# Pre-elaborazione dei dati

Gianluca Amato

Corso di Laurea Specialistica in Economia Informatica
Università “G. D'Annunzio” di Chieti-Pescara
anno accademico 2004-2005

# Knowledge Discovery in Databases

ci occupiamo di questo

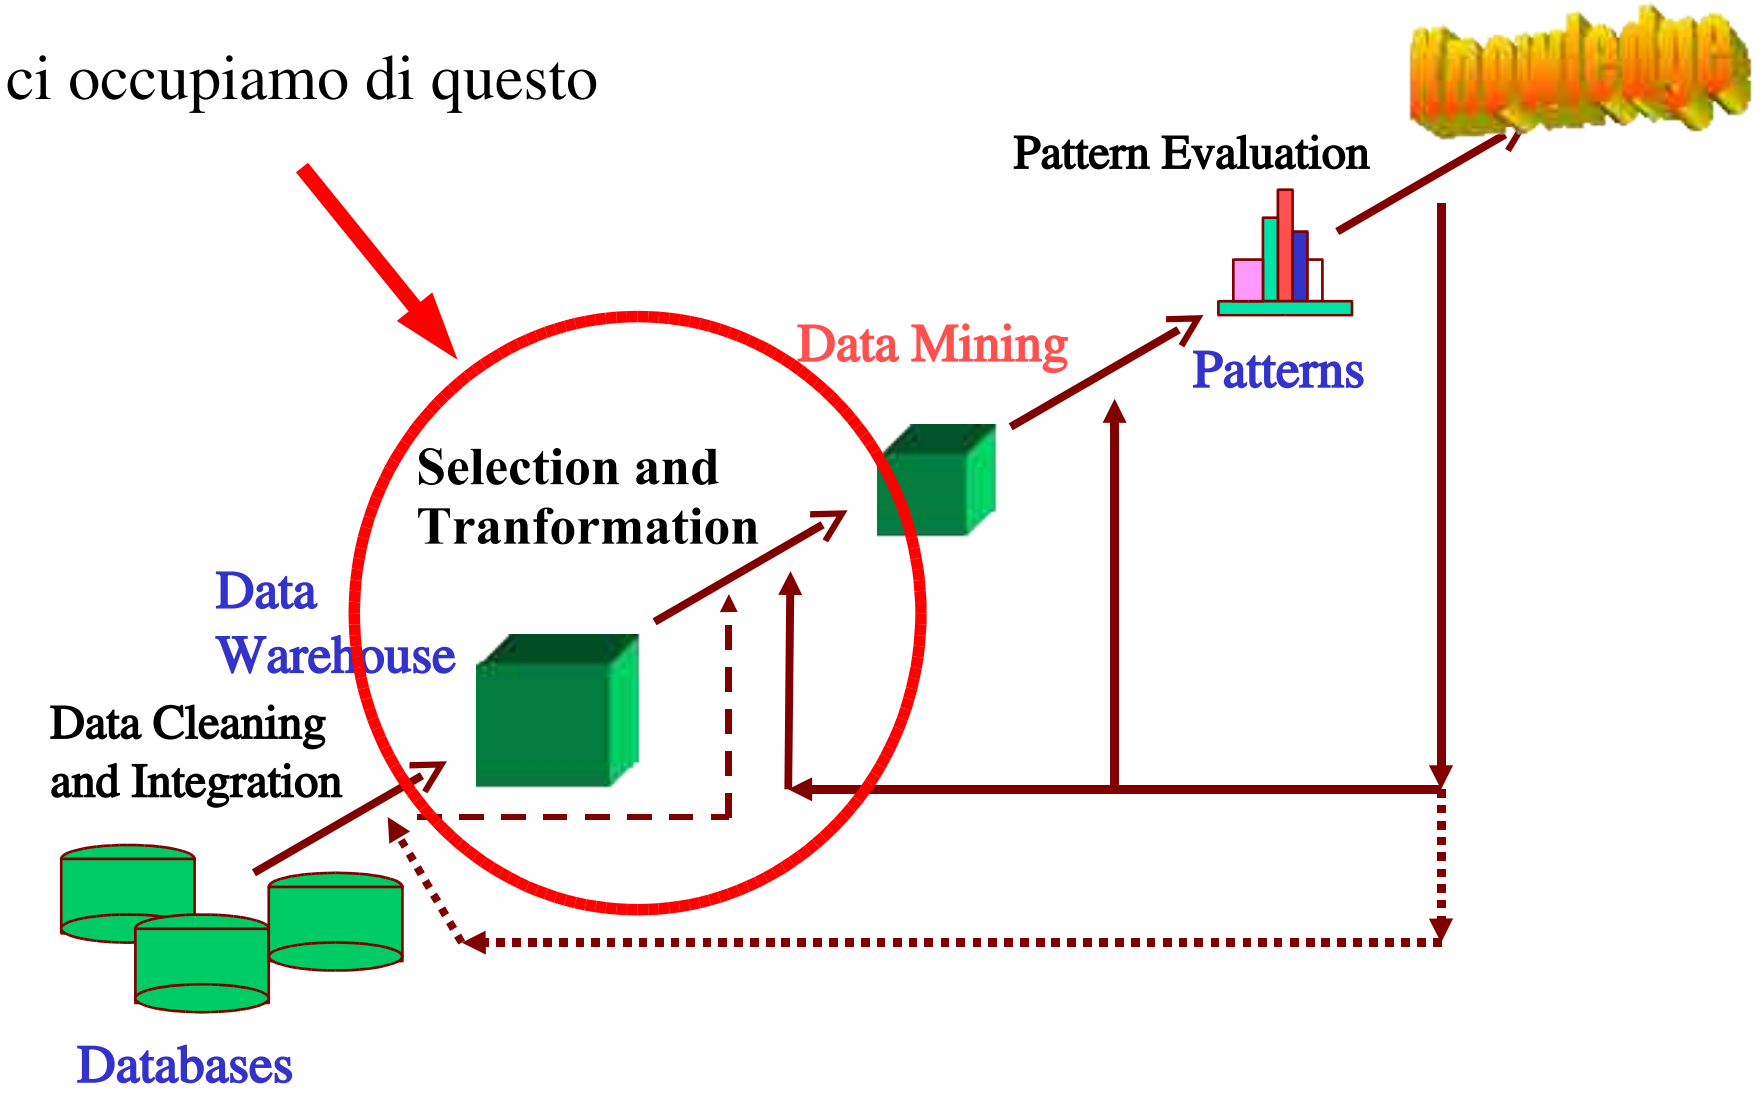

# Istanze e attributi

# Input a un sistema di data mining

- Mentre nei sistemi OLAP la forma preferita di dati è il cubo multidimensionale, per i sistemi di data mining la visione tabellare è di solito più conveniente.
- L'input corrisponde essenzialmente a una tabella di un database relazionale:
  - ogni riga della tabella è una istanza (o esempio, o tupla )
  - ogni colonna è un attributo
- L'input è dunque un insieme di istanze, ognuna delle quali è un esempio indipendente dell'informazione che si vuole apprendere.

# Un esempio di Input

| | lun. sepalo | larg. sepalo | lun. petalo | larg. petalo | tipo |
|---|---|---|---|---|---|
| 1 | 5.1 | 3.5 | 1.4 | 0.2 | Iris setosa |
| 2 | 4.9 | 3 | 1.4 | 0.2 | Iris setosa |
| 3 | 4.7 | 3.2 | 1.3 | 0.2 | Iris setosa |
| 4 | 4.6 | 3.1 | 1.5 | 0.2 | Iris setosa |
| 5 | 5 | 3.6 | 1.4 | 0.2 | Iris setosa |
| .. | | | | | |
| 51 | 7 | 3.2 | 4.7 | 1.4 | Iris versicolor |
| 52 | 6.4 | 3.2 | 4.5 | 1.5 | Iris versicolor |
| 53 | 6.9 | 3.1 | 4.9 | 1.5 | Iris versicolor |
| .. | | | | | |
| 103 | 7.1 | 3 | 5.9 | 2.1 | Iris virginica |
| 104 | 6.3 | 2.9 | 5.6 | 1.8 | Iris virginica |
| 105 | 6.5 | 3 | 5.8 | 2.2 | Iris virginica |

# Attributi (1)

- Gli attributi possono essere distinti secondo il "livello di misura"
  - nominali
    - ogni valore è un simbolo distinto
    - l'unica operazione permessa è decidere se due valori sono uguali
    - ad esempio l'attributo tipo per il data set degli iris è un attributo nominale che assume tre possibili valori
  - ordinali
    - come gli attributi nominali, ma in più c'è un ordine
      - è possibile confrontare due valori co tutti gli operatori relazionali (<, >, = e derivati)
    - ad esempio, l'attributo temperatura può assumere i valori freddo, tiepido, caldo con freddo < tiepido < caldo.
      - spesso si usano i numeri interi per rappresentare i valori ordinali, dato che per essi è definito un ordinamento standard.
      - in questo caso, si potrebbe usare 0 per il freddo, 1 per il tiepido, 2 per il caso.
    - la distinzione tra attributi nominali ed ordinali non è sempre chiara.

