

# Regole associative

Gianluca Amato

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

1

# Regole associative

2

## Cos'è una regola associativa ? (1)

- Una **regola associativa** è una regola che collega tra di loro i valori degli attributi di un insieme di istanze.
- Le regole associative hanno la forma
  - **Corpo** -> **Testa** [**supporto,confidenza**]
  - Corpo e Testa sono congiunzioni di **item**
  - un item è una formula atomica del tipo **predicato(x,value)**
    - *predicato* è uno degli attributi che compongono il nostro insieme di istanze
    - *valore* è uno dei possibili valori (o un insieme di possibili valori) assunti da *predicato*
  - supporto e confidenza sono due valori percentuali
- **Esempio**
  - $\text{laurea}(x, \text{"economia"}) \wedge \text{incorso}(x, \text{true}) \rightarrow \text{voto}(x, 100..110)$  [s: 20%, c: 75%]

3

## Cos'è una regola associativa? (2)

- A differenza che nelle altre analisi, è conveniente considerare attributi che possono assumere più di un valore:
  - l'attributo "articolo" delle istanze "acquisti"
  - l'attributo "sostenuto" delle istanze "studenti"
- Ovviamente, attributi **multivalori** non esistono nel mondo dei database relazionali, ma si possono simulare facilmente
  - come?
- **Regola associativa sul database studenti**
  - $\text{facoltà}(x, \text{"economia"}) \wedge \text{sostenuto}(x, \text{"crittografia"})$   
->  $\text{corso\_di\_laurea}(x, \text{"lei"})$  [s: 1%, c: 99%]
- **Regola associativa sul database acquisti**
  - $\text{compra}(x, \text{"computer"}) \rightarrow \text{compra}(x, \text{"monitor"})$  [s: 0.5%, c: 70%]

4

## Cosa sono supporto e confidenza?

- Sia data la regola:
  - compra(x,"pannolino") → compra(x,"birra")
- **Supporto**: la percentuale di acquisti che comprendono sia i pannolini che la birra.

$$\frac{\#\{x \mid \text{compra}(x, \text{pannolino}) \wedge \text{compra}(x, \text{birra})\}}{\#\text{ n. totale istanze}}$$

- **Confidenza**: tra gli acquisti che includono i pannolini, la percentuale di quelli che includono anche la birra.

$$\frac{\#\{x \mid \text{compra}(x, \text{pannolino}) \wedge \text{compra}(x, \text{birra})\}}{\#\{x \mid \text{compra}(x, \text{pannolino})\}}$$

- Le regole associative sono **interessanti** se superano dei valori di **soglia** sia per confidenza che per il supporto.

5

## Esempio: calcolo supporto e confidenza

| Transaction ID | Items Bought |
|----------------|--------------|
| 2000           | A, B, C      |
| 1000           | A, C         |
| 4000           | A, D         |
| 5000           | B, E, F      |

- Problema: trovare tutte le regole del tipo
  - bought(x,\_) → bought(x,\_)
  - supporto e confidenza minimi 50%
- Risultati
  - bought(x,A) → bought(x,C) [sup: 50%, conf: 66.6%]
  - bought(x,C) → bought(x,A) [sup: 50%, conf: 100%]

6

## Classificazione delle regole associative

- Regole **booleane** e **quantitative**: una regola è booleana se in tutti gli item **predicato(x,v)**, v è un valore unico. Se v è un insieme di valori (tipicamente un intervallo), la regola è detta quantitativa.
  - Regola booleana mono-dimensionale:
    - buys(x, "DB2") ∧ buys(x, "DMBook") → buys(x, "DBMiner") [0.2%, 60%]
  - Regola quantitativa multi-dimensionale:
    - age(x, "30..39") ∧ income(x, "42..48K") → buys(x, "PC") [1%, 75%]
- Regole **mono-dimensionali** e **multi-dimensionali**: a seconda del numero di attributi diversi coinvolti.
  - Vedi esempio di sopra
- Le regole booleane mono-dimensionali sono le più comuni, e sono adoperate per la **market basket analysis**.

