⇒ si "creano" dei punti in uno spazio vettoriale in modo che sia preservata la distanza

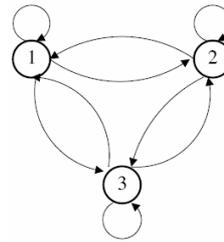
⇒ (si vedrà meglio in seguito)

Dettagli

Terzo metodo: embedding generativo

- ⇒ Si assume un modello statistico per il dato non vettoriale
- ⇒ Si calcolano i parametri del modello
- ⇒ Si estraggono delle features legate al modello statistico

ESEMPIO: Hidden Markov Models



- ⇒ features = Probabilità media di essere nello stato Si osservando la sequenza

37

Fase 4: preprocessing

Preprocessing

- ⇒ Concetto di scala
- ⇒ Data standardization
- ⇒ Data transformation
 - ⇒ Riduzione della dimensionalità
- ⇒ Riduzione del rumore

(ci concentriamo sul caso generico di spazi vettoriali)

38

Scala

⇒ Definizione di scala: significatività relativa dei numeri

ESEMPIO: si considerino due numeri 10, 12

⇒ sono molto simili in una scala [0-100]

⇒ molto diversi in una scala [10-13]

⇒ Riconoscere la scala di un problema è fondamentale:

⇒ nel calcolare la relazione tra due pattern

⇒ nell'interpretare i risultati (in particolare del clustering)

39

Scala

Tipi di scala:

⇒ qualitativa: le misure non hanno significato

⇒ nominal scale

⇒ ordinal scale

⇒ quantitativa: le misure hanno significato

⇒ interval scale

⇒ ratio scale

40

Scala

⇒ Nominal scale:

- ⇒ non è una scala vera e propria, perché i numeri sono utilizzati come nomi
- ⇒ Esempio: (sì/no) può essere codificata come (1,0), (0,1) o (50,100).
- ⇒ I numeri da soli non hanno nessun significato quantitativo

⇒ Ordinal scale:

- ⇒ scala numerica più povera
- ⇒ i numeri hanno un senso solo in relazione agli altri
- ⇒ Esempio: (1,2,3), (10,20,30), (1,20,300) sono equivalenti da un punto di vista ordinale
- ⇒ Esempio: lista di accesso all'università (non è importante il valore assoluto della prova d'ingresso ma il valore relativo – essere nei primi 100)

41

Scala

⇒ Interval scale:

- ⇒ la separazione tra i numeri ha un senso.
- ⇒ Esiste un'unità di misura e l'interpretazione dei numeri dipende da questa unità di misura
- ⇒ Esempio: voto di un compito
 - ⇒ 9 è un buon voto se la scala è [0-10]
 - ⇒ è un pessimo voto se la scala è [0-30]
- ⇒ Esempio 2:
 - ⇒ temperatura a 90° è diversa a seconda che la scala sia Celsius o Fahrenheit

42

Scala

- ⇒ Ratio scale: i numeri hanno un valore assoluto.
 - ⇒ Esistono uno zero assoluto e un'unità di misura, ma il rapporto tra due numeri ha sempre lo stesso significato.
- ⇒ ESEMPIO: la distanza tra due città
 - ⇒ può essere misurata in metri, centimetri o chilometri
 - ⇒ se raddoppio la distanza raddoppio anche il tempo che ci metto ad andare da una città all'altra (indipendentemente dall'unità di misura)

43

Problema

- ⇒ Problema: a volte le variabili che descrivono un oggetto non sono nella stessa scala
- ⇒ Ci sono metodi che soffrono se le features sono a scala diversa
- ⇒ Alla lavagna: esempio: calcolo della distanza euclidea tra due punti
- ⇒ Soluzioni:
 - ⇒ data standardization
 - ⇒ data transformation

