

Riconoscimento e recupero dell'informazione per bioinformatica

Rappresentazione dei dati

Manuele Bicego

Corso di Laurea in Bioinformatica

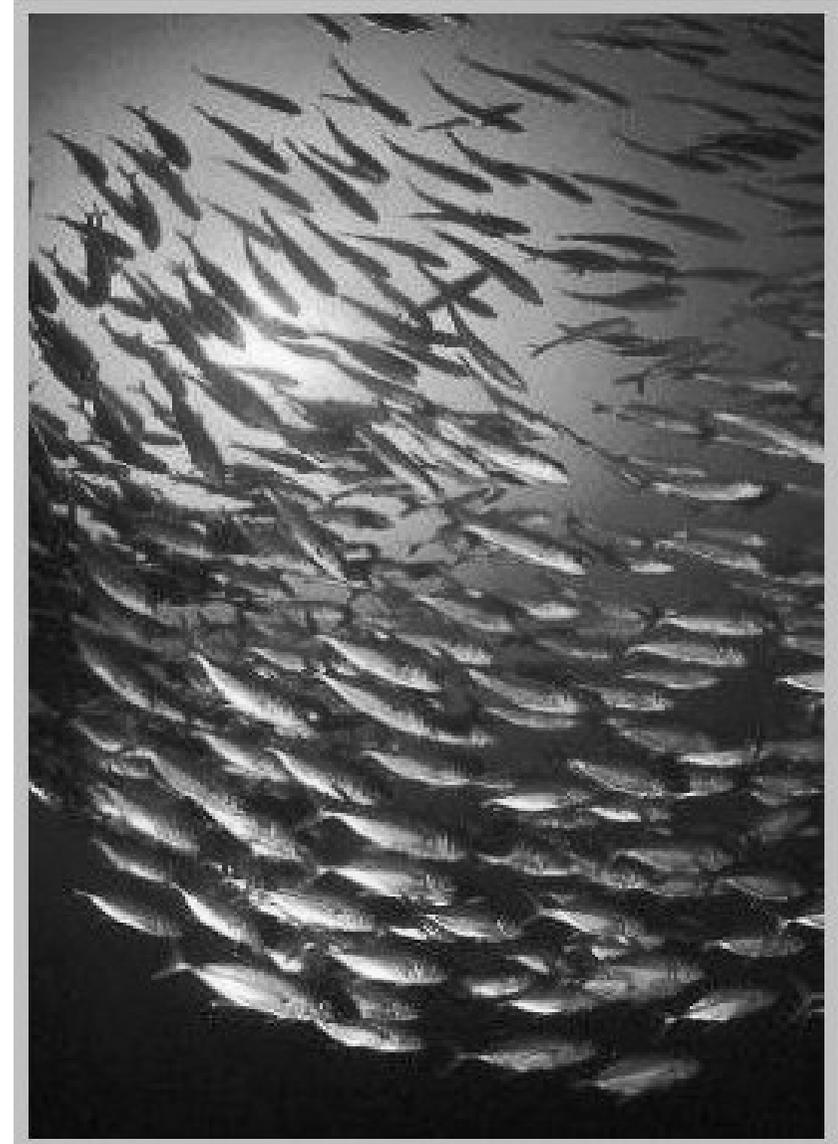
Dipartimento di Informatica - Università di Verona

Sommario

- ⇒ Rappresentazione dei dati:
 - ⇒ campionamento
 - ⇒ Rappresentazione:
 - ⇒ Estrazione delle features
 - ⇒ Costruzione del pattern
- ⇒ preprocessing (scaling, riduzione del rumore, riduzione della dimensionalità)

La rappresentazione dei dati

- ⇒ Rappresentazione dei dati: il problema di come rappresentare gli oggetti del problema in esame
 - ⇒ Rappresentazione che un calcolatore possa capire
 - ⇒ Rappresentazione utilizzata per costruire il modello, per fare il testing
 - ⇒ Scelta cruciale



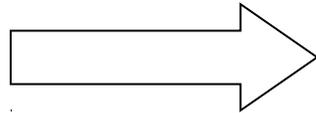
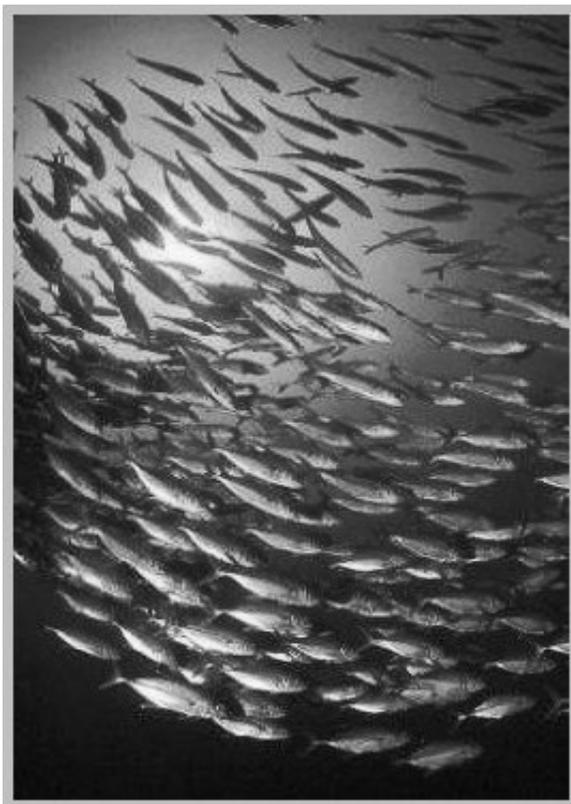
La rappresentazione dei dati

1. Campionamento (acquisizione dati)
2. Rappresentazione: estrazione delle features e costruzione del pattern
3. Preprocessing: scaling, riduzione del rumore, riduzione della dimensionalità

Fase 1: campionamento

Rappresenta la raccolta dati vera e propria: effettuare delle misure sugli oggetti del problema

Esempio 1: modellare pesci



campionamento



immagine (dato grezzo)

Fase 1: campionamento

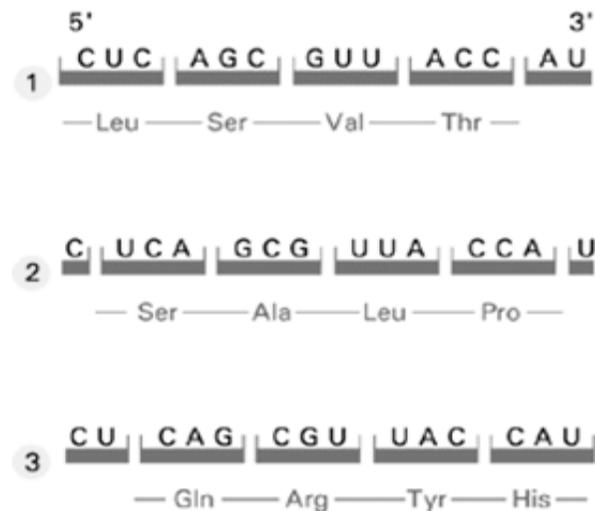
⇒ Esempio 2: filogenesi di microrganismi

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

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

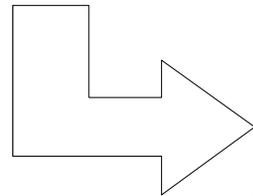
⇒ estrarre il DNA e amplificare quello dei geni prescelti per la filogenesi (scelta dei primer, scelta dei parametri della PCR)

⇒ Sequenziare

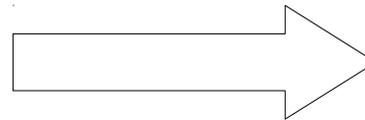


Fase 1: campionamento

⇒ Esempio 3: riconoscimento di volti



campionamento



Fase 1: campionamento

SCELTA CRUCIALE: il tipo di sensore da utilizzare

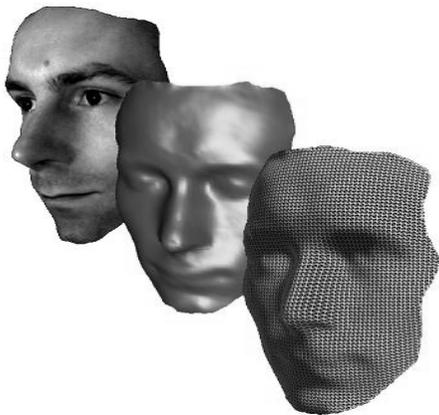
⇒ Esempio: riconoscimento di volti



telecamera tradizionale:

PRO: alta risoluzione

CON: sensibile ai cambi di illuminazione



Sensore 3D:

PRO: risolve il problema della liveness

CON: computazionalmente oneroso



telecamera a infrarosso:

PRO: funziona anche al buio

CON: risoluzione bassa

CON: Info interessante?

Fase 1: campionamento

Problemi da tenere in considerazione:

⇒ frequenza di campionamento: capacità di modellare evoluzione temporale

⇒ risoluzione (dipende dal sensore): quanti dettagli si riescono a recuperare

⇒ capacità di gestire cambiamenti di condizioni al contorno (eg. cambi di illuminazione)

il campionamento dipende strettamente dal problema (e tipicamente è deciso dall'esperto)

La rappresentazione dei dati

1. Campionamento (acquisizione dati)
2. Rappresentazione: estrazione delle features e costruzione del pattern
3. Preprocessing: scaling, riduzione del rumore, riduzione della dimensionalità

Fase 2: Rappresentazione

- ⇒ Problema vero e proprio: rappresentare gli oggetti del problema in esame a partire dalle misurazioni fatte durante il campionamento
- ⇒ Scelta semplice: si utilizzano direttamente i dati derivanti dal campionamento (dati grezzi)
 - ⇒ Problema: presenza di informazione irrilevante



SFONDO

Fase 2: Rappresentazione

- ⇒ Soluzione: si elaborano i dati provenienti dal campionamento: si aggregano misure, si estraggono nuovi dati, si scartano le informazioni irrilevanti, etc etc
- ⇒ Due fasi:
 - ⇒ Estrazione di features (caratteristiche)
 - ⇒ Costruzione del pattern (insieme di features): aggregazione delle features

Esempio:

⇒ Opzione 1:



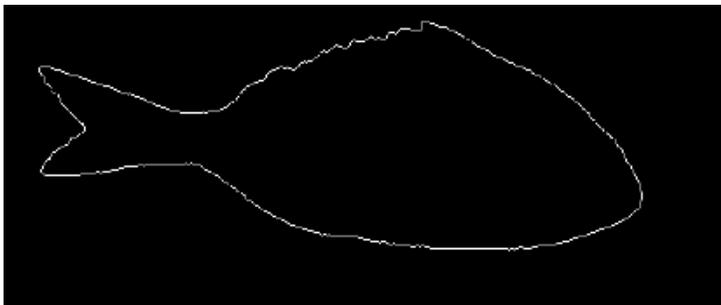
Features

Altezza e
larghezza

Pattern:

vettore di due
dimensioni [a,l]

⇒ Opzione 2:



Features

Coordinate del
contorno
dell'oggetto, a
partire dalla
coda

Pattern:

sequenza di
vettori di due
dimensioni (le
coordinate di
ogni punto del
contorno)

x1,y1
x2,y2
x3,y3
...
xn,yn

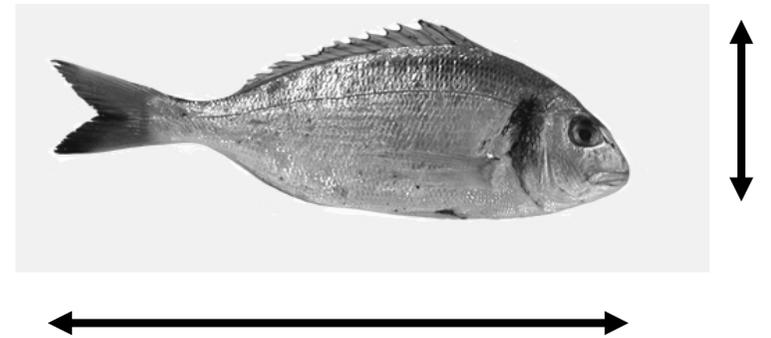
Opzione 1

Vantaggi:

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

Svantaggi

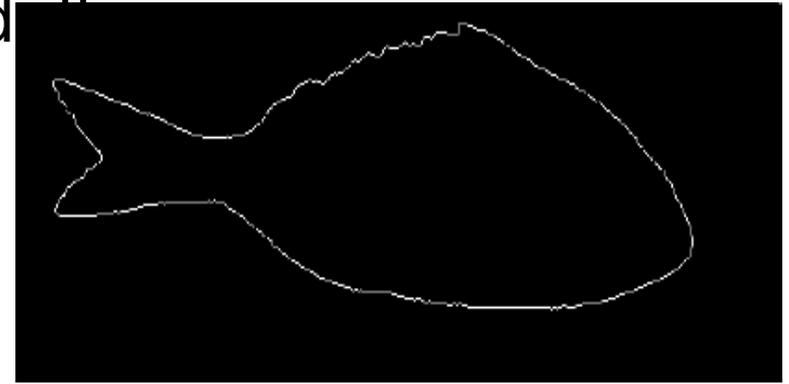
- ⇒ troppo semplificata: non riesce a modellare la forma del pesce, il colore



Opzione 2

Vantaggi

- ⇒ rappresentazione più ricca: modella la forma del pesce



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. Non modella il colore

Estrazione delle features

Feature: caratteristica del problema in esame

⇒ rilevante

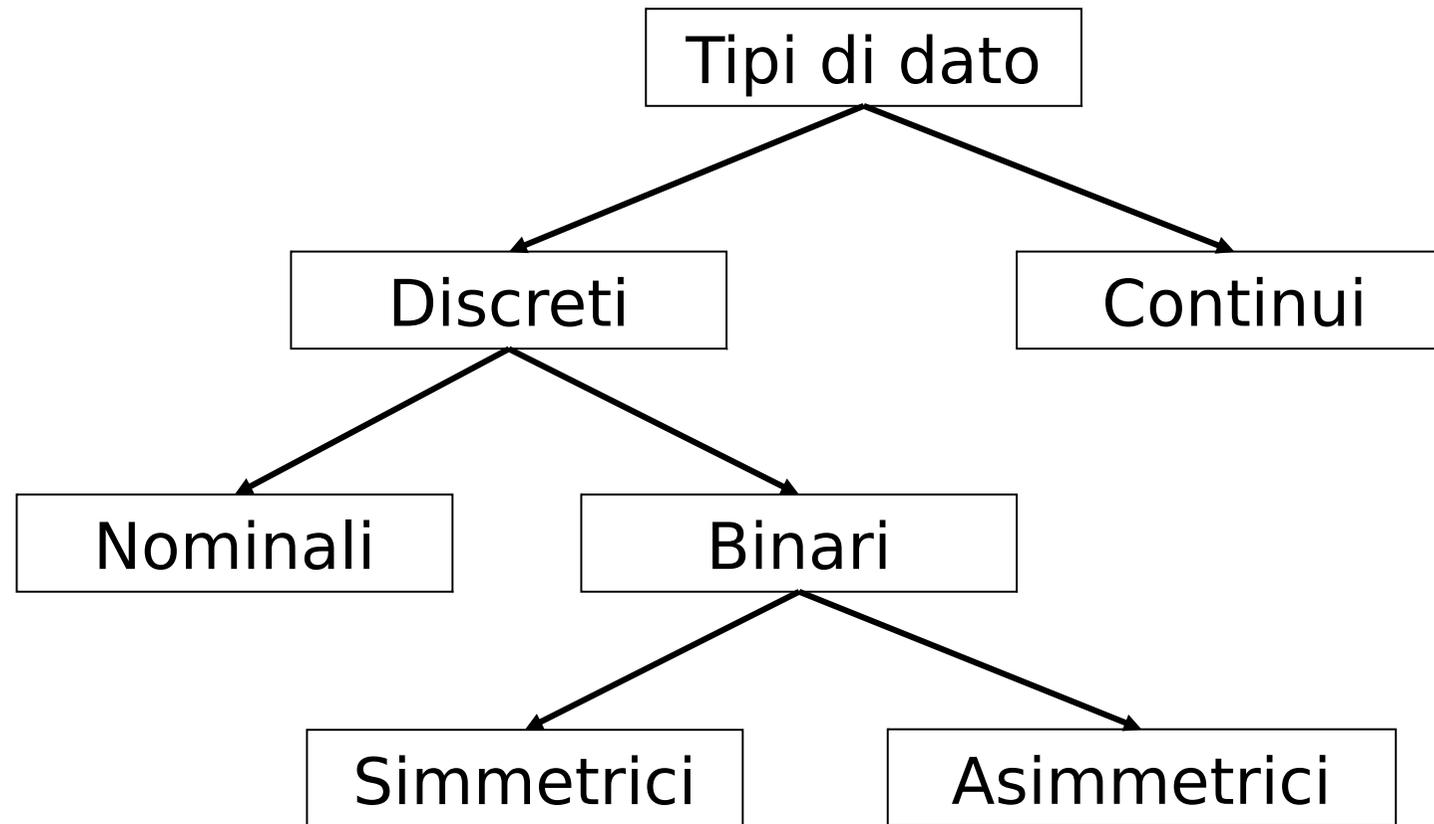
⇒ discriminante

⇒ quantificabile a partire dai dati grezzi

⇒ (interpretabile)

La scelta di queste features è chiaramente
cruciale

Tipologie di features: tipi di dato



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

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 (ad esempio una malattia)

⇒ no: assenza

Costruzione del pattern

Pattern: insieme di features/misure relative allo stesso oggetto

Problema della costruzione del pattern: “Come mettere assieme le varie *features*”

⇒ Un vettore, una sequenza, un grafo....