7

## Altra terminologia

- Si parla di analisi di associazioni a un **singolo livello** o a **livelli multipli**: a seconda se tutti gli item appartengono allo stesso livello di astrazione o no.
  - Una analisi multi-livello è in grado di trovare il seguente insieme di regole:
    - age(x,"30...39") => buys(x,"computer")
    - age(x,"30...39") => buys(x,"laptop computer")
- Ci sono varie possibili estensioni al concetto di regola di associazione. Ad esempio:
  - Analisi di correlazione
  - Analisi di maxpatterns e closed itemsets.

8

## Regole associative booleane mono-dimensionali

9

## Frequent Itemsets (1)

- Presentiamo uno degli algoritmi fondamentali per l'analisi di associazioni mono-dimensionali booleane: **Apriori**.
- Si basa sul concetto di frequent itemset:
  - **itemset**: un insieme di item. Esempio: { compra(x,pannolini), compra(x,birra), compra(x,nutella) }
    - nel caso di regole monodimensionali booleane, gli item si scrivono senza il nome del predicato.. otteniamo l'itemset { pannolini, birra, nutella }
  - **k-itemset**: un itemset con k elementi.
  - la **frequenza** di un itemset è il numero di transazioni in cui sono presenti tutti gli elementi di un itemset.
  - un **frequent itemset** è un itemset la cui frequenza (rispetto al numero totale di istanze) supera la soglia di min. supporto.

10

## Frequent Itemsets (2)

- Per trovare le regole associative interessanti con supporto minimo  $s$  e confidenza minima  $c$ :
  - Si determinano tutti gli itemset frequenti con supporto minimo  $s$
  - Se  $X$  è un itemset frequente e  $X=X_1 \cup X_2$ , allora  $X_1 \Rightarrow X_2$  è una regola di associazione che supera la **soglia minima di supporto**.
  - Se la regola supera anche la **soglia di confidenza minima**, allora è una regola interessante.

11

## Esempio: itemsets e regole associative

| Transaction ID | Items Bought |
|----------------|--------------|
| 2000           | A,B,C        |
| 1000           | A,C          |
| 4000           | A,D          |
| 5000           | B,E,F        |

Min. support 50%  
Min. confidence 50%

| Frequent Itemset | Support |
|------------------|---------|
| {A}              | 75%     |
| {B}              | 50%     |
| {C}              | 50%     |
| {A,C}            | 50%     |

Per la regola  $A \Rightarrow C$ :

$$\text{support} = P(\{A \cap C\}) = 50\%$$

$$\text{confidence} = P(\{A \cap C\})/P(\{A\}) = 66.6\%$$

12

## Il principio Apriori

- Qualunque sottoinsieme di un itemset frequent è un itemset frequente.
- Si applica questo principio nel calcolo degli itemset frequenti:
  - In maniera iterativa, trovo tutti i k-itemset frequenti per k da 1 in poi.
  - Tutti i possibili k-itemset frequenti sono ottenuti dall'unione di due (k-1)-itemset frequenti.
    - Non è necessario controllare tutti i possibili sottoinsiemi di k elementi per sapere se sono frequenti.

13

## L'algoritmo Apriori

- Si basa su due passi fondamentali, eseguiti ripetutamente: **Join** e **Prune**.
  - Passo **Join**: partendo da  $L_{k-1}$ , l'insieme dei k-itemset frequenti, genero  $C_k$ , l'insieme dei k-itemset candidati.
    - Per controllare se  $X \in C_k$  è frequente, posso fare una scansione della base di dati e contare in quante transazioni appare X.
    - L'operazione è costosa, si riduce prima il numero di candidati con il passo Prune.
  - Passo **Prune**: elimino da  $C_k$  tutti quegli itemset X per cui esiste un sottoinsieme di k elementi di X che non è in  $L_{k-1}$ .

