

## VII.3 Assoziationsregeln

© Institut AIFB, 2003.  
Alle Rechte vorbehalten. Nachdruck oder photomechanische Wiedergabe nur mit Genehmigung des Verfassers.  
Zuwendungen unterliegen den strafrechtlichen Bedingungen des Urheberrechtsgesetzes.

### Kapitel VII.3 Assoziationsregeln

#### VII.3 Assoziationsregelverfahren

##### VII.3.1 Einführung [Bollinger 96]

- Algorithmen zum Entdecken von Assoziationsregeln sind typische Vertreter von Data Mining Verfahren.
- Assoziationsregeln beschreiben Korrelationen zwischen gemeinsam auftretenden Dingen.
- **Beispiel: (Warenkorb-Analyse)**  
Artikel, die Kunden eines Supermarktes zusammen einkaufen  
*„In 45% der Fälle, in denen Lachs gekauft wird, wird auch Weißwein gekauft. Diese beiden Produkte kommen in 2% aller Transaktionen vor.“*
- typische Anwendungsbereiche:
  - Einzel- und Versandhandel
  - Tourismus

Vorlesung: Knowledge Discovery

2

### Kapitel VII.3 Assoziationsregeln

- Für Assoziationsregeln sind folgende Parameter relevant:
  - **Konfidenz** der Regel,  
d.h. Stärke der Korrelation („in 45% der Fälle“)
  - **Support** der Regel,  
d.h. Häufigkeit des gemeinsamen Auftretens („in 2% aller Transaktionen“)
- Algorithmen sind so konstruiert, daß sie **alle** Assoziationsregeln mit vorgegebener Mindestkonfidenz und Mindestsupport entdecken.
- Benutzer muß **keine** Annahmen darüber machen, welche Dinge korrelieren könnten. (Dies ist bei Tausenden von Artikeln auch nicht möglich.)
- Datenbestände sind typischerweise sehr groß  
=> Algorithmen müssen **effizient** sein.

Vorlesung: Knowledge Discovery

3

### Kapitel VII.3 Assoziationsregeln

#### VII.3.2 Das Assoziationsproblem

- gegeben:
  - Menge J von **Items** (uninterpretierte, diskrete Entities)
  - Liste D von Transaktionen, wobei eine **Transaktion** eine Menge  $t \subseteq J$  von Items ist.
- **Assoziationsregel**  $X \rightarrow Y$  besteht aus:
  - **Regelrumpf** X (Menge von Items)
  - **Regelkopf** Y (Menge von Items)
- Transaktion t **erfüllt** Assoziationsregel  $X \rightarrow Y$  falls  $(X \cup Y) \subseteq t$

Vorlesung: Knowledge Discovery

4

- **Support** einer Assoziationsregel  $X \rightarrow Y$  ist der Anteil der Transaktionen aus  $D$ , die die Regel erfüllen:

$$\text{support}(X \rightarrow Y) = \frac{|\{t \in D \mid (X \cup Y) \subseteq t\}|}{|D|}$$

- **Konfidenz** einer Assoziationsregel  $X \rightarrow Y$  ist das Verhältnis der Transaktionen aus  $D$ , die die Regel erfüllen, zur Gesamtheit aller Regeln, die Regelrumpf erfüllen:

$$\text{confidence}(X \rightarrow Y) = \frac{|\{t \in D \mid (X \cup Y) \subseteq t\}|}{|\{t \in D \mid X \subseteq t\}|} = \frac{\text{support}(X \rightarrow Y)}{\text{support}(X)}$$

- Definition (**Assoziationsproblem**):

- gegeben: Menge  $D$  von Transaktionen  
Wert für minimalen Support  $s_{\min}$   
Wert für minimale Konfidenz  $c_{\min}$

- gesucht: Finde alle Assoziationsregeln  $X \rightarrow Y$ , so daß  
 $\text{support}(X \rightarrow Y) \geq s_{\min}$   
 $\text{confidence}(X \rightarrow Y) \geq c_{\min}$