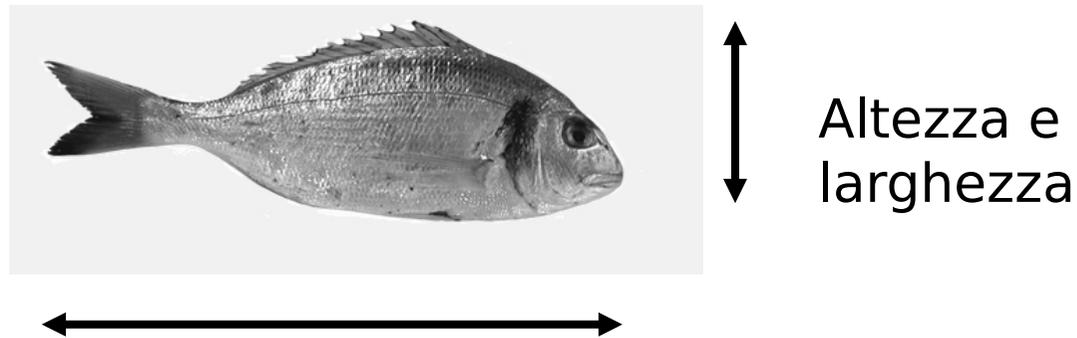
... vediamo i vari tipi di pattern

Tipi di pattern: i vettori

Dati vettoriali (formato più diffuso)

⇒ per ogni oggetto si ha un insieme prefissato di features, messe in ordine in un vettore

⇒ Esempio:

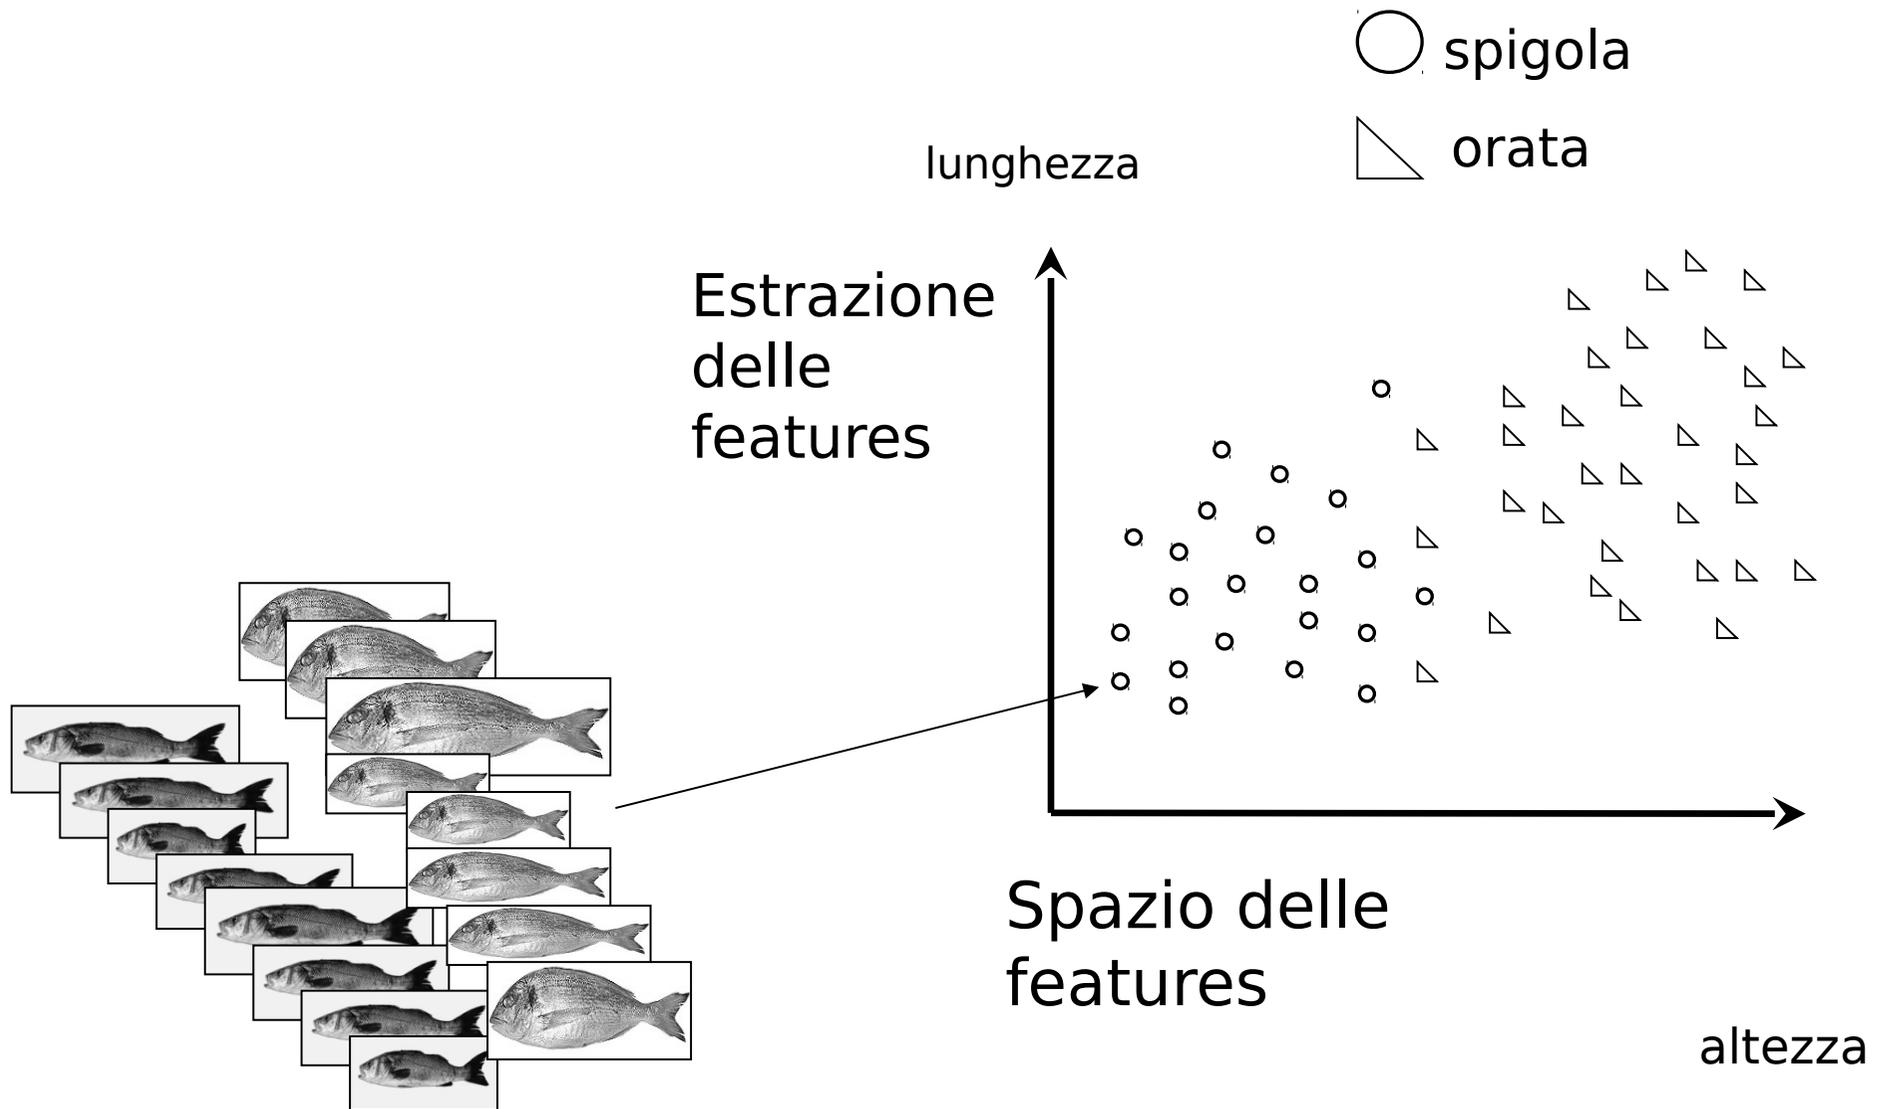


⇒ il vettore è ordinato

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

⇒ "d" è il numero delle features

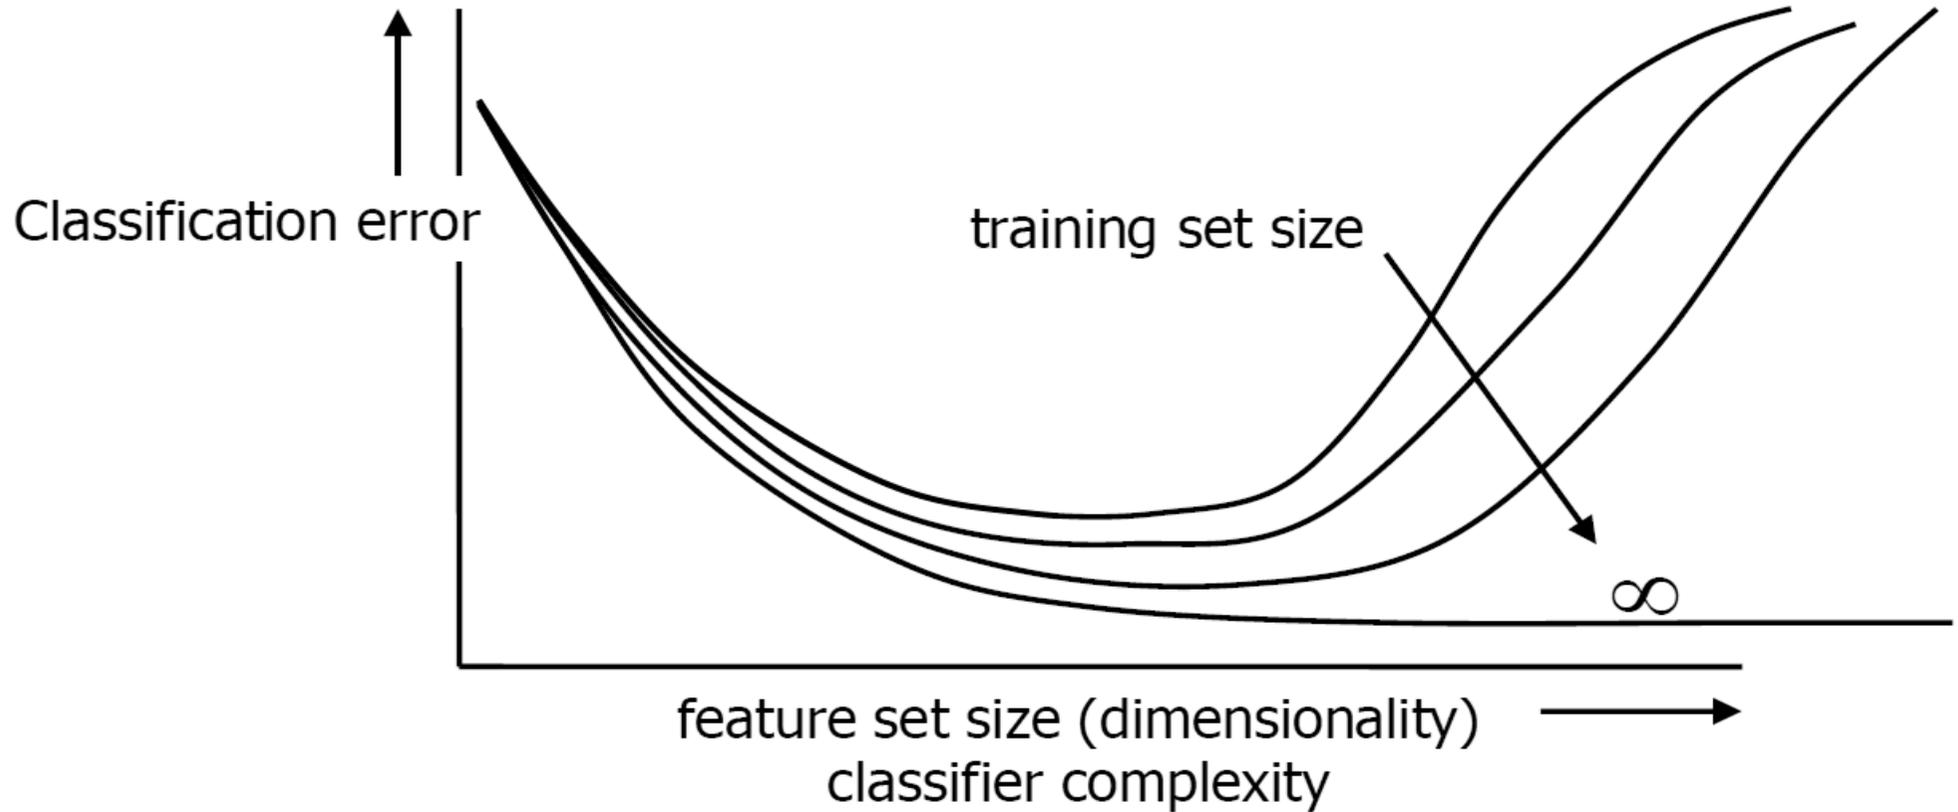
Tipi di pattern: i vettori



Commenti su spazi vettoriali

- ⇒ La scelta delle features è cruciale
- ⇒ Utilizzando molte features gli spazi diventano estremamente grandi
 - ⇒ problema di visualizzare i dati
 - ⇒ problema della curse of dimensionality
- ⇒ Curse of dimensionality: insieme di problemi che possono nascere se lo spazio ha una dimensionalità troppo elevata rispetto al numero di oggetti o se il modello è troppo complesso
 - ⇒ Esempio: 5 punti, 100 features
 - ⇒ Esempio: 5 punti, polinomio di grado 10

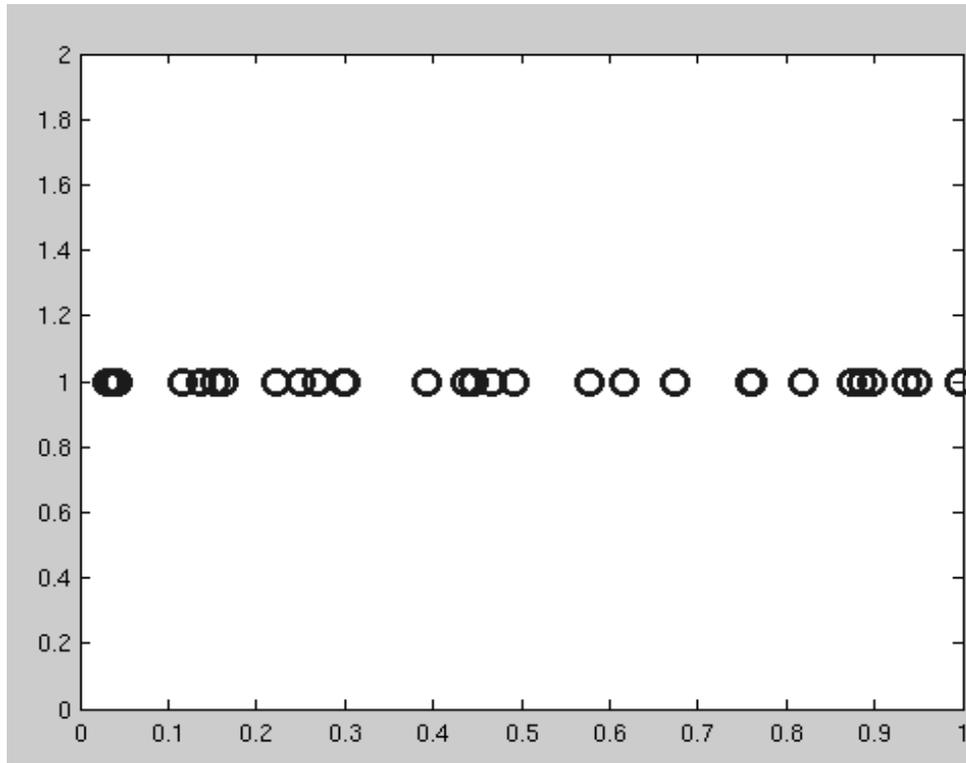
Curse of dimensionality: aumentando troppo il numero delle features l'errore di classificazione cresce