14

## L'algoritmo Apriori: pseudo-codice

$C_k$ : Candidate itemset of size k

$L_k$ : frequent itemset of size k

$L_1 = \{\text{frequent items}\}$ ; // ottenuti da una scansione del database

**for** ( $k = 1$ ;  $L_k \neq \emptyset$ ;  $k++$ ) **do begin**

$C_{k+1}$  = candidati generati da  $L_k$  con i passi Join e Prune

**for each** transaction  $t$  in database **do**

incrementa il conteggio di tutti i candidati in  $C_{k+1}$  che sono contenuti in  $t$

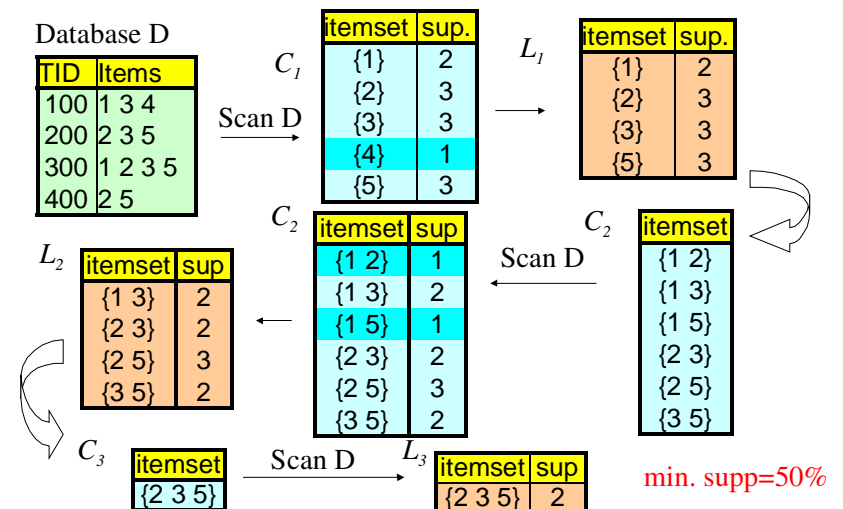
$L_{k+1}$  = candidates in  $C_{k+1}$  with min\_support

**end**

**return**  $\cup_k L_k$ ;

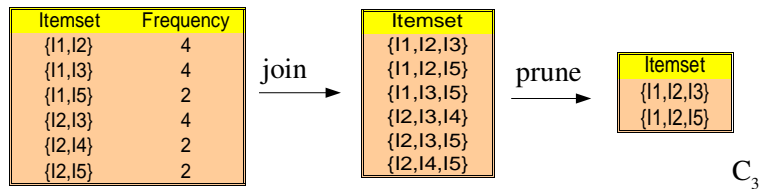
15

## Esempio: algoritmo Apriori



16

## I passi Join e Prune



$L_2$

- Il passo Join, partendo da  $L_k$ , mette assieme le coppie di itemset che hanno  $k-1$  elementi uguali
  - ottimizzazione: se esiste un ordinamento tra gli item, e gli itemset sono ordinati in maniera lessicografica, ci possiamo limitare a mettere insieme gli itemset che hanno i **primi  $k-1$**  elementi uguali
- Il passo Prune, partendo dal risultato di Join, elimina gli itemset che hanno un sotto-insieme non appartenente ad  $L_k$

17

## Pseudocodice per Join e Prune

- Supponiamo che gli item in  $L_k$  siano ordinati in maniera lessicografica.
- **Join:**  
 insert into  $C_k$   
 select  $p.item_1, p.item_2, \dots, p.item_{k-1}, q.item_{k-1}$   
 from  $L_{k-1} p, L_{k-1} q$   
 where  $p.item_1=q.item_1, \dots, p.item_{k-2}=q.item_{k-2}, p.item_{k-1} < q.item_{k-1}$
- **Prune:**  
 forall **itemsets**  $c$  in  $C_k$  do  
 forall **( $k-1$ )-subsets**  $s$  of  $c$  do  
 if ( $s$  is not in  $L_{k-1}$ ) then delete  $c$  from  $C_k$

18

## Possibili ottimizzazioni

- Ne sono state studiate tante, vediamo due:
  - **Transaction reduction:** se una transazione non contiene nessun itemset in  $L_k$  non potrà contenere nessun itemset in  $L_{k+1}$  o successivi. Si può quindi eliminare e non considerare mai più.
  - **Partizionamento:** si divide il database in tante parti, ognuna delle quali può essere caricata in memoria. Calcolo gli itemset frequenti per le varie partizioni. Alla fine calcolo gli itemset frequenti globali, tenendo conto che un item frequente per tutto il database è frequente per almeno una delle sue partizioni.