# Attributi (2)

- intervallo
  - assumono valori ordinati e ottenuti da precise unità di misura
  - esiste il concetto di distanza, per cui è possibile sottrarre due valori
  - le altre operazioni aritmetiche come somma e prodotto non hanno senso, e non esiste un valore zero significativo.
  - ad esempio la temperatura, quando espressa in gradi Celsius o l'attributo anno.
- ratio
  - assumono valori ordinati e ottenuti da precise unità di misura, per cui esiste un valore zero ben definito.
  - tutte le operazioni aritmetiche hanno sesnso.
  - ad esempio la temperatura, quando espressa in gradi Kelvin.

# Attributi (3)

- In pratica, la maggior parte delle volte gli algoritmi di data mining trattano solo due classi di attributi:
  - nominali (chiamati anche categoriali o discreti)
  - numerici: corrispondono ai tipi ordinale, intervallo o ratio a seconda del tipo di algoritmo
    - assumono un qualunque valore numerico
    - bisogna stare attenti al fatto che l'algoritmo non faccia delle operazioni che non hanno senso sul tipo di dato in questione

# Metadati

- I sistemi di data mining possono usare altre informazioni oltre al tipo di attributi:
  - informazioni dimensionali, in modo da non confrontare dati espressi con unità di misura diverse (cosa vuol dire che 3 Km è minore di 5 Litri?)
  - ordinamenti circolari: indicare se un attributo è soggetto a particolare circolarità dei dati
    - gli angoli vanno da 0 a 360° (o da 0 a $2\pi$) e poi ricomnciano da 0.
    - ci si può riferire allo "stesso giorno nella prossima settimana" o alla "prossima domenica"
  - gerarchie di concetti: alcuni attributi possono essere trattati a vari livelli di dettaglio
- Tutte queste informazioni prendono il nome di metadati e consentono di aumentare l'efficienza del sistema di data mining.

# Perché pre-elaborare i dati?

# Pre-elaborazione dei dati (1)

- I dati nel mondo reale sono sporchi:
  - incompleti: manca il valore di alcuni attributi, o mancano del tutto alcuni attributi interessanti.
  - inaccurati: contengono valori errati o che si discostano sensibilmente da valori attesi.
    - Ad esempio, nel campo età di un impiegato si trova il valore di 120 anni.
  - inconsistenti: ad esempio, due filiali dello stesso negozio usano codici diversi per rappresentare la stessa merce venduta.
- Queste inesattezze non influivano sullo scopo iniziale per cui i dati sono stati raccolti, e vengono scoperti solo ora.
- GIGO: garbage in – garbage out
  - se i dati in input non sono di buona qualità, neanche le analisi basate su di questi lo possono essere!

# Pre-elaborazione dei dati (2)

- Principali tecniche nella fase di pre-elaborazione dei dati:
  - data cleaning (pulitura dei dati)
    riempire i campi con i valori mancanti, “lisciare” i dati rumorosi, rimuovere i valori non realistici.
  - data integration (integrazione dei dati)
    integrare dati provenienti da database multipli risolvendo le inconsistenze.
  - data transformation (trasformazione dei dati)
    preparare i dati per l'uso con alcuni particolari algoritmi di analisi.
  - data reduction (riduzione dei dati)
    ridurre la mole dei dati in input, ma senza compromettere la validità delle analisi (campionamento, astrazione dei dati con le gerarchie di concetti, ...)

# Data Cleaning

# Data Cleaning

- Le attività eseguite durante il passo di data cleaning sono:
  - riempire gli attributi che hanno valori mancanti
  - identificare gli outliers (dati molto diversi dai valori attesi)
  - "lisciare" i dati rumorosi
  - correggere le inconsistenze
- Alcuni algoritmi di analisi hanno dei meccanismi per gestire dati con valori mancanti o con outliers.
  - essi operano però senza conoscenza del dominio applicativo
- I risultati migliori si ottengono con una pulizia a priori dei dati, con l'aiuto di esperti del dominio applicativo.

# Dati mancanti (1)

- Varie ragioni per cui i dati mancano
  - malfunzionamento di qualche apparecchiatura.
  - dati inconsistenti con altri e quindi cancellati in una fase precedente.
  - dati non immessi.

- Mancanze casuali o no?
  - se un valore non è presente perché un determinato test non è stato eseguito in maniera deliberata, allora la presenza di un attributo mancante può veicolare una grossa mole di informazione.
    - le persone che studiano i database di natura medica hanno scoperto che spesso è possibile effettuare una diagnosi semplicemente guardando quali sono i test a cui è stato sottoposto

# Dati mancanti (2)

- I possibili approcci quando si hanno dati con valori mancanti:
  - ignorare le istanze con valori mancanti
    - non molto efficace, in particolare se la percentuale di tuple con dati mancanti è alta.
    - si usa spesso quando il dato che manca è la classe in un problema di classificazione
  - riempire i valori mancanti manualmente
    - in generale è noioso, e potrebbe essere non fattibile
  - usare un valore costante come “Unknown” oppure 0 (a seconda del tipo di dati).
    - potrebbe alterare il funzionamento dell'algortimo di analisi, meglio allora ricorrere ad algoritmi che gestiscono la possibilità di dati mancanti
    - è però utile se la mancanza di dati ha un significato particolare di cui tener conto

# Dati mancanti (3)

- Altri possibili approcci:
  - usare la media dell'attributo al posto dei valori mancanti
  - per problemi di classificazione, usare la media dell'attributo per tutti i campioni della stessa classe
    - è una versione perfeziona del metodo della media per problemi di classificazione.
  - predirre il valore dell'attributo mancante sulla base degli altri attributi noti
    - la predizione può avvenire usando regressione lineare, alberi di classificazione, etc..
    - si usano algoritmi di data mining per preparare i dati in input ad altri algoritmi di data mining.

# Dati inaccurati (1)

- Cause specifiche delle inesattezze
  - errori tipografici in attributi nominali: coca cola diventa coccola
    - il sistema di data mining pensa si tratti di prodotti diversi
  - sinonimi: pepsi cola  e pepsi
  - errori tipografici o di misura in attributi numerici
    - alcuni valori sono chiaramente poco sensati, e possono essere facilmente riconosciuti
    - ma altri errori possono essere più subdoli
  - errori deliberati: durante un sondaggio, l'intervistato può fornire un CAP falso
    - errori causati da sistemi di input automatizzati
    - se il sistema insiste per un codice ZIP (come il CAP ma negli USA) e l'utente non lo possiede?

# Dati inaccurati (2)

- Occorre imparare a conoscere i propri dati!
  - capire il significato di tutti i campi
  - individuare gli errori che sono stati connessi
- Semplici programmi di visualizzazione grafica consentono di identificare rapidamente dei problemi:
  - attributi nominali: istogrammi
    - la distribuzione è consistente con ciò che ci si aspetta?
  - attributi numerici: grafici
    - c'è qualche dato ovviamente sbagliato?
- Vediamo due tecniche tipiche:
  - binning: per “lisciare” i dati rumorosi
  - clustering: per riconoscere gli outliers

# Dati rumorosi e binning

- Per rumore si intende un errore causale su una variabile misurata (tipicamente numerica)
  - è una delle possibile cause di dati inaccurati
- Il rumore può essere dovuto a
  - apparati di misura difettosi
  - problemi con le procedure di ingresso dati
  - problemi di trasmissione
  - limitazioni tecnologiche
- Il binning è una tecnica per ridurre la variabilità (e quindi il rumore) nei dati

# Equi-Depth Binning (1)

- si considerano tutti i possibili valori (con ripetizioni) assunti dall'attributo e li si ordina
  - chiamiamo $a_i$ con $i \in [1..N]$ i dati input, già ordinati
- si fissa un valore d per la profondità (depth) e si divide l'intervallo $[a_0, a_N]$ in intervalli (bin) consecutivi disgiunti di ampiezza più o meno uguale ad d
  - quindi ci saranno circa N/d intervalli
  - chiamiamoli $I_0, ..., I_m$
  - la corrispondenza tra i dati e gli intervalli è data da una funzione v tale che $a_i \in I_{v(i)}$
- ora sostituiamo ad ogni $a_i$ un valore derivato dal corrispondente intervallo

# Equi-Depth Binning (2)

- varie possibilità per questa sostituzione
  - smoothing by bin means
    - si sostituisce ad $a_i$ la media del corrispondente intervallo
    - $a_i \rightarrow$ media $I_{v(i)}$
  - smoothing by bin medians
    - si sostituisce ad $a_i$ la mediana del corrispondente intervallo
    - $a_i \rightarrow$ mediana $I_{v(i)}$
  - smoothing by bin boundaries
    - si sostituisce ad $a_i$ uno dei due estremi dell'intervallo corrispondente, in particolare quello più vicino
    - se $a_i - \min I_{v(i)} < \max I_{v(i)} - a_i$ ,
      allora $a_i \rightarrow \min I_{v(i)}$
      altrimenti $a_i \rightarrow \max I_{v(i)}$

# Equi-Depth Binning (3)

- Prezzi (in euro): 4, 8, 9, 15, 21, 21, 24, 25, 26, 28, 29, 34
  - Partizionamento in intervalli di 4 elementi (d=4)
    - Bin 1: 4, 8, 9, 15
    - Bin 2: 21, 21, 24, 25
    - Bin 3: 26, 28, 29, 34
  - Smoothing by bin means:
    - Bin 1: 9, 9, 9, 9
    - Bin 2: 23, 23, 23, 23
    - Bin 3: 29, 29, 29, 29
  - Smoothing by bin boundaries
    - Bin 1: 4, 4, 4, 15
    - Bin 2: 21, 21, 25, 25
    - Bin 3: 26, 26, 26, 34
- Non sempre è possibile avere intervalli di esattamente d elementi.

