

# Lernen von Assoziationsregeln

Gegeben:

R eine Menge von Objekten, die binäre Werte haben

t eine Transaktion,  $t \subseteq R$

r eine Menge von Transaktionen

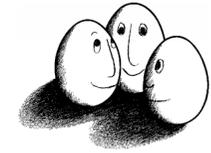
$S_{\min} \in [0,1]$  die minimale Unterstützung,

$Conf_{\min} \in [0,1]$  die minimale Konfidenz

Finde alle Regeln c der Form  $X \rightarrow Y$ , wobei  $X \subseteq R$ ,  $Y \subseteq R$ ,  $X \cap Y = \{\}$

$$s(r, c) = \frac{|\{t \in r \mid X \cup Y \in t\}|}{|r|} \geq S_{\min}$$

$$conf(r, c) = \frac{|\{t \in r \mid X \cup Y \in t\}|}{|\{t \in r \mid X \in t\}|} \geq conf_{\min}$$



# Binäre Datenbanken

R eine Menge von Objekten, die binäre Werte haben

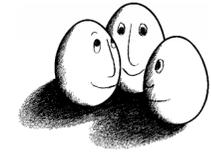
A, B, C

r eine Menge von Transaktionen

t eine Transaktion,  $t \subseteq R$

B,C

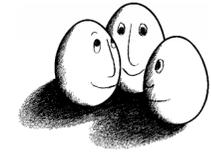
A	B	C	ID
0	1	1	1
1	1	0	2
0	1	1	3
1	0	0	4




# Warenkorbanalyse

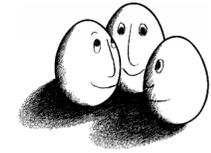
Aftershave	Bier	Chips	EinkaufsID
0	1	1	1
1	1	0	2
0	1	1	3
1	0	0	4

{Aftershave} → {Bier}       $s = \frac{1}{4}, \text{conf} = \frac{1}{2}$   
 {Aftershave} → {Chips}       $s = 0$   
 {Bier} → {Chips}       $s = \frac{1}{2}, \text{conf} = 2/3$  - zusammen anbieten?  
 {Chips} → {Aftershave}       $s = 0$   
 {Aftershave} → {Bier, Chips}       $s = 0$



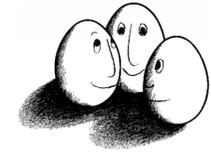
# Wieder ein Verband...





# Ordnungsrelation

- Hier ist die Ordnungsrelation die Teilmengenbeziehung.
- Eine Menge  $S_1$  ist größer als eine Menge  $S_2$ , wenn  $S_1 \supseteq S_2$ .
- Eine kleinere Menge ist allgemeiner.



# Assoziationsregeln

LH: Assoziationsregeln sind keine logischen Regeln!

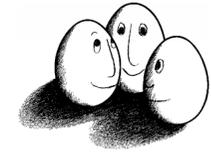
- In der Konklusion können mehrere Attribute stehen
- Attribute sind immer nur binär.
- 0 wird nicht wie „falsch“ behandelt.
- Mehrere Assoziationsregeln zusammen ergeben kein Programm.

LE: Binärvektoren (Transaktionen)

- Attribute sind eindeutig geordnet.

Aufgabe:

- Aus häufigen Mengen Assoziationsregeln herstellen



# Apriori Algorithmus

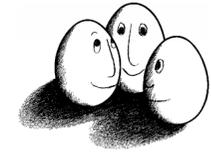
(Agrawal, Mannila, Srikant, Toivonen, Verkamo 1996)

LH des Zwischenschritts: Häufige Mengen  $L_k = X \cup Y$   
mit  $k$  Objekten (large itemsets, frequent sets)


*Idee:*

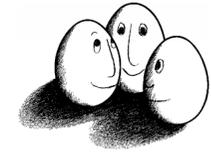
- **Wenn eine Menge häufig ist, so auch all ihre Teilmengen. (Anti-Monotonie)**
- **Wenn eine Menge selten ist, so auch all ihre Obermengen. (Monotonie)**
- Wenn  $X$  in  $L_{k+1}$  dann alle  $S_i \subseteq X$  in  $L_k$  (Anti-Monotonie)
- Alle Mengen  $L_k$ , die  $k-1$  Objekte gemeinsam haben, werden vereinigt zu  $C_{k+1}$ , d.h. sie bilden die Menge der Kandidaten für häufige Mengen in der nächsten Runde

Dies ist der Kern des Algorithmus', die **Kandidatengenerierung**.



# Beispiel





# Beispiel

Gesucht werden Kandidaten mit  $k+1 = 5$

$L_4 = \{ \{ABCD\}, \{ABCE\}, \{ABDE\}, \{ACDE\}, \{BCDE\} \}$

k-1 Stellen gemeinsam,  
vereinigen zu:

$I = \{ ABCDE \}$

Sind alle k langen Teilmengen von I in  $L_4$ ?