**Beispiel:** Transaktionen und Assoziationsregeln in einer Supermarkt-Anwendung

Einkaufs-Transaktionen	gekaufte Artikel (Items)
$t_1$	Saft, Cola, Bier
$t_2$	Saft, Cola, Wein
$t_3$	Saft, Wasser
$t_4$	Cola, Bier, Saft
$t_5$	Saft, Cola, Bier, Wein
$t_6$	Wasser



Artikel (Item)	Transaktionen, in denen der Artikel vorkommt	Support des Items
Saft	$t_1, t_2, t_3, t_4, t_5$	$5/6 = 83.3\%$
Cola	$t_1, t_2, t_4, t_5$	$4/6 = 66.6\%$
Bier	$t_1, t_4, t_5$	$3/6 = 50\%$
Wein	$t_2, t_5$	$2/6 = 33.3\%$
Wasser	$t_3, t_6$	$2/6 = 33.3\%$

Die Regel  $\text{Saft} \rightarrow \text{Cola}$  gilt z.B. mit einem Support von 66.6% und einer Konfidenz von 80%

VII.3.3 Apriori-Algorithmus zum Finden von Assoziationsregeln

[Agrawal et al. 94]

**Idee:**

- Schritt 1: Bestimme alle Itemmengen mit vorgegebenem Mindestsupport, die sog. **häufigen Itemmengen**
- Schritt 2: Bilde alle **Assoziationsregeln** mit vorgegebener Mindestkonfidenz aus den häufigen Itemmengen

- zu Schritt 1:
  - berechne sukzessive die häufigen Itemmengen mit  $i=1,2,3,\dots$  Elementen.
  - fasse die häufigen Itemmengen mit  $i$  Elementen zur Menge  $I_i$  zusammen:  $I_i := \{X \mid X \text{ ist häufige Itemmenge, } |X| = i\}$
- **Lemma:** (i) Für  $X' \subseteq X$  gilt:  $\text{support}(X') \geq \text{support}(X)$   
 (ii) Wenn  $X$  häufige Itemmenge ist, dann auch jedes  $X' \subseteq X$   
 (iii) Für  $X \in I_{n+1}$  gilt: alle  $n$ -elementigen Teilmengen von  $X$  sind häufig.  
 (iv) Sei  $X$  eine  $n+1$ -elementige Menge von Items. Wenn es eine  $n$ -elementige Teilmenge  $X'$  von  $X$  gibt mit  $X' \notin I_n$ , dann gilt auch  $X \notin I_{n+1}$ .

- **Lemma (Wdh.):**  
 (iv) Sei  $X$  eine  $n+1$ -elementige Menge von Items. Wenn es eine  $n$ -elementige Teilmenge  $X'$  von  $X$  gibt mit  $X' \notin I_n$ , dann gilt auch  $X \notin I_{n+1}$ .
- Berechnung von  $I_{n+1}$  aus  $I_n$ :
  - $n$ -elementige **häufige** Mengen werden um jeweils ein Element erweitert
  - prüfe, ob  $(n+1)$ -elementige Menge häufig ist:  
wenn ja, nehme  $(n+1)$ -elementige Menge in  $I_{n+1}$  auf.

**Apriori-Algorithmus zur Berechnung häufiger Itemmengen:**

1. Initialisierung:
  - $s_{\min}$  = Wert für minimalen Support;
  - $n := 1$ ;
  - $I := \emptyset$ ;
  - $H_n := \{\{i\} \mid i \text{ ist ein Item}\}$ ;
2. gehe über die Datenbasis  $D$  und bestimme für alle  $H \in H_n$  den Support;
3.  $I_n := \{H \in H_n \mid \text{support}(H) \geq s_{\min}\}$ ;  
 $I := I \cup I_n$ ;
4. Falls  $I_n = \emptyset$ , gebe  $I$  als Ergebnis aus; Ende.
5.  $H_{n+1} := \{\{i_1, i_2, \dots, i_{n+1}\} \mid \forall j: 1 \leq j \leq n+1: (\{i_1, i_2, \dots, i_{n+1}\} - \{i_j\}) \in I_n\}$ ;  
 $n := n+1$ ; /\* Details s. Tafel \*/
6. gehe nach 2.

