Vorlesungsplan

- 17.10. Einleitung
- 24.10. Ein- und Ausgabe
- 31.10. Reformationstag, Einfache Regeln
- 7.11. Naïve Bayes, Entscheidungsbäume
- 14.11. Entscheidungsregeln, Assoziationsregeln
- 21.11. Lineare Modelle, Instanzbasiertes Lernen
- 28.11. Clustering
- 5.12. Evaluation
- 12.12. Evaluation
- 19.12. Lineare Algebra für Data Mining
- 9.1. Statistik für Data Mining
- 16.1. Lineare Modelle, Support Vector Machines (SVM)
- 19.1. Vorlesung statt Übung: Bayes-Netze
- 23.1. Clustering
- 26.1. Vorlesung statt Übung:Clustering II
- 30.1. **Finden von häufigen Teilstrukturen**
- 2. 2. Klausur

Häufige Item-Mengen: die Schlüssel-Idee

- *Häufige Item-Menge*: Menge von Items mit minimaler Unterstützung (ist mind. in min-supp. Transaktionen enthalten)
  - Monotonie-Prinzip: Jede Teilmenge einer häufigen Item-Menge muß auch eine häufige Item-Menge sein
    - z.B., wenn {*AB*} eine häufige Menge ist, müssen {*A*} und {*B*} auch häufig sein
  - Bestimme iterativ häufige Item-Mengen mit Kardinalität von 1 bis *k (k*-Item-Menge*)*

Apriori Algorithmus

- Join Schritt: C_k wird erzeugt durch Vereinigung von L_{k-1} mit sich selbst
- Prune Schritt: Jede (k-1)-Item-Menge, die nicht häufig ist, kann nicht Teilmenge einer häufigen k-Item-Menge sein
- Pseudo-code:

C_k: Kandidaten für Item-Mengen der Größe k
L_k : häufige Item-Mengen der Größe k

L_1 = {häufige Items};
for (k = 1; L_k !=∅; k++) **do begin**
  C_{k+1} = erzeuge Kandidaten aus L_k;
  for each Transaktion t in der Datenbank do
    erhöhe den Zähler aller Kandidaten in C_{k+1} die in t enthalten sind
  L_{k+1} = Kandidaten in C_{k+1} mit minimaler Unterstüzung
  end
return $\cup_k L_k$;

Methoden zur Verbessung der Effizienz von Apriori

- Hash-basiertes Zählen der Item-Mengen: Eine *k*-Item-Menge, deren Hash-Bucket Zähler unter Min-Support liegt, kann nicht häufig sein
- Transaktionsreduktion: Eine Transaktion, die keine häufige k-Item-Menge enthält, ist nutzlos in folgenden DB Durchläufen
- Partitionieren: Jede Item-Menge, die potentiell häufig in der DB ist, muß in mindestens einer der Partitionen der DB häufig sein
- Sampling: Untersuche eine Teilmenge der gegebenen Daten, kleinerer min-support + eine Methode zum Prüfen der Vollständigkeit

Ist Apriori schnell genug? — Performanz-Engpässe

- Der Kern des Apriori Algorithmus:
  - Nutze häufige (k – 1)-Item-Mengen zum Erzeugen der Kandidaten
  - Nutze DB Durchlauf zum Prüfen der Kandidaten
- Engpaß von *Apriori*: Kandidatenerzeugung
  - Riesige Kandidaten-Mengen:
    - 10^4 häufige 1-Item-Mengen erzeugen 10^7 Kandidaten 2-Item-Mengen
    - Zum Finden einer häufiges Item-Menge der Größe 100, müssen etwa $2^{100} \approx 10^{30}$ Kandidaten erzeugt werden.
  - Mehrfache Durchläufe über die DB:
    - Es werden (n +1) Durchläufe benötigt, n ist die Länge der größten Item-Menge

Finden von häufigen Item-Mengen ohne Kandidaten Erzeugung

- Komprimiere eine große DB in eine kompakten, Frequent-Pattern Baum (FP-tree)-Struktur
  - stark komprimiert, aber vollständige Information für das Finden von häufigen Item-Mengen
  - vermeidet DB Durchläufe
- FP-tree-basierte Methode zum Finden von häufigen Item-Mengen
  - Teile-und-Herrsche Prinzip: zerlege Gesamtaufgabe in kleinere Aufgaben
  - Vermeide Kandidatenerzeugung:
    dafür Test auf einem Teil der DB