19

Regole associative multi-livello

20

## Regole associative a più livelli

- Per molte applicazioni, è difficile trovare delle associazioni forti tra oggetti a un livello primitivo di dettaglio.
  - Occorre considerare regole associative a tutti i livelli della gerarchia di concetti.
- Approccio **top-down**:
  - Si calcolano gli itemset a partire dal livello di astrazione più generico;
    - latte -> pane [20%,60%]
  - Si procede via via verso livello sempre più specifici.
    - latte scremato -> pane integrale [6%, 50%]

21

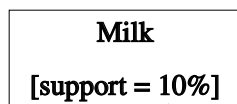
## Supporto uniforme e supporto ridotto

- **Supporto uniforme**: lo stesso livello di supporto minimo è usato a tutti i livelli di astrazione.
  - Efficiente! Se un itemset a un certo livello di astrazione non è frequente, non dobbiamo esaminarlo per nessuno dei livelli di dettaglio maggiori.
  - È difficile scegliere il livello di supporto appropriato:
    - Troppo basso: genera troppe regole associative
    - Troppo alto: si rischia di mancare del tutto regole associative ad alto livello di dettaglio.
- **Supporto ridotto**: valori di supporto minimo diversi per ogni livello.

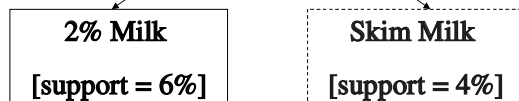
22

## Supporto uniforme

Level 1  
min\_sup = 5%



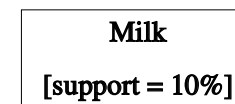
Level 2  
min\_sup = 5%



23

## Supporto ridotto

Level 1  
min\_sup = 5%



Level 2  
min\_sup = 3%



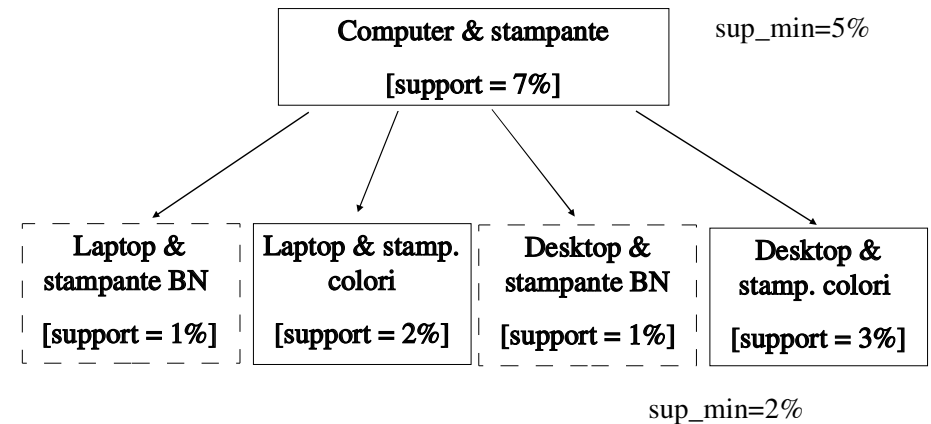
24

## Strategie per il metodo di supporto ridotto

- **Livelli indipendenti:** gli itemset a differenti livelli di astrazione sono calcolati in maniera indipendente tra di loro.
  - Strategia **completa:** trova tutti gli itemset frequenti
- **Filtraggio incrociato:** un k-itemset a livello i viene considerato un candidato solo se al livello i-1 è frequente.
  - Strategia **efficiente:** ma può non trovare tutti gli itemset frequenti.
- **Filtraggio incrociato sul singolo item:** stessa cosa del filtraggio incrociato, ma il filtraggio avviene solo a livello di 1-itemset.
  - Compromesso tra i due