**Fortführung des Beispiels (mit  $s_{\min}=50\%$ )**

Einkaufs-Transaktionen	gekaufte Artikel (Items)
$t_1$	Saft, Cola, Bier
$t_2$	Saft, Cola, Wein
$t_3$	Saft, Wasser
$t_4$	Cola, Bier, Saft
$t_5$	Saft, Cola, Bier, Wein
$t_6$	Wasser

↓  
Apriori, Schritt 1

$n$	$H_n$	$I_n$
1	$\{\{Saft\}, \{Cola\}, \{Bier\}, \{Wein\}, \{Wasser\}\}$	$\{\{Saft\}, \{Cola\}, \{Bier\}\}$
2	$\{\{Saft, Cola\}, \{Saft, Bier\}, \{Cola, Bier\}\}$	$\{\{Saft, Cola\}, \{Cola, Bier\}, \{Saft, Bier\}\}$
3	$\{\{Saft, Cola, Bier\}\}$	$\{\{Saft, Cola, Bier\}\}$
4	$\{\}$	$\{\}$

Fortführung des Beispiels (mit  $s_{min}=50\%$ )

n	$H_n$	$I_n$
1	{{Saft},{Cola},{Bier},{Wein},{Wasser}}	{{Saft},{Cola},{Bier}}
2	{{Saft, Cola},{Saft, Bier},{Cola, Bier}}	{{Saft, Cola},{Cola, Bier}, {Saft, Bier}}
3	{{Saft, Cola, Bier}}	{{Saft, Cola, Bier}}
4	$\emptyset$	$\emptyset$

Zu Schritt 2 (Erzeugung der Regeln):

- gegeben sei  $c_{min} = 75\%$
- Aus  $\{Saft, Cola\} \in I_2$  erhalten wir z.B. die Regeln

$$\text{confidence}(Saft \rightarrow Cola) = \frac{\text{support}(\{Saft, Cola\})}{\text{support}(\{Saft\})} = \frac{2/3}{5/6} = 80\%$$

$$\text{confidence}(Cola \rightarrow Saft) = \frac{\text{support}(\{Saft, Cola\})}{\text{support}(\{Cola\})} = \frac{2/3}{2/3} = 100\%$$

Apriori-Algorithmus (Schritt 2)

Schritt 1: Bestimme alle Itemmengen mit vorgegebenem Mindestsupport, die sog. **häufigen Itemmengen**

Schritt 2: Bilde alle **Assoziationsregeln** mit vorgegebener Mindestkonfidenz aus den häufigen Itemmengen unter Verwendung des Satzes:

**Satz:** Sei X häufige Itemmenge, dann gilt für  $X' \subseteq X$ :

$$\text{confidence}((X - X') \rightarrow X') = \frac{\text{support}(X)}{\text{support}(X - X')}$$

D.h. die Konfidenz lässt sich aus dem Support der häufigen Itemmengen berechnen.