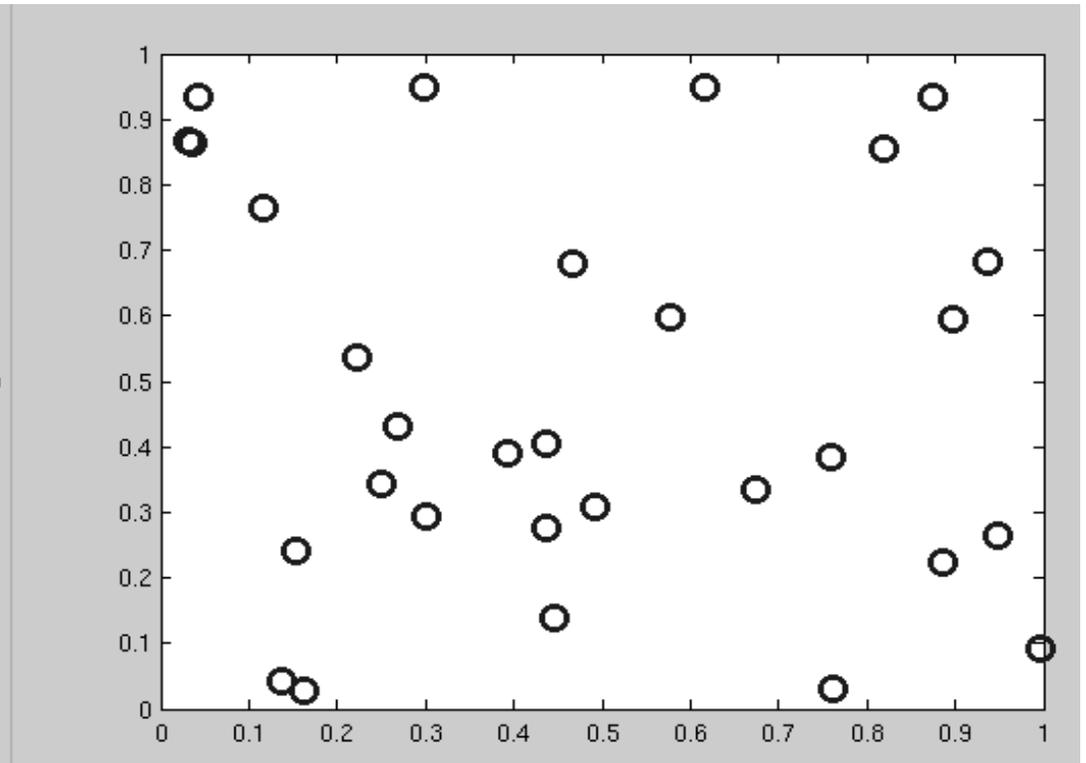
Peaking Phenomenon, Overtraining, Curse of Dimensionality, Rao's Paradox

Curse of dimensionality

- ⇒ Problema 1: molte features, lo spazio diventa vuoto
 - ⇒ Poco espressivo, poco denso, facile costruire classificatori che non generalizzano bene



30 punti in uno spazio 1D:
molte sovrapposizioni



30 punti in uno spazio 2D:
pochissime sovrapposizioni

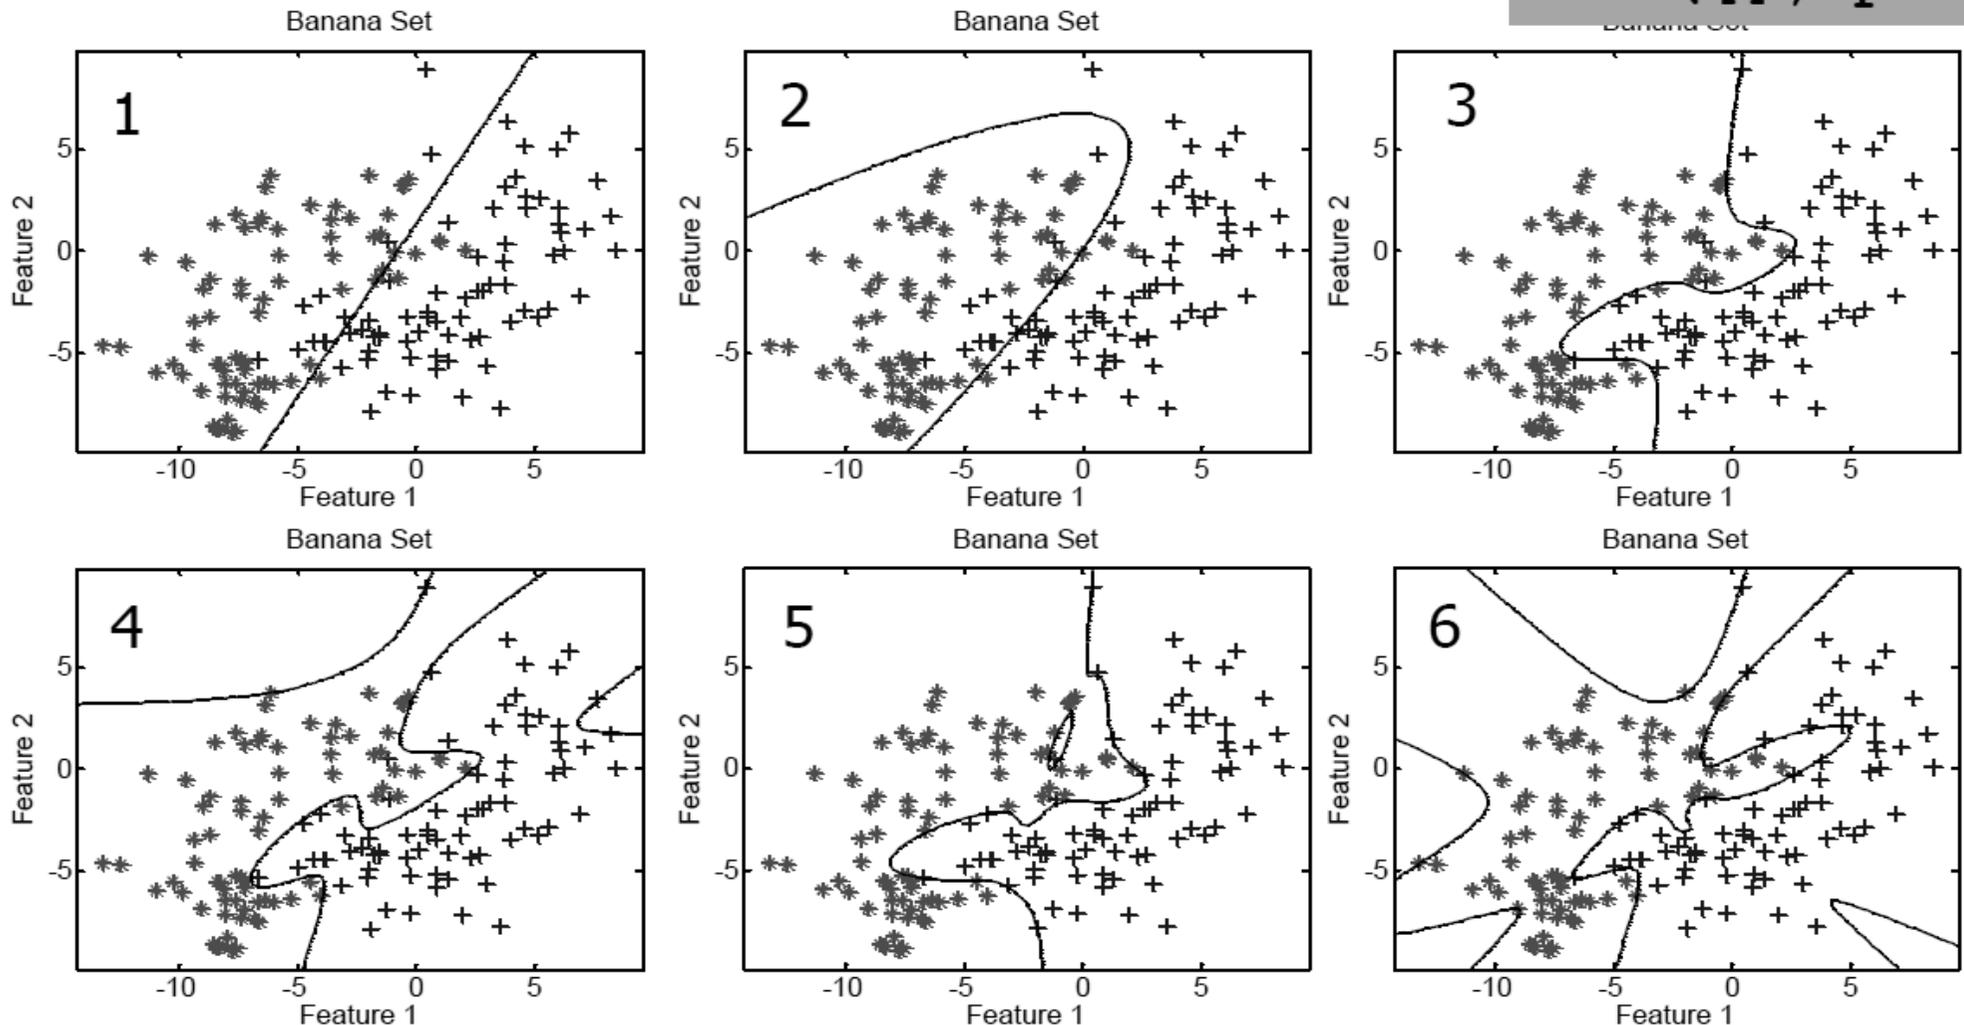
Curse of dimensionality

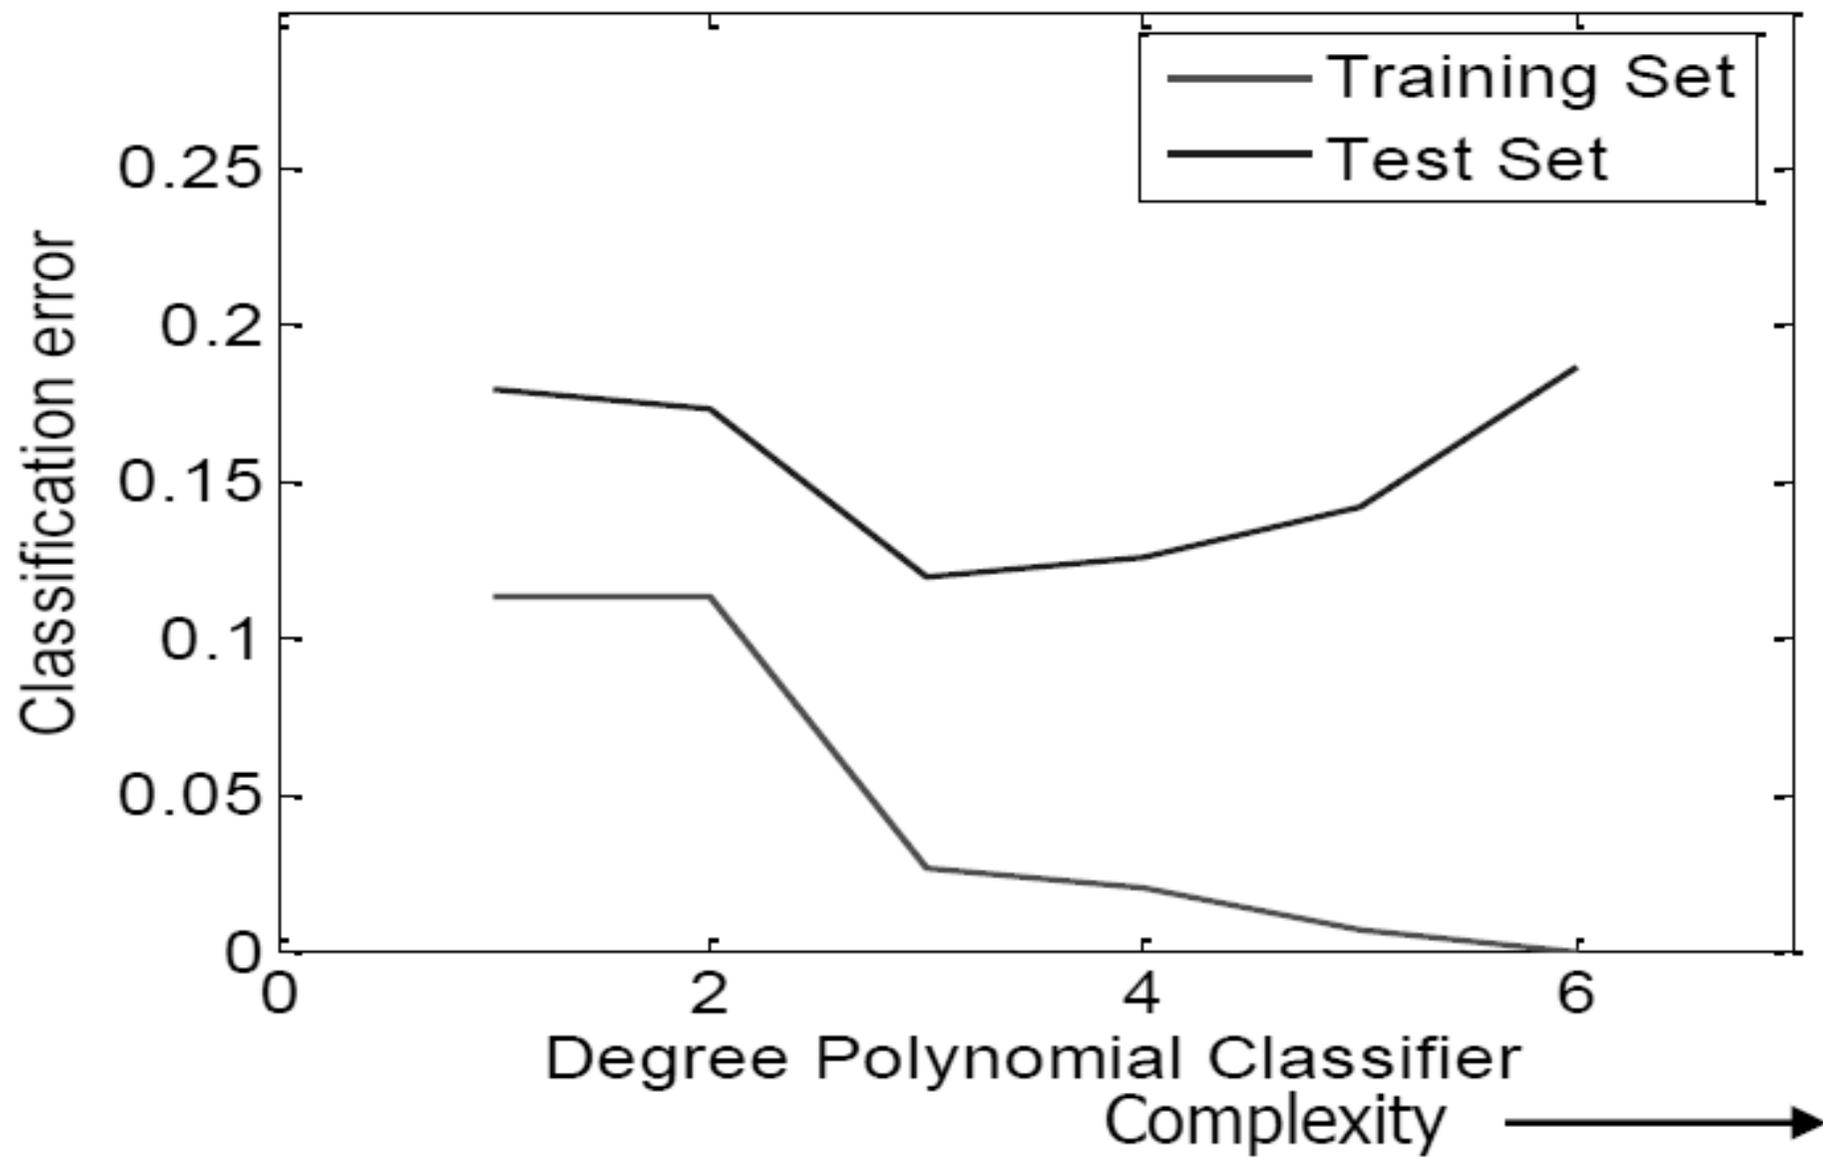
- ⇒ Secondo problema: tipicamente è più difficile stimare i parametri
 - ⇒ Meno “dati” per parametro
 - ⇒ Esempio: una media in uno spazio bidimensionale è fatta di due valori, in uno spazio 10D di 10 valori, tutti da stimare a partire dallo stesso numero di oggetti