44

Data standardization

- ⇒ La standardizzazione dei dati produce dati "senza dimensionalità"
 - ⇒ tutta la conoscenza su scala e locazione dei dati viene persa dopo la standardizzazione
 - ⇒ creazione di nuovi dati "in formato standard" – confrontabili
- ⇒ E' necessario standardizzare i dati!
 - ⇒ esempio distanza euclidea visto in precedenza
- ⇒ Approcci di standardizzazione:
 - ⇒ approcci globali standardizzano l'intero data set
 - ⇒ approcci intra-gruppo standardizzano ogni gruppo
 - ⇒ problema nel caso del clustering: i cluster non sono noti
 - ⇒ possibile soluzione: standardizzazione iterativa (prima si calcolano i cluster, poi si standardizza, poi si ricalcolano i cluster e così via)

45

Approcci di data standardization

- ⇒ NOTA: la scelta dell'approccio da utilizzare dipende dal data set e dal campo di applicazione
- ⇒ Alla lavagna:
 - ⇒ notazione
 - ⇒ formulazione generale
 - ⇒ esempi di standardizzazione
 - ⇒ intuizioni sugli effetti

46

Data transformation

- ⇒ In qualche modo legato alla standardizzazione dei dati
 - ⇒ serve per migliorare la rappresentazione
- ⇒ Data standardization: le operazioni sono implementate dimensione per dimensione
- ⇒ Data transformation: le operazioni agiscono su tutte le dimensioni contemporaneamente (tipicamente in modo lineare)

47

Data transformation

In genere effettuata con i seguenti obiettivi:

1. ridurre la dimensionalità dello spazio delle features
 - ⇒ per visualizzare il dataset
 - ⇒ per ridurre il carico computazionale delle tecniche applicate
 - ⇒ per alleviare il problema della "curse of dimensionality"
 - ⇒ per eliminare la ridondanza di alcune direzioni del dataset
2. mettere in evidenza particolari strutture o migliorare le capacità discriminative dello spazio

48

Data transformation

⇒ Approccio classico: trasformazione lineare dello spazio delle features

$$Y = A'X$$

⇒ SCOPO: ridurre la dimensionalità dello spazio mantenendo la maggior quantità di informazione possibile

⇒ "Informazione": concetto che assume significati diversi a seconda della tecnologia utilizzata

49

Diversi approcci

⇒ Approcci non supervisionati:

⇒ si utilizzano solo i dati

⇒ Esempio: Principal Component Analysis

⇒ Approcci supervisionati:

⇒ si utilizzano altre informazioni (ad esempio le etichette)

⇒ Esempio: trasformata di Fisher

⇒ La seconda classe di approcci si può utilizzare solo in caso di problema supervisionato (classificazione)

⇒ L'idea è che lo spazio viene "ridotto" tenendo conto del task finale di classificazione

50

Principal Component Analysis

- ⇒ Approccio lineare non supervisionato alla riduzione della dimensionalità
- ⇒ Obiettivo: mantenere la maggior aderenza ai dati originali
 - ⇒ Minimizza lo scarto quadratico medio tra i dati originali e quelli ricostruiti
 - ⇒ estrae le direzioni di massima varianza dei dati
- ⇒ IDEA:
 - ⇒ trasformazione lineare delle variabili principali che proietta i dati in uno spazio così costruito:
 - ⇒ la prima direzione è quella di massima varianza
 - ⇒ la seconda direzione viene scelta tra le rimanenti, in modo che sia ortogonale alla prima, e di massima varianza
 - ⇒ si continua così fino alla fine

51

Principal Component Analysis

- ⇒ come si realizza (alla lavagna)

52

Principal Component Analysis

⇒ Vantaggi:

- ⇒ migliore tecnica lineare di compressione dei dati
 - ⇒ migliore in senso di "errore quadratico medio"
- ⇒ i parametri del modello possono essere ricavati direttamente dai dati
- ⇒ compressione e decompressione sono operazioni molto veloci (moltiplicazione di matrici)

⇒ Svantaggi:

- ⇒ alto costo computazionale per il calcolo dei parametri del modello (soprattutto in caso di dimensionalità elevata)
- ⇒ non è chiaro come questa tecnica possa gestire il caso di dati incompleti
- ⇒ PCA non tiene conto della densità di probabilità dello spazio considerato (viene considerata solo la vicinanza del vettore trasformato al vettore originale)
- ⇒ non è detto in tutti i casi che le direzioni a varianza maggiore siano le direzioni ottimali

53

Principal Component Analysis

⇒ Problema: come calcolare il numero di componenti principali ottimali?