Fortführung des Beispiels: abgeleitete Assoziationsregeln zu den häufigen Itemmengen (mit  $\text{minsupp}=50\%$ )

Regeln mit Support $\geq 50\%$	erfüllende Transaktionen	Support	Konfidenz
Saft $\rightarrow$ Cola	$t_1, t_2, t_4, t_5$	66%	80%
Cola $\rightarrow$ Saft	$t_1, t_2, t_4, t_5$	66%	100%
Cola $\rightarrow$ Bier	$t_1, t_4, t_5$	50%	75%
Bier $\rightarrow$ Cola	$t_1, t_4, t_5$	50%	100%
Saft $\rightarrow$ Bier	$t_1, t_4, t_5$	50%	60%
Bier $\rightarrow$ Saft	$t_1, t_4, t_5$	50%	100%
Saft, Bier $\rightarrow$ Cola	$t_1, t_4, t_5$	50%	100%
Cola, Saft $\rightarrow$ Bier	$t_1, t_4, t_5$	50%	75%
Bier, Cola $\rightarrow$ Saft	$t_1, t_4, t_5$	50%	100%
Cola $\rightarrow$ Saft, Bier	$t_1, t_4, t_5$	50%	75%
Bier $\rightarrow$ Cola, Saft	$t_1, t_4, t_5$	50%	100%
Saft $\rightarrow$ Cola, Bier	$t_1, t_4, t_5$	50%	60%

Bemerkungen I/II:

- Wenn die größte häufige Itemmenge n Elemente enthält, benötigt der Algorithmus n Durchläufe
- 1 Megabyte Warenkorb-Daten wird im Sekundenbereich analysiert
- Algorithmus entdeckt Tausende von Regeln:
  - **Visualisierung, Browsing** notwendig
  - **Formale Begriffsanalyse** kann zur Reduktion verwendet werden
  - Regeln mit sehr hohen Support-/Konfidenzwerten schon bekannt
  - Regeln im "**Mittelfeld**" interessant
  - verwende zusätzlich statistische **Maße** für Bewertung von Regeln

**Bemerkungen II/II:**

- Regeln berücksichtigen viele **externe Einflußfaktoren** nicht, da diese in den Transaktionen nicht repräsentiert sind:
  - Käufergruppen (Alter, sozialer Status, ...)
  - Tageszeit, Wochentag
  - Werbekampagnen
- Das Verfahren kann auf interessante Teilmengen der Transaktionenmenge D eingeschränkt werden:
  - benutzerdefiniert (z.B. mit SQL-Statements oder OLAP)
  - oder durch Vorschaltung eines Clusterverfahrens

**Weitere Auswertung:**

- Wenn die Regel  $X \rightarrow Y$  vom Benutzer als interessant befunden ist, kann sie weiter ausgewertet werden:
- Für Regel  $X \rightarrow Y$  sei  $D_x$  Menge der Transaktionen die X enthalten.
  - Sei  $D_x^Y$  die Menge der Transaktionen, die auch Y enthalten
  - Sei  $D_x^{-Y}$  die Menge der Transaktionen, die Y nicht enthalten
  - Was sind diskriminierende Faktoren?
  - Bestimmung mit überwachten Lernverfahren (z.B. Entscheidungsbäume, ILP)!

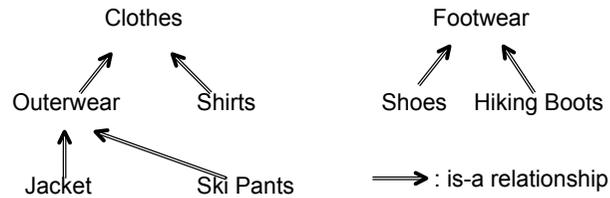
VII.3.4 Mining Generalized Association Rules (Srikant/Agrawal 1995)

- Rules can be generalized with background knowledge, by using **taxonomies** on the items, e.g.
  - Bier *is-a* alkoholisches Getränk
  - Chips *is-a* Salzgebäckleading to rules like
  - Salzgebäck  $\rightarrow$  Bier
  - Chips  $\rightarrow$  alkoholisches Getränk
- The knowledge can be derived from **ontologies** and **domain models**.
- The basic algorithm does not consider taxonomies: only items are considered which are the **leaves** of such a taxonomy, i.e. items are real products being purchased.