# Equi-Width Binning

- È simile al Equi-Depth Binning, ma gli intervalli sono ottenuti in modo da avere più o meno tutti la stessa ampiezza (width)
  - ovvero, se gli intervalli che otteniamo sono $I_0$, ..., $I_m$, il valore $\max I_i - \min I_i$ è più o meno costante, al variare di $i \in [0...m]$
- Con i dati di prima, e una ampiezza per ogni intervallo più o meno fissata a 10, otteniamo i seguenti bin:
  - Bin 1: 4, 8, 9, 1
  - Bin 2: 21, 21, 24, 25, 26, 28, 29, 34

# Clustering

- Con questo  metodo è possibile riconoscere gli outliers.
  - si dividono i possibili valori degli attributi da pulire in gruppi;
  - eventuali valori che non ricadono in nessun gruppo sono degli outliers.
- Anche in questo caso usiamo algoritmi di data-mining come preparazione per altri algoritmi di data-mining

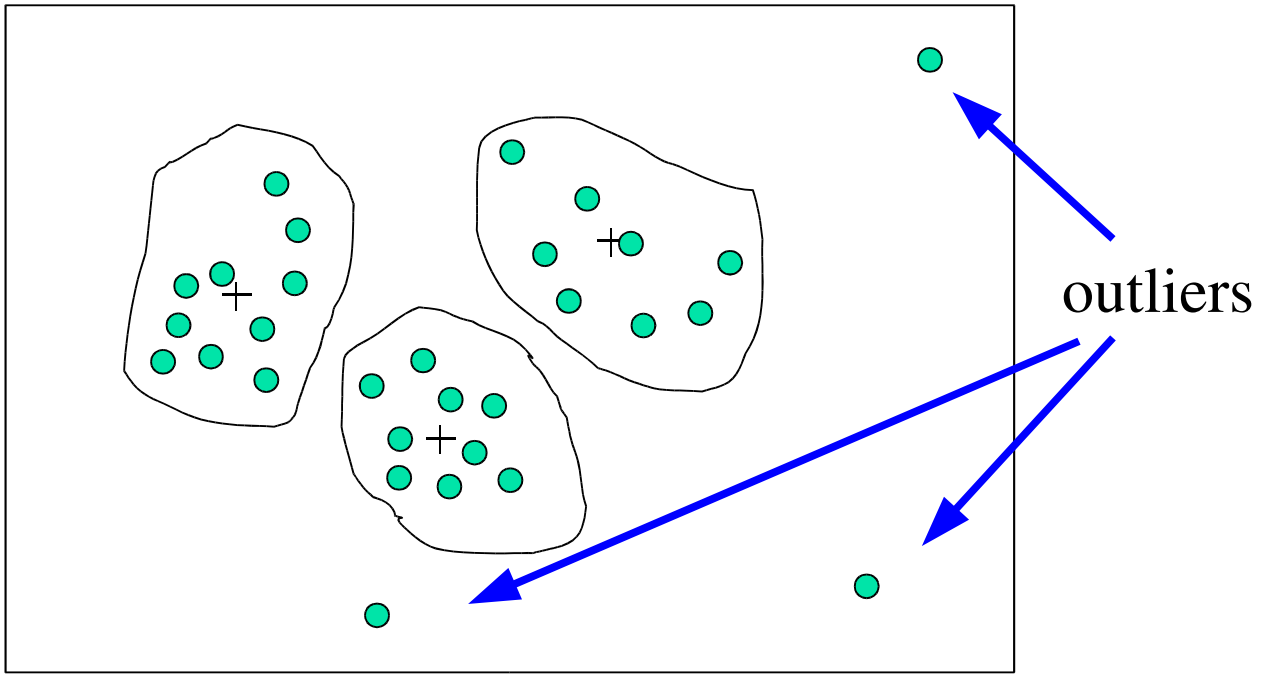

# Data Integration

# Data Integration (1)

- Si tratta di combinare dati provenienti da sorgenti diverse
- Primo aspetto: schema integration
  - integrazione dei metadati (ovvero dello schema relazionale) tra più database
  - il problema è capire che relazione c'è tra entità provenienti da divese sorgente
    - ad esempio, come fa il progettista a capire se l'attributo customer_id di un database e cust_number in un altro si riferiscono alla stessa entità
- Secondo aspetto: integrazione dei dati vera propria
  - ammesso di aver trovato che le tabelle customer di due diversi database si riferiscono alla stessa entità, come si fa a mettere assieme in una unica tabella le informazioni?
  - possibilità informazioni discordanti (errori, unità di misura diverse, etc..)

# Data Integration (2)

- Terzo aspetto: ridondanza
  - alcuni attributi possono essere ricavati (perfettamente o in parte) da altri
  - inconsistenza negli attributi tra due database diversi può provocare ridondanza
    - ad esempio, non si capisce che i campi “categoria merceleogica” di una tabella è “tipo prodotto” di un altra si riferiscono allo stesso tipo di informazione.
    - quando si metteno assieme i dati, si creano due campi diversi nella tabella integrata.
    - i valori dei due campi sono strettamente collegati
  - per gli attributi numerici, è possibile provare a scoprire se due attributi sono tra loro ridondanti usando una analisi di correlazione (che vedremo in futuro)

# Data Trasformation

# Data Transformation

- I dati sono consolidati e trasformati in forme più appropriate per le analisi. Varie possibilità sono
  - smoothing (lisciamento) rimuovere i rumori nei dati (binning, clustering, regressione, ...)
    - già visti nella fase di Data Cleaning
  - aggregazione: costruire dati aggregati prima dell'analisi
    - nei sistemi OLAM, corrisponde a scegliere il cuboide appropriato
    - eventualmente usando le gerarchie di concetti
  - costruzione degli attributi: costruire nuovi attributi a partire da quelli presenti per aiutare l'algoritmo di analisi
    - per esempio, si aggiunge l'attributo derivato area come prodotto degli attributi altezza e larghezza.
  - normalizzazione: modificare la scala dei dati in modo che cadano in intervalli stabilit (ad esempio da -1ad 1)

# Normalizzazione (1)

- Spesso gli attributi assumono valori in intervalli di ampiezza diversa.
  - può compromettere il funzionamento di alcune analisi
  - necessità di normalizzare i dati
- min-max normalization: si riscala l'attributo A in modo che i nuovi valori cadano tra $new\_min_A$ e $new\_max_{A.}$

$$v' = \frac{v - \mathbf{min}_A}{\mathbf{max}_A - \mathbf{min}_A}\left(\mathbf{new}_{\mathbf{max}_A} - \mathbf{new}_{\mathbf{min}_A}\right) + \mathbf{new}_{\mathbf{min}_A}$$

  - il minimo e il massimo effettivo dell'attributo A potrebbero essere ignoti.
    - si verifica un superamento dei nuovi limiti se successivamente appare un dato con un valore di A oltre l'intervallo originario.
  - molto influenzato dagli outliers

# Normalizzazione (2)

- z-score normalization (anche z-mean normalization)

$$v' = \frac{v - mean_A}{\sigma_A}$$

media

deviazione standard

  - utile quando non si conosce minimo e massimo per A
  - i valori normalizzato non hanno un minimo e un massimo fissato
  - non influenzato dagli outlier (o almeno non altrettanto del metodo precedente)

# Normalizzazione (3)

- normalization by decimal scaling:
  - una variante del metodo min-max
  - restringe i valori tra -1 ed 1 modificando la posizione della virgola

$$v' = \frac{v}{10^j}$$ dove $j$ è il più piccolo intero tale che Max(|v' |)<1

  - ad esempio, se l'attributo A varia da -986 a 917, per normalizzare dividiamo tutto per 1000. I nuovi valori andranno da -0.986 a 0.917.
    - il passaggio da valori di base a valori normalizzati è molto semplice

# Data Reduction

# Data Reduction

- I data warehouse possono memorizzare dati dell'ordine di terabyte: le analisi sono troppo complesse.
- Necessità di effettuare una riduzione dei dati
  - ottenere una rappresentazione ridotta dei dati con una occupazione molto inferiore di memoria ma che produce gli stessi (o comunque simili) risultati analitici.
- Varie strategie
  - aggregazione
    - usare un cuboide a più alto livello di aggregazione, purché sufficiente per il compito di analisi che dobbiamo svolgere.
  - riduzione della dimensionalità (dimensionality reduction)
  - compressione dei dati
  - riduzione della numerosità (numerosity reduction)
  - discretizzazione e generazione delle gerarchie di concetto

# Riduzione della dimensionalità (1)

- Selezionare un insieme minimo di attributi che descrivano in maniera adeguata i dati in ingresso
  - ad esempio, eliminare gli attributi irrilevanti come può essere una chiave primaria
  -
- Può essere effettuata da un esperto del settore analizzato, ma qui parleremo di metodi automatici
- Serve una "misura" della bontà di un insieme di attributi, in modo che si possa scegliere l'insieme migliore.
- Una ricerca esaustiva è spesso impossibile:
  - se ho d attributi in totale, ci sono $2^d$ possibili sottoinsiemi
  - si usano quindi algoritmi euristici