⇒ Soluzione 1. scegliere il numero di componenti che arrivano a coprire una certa percentuale di varianza (esempio 95%)

⇒ Come si misura? concetto di "importanza" di una componente principale

$$\text{imp}(i) = \frac{\lambda_i}{\sum_{i=1}^d \lambda_i} \quad \text{varianza}(1, \dots, L) = \sum_{i=1}^L \text{imp}(i) = \frac{\sum_{i=1}^L \lambda_i}{\sum_{i=1}^d \lambda_i}$$

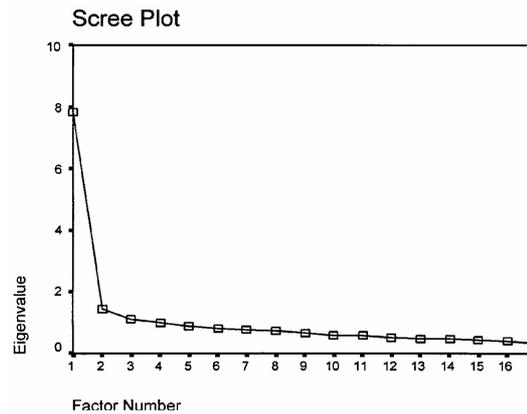
54

Principal Component Analysis

⇒ Soluzione 2: Cattell Scree test

⇒ plottare gli autovalori

⇒ trovare dove la decrescita degli autovalori non è più così marcata



55

Altri metodi

⇒ Independent Component Analysis (ICA):

⇒ Un metodo computazionale per distinguere le diverse componenti additive di un segnale

⇒ si assume l'indipendenza statistica tra le varie componenti

$$x_i = a_{i,1}s_1 + a_{i,2}s_2 + \dots + a_{i,m}s_m \quad x = As$$

⇒ ESEMPIO: Source separation

⇒ Problema in signal processing: vengono mescolati assieme diversi segnali, l'obiettivo è quello di identificare i segnali originali

⇒ Esempio classico: "**cocktail party problem**": un numero di persone stanno parlando simultaneamente in una stanza e una persona cerca di seguire una sola delle conversazioni

56

Altri metodi

- ⇒ Il problema viene risolto cercando di massimizzare l'indipendenza statistica tra le componenti stimate.
- ⇒ Dipendentemente dalla scelta del concetto di "indipendenza statistica" abbiamo versioni differenti
 - ⇒ Esempio: mutua informazione
- ⇒ Modelli di ICA
 - ⇒ ICA lineare senza rumore $x = As$
 - ⇒ ICA lineare con rumore $x = As + \eta$
 - ⇒ ICA non lineare $x = f(s | \theta) + \eta$

57

Metodi supervisionati

- ⇒ IDEA: utilizzo l'informazione del task finale
 - ⇒ non sempre l'informazione "classicamente" estratta corrisponde alla migliore informazione per risolvere il problema
 - ⇒ ESEMPIO: PCA vs Fisher
- ⇒ Linear Discriminant Analysis (Fisher)
 - ⇒ tecnica classica di riduzione della dimensionalità che mira a massimizzare la separabilità tra le classi nello spazio risultante
 - ⇒ spesso utilizzata anche come classificatore lineare (dettagli in seguito)
 - ⇒ anche chiamata:
 - ⇒ Discriminant Analysis
 - ⇒ Fisher Linear Analysis

58

Linear Discriminant Analysis

⇒ come si realizza (alla lavagna)

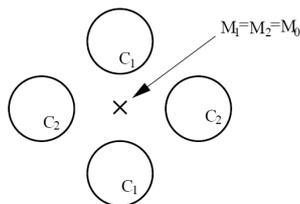
59

Linear Discriminant Analysis

⇒ Vantaggi: massimizza la separabilità tra le classi

⇒ Svantaggi:

- ⇒ Principale: dato un problema a C classi, la massima dimensionalità dello spazio risultante è $c-1$
 - ⇒ se abbiamo un problema binario allora possiamo proiettare i dati in uno spazio monodimensionale (molto restrittivo!)
- ⇒ Secondario: il criterio di Fisher non funziona se le classi sono multimodali e condividono la stessa media



60

Feature Selection

- ⇒ Approccio alternativo alla riduzione della dimensionalità
 - ⇒ rid. dimensionalità: considera tutte le feature e le trasforma
 - ⇒ feature selection: sceglie solo alcune feature (in base ad un criterio di ottimalità)
 - ⇒ Vantaggio: spesso alcune features sono irrilevanti / dannose
 - ⇒ Svantaggio: computazionalmente oneroso

- ⇒ Problemi da risolvere
 - ⇒ scegliere il criterio di ottimalità: informazione (come si misura?), varianza, capacità di classificazione (solo per problemi supervisionati)
 - ⇒ come trovare il sottoinsieme ottimale senza provarli tutti (troppo oneroso computazionalmente)

- ⇒ Esempio: Sequential Forward Feature Selection

61

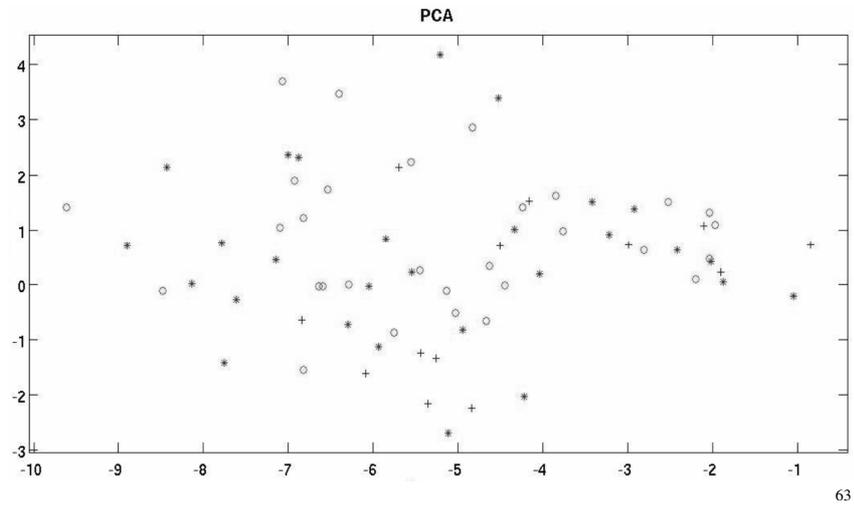
Feature Selection

- ⇒ Forward Sequential Feature Selection
 - ⇒ Algoritmo greedy per trovare l'insieme ottimale di features
- ⇒ Schema:
 - ⇒ si valuta il criterio per tutte le features singolarmente
 - ⇒ si sceglie la feature che massimizza il criterio (chiamata f_1)
 - ⇒ si valuta il criterio per tutte le coppie (f_1, f_x) – cioè tenendo fissata f_1
 - ⇒ si sceglie la coppia che massimizza il criterio (la coppia (f_1, f_2))
 - ⇒ si valuta il criterio per tutte le terne (f_1, f_2, f_x) – cioè tenendo fissate f_1 e f_2
 - ⇒ ...
- ⇒ Algoritmo greedy – ad ogni istante la scelta migliore
 - ⇒ computazionalmente efficiente
 - ⇒ sub ottimale