- ⇒ Esistono metodi che riducono la dimensionalità di questi spazi (vedremo in seguito)

Curse of dimensionality

⇒ Stesso fenomeno se si aumenta troppo la complessità di un classificatore





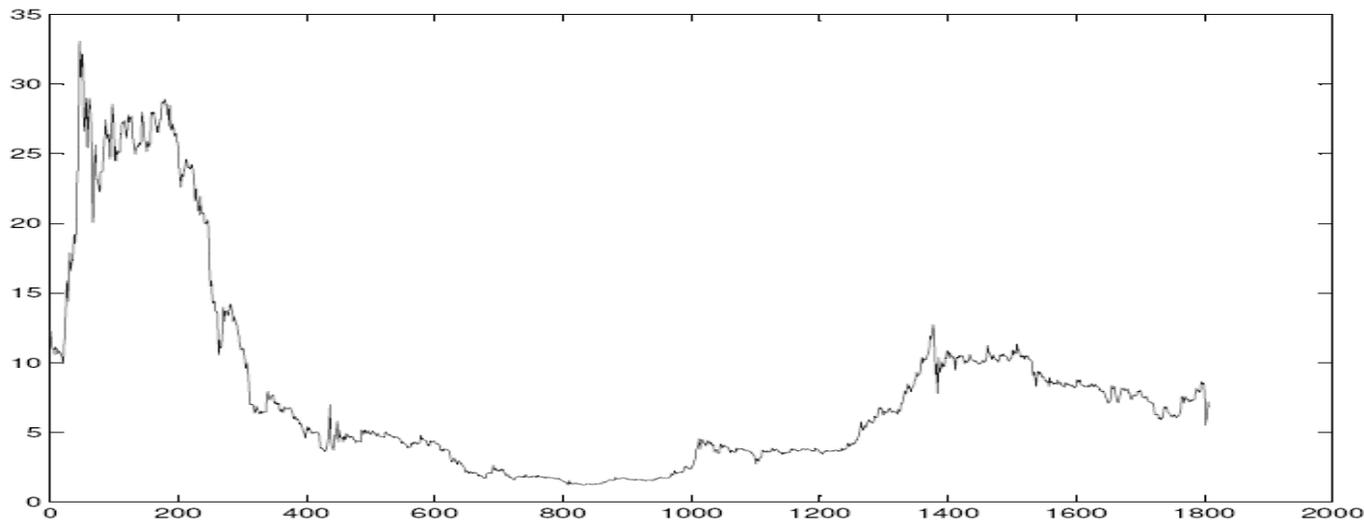
Tipi di pattern: le sequenze

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

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

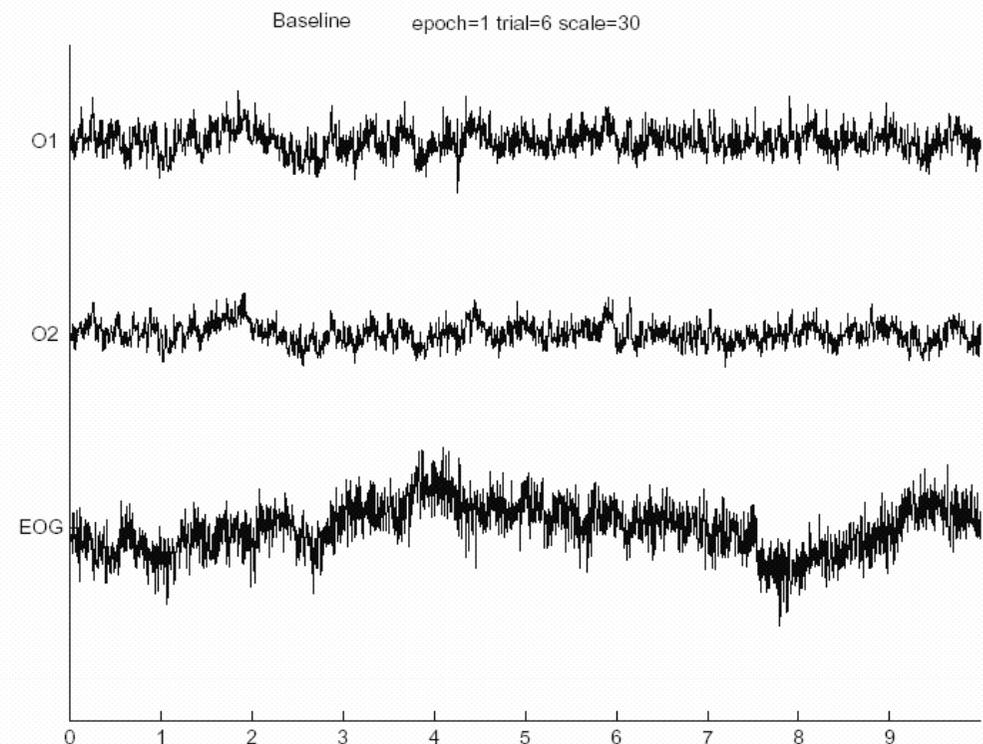
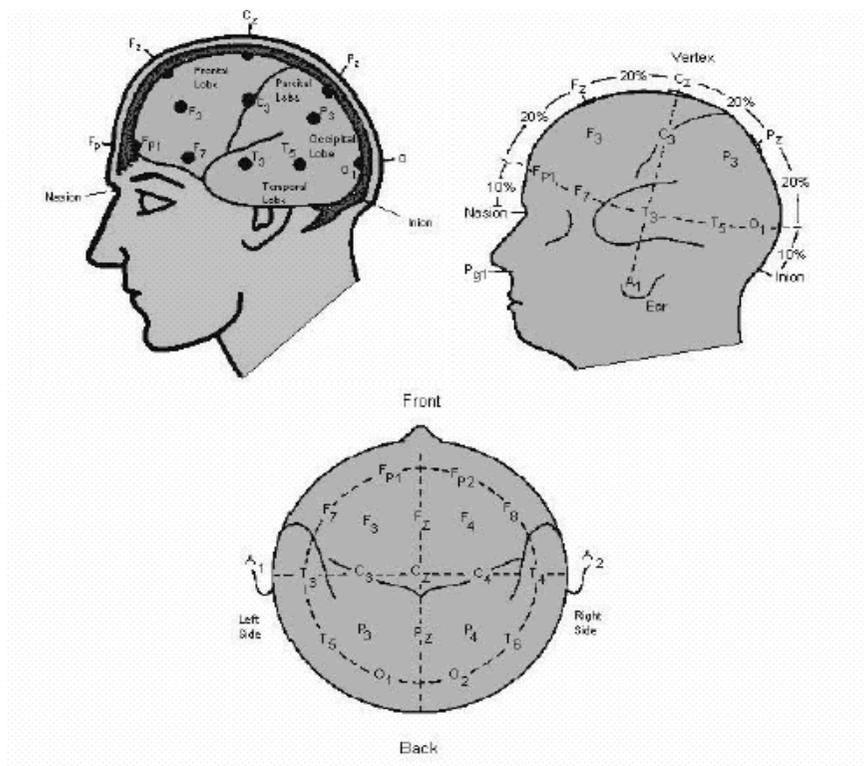
⇒ Sequenze temporali:

⇒ sequenza di features che rappresentano la misurazione di un fenomeno a intervalli di tempo regolari



Esempio 1: indici di mercato (DowJones)

Tipi di pattern: le sequenze



⇒ Esempio 2: segnali elettro encefalografici (EEG)

Tipi di pattern: le sequenze



Tracking: “inseguire” le persone

Tipi di pattern: le sequenze

⇒ Sequenze non temporali:

⇒ sequenze dove l'ordine non è dato dal tempo

⇒ Esempio 1:

⇒ sequenze nucleotidiche

```
atgcgatcgatcgatcgatcagggcgcgctacgagcggcgaggacct  
catcatcgatcag
```

⇒ sequenze aminoacidiche

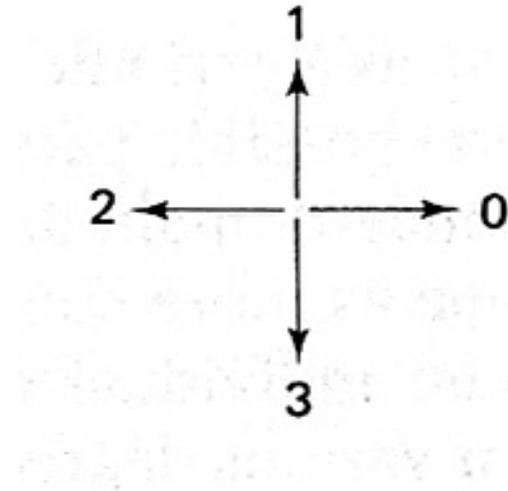
```
MRPQAPGSLVDPNEDEL RMAPWYWG RISR EEA KSI L HGK PDGS FLVR DAL SMKGEYTL TLMKDGCEK  
LIKICHMDRKYGFIETDLFNSV VEMINYYKENSLSMYNKTLDITLSNPIVRAREDEESQPHGDLCLL  
SNEFIRTCQLLQNLEQNL ENKRNSFN AIREELQEKKLHQSVFGNTEKIFRNQIKL NESFMKAPADA...
```

...

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.

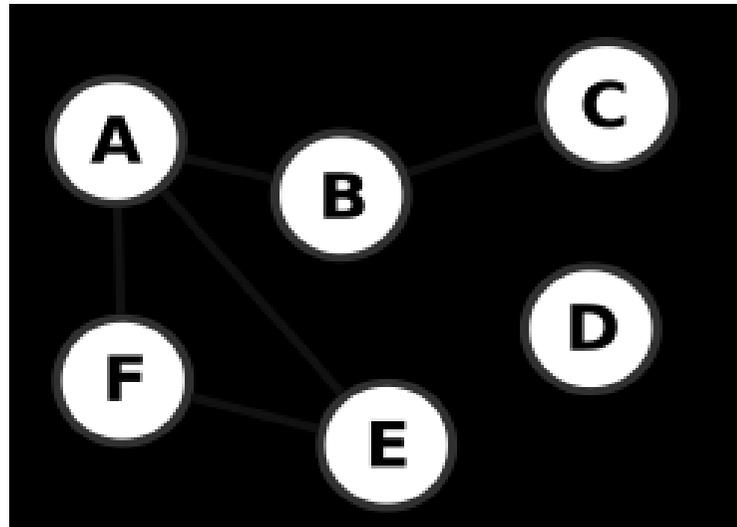
Tipi di pattern: le sequenze

Riassumendo le caratteristiche delle sequenze:

- ⇒ esiste un concetto di “sequenzialità” dei dati
- ⇒ l’ordine è importante
 - ⇒ “xyyyx” non è la stessa cosa di “yyyxx”
- ⇒ la lunghezza di due sequenze diverse potrebbe essere diversa
 - ⇒ e.g. lunghezza contorno di un oggetto
 - ⇒ e.g. lunghezza gene
- ⇒ Sequenze di lunghezza diversa non possono essere rappresentate in uno spazio vettoriale (gli spazi necessari sarebbero di dimensione diversa)

Tipi di pattern: i grafi

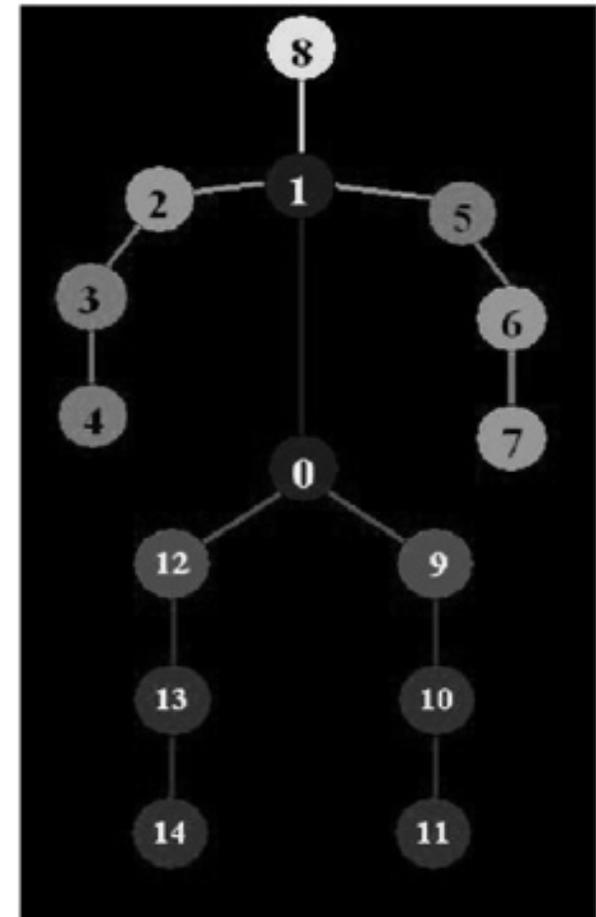
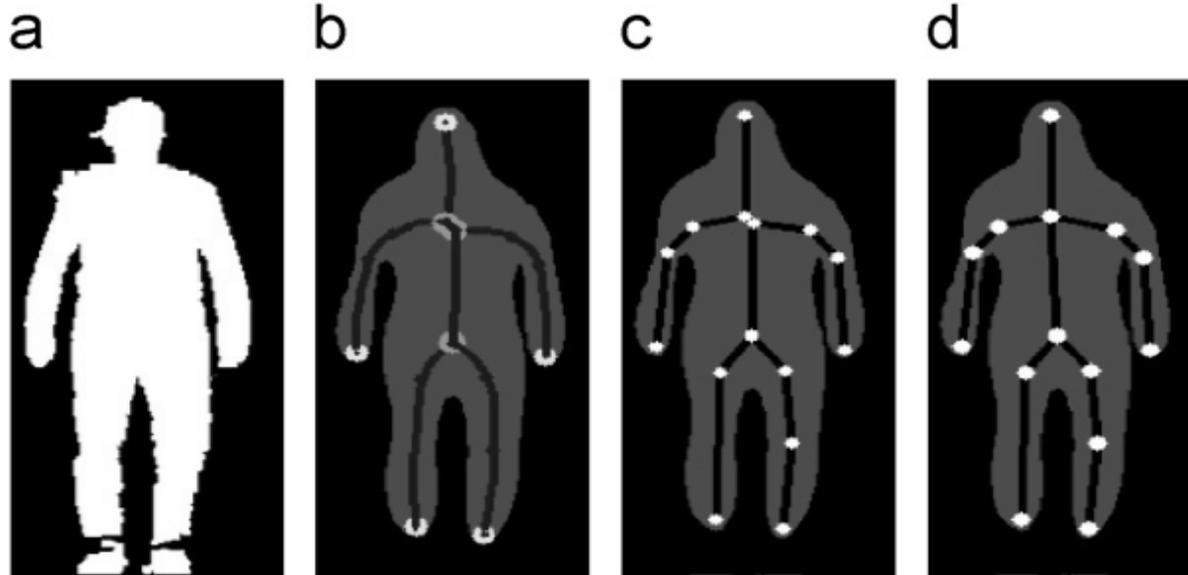
- ⇒ I grafi (e gli alberi) rappresentano un insieme di nodi collegati da archi (vedi il corso di Algoritmi)
- ⇒ Codificano la relazione tra parti
 - ⇒ esempio: vicinanza, connettività, etc