$\{ABCD\}$   $\{ABCE\}$   $\{ABDE\}$   $\{ACDE\}$   $\{BCDE\}$  – ja!

Dann wird I Kandidat  $C_5$ .


$L_4 = \{ \{ABCD\}, \{ABCE\} \}$

$I = \{ ABCDE \}$

Sind alle Teilmengen von I in  $L_4$ ?

$\{ABCD\}$   $\{ABCE\}$   $\{ABDE\}$   $\{ACDE\}$   $\{BCDE\}$  – nein!

Dann wird I nicht zum Kandidaten.



# Kandidatengenerierung

Erzeuge-Kandidaten( $L_k$ )

$C_{k+1} := \{\}$

Forall  $l_1, l_2$  in  $L_k$ , so dass  $l_1 = \{i_1, \dots, i_{k-1}, i_k\}$ ,  
 $l_2 = \{i_1, \dots, i_{k-1}, i'_k\}, i_k < i'_k$

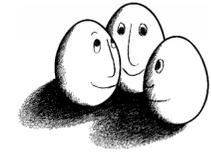
$l := \{i_1, \dots, i_{k-1}, i_k, i'_k\}$

if alle  $k$ -elementigen Teilmengen von  $l$  sind in  $L_k$

then  $C_{k+1} := C_{k+1} \cup \{l\}$

Return  $C_{k+1}$

Prune( $C_{k+1}, r$ ) vergleicht Häufigkeit von Kandidaten mit  $s_{\min}$  und liefert tatsächliche Mengen  $L_{k+1}$ .



# Häufige Mengen

Häufige-Mengen(R, r, smin)

$$C_1 := \bigcup_{i \in R} \{i\},$$

$$L_1 := \text{Prune}(C_1)$$

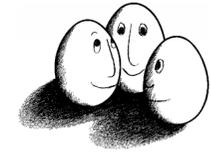
while  $L_k \neq \{ \}$

$$C_{k+1} := \text{Erzeuge-Kandidaten}(L_k)$$

$$L_{k+1} := \text{Prune}(C_{k+1}, r)$$

$$k := k+1$$

$$\text{Return } \bigcup_{j=2}^k L_j$$



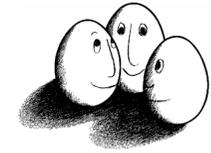
# APRIORI

Apriori(R, r, smin, confmin)

L:= Häufige-Mengen(R, r, smin)

c:= Regeln (L, confmin)

Return c



# Regelgenerierung

Aus den häufigen Mengen werden Regeln geformt.

Wenn die Konklusion länger wird, kann die Konfidenz sinken.

Die Ordnung der Attribute wird ausgenutzt:

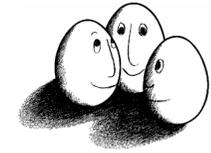
$$l_1 = \{i_1, \dots, i_{k-1}, i_k\} \quad c_1 = \{i_1, \dots, i_{k-1}\} \rightarrow \{i_k\} \quad \text{conf}_1$$

$$l_1 = \{i_1, \dots, i_{k-1}, i_k\} \quad c_2 = \{i_1, \dots\} \rightarrow \{i_{k-1}, i_k\} \quad \text{conf}_2$$

...


$$l_1 = \{i_1, \dots, i_{k-1}, i_k\} \quad c_k = \{i_1\} \rightarrow \{\dots, i_{k-1}, i_k\} \quad \text{conf}_k$$

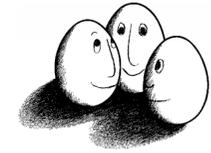
$$\text{conf}_1 \geq \text{conf}_2 \geq \dots \geq \text{conf}_k$$



# Implementierung

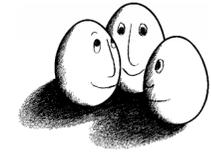
- Hash-Tree für den Präfixbaum, der sich aus der Ordnung der Elemente in den Mengen ergibt.
- An jedem Knoten werden Schlüssel und Häufigkeit gespeichert.





## Was wissen Sie jetzt?

- Assoziationsregeln sind keine logischen Regeln.
- Anti-Monotonie der Häufigkeit: Wenn eine Menge häufig ist, so auch all ihre Teilmengen.
- Man erzeugt häufige Mengen, indem man häufige Teilmengen zu einer Menge hinzufügt und diese Mengen dann auf Häufigkeit testet (Bottom-up Suche im Verband der Mengen).
- Monotonie der Seltenheit: Wenn eine Teilmenge selten ist, so auch jede Menge, die sie enthält.
- Man beschneidet die Suche, indem Mengen mit einer seltenen Teilmenge nicht weiter betrachtet werden.

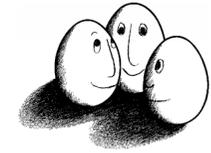


# Probleme von Apriori

- Im schlimmsten Fall ist Apriori exponentiell in  $R$ , weil womöglich alle Teilmengen gebildet würden.