VII.3.4.1 Problem Statement

- **Def.:** Let *is-a* be a hierarchy on the set  $J^*$  of generalized items, s.t.  $J \subseteq J^*$  contains all leaves. A *generalized association rule* is an association rule  $X \Rightarrow Y$  s.t. there are no  $x \in X$  and  $y \in Y$  with *x is-a y*.
- **Problem:** Determine, for given *minsupp* and *minconf*, all generalized association rules having at least minimum support *minsupp* and minimum confidence *minconf*.

**Example:** Taxonomy for Clothes and Footwear (Srikant/Agrawal 1995)



Idea: - derive rule 'Outerwear => Hiking Boots'  
from 'Jacket => Hiking Boots' and  
'Ski Pants => Hiking Boots'

**Example:** (Srikant/Agrawal 1995)

- given database D:

Transaction	Items Bought
100	Shirt
200	Jacket, Hiking Boots
300	Ski Pants, Hiking Boots
400	Shoes
500	Shoes
600	Jacket

- assume: minimum support = 30%, minimum confidence = 60%

Frequent Itemsets	
Itemset	Support
{ Jacket }	2
{ Outerwear }	3
{ Clothes }	4
{ Shoes }	2
{ Hiking Boots }	2
{ Footwear }	4
{ Outerwear, Hiking Boots }	2
{ Clothes, Hiking Boots }	2
{ Outerwear, Footwear }	2
{ Clothes, Footwear }	2

Rules		
Rule	Support	Conf.
Outerwear ⇒ Hiking Boots	33%	66.6%
Outerwear ⇒ Footwear	33%	66.6%
Hiking Boots ⇒ Outerwear	33%	100%
Hiking Boots ⇒ Clothes	33%	100%

Observations:

(1) - rules 'Ski Pants => Hiking Boots',  
'Jackets => Hiking Boots'  
do **not** have minimum support

- generalized rule 'Outerwear => Hiking Boots'  
may have minimum support.

- if  $X \Rightarrow Y$  has minimum support, so do its **ancestors**  
 $X \Rightarrow Y^*$ ,  $X^* \Rightarrow Y$ ,  $X^* \Rightarrow Y^*$

where  $X^*$  denotes an itemset which is derived from  $X$  by  
replacing one or more of its items with more general items  
and where  $|X^*| = |X|$  holds.

(2) - rule 'Outerwear => Hiking Boots' has minimum confidence  
- generalized rule may not have minimum confidence:  
'Clothes => Hiking Boots' has only confidence of 50%

- if  $X \Rightarrow Y$  has minimum confidence, so does  $X \Rightarrow Y^*$ .

Rules  $X^* \Rightarrow Y$  and  $X^* \Rightarrow Y^*$  may not have minimum confidence.

(3) - support for an item  $x$  is not equal to the sum of the supports  
of its sub-concepts: several sub-concepts may be present in a single  
transaction

VII.3.4.2 Basic Algorithm

- **Def.:** Transaction  $t$  **supports** an itemset  $X$ , if for each item  $x \in X$   $t$  contains  $x$  or some sub-concept(s) of  $x$ .
- Check becomes simpler if we first add to  $t$  all (direct/indirect) super-concepts of all its items; we call the resulting transaction  $t'$  an **extended** transaction.
- **Lemma:**  $t$  supports  $X$  iff  $t'$  is a superset of  $X$ .

1) iff = if and only if ( $\Leftrightarrow$ )

- algorithm consists of 3 steps:
  - (1) find all frequent item sets

```

L1 := {frequent 1-itemsets};
k := 2; // k represents the pass number
while ( L_{k-1} ≠ ∅ ) do
begin
  C_k := New candidates of size k generated from L_{k-1}.
  forall transactions t ∈ D do
  begin
    Add all ancestors of each item in t to t, removing
    any duplicates.
    Increment the count of all candidates in C_k that
    are contained in t.
  end
  L_k := All candidates in C_k with minimum support.
  k := k + 1;
end
Answer := ∪_k L_k;
    
```

