

Einsatz und Realisierung von Datenbanksystemen


Übungsblatt 08

Maximilian E. Schüle
schuele@in.tum.de
02.11.060

Garching, 26. Juni 2017




Assoziationsregeln



Definitionen

Warenkorbdaten $\mathcal{D} = \{T_1, \dots, T_n\}$ $T_i \subseteq I = \{i_1, \dots, i_m\}$

Daten über miteinander gekaufte Elemente pro Einkauf oder pro Kunde




Frequentitemset $\mathcal{L} := \bigcup_{k=1}^{\infty} \mathcal{L}_k = \{L | L \subseteq I \wedge s(L) \geq s_0\}$

Menge von Elementen, genannt Items, die in einer bestimmten Anzahl von Warenkörben gemeinsam auftreten



Assoziationsregel $X \Rightarrow Y$ mit $X \subset T, Y \subset T, X \cap Y = \emptyset$

Korrelation zwischen Elementen
Starke Regel, wenn Konfidenz über Vertrauenswert



Kennzahlen

Support $\sigma(X) := |\{T | T \in \mathcal{D} \wedge X \subseteq T\}|$ $s(X) := \frac{\sigma(X)}{|\mathcal{D}|}$

Relative Häufigkeit einer Item-Menge
Minimale Support: definierter Schwellenwert

Konfidenz $k(X \Rightarrow Y) := P(Y|X) = \frac{\sigma(X \cup Y)}{\sigma(X)} = \frac{s(X \cup Y)}{s(X)}$


Häufigkeit der Transaktionen die Y enthalten, wenn diese bereits X enthalten

Apriori-Algorithmus – Apriori-Prinzip (1)

Apriori-Prinzip (a priori: lat. *ab*: von; lat. *prior*: vorherig)

Support einer Item-Menge maximal so groß wie der Support ihrer Teilmengen:

$$\forall X, Y \subseteq I. (X \subseteq Y) \Rightarrow s(X) \geq s(Y)$$



Apriori-Algorithmus – Frequentitemsets

Warenkörbe

TID	Items
1	{Stift, Lineal}
2	{Stift, Lineal, Papier}
3	{Stift, Lineal}
4	{Lineal, Papier}

Iteration	Item-Menge	Support
1	{Stift}	3
1	{Lineal}	4
1	{Papier}	2
2	{Stift, Lineal}	3
2	{Stift, Papier}	1
2	{Lineal, Papier}	2
3	{Stift, Lineal, Papier}	

```

 $\mathcal{L}_1 = \{\text{large 1 itemsets}\};$ 
for ( $k = 2; \mathcal{L}_{k-1} \neq \emptyset; k++$ ) do
     $\mathcal{C}_k = \text{apriori-gen}(\mathcal{L}_{k-1});$ 
    forall  $t \in \mathcal{D}$  do
         $\mathcal{C}_t = \text{subset}(\mathcal{C}_k, t);$ 
        forall  $c \in \mathcal{C}_t$  do
             $c.\text{count}++;$ 
        end
    end
     $\mathcal{L}_k = \{c \in \mathcal{C}_k | c.\text{count} \geq \sigma_0\};$ 
end
return  $\bigcup_k \mathcal{L}_k;$ 
    
```

Hausaufgabe 01 – Apriori

Siehe Tafel

VerkaufsTransaktionen	
TransID	Produkt
111	Drucker
111	Papier
111	PC
111	Toner
222	PC
222	Scanner
333	Drucker
333	Papier
333	Toner
444	Drucker
444	PC
555	Drucker
555	Papier
555	PC
555	Scanner
555	Toner

Zwischenergebnisse	
FI-Kandidat	Anzahl
{Drucker}	4
{Papier}	3
{PC}	4
{Scanner}	2
{Toner}	3
{Drucker, Papier}	3
{Drucker, PC}	3
{Drucker, Scanner}	
{Drucker, Toner}	3
{Papier, PC}	2
{Papier, Scanner}	
{Papier, Toner}	3
{PC, Scanner}	
{PC, Toner}	2
{Scanner, Toner}	

Hausaufgabe 02 – Threshold und NRA

Siehe Tafel Top-1-Berechnung (zur Bestimmung des günstigsten Wohnorts) für eine junge Familie mit zwei Kindern

Mietspiegel		Kindergarten	
Ort	Miete	Ort	Beitrag
Garching	800	Grünwald	-100
Ismaning	900	Unterföhring	0
Unterföhring	1000	Bogenhausen	100
Nymphenburg	1500	Ismaning	200
Bogenhausen	1600	Garching	250
Grünwald	1700	Nymphenburg	300

Hausaufgabe 03 – Skyline


SQL mit Skyline:

```
select MatrNr  
from Klausur k  
skyline of k.Vorbereitungszeit min, k.Note min
```

SQL ohne Skyline:


```
select MatrNr  
from Klausur k  
where not exists (  
    Select *  
    from klausur dom  
    Where -- wird nicht dominiert  
        dom.Vorbereitungszeit <= k.Vorbereitungszeit and  
        dom.Note <= k.Note and ( -- und sonst mind. genauso  
        dom.Vorbereitungszeit < k.Vorbereitungszeit or  
        dom.Note < k.Note) -- von einem eines besser  
)
```

Hausaufgabe 04 – K-Means




- 1. Initiale Werte
- 2. Clustern
- 3. Neue Zentren

Hausaufgabe 04 – K-Means



Hausaufgabe 04 – K-Means



Hausaufgabe 04 – K-Means

```

with points(id,x,y) as (
    VALUES ('A', 2, 12), ('B', 3, 11), ('C', 3,8), ('D', 5,4),
    ('E',7,5),('F',7,3),('G',10,8),('H',13,8)
),
clusters_0(cid,x,y) as (
    VALUES ('1', 2, 12), ('2', 3, 11), ('3', 3,8)
),
clusters_1(cid, x,y, count) as (
    select cid, avg(px), avg(py), count(*) from (
        select cid, p.x as px, p.y as py, rank() OVER (
            partition by p.id
            order by (p.x-c.x)*(p.x-c.x)+(p.y-c.y)*(p.y-c.y) asc,
            (c.x*c.x+c.y*c.y) asc)
        from points p, clusters_0 c
    ) x
    where x.rank=1
    group by cid
),
clusters_2 (cid, x,y, count) as (
    select cid, avg(px), avg(py), count(*) from (
        select cid, p.x as px, p.y as py, rank() OVER (
            partition by p.id
            order by (p.x-c.x)*(p.x-c.x)+(p.y-c.y)*(p.y-c.y) asc,
            (c.x*c.x+c.y*c.y) asc)
        from points p, clusters_1 c
    ) x
    where x.rank=1
    group by cid
),
clusters_3 (cid, x,y, count) as (
    select cid, avg(px), avg(py), count(*) from (
        select cid, p.x as px, p.y as py, rank() OVER (
            partition by p.id
            order by (p.x-c.x)*(p.x-c.x)+(p.y-c.y)*(p.y-c.y) asc,
            (c.x*c.x+c.y*c.y) asc)
        from points p, clusters_2 c
    ) x
    where x.rank=1
    group by cid
)
select * from clusters_3

```

```

with points(id,x,y) as (
    VALUES ('A',2,12), ('B',3,11),
    ('C',3,8), ('D',5,4), ('E',7,5),
    ('F',7,3), ('G',10,8), ('H',13,8)
)
select *
from kmeans(
    (table points),
    λ(a,b) sqrt((a.x-b.x)^2+(a.y-b.y)^2),
    3
)

```

Hausaufgabe 05 – Klassifikationsbaum


- 1) Vorhersageattribut
- 2) Partitionieren

```
Select wiealt, Schäden, count(*)
From Schadenshöhe
Group by wiealt, Schäden
```

```
Select Autotyp, Schäden, count(*)
From Schadenshöhe
Group by Autotyp, Schäden
```

```
Select Geschlecht, Schäden, count(*)
From Schadenshöhe
Group by Geschlecht, Schäden
```

Schadenshöhe			
wiealt	Geschlecht	Autotyp	Schäden
45	w	Van	gering
18	w	Coupé	gering
22	w	Van	gering
38	w	Coupé	gering
19	m	Coupé	hoch
24	m	Van	hoch
40	m	Coupé	hoch
40	m	Van	gering
:	:	:	:



Hausaufgabe 06 – Threshold

Preis - (100 * P S) + 24 * Unterhalt

Auto	Preis	PS	Auto	Unterhalt p. Monat
Seat Leon	25000€	200	Seat Leon	215€
Audi A1	17000€	96	Audi A1	220€
Citroen DS 4	20679€	100	Citroen DS 4	225€
Mini One	16500€	75	Mini One	262€
Mercedes C-Klasse	35000€	160	Mercedes C-Klasse	290€
Porsche Cayenne	80100€	420	Porsche Cayenne	430€

Zw. Ergebnis: Phase 4

Auto	Score
Seat Leon	10160
Audi A1	12680
Mini One	15288
Citroen DS 4	16079
Threshold	16967

Hausaufgabe 06 – NRA

Preis - (100 * PS) + 24 * Unterhalt

Auto	Preis	PS	Auto	Unterhalt p. Monat
Seat Leon	25000€	200	Seat Leon	215€
Audi A1	17000€	96	Audi A1	220€
Citroen DS 4	20679€	100	Citroen DS 4	225€
Mini One	16500€	75	Mini One	262€
Mercedes C-Klasse	35000€	160	Mercedes C-Klasse	290€
Porsche Cayenne	80100€	420	Porsche Cayenne	430€

NRA: Phase 4

Auto	Score
Seat Leon	10160
Audi A1	12680
Mini One	15288
Citroen DS 4	16079

<http://db.in.tum.de/teaching/ss17/impldb/>

Maximilian E. Schüle
schuele@in.tum.de
02.11.060

Viel Spaß!