In der Praxis sind die Transaktionen aber spärlich besetzt. Die Beschneidung durch  $s_{\min}$  und  $conf_{\min}$  reicht bei der Warenkorbanalyse meist aus.

- Apriori liefert unglaublich viele Regeln.
- Die Regeln sind höchst redundant.
- Die Regeln sind irreführend, weil die Kriterien die apriori Wahrscheinlichkeit nicht berücksichtigen. Wenn sowieso alle Cornflakes essen, dann essen auch hinreichend viele Fußballer Cornflakes.



# Prinzipien für Regelbewertungen

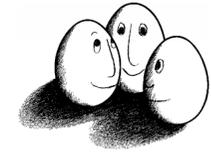
1.  $RI(A \rightarrow B) = 0$ , wenn  $|A \rightarrow B| = (|A| |B|) / |r|$   
A und B sind unabhängig.
2.  $RI(A \rightarrow B)$  steigt monoton mit  $|A \rightarrow B|$ .
3.  $RI(A \rightarrow B)$  fällt monoton mit  $|A|$  oder  $|B|$ .

Also:  $RI > 0$ , wenn  $|A \rightarrow B| > (|A| |B|) / |r|$   
d.h., wenn A positiv mit B korreliert ist.

$RI < 0$ , wenn  $|A \rightarrow B| < (|A| |B|) / |r|$   
d.h., wenn A negativ mit B korreliert ist.

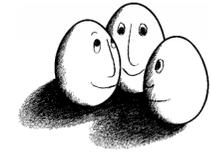
Wir wissen, dass immer  $|A \rightarrow B| \leq |A| \leq |B|$  gilt, also  
lokal:  $RI_{\max}$  wenn  $|A \rightarrow B| = |A|$  oder  $|A| = |B|$   
global:  $RI_{\max}$  wenn  $|A \rightarrow B| = |A| = |B|$

(Piatetsky-Shapiro 1991)



# Konfidenz

- Die Konfidenz erfüllt die Prinzipien nicht! (Nur das 2.)  
Auch unabhängige Mengen A und B werden als hoch-konfident bewertet.
- Die USA-Census-Daten liefern die Regel  
aktiv-militär → kein-Dienst-in-Vietnam mit 90% Konfidenz.  
Tatsächlich ist  $s(\text{kein-Dienst-in-Vietnam})=95\%$   
Es wird also wahrscheinlicher, wenn aktiv-militär gegeben ist!
- Gegeben eine Umfrage unter 2000 Schülern, von denen 60% Basketball spielen,  
75% Cornflakes essen. Die Regel  
Basketball → Cornflakes hat Konfidenz 66%  
Tatsächlich senkt aber Basketball die Cornflakes Häufigkeit!



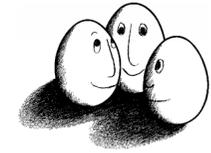
# Signifikanztest

- Ein einfaches Maß, das die Prinzipien erfüllt, ist:

$$|A \rightarrow B| - \frac{|A||B|}{|r|}$$

- Die Signifikanz der Korrelation zwischen A und B ist:

$$\frac{|A \rightarrow B| - \frac{|A||B|}{|r|}}{\sqrt{|A||B|\left(1 - \frac{|A|}{|r|}\right)\left(1 - \frac{|B|}{|r|}\right)}}$$



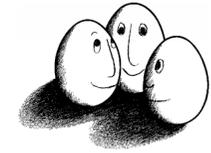
# Sicherheitsmaß

Shortliffe, Buchanan 1990 führten ein Sicherheitsmaß CF ein (für Regeln in Wissensbasen).

- Wenn  $\text{conf}(A \rightarrow B) > s(B)$   
 $\text{CF}(A \rightarrow B) = \text{conf}(A \rightarrow B) - s(B)/(1-s(B))$
- Wenn  $\text{conf}(A \rightarrow B) < s(B)$   
 $\text{CF}(A \rightarrow B) = \text{conf}(A \rightarrow B)$
- Sonst  
 $\text{CF}(A \rightarrow B) = 0$ .

Das Sicherheitsmaß befolgt die Prinzipien für Regelbewertung.

Wendet man Signifikanztest oder Sicherheitsmaß an, erhält man weniger (irrelevante, irreführende) Assoziationsregeln.



# Was wissen Sie jetzt?

- Sie haben drei Prinzipien für die Regelbewertung kennen gelernt:
  - Unabhängige Mengen sollen mit 0 bewertet werden.
  - Der Wert soll höher werden, wenn die Regel mehr Belege hat.
  - Der Wert soll niedriger werden, wenn die Mengen weniger Belege haben.
- Sie haben drei Maße kennen gelernt, die den Prinzipien genügen:
  - Einfaches Maß,
  - statistisches Maß und
  - Sicherheitsmaß.