62

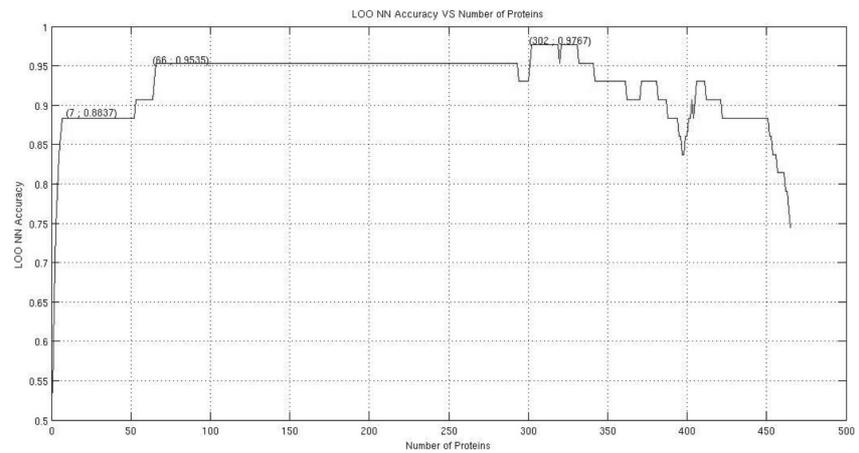
Esempio: neuropatologie

⇒ Usando tutte le features e applicando la PCA



Esempio: neuropatologie

⇒ feature selection



Visualizzazione dei dati

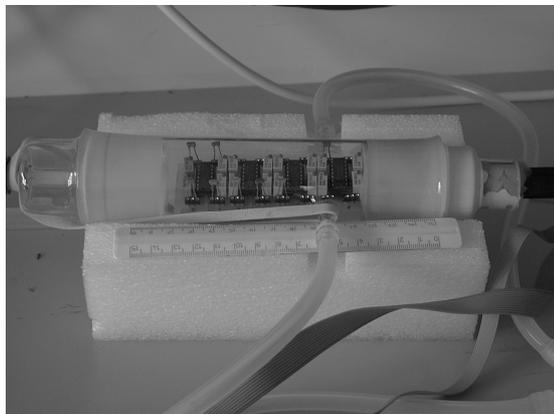
- ⇒ Studio di metodologie per visualizzare dati/informazioni in modo grafico
- ⇒ Fondamentale per:
 - ⇒ validazione/interpretazione dei risultati
- ⇒ Il nostro punto di vista:
 - ⇒ rappresentare dati in uno spazio vettoriale a dimensione 2/3 per poter vedere la relazione tra i dati
- ⇒ Approccio classico: ridurre la dimensionalità con le tecniche viste precedentemente, tipo PCA

65

Esempio

Riconoscimento di odori

- ⇒ Array di sensori chimici, ognuno sensibile a composti diversi



66

Esempio

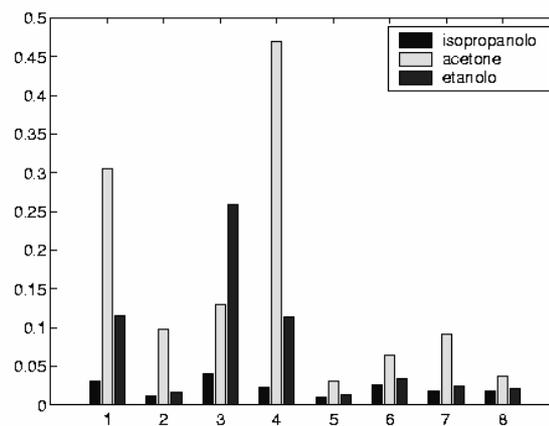
⇒ Dato un composto da analizzare, viene fatto passare sopra il "naso elettronico"



67

Esempio

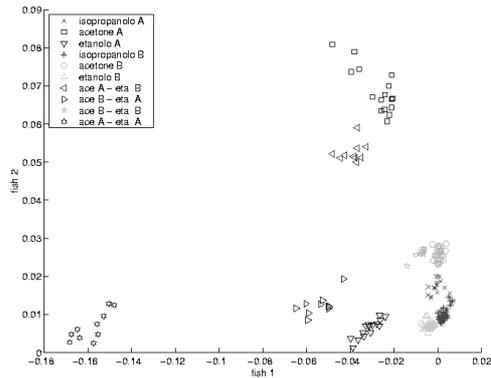
⇒ Il risultato è un punto in uno spazio 8-dimensionale