Maggiori dettagli nella parte del corso con la Prof.ssa
Giugno

Tipi di pattern: i grafi

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

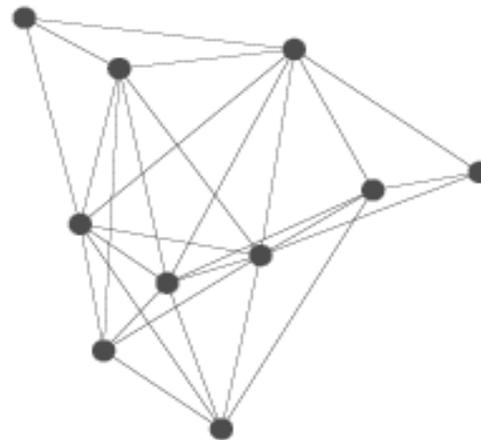


Tipi di pattern: i grafi

- ⇒ Esempio 2: Protein-Protein Interaction Networks
- ⇒ Grafi dove vengono visualizzate le interazioni tra le proteine
 - ⇒ fondamentali in biologia

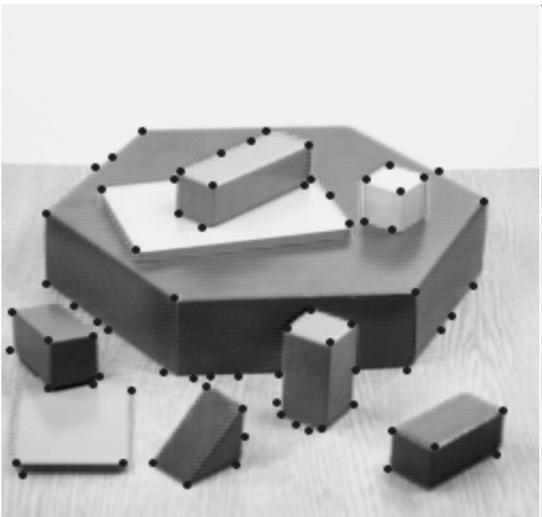
- list of N proteins (nodes)
- list of protein pairs (edges)

This is an undirected, unweighted graph



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

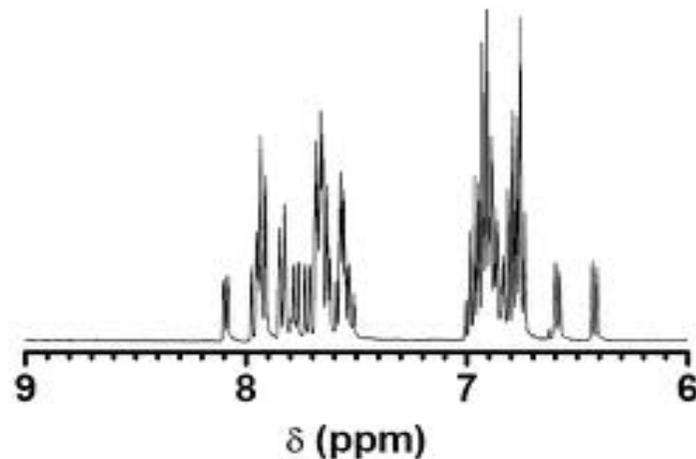


non c'è un ordine
in ogni immagine
ce ne può essere un
numero variabile

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)



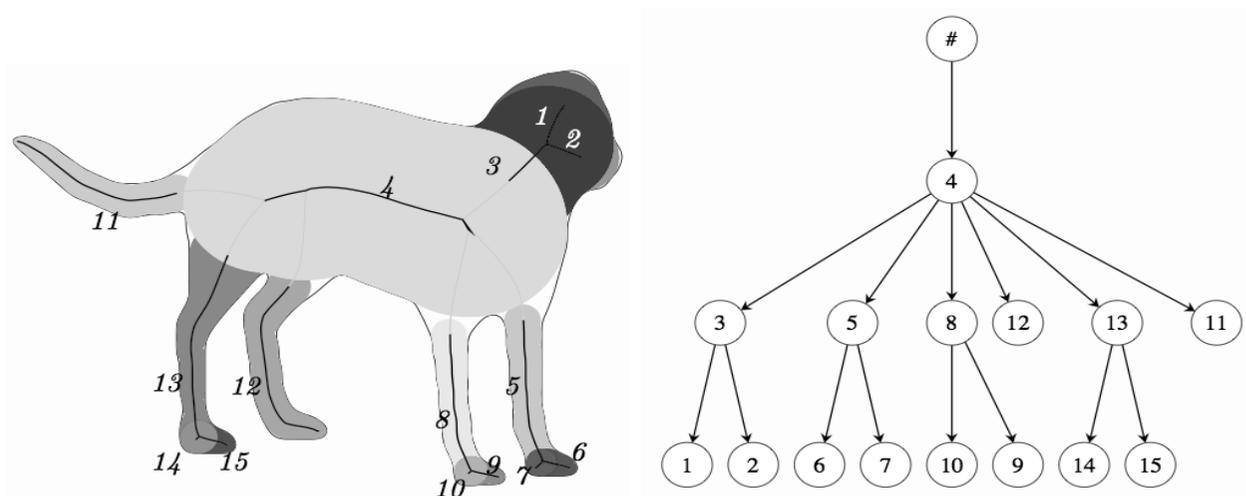
Altri tipi di pattern

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

Summary: vettori vs altri tipi di pattern

⇒ Tipicamente pattern complessi (sequenze, grafi, ...) sono più “espressivi” dei vettori



⇒ MA: molte delle tecniche di Pattern Recognition Statistica funzionano solo nel caso di spazi vettoriali (si pensi ai classificatori che usano la media!)

⇒ In caso di dati non vettoriali la maggior parte delle assunzioni non vale

Summary: vettori vs altri tipi di pattern

Soluzioni possibili:

- ⇒ creazione/utilizzo di metodi di classificazione o di clustering che lavorano con questi tipi di dato
 - ⇒ Esempio: definizione di misure di similarità che riescano a tenere in considerazione la struttura del pattern
- ⇒ incapsulamento (embedding) in uno spazio vettoriale

Dettagli

- ⇒ SOLUZIONE 1: creazione/utilizzo di metodi di classificazione/clustering capaci di lavorare con questi tipi di dato
 - ⇒ metodi che non necessitano di uno spazio vettoriale
 - ⇒ Esempio 1: Hidden Markov Models per sequenze
 - ⇒ Esempio 2: metodi che basano il loro funzionamento sulla definizione di misure di distanza
 - ⇒ il problema viene risolto con la definizione di misure di similarità che riescano a tenere in considerazione la struttura non vettoriale del pattern (e.g. distanza dynamic time warping per riconoscimento del parlato)
- ⇒ si vedrà meglio in seguito!

Dettagli

- ⇒ SOLUZIONE 2: incapsulamento (embedding) in uno spazio vettoriale:
 - ⇒ L'idea è quella di riportare il problema in uno spazio vettoriale

- ⇒ Vediamo due possibili classi di approcci:
 1. estrazione di features da dati non vettoriali
 2. incapsulamento (embedding) tramite misure di similarità

Dettagli

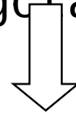
Approccio 1: estrazione di un insieme predeterminato di features dall'oggetto non vettoriale

ESEMPIO

⇒ Sequenza nucleotidica

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

atgcgatcgatcgatcgatcaggcgcgc+acgagcggcgaggacctcatcatcgatcag



[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

Approccio 2: incapsulamento in uno spazio dove vengono preservate le caratteristiche di similarità tra gli 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

Multi dimensional Scaling (MDS)

- ⇒ insieme di tecniche statistiche tipicamente utilizzate per visualizzare dati in uno spazio bi- o tri-dimensionale
- ⇒ Il punto di partenza è una matrice di similarità (o dissimilarità/distanza) tra tutte le possibili coppie di pattern

$$\mathbf{D}_1 = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \end{matrix} & \begin{pmatrix} 0.0 & & & & \\ 2.0 & 0.0 & & & \\ 6.0 & 5.0 & 0.0 & & \\ 10.0 & 9.0 & 4.0 & 0.0 & \\ 9.0 & 8.0 & 5.0 & 3.0 & 0.0 \end{pmatrix} \end{matrix}$$

Multi dimensional Scaling (MDS)

- ⇒ Dato un'insieme di oggetti $x_1..x_N$, abbiamo a disposizione la matrice delle distanze $D = [d_{i,s}]$
 - ⇒ $d_{i,s}$ = distanza tra x_i e x_s
- ⇒ GOAL: creare un insieme $\mathbf{Y} = [y_1..y_N]$ in uno spazio a 2 o 3 dimensioni tale che le distanze $d_{i,s}^{new}$ e $d_{i,s}$ siano il più simili possibili ($d_{i,s}^{new}$ = distanza tra y_i e y_s)
- ⇒ Si definisce la funzione errore (errore di rappresentazione) in questo modo

$$E_{SAM} = \frac{1}{C} \sum_{i,s} \frac{(d_{i,s} - d_{i,s}^{new})^2}{d_{i,s}}$$

Multi dimensional Scaling (MDS)

⇒ Algoritmo: (discesa lungo il gradiente per trovare gli y_i che minimizzano E_{SAM})

PASSO 0: inizializzazione casuale di $\mathbf{Y} = [y^0_1 \dots y^0_N]$

Ripetere fino a convergenza

PASSO 1: calcolare l'errore $E_{SAM}^{(t)}$ al tempo t

PASSO 2: Aggiornare i vettori $\mathbf{Y} = [y_1 \dots y_N]$ secondo la formula

$$y_{ij}^{t+1} = y_{ij}^t - \eta \Delta_{ij}^t$$

$$\Delta_{ij}^t \propto \frac{\partial E_{SAM}^t}{\partial y_{ij}^t}$$

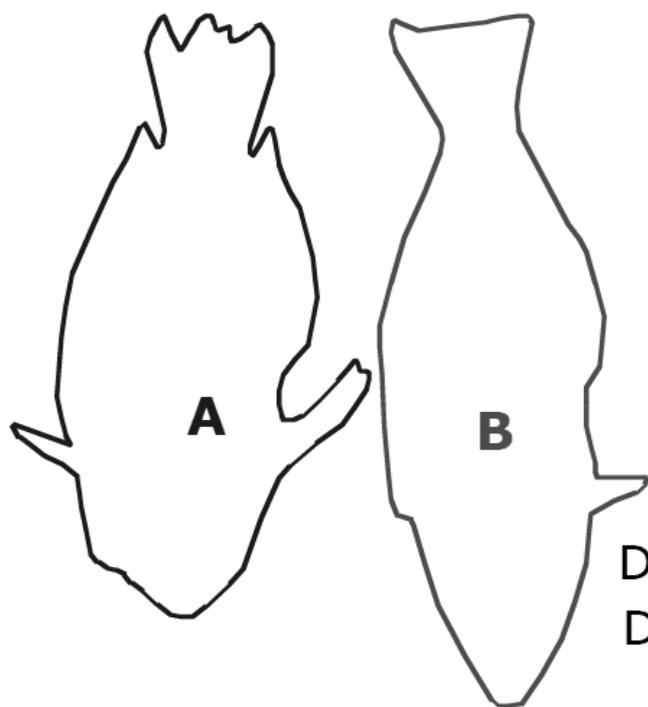
η learning rate

Problematiche

- ⇒ Non è detto che si riesca a trovare uno spazio vettoriale in grado di preservare le distanze tra gli oggetti del problema
- ⇒ Ci sono molte misure di dissimilarità che hanno senso da un punto di vista dell'applicazione ma che non sono “buone” da un punto di vista matematico (non sono metriche)

1. Positivity: $d_{ij} \geq 0$
2. Reflexivity: $d_{ii} = 0$
3. Definiteness: $d_{ij} = 0$ objects i and j are identical
4. Symmetry: $d_{ij} = d_{ji}$
5. Triangle inequality: $d_{ij} < d_{ik} + d_{kj}$

Problematiche



Dist(**A**,**B**):

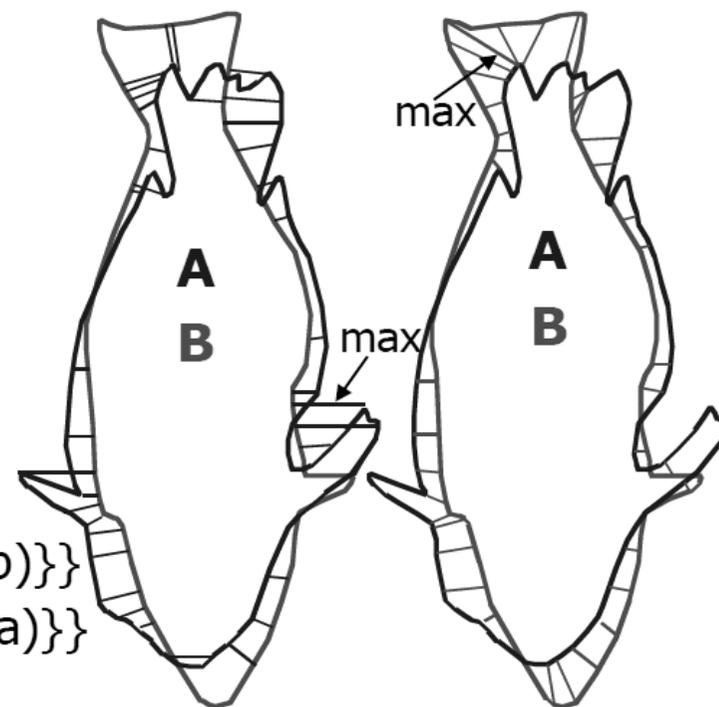
$a \in \mathbf{A}$, points of **A**

$b \in \mathbf{B}$, points of **B**

$d(a,b)$: Euclidean distance

$$D(\mathbf{A},\mathbf{B}) = \max_a \{ \min_b \{ d(a,b) \} \}$$

$$D(\mathbf{B},\mathbf{A}) = \max_b \{ \min_a \{ d(b,a) \} \}$$

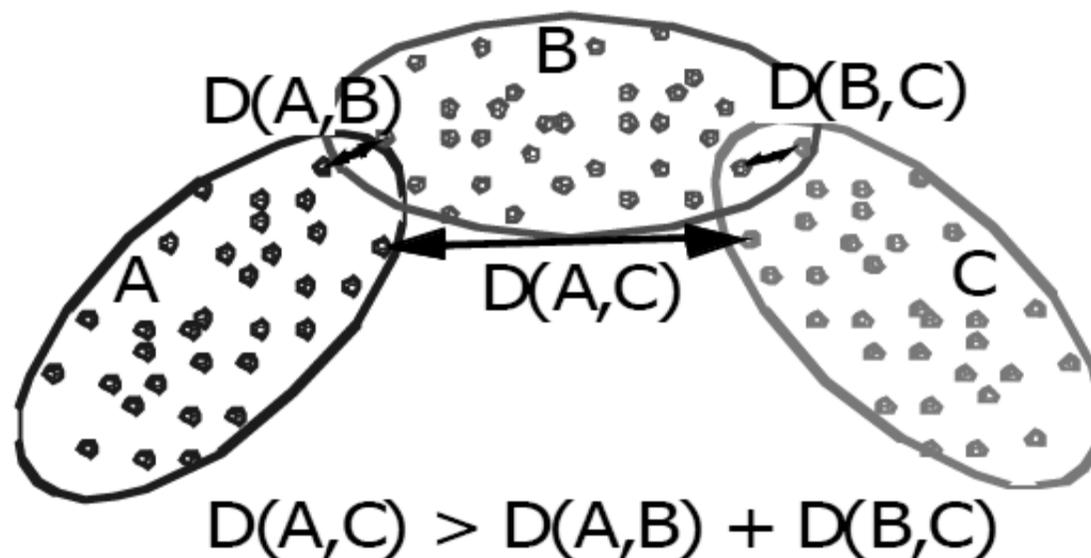


Esempio: distanza di Hausdorff per confrontare shapes

Molto utilizzata, funziona bene, ma... è una misura non simmetrica

Come si fa a creare uno spazio vettoriale dove la distanza tra A e B è diversa dalla distanza tra B e A???

Problematiche



Esempio: misura di distanza tra clusters (insiemi) – Single Linkage

Uno dei più famosi metodi di clustering si basa su questa distanza, ma... questa misura non soddisfa la disuguaglianza triangolare!

(Non vale che $D(A,C) \leq D(A,B) + D(B,C)$)

Problematiche



Caso ESTREMO:

$$D(\text{Libro, tavolo}) = 0$$

$$D(\text{tazza, tavolo}) = 0$$

$$D(\text{Libro, tazza}) > 0!$$

Anche in questo caso la distanza ha perfettamente senso!