# Riduzione della dimensionalità (2)

- Possibili algoritmi euristici
  - step-wise forward selection
    - parto da un insieme vuoto di attributi
    - ad ogni passo aggiungo l'attributo che massimizza la qualità dell'insieme risultante
      - Insieme di attributi : {A1, A2, A3, A4, A5, A6 }
      - Insiemi ridotti: {} → {A1} → {A1,A6}→ {A1,A4,A6}
  - step-wise backward selection
    - parto da tutti gli attributi
    - ad ogni passo tolgo l'attributo che massimizza la qualità dell'insieme risultante
      - Insieme di attributi : {A1, A2, A3, A4, A5, A6 }
      - Insiemi ridotti: {A1, A2, A3, A4, A5, A6} → {A1, A3, A4, A5, A6} → {A1, A4, A5, A6} → {A1, A4, A6}
  - combinazione di forward e backward selection

# Riduzione della dimensionalità (3)

- Posso anche usare gli alberi di decisione
  - costruisco un albero di decisione e mantengo solo gli attributi che appaiono nell'albero

Insieme iniziale di attributi:
{A1, A2, A3, A4, A5, A6}

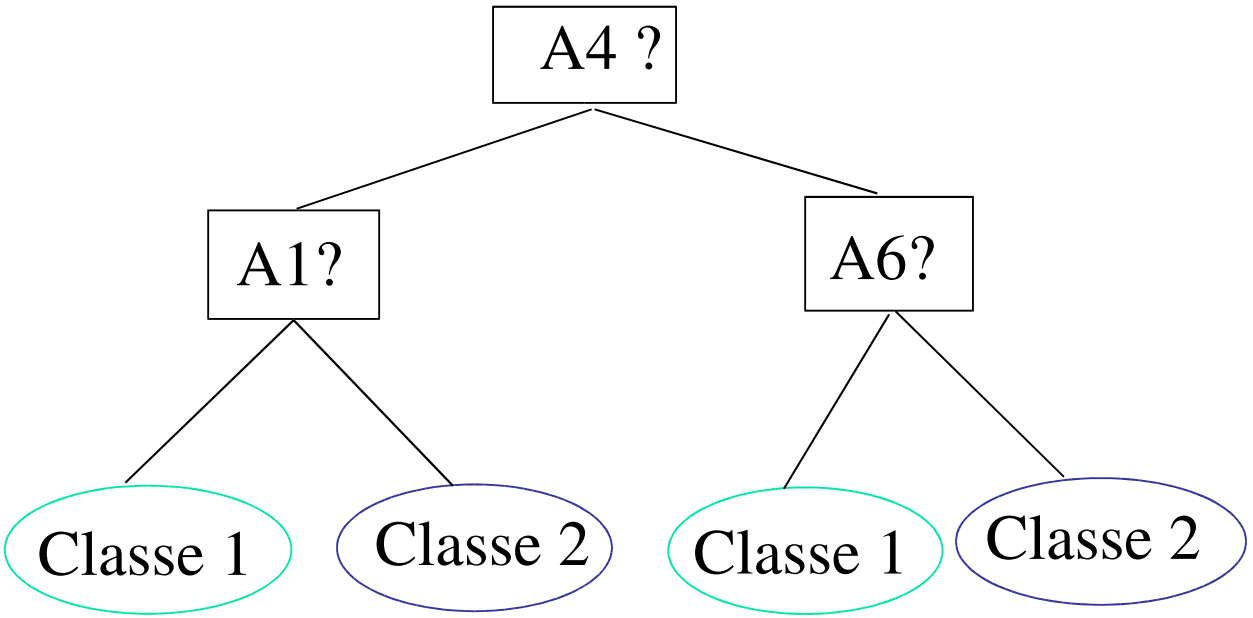


Insieme ridotto: {A1, A4, A6}

# Compressione dei dati (1)

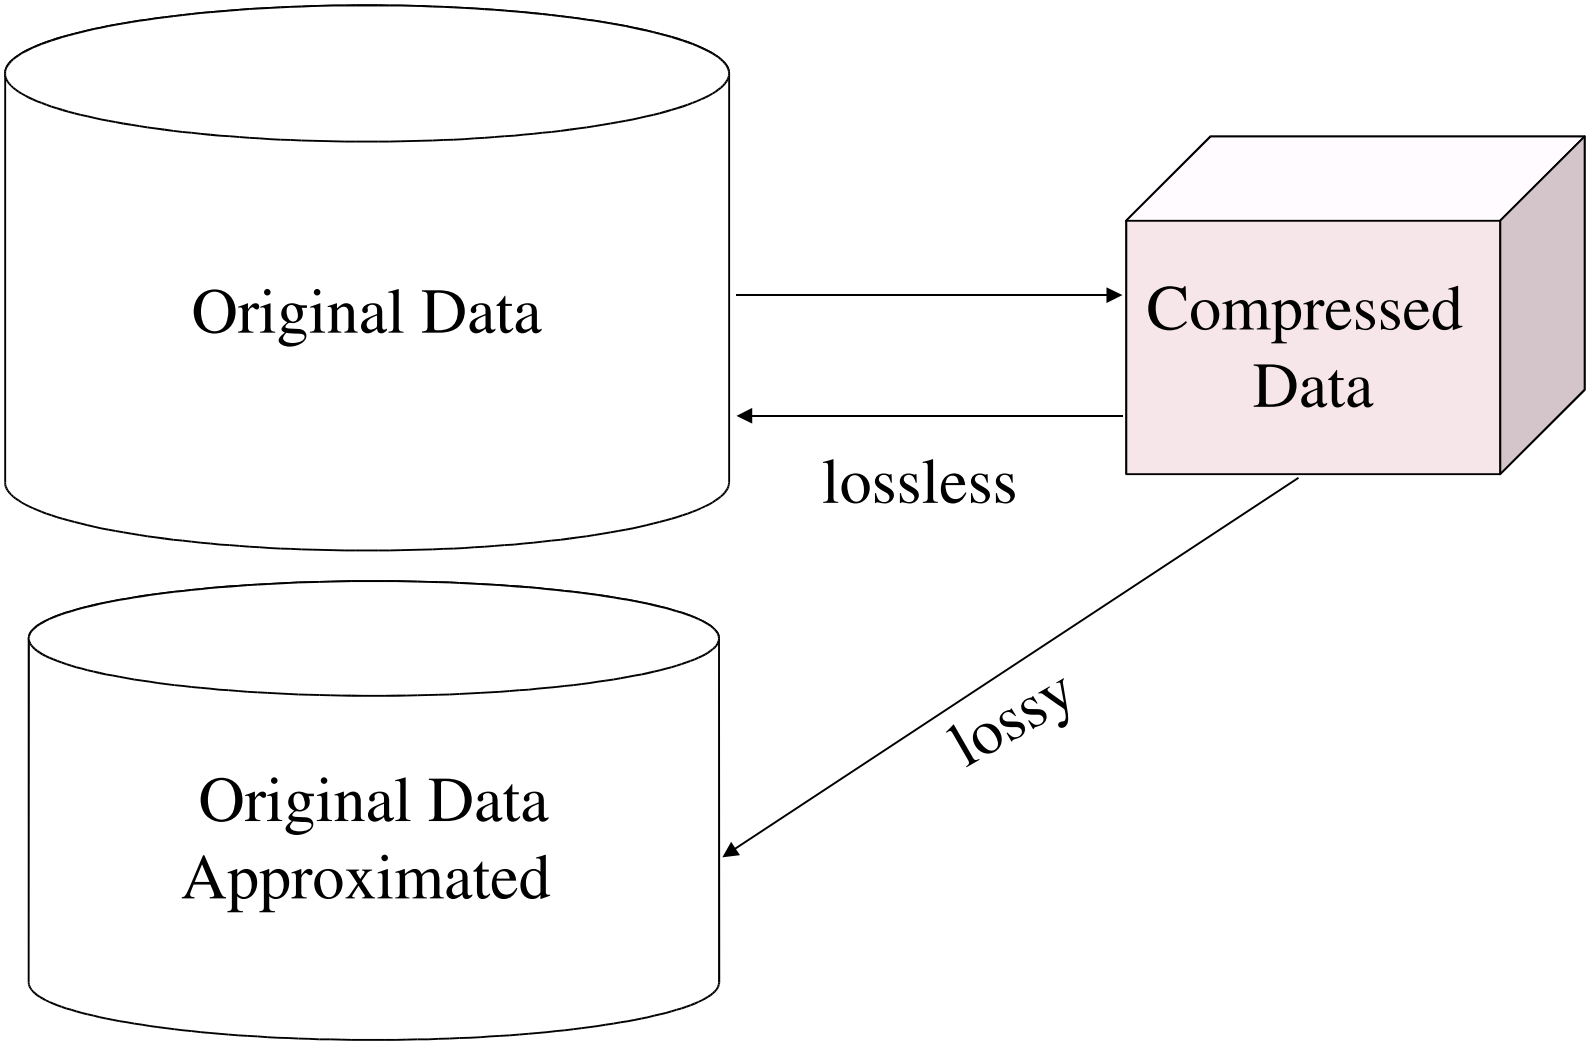

# Compressione dei dati (2)

- Un insieme di tecniche che consentono di ridurre la dimensioni dei dati
  - lossless (senza perdita)
    - una enorme letteratura per quello che riguarda la compressione delle stringhe
    - esempio: formati ZIP, RAR, Gzip, BZ2 per file generici
    - esempio: formati GIF per immagini
  - lossy (con perdita)
    - tipicamente usate per contenuti multimediali
    - esempio: mp3, Ogg Vorbis (audio), MPEG (video), JPEG (immagini)

