

Regole associative

Regole associative

- Le regole associative descrivono correlazioni di eventi e possono essere viste come regole probabilistiche.
- Due eventi sono correlati quando sono frequentemente osservati insieme.
- Esempio: database di transazioni di vendita in un supermercato. Le regole associative in questo caso descrivono quali oggetti sono frequentemente acquistati insieme
 - Panettone=>spumante
 - Pannolini => birra

2

Regole associative

Regole associative

- Il problema della scoperta di regole associative può essere espresso come segue
- Sia $I = \{i_1, i_2, \dots, i_m\}$ un insieme di letterali chiamati **oggetti** (o **items**).
- Una **transazione** T è un insieme di oggetti tali che $T \subseteq I$. Un **database di transazioni** D è un insieme di transazioni ed è solitamente memorizzato in una tabella della forma

Identificativo della transazione	Item
----------------------------------	------

- Un **itemset** X è un set di oggetti tali che $X \subseteq I$. Si dice che una transazione T **contiene** un itemset X se $X \subseteq T$.

- Il **supporto** di un itemset X (supporto(X)) è la frazione di transazioni in D che contiene X
$$\text{supporto}(X) = \frac{\text{transazioni che contengono } X}{\text{numero totale di transazioni}}$$
- Una **regola associative** è una implicazione della forma $X \Rightarrow Y$, dove X e Y sono itemsets e $X \cap Y \neq \emptyset$.

3

4

Confidenza e supporto

- $X \Rightarrow Y$ ha **supporto** s nel database D se e solo se una frazione pari ad s delle transazioni in D contengono $X \cup Y$:

$$s = \text{supporto}(X \Rightarrow Y) = \text{supporto}(X \cup Y)$$

- $X \Rightarrow Y$ ha **confidenza** c nel database D , se e solo se, tra tutte le transazioni che contengono X , ce n'è una frazione c che contengono anche Y :

$$c = \text{confidenza}(X \Rightarrow Y) = \frac{\text{supporto}(X \cup Y)}{\text{supporto}(X)}$$

- Confidenza e supporto possono essere indicati anche in forma percentuale

5

Esempi

- $1 \ \&2 \Rightarrow 3$ ha il 90% di confidenza se, quando un cliente ha comperato gli oggetti 1 e 2, nel 90% dei casi has comperato anche 3
- $1 \ \&2 \Rightarrow 3$ ha il 20% di supporto se il 20% delle transazioni contiene 1, 2 e 3. Indica la frazione dei casi nei quali la regola si applica

6

Esempio

Transaction ID	Purchased Items
1	{1, 2, 3}
2	{1, 4}
3	{1, 3}
4	{2, 5, 6}

- Per supporto minimo 50% e confidenza minima 50% abbiamo le seguenti regole
- $1 \Rightarrow 3$ con supporto 50% e confidenza 66%
- $3 \Rightarrow 1$ con supporto 50% e confidenza 100%

7

Regole associative

- Dato un database D , il compito di scoprire le regole associative può essere riformulato come segue:
 - scoprire tutte le regole associative con almeno un minimo supporto (chiamato **minsup**) e una minima confidenza (chiamata **minconf**), dove minsup e minconf sono valori specificati dall'utente
- Il compito di scoprire regole associative può essere decomposto in due sottoproblemi:
 - Trovare tutti gli itemset che hanno supporto sopra il minimo. Tali itemset sono chiamati **itemset grandi**. Questo sottoproblema è risolto dall'algoritmo APRIORI
 - Generare tutte le regole associative con almeno il supporto minimo dall'insieme degli itemset grandi

8

Regole associative

- Il secondo sottoproblema è risolto dal seguente algoritmo:
 - Per ciascun itemset grande A, trova tutti i sottoinsiemi non vuoti
 - Per ciascun sottoinsieme X di A, genera la regola $X \Rightarrow (A-X)$ se e solo se il rapporto tra il supporto di A e il supporto di X è almeno minconf

9

Esempio

Transaction ID	Purchased Items
1	{1, 2, 3}
2	{1, 4}
3	{1, 3}
4	{2, 5, 6}

- Supporto minimo 50%=2 transazioni e confidenza minima 50%

Frequent Itemsets	Support
{1}	75%
{2}	50%
{3}	50%
{1,3}	50%

- Per la regola $1 \Rightarrow 3$
 - Supporto=supporto({1,3})=50%
 - Confidenza=supporto({1,3})/supporto({1})=66%