Trovare metodi per gestire queste misure di dissimilarità altamente informative ma non metriche è un problema ancora aperto nella Pattern Recognition

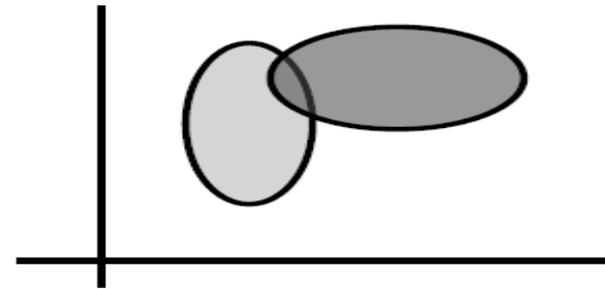
Considerazioni finali sulla rappresentazione

- ⇒ La scelta della rappresentazione è cruciale, e rappresenta il cuore della Pattern Recognition
 - ⇒ Goal della PR: dato un problema reale, l'obiettivo è trovare una rappresentazione che permetta di “generalizzare bene”
- ⇒ Quali sono le caratteristiche di una rappresentazione adeguata?

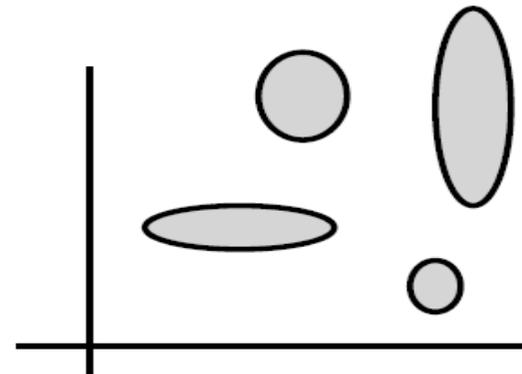
Considerazioni finali sulla rappresentazione

Buona rappresentazione:

⇒ *Classe specifica:* classi differenti devono essere rappresentate in posizioni differenti nello spazio della rappresentazione

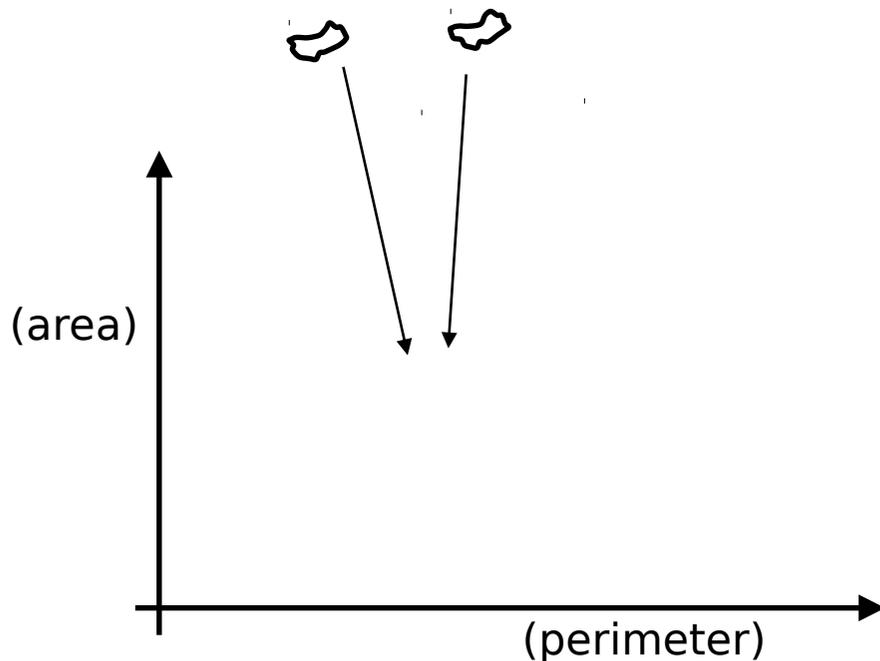


⇒ *Compattezza:* ogni classe deve essere rappresentata in una zona piccola dello spazio



Considerazioni finali sulla rappresentazione

Compactness: "Representations of real world similar objects are close"



IOTESI DI COMPATTEZZA: *Se due oggetti del problema sono simili allora hanno una rappresentazione simile (sono vicini nello spazio della rappresentazione)!*

"Nessuna possibilità di generalizzare se la rappresentazione viola questa regola"

(A.G. Arkedev and E.M. Braverman, Computers and Pattern Recognition, 1966.)

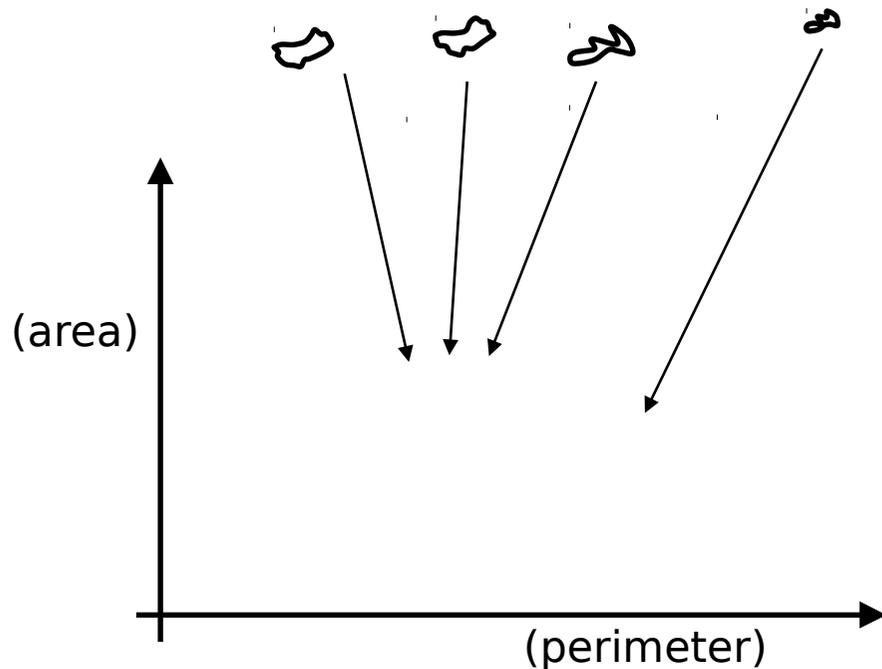
Considerazioni finali sulla rappresentazione

Attenzione: L'ipotesi di compattezza dice che:

Oggetti simili → rappresentazioni vicine

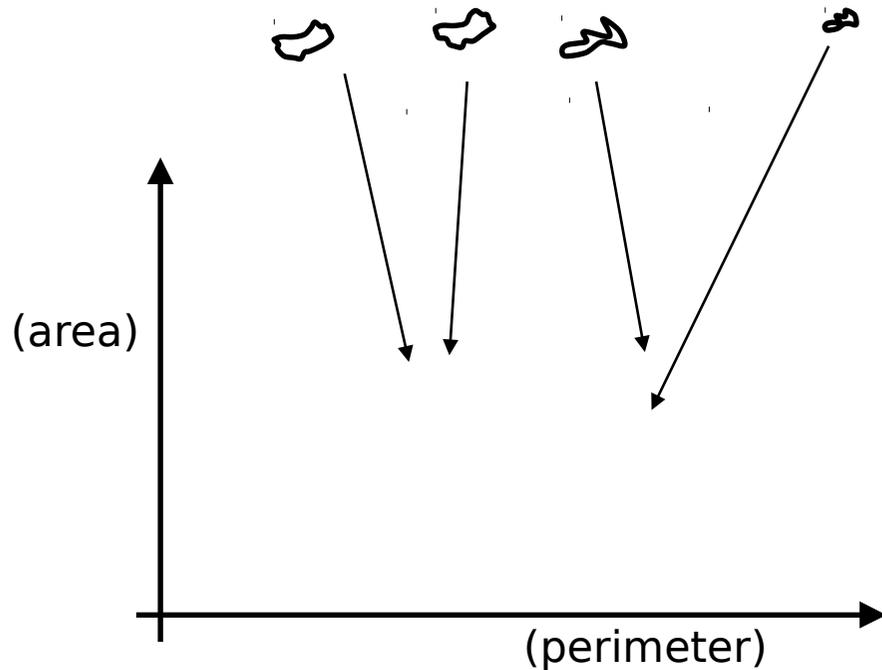
Questo in generale non è sufficiente per avere un classificatore perfetto, perché non è detto che valga anche il contrario

Oggetti dissimili → rappresentazioni lontane



Considerazioni finali sulla rappresentazione

Se vale anche il contrario allora si parla di
"TRUE REPRESENTATIONS"



Oggetti simili → rappresentazioni vicine
Oggetti dissimili → rappresentazioni lontane

La rappresentazione dei dati

1. Campionamento (acquisizione dati)
2. Rappresentazione: estrazione delle features e costruzione del pattern
3. Preprocessing: scaling, riduzione del rumore, riduzione della dimensionalità

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)

Scala

⇒ Definizione di scala: significatività relativa dei numeri

ESEMPIO: si considerino due numeri 10, 12

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

⇒ sono 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)

Scala

Tipi di scala:

⇒ qualitativa: le misure non hanno significato

⇒ I numeri sono usati come nomi,

⇒ Esempio: (sì/no) può essere codificata come (1,0), (0,1) o (50,100).

⇒ oppure semplicemente conta l'ordine tra di essi (1,2,3 sono come 10,20,100)

⇒ Esempio lista di accesso all'università

⇒ quantitativa: le misure hanno significato

⇒ I numeri hanno un valore (c'è un'unità di misura che dà il significato al valore)

⇒ Esempio: voto 9 (in decimi è buono, in trentesimi no!)

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

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 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

Approcci di data standardization

- ⇒ Ci sono due modi per standardizzare i dati
 - ⇒ approcci globali standardizzano l'intero data set
 - ⇒ approcci intra-gruppo standardizzano ogni gruppo (ATTENZIONE a non perdere tutta l'informazione!)
 - ⇒ 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)

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)

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

Data transformation

⇒ Approccio classico: trasformazione lineare dello spazio delle features

$$Y = A' X$$

⇒ Ogni nuova feature è una combinazione lineare di tutte le feature precedenti

⇒ Vediamo un esempio per un solo vettore x (una colonna della matrice \mathbf{X})

Esempio

$$A' \cdot x = y$$

A: matrice di
trasformazione dei
dati

Matrice 7x2

x: (dato) punto in uno
spazio a dimensione 7

Matrice 7x1

y: (dato trasformato) punto in
uno spazio a dimensione 2

Matrice 2x1

Data transformation

- ⇒ Quindi: si vuole ridurre la dimensionalità dello spazio mantenendo la maggior quantità di informazione possibile
- ⇒ “Informazione”: concetto che assume significati diversi a seconda della tecnologia utilizzata

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

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

Principal Component Analysis

⇒ Cosa fa?

- ⇒ trasformazione lineare delle variabili che proietta i dati in uno spazio tale per cui
 - ⇒ la prima direzione è quella di massima varianza
 - ⇒ la seconda direzione è quella di massima varianza che sia però ortogonale alla prima
 - ⇒ si continua così fino alla fine

⇒ Come si realizza?

- ⇒ Esiste un algoritmo che ci permette di trovare direttamente la matrice di trasformazione A che realizza la PCA
- ⇒ Si basa sugli autovalori e autovettori della matrice di covarianza dei dati

Principal Component Analysis

(Algoritmo alla lavagna)

Principal Component Analysis

⇒ Vantaggi:

⇒ migliore tecnica lineare di riduzione della dimensionalità di un insieme di dati

⇒ migliore in senso di “errore quadratico medio”

⇒ i parametri del modello possono essere ricavati direttamente dai dati

⇒ La proiezione nello spazio è un'operazione molto veloce (moltiplicazione di matrici)

Principal Component Analysis

⇒ 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

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

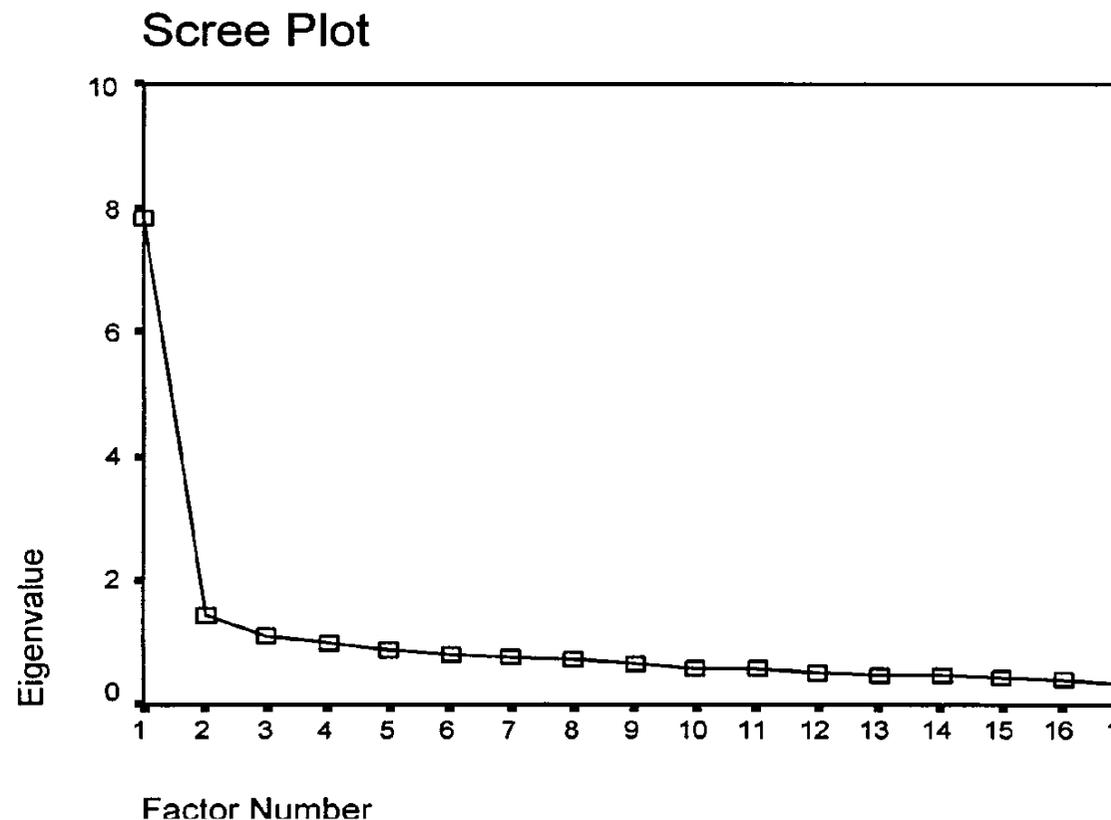
$$\text{imp}(i) = \frac{\lambda_i}{\sum_{i=1}^d \lambda_i} \quad \text{varianza}(1, \dots, L) = \sum_{i=1}^L \text{imp}(i) = \frac{\sum_{i=1}^L \lambda_i}{\sum_{i=1}^d \lambda_i}$$

Principal Component Analysis

⇒ Soluzione 2: Cattell Scree test

⇒ plottare gli autovalori

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



Metodi supervisionati

- ⇒ IDEA: utilizzo l'informazione del task finale
 - ⇒ non sempre l'informazione "non supervisionata" 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

Linear Discriminant Analysis

Occorre definire un criterio per misurare la “separabilità tra le classi”

⇒ Diverse opzioni:

⇒ Esempio: la distanza tra le medie nello spazio risultante (IDEA: più sono separate le classi nello spazio dopo la trasformazione, più separate sono le classi)

⇒ Criterio non ottimale: non tiene conto della dispersione dei punti all'interno della classe

⇒ Esistono criteri migliori: il criterio di Fisher!

Linear Discriminant Analysis

Criterio di Fisher

$$J(A, X) = \text{traccia} \{ S_{wy}^{-1} \cdot S_{By} \}$$

Dove:

- ⇒ S_{wy} : “Within Class Covariance” nello spazio finale:
dispersione interna alle classi
- ⇒ S_{By} : “Between Class Covariance” nello spazio finale:
dispersione tra le diverse classi

Linear Discriminant Analysis

⇒ L'idea è di:

- ⇒ Massimizzare la Covarianza tra le classi (classi ben separate tra di loro)
- ⇒ Minimizzare la Covarianza interna alle classi (classi ben compatte)

⇒ Come si trova la A che massimizza $J(A, X)$?