# Compressione dei dati (3)

- Analisi delle componenti principali
  - dati N vettori in k dimensioni, trovare c<=k vettori ortonormali (le componenti principali) che possono essere usati per rappresentare i dati
    - l'insieme di dati originale viene ridotto ad un insieme di N vettori in c dimensioni
  - i nuovi dati sono combinazioni lineari delle c componenti principali
    - le componenti principali sono ordinati per “significatività”
    - i più significativi sono quelli che mostrano maggiore variabilità nei dati
    - i meno significativi sono quelli che mostrano minore variabilità nei dati
  - funziona solo su dati numerici

# Compressione dei dati (4)

analisi con: k=2 c=1

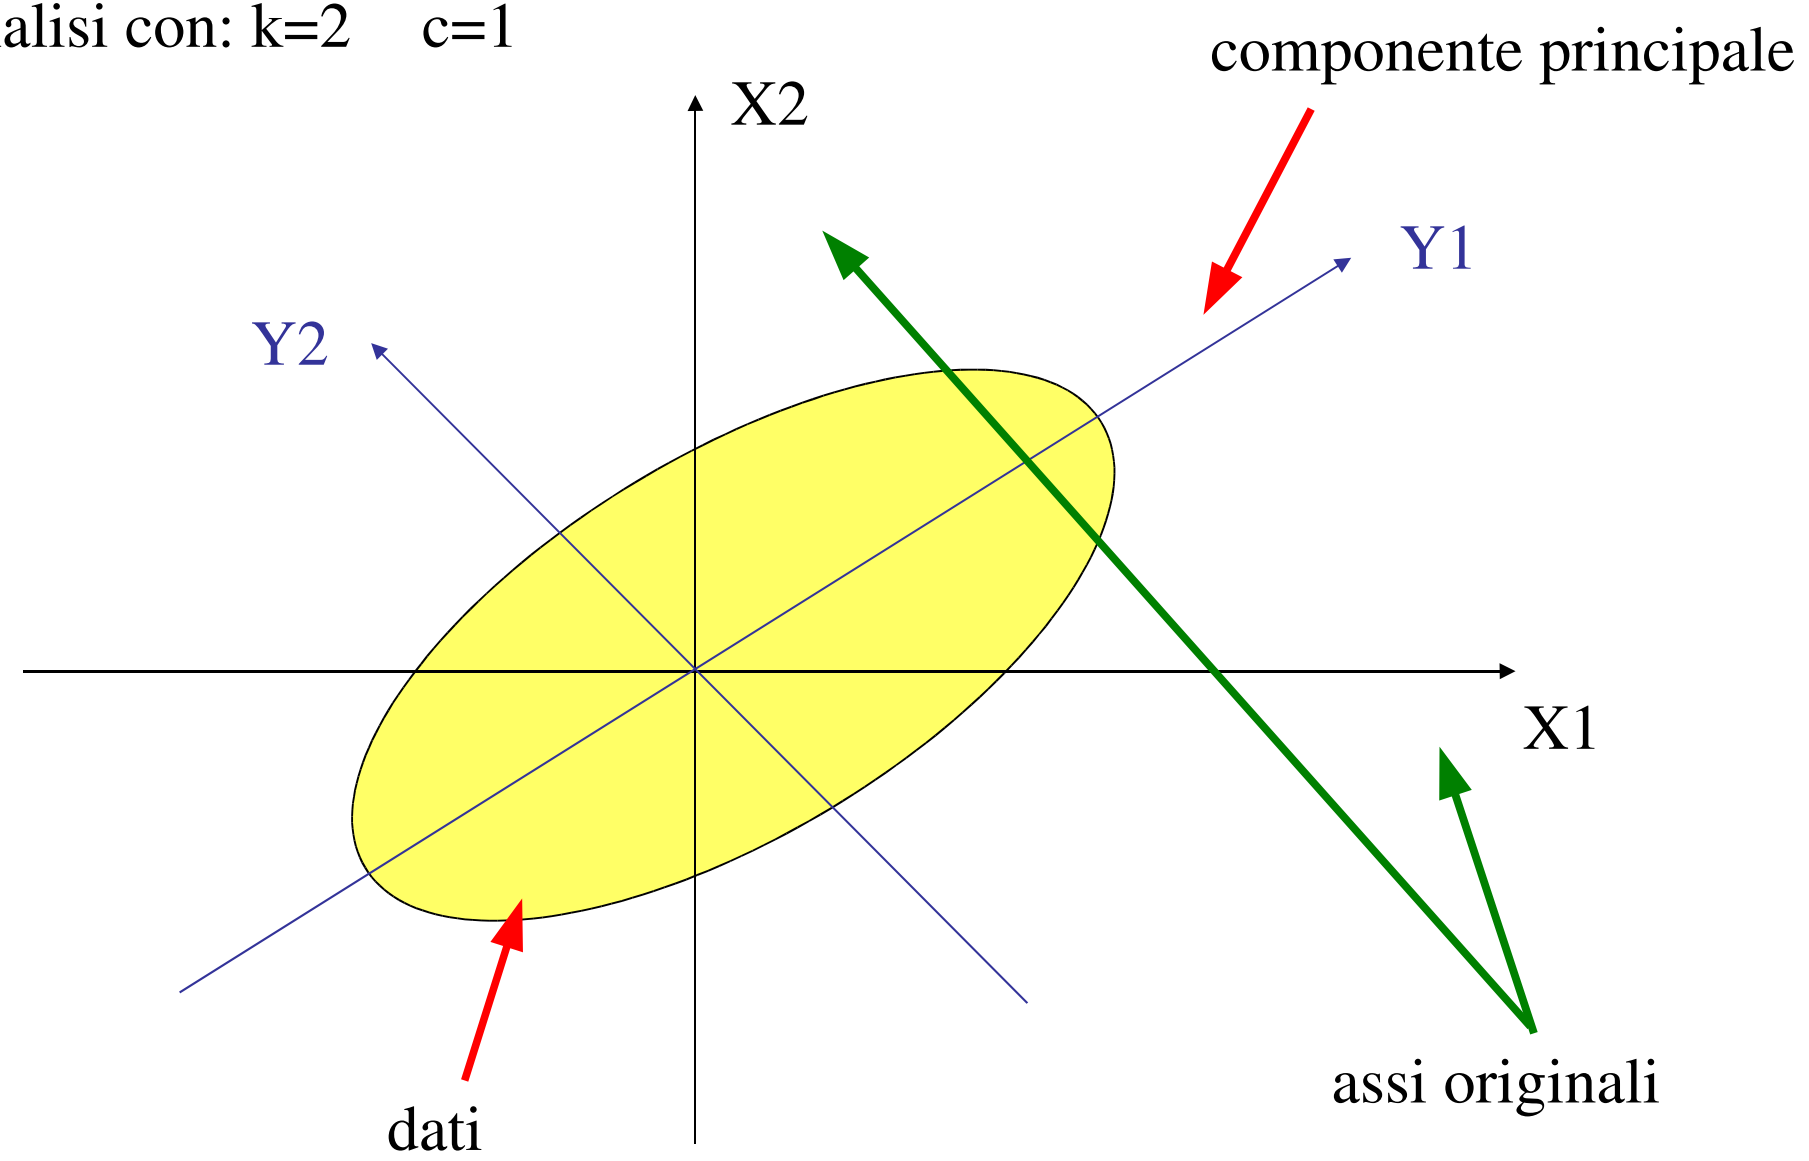

# Riduzione della numerosità

- Ridurre la mole dei dati scegliendo una rappresentazione diversa
- Metodi parametrici
  - assumere che i dati soddisfino un dato modello, stimare i parametri del modello e usare questi ultimi invece dei parametri originali
    - ad esempio, stimare una serie di numeri usando la regressione lineare..
    - od un insieme di numeri con una distribuzione gaussiana
  - assumiamo che siano ben noti dai corsi di statistica
- Metodi non parametrici
  - non si assume nessun modello particolare
  - famiglie principali di metodi:
    - raggruppamento
    - campionamento

# Raggruppamento (1)

- Si dividono i dati in cluster
- La rappresentazione dei cluster sostituisce la rappresentazione iniziale dei dati.
  - cosa si intende per rappresentazione dei cluster?
  - varie possibilità:
    - un punto medio,
    - una figura geometrica che approssima il cluster (poligoni, cerchi, etc..)