- (2) generate all rules with minimum support and minimum confidence
- (3) evtl. prune all uninteresting rules (see next slide)

VI.3.4.3 Interesting Rules [Srikant/Agrawal 1995]

- structure of taxonomy can be used to **prune** redundant rules

Example:

- Assume 'Outerwear → Hiking Boots' with support 8%, confidence 70%.
- Assume that 25% of 'Outerwear'-transactions are 'Ski Pants'-transactions.
- We therefore **expect** the rule
 

Ski Pants → Hiking Boots

 to hold with support 2% and confidence 70%.
- If such a rule is generated, the more special rule is **redundant** when compared to the more general rule.

Definition: A rule  $X_3 \rightarrow Y_3$  is a **close ancestor** of a rule  $X_1 \rightarrow Y_1$ , if there is no ancestor  $X_2 \rightarrow Y_2$  of  $X_1 \rightarrow Y_1$ , which has  $X_3 \rightarrow Y_3$  as ancestor.

Definition: **Interesting Rule**

Let  $r \geq 1$  be a user-specified interest factor.

A rule is  $r$ -interesting with respect to one of its ancestors if its support is at least  $r$  times as high as the support expected based on the ancestor, or if its confidence is at least  $r$  times as high as the confidence expected based on the ancestor.

A rule is **interesting** if it has no ancestors or if it is  $r$ -interesting with respect to all its close ancestors.

Example: (Srikant/Agrawal 1995)

Rule #	Rule	Support	Item	Support
1	"Clothes $\Rightarrow$ Footwear"	10	Clothes	5
2	"Outerwear $\Rightarrow$ Footwear"	8	Outerwear	2
3	"Jackets $\Rightarrow$ Footwear"	4	Jackets	1

Let  $r=2$ .

- Rule 1 is interesting, since it has no ancestors.
- Rule 2 is interesting, since its support is at least  $r$  times the support expected based on its only ancestor (rule 1) (and the same holds for its confidence):

$$(i) \frac{\text{support(Outerwear)}}{\text{support(Clothes)}} = \frac{2}{5}$$

$$(ii) \text{expected\_support(Outerwear} \rightarrow \text{Footwear)} =$$

$$2/5 \cdot \text{support(Clothes} \rightarrow \text{Footwear)} = 2/5 \cdot 10 = 4$$

$$(iii) \text{support(Outerwear} \rightarrow \text{Footwear)} = 8 \geq 2 \cdot 4 = r \cdot 4$$

- Rule 3 is **not interesting**, since its support is less than  $r$  times the support expected based on rule 2:

$$(i) \frac{\text{support(Jackets)}}{\text{support(Outerwear)}} = \frac{1}{2}$$

$$(ii) \text{expected\_support(Jackets} \rightarrow \text{Footwear)} =$$

$$1/2 \cdot \text{support(Outerwear} \rightarrow \text{Footwear)} = 1/2 \cdot 8 = 4$$

$$(iii) \text{support(Jackets} \rightarrow \text{Footwear)} = 4 < 2 \cdot 4 = r \cdot 4$$

Remark:

In practise, the measure of interest is able to prune between 40% and 60% of all generated rules.

Remarks:

- basic algorithm can be made more efficient by applying several optimization steps,
  - e.g. pre-compute all super-concepts of all available items
- taxonomy provides means for
  - generating **more useful** rules
  - **pruning uninteresting** rules

Examples of real data:

- **supermarket** data:

- 548.000 items
- taxonomy has 4 levels, 118 roots
- $\approx$  1.5 million transactions with an average of 9.6 items per transaction
- optimized algorithm needs  $\approx$  90 minutes to generate all rules with support of 1%

- **department store** data:

- 228.000 items
- taxonomy has 7 levels, 89 roots
- $\approx$  570.000 transactions with an average of 4.4 items per transaction
- optimized algorithm needs  $\approx$  5 minutes to generate all rules with support of 1%