Konstruktion des FP-Baums aus den Transaction

TID	Items bought	(ordered) frequent items
100	{f, a, c, d, g, i, m, p}	{f, c, a, m, p}
200	{a, b, c, f, l, m, o}	{f, c, a, b, m}
300	{b, f, h, j, o}	{f, b}
400	{b, c, k, s, p}	{c, b, p}
500	{a, f, c, e, l, p, m, n}	{f, c, a, m, p}

min_support = 3

Schritte:

1. Durchlaufe DB einmal, finde häufige 1-Itemmengen
2. Sortiere häufige Items absteigend nach Häufigkeit
3. Durchlauf DB nochmal, konstruiere FP-Baum

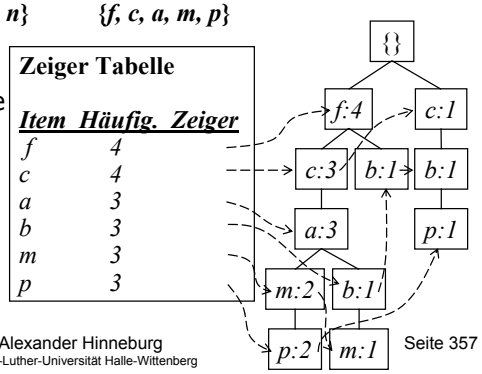

Vorteile der FP-Baum Struktur

- Vollständigkeit:
  - Item-Mengen in Transaktionen werden nicht zerstört
- Kompaktheit
  - reduziert irrelevante Information — nicht-häufige Items werden gelöscht
  - Sortierung nach absteigender Häufigkeit: häufigere Items werden in vielen Transaktionen nur einmal repräsentiert
  - Beispiele für DBs mit Kompressionsrate 100

Schritte zum Verarbeiten der FP-Bäume

1) Konstruiere bedingte Transaktionsmenge für jeden Knoten in einem FP-Baum
2) Konstruiere bedingten FP-Bäume aus bedingten Transaktionsmengen
3) Durchsuche rekursiv die bedingten FP-Bäume und vergrößere die häufigen Item-Mengen, die bisher gefunden worden sind
   - Falls der bedingte FP-Baum nur einen Pfad enthält, erzeuge alle häufigen Item-Menge durch Aufzählen

Schritt 1: Vom FP-Baum zur bedingten Transaktionsmenge

- Beginne mit der Zeigertabelle und durchlaufe die Liste für jedes häufige Item
- Sammle alle Präfix-Pfade eines Item, um dessen bedingte Muster-Menge aufzubauen

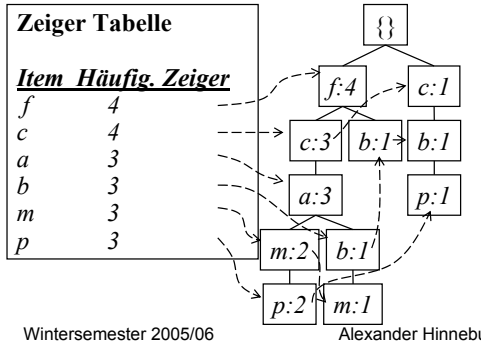

bedingte Trans.-Mengen

Item	*bedingte Trans.-Menge*
c	***f:3***
a	***fc:3***
b	***fca:1, f:1, c:1***
m	***fca:2, fcab:1***
p	***fcam:2, cb:1***

min_support = 3

Eigenschaften von FP-Bäumen für die Konstruktion von bedingten Trans.-Mengen

- Eigenschaft der Item-Liste
  - Für jedes häufige Item a_i gilt, alle möglichen häufigen Item-Mengen werden beim Durchlaufen von a_i's Liste erzeugt
- Präfix-Pfad Eigenschaft
  - Die Häufigkeit einer Item-Menge (repräsentiert durch den Präfix-Pfad P) für einen Knoten a_i wird im Zähler des Knotens a_i gespeichert.