- ⇒ Con un procedimento simile a quello usato per la PCA
- ⇒ A è formata dagli m autovettori corrispondenti agli m autovalori più grandi della matrice $S_{wX}^{-1} \cdot S_{bX}$
- ⇒ S_{wX} S_{bX} hanno lo stesso significato di S_{wY} S_{bY} , (Within-class e Between-class) ma sono calcolati nello spazio originale X

Linear Discriminant Analysis

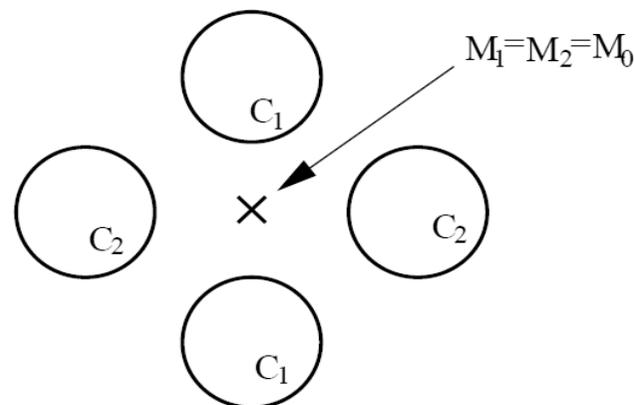
⇒ Vantaggi: massimizza la separabilità tra le classi

⇒ 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



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

Feature Selection

⇒ 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

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

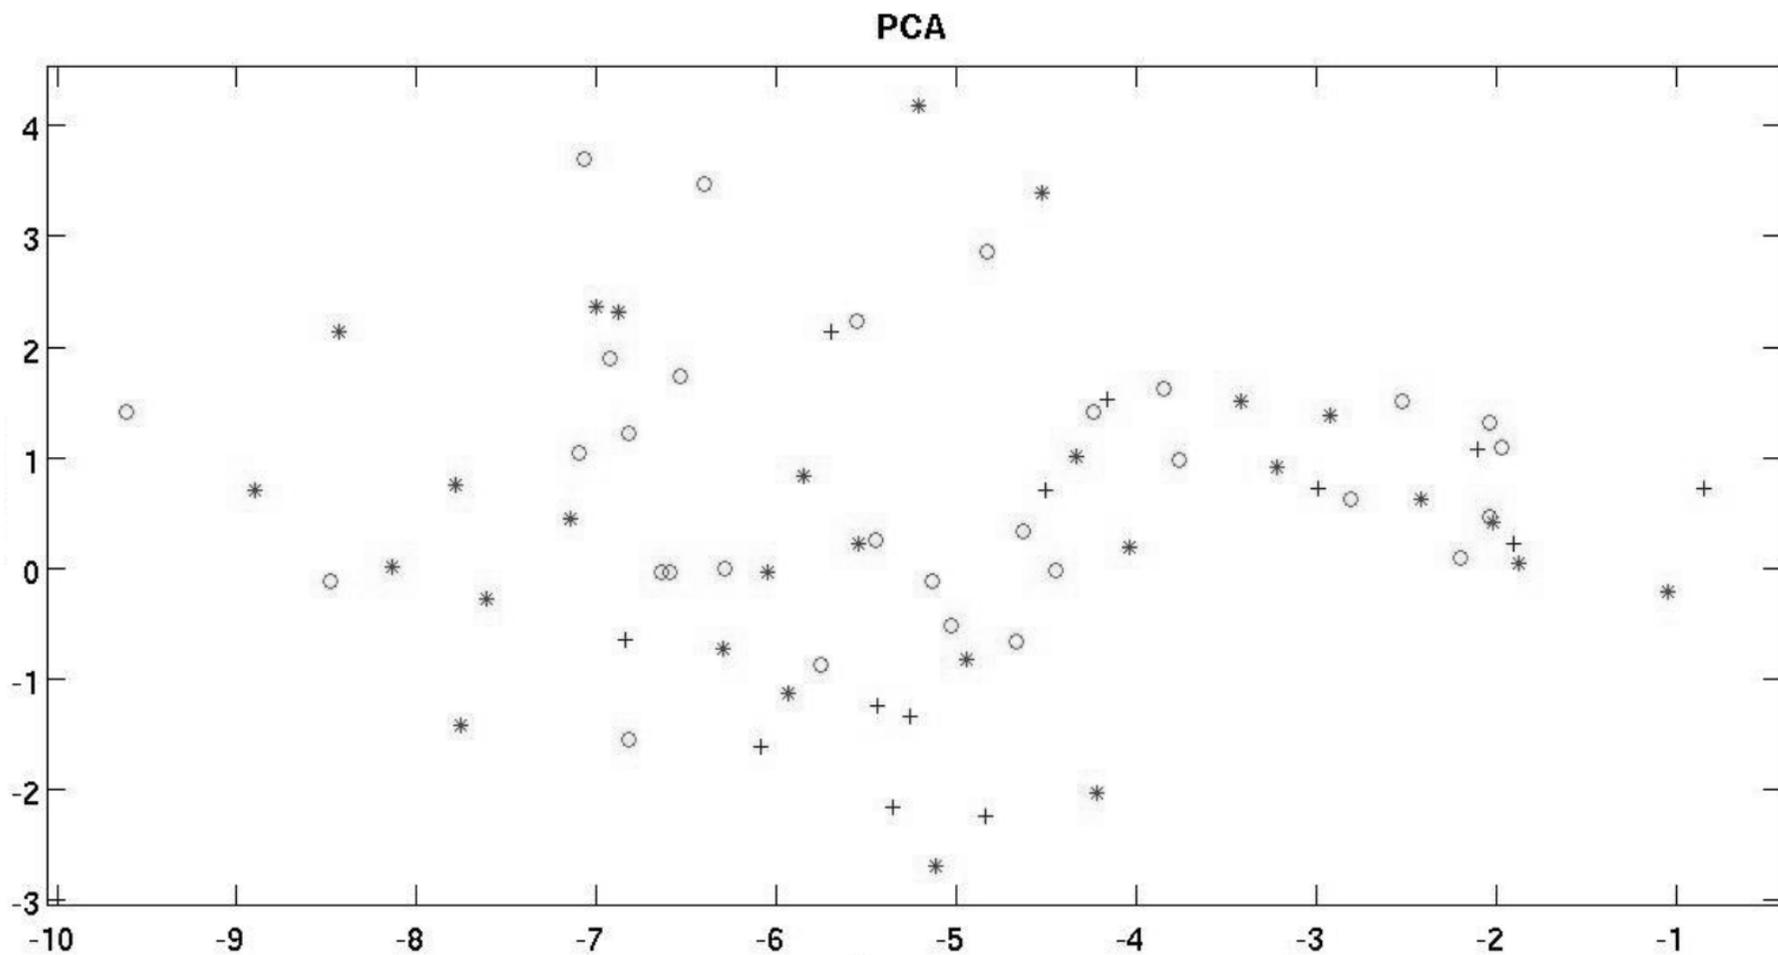
⇒ sub ottimale

Esempio: neuropatologie

- ⇒ Obiettivo: analisi di dati derivanti da pazienti affetti da Miopatie infiammatorie (malattie autoimmuni) per classificare sani/malati (o le diverse tipologie)
 - ⇒ gli anticorpi del sistema immunitario riconoscono particolari proteine (normalmente presenti) del siero di un paziente, come agenti estranei (antigeni), scatenando una risposta infiammatoria causa della malattia.
 - ⇒ Analisi di laboratorio permettono di individuare le proteine muscolari colpite dalla risposta immunitaria.
 - ⇒ Ogni paziente è caratterizzato da un insieme di proteine (profilo sierologico), alcune delle quali vengono riconosciute e colpite dalla risposta immunitaria, altre no.
- ⇒ Dal nostro punto di vista: una proteina è una feature!