# Raggruppamento (2)

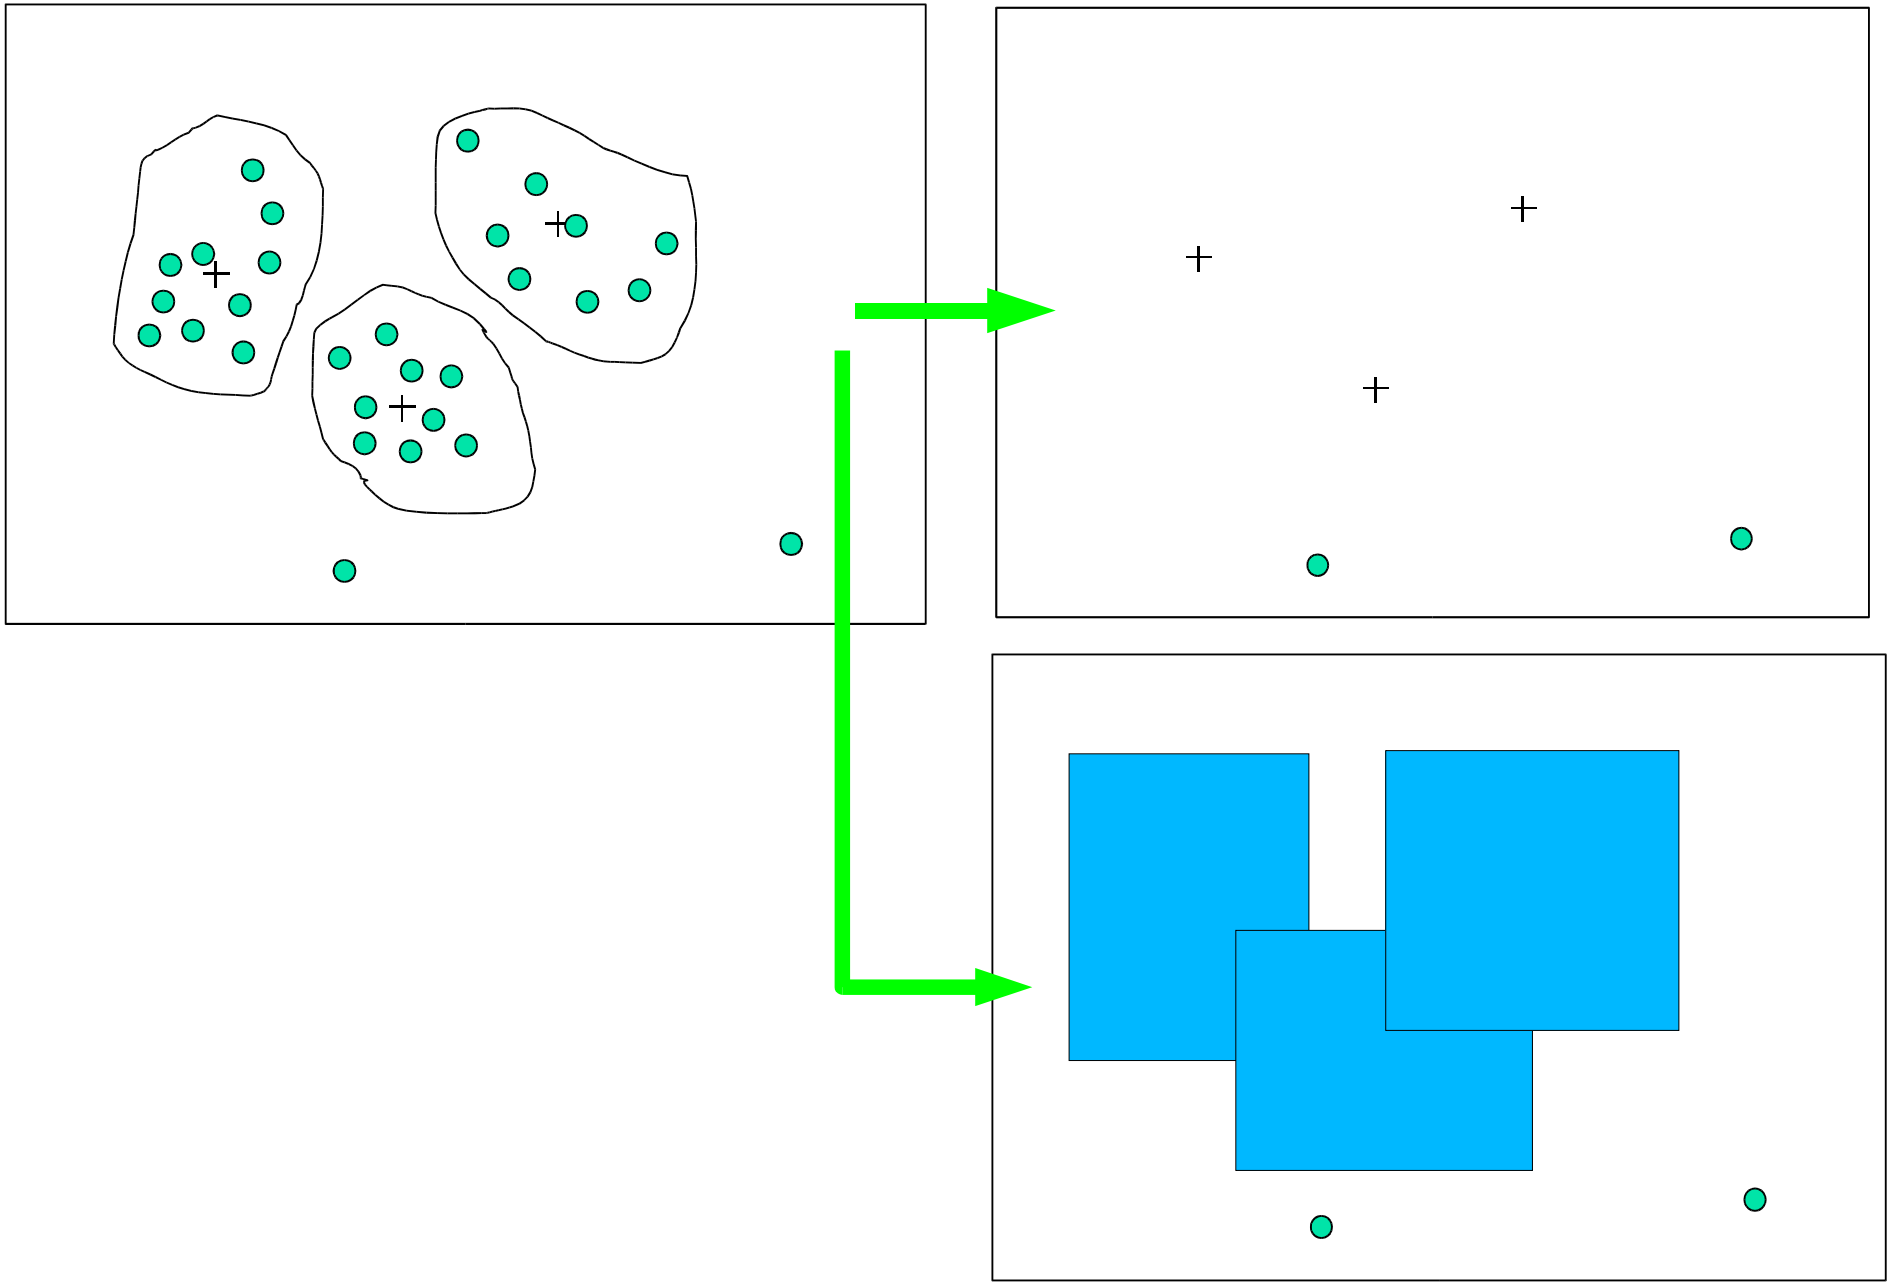

# Campionamento (1)

- Scegliere un sottoinsieme dei dati (campione) per eseguire le analisi.
- Sia N il numero di istanze nel mio insieme di dati D e n il numero di istanze che voglio scegliere per il campione.
  - campionamento semplice senza rimpiazzo:
    - scelgo n < N istanze da D. In ogni scelta, tutte le istanze hanno uguale probabilità, e non è possibile scegliere due volte la stessa istanza.
  - campionamento semplice con rimpiazzo
    - come sopra ma è possibile scegliere più volte la stessa istanza
- Rischiano di alterare i risultati dell'analisi
- Un vantaggio dei metodi di campionamento è che il costo per ottenere un campione è proporzionale alla dimensione del campione
  - ha dunque complessità sub-lineare rispetto ai dati in input

