Data mining
Introduzione

Elena Baralis
Politecnico di Torino

Knowledge discovery

- Processo di estrazione dai dati di pattern
  - validi
  - precedentemente ignoti
  - potenzialmente utili
  - comprensibili

[Fayyad, Piatesky-Shapiro, Smyth 1996]

Esempio

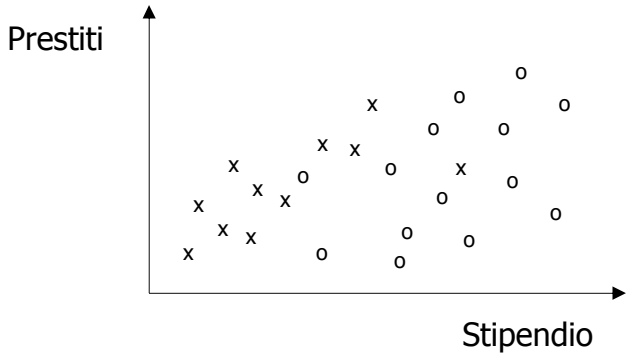

Persone che hanno ricevuto un prestito dalla banca:
x: persone che hanno mancato la restituzione di rate
o: persone che hanno rispettato le scadenze

Knowledge discovery

- Dati: insieme di informazioni contenute in una base di dati o data warehouse
- Pattern: espressione in un linguaggio opportuno che descrive in modo succinto le informazioni estratte dai dati
  - regolarità
  - informazione di alto livello

Esempio

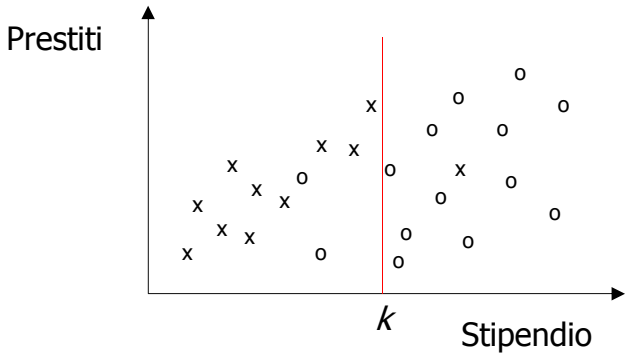

If stipendio < *k*$ **then** mancati pagamenti

Elena Baralis
Politecnico di Torino

Caratteristiche dei pattern

- Validità: i pattern scoperti devono essere validi su nuovi dati con un certo grado di certezza
  - Esempio: spostamento a destra del valore di k porta riduzione del grado di certezza
- Novità: misurata rispetto a variazioni dei dati o della conoscenza estratta

Elena Baralis
Politecnico di Torino

Caratteristiche dei pattern

- Utilità
  - Esempio: aumento di profitto atteso dalla banca associato alla regola estratta
- Comprensibilità: misure di tipo
  - sintattico (numero di bit del pattern)
  - semantico

Processo di estrazione

- Richiede l'esecuzione di un insieme di passi
  - preparazione dei dati, ricerca dei pattern, valutazione dell'informazione estratta, raffinamenti
  - operazioni non "ovvie"

Processo di estrazione

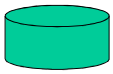

Dati

Sviluppo della conoscenza del dominio applicativo

Processo di estrazione

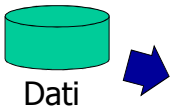

Dati

Passo di selezione dei dati:
focalizzazione su un sottoinsieme
significativo dei dati

Processo di estrazione

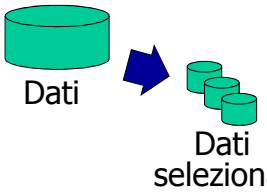

Passo di preelaborazione dei dati:
- rimozione di rumore o eccezioni
- gestione dati mancanti
- pulizia dei dati