25

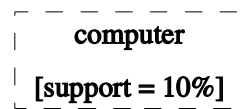
## Filtraggio incrociato



26

## Filtraggio incrociato sul singolo item

Level 1  
min\_sup = 12%



Level 2  
min\_sup = 3%



27

## Altre strategie per il metodo di supporto ridotto

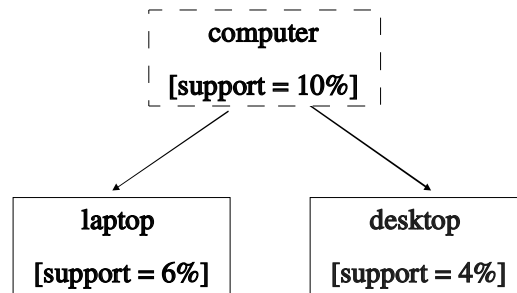
- **Filtraggio incrociato controllato sul singolo item:** per ogni livello abbiamo due soglie:
  - Soglia di supporto minimo
  - Soglia di passaggio di livello
- Gli itemset frequenti sono quelli la cui frequenza supera il supporto minimo.
- Gli itemset che vengono considerati per il livello successivo di dettaglio sono quelli la cui frequenza supera la soglia di passaggio.

28

## Filtraggio incrociato controllato

Level 1  
min\_sup = 12%  
level\_passage=10%

Level 2  
min\_sup = 3%



29

## Cross-level association rules

- Finora abbiamo considerato regole i cui i vari item hanno tutti lo stesso livello di dettaglio.
- **Cross-level association rules**: quando i livelli di dettaglio dei vari item differiscono.
  - Computer -> stampante BN [sup: 4%, conf. 30%]

30

## Associazioni multi-livello ridondanti

- Alcune regole possono essere ridondanti a causa di regole più astratte.
  - R1) Latte => pane integrale [sup: 8%, conf: 70%]
  - R2) Latte scremato => pane integrale [sup: 2%, conf: 72%]
- Diciamo che la regola R1 è **antenato** della R2: la R1 si ottiene da R2 rimpiazzando alcuni item con altri item a un livello di astrazione superiore.
- Supponiamo che  $\frac{1}{4}$  delle vendite di latte sia da latte scremato
  - Supporto atteso "Latte scremato => pane integrale" è  $\frac{1}{4} * 8\% = 2\%$
  - La confidenza attesa è il 70%
  - **Seconda regola ridondante!!**

31

Regole associative  
multi-dimensionali

32



## Regole associative multi-dimensionali (1)

- Regole associative **multi-dimensionali**:
  - Regole **inter-dimensionali** (ogni predicato occorre una sola volta):
    - $\text{age}(x, "19-25") \wedge \text{occupation}(x, "student") \rightarrow \text{buys}(x, "coke");$
  - Regole **ibride** (predicati ripetuti)
    - $\text{age}(x, "19-25") \wedge \text{buys}(x, "pop\ corn") \rightarrow \text{buys}(x, "coke")$

33

## Regole associative multi-dimensionali (2)

- Regole multi-dimensionali **booleane**
  - Si usa un algoritmo simile ad Apriori
- Regole multi-dimensionali **quantitative**
  - Gli attributi quantitativi vanno discretizzati. Ci sono tre approcci:
    - discretizzazione **statica**, eseguita prima di applicare l'algoritmo di ricerca delle regole associative
      - una volta discretizzati, si applica un algoritmo standard come Apriori.
    - discretizzazione **dinamica**, eseguita in parallelo alla ricerca di regole associative

34

## Discretizzazione statica e dinamica

- La discretizzazione dinamica produce regole “migliori”, tipicamente con un supporto e confidenza più elevati.
- Supponiamo di discretizzare age negli intervalli “1-18”, “19-36”, “37-48”,...
- Applicando Apriori possiamo ottenere regole del tipo  
 $\text{age}(X, "1-18") \wedge \text{buys}(X, "computer") \rightarrow \text{buys}(X, "joystick")$   
 $\text{age}(X, "19-36") \wedge \text{buys}(X, "computer") \rightarrow \text{buys}(X, "joystick")$
- Un algoritmo che usa una discretizzazione dinamica è in grado di ottenere:  
 $\text{age}(X, "12-28") \wedge \text{buys}(X, "computer") \rightarrow \text{buys}(X, "joystick")$   
con confidenza e supporto maggiori.
  - l'intervallo “12-28” è generato ad-hoc per migliorare le prestazioni della regola associativa.

