

Metodi di Esplorazione e Sommazione

Metodi descrittivi d'apprendimento

Regolarità locale

Regole d'Associazione

Mining di Sottogruppi

Modelli globali

Clustering

Regole d'Associazione

Obiettivo generale

Compito della Ricerca

Attributi Binari

Apriori algoritmo

Insiemi Frequenti

Problemi

Supplementi

Obiettivi di Regole d'Associazione

Obiettivo generale: Sopportare esplorazioni

Trovare associazioni fra valori di variabili
dipendenze fra variabili: associazioni, correlazioni

Analizzare transazioni: merce comprate in stessa transazione
parole in un testo, errori in un rete, ... "items" ricorrendo insieme

Se si comprano pizza e birra, è probabile che si compra anche chips.
Ordinare merce in mercato. Offrire prodotti ai clienti...

Introdotta da Agrawal, Mannila 1996 e poi soggetto pre-
dominante di data mining, ma non dominante in pratica

Compito: Regole d'Associazione

Sia I un insieme d'oggetti (items)

e T un insieme di transazioni $t \in T: t \subset I$

s_{min} minimale frequenza (supporto) e c_{min} minimale confidenza
 $0 < s_{min}, c_{min} \leq 1$ (scelti dall'utente)

Il compito è: trova tutte le regole $r := X \rightarrow Y$

$X \subset I, Y \subset I \quad X \cap Y = \emptyset$

$s(r) := |\{t \in T \mid X \cup Y \subset t\}| / |T| \geq s_{min}$

$c(r) := |\{t \in T \mid X \cup Y \subset t\}| / |\{t \in T \mid X \subset t\}| \geq c_{min}$

valori tipici: $s_{min} = 0.01$ $c_{min} = 0.5$ $\{pizza, birra\} \rightarrow \{chips\}$

almeno il 1 percento dei clienti hanno comprato pizza, birra, chips

almeno il 50 percento dei clienti che hanno comprato pizza, birra

hanno anche comprato chips

Regole d'Associazione: Attributi binari

Sia $R=\{A_1, \dots, A_p\}$ uno schema d'attributi binari
e r una relazione su R

$X \subset R, Y \subset R, X \cap Y = \emptyset$

s_{min} minimale frequenza (supporto) e c_{min} minimale confidenza
 $0 < s_{min}, c_{min} \leq 1$ (scelti dall'utente)

Il compito è: trova tutte le regole $r := X \rightarrow Y$

$X = \{A_{i_1}, \dots, A_{i_k}\} \quad Y = \{B\} \quad r := A_{i_1}=1 \wedge \dots \wedge A_{i_k}=1 \rightarrow B=1$

attributi categoriali: selettori $A=a$
mà: esplosione di *frequent set*

Algoritmo Apriori

APRIORI(I, T, s_{min}, c_{min})

trova $L :=$ insiemi-frequenti(I, T, s_{min}) frequent sets

trova $R :=$ regole (L, c_{min})

Un insieme $X \subset I$ è frequente := $s(X) := |\{t \in T \mid X \subset t\}| / |T| \geq s_{min}$

Il spazio degli insiemi $X \subset I$ è parzialmente ordinato

$X < Y ::= X \subset Y \quad X \cup \{a\}$ successore (diretto) di X

1) X non è frequente, Y successore di X ($X < Y$) $\Rightarrow Y$ non è frequente

2) $c(X \rightarrow Y) = s(X \cup Y) / s(X)$

3) $c(X \rightarrow Y \cup Z) \leq c(X \rightarrow Y)$

Insiemi Frequenti

insiemi-frequenti(I, T, s_{min})

$k:=1, C_k := \cup \{i\} \mid i \in I, L_k := \text{pota}(C_k, T)$

while $L_k \neq \emptyset$

$C_{k+1} := \text{genera-candidati}(L_k)$

$L_{k+1} := \text{pota}(C_{k+1}, T)$

$k := k+1$

return $\cup L_j \mid j=1, \dots, k$

pota (C_k, T) verifica per ogni insieme $X \in C_k$, se X è frequente

genera-candidati(L_k) include gli insiemi X con $k+1$ oggetti, così che ogni sottoinsieme Y di X con k oggetti è elemento di L_k