Processo di estrazione

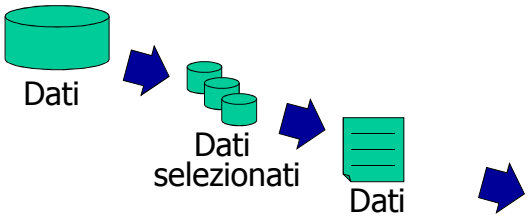

Passo di trasformazione dei dati: riduzione del numero di variabili da considerare

Processo di estrazione

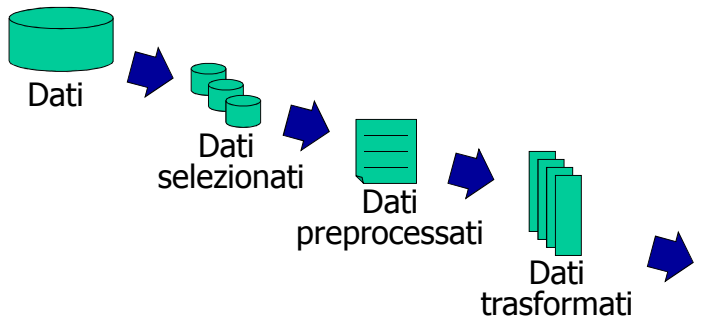

Passo di data mining:
- selezione del tipo di estrazione
- selezione dell'algoritmo

Processo di estrazione

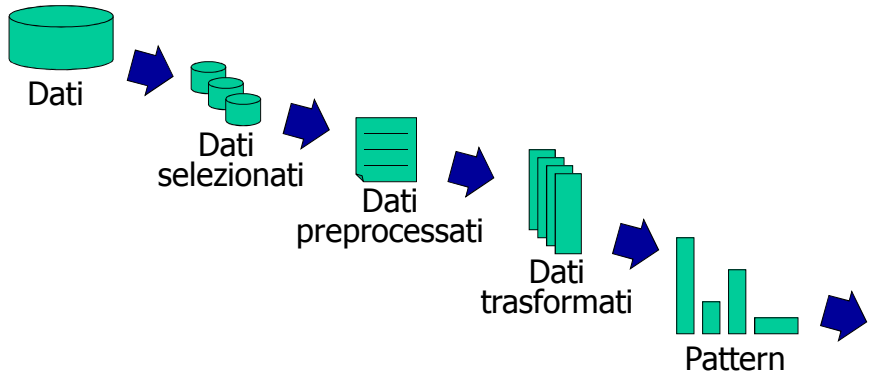

Passo di interpretazione e valutazione

Processo di estrazione

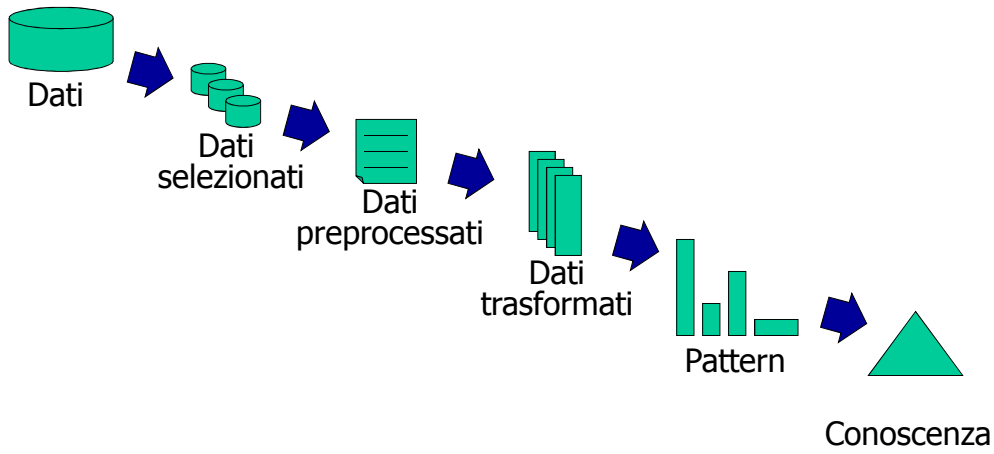

Data mining
Preparazione dei dati

Elena Baralis
Politecnico di Torino

Passi principali

- Pulizia dei dati
  - dati incompleti
  - dati rumorosi
  - riconoscimento di outliers ed eccezioni
  - gestione delle inconsistenze
- Integrazione dei dati
- Trasformazione dei dati
  - normalizzazione
  - aggregazione
- Riduzione dei dati
  - rappresentazione ridotta in volume, che genera risultati analitici simili
    - discretizzazione
    - campionamento