# Campionamento (2)

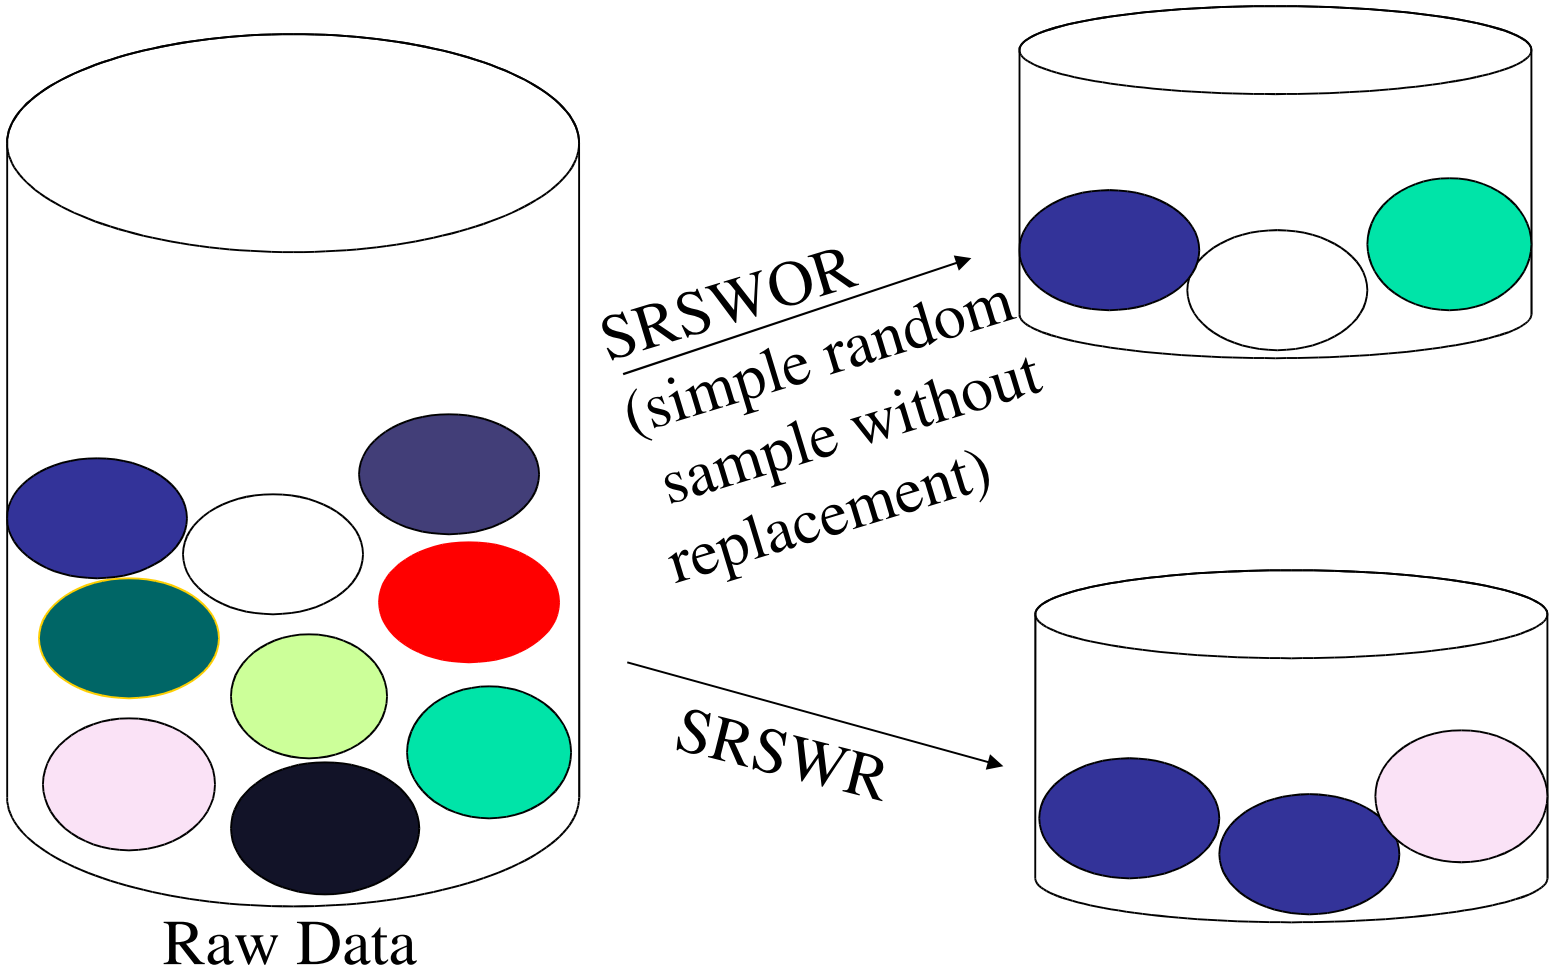

# Campionamento (3)

- Campionamento stratificato
  - i dati sono divisi in gruppi disgiunti $G_1 \ldots G_k$ chiamati strati
  - scelgo da ogni gruppo $G_i$ un campione proporzionale alla dimensione di $G_i$ (ovvero scelgo $n*|G_i|/N$ elementi)
  - per problemi di classificazione, gli stati corrispondono alle classi.

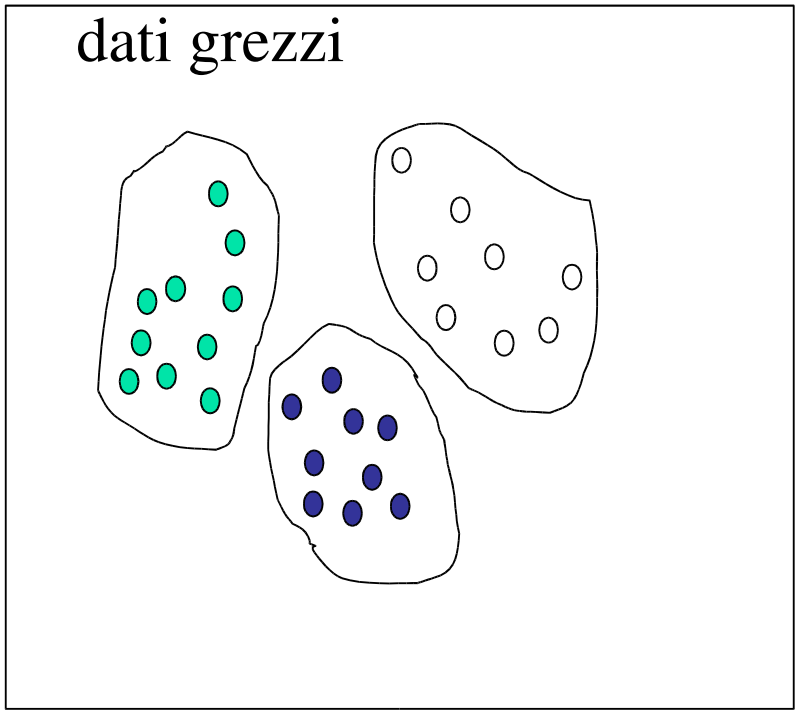


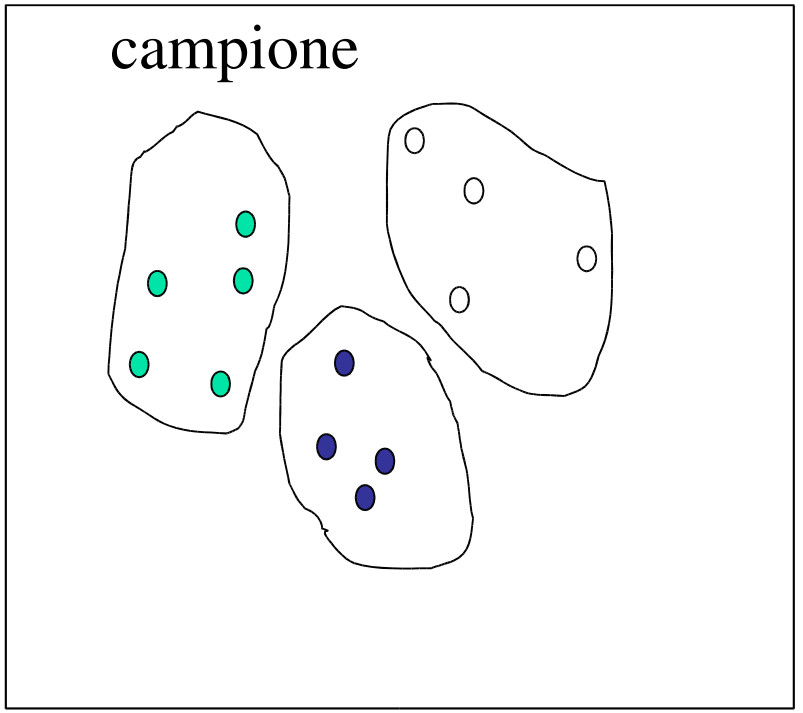

# Discretizzazione e gerarchie di concetti

# Discretizzazione

- Consiste nel ridurre il numero di possibili valori diversi che assume un attributo
  - si divide il range dell'attributo in intervalli o comunque in sottoinsiemi
  - si sostituisce ai dati originali una etichetta che rappresenti l'intervallo o il sottoinsieme a cui appartiene
  - può migliorare l'efficienza di alcuni algoritmi di analisi
- Si può applicare la discretizzazione in maniera ricorsiva per ottenere una gerarchia di concetti
- Alcuni metodi per valori numerici
  - binning (già visto come algoritmo di data cleaning)
  - discretizzazione basata sull'entropia
  - segmentazione per partizionamento naturale

# Binning

- Binning
  - si procede come nel caso della pulizia dati
  - oltre a rimpiazzare i dati con un valore caratteristico del bin a cui esso appartiene (media, mediana, estemi o altro), spesso lo si sostituisce con una “etichetta” che rappresenta l'intervallo di valori che esso assume
  - Esempio: 4, 8, 9, 15, 21, 21, 24, 25, 26, 28, 29, 34
    - Partizionamento equi-depth in intervalli di 4 elementi (d=4)
      - Bin 1: 4, 8, 9, 15
      - Bin 2: 21, 21, 24, 25
      - Bin 3: 26, 28, 29, 34
    - Intervalli ottenuti: [-4,18),[18,25.5),[25.5,34]
    - gli estremi di ogni intervallo sono stati posti a metà tra il massimo valore del bin corrispondente e il minimo del successivo.

# Discretizzazione ed entropia (1)

- Si applica tipicamente come preliminare alla classificazione
  - esiste un attributo “classe” per il calcolo dell'entropia
- Ogni valore *v* di un attributo A è una possibile frontiera per la divisione negli intervalli $A < v$ e $A \geq v$.
- Scelgo il valore che mi da il maggiore guadagno di informazione IG(S,*v*) definito come la differenza tra
  - l'entropia dell'insieme S dei dati iniziali: E(S)
  - l'entropia media dopo il partizionamento.

$$E(S,v)=\frac{|S_1|}{|S|}Ent(S_1)+\frac{|S_2|}{|S|}Ent(S_2)$$

dove $S_1$ ed $S_2$ sono gli insiemi corrispondenti alle condizioni $A < v$ e $A \geq v$ rispettivamente.

  - I(S,v)=E(S) - E(S,v)

# Discretizzazione ed entropia (2)

- Il processo si applica ricorsivamente ai sotto-intervalli così ottenuti, fino a che non si raggiunge una condizione di arresto
  - ad esempio, fino a che il guadagno di informazione che si ottiene diventa inferiore a una certa soglia *d*
- Supponiamo di avere le classi "s" ed "n" e l'insieme S costituito dalle seguenti coppie: (0, s), (2,n), (30,n), (31,n), (32,s), (40,s).
  - Calcoliamo le varie entropie condizionate:
    - E(S,0)=1 E(S,2)=0.87 E(S,30)=1 E(S,31)=0.92
    - E(S,32)=0.54 E(S,40)=0.81
  - Il guadagno di informazione maggiore si ha generando i sotto-intervalli A < 30 e A≥30
- Spesso, piuttosto che dividere sul valore ottenuto (30), si divide sul valore di mezzo tra quello ottenuto e il precedente
  - in questo caso si avrebbe A<16 e A ≥16

# Partizionamento naturale (1)

- I metodi precedenti danno spesso intervalli innaturali
  - intervalli del tipo (€50.000-€60.000) sono più desiderabili di intervalli del tipo (€51.492-€60.872).
- la regola 3-4-5 può essere usata per generare intervalli naturali
- in linea di massima, il metodo divide un dato intervallo in 3, 4 o 5 sotto-intervalli diversi, ricorsivamente a seconda dell'intervallo di valori assunti dalla cifra più significativa
  - se l'intervallo copre 3, 6, 7 o 9 valori distinti della cifra più significativa, partiziona l'intervallo in 3 intervalli
    - di uguale ampiezza per 3, 6 o 9 valori di stinti
    - nella proporzione 2-3-2 per 7 valori distinti
  - per 2, 4 o 8 valori distinti, partiziona i dati in 4 intervalli.
  - per 1, 5 o 10 valori distinti, partiziona i dati in 5 intervalli.

# Partizionamento naturale (2)

- Se  l'attributo A varia da -199 a 1838:
  - si arrotondano gli estremi dell'intervallo alla cifra più significativa, ottenendo l'intervallo (-1000,2000]
  - l'intervallo copre 3 cifre significative diverse
    - (2000-(-1000))/1000=3
    - si divide in 3 sotto-intervalli (-1000,0], (0,1000], (1000,2000]
  - si procede ricorsivamente (se si vuole)
- la regola funziona male se ci sono valori estremi molto diversi dai valori medi.. in tal caso, si può usare per partizionare solo i dati dal 5° al 95° percentile

# Partizionamento naturale (3)

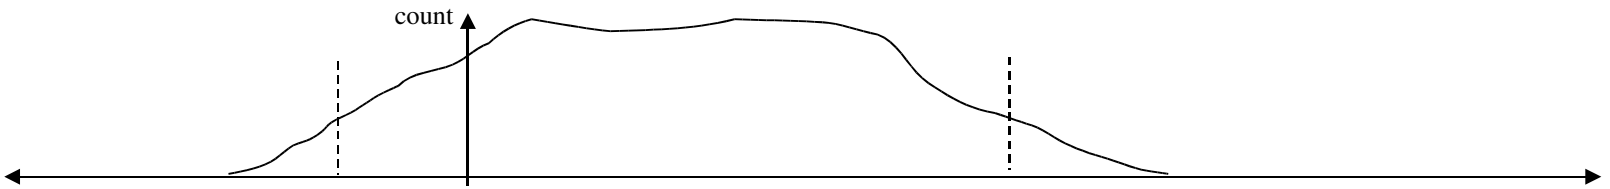


Step 1: -$351 -$159 profit $1,838 $4,700

Min Low (i.e, 5%-tile) High(i.e, 95%-0 tile) Max

Step 2: msd=1,000 Low=-$1,000 High=$2,000

Step 3:

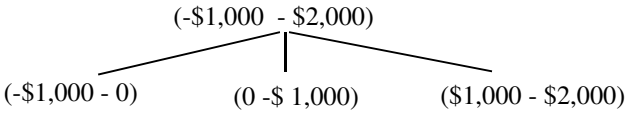


Step 4:

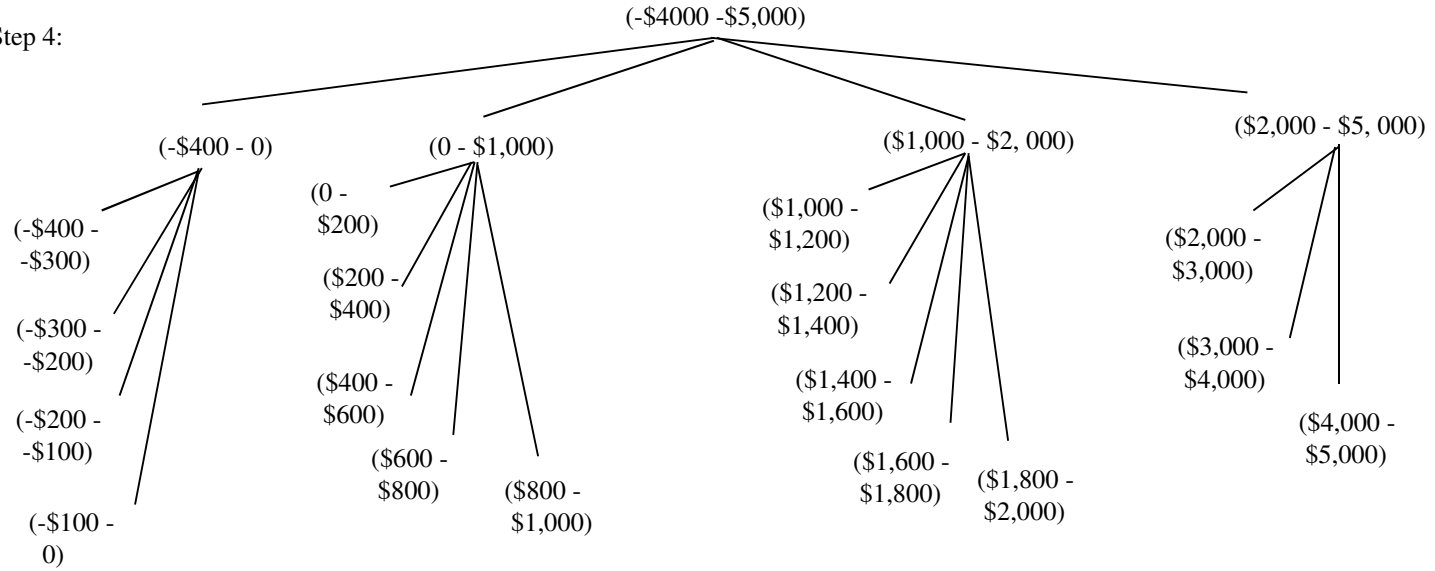

# Discretizzazione per attributi categoriali

- I metodi visti prima funzionano per attributi numerici
  - e per gli attributi categoriali?
- Abbiamo già visto i concetti di
  - schema hierarchy: la gerarchia è data specificando un ordine tra gli attributi
  - set-grouping hierarchy: la gerarchia è data specificando a mano la gerarchia
- Esistono possibilità intermedie
  - specificare gli attributi da usare per la gerarchia ma non l'ordinamento.
    - l'ordinamento è ricercato automaticamente, basandosi sul numero dei distinti valori assunti dagli attributi

# Discretizzazione per attributi categoriali (2)

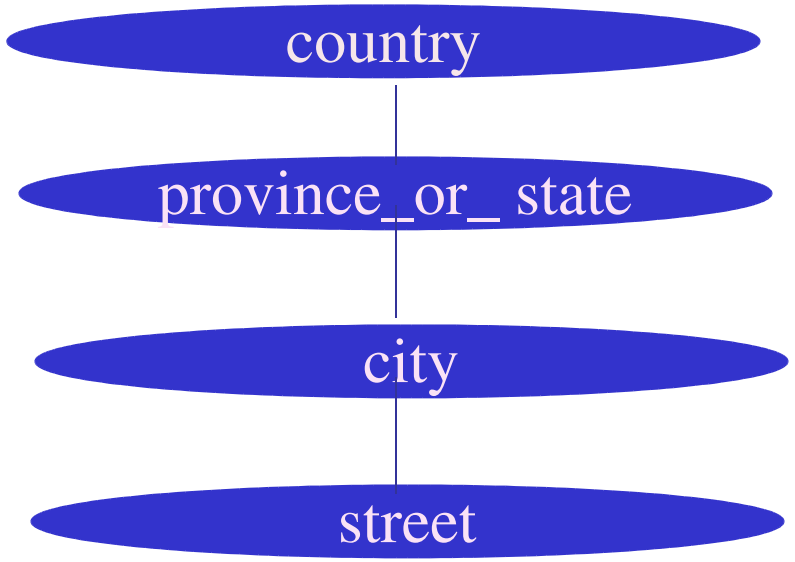


15 valori distinti

65 valori distinti

3567 valori distinti

674,339 valori distinti