Problemi

Efficienza:

una transazione contiene pochi oggetti --->

numero d'insiemi frequenti non è esponenziale e cala con k

mà: nessun frequent set con più di ca. 15 oggetti:

se esiste un frequent set con K oggetti, poi ci sono almeno 2^K set

Abbondanza delle regole

migliaia di regole

Ridondanza delle regole

p.e. una regola più speciale ha una confidenza più bassa

Valutazione d'una regola è troppo semplice

confidenza: c_{min} indipendente dalla frequenza della conclusione

Supplementi

Efficienza

minimizzare gli scan (passi) per la banca dati
organizzazione d'insiemi frequenti con alberi di hash (nodi: items)
campionamento, integrazione nella banca dati

Abbondanza delle regole

tassonomie d'oggetti

Ridondanza delle regole

sistema minimale di regole

Valutazione d'una regola è troppo semplice

valutazioni statistiche

Regole di sequenze

insieme ordinato d'oggetti (tempo): web pagine visitate, errori in rete

Clustering

Sono dati N vettori di d dimensioni (d attributi e N oggetti)
Trova spartizione *ragionevole* dei N esempi in c sottoinsiemi

Gli oggetti d'un sottoinsieme (cluster) sono i più simili possibili
e oggetti di differenti cluster sono i più dissimili possibili

Il metodo deve scoprire le classi, raggruppando oggetti simili
(=con valori simili degli attributi) nella stessa classe/cluster

c dato o scoperto dall'algoritmo

Non esistono attributi target

Usato come

- descrizione sommaria
- fondamento per modelli predittivi più accurati

Clustering: Esempio

Ci vuole pochi cluster omogenei e non un gran numero d'oggetti

oggetti: i clienti d'un'impresa
cluster: gruppi omogenei di clienti
azioni di marketing specifici per i gruppi

I gruppi (cluster) non solo vengono definiti di liste d'oggetti appartenenti
ma idealmente sono descritti da comprensibili e compatte caratteristiche

gente con figli abitando in campagna
gente anziana con reddito alto
laureati lavorando in servizio pubblico

Clustering: Metodi

- Metodi Numerici

variabili numeriche sono dominanti
distanza, centroido, media, correlazioni ...

- spartizioni
- gerarchie
- componenti di densità (modelli probabilistici)

- Metodi Concettuali

variabili categoriali sono dominanti
descrizioni caratteristiche vengono derivate

Spartizioni

Sia X un insieme d'oggetti e $S \subseteq X$ un insieme d'esempi
 $\text{dist}: X \times X \rightarrow \mathbb{R}^+$ una funzione di distanza

$q: 2^S \rightarrow \mathbb{R}^+$ una funzione di qualità (per un insieme di sottoinsiemi)

Il compito di analisi di clustering:

Trova $C = \{C_1, \dots, C_k\}$ $C_i \subseteq S$ così che $q(C)$ sia massimo

tipicamente una spartizione: $C_i \cap C_j = \emptyset \quad \cup C_i = S$

q viene definito in base a *dist*

p.e. $q := -\sum d(C_i)$ $d(C_i) := \sum \text{dist}(x,y) / m_i$ $x,y \in C_i$ $m_i := |C_i|(|C_i|-1)/2$
o la distanza media dal centro (centroido)

Spartizioni: Problemi

Come definire la funzione di distanza?

Come pesare gli attributi?

Il numero delle spartizioni è super-esponenziale,
solo una ricerca semplice (greedy search)

Spartizioni: k-Means

k viene dato dall'utente

supposizione: si può definire il centro z d'un insieme C d'oggetti

col minima somma di distanze a tutti gli oggetti di C , non necessariamente $z \in C$

p.e. $z(C) := \sum_{c \in C} c / |C|$ $c \in C$ c vettore numerico

k-Means(S,k) (tipicamente con convergenza rapida)

$Z = \{z_1, \dots, z_k\}$ k esempi selezionati casualmente

while qualità diventa migliorata

$C_i := \{s \in S \mid i = \operatorname{argmin}_{j=1, \dots, k} \operatorname{dist}(s, z_j)\}$ $i=1, \dots, k$

$z_i := z(C_i)$ $i=1, \dots, k$

end

return $\{C_1, \dots, C_k\}$

Qualità = (negativa) somma delle medie di distanze ai centri

Problema: convergenza in un minimo locale; diverse iniziazioni

outlier formano cluster singolari

Spartizioni: Componenti algoritmici

Funziona di qualità: come è buona la spartizione?

