Vorlesung Wissensentdeckung in Datenbanken

Tree Projection – LTree

Katharina Morik, Claus Weihs

Informatik LS 8
Computergestützte Statistik
Technische Universität Dortmund

16.7.2009

Gliederung

1 Einführung

2 LTrees

3 LTrees zum frequent set mining

4 Vor- und Nachteile

Tree Projection – LTree

- Man kann statt FPtrees auch LTrees verwenden.
- Implementierungsdetails von frequent set mining FIMI workshops (Goethals, Zaki)
- Aspekte, die bedacht werden:
  - Speicherbedarf
    - Passt in Hauptspeicher?
    - Passt in Cache?
  - I/O Zugriffe auf Datenbank
  - Laufzeit

R.C. Agarwal, C.C. Aggarwal, V.V. Prasad 2001
„A Tree Projection Algorithm for Generation of Frequent Itemsets“
in: J. Parallel and Distribute Computing 61(3), 350 – 371

LTrees

- Lexikografische Ordnung der items – hier: $a < b < c < d < e < f$
- Mögliche Erweiterungen eines Kotens P sind die lexikalisch größeren Geschwister – hier: $R(a) = \{b, c, d, e, f\}$, $R(ab) = \{c, d, f\}$, $R(b) = \{c, d\}$, $R(bc) = \{d\}$
- Erweiterung eines Knotens P um ein weiteres häufiges item hier: $E(a) = \{b, c, d, f\}$, $E(b) = \{c, d\}$, $E(c) = \{d, f\}$, $E(d) = \{f\}$
- $E(P) \subseteq R(P) \subseteq E(Q)$ wobei P eine Erweiterung von Q ist.

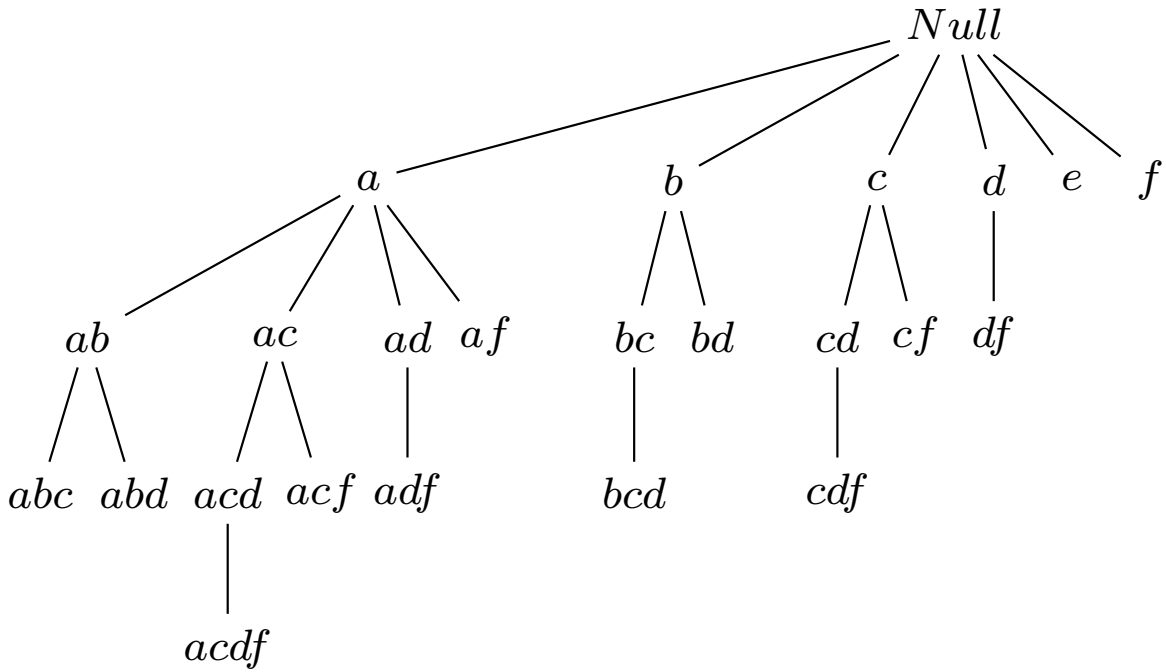

Angenommenes Beispiel A

LTrees in frequent set mining

- Knoten ist aktiv, wenn er als Erweiterung generiert wird – hier: $\{a, ab, ac, abc, acd\}$; inaktiv, wenn der Baum, dessen Wurzel er ist, nicht erweitert werden kann.
- Ein Grenzknoten ist ein aktiver Knoten, dessen Erweiterung noch nicht generiert ist – hier: $\{abc, acd\}$.
- Aktive items $F(P)$ von P sind
  - P ist Grenzknoten, dann $F(P) = R(P)$
  - Sonst aktive Knoten in $E(P)$ und deren aktive items.

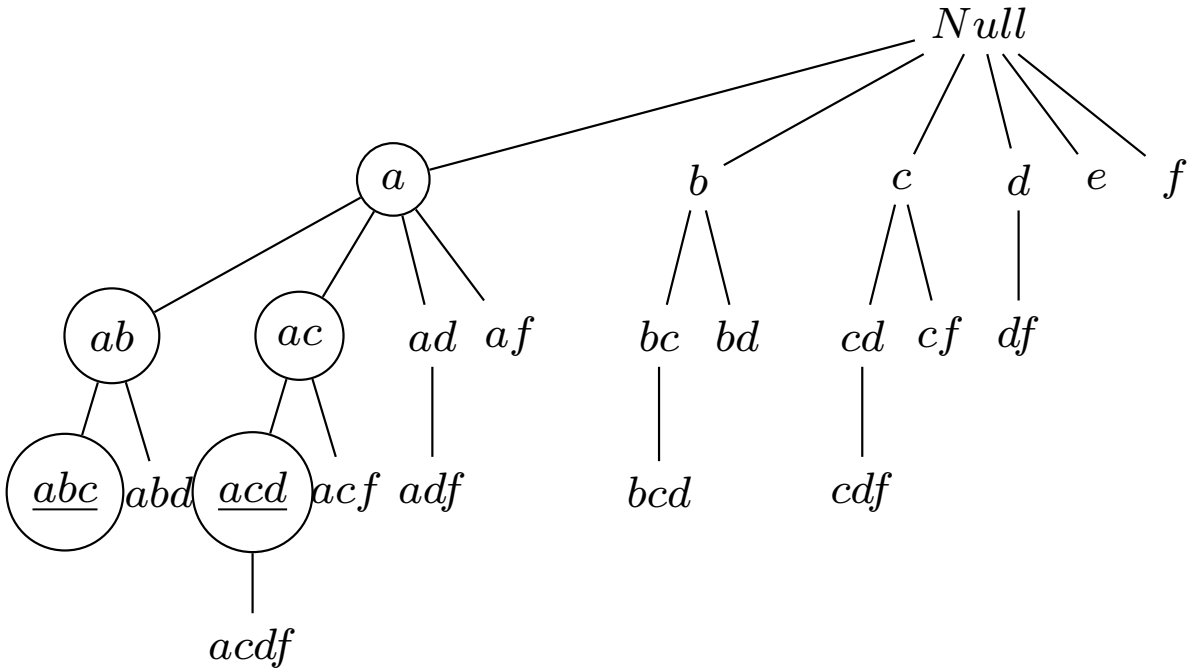

Knoten

- An einem Knoten P sind gespeichert:
  - Der item set P
  - $AE(P)$: Aktuell aktive Erweiterungen von P
  - $F(P)$:aktive items von P
  - Matrix $E(P) \times E(P)$

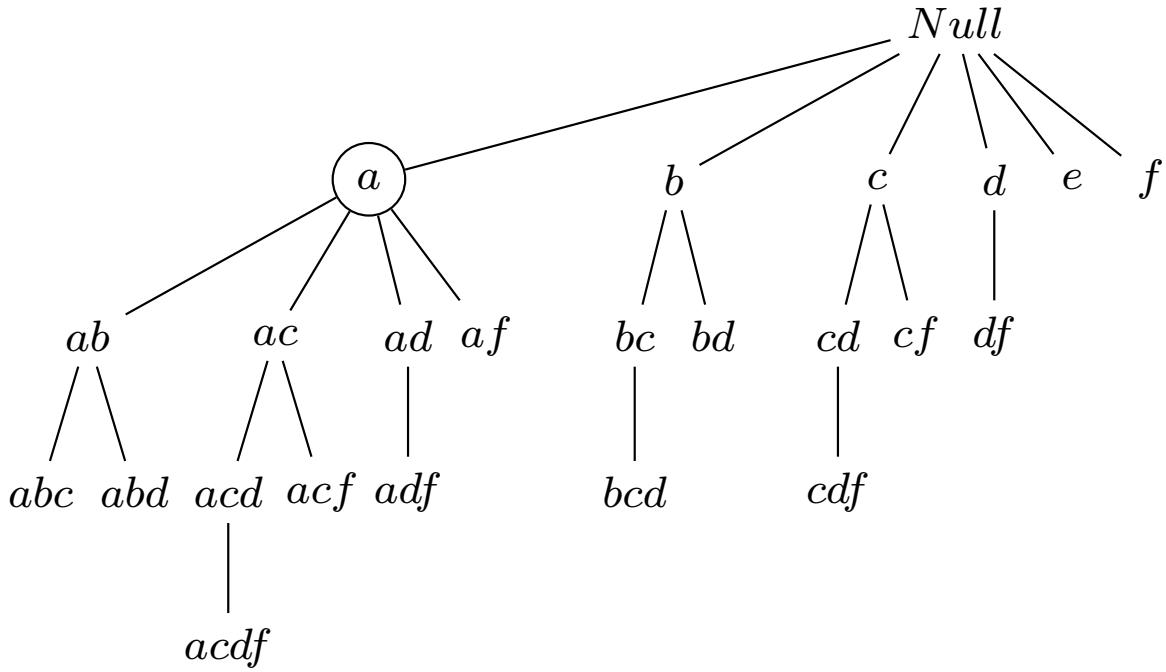

a
$AE(a) = \{b, c\}$
$F(a) = \{b, c, d, f\}$

a	b	c	d	f
b	-			
c	$\#abc$	-		
d	$\#abd$	$\#acd$	-	
f	$\#abf$	$\#acf$	$\#adf$	-

Tree Projection

- Projektion von Datenbanktupel T auf itemset P:
  - falls $T \cap P = \{\}$, ist $T(P) = null$,
  - sonst: $T(P) = T \cap F(P)$
- Beispiel: Transaktion $\{a, b, c, d, e, f, g, h, k\}$
  $T(a) = \{b, c, d, f\}$

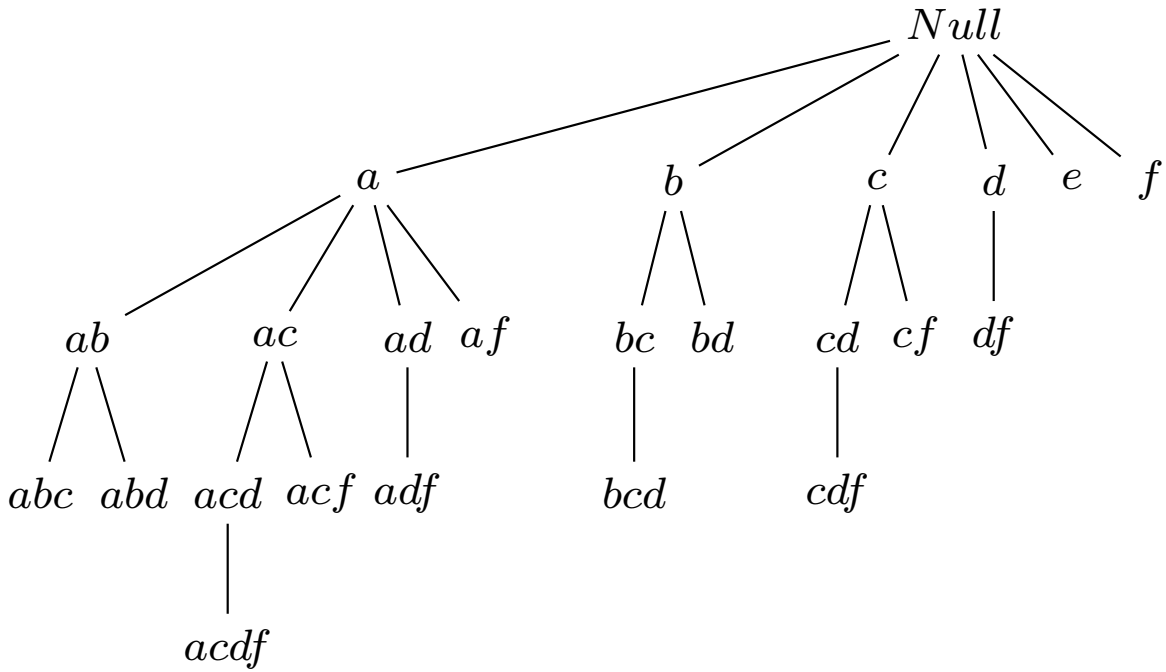

Algorithmus – Breitensuche

- Aufbau des LTrees
  - $AddTree()$
  - $PruneTree()$
- Tree projection
  - $AddCounts()$
- Vorteile Breitensuche:
  - Beschränkung auf eine Ebene in einem Schritt $\rightarrow$ passt in Hauptspeicher
- Nachteile Breitensuche:
  - Tree projection auf jeder Ebene $\rightarrow k$ DB scans

BreadthFirst$(minSup : s, DB : T)$
$L_1 :=$ all frequent 1-itemsets;
$E(null) :=$ set of items in L_1;
make top-level of LTree;
$k := 1$;
$while\ level - k\ not\ null\ do$

- create matrices at level $k - 1$nodes
- $for\ each$ T in T do $AddCounts$(T);
- $AddTree(k)$; // creates L_{k+1}
- $PruneTree(k)$; // deletes inactive nodes up to level $k + 1$
- $k := k + 1$;

$AddTree()$, $PruneTree()$

- $AddTree(k)$
  - L_{k+1} = alle $k+1$ itemsets mit ausreichendem support;
  - Knoten auf Ebene $k+1$ hinzufügen;
- $PruneTree(k)$
  - entferne alle inaktiven Knoten auf Ebene $k+1$;
  - für jeden Knoten P auf Ebene $k+1$ do $F(P) := R(P)$;
  - for $r = k, --1, until\ 0$ do
    - entferne inaktive Knoten auf Ebene r;
    - update $F(P)$ aller Knoten auf Ebene r und ihrer Kinder;

Matrix zählen

Beispiel Matrix
$E(Null) \times E(Null)$
für Kandidaten der Ebene 2:
Verarbeitung von 4
Transaktionen

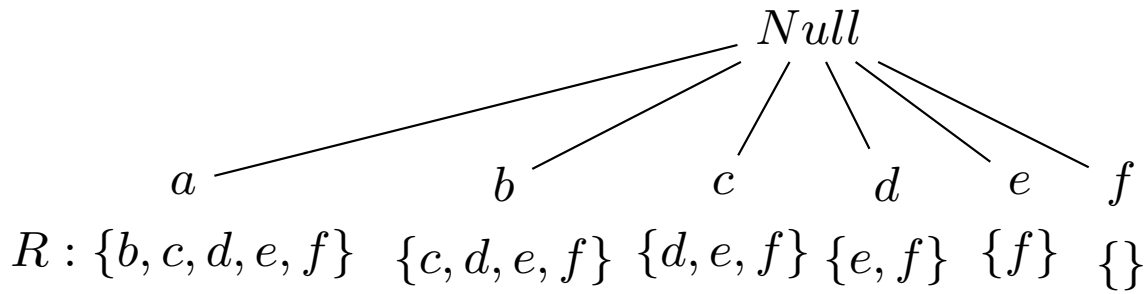

	a	b	c	d	e
b	ab 1				
c	ac 2	bc 1			
d	ad 2	bd 2	cd 3		
e	ae 1	be 2	ce 2	de 3	
f	af 2	bf 1	cf 3	df 3	ef 2

Transaktionen

Matrix zählen

Beispiel Matrix
$E(Null) \times E(Null)$
für Kandidaten der Ebene 2:
Verarbeitung von 4
Transaktionen

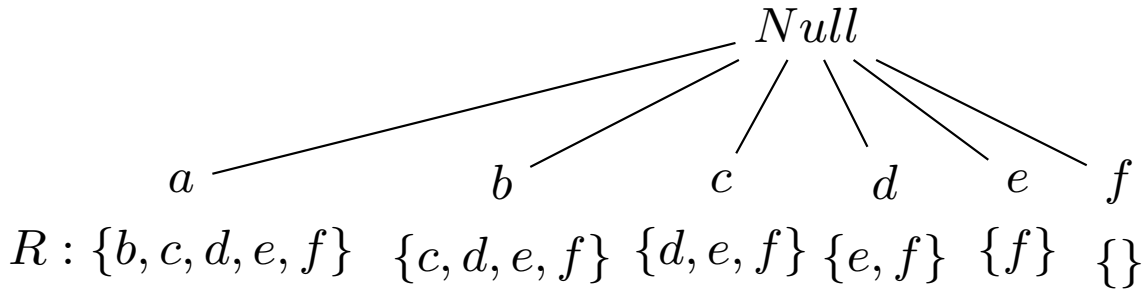

	a	b	c	d	e
b	ab 1				
c	ac 2	bc 1			
d	ad 2	bd 2	cd 3		
e	ae 1	be 2	ce 2	de 3	
f	af 2	bf 1	cf 3	df 3	ef 2

Transaktionen
acdf

Matrix zählen

Beispiel Matrix
$E(Null) \times E(Null)$
für Kandidaten der Ebene 2:
Verarbeitung von 4
Transaktionen

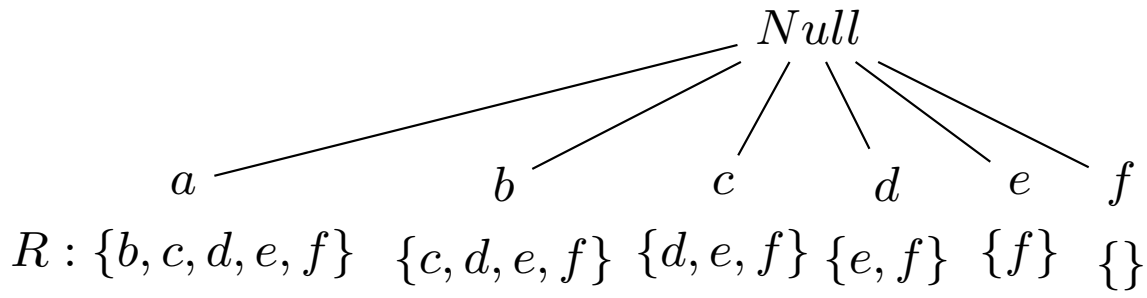

	a	b	c	d	e
b	ab 1				
c	ac 2	bc 1			
d	ad 2	bd 2	cd 3		
e	ae 1	be 2	ce 2	de 3	
f	af 2	bf 1	cf 3	df 3	ef 2

Transaktionen
acdf
abcdef

Matrix zählen

Beispiel Matrix
$E(Null) \times E(Null)$
für Kandidaten der Ebene 2:
Verarbeitung von 4
Transaktionen

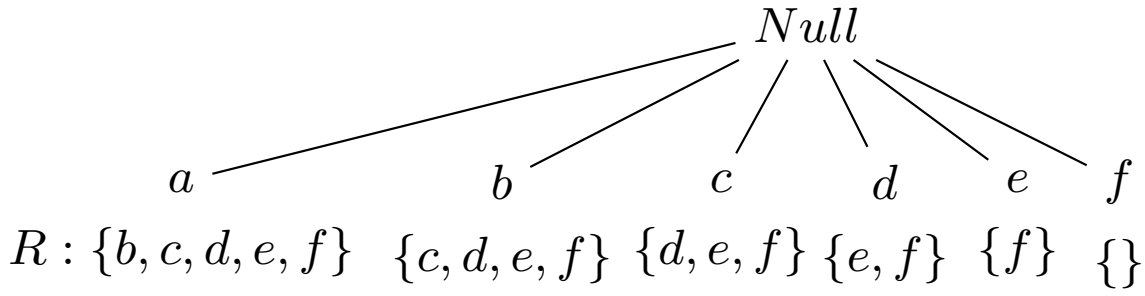

	a	b	c	d	e
b	ab 1				
c	ac 2	bc 1			
d	ad 2	bd 2	cd 3		
e	ae 1	be 2	ce 2	de 3	
f	af 2	bf 1	cf 3	df 3	ef 2

Transaktionen

acdf

abcdef

bde

Matrix zählen

Beispiel Matrix
$E(Null) \times E(Null)$
für Kandidaten der Ebene 2:
Verarbeitung von 4
Transaktionen

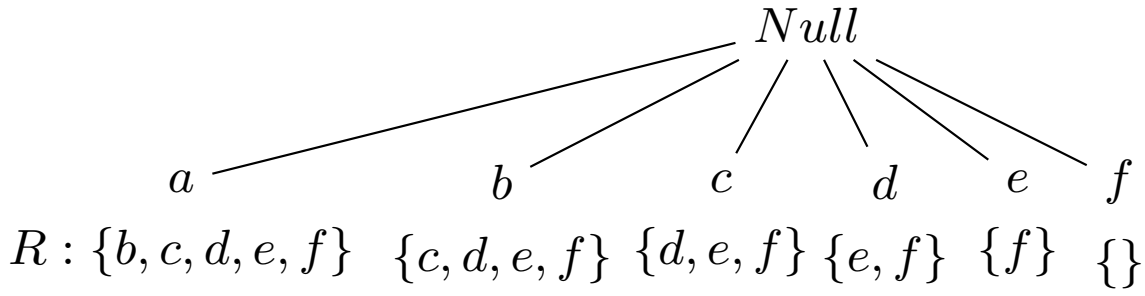

	a	b	c	d	e
b	ab 1				
c	ac 2	bc 1			
d	ad 2	bd 2	cd 3		
e	ae 1	be 2	ce 2	de 3	
f	af 2	bf 1	cf 3	df 3	ef 2

Transaktionen

acdf

abcdef

bde

cdef

Projektion

- Transaktionen müssen auf die Grenzknoten projiziert werden, wo dann in der Matrix gezählt wird.
- Beim Erzeugen von Knoten auf Ebene $k+1$, wird für alle Knoten P der Ebene $k-1$ jeweils eine Matrix $E(P) \times E(P)$ angelegt.
- Was dann noch an Speicher frei ist, ist für die Transaktionen da.
- Strategien:
  - Je 1 Transaktion auf alle Knoten der Ebene $k-1$ projizieren: weniger Speicher, mehr Rechenzeit;
  - Viele Transaktionen auf einen Knoten projizieren: bessere Rechenzeit, mehr Speicher.
  - Ausweg: Transaktion von oben nach unten über die Ebenen projizieren, blockweise.

Cache-Blöcke

- Zählen der Häufigkeit von $k+1$-itemsets, die Nachfolger von $k-1$-Knoten sind gemäß Ausschnitten aus der Matrix.
- Beispiel: Transaktion $\{a, b, \ \ c\ \ , d, \ \ e\ , \ \ f\ \}$ strip ‚c'

$p1$ $p2$ $p3$

strip

	a	b	c	d	e
b	ab				
c	ac	bc			
d	ad	bd	cd+1		
e	ae	be	ce+1	de+1	
f	af	bf	cf+1	df+1	ef+1

Auf jede Transaktion, die mindestens ein item mit denen im ‚strip' teilt, werden 3 Zeiger gesetzt.

for $outerP$ $p1$ bis $p2$ do

for $innerP = outerP + 1$ to $p3$ do

$MatrixEintrag(outerP, innerP) + 1$

Tiefensuche

- Vorteile Tiefensuche
  - von der Wurzel zum aktuellen Knoten wird die Baumprojektion einfach durchgereicht
- Nachteile Tiefensuche
  - passt am Anfang nicht in Hauptspeicher, denn vom Wurzelknoten wird die gesamte Datenbank hinunterprojiziert

- Kombination:
  - anfangs Breitensuche
  - sobald alle Baumprojektionen an den Grenzknoten in den Hauptspeicher passen, werden sie in separate Dateien je Grenzknoten gespeichert und jeweils per Tiefensuche bearbeitet.

Experimente

- Sehr effizient: 213 972 Transaktionen mit durchschittlich 31 items
  - level 0 (2-itemset Kandidaten) 23,49 CPU Sekunden bei 16 276 365 Matrixeinträgen
  - level 1 (3-itemset Kandidaten) 25,44 CPU Sekunden bei 3 521 972 Matrixeinträgen
  - level 2 (4-itemset Kandidaten) 9,76 CPU Sekunden bei 219 269 Matrixeinträgen
- Puffer von Transaktionen wird depth-first auf Knoten im Cache projiziert – günstige Zugriffe auf immer die selben Adressen im Cache.

Was wissen wir jetzt?

- LTrees sind kompakter als hash trees.
- Tree Projection verwendet LTrees für häufige Mengen – lexikographische Ordnung.
- Es gibt keine explizite Kandidatengenerierung, aber der Aufbau des LTrees wird ähnlich wie bei Apriori realisiert. Allerdings wird erst hinterher der Baum gestutzt. Daher langsamer als FP growth.
- Sorgfalt bei der Speicherausnutzung:
  - Breiten- vs. Tiefensuche beim LTree-Aufbau,
  - Tiefensuche beim Projizieren der Tupel
  - Ausschnitte aus den Matritzen nach ‚strips‘