Dati incompleti

- Mancanza del dato dovuta a cause diverse,tipicamente legate al processo di data entry
  - malfunzionamento di strumenti
  - non inserito perché non importante
- Soluzioni
  - ignorare la tupla con informazione mancante
  - usare un valore speciale (NULL, N/A)
  - usare come valore il valor medio dell'attributo
  - usare come valore il valor medio dell'attributo all'interno della stessa classe

Dati rumorosi

- Errori casuali o varianza significativa di una misura
  - malfunzionamento di strumenti/trasmissione in rete
  - limitazioni tecnologiche
  - problemi di data entry
- Soluzioni
  - clustering o regressione per riconoscere ed eliminare gli outliers
  - discretizzazione

Elena Baralis
Politecnico di Torino

Clustering

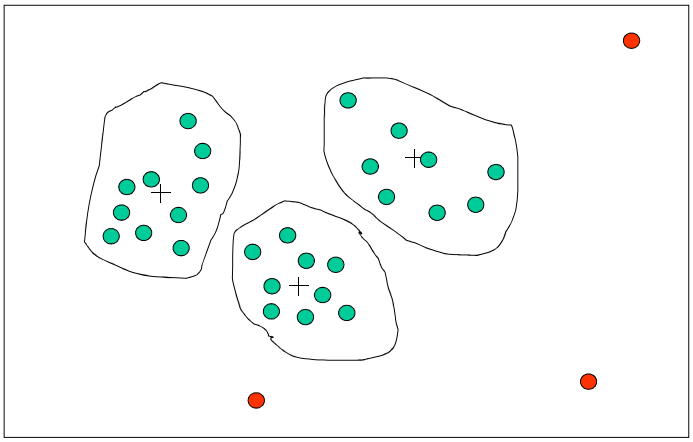

Tratto da Han, Kamber,"Data mining; Concepts and Techniques", Morgan Kaufmann 2006

Elena Baralis
Politecnico di Torino

Regressione

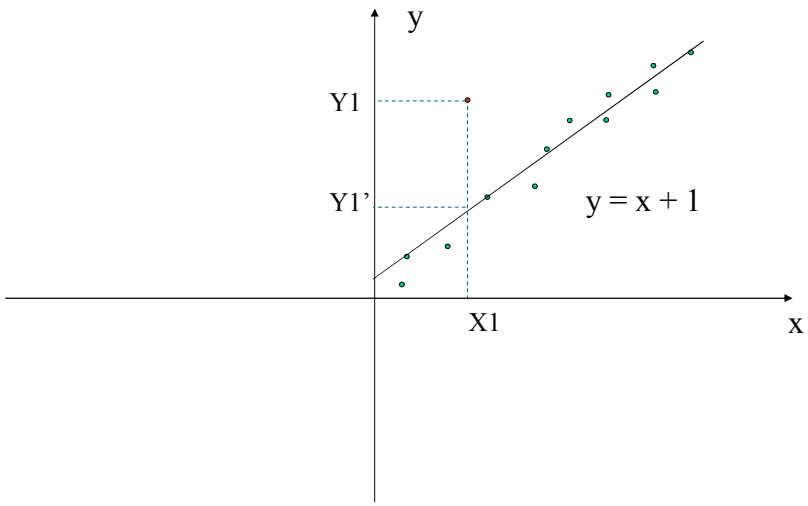

Tratto da Han, Kamber,"Data mining; Concepts and Techniques", Morgan Kaufmann 2006