68

Esempio

⇒ Per visualizzare tutti gli esperimenti: PCA + plot



69

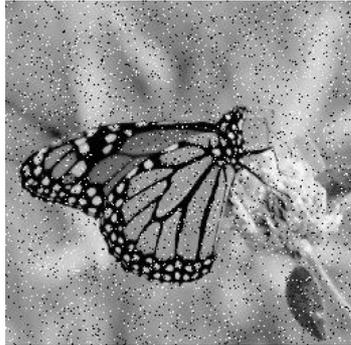
Multi dimensional Scaling (MDS)

- ⇒ insieme di tecniche statistiche utilizzate per esplorare similarità e dissimilarità nei dati
- ⇒ Il punto di partenza è una matrice di prossimità
 - ⇒ Rappresentazione proximity-based vs. rappresentazione feature-based
- ⇒ Idea: proiettare questi dati in uno spazio vettoriale dove le distanze vengono preservate
- ⇒ ESEMPIO: Sammon's mapping (alla lavagna)

70

Riduzione del rumore

- ⇒ Rumore: informazione irrilevante (o dannosa) nei dati
- ⇒ Per rimuovere il rumore vengono utilizzate tecniche di filtraggio (molto utilizzate in signal/image processing)



rumore sale e pepe

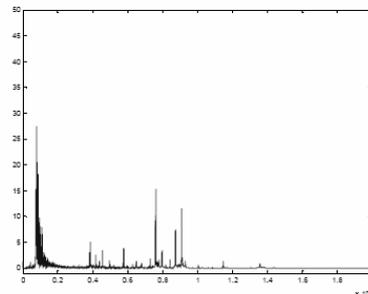
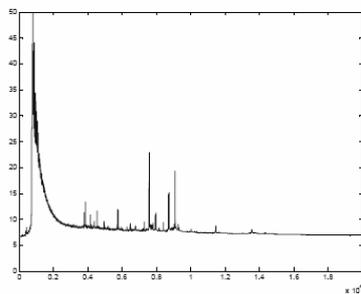


immagine "ripulita"

71

Riduzione del rumore

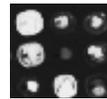
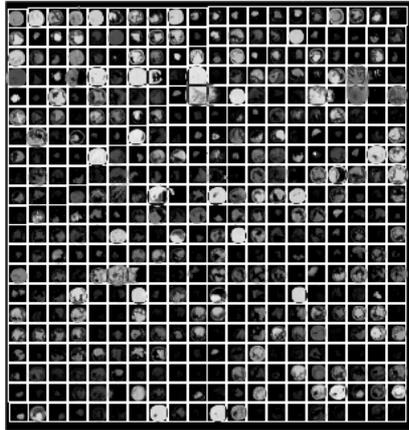
- ⇒ Mass spectrometry: esiste un bias di intensità sistematico per il quale il profilo osservato differisce da zero



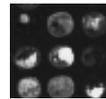
72

Riduzione del rumore

⇒ Microarray: errori nelle immagini degli spot



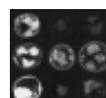
dimensione



rotondità



intensità



distribuzione
dei pixel

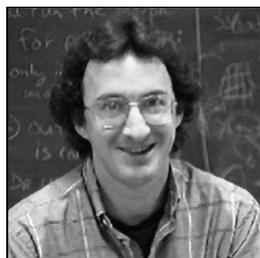
73

Riduzione del rumore

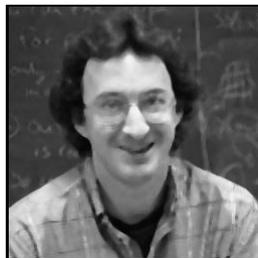
⇒ NOTA: E' necessario eliminare il rumore preservando l'informazione



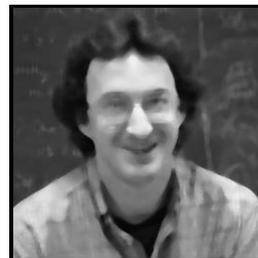
immagine
originale



filtro mediano 3x3



filtro mediano 5x5



filtro mediano 7x7

74