omogeneità dei cluster / similarità degli oggetti

p.e. errore quadrato (distanza dal centro)

o medio errore

Algoritmo di ricerca: k centri dei cluster con ottima qualità

p.e. iterativo:

aggrega oggetti al prossimo centro, calcola nuovo centro

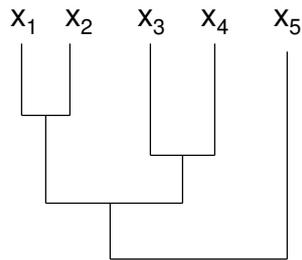
Rappresentazione del cluster: centro del cluster

Gerarchie

Matrice di distanza: $N \times N$ paia d'oggetti

Seria di clustering: bottom up, da cluster d'un solo oggetto a un solo cluster

Dendogrammo:



Agglomerazione

I cluster più simili vengono agglomerati ad un nuovo cluster

Distanza di due cluster con un solo oggetto:= distanza dei due oggetti

$$\text{dist}(C_1 \cup C_2, C_3) = f(\text{dist}(C_1, C_3), \text{dist}(C_2, C_3))$$

$f = \min$: single linkage clustering, distanza basata su prossimi oggetti: catene

$f = \max$: complete linkage clustering cluster compatti

$f = \text{average}$: average linkage clustering

Problema: $O(N^2)$ Dati non voluminosi, p.e. $N < 10^4$

Metodi di spartizioni: quasi $O(N)$

Scalabilità: campionamento

Clustering di Densità

Supposizione

k cluster di oggetti

Distribuzione di S è una combinazione di k componenti distribuzioni (somma lineare, pesata)

p.e distribuzioni multinomiali (normali) di variabili categoriali (continue)

I parametri delle distribuzioni sono sconosciuti (p.e. media, varianza)

Funziona di qualità:

Likelihood: probabilità dei dati osservati dipendente di parametri

Trova parametri, così che la probabilità sia massima

Parametri: parametri delle distribuzioni, pesi, k

Problema d'ottimizzazione nonlineare difficile: EM algoritmo expectation max.

Probabilità per un oggetto di appartenere ad un cluster, nessun assegnazione ad un solo cluster

Autoclass (Cheeseman)

Densità: Pros e Cons

+ Non richiede una misura di distanza

– Supposizioni su modello probabilistico sono ragionevoli?

A priori conoscenze sull'applicazione sono necessarie per specificare la forma funzionale delle distribuzioni. Può essere difficile, ma obbliga utente di specificare esplicitamente le supposizioni.

+ Funziona di qualità è una misura naturale

probabilità dei dati osservati dipendente dei parametri

– Spazio dei parametri è voluminoso

Clustering Concettuale

Aggiungere ad un metodo numerico di clustering un metodo d'apprendimento di concetti, derivando per ogni cluster una descrizione che generalizza i suoi oggetti.

Ma esiste una buona descrizione per ogni cluster numerico?

Metodi concettuali di clustering ricercano cluster in uno spazio di descrizioni Automatica interpretazione d'un clustering

Michalski, Stepp: Star, Cluster/2

Origine:

apprendimento supervisionato di concetti disgiuntivi da esempi solo positivi

Componenti: rappresentazione, qualità, ricerca

Valutare un Clustering predictability

Categorizzare un oggetto nuovo:

determinare il cluster a cui appartiene l'oggetto

clustering concettuale: verificare la descrizione

(clustering numerico: distanza ai centri del clustering)

Predire i valori degli attributi per un membro di un cluster

p.e. attributi sconosciuti d'un oggetto classificato (valori mancanti)

gerarchie offrono migliori predizioni

trade-off per una valutazione di un attributo, dato un clustering:

predictability: dato il cluster a cui appartiene oggetto, predire valore mancante per un attributo

predictiveness: determinare cluster con il valore d'un attributo

Valutare clustering: valutare predictability per tutti gli attributi



Clustering Concettuale: Componenti

Rappresentazione

cluster=sottogruppo (paia d'attributo-valore)

cluster probabilistico (Autoclass, Cobweb): distribuzioni probabilist. (valori attr.)

spartizioni (Cluster/2; Michalski, Stepp) / gerarchie/ intersezioni fra cluster overlap

Qualità

predictability vs. predictiveness (Autoclass, Cobweb)

funzioni lexicografiche di valutazione (LEF lexicographic evaluation functions):
criteri ordinati, granularità (Michalski)

Ricerca

incrementiva e partizionante:

associare un cluster per un altro oggetto, partizionare cluster se necessario

dipende dal collocamento d'oggetti: raffinamento iterativo necessario

STAR: Operatori di specializzazione (p.e. aggiungi selettore) / generalizzazione