INTELLIGENTE DATENANALYSE IN MATLAB

Unüberwachtes Lernen: Clustern von Attributen

Michael Brückner/Tobias Scheffer

Literatur

- J. Han, M. Kamber: Data Mining – Concepts and Techniques.
- J. Han et. al: Mining Frequent Patterns without Candidate Generation.
- C. Zhang, S. Zhang: Association Rule Mining.

Überblick

- Schritte der Datenanalyse:

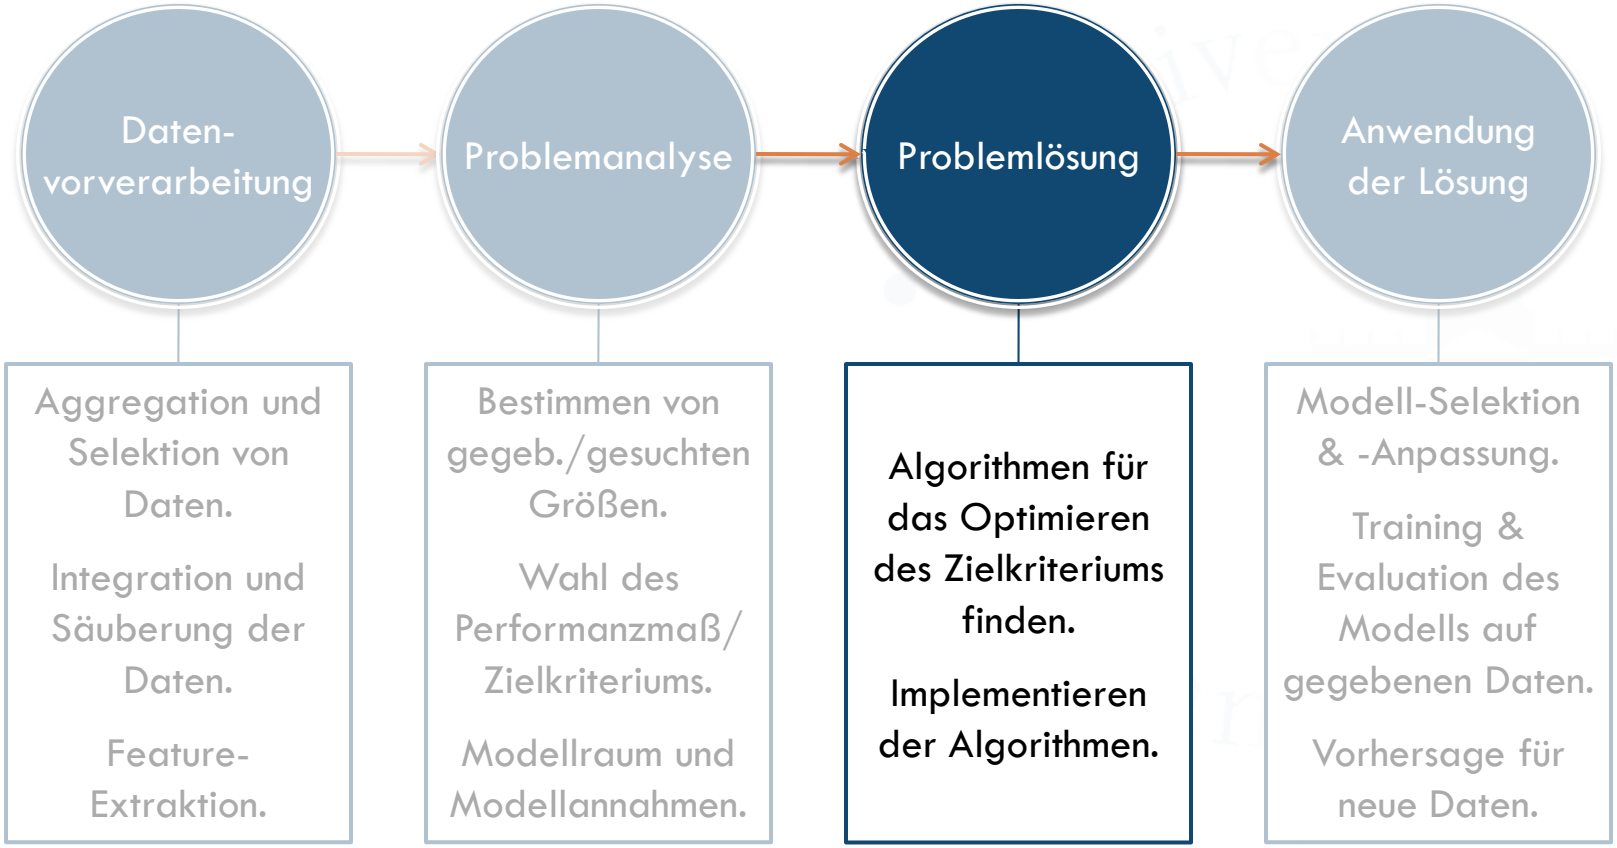

Unüberwachtes Lernen

Arten von Modellen & Lernproblemen

- Clustern von Instanzen:
  - Finden und deterministische bzw. probabilistische Zuweisung zu Bereichen mit vielen Datenpunkten (Cluster).
- Clustern von Attributen:
  - Häufig zusammen auftretende (ähnliche bzw. korrelierte) Attribute finden.
- Clustern von Instanzen & Attributen (Co-Clustern):
  - Gleichzeitiges Clustern von Instanzen und Attributen.
- Outlier Detection:
  - Suche nach seltenen/auffälligen Datenpunkten.

Clustern von Attributen

Problemstellung

- Gegeben: Menge von n Trainingsdaten $\mathbf{x}_i \in X^m$ mit m Attributen (Datenmatrix $\mathbf{X} \in X^{m \times n}$ mit Spaltenvektoren $\mathbf{x}_i$).
- Gesucht:
  - Numerische Attribute:
    - Cluster von ähnlichen, assoziierten oder redundanten Attributen analog zu Clustern von Instanzen (transponierte Datenmatrix clustern).
  - Diskrete Attribute:
    - Finden von Frequent Itemsets, d.h. häufig auftretender Muster bspw. für Kompression, Visualisierung etc.
    - Lernen von Assoziationsregeln der Form „wenn die Attribute $1, 2, 3$ die Werte a, b, c annehmen, dann haben die Attribute $4, 5$ die Werte d, e“.

Clustern von Attributen

Anwendung

- Warenkorbanalyse.
  - z.B. für Katalog-Design, Cross-/Up-Selling, Empfehlungs-systeme, Produktanordnung in Supermärkten usw.
- Analyse des Surfverhaltens von Internetnutzern.
  - z.B. zur Optimierung der Navigation auf einer Webseite.
- Gruppierung von Dokumenten.
  - z.B. für Email-Batch-Erkennung, Plagiat-Erkennung.

Lernen von Assoziationsregeln

- Gesucht sind Assoziationsregeln der Form „wenn die Attribute p_i der Menge $P = \{p_1, \ldots, p_s\} \subset \{1, \ldots, m\}$ bestimmte Werte y_i annehmen, dann haben die Attribute q_j der Menge $Q = \{q_1, \ldots, q_t\} \subset \{1, \ldots, m\}$, $P \cap Q = \varnothing$ die Werte y'_j “.
  - Definition: Boolesche Funktion

$$g(\mathbf{x}, p, y) = \begin{cases} wahr & x_p = y \\ falsch & x_p \neq y \end{cases}$$

  - Definition: Assoziationsregel

$$g(\mathbf{x}, p_1, y_1) \wedge \ldots \wedge g(\mathbf{x}, p_s, y_s) \Rightarrow g(\mathbf{x}, q_1, y'_1) \wedge \ldots \wedge g(\mathbf{x}, q_t, y'_t)$$

Lernen von Assoziationsregeln

Beispiel

- Beispiel Warenkorbanalyse: Welche Produkte werden (nicht) zusammen gekauft?

Kunde	Brot	Milch	Eier	Bier	Müsli
1	nein	ja	ja	nein	ja
2	ja	ja	nein	ja	nein
3	nein	nein	ja	ja	nein
4	nein	ja	ja	nein	ja

  - Mögliche boolesche Fragen:
    - Kaufte Kunde 1 Milch? $g(\mathbf{x}_1, \text{Milch}, \text{ja}) = \textit{wahr}$
    - Kaufte Kunde 3 keine Eier? $g(\mathbf{x}_3, \text{Eier}, \text{nein}) = \textit{falsch}$
  - Mögliche Assoziationsregeln:
    - Wer Milch kauft, kauft auch Müsli: $g(\mathbf{x}, \text{Milch}, \text{ja}) \Rightarrow g(\mathbf{x}, \text{Müsli}, \text{ja})$
    - Wer Bier und Eier kauft, kauft kein Brot:
      $g(\mathbf{x}, \text{Bier}, \text{ja}) \wedge g(\mathbf{x}, \text{Eier}, \text{ja}) \Rightarrow g(\mathbf{x}, \text{Brot}, \text{nein})$

Lernen von Assoziationsregeln

Dateneigenschaften

- Wertebereich der Attribute:
  - Binäre/boolesche, nominale oder ordinale Attribute.
  - Numerische Attribute: müssen zuvor diskretisiert werden.
- Bedeutung der Attribute:
  - Verschiedene Attribute/Belegungen unterschiedlich „wichtig“.
    - z.B. „Wer Computer kauft, kauft auch Computer-Zubehör“ ist evtl. informativer als „Wer einen Dell-PC kauft, kauft auch eine Maus“.
    - z.B. „Wer Milch kauft, kauft auch Müsli“ ist evtl. informativer als „Wer Milch kauft, kauft kein Bier“.
  - Redundanz, d.h. Ähnlichkeit/Korrelation zwischen Attributen führt zu semantisch gleichen (redundanten) Regeln.

Lernen von Assoziationsregeln

Bewertung von Assoziationsregeln

- Es gibt exponentiell viele mögliche Assoziationsregeln.
- Assoziationsregeln unterschiedlich stark durch Daten gestützt, d.h. unterschiedlich wahrscheinlich.
  - Betrachten Ereignisse:

$$A = g(\mathbf{x}, p_1, y_1) \wedge \ldots \wedge g(\mathbf{x}, p_s, y_s)$$
$$B = g(\mathbf{x}, q_1, y_1') \wedge \ldots \wedge g(\mathbf{x}, q_t, y_t')$$

  - Frage: Wie wahrscheinlich ist eine Assoziationsregel $A \Rightarrow B$ gegeben die Daten?

$$P(A \Rightarrow B \mid \mathbf{X}) = P(\neg A \vee B \mid \mathbf{X}) = 1 - P(A \mid \mathbf{X}) + P(A, B \mid \mathbf{X})$$

  - Aus $P(A \mid \mathbf{X}) = 0$ folgt jedoch $P(A \Rightarrow B \mid \mathbf{X}) = 1$.

Lernen von Assoziationsregeln

Bewertung von Assoziationsregeln

- Betrachten daher zwei Kriterien:
  - Rückhalt (*support*), d.h. wie häufig treten die Ereignisse A und B gemeinsam ein:

$$\text{supp}(A \Rightarrow B) = P(A, B \mid \mathbf{X})$$

  - Vertrauen (*confidence*), d.h. wie oft tritt B ein wenn A eingetreten ist:

$$\text{conf}\,(A \Rightarrow B) = P(B \mid A, \mathbf{X}) = P(A, B \mid \mathbf{X}) / P(A \mid \mathbf{X})$$

- Assoziationsregel $A \Rightarrow B$ ist *stark* mit Mindest-Support $s_{\min}$ und Mindest-Konfidenz $c_{\min}$ falls:

$$\text{supp}(A \Rightarrow B) \geq s_{\min} \quad \text{und} \quad \text{conf}\,(A \Rightarrow B) \geq c_{\min}$$

Lernen von Assoziationsregeln

Beispiel (Fortsetzung)

- Beispiel für $s_{\min} = 40\%$ und $c_{\min} = 60\%$:
  - Wer Milch kauft, kauft auch Müsli:

$$\text{supp} = P(g(\mathbf{x}, \text{Milch}, \text{ja}), g(\mathbf{x}, \text{Müsli}, \text{ja})) = \frac{2}{4}$$

$$\text{conf} = P(g(\mathbf{x}, \text{Müsli}, \text{ja}) \mid g(\mathbf{x}, \text{Milch}, \text{ja})) = \frac{2}{3}$$

Kunde	Brot	Milch	Eier	Bier	Müsli
1	nein	ja	ja	nein	ja
2	ja	ja	nein	ja	nein
3	nein	nein	ja	ja	nein
4	nein	ja	ja	nein	ja

$\Rightarrow$ Starke Assoziationsregel $g(\mathbf{x}, \text{Milch}, \text{ja}) \Rightarrow g(\mathbf{x}, \text{Müsli}, \text{ja})$

  - Wer Bier und Eier kauft, kauft kein Brot:

$$\text{supp} = P(g(\mathbf{x}, \text{Bier}, \text{ja}), g(\mathbf{x}, \text{Eier}, \text{ja}), g(\mathbf{x}, \text{Brot}, \text{nein})) = \frac{1}{4}$$

$$\text{conf} = P(g(\mathbf{x}, \text{Brot}, \text{nein}) \mid g(\mathbf{x}, \text{Bier}, \text{ja}), g(\mathbf{x}, \text{Eier}, \text{ja})) = 1$$

$\Rightarrow$ Schwache Assoziationsregel $g(\mathbf{x}, \text{Bier}, \text{ja}) \wedge g(\mathbf{x}, \text{Eier}, \text{ja}) \Rightarrow g(\mathbf{x}, \text{Brot}, \text{nein})$

Lernen von Assoziationsregeln

Lösungsansatz

- *Frequent-Itemset-Suche*: Finde zunächst alle Mengen

$$I = \{g(\mathbf{x}, p_1, y_1), \ldots, g(\mathbf{x}, p_h, y_h)\}$$

mit Mindest-Support, d.h. $P(g(\mathbf{x}, p_1, y_1), \ldots, g(\mathbf{x}, p_h, y_h)) \geq s_{\min}$.

- *Regel-Extraktion*: Für jede dieser Mengen I, bilde alle nicht-leeren Teilmengen $D \subset I$ und prüfe ob

$$\text{conf}(D \Rightarrow I \setminus D) = \frac{P(I)}{P(D)} \geq c_{\min}$$

erfüllt ist. Falls ja, ist $D \Rightarrow I \setminus D$ eine starke Assoziationsregel.

Frequent-Itemset-Suche

- Für eine gegebene Menge $I = \{g(\mathbf{x}, p_1, y_1), \ldots, g(\mathbf{x}, p_h, y_h)\}$ gelten folgende Aussagen:
  - Der Support von I ist größer oder gleich dem Mindest-Support, d.h. $\text{supp}(I) = P(g(\mathbf{x}, p_1, y_1), \ldots, g(\mathbf{x}, p_h, y_h)) \geq s_{\min}$.
  - $\Leftrightarrow$ Ereignisse $g(\mathbf{x}, p_1, y_1), \ldots, g(\mathbf{x}, p_h, y_h)$ wurden in den Daten *häufig* gemeinsam beobachtet.
  - $\Leftrightarrow$ Menge I bildet ein *Frequent Itemset*.
  - $\Rightarrow$ Jede Teilmenge von I bildet ein *Frequent Itemset*.

Frequent-Itemset-Suche

- A-Priori-Eigenschaft: Jede Teilmenge eines Frequent Itemsets ist ein Frequent Itemset.
  - Beispiel: Wenn Milch & Müsli oft gekauft wird, wird auch Milch oft gekauft bzw. wird auch Müsli oft gekauft.
  - Folge: Frequent Itemset mit $k+1$ Elementen besteht aus Vereinigung zweier k-elementiger Frequent Itemsets (mit $k-1$ gleichen Elementen).
  - Beginnend mit 1-elementigen Frequent Itemsets lassen sich so beliebig große Frequent Itemsets finden (Apriori-Algorithmus).

Frequent-Itemset-Suche

Apriori-Algorithmus

- Algorithmus:

Apriori(*Datenmatrix* $\mathbf{X}$, *Mindest-Support* $s_{\min}$)

Setze $k = 0, C_1 = \{\{g(\mathbf{x}, i, y_i)\} | 1 \le i \le m, y_i \in Y_i\}$

DO

$k = k + 1$

$L_k = \emptyset,\ C_{k+1} = \emptyset$

FOR $I \in C_k$

IF $\text{supp}(I) \ge s_{\min}$ THEN

FOR $J \in L_k$

IF $|I \cup J| = k + 1$ THEN

$C_{k+1} = C_{k+1} \cup \{I \cup J\}$

$L_k = L_k \cup \{I\}$

WHILE $C_{k+1} \neq \emptyset$

RETURN $L_1 \cup \ldots \cup L_k$

C_k sind alle Kandidaten für Frequent Itemsets der Größe k

L_k sind alle Frequent Itemsets der Größe k

I und J sind Frequent Itemsets der Größe k mit $k-1$ gleichen Elementen

Frequent-Itemset-Suche

Apriori-Algorithmus: Beispiel

- Betrachten beispielhaft nur „positive“ Items und $s_{\min} = 50\%$:

C_1

Itemset	Support
$\{b\}$	1/4
$\{m\}$	3/4
$\{e\}$	3/4
$\{r\}$	1/2
$\{s\}$	1/2

L_1

Itemset	Support
$\{m\}$	3/4
$\{e\}$	3/4
$\{r\}$	1/2
$\{s\}$	1/2

C_2

Itemset	Support
$\{m,e\}$	1/2
$\{m,r\}$	1/4
$\{e,r\}$	1/4
$\{m,s\}$	1/2
$\{e,s\}$	1/2
$\{r,s\}$	0

$L_1 = \{\{m\},\{e\},\{r\},\{s\}\}$

Kunde	Brot	Milch	Eier	Bier	Müsli
1	nein	ja	ja	nein	ja
2	ja	ja	nein	ja	nein
3	nein	nein	ja	ja	nein
4	nein	ja	ja	nein	ja

Elementarereignisse (Items)

$$
\begin{cases}
b = g(\mathbf{x}, Brot, ja) \\
\bar{b} = g(\mathbf{x}, Brot, nein) \\
m = g(\mathbf{x}, Milch, ja) \\
\bar{m} = g(\mathbf{x}, Milch, nein) \\
e = g(\mathbf{x}, Eier, ja) \\
\bar{e} = g(\mathbf{x}, Eier, nein) \\
r = g(\mathbf{x}, Bier, ja) \\
\bar{r} = g(\mathbf{x}, Bier, nein) \\
s = g(\mathbf{x}, Müsli, ja) \\
\bar{s} = g(\mathbf{x}, Müsli, nein)
\end{cases}
$$

Frequent-Itemset-Suche

Apriori-Algorithmus: Beispiel

- Betrachten beispielhaft nur „positive“ Items und $s_{\min} = 50\%$:

C_2

Itemset	Support
$\{m,e\}$	1/2
$\{m,r\}$	1/4
$\{e,r\}$	1/4
$\{m,s\}$	1/2
$\{e,s\}$	1/2
$\{r,s\}$	0

L_2

Itemset	Support
$\{m,e\}$	1/2
$\{m,s\}$	1/2
$\{e,s\}$	1/2

C_3

Itemset	Support
$\{m,e,s\}$	1/2

$L_1 = \{\{m\},\{e\},\{r\},\{s\}\}$

$L_2 = \{\{m,e\},\{m,s\},\{e,s\}\}$

Kunde	Brot	Milch	Eier	Bier	Müsli
1	nein	ja	ja	nein	ja
2	ja	ja	nein	ja	nein
3	nein	nein	ja	ja	nein
4	nein	ja	ja	nein	ja

Elementarereignisse (Items)

$$\begin{cases} b = g(\mathbf{x}, Brot, ja) \\ \bar{b} = g(\mathbf{x}, Brot, nein) \\ m = g(\mathbf{x}, Milch, ja) \\ \bar{m} = g(\mathbf{x}, Milch, nein) \\ e = g(\mathbf{x}, Eier, ja) \\ \bar{e} = g(\mathbf{x}, Eier, nein) \\ r = g(\mathbf{x}, Bier, ja) \\ \bar{r} = g(\mathbf{x}, Bier, nein) \\ s = g(\mathbf{x}, Müsli, ja) \\ \bar{s} = g(\mathbf{x}, Müsli, nein) \end{cases}$$

Frequent-Itemset-Suche

Apriori-Algorithmus: Beispiel

- Betrachten beispielhaft nur „positive“ Items und $s_{\min} = 50\%$:

C_3

Itemset	Support
$\{m,e,s\}$	1/2

L_3

Itemset	Support
$\{m,e,s\}$	1/2

C_4

Itemset	Support

$$L_1 = \{\{m\},\{e\},\{r\},\{s\}\}$$
$$L_2 = \{\{m,e\},\{m,s\},\{e,s\}\}$$
$$L_3 = \{\{m,e,s\}\}$$

Kunde	Brot	Milch	Eier	Bier	Müsli
1	nein	ja	ja	nein	ja
2	ja	ja	nein	ja	nein
3	nein	nein	ja	ja	nein
4	nein	ja	ja	nein	ja

Elementarereignisse (Items)

$$\begin{cases} b = g(\mathbf{x}, Brot, ja) \\ \bar{b} = g(\mathbf{x}, Brot, nein) \\ m = g(\mathbf{x}, Milch, ja) \\ \bar{m} = g(\mathbf{x}, Milch, nein) \\ e = g(\mathbf{x}, Eier, ja) \\ \bar{e} = g(\mathbf{x}, Eier, nein) \\ r = g(\mathbf{x}, Bier, ja) \\ \bar{r} = g(\mathbf{x}, Bier, nein) \\ s = g(\mathbf{x}, Müsli, ja) \\ \bar{s} = g(\mathbf{x}, Müsli, nein) \end{cases}$$

Frequent-Itemset-Suche

Apriori-Algorithmus: Implementierung

- Mengenoperationen:
  - Verwendung von Hashs bzw. Hash-Bäumen.
- Berechnung des Supports:
  - Ignoriere Items die nicht Element eines Frequent Itemset der Größe k sind bei Berechnungen für Itemsets der Größe $>k$.
- Partitionierung der Daten:
  - Frequent Itemset bzgl. aller Daten muss Frequent Itemset mindestens einer Partition sein.
  - Berechne Frequent Itemsets aller Partitionen und prüfe welche davon auch Frequent Itemsets bzgl. aller Daten sind.

Frequent-Itemset-Suche

Apriori-Algorithmus: Bewertung

- Vorteile:
  - Effektiv und relativ einfach zu implementieren.
- Nachteile:
  - Sehr viele Kandidaten (hohe Laufzeit/Speicherverbrauch).
    - 10^4 elementare Frequent Itemsets erzeugen 10^7 zwei-elementige Kandidaten.
    - Suche nach Frequent Itemset der Größe 100 erfordert mindestens $2^{100} \approx 10^{30}$ Kandidaten.
  - Viele Iterationen über die Daten.
    - Frequent Itemset der Größe k erfordert $k+1$ Iterationen.

Frequent-Itemset-Suche

FP-Growth-Algorithmus

- Idee: Daten als Frequent-Pattern-Baum darstellen und daraus Frequent Itemsets extrahieren.
- Aufbau des FP-Baums:
  - Speichert nur Informationen welche zum Finden von Frequent Itemsets notwendig sind (*Sufficient Statistics*).
  - Benötigt lediglich 2 Iterationen über die Daten.
- Extraktion der Frequent Itemsets:
  - Divide & Conquer-Ansatz, d.h. Reduktion des Suchproblems in viele kleine Optimierungsprobleme.
  - Vermeidung aufwendiger Kandidaten-Generierung.

Frequent-Itemset-Suche

FP-Growth-Algorithmus: Aufbau des FP-Baums

- Bestimmung aller Elementar-ereignisse (Items) und Sortierung nach ihrer Häufigkeit.

Kunde	$\bar{b}$	m	e	r	$\bar{r}$	s	$\bar{s}$	b	$\bar{m}$	$\bar{e}$
1	1	1	1	0	1	1	0	0	0	0
2	0	1	0	1	0	0	1	1	0	1
3	1	0	1	1	0	0	1	0	1	0
4	1	1	1	0	1	1	0	0	0	0
Häufigkeit	3	3	3	2	2	2	2	1	1	1

- Entferne alle Attribute mit zu kleinem Support.

Kunde	Brot	Milch	Eier	Bier	Müsli
1	nein	ja	ja	nein	ja
2	ja	ja	nein	ja	nein
3	nein	nein	ja	ja	nein
4	nein	ja	ja	nein	ja

Elementarereignisse (Items)

$$
\begin{cases}
b = g(\mathbf{x}, Brot, ja) \\
\bar{b} = g(\mathbf{x}, Brot, nein) \\
m = g(\mathbf{x}, Milch, ja) \\
\bar{m} = g(\mathbf{x}, Milch, nein) \\
e = g(\mathbf{x}, Eier, ja) \\
\bar{e} = g(\mathbf{x}, Eier, nein) \\
r = g(\mathbf{x}, Bier, ja) \\
\bar{r} = g(\mathbf{x}, Bier, nein) \\
s = g(\mathbf{x}, Müsli, ja) \\
\bar{s} = g(\mathbf{x}, Müsli, nein)
\end{cases}
$$

Frequent-Itemset-Suche

FP-Growth-Algorithmus: Aufbau des FP-Baums

- Betrachten beispielhaft nur „positive“ Items.
- Konstruktion des Präfix-Baums der Instanzen:

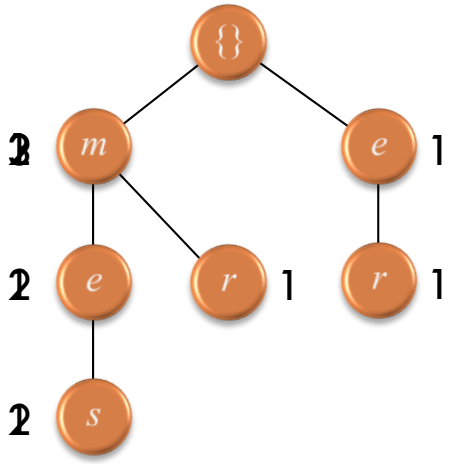

Kunde	*m*	*e*	*r*	*s*	*b*
1	1	1	0	1	0
2	1	0	1	0	1
3	0	1	1	0	0
4	1	1	0	1	0

Nicht berücksichtigt bei Konstruktion des FP-Baums da zu kleiner Support

Frequent-Itemset-Suche

FP-Growth-Algorithmus: Extraktion der Frequent Itemsets

- Alle Frequent Itemsets, welche g_k enthalten und $g_{k+1}, \ldots, g_m$ nicht enthalten, sind Teilmengen eines Pfades von der Wurzel zu einem Knoten g_k.
- Idee: Rekursiv alle Frequent Itemsets extrahieren.

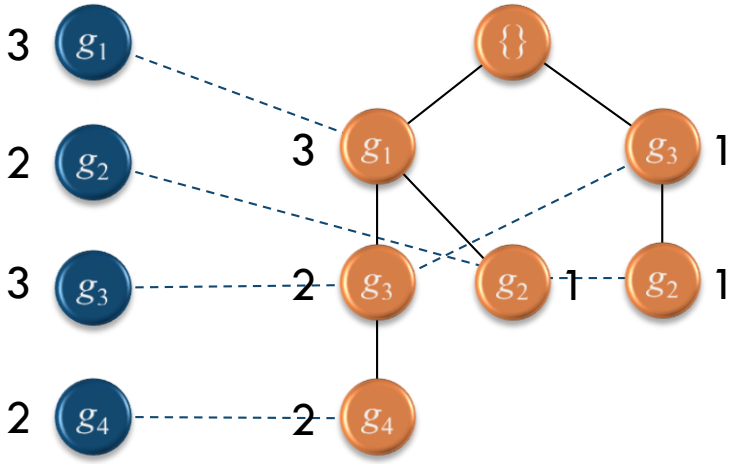

Frequent-Itemset-Suche

FP-Growth-Algorithmus: Extraktion der Frequent Itemsets

- Algorithmus:
  - Für alle Knoten (Items) g_k, betrachte Teilbaum mit allen Pfaden von der Wurzel zu einem Knoten (Item) g_k.
  - Berechne Support der Items für diesen Teilbaum.
  - Falls g_k ein Frequent Item ist, bestimme alle Frequent Itemsets $I_1,\ldots,I_z$ des Teilbaumes:
    - Erzeuge FP-Baum mit allen Frequent Items g_p des Teilbaumes und bestimme davon rekursiv alle Frequent Itemsets.
    - Rückgabe aller Frequent Itemsets $\{g_k\}, I_1 \cup \{g_k\}, \ldots, I_z \cup \{g_k\}$.
  - Sonst, Rückgabe der leeren Menge.

Frequent-Itemset-Suche

FP-Growth-Algorithmus: Extraktion der Frequent Itemsets

- Beispiel für $n = 4, s_{\min} = 50\%$:

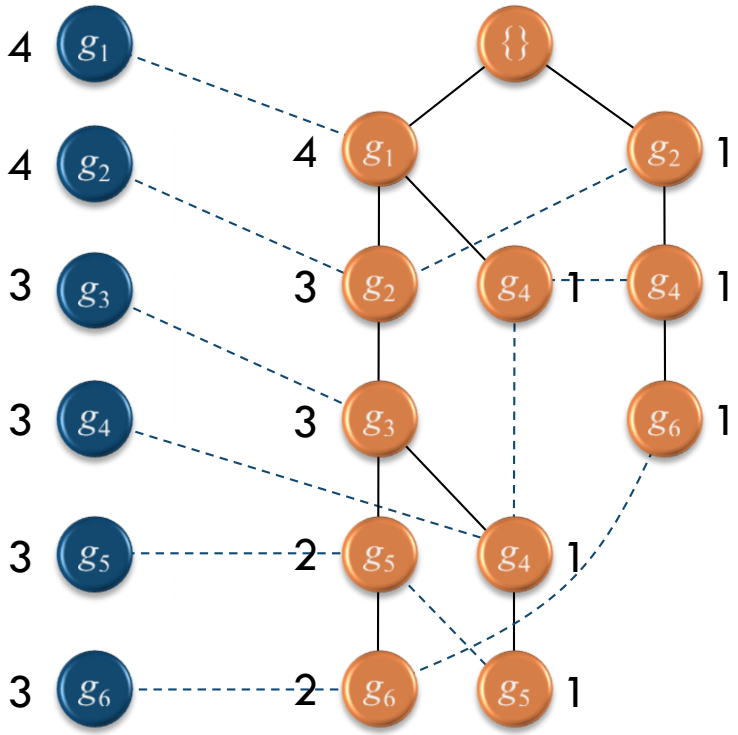

Teilbaum für g_6:

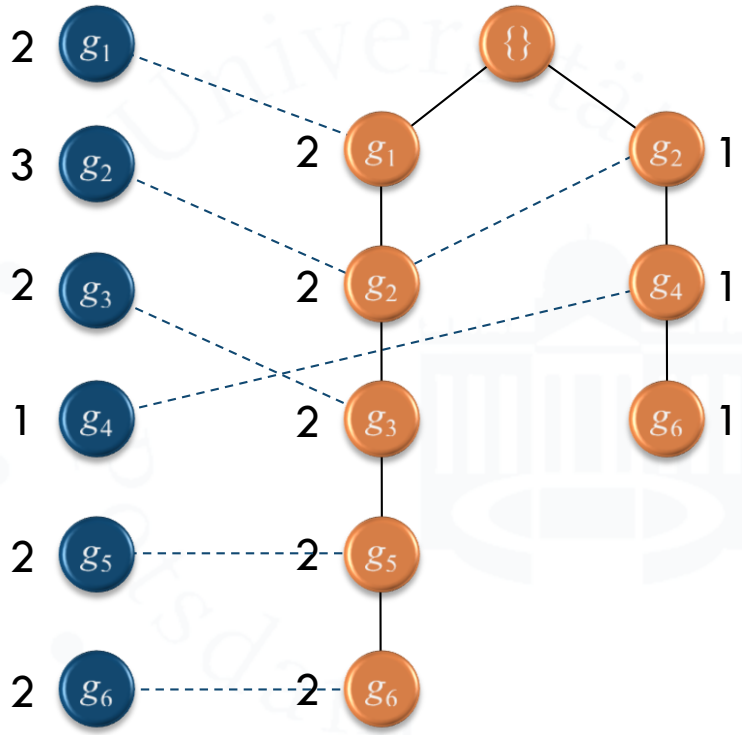

Frequent-Itemset-Suche

FP-Growth-Algorithmus: Extraktion der Frequent Itemsets

- Beispiel für $n = 4, s_{\min} = 50\%$:

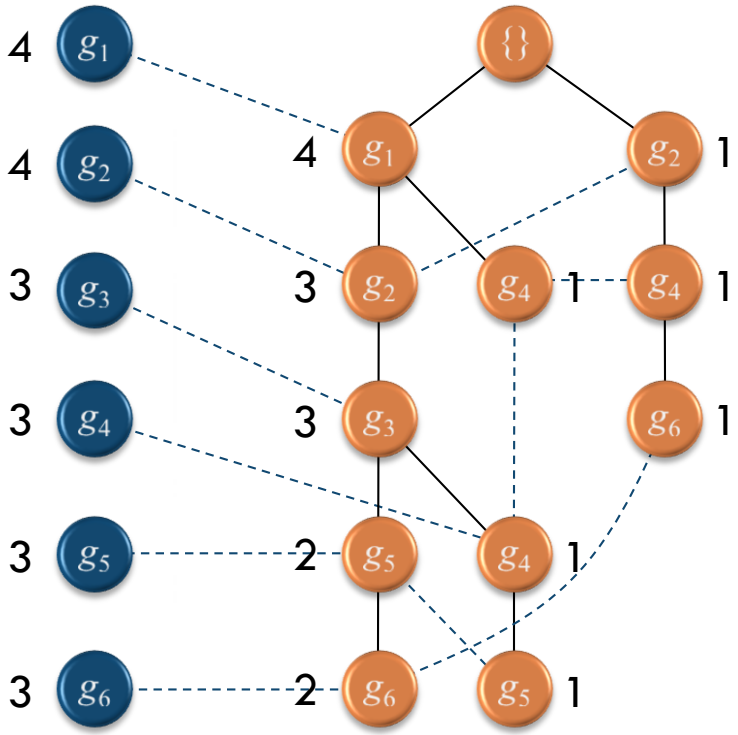

Teilbaum für g_6:

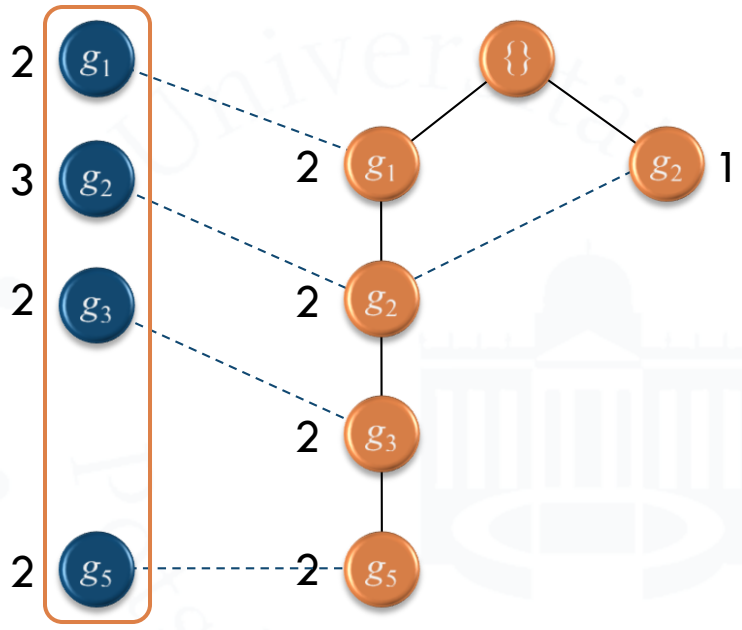

Frequent Items des Teilbaumes

Frequent-Itemset-Suche

FP-Growth-Algorithmus: Extraktion der Frequent Itemsets

- Beispiel für $n = 4, s_{\min} = 50\%$:

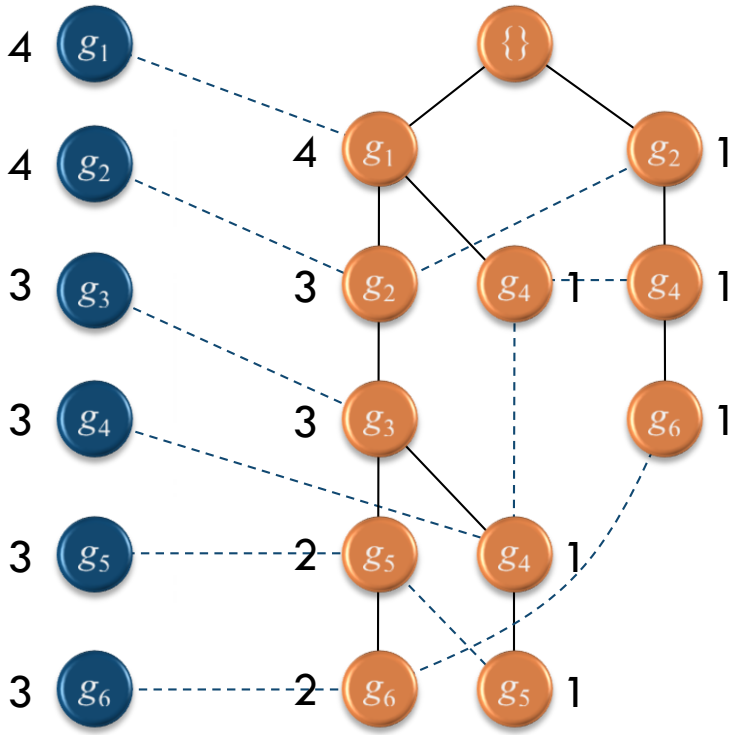

Teilbaum für g_6:

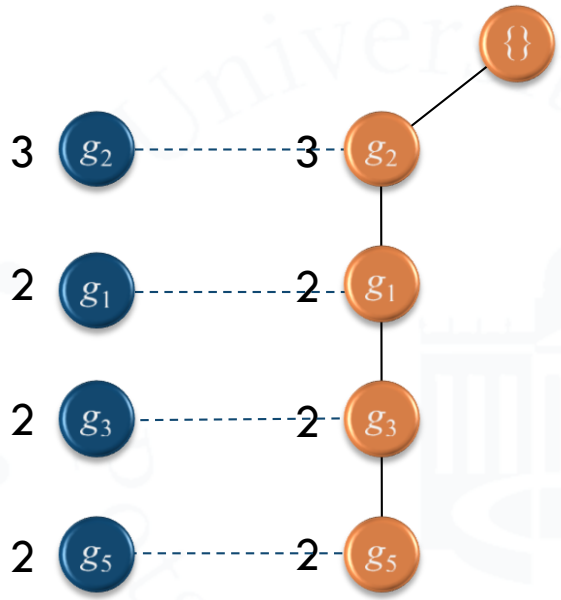

FP-Baum des Teilbaumes

Frequent-Itemset-Suche

FP-Growth-Algorithmus: Extraktion der Frequent Itemsets

- Beispiel für $n = 4, s_{\min} = 50\%$:

Teilbaum für g_6:

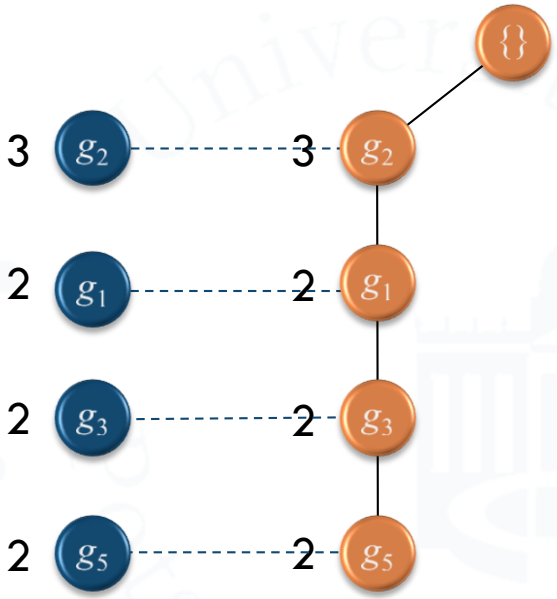

Rekursion bzgl. g_6 ergibt:

$\{g_2\}$

$\{g_1\},\{g_2,g_1\}$

$\{g_3\},\{g_2,g_3\},\{g_1,g_3\},\{g_2,g_1,g_3\}$

$\{g_5\},\{g_2,g_5\},\{g_1,g_5\},\{g_2,g_1,g_5\},\{g_3,g_5\},\{g_2,g_3,g_5\},\{g_1,g_3,g_5\},\{g_2,g_1,g_3,g_5\}$

$\{g_6\},\{g_2,g_6\},\{g_1,g_6\},\{g_2,g_1,g_6\},\{g_3,g_6\},\{g_2,g_3,g_6\},\{g_1,g_3,g_6\},\{g_2,g_1,g_3,g_6\},\ldots$

Frequent-Itemset-Suche

FP-Growth-Algorithmus: Bewertung

- Vorteile:
  - FP-Growth ist deutlich schneller als Apriori.
  - Keine Kandidaten-Generierung.
  - Iterationen über kompakte Datenstruktur (FP-Baum) statt über alle Daten.
- Nachteile:
  - Höherer Implementierungsaufwand.
  - Innerhalb der Rekursion werden viele gleiche Bäume erzeugt; viele redundante Berechnungen.

Zusammenfassung

- Ziel: Identifikation ähnlicher bzw. korrelierter Attribute.
  - Assoziationsregeln, Frequent Itemsets, Sequenzmuster.
- Frequent-Itemset-Suche mit Kandidaten-Generierung (z.B. Apriori-Algorithmus):
  - Idee: Teilmenge eines Frequent Itemsets ist wieder ein Frequent Itemset $\Rightarrow$ Konstruktion großer Itemsets aus kleinen.
- Frequent-Itemset-Suche ohne Kandidaten-Generierung (z.B. FP-Growth-Algorithmus):
  - Idee: Konstruktion eines Präfix-Baumes $\Rightarrow$ Finden von Frequent Itemsets durch rekursives traversieren & restrukturieren des Baumes.