Normalizzazione dei dati

- È un tipo di trasformazione dei dati
  - i valori di un attibuto sono riportati in un intervallo prefissato
    - tipicamente (-1,+1) o (0,+1)
- Tecniche
  - min-max

$$v' = \frac{v - min_A}{max_A - min_A}(new\_max_A - new\_min_A) + new\_min_A$$

  - z-score

$$v' = \frac{v - mean_A}{stand\_dev_A}$$

  - scalamento decimale

$$v' = \frac{v}{10^j}$$ j intero minimo tale che max(|v'|)< 1

Riduzione dei dati

- Generazione di una rappresentazione ridotta in volume, che genera risultati analitici simili
  - campionamento
    - riduzione della cardinalità dell'insieme
  - feature selection
    - riduzione del numero di attributi
  - discretizzazione
    - riduzione della cardinalità del dominio di un attributo

Campionamento

- Selezione di un sottoinsieme (campione) dei dati di partenza
  - rappresentativo
  - riduce la complessita` degli algoritmi di data mining
  - non sempre riduce effettivamente il numero di I/O di pagine
- Modalita`
  - campionamento casuale
    - senza sostituzione
    - con sostituzione
  - campionamento stratificato
    - per ogni sottoclasse di interesse, il campione contiene una frazione proporzionale alla popolazione della sottoclasse nella base dati di partenza
    - appropriato per dati con distribuzione non uniforme

Campionamento

Dati di partenza

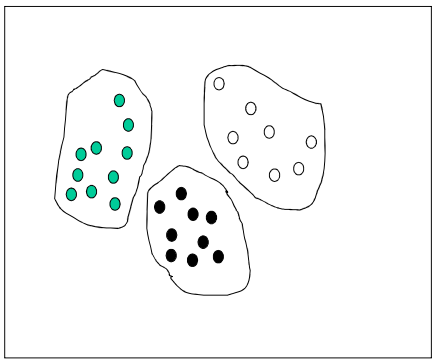

Campionamento stratificato

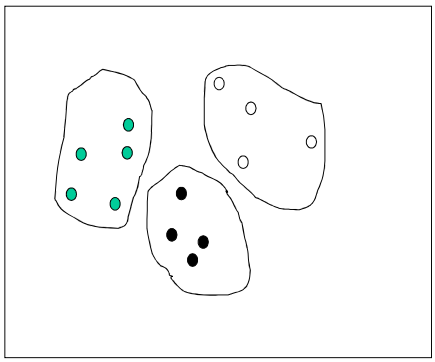

Tratto da Han, Kamber,"Data mining; Concepts and Techniques", Morgan Kaufmann 2006

Feature selection

- Selezione di un sottoinsieme degli attributi che fanno parte dello schema di partenza
  - selezione di un insieme minimo di attributi tale da conservare la distribuzione dei dati di partenza
  - utile specialmente per gli algoritmi di clustering
- Causa anche una riduzione del numero di pattern estratti
  - maggiore interpretabilita` del risultato
- Tecniche euristiche
  - esplorazione esaustiva impossibile a causa del vasto numero di scelte possibili
  - si aggiunge/toglie un attributo alla volta e si osserva l'effetto

Discretizzazione

- Divisione del dominio di un attributo continuo in un insieme di intervalli
  - riduce la cardinalità del dominio di un attributo
- Tecniche
  - N intervalli con la stessa ampiezza $W=(v_{max} - v_{min})/N$
    - semplice
    - sensibile agli outliers e ai dati sparsi
    - incrementale
  - N intervalli con (approssimativamente) la stessa cardinalità
    - si adatta meglio a dati sparsi e outliers
    - non incrementale
  - clustering
    - si adatta bene a dati sparsi e outlier

Discretizzazione

Prezzo	Ampiezza (W=10)	Cardinalità (N=2)	Clustering
7	[0,10]	[7,20]	[7,7]
20	[11,20]	[22,50]	[20,22]
22	[21,30]	[51,53]	[50,53]
50	[31,40]		
51	[41,50]		
53	[51,60]		