35

Critiche al concetto di supporto e confidenza

36

## Regole interessanti (1)

- Supporto e confidenza sono buone misure oggettive per determinare se le regole sono interessanti?
- Abbiamo bisogno di una misura di “**correlazione tra eventi**”
- Esempio 1:
  - tra 5000 studenti
    - 3000 giocano a basket
    - 3750 mangiano cereal
    - 2000 giocano a basket e mangiano cereali
  - *play basketball*  $\Rightarrow$  *eat cereal* [40%, 66.7%] è una regola forte, ma è fuorviante, in quanto la percentuale di studenti che mangiano cereali è del 75%
  - *play basketball*  $\Rightarrow$  *not eat cereal* [20%, 33.3%] è molto più accurata, sebbene con valori di confidenza e supporto inferiori.

37

## Regole interessanti (2)

- Esempio 2:
  - X e Y sono positiv. correlati
  - X e Z sono neg. correlati
  - $X \Rightarrow Z$  è più forte di  $X \Rightarrow Y$

|   |   |   |   |   |   |   |   |   |
|---|---|---|---|---|---|---|---|---|
| X | 1 | 1 | 1 | 1 | 0 | 0 | 0 | 0 |
| Y | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| Z | 0 | 1 | 1 | 1 | 1 | 1 | 1 | 1 |

| Rule              | Support | Confidence |
|-------------------|---------|------------|
| $X \Rightarrow Y$ | 25%     | 50%        |
| $X \Rightarrow Z$ | 37.50%  | 75%        |

38

## Lift di una regola associativa (1)

- Dati due eventi A, B si definisce il **coefficiente di correlazione** tra i due come
 
$$corr_{A,B} = \frac{P(A \cup B)}{P(A)P(B)} = \frac{P(B|A)}{P(B)}$$
  - Se  $corr_{A,B} = 1$  i due eventi sono indipendenti
  - Se  $corr_{A,B} > 1$  i due eventi sono positivamente correlati
  - Se  $corr_{A,B} < 1$  i due eventi sono negativamente correlati
- Se  $A \Rightarrow B$  è una regola associativa, il valore  $corr_{A,B}$  è detto **lift** o (**interesse**)
  - è la confidenza diviso il supporto della conclusione
  - notare che il lift di  $A \Rightarrow B$  e  $B \Rightarrow A$  è uguale

39

## Lift di una regola associativa (2)

- Riprendiamo l'esempio 2
- Otteniamo i seguenti valori di interesse

|   |   |   |   |   |   |   |   |   |
|---|---|---|---|---|---|---|---|---|
| X | 1 | 1 | 1 | 1 | 0 | 0 | 0 | 0 |
| Y | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| Z | 0 | 1 | 1 | 1 | 1 | 1 | 1 | 1 |

| Itemset | Support | Interest |
|---------|---------|----------|
| X,Y     | 25%     | 2        |
| X,Z     | 37.50%  | 0.9      |
| Y,Z     | 12.50%  | 0.57     |

- Si vede chiaramente che la regola  $X \Rightarrow Y$  è più interessante di  $X \Rightarrow Z$

40

## Regole associative vincolate

41

## Vincoli sul contenuto delle regole

- Altri tipi di vincoli possono essere imposti sul contenuto delle regole, piuttosto che sulla forma.
  - ad esempio, supponiamo di avere un database con due tabelle
    - (1) trans (TID, Itemset) (2) itemInfo (Item, Type, Price)
  - ci si può restringere a considerare quelle regole della forma  $S_1 \Rightarrow S_2$  tali che:  
$$\text{sum}(S_1.\text{price}) < 100 \wedge \text{min}(S_1.\text{price}) > 20 \wedge \text{count}(S_1) > 3 \wedge \text{sum}(S_2.\text{price}) > 1000$$
- Una “**constrained association query**” (CAQ) è una stringa del tipo  $\{(S_1, S_2) \mid C\}$  dove C è un insieme di vincoli che coinvolgono  $S_1$  ed  $S_2$  (lato sinistro e destro della regola associativa).