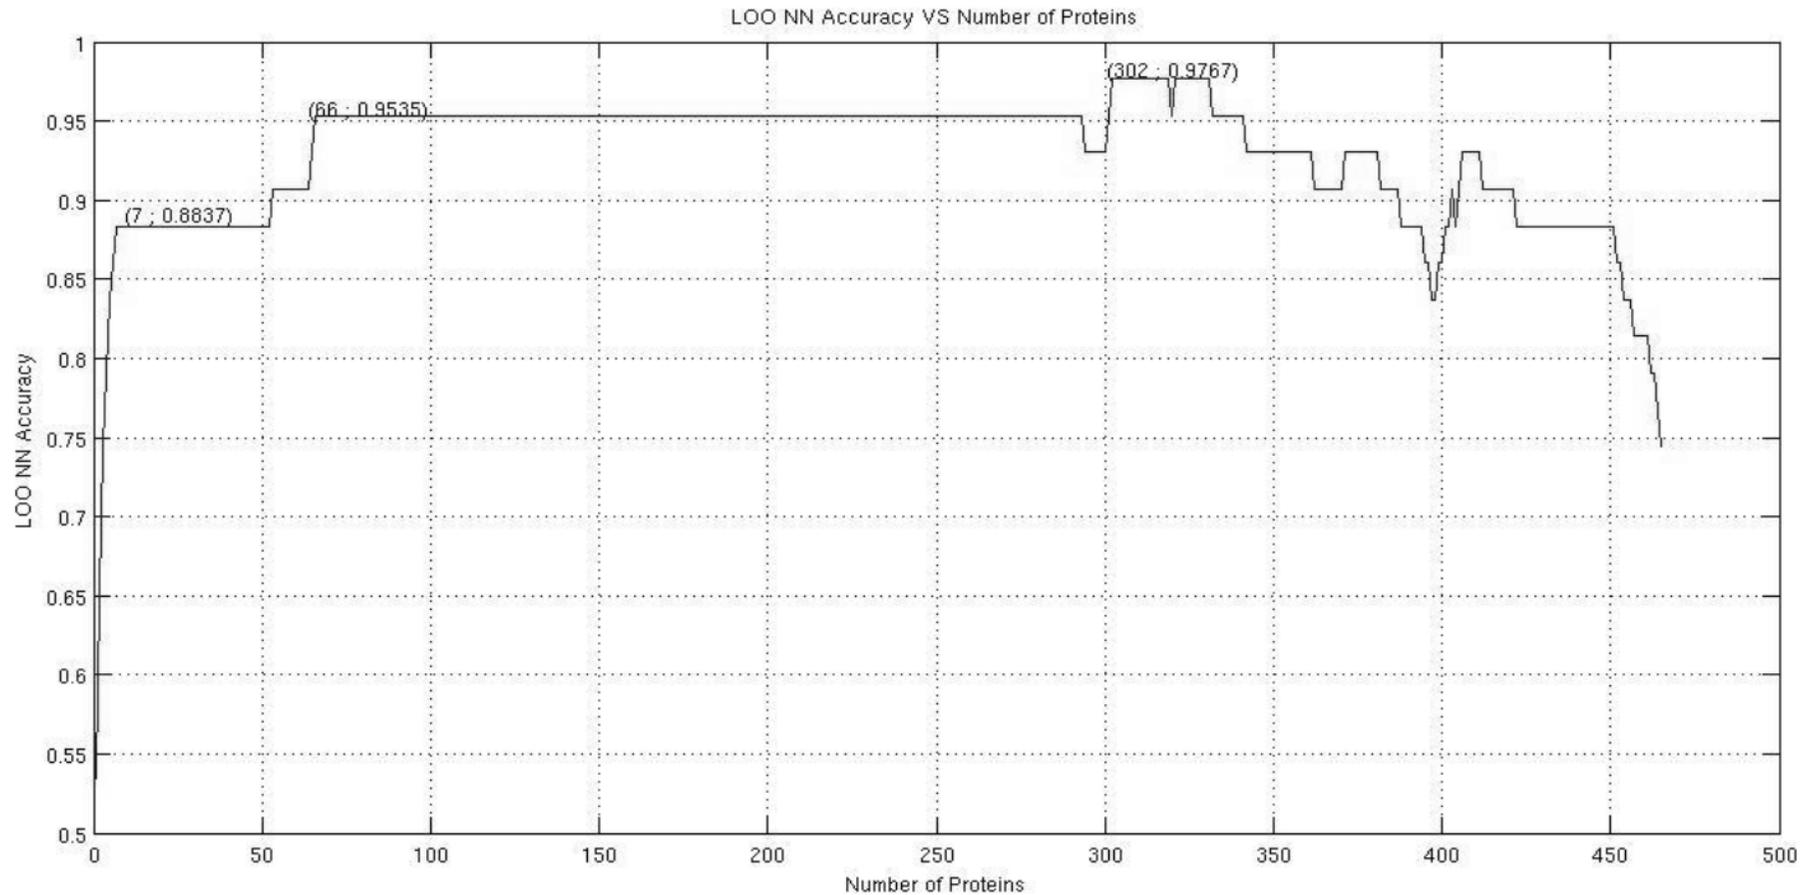
Esempio: neuropatologie

⇒ Usando tutte le features e applicando la PCA



Esempio: neuropatologie

⇒ feature selection



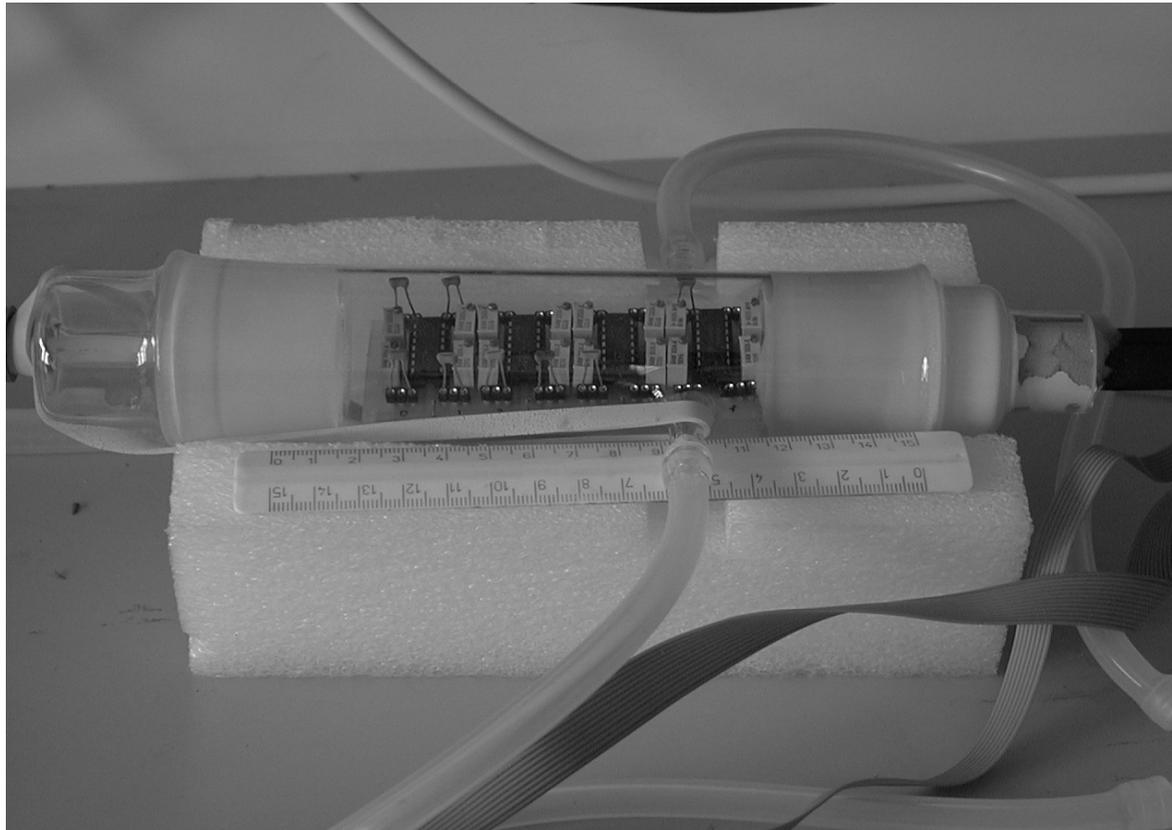
Visualizzazione dei dati

- ⇒ 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

Esempio

Riconoscimento di odori

⇒ Array di sensori chimici, ognuno sensibile a composti diversi



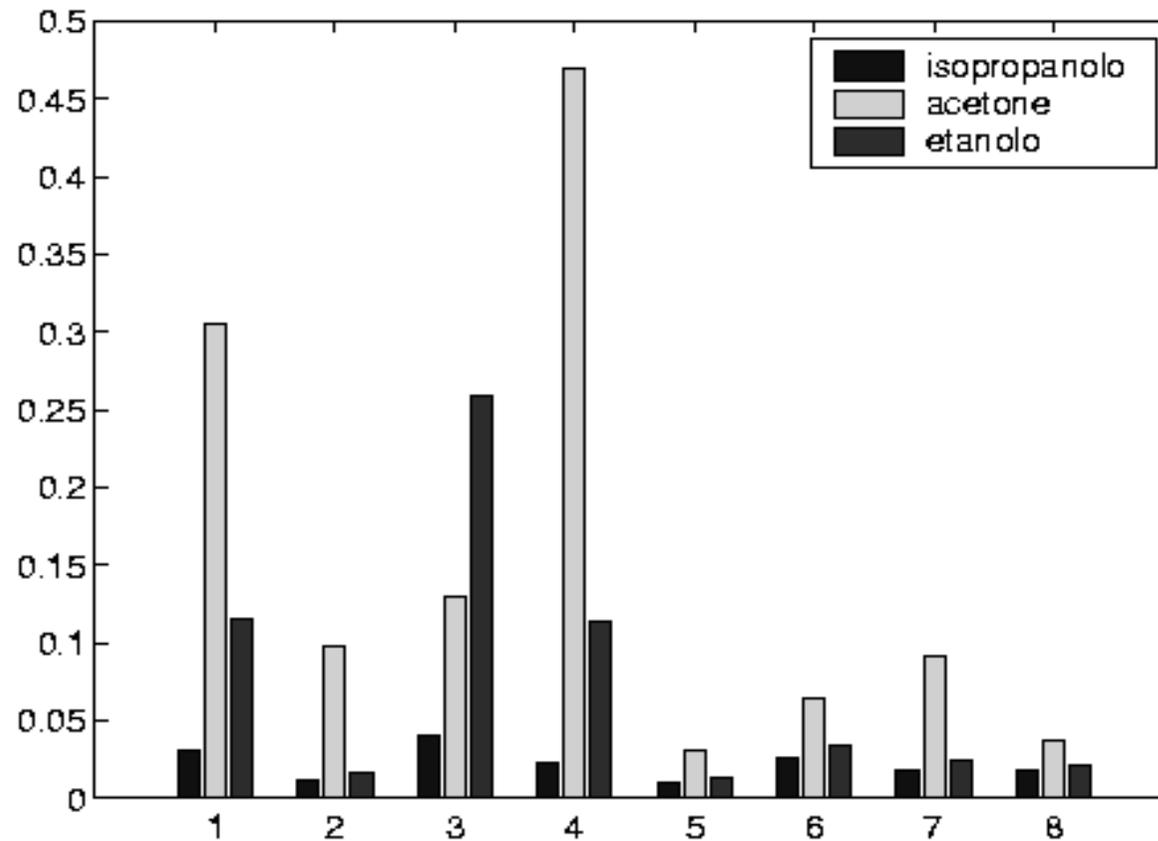
Esempio

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



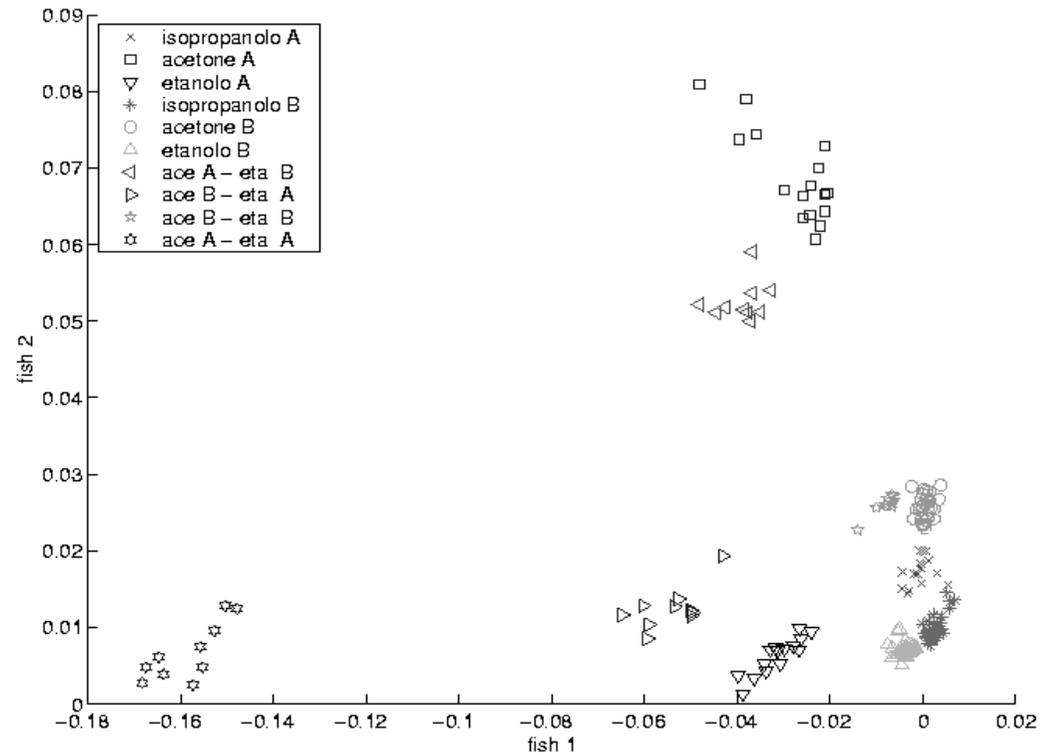
Esempio

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



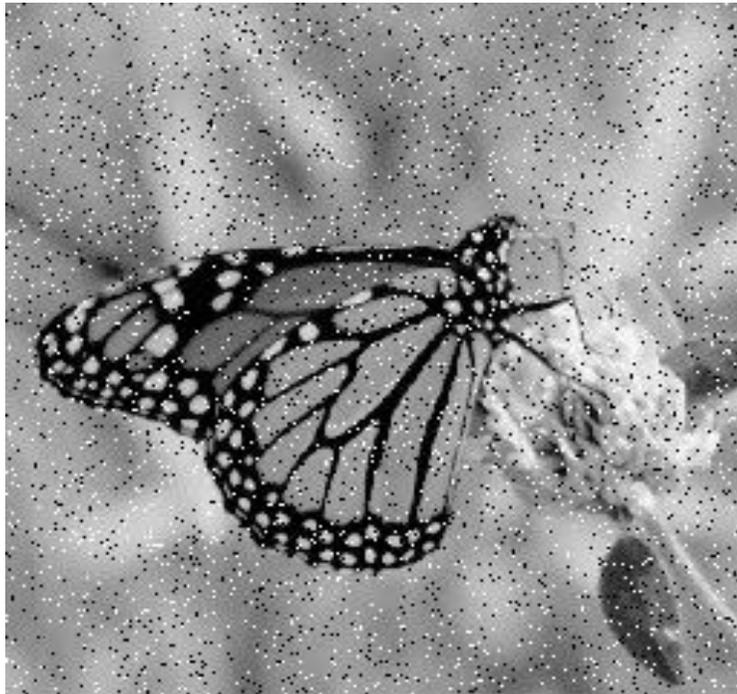
Esempio

⇒ Per visualizzare tutti gli esperimenti: PCA + plot



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)



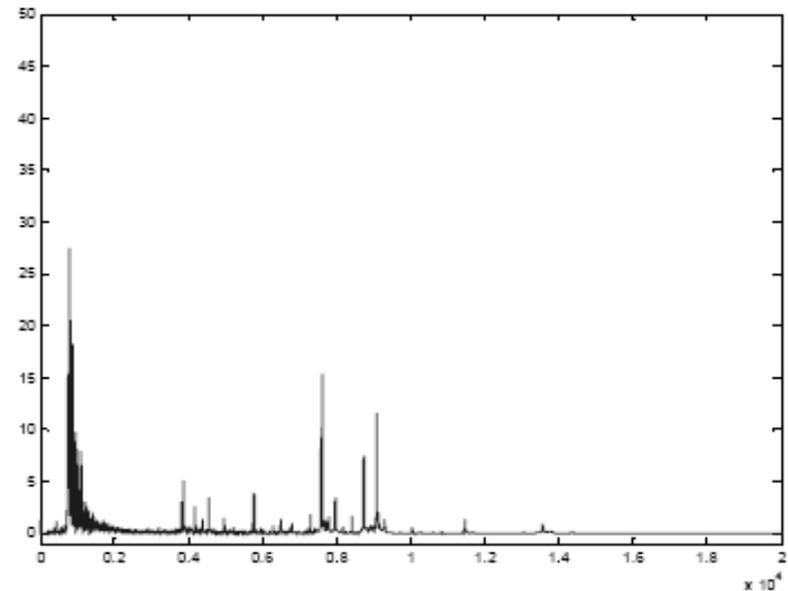
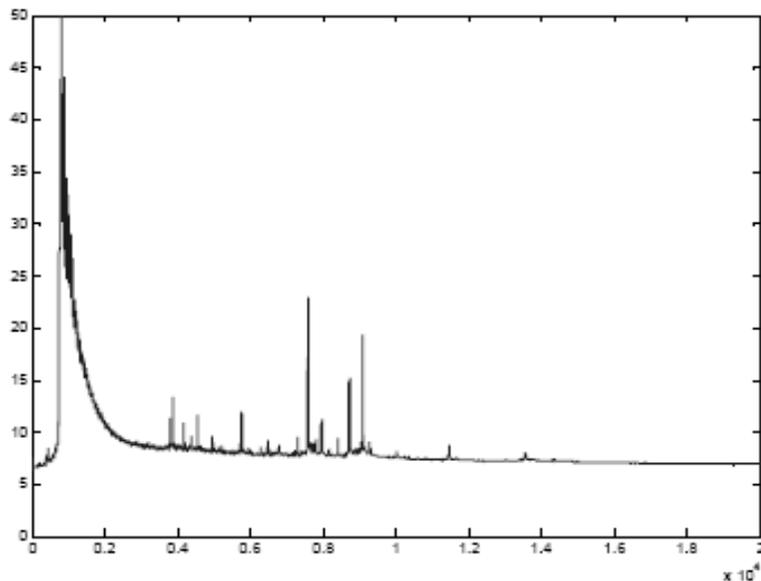
rumore sale e pepe



immagine "ripulita"

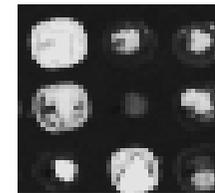
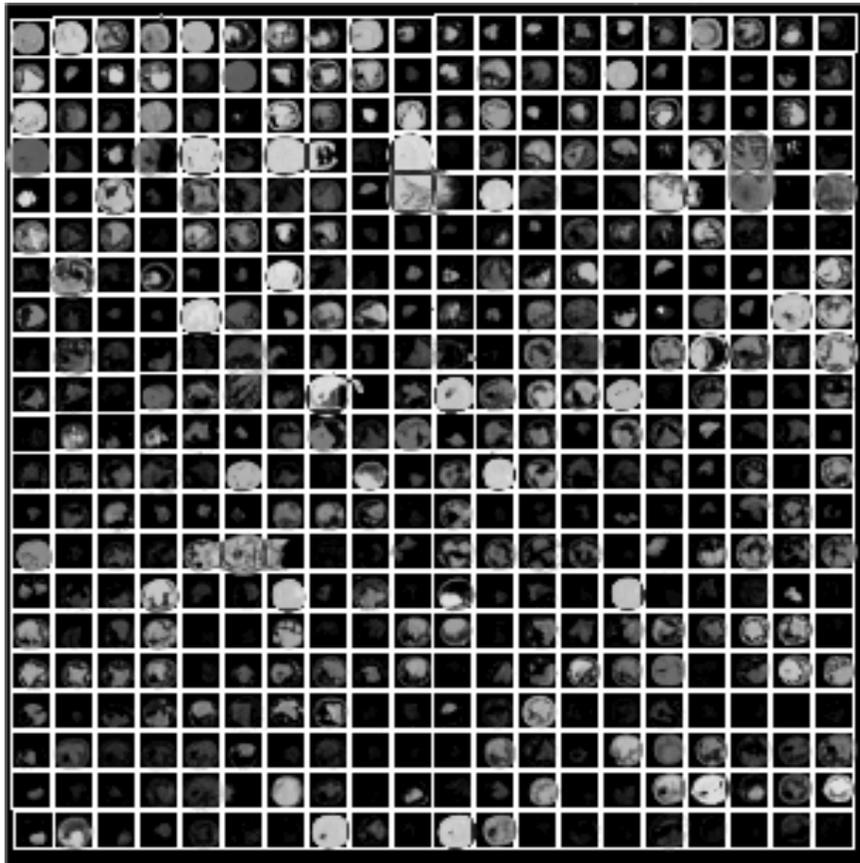
Riduzione del rumore

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

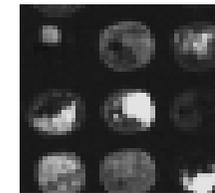


Riduzione del rumore

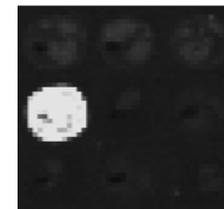
⇒ Microarray: errori nelle immagini degli spot



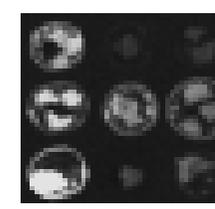
dimensione



rotondità



intensità



distribuzione
dei pixel

Riduzione del rumore

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

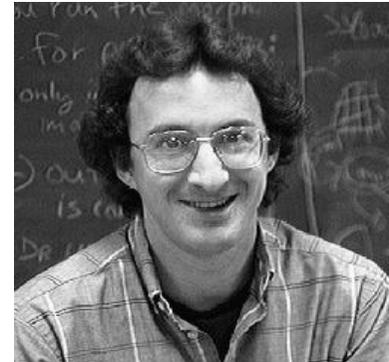
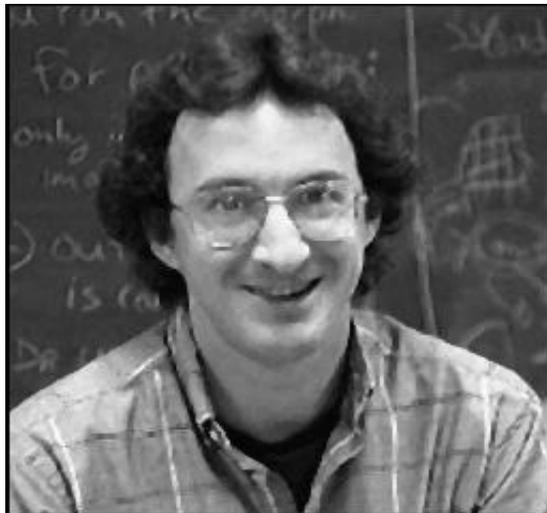
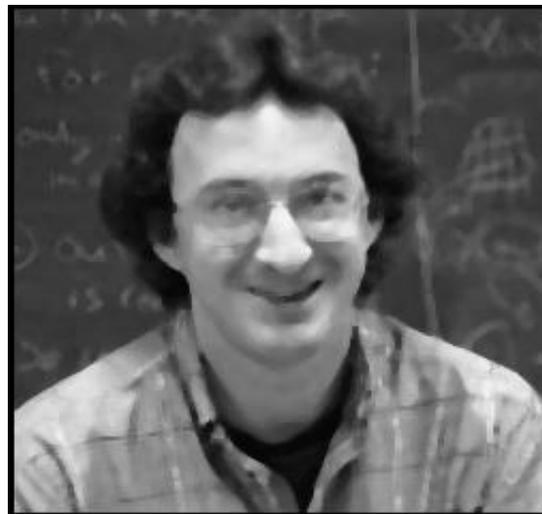


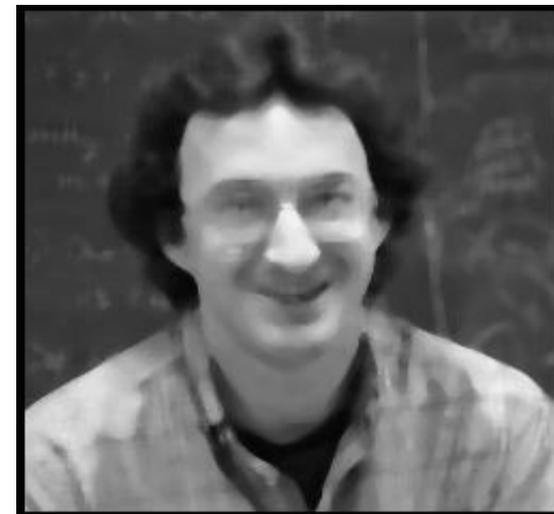
immagine originale



filtro mediano
3x3



filtro mediano
5x5



filtro mediano
7x7