10

Supporto: proprietà'

- Il supporto di un itemset e' sempre inferiore a quello di ciascuno dei suoi sottoinsiemi propri
- Infatti le transazioni che contengono un insieme X saranno un sottoinsieme di quelle che contengono X piu' qualche altro item
- Quindi: se un sottoinsieme proprio X di un itemset A non e' grande, allora neanche A puo' essere grande
- Esempio: {1,2} non e' grande quindi {1,2,3} non puo' essere grande

11

Supporto: proprietà'

- Non e' pero' vero il viceversa, ovvero che se tutti i sottoinsiemi propri di un itemset A sono grandi allora A e' grande
- Esempio: {1,2} non e' grande, anche se tutti i suoi sottoinsiemi propri {1} e {2} lo sono

12

Algoritmo APRIORI

Notazione

k-itemset: un itemset con k oggetti.

L_k : insieme dei k-itemsets grandi (quelli con supporto minimo).

```
1.  $L_1 = \{1\text{-itemsets grandi}\};$ 
2. per ( $k=2; L_{k-1} \neq \emptyset ; k++$ ) fai
3.    $C_k = \text{apriori-gen}(L_{k-1});$  // nuovi candidati
4.   Per tutti le transazioni  $t \in D$  fai
5.      $C_t = \text{subset}(C_k, t);$  //candidati contenuti in t
6.     Per tutti gli insiemi candidati  $c \in C_t$  do
7.        $c.\text{count}++;$ 
8.   fine
9.    $L_k = \{c \in C_k \mid c.\text{count} > \text{minsup}\}$ 
10. fine
11.  $\text{Answer} = \bigcup_k L_k$ 
```

13

apriori-gen

- Due passi:
 - Passo di join
 - Passo di potatura

14

Passo di join

- Si assume che gli item negli itemset siano mantenuti in ordine alfabetico sulla base del loro nome
- Un k-itemset puo' essere visto come una tabella con k colonne
- Si genera un itemset di k elementi unendo due itemset grandi di k-1 elementi che hanno i primi k-2 elementi uguali (in questo modo, due sottoinsiemi di k-1 elementi sono sicuramente grandi)

Insert into C_k

Select $p.\text{item}_1, p.\text{item}_2, \dots, p.\text{item}_{k-1}, q.\text{item}_{k-1}$

From L_{k-1} p, L_{k-1} q

Where ($p.\text{item}_1 = q.\text{item}_1$) and and

($p.\text{item}_{k-2} = q.\text{item}_{k-2}$) and ($p.\text{item}_{k-1} < q.\text{item}_{k-1}$)

15

Passo di potatura

- Si eliminano gli itemset che non hanno tutti i sottoinsiemi con k-1 elementi grandi

Per tutti gli itemset $c \in C_k$ fai

Per tutti i (k-1)-sottoinsiemi s di c fai


Se ($s \notin L_{k-1}$) allora

Cancella c da C_k

16

Esempio

Supp. Min.=50%=2 trans.



17

Altra forma del database

- Si possono apprendere regole associative anche da database della forma

Attribute ₁	Attribute ₂	Attribute _n
Value _{1,1}	Value _{1,2}	Value _{1,n}
....
Value _{m,1}	Value _{m,2}	Value _{m,n}

- In pratica, ogni record è considerato come una transazione e ogni possibile uguaglianza Attributo=Valore un item

18

Altra forma del database

- In questo caso una regola associativa ha la forma
- $A_1=v_{A_1}, A_2=v_{A_2}, \dots, A_j=v_{A_j} \Rightarrow B_1=v_{B_1}, B_2=v_{B_2}, \dots, B_k=v_{B_k}$
- dove $A_1, A_2, \dots, A_j, B_1, B_2, \dots, B_k$ sono nomi di attributi e $v_{A_1}, v_{A_2}, \dots, v_{A_j}, v_{B_1}, v_{B_2}, \dots, v_{B_k}$ sono valori tali che v_{A_i} (v_{B_h}) appartiene al dominio dell'attributo A_i (B_h).
- I database della prima forma possono essere tradotti in questa seconda forma considerando un attributo booleano per ogni possibile item.

19

Weka

- Weka apprende regole associative da database nella seconda forma

20