43

## Metaregole

- E' possibile focalizzare la ricerca solo di determinate regole
  - Ad esempio, vogliamo capire il profilo dei clienti della AllElectronics che comprano software educativo.
- Alcuni sistemi consentono di specificare una **metaregola** del tipo
  - $P_1(x, Y) \wedge P_2(x, W) \Rightarrow \text{buys}(x, \text{”software educativo”})$
  - $P_1$  e  $P_2$  sono “**variabili di predicato**” e possono essere istanziate con un qualunque attributo
- Il sistema di analisi cerca solo regole che “matchano” la meta-regola:
  - $\text{age}(x, \text{”30..39”}) \wedge \text{income}(x, \text{”41K..60K”}) \Rightarrow \text{buys}(x, \text{”software educativo”})$

42

## Classificazione dei vincoli

- I vincoli che si possono esprimere sono i seguenti
  - vincoli di **dominio**
    - $S \subseteq V$  oppure  $S \supseteq V$
    - Esempio:  $\{\text{snacks}, \text{sodas}\} \subseteq S$
  - vincoli di **aggregazione**
    - $\text{agg}(S) \theta v$  dove  $\text{agg} \in \{\text{min}, \text{max}, \text{sum}, \text{count}, \text{avg}\}$ , and  $\theta \in \{=, \neq, <, \leq, >, \geq\}$
    - Esempio:  $\text{count}(S.\text{Type}) = 1$ ,  $\text{avg}(S.\text{Price}) < 100$

44

## Ottimizzazione delle CAQ

- Data una CAQ =  $\{ (S1, S2) \mid C \}$  l'algoritmo è
  - **corretto**: se trova solo insiemi frequenti che soddisfano i vincoli C
  - **completo**: se trova tutti gli insiemi frequenti che soddisfano i vincoli C
- Una soluzione naïve:
  - applicare Apriori per trovare tutti gli insiemi frequenti e poi eliminare quelli che non soddisfano C
- Una soluzione migliore
  - analizzare i vincoli e tentare di anticipare il più possibile il loro utilizzo, in modo da ridurre la complessità della operazione.

45

## Monotonia ed anti-monotonia

- Un vincolo  $C_a$  è **anti-monotono** se, quando S non soddisfa  $C_a$ , nessun sopra-insieme di S soddisfa  $C_a$ 
  - il vincolo  $\text{supporto}(S) \geq s$  è un vincolo anti-monotono
  - ad ogni passo di Apriori si può controllare  $C_a$  ed eliminare gli itemset che non lo soddisfano
- Un vincolo  $C_m$  è **monotono** se, quando S soddisfa  $C_m$ , tutti i sopra-insiemi di S soddisfano  $C_m$ 
  - se un itemset S soddisfa  $C_m$  non è necessario controllarlo per gli itemset derivati da S

46

## Vincoli convertibili (1)

- Si supponga che tutti gli item siano ordinati secondo un determinato ordinamento totale
- Un vincolo C è **convertibile monotono** sse quando un itemset S soddisfa C, ogni item-set ottenuto aggiungendo elementi in coda ad S soddisfa C
  - Esempio:  $\text{avg}(I.\text{price}) \geq 100$  è convertibile monotono, con l'ordinamento standard dei numeri.
  - Siccome  $\{50,100,500\}$  soddisfa  $\text{avg}(I.\text{price}) \geq 100$ , allora anche  $\{50,100, 500, 1500\}$  lo soddisfa

47

## Vincoli convertibili (2)

- Un vincolo C è **convertibile anti-monotono** sse quando un itemset S **non** soddisfa C, ogni itemset ottenuto aggiungendo elementi in coda ad S **non** soddisfa C.
  - Esempio:  $\text{avg}(I.\text{price}) \leq 100$
- Se si considera l'ordinamento inverso (si ordinano gli elementi nell'itemset dal più grande al più piccolo) allora:
  - $\text{avg}(I.\text{price}) \geq 100$  è convertibile anti-monotono
  - $\text{avg}(I.\text{price}) \leq 100$  è convertibile monotono
- I vincoli  $\text{sum}(S) \leq v$  e  $\text{sum}(S) \geq v$  non ricadono in nessuna delle categorie viste prima: sono vincoli **inconvertibili**.
  - Notare che se vale che tutti gli elementi in S sono positivi, allora  $\text{sum}(S) \leq v$  è antimonotono e  $\text{sum}(S) \geq v$  è monotono.