Schritt 2: Konstruktion des bedingten FP-Baumes

- Für jede bedingte Trans. -Menge
  - Fasse die Zähler für jedes Item in der Menge zusammen
  - Konstruiere den FP-Baum für die häufigen Items dieser Menge

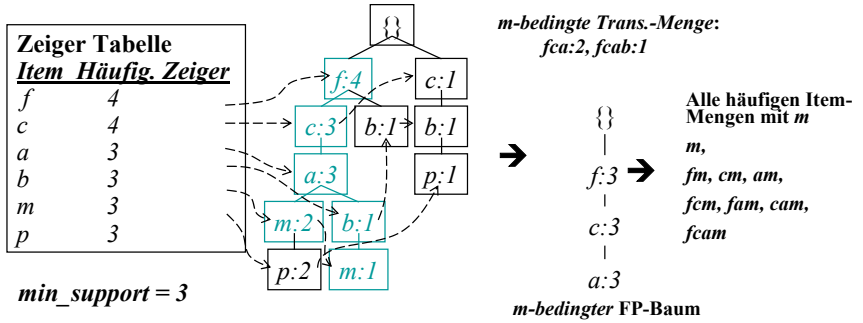

Finden von häufigen Item-Mengen durch Erzeugen von bedingten Trans.-Mengen

Item	Bedingte Trans.-Menge	Bedingter FP-Baum
p	{(fcam:2), (cb:1)}	{(c:3)}|p
m	{(fca:2), (fcab:1)}	{(f:3, c:3, a:3)}|m
b	{(fca:1), (f:1), (c:1)}	leer
a	{(fc:3)}	{(f:3, c:3)}|a
c	{(f:3)}	{(f:3)}|c
f	leer	leer

min_support = 3

Schritt 3: Rekursives Durchsuchen der bedingten FP-Bäume

min_support = 3

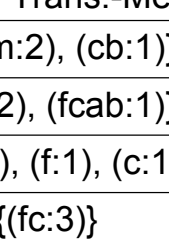

***m-bedingter* FP-Baum**

Bedingte Trans.-Menge für "am": (fc:3)

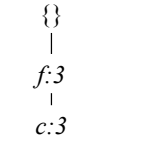

***am-bedingter* FP-Baum**

Bedingte Trans.- Menge für "cm": (f:3)

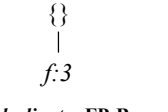

***cm-bedingter* FP-Baum**

Bedingte Trans.- Menge für "cam": (f:3)

***cam-bedingter* FP-Baum**

FP-Baum mit nur einem Pfad

- Angenommen ein FP-Baum T hat nur einen Pfad P
- Die vollständige Menge der häufigen Item-Mengen von T kann durch Aufzählen aller Kombinationen der Teilpfade von P erzeugt werden

min_support = 3

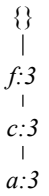

→

Alle häufigen Item-Mengen mit *m*

m,
fm, cm, am,
fcm, fam, cam,
fcam

***m-bedingter* FP-Baum**

Prinzips des Vergrößerns der häufigen Item-Mengen

- Eigenschaft
  - Sei α eine häufige Item-Menge in der DB, B α's bedingte Trans.-Menge und β eine Item-Menge in B. Dann ist $\alpha \cup \beta$ eine häufige Item-Menge in der DB, gdw. β ist häufig in B.
- "*abcdef* " ist eine häufige Item-Menge, gwd.
  - "*abcde* " ist eine häufige Item-Menge, und
  - "*f* " ist häufig in der Menge der Transaktionen die "*abcde* " enthalten

Warum ist das Vergrößern häufiger Item-Mengen schnell?

- Experimentelle Studie zeigt
  - FP-growth ist deutlich schneller als Apriori
- Erklärung
  - Keine Erzeugung von Kandidaten, kein Kandidaten-Test
  - Kompakte Datenstruktur
  - Vermeidung von wiederholten DB Durchläufen
  - Basisoperationen sind Zählen und FP-Baum Konstruktion

FP-growth vs. Apriori: Skalierbarkeit bezüglich Min-Support