
Einführung in Web- und Data-Science

Prof. Dr. Ralf Möller

Universität zu Lübeck

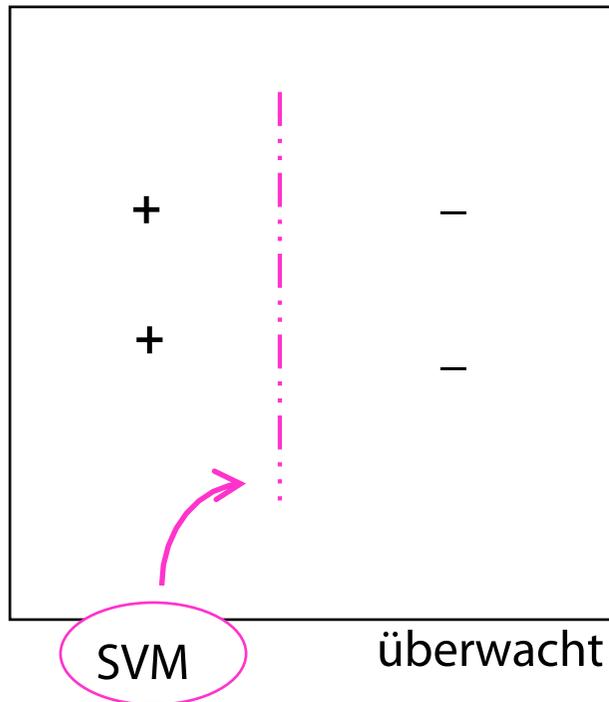
Institut für Informationssysteme

Tanya Braun (Übungen)

Wiederholung: Überwachtes Lernen

- Gegeben:
 - Tabellarische Daten,
 - Klassifikationsattribut vorhanden
(Überwachung durch klassifizierte Daten)
- Gesucht: Klassifikator für neue Daten
- Klassifikator erstellbar z.B. durch
 - Netze mit Parametrierungs- und Kompositionsmöglichkeit
 - Support-Vektor-Maschinen mit Kernel-Operator
- Heute: Unüberwachtes Lernen
(kein Klassifikationsattribut vorhanden)

Ausnutzung von Daten bei SVMs: Clusterbildung



Nur klassifizierte Daten

Clusterbildung z.B. realisierbar durch k-nächste-Nachbarn-Klassifikation
(also instanzbasiert, nicht modellbasiert)

Assoziationsregeln

- Gegeben eine Menge von **Warenkörben**, finde **Regeln**, die das Auftreten eines Artikels (oder mehrerer Artikel) **vorhersagt**
- Warenkorbeintragung in DB im Jargon **Transaktion** genannt (Daten aus Online-Transaction-Processing, OLTP)

Warenkorbtransaktionen

<i>TID</i>	<i>Artikel</i>
1	Bread, Milk
2	Bread, Diaper, Beer, Eggs
3	Milk, Diaper, Beer, Coke
4	Bread, Milk, Diaper, Beer
5	Bread, Milk, Diaper, Coke

Beispiele für Assoziationsregeln

$\{\text{Diaper}\} \rightarrow \{\text{Beer}\},$
 $\{\text{Milk, Bread}\} \rightarrow \{\text{Diaper, Coke}\},$
 $\{\text{Beer, Bread}\} \rightarrow \{\text{Milk}\},$

Rakesh Agrawal, Tomasz Imieliński, Arun Swami: Mining Association Rules between Sets of Items in Large Databases. In: Proc. 1993 ACM SIGMOD International Conference on Management of data, SIGMOD Record. Bd. 22, Nr. 2, Juni **1993**

Häufige Artikelmenngen

- Gegeben eine Datenmenge **D** in Form von Warenkörben, finde Kombination von Artikeln, die häufig zusammen vorkommen

Warenkorbtransaktionen

<i>TID</i>	<i>Artikel</i>
1	Bread, Milk
2	Bread, Diaper, Beer, Eggs
3	Milk, Diaper, Beer, Coke
4	Bread, Milk, Diaper, Beer
5	Bread, Milk, Diaper, Coke

Beispiele für häufige Artikelmenngen

{Diaper, Beer},
{Milk, Bread}
{Beer, Bread, Milk},

Definition: Häufige Artikelmenge

- **Artikelmenge** \subseteq Gesamt-Artikelmenge I

- Z.B.: {Milk, Bread, Diaper}

- **Unterstützungszähler (σ)**

- Anzahl $\sigma(w)$ des Auftretens der Artikelmenge w in den Daten (Anzahl der Warenkörbe, in denen Artikelmenge vorkommt)

- Z.B.: $\sigma(\{\text{Milk, Bread, Diaper}\}) = 2$

<i>TID</i>	<i>Artikel</i>
1	Bread, Milk
2	Bread, Diaper, Beer, Eggs
3	Milk, Diaper, Beer, Coke
4	Bread, Milk, Diaper, Beer
5	Bread, Milk, Diaper, Coke

- **Unterstützung (support)**

- Anteil der Warenkörbe, in denen Artikelmenge vorkommt: $s(w) = \sigma(w) / |D|$

- Z.B.: $s(\{\text{Milk, Bread, Diaper}\}) = 2/5$

- **Häufige Artikelmenge (frequent itemset)**

- Artikelmenge mit Support \geq **minsup** (Schwellwert)

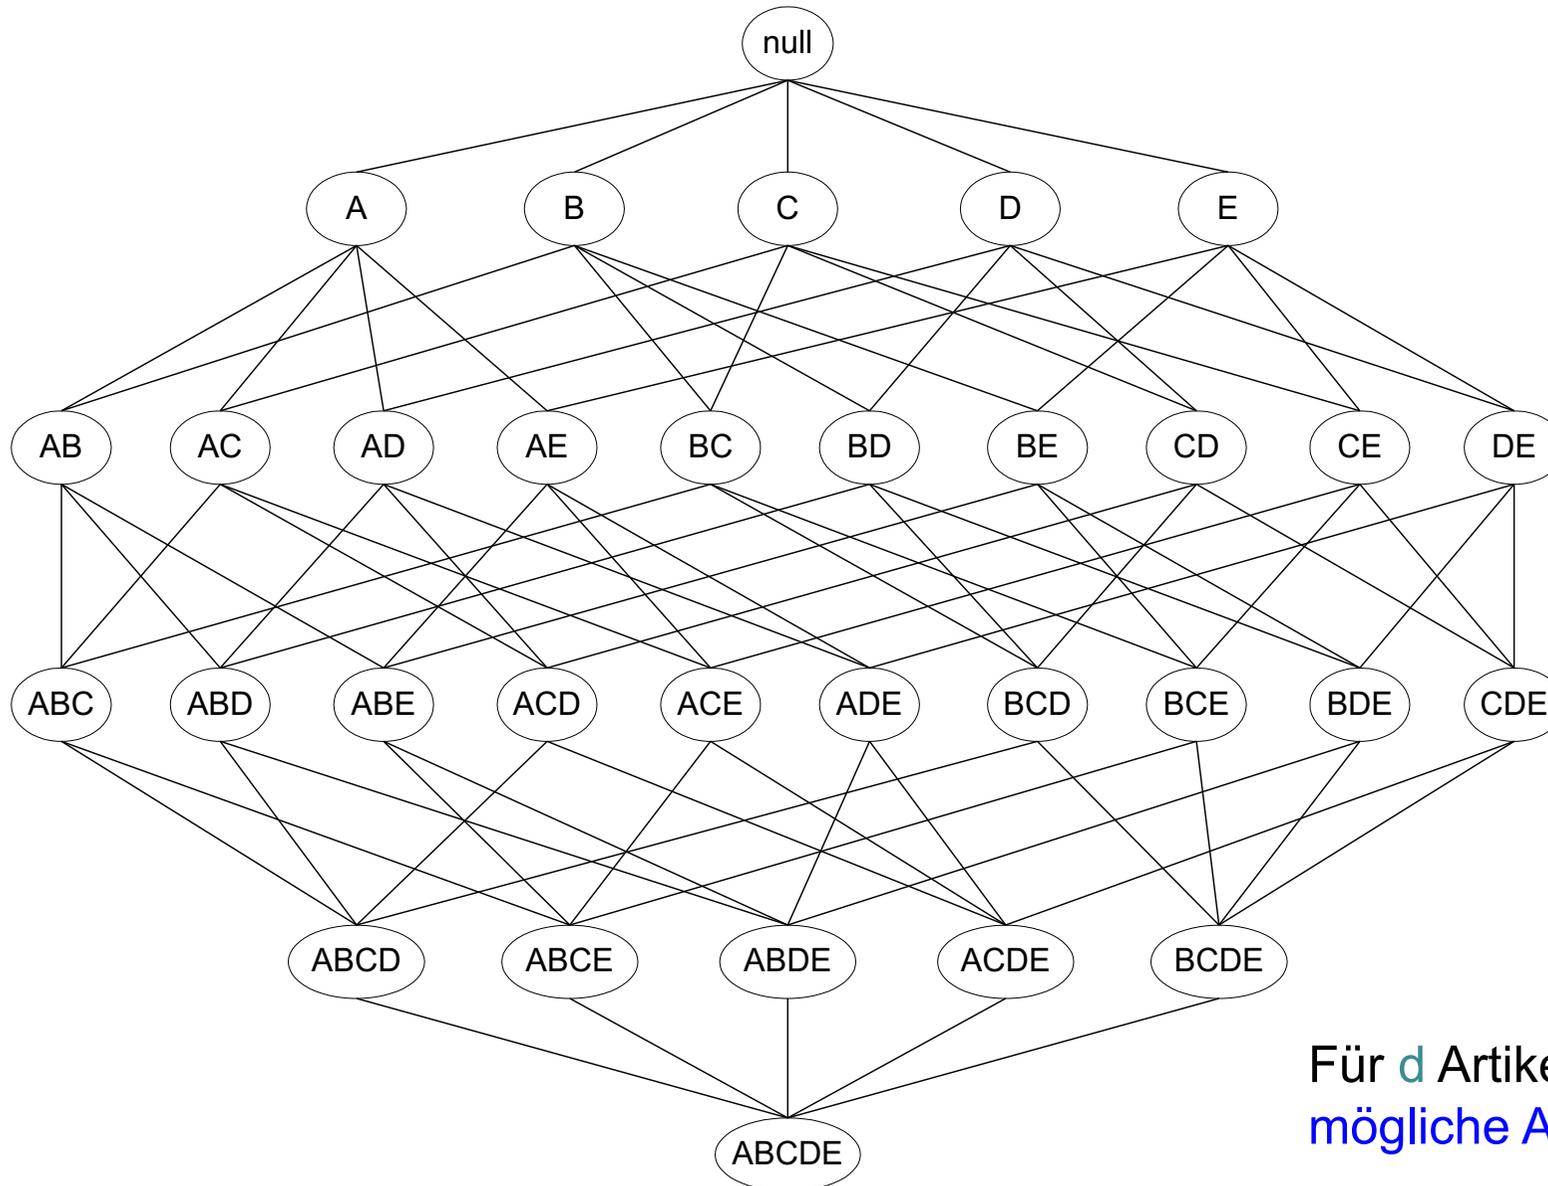
Warum häufige Artikelmenge finden?

- Interessant für **Platzierung** von Artikeln
(im Supermarkt, auf Webseiten, ...)
- Häufige Artikelmenge kennzeichnen positive Kombinationen
(seltene Artikelmenge kaum relevant),
bieten also **Zusammenfassung** einer Datenmenge
- ...

Suche nach häufigen Artikelmengen

- **Aufgabe:**
 - Gegeben eine Transaktionsdatenbasis D (Warenkörbe) und ein Schwellwert minsup
 - Finde alle häufigen Artikelmengen (und deren jeweilige Anzahl in den Daten)
- **Anders gesagt:** Zähle die jeweiligen Vorkommen von Kombinationen von Artikeln in den Daten über einem Schwellwert minsup
- **Annahme:** Gesamt-Artikelmenge I bekannt

Wie viele Artikelmenngen gibt es?



Für d Artikel gibt es 2^d
mögliche Artikelmenngen

Monotonie vom Support

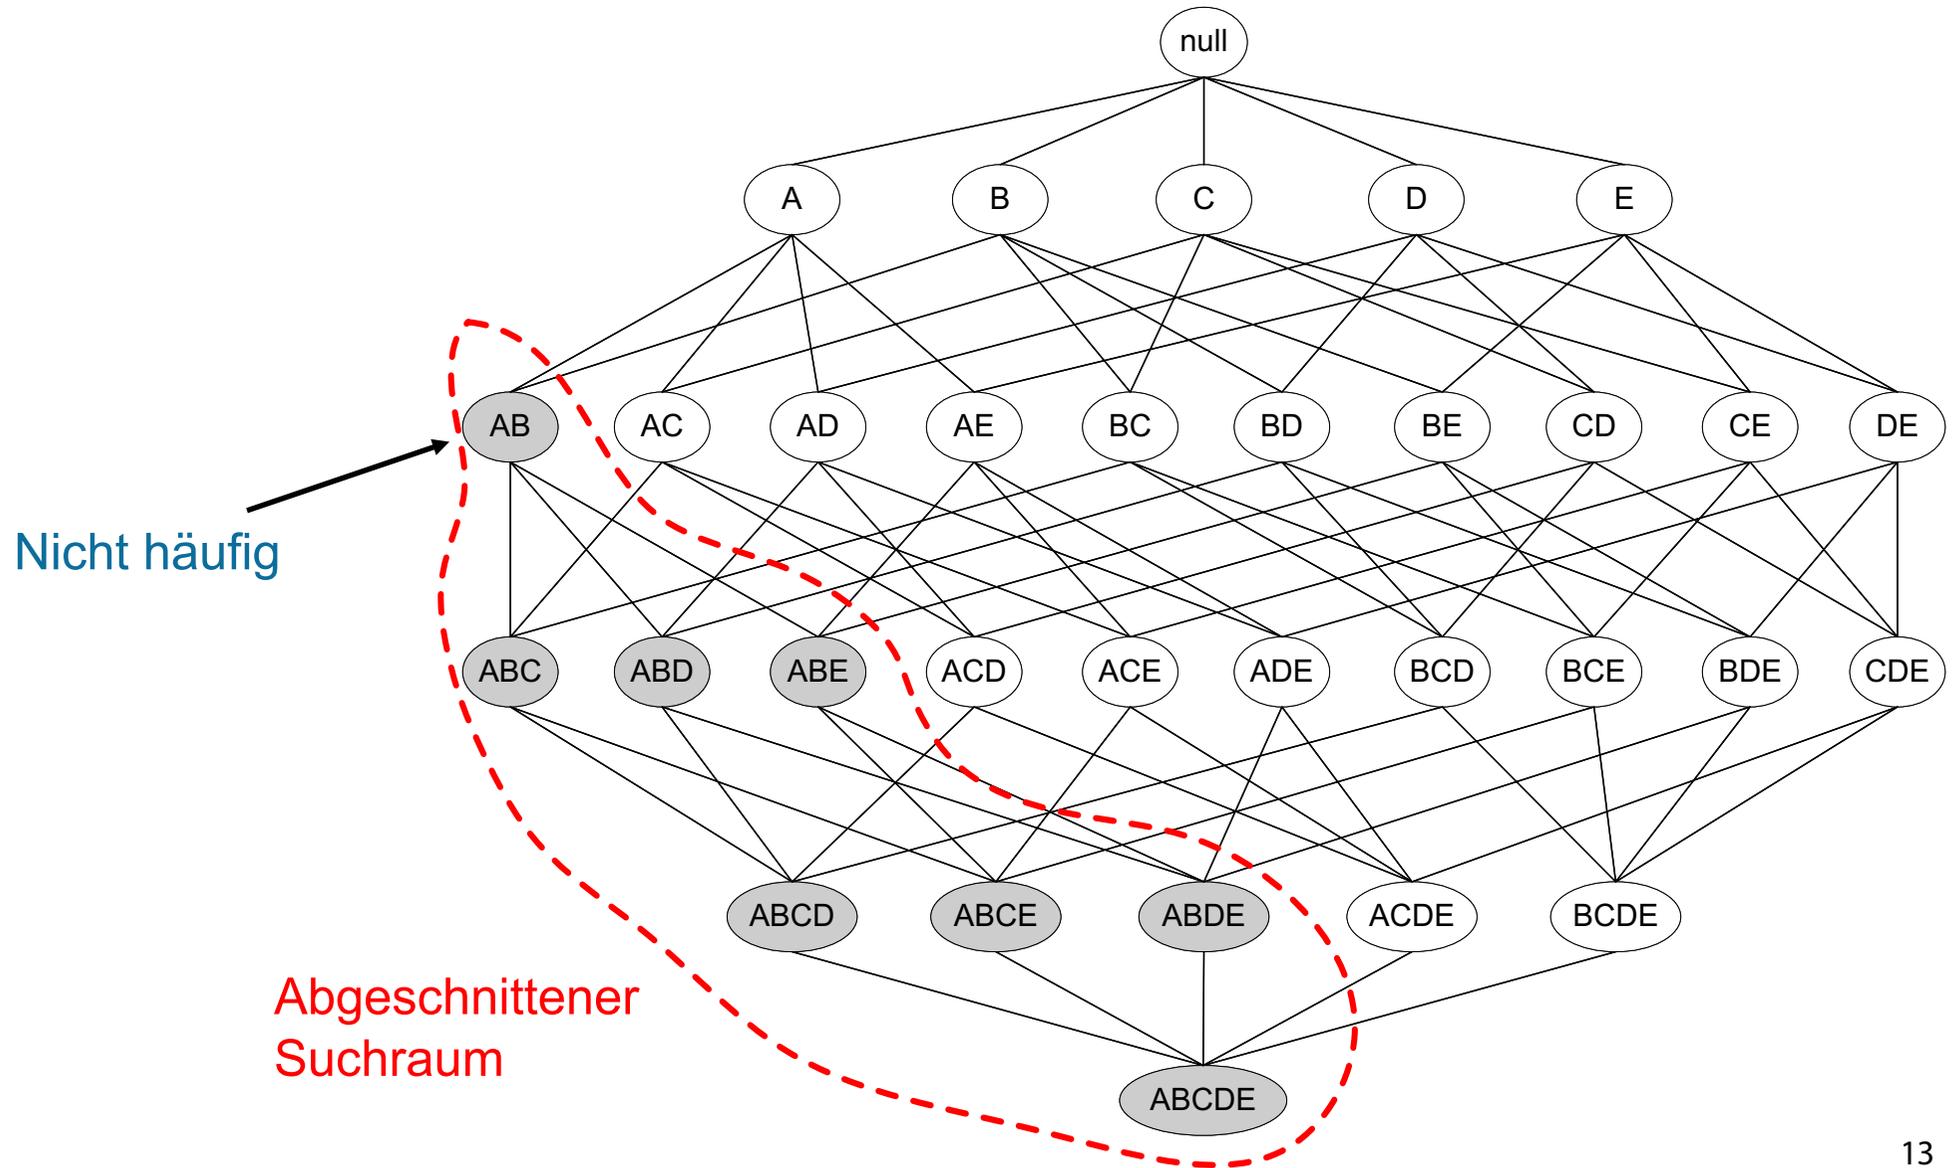
<i>TID</i>	<i>Artikel</i>
1	Bread, Milk
2	Bread, Diaper, Beer, Eggs
3	Milk, Diaper, Beer, Coke
4	Bread, Milk, Diaper, Beer
5	Bread, Milk, Diaper, Coke

$s(\text{Bread}) > s(\text{Bread, Beer})$

$s(\text{Milk}) > s(\text{Bread, Milk})$

$s(\text{Diaper, Beer}) > s(\text{Diaper, Beer, Coke})$

Apriori-Verfahren (Idee)



Apriori-Verfahren (Prinzip)

1er-Artikelmengen

Artikel	Anzahl
Bread	4
Coke	2
Milk	4
Beer	3
Diaper	4
Eggs	1

minsup = 3/5



Artikelmenge	Anzahl
{Bread,Milk}	3
{Bread,Beer}	2
{Bread,Diaper}	3
{Milk,Beer}	2
{Milk,Diaper}	3
{Beer,Diaper}	3

2er-Artikelmengen

(Cola und Eier nicht mehr berücksichtigt)



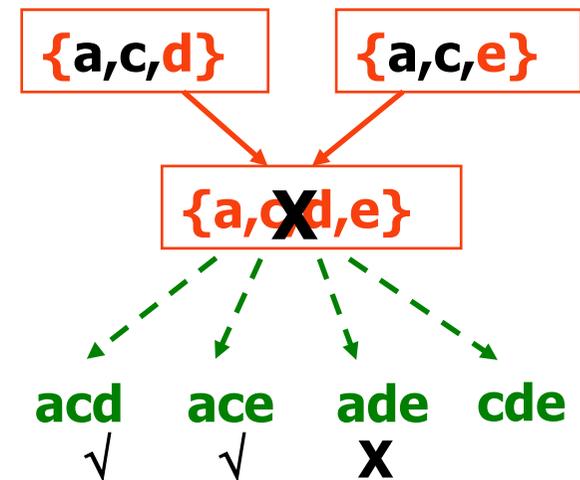
3er-Artikelmengen

Artikelmenge	Anzahl
{Bread,Milk,Diaper}	3



Apriori-Verfahren (Prinzip)

- $L_3 = \{abc, abd, acd, ace, bcd\}$
- **Self-Join:** $L_3 \bowtie L_3$
 - $abcd$ aus abc und abd
 - $acde$ und acd und ace
- **Beschneidung:**
 - $acde$ entfernt, weil ade nicht in L_3
- $C_4 = \{abcd\}$



Definition: Assoziationsregel

Sei D eine Datenbasis von
Transaktionen

Transaction ID	Artikel
2000	A, B, C
1000	A, C
4000	A, D
5000	B, E, F

- Sei I die Artikelmenge in der DB, z.B.: $I = \{A, B, C, D, E, F\}$
- Eine Regel ist definiert durch $X \rightarrow Y$,
wobei $X \subset I$, $Y \subset I$, $X \neq \emptyset$, $Y \neq \emptyset$, and $X \cap Y = \emptyset$
 - Beispiel: $\{B, C\} \rightarrow \{A\}$ ist eine Regel

Definition: Bewertungsmaße für Regel

■ Unterstützung/Support $s(.)$

- Anteil der Transaktionen, die X und Y enthalten

■ Konfidenz $c(.)$

- Maß, wie oft Artikel Y in Transaktionen vorkommen, die auch X enthalten

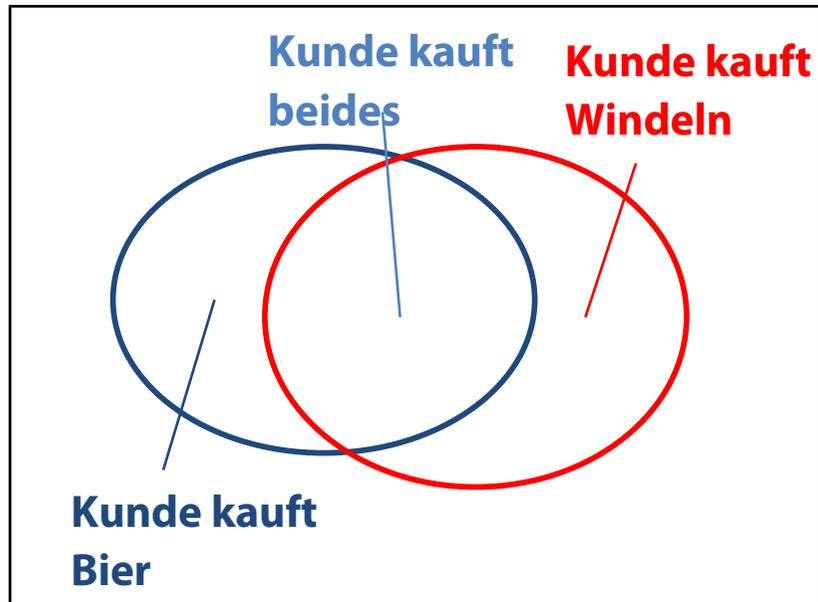
<i>TID</i>	<i>Items</i>
1	Bread, Milk
2	Bread, Diaper, Beer, Eggs
3	Milk, Diaper, Beer, Coke
4	Bread, Milk, Diaper, Beer
5	Bread, Milk, Diaper, Coke

Beispiel: {Milk, Diaper} → Beer

$$s = \frac{\sigma(\text{Milk, Diaper, Beer})}{|T|} = \frac{2}{5} = 0.4$$

$$c = \frac{\sigma(\text{Milk, Diaper, Beer})}{\sigma(\text{Milk, Diaper})} = \frac{2}{3} = 0.67$$

Mining von Assoziationsregeln



Finde alle Regeln $r = X \rightarrow Y$ mit

- $s(r) \geq \text{minsup}$ und
- $c(r) \geq \text{minconf}$
- **Support s** : relative Häufigkeit (in %), von Transaktionen, die $X \cup Y$ enthalten
- **Konfidenz c** : Bedingte relative Häufigkeit (in %) von Transaktionen Y enthalten, wenn sie auch X enthalten

TID	Items
100	A,B,C
200	A,C
300	A,D
400	B,E,F

Sei der minimale Support 50%
und die minimale Konfidenz 50%:

- $A \rightarrow C$ (50%, 66.6%)
- $C \rightarrow A$ (50%, 100%)

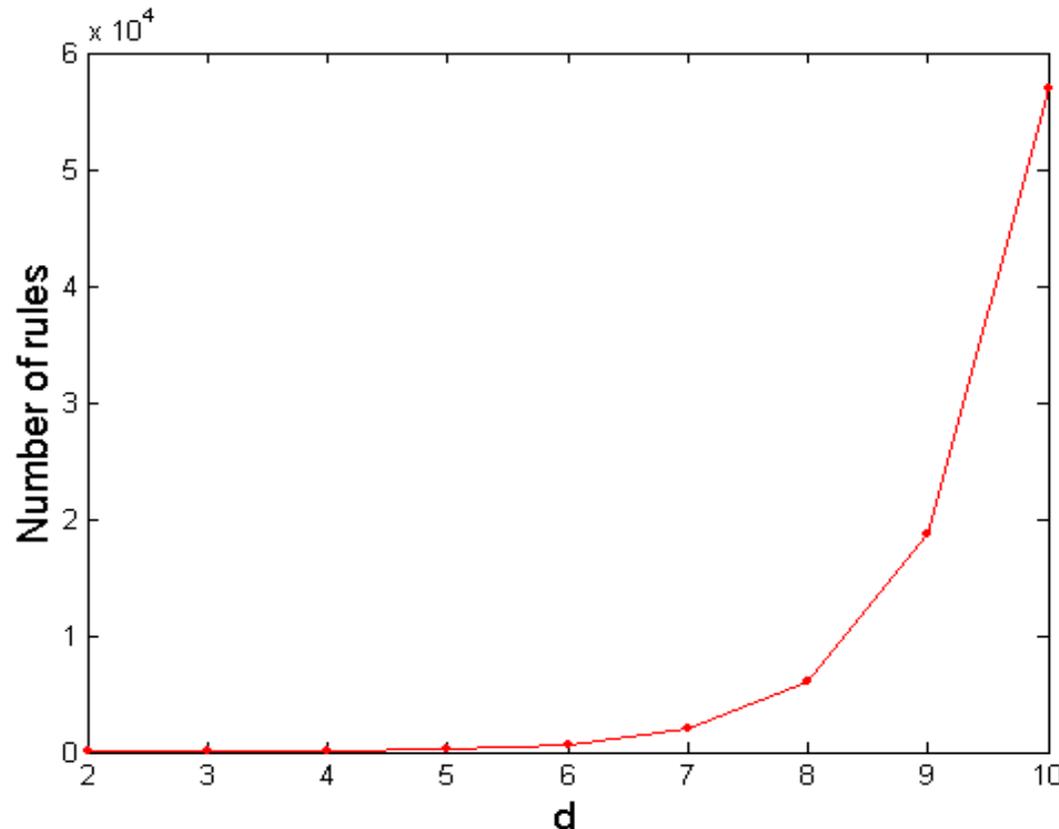
Brute-Force-Verfahren

- Betrachte alle möglichen Assoziationsregeln
- Berechne Support und Konfidenz für jede Regel
- Eliminiere Regeln, deren Support oder Konfidenz kleiner als **minsup** und **minconf** Schwellwerte
- \Rightarrow **Zu aufwendig!** Kombinatorische Explosion

Berechnungsaufwand

- Gegeben d Artikel in I :
 - Anzahl der Artikelmengen: 2^d
 - Anzahl der Assoziationsregeln:

$$\sum_{k=1}^{d-1} \left[\binom{d}{k} \times \sum_{j=1}^{d-k} \binom{d-k}{j} \right]$$
$$= 3^d - 2^{d+1} + 1$$



Wenn $d=6$, $R = 602$ Regeln

Mining von Assoziationsregeln

<i>TID</i>	<i>Items</i>
1	Bread, Milk
2	Bread, Diaper, Beer, Eggs
3	Milk, Diaper, Beer, Coke
4	Bread, Milk, Diaper, Beer
5	Bread, Milk, Diaper, Coke

Beispiele für Regeln:

{Milk,Diaper} → {Beer} (s=0.4, c=0.67)

{Milk,Beer} → {Diaper} (s=0.4, c=1.0)

{Diaper,Beer} → {Milk} (s=0.4, c=0.67)

{Beer} → {Milk,Diaper} (s=0.4, c=0.67)

{Diaper} → {Milk,Beer} (s=0.4, c=0.5)

{Milk} → {Diaper,Beer} (s=0.4, c=0.5)

Beobachtungen:

Regeln sind binäre Partitionen der gleichen Artikelmenge:

{Milk, Diaper, Beer}

Regeln von der gleichen Artikelmenge haben gleichen Support aber verschiedene Konfidenz

Entkopplung von Support und Konfidenz

Zweischrittiger Ansatz

- Generiere häufige Artikelmenngen mit
 $\text{support} \geq \text{minsup}$
- Generiere Assoziationsregeln
durch **binäre Partitionierung**
von häufigen Artikelmenngen, so dass
 $\text{confidence} \geq \text{minconf}$

Regelgenerierung – Einfacher Ansatz

- Gegeben die häufige Artikelmenge X , finde alle nichtleeren Teilmengen $y \subset X$, so dass $y \rightarrow X - y$ die Konfidenzanforderung erfüllt

Beispiel: $\{A,B,C,D\}$ sei eine häufige Artikelmenge:

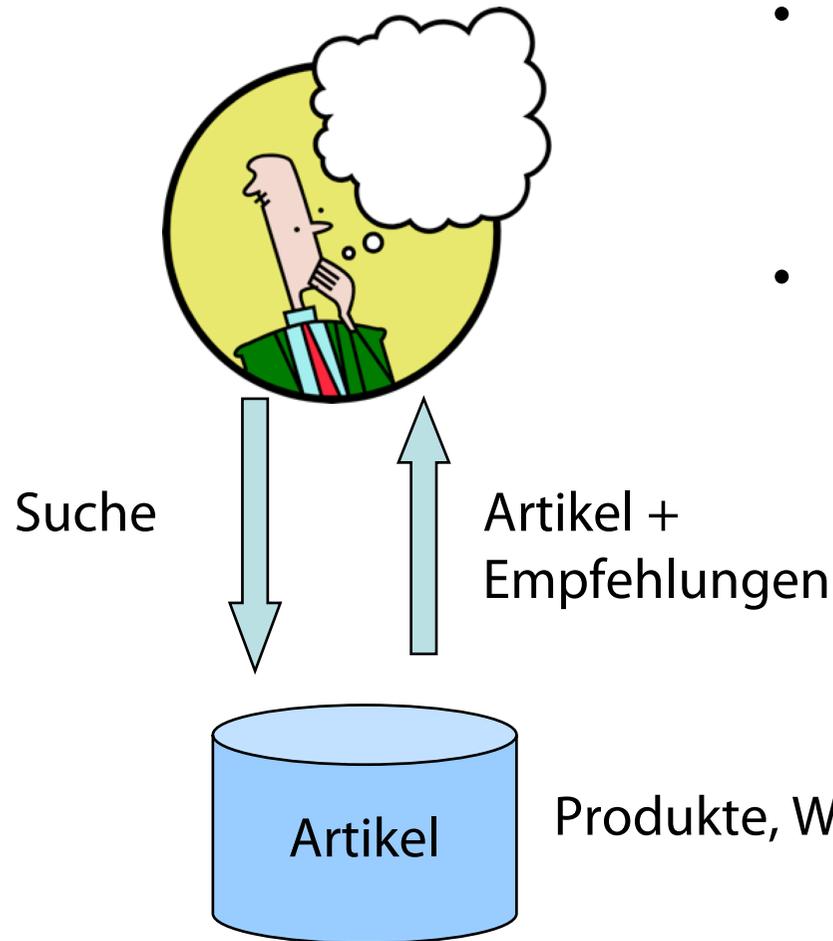
$ABC \rightarrow D, \quad ABD \rightarrow C, \quad ACD \rightarrow B, \quad BCD \rightarrow A,$
 $A \rightarrow BCD, \quad B \rightarrow ACD, \quad C \rightarrow ABD, \quad D \rightarrow ABC$
 $AB \rightarrow CD, \quad AC \rightarrow BD, \quad AD \rightarrow BC, \quad BC \rightarrow AD,$
 $BD \rightarrow AC, \quad CD \rightarrow AB$

- Falls $|X| = k$, dann gibt es $2^k - 2$ Kandidatenregeln (ohne $L \rightarrow \emptyset$ und $\emptyset \rightarrow L$)

Anwendungen der Warenkorbanalyse

- "Verstehen" von Transaktionsdaten
- Data Mining (offline)
 - Systematische Anwendung statistischer Methoden auf große Datenbestände, mit dem Ziel, ...
 - ... neue Querverbindungen und Trends zu erkennen
- Empfehlungsgenerierung (online)
 - Vorhersage treffen, die quantifiziert wie stark das Interesse eines Benutzers an einem Objekt ist, ...
 - ... um dem Benutzer genau die Objekte aus der Menge aller vorhandenen Objekte zu empfehlen, für die er sich vermutlich am meisten interessiert

Anwendung: Empfehlungsgenerierung



- Beschränktheit der Ressource "Platz"
- Was sind "gute" Empfehlungen
 - Steigerung der Kundenzufriedenheit
 - Steigerung des Umsatzes des Anbieters
- Techniken
 - Verwendung von häufigen Artikelmenngen
 - Verwendung von Assoziationsregeln

Verfeinerung der Empfehlungsgenerierung

Personalisierung: Kundenspezifische Empfehlung

Schätzung der Kundenzufriedenheit über "Nützlichkeit"

- **C:** Menge von Kunden
- **S:** Menge von Artikeln
- **Nützlichkeitsmaß:** $u : C \times S \rightarrow R$
 - **R:** Menge von Bewertungen (total geordnete Menge)
 - Beispiele: 0-5 Sterne, reelle Zahlen aus $[0,1]$
- Nützlichkeit = engl. Utility

Maximierung der Nützlichkeitschätzung

- Für jeden Nutzer $c \in C$
bestimme diejenigen Artikel s' aus dem Sortiment S ,
die die Nützlichkeiten für den Nutzer c maximieren

$$\forall c \in C, \quad s'_c = \arg \max_{s \in S} u(c, s).$$

- Kundenspezifische Nützlichkeitschätzung s'_c eines Artikels
definiert Rang der Artikel
-

Zentrales Problem

- Nützlichkeit nur partiell definiert, also nicht für alle Elemente aus dem **CxS Raum** bekannt
- Nützlichkeit **u** muss extrapoliert werden

	King Kong	LOTR	Matrix	Nacho Libre
Alice	1		0.2	
Bob		0.5		0.3
Carol	0.2		1	
David				0.4



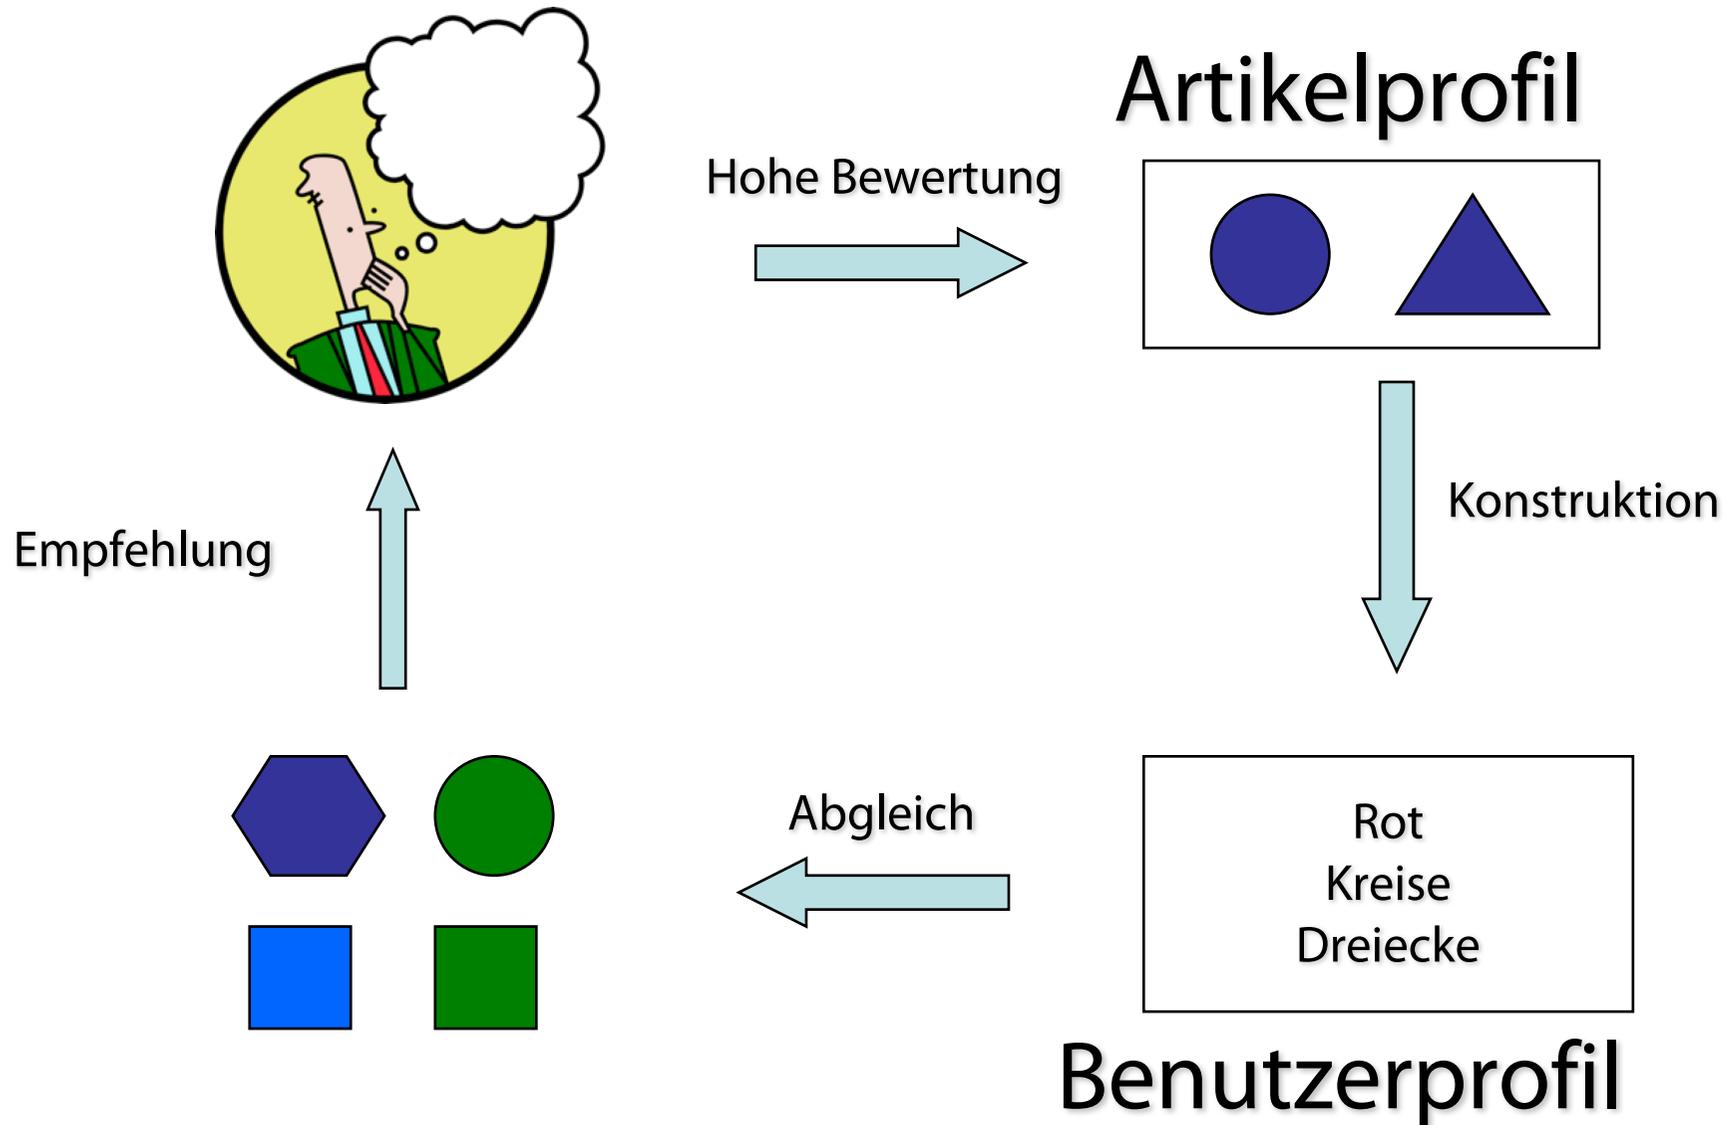
Erfassung von Nützlichkeitsmaßen

- Explizit
 - Nutzer bewerten Artikel
 - Funktioniert nicht in der Praxis, Nutzer werden gestört
- Implizit
 - Erfasse Maße aus Nutzeraktionen
 - Kauf eines Artikels ergibt gute Bewertung
 - Was ist mit schlechten Bewertungen?

Extrapolierung der Nützlichkeiten

- Schlüsselproblem: Matrix U ist dünn besetzt
 - Die meisten Leute haben die meisten Artikel nicht bewertet
 - Extrapolation nötig (Filterung)
- Ansätze
 - Inhaltsbasierte Filterung
 - Empfehlung von Artikeln, die "ähnlich" zu den schon hoch bewerteten sind: Wähle $u(c,s)$ wie $u(c, s')$ mit $\text{sim}(s, s')$
 - Kollaborative Filterung
 - Empfehlung von Artikeln, die von "ähnlichen" Benutzern hoch bewertet werden: $u(c,s)$ wie $u(c', s)$ mit $\text{sim}(c, c')$

Übersicht



Artikelmerkmale

- Für jeden Artikel s generiere Artikelprofil $\text{content}(s)$
- Profil ist Menge von Merkmalswerten
 - Text: Menge von (Wort, Gewicht)-Paaren
 - Kann als Vektor gedeutet werden
 - Auch für Filme:
 - Text extrahieren aus Angaben zu Titel, Schauspieler, Regisseur, usw.
- Wie findet man Gewichtsangaben?
 - Standardansatz: TF.IDF
(Term Frequency by Inverse Doc Frequency)

TF.IDF

f_{ij} = relative Anzahl der Terme t_i im Document d_j

$$TF_{ij} = \frac{f_{ij}}{\operatorname{argmax}_k f_{kj}}$$

n_i = Anzahl der Dokumente in denen Term i vorkommt

N = Gesamtanzahl der Dokumente

$$IDF_i = \log \frac{N}{n_i}$$

TF.IDF-Maß $w_{ij} = TF_{ij} \cdot IDF_i$

Inhaltsbasierte Nützlichkeitschätzung (Filterung)

- Für Nutzer c nehme zugeordnete Artikel $\text{items}(c)$...
- ... und bestimme $\text{content}(s)$ für alle $s \in \text{items}(c)$
- Definiere $\text{profile}(c)$ als
 - ◆ Mittel der $\text{content}(s)$ für alle $s \in \text{items}(c)$ oder
 - ◆ Mittel der Abstände vom Mittelwert von $\text{content}(s)$ mit $s \in \text{items}(c)$ (weitere Definitionen sind möglich)
- Wir erhalten: Menge von (Term, Gewicht)-Paaren
 - ◆ Kann als Vektor w gedeutet werden

- Nützlichkeitsfunktion $u(c, s)$:
$$u(c, s) = \cos(\vec{w}_c, \vec{w}_s) = \frac{\vec{w}_c \cdot \vec{w}_s}{\|\vec{w}_c\|_2 \times \|\vec{w}_s\|_2}$$

- Profil auch Bewertung genannt

$$= \frac{\sum_{i=1}^K w_{i,c} w_{i,s}}{\sqrt{\sum_{i=1}^K w_{i,c}^2} \sqrt{\sum_{i=1}^K w_{i,s}^2}}$$

$\|\cdot\|_2$ denotiert Euklidische Norm (Länge des Vektors)

Begrenzungen der inhaltsbasierten Filterung

- Merkmale nicht immer einfach zu definieren
 - Bilder?, Musik?
 - Meist umgebender oder zugeordneter Text verwendet
- Überspezialisierung
 - Artikel außerhalb des Profils werden nicht empfohlen
 - Menschen haben verschiedene Interessen
- Empfehlungen für neue Benutzer
 - Wie ist das Profil definiert?
 - Rückgriff auf:
 - Häufige Artikelmenen (nutzerunspezifisch)
 - Assoziationsregeln (nutzerunspezifisch)

Nutzer-Nutzer kollaborative Filterung

- Betrachte Nutzer c
- Bestimme Menge D von Nutzern, deren Bewertungen "ähnlich" zu denen von c sind
- Schätze $\text{profile}(c)$ aus den Angaben $\text{profile}(d)$ für $d \in D$

- Was sind "ähnliche" Nutzer?

Ähnliche Nutzer: Distanzmaße

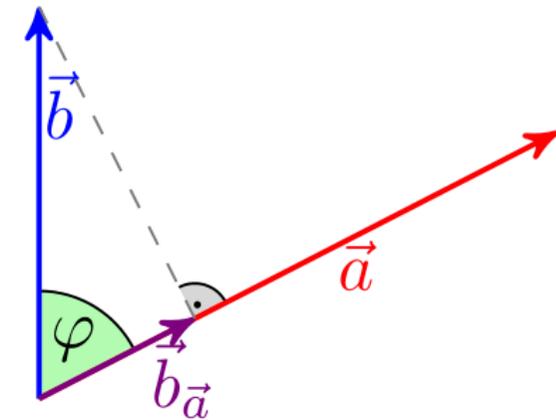
Sei eine Nutzerbewertung $r_c = \text{profile}(c)$ gegeben, dann definiere Ähnlichkeit sim der Nutzer c_1 und c_2 als

1. Kosinusähnlichkeit

$$\text{sim}(c_1, c_2) = \cos(r_{c_1}, r_{c_2})$$

$$\mathbf{a} \cdot \mathbf{b} = \|\mathbf{a}\| \|\mathbf{b}\| \cos \theta$$

$$\cos(\theta) = \frac{\mathbf{A} \cdot \mathbf{B}}{\|\mathbf{A}\| \|\mathbf{B}\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}}$$



Orthogonale Projektion \vec{b}_a des Vektors \vec{b} auf die durch \vec{a} bestimmte Richtung

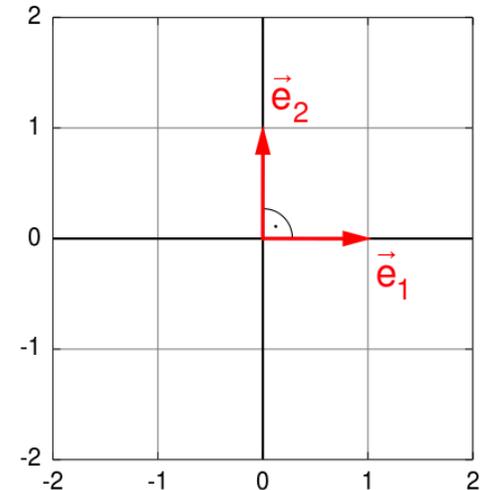
$$\vec{a} \cdot \vec{b} = a_1 b_1 + a_2 b_2 + a_3 b_3.$$

Für die **kanonischen Einheitsvektoren** $\vec{e}_1 = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ und $\vec{e}_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ gilt nämlich:

$$\vec{e}_1 \cdot \vec{e}_1 = 1, \vec{e}_1 \cdot \vec{e}_2 = \vec{e}_2 \cdot \vec{e}_1 = 0 \text{ und } \vec{e}_2 \cdot \vec{e}_2 = 1$$

Daraus folgt (unter Vorwegnahme der weiter unten erläuterten Eigenschaften des Skalarproduktes):

$$\begin{aligned} \vec{a} \cdot \vec{b} &= (a_1 \vec{e}_1 + a_2 \vec{e}_2) \cdot (b_1 \vec{e}_1 + b_2 \vec{e}_2) \\ &= a_1 b_1 \vec{e}_1 \cdot \vec{e}_1 + a_1 b_2 \vec{e}_1 \cdot \vec{e}_2 + a_2 b_1 \vec{e}_2 \cdot \vec{e}_1 + a_2 b_2 \vec{e}_2 \cdot \vec{e}_2 \\ &= a_1 b_1 + a_2 b_2 \end{aligned}$$



Kanonische Einheitsvektoren in der euklidischen Ebene

Ähnliche Nutzer: Distanzmaße

Sei eine Nutzerbewertung $r_c = \text{profile}(c)$ gegeben, dann definiere Ähnlichkeit sim der Nutzer c_1 und c_2 als

1. Kosinusähnlichkeit

– $\text{sim}(c_1, c_2) = \cos(r_{c_1}, r_{c_2})$ oder als

2. Funktion über Bewertungen $x=r_{c_1}$ and $y=r_{c_2}$, so dass

– falls c_1 und c_2 gleiche Bewertungen vergeben \rightarrow max

– Normalisierung von x und y nötig

– Allgemein bekannt als:

- Pearson Korrelationskoeffizient oder
- empirischer Korrelationskoeffizient

Korrelationskoeffizient

Normalisierte Werte (z-Transformation)

$$r = \frac{1}{n-1} \sum_{i=1}^n \frac{(x_i - \bar{x})}{s_x} \frac{(y_i - \bar{y})}{s_y}$$