48

## Vincoli succinti (1)

- **Informalmente:** un vincolo  $C_s$  è **succinto** se è possibile trovare una procedura che generi direttamente tutti e soli gli itemset che soddisfano  $C_s$  (senza controllare effettivamente il vincolo)
  - gli itemset  $J$  tali che  $\min(J.price) \geq 500$  sono generabile direttamente come sotto-insiemi degli item con prezzo superiore a 500
  - gli itemset  $J$  tali che  $\min(J.price) \leq 500$  è generabile direttamente come unione di due itemset  $S_1 \cup S_2$  dove  $S_1 \neq \emptyset$  contiene solo item con prezzo inferiore di 500 ed  $S_2$  contiene item con prezzo superiore a 500
  - invece, il vincolo  $\text{sum}(J.price) \leq 2000$  non è succinto

49

## Vincoli succinti (2)

- **Formalmente:** dato un insieme di oggetti  $I$ 
  - un sottoinsieme  $I_s$  di  $I$  è **succinto** se è esprimibile come  $\sigma_p(I)$ , ovvero come proiezione di  $I$  rispetto a un determinato predicato esprimibile nell'algebra relazionale.
    - $\{S \mid S.price \leq 500\}$  è succinto
    - $\{S \mid S.price \text{ è primo}\}$  non è succinto
  - $SP \subseteq 2^I$  è succinto se esistono  $I_1, \dots, I_k \subseteq I$  **succinti** tali che ogni elemento di  $SP$  si può scrivere a partire da sottoinsiemi di  $I_1, \dots, I_k$  usando le operazioni di unione e differenza di insiemi.
    - $\{SP \mid \min(SP).price \leq 500\}$  è succinto perchè ogni elemento di  $SP$  si scrive come  $I_1 \cup I_2$  con  $I_1 \subseteq \{I \mid I.price \leq 500\}$  ed  $I_2 \subseteq \{I \mid I.price > 500\}$ .

50

## Vincoli succinti (3)

- Un vincolo  $C$  è **succinto** se l'insieme degli item che lo soddisfa è succinto
  - $\min(S.price) \leq 500$  è succinto per quanto vista prima
- Alcune proprietà dei vincoli succinti
  - se  $S_1$  ed  $S_2$  soddisfano  $C$ , anche  $S_1 \cup S_2$  soddisfa  $C$

51

## Conclusioni

- Determinazione di regole associative
  - probabilmente il più grosso contributo della comunità di ricercatori nelle basi di dati al KDD
  - un gran numero di pubblicazioni relative
- Direzioni di ricerca
  - determinazione di regole associative in tipi di dati complessi
    - dati spaziali
    - serie temporali

52

## Bibliografia (1)

### Algoritmo Apriori:

[1] R. Agrawal and R. Srikant. *Fast algorithms for mining association rules*. VLDB '94 487-499, Santiago, Chile.

### Regole Associative Multilivello

[2] R. Srikant and R. Agrawal. *Mining generalized association rules*. VLDB'95, 407-419, Zurich, Switzerland, Sept. 1995.

[3] J. Han and Y. Fu. *Discovery of multiple-level association rules from large databases*. VLDB'95, 420-431, Zurich, Switzerland.

### Regole Associative Quantitative

[4] B. Lent, A. Swami, and J. Widom. *Clustering association rules*. ICDE'97, 220-231, Birmingham, England.

[5] R. Srikant and R. Agrawal. *Mining quantitative association rules in large relational tables*. SIGMOD'96, 1-12, Montreal, Canada.

[6] R.J. Miller and Y. Yang. *Association rules over interval data*. SIGMOD'97, 452-461, Tucson, Arizona.

## Bibliografia (2)

### Regole associative vincolate

[7] M. Kamber, J. Han, and J. Y. Chiang. *Metarule-guided mining of multi-dimensional association rules using data cubes*. KDD'97, 207-210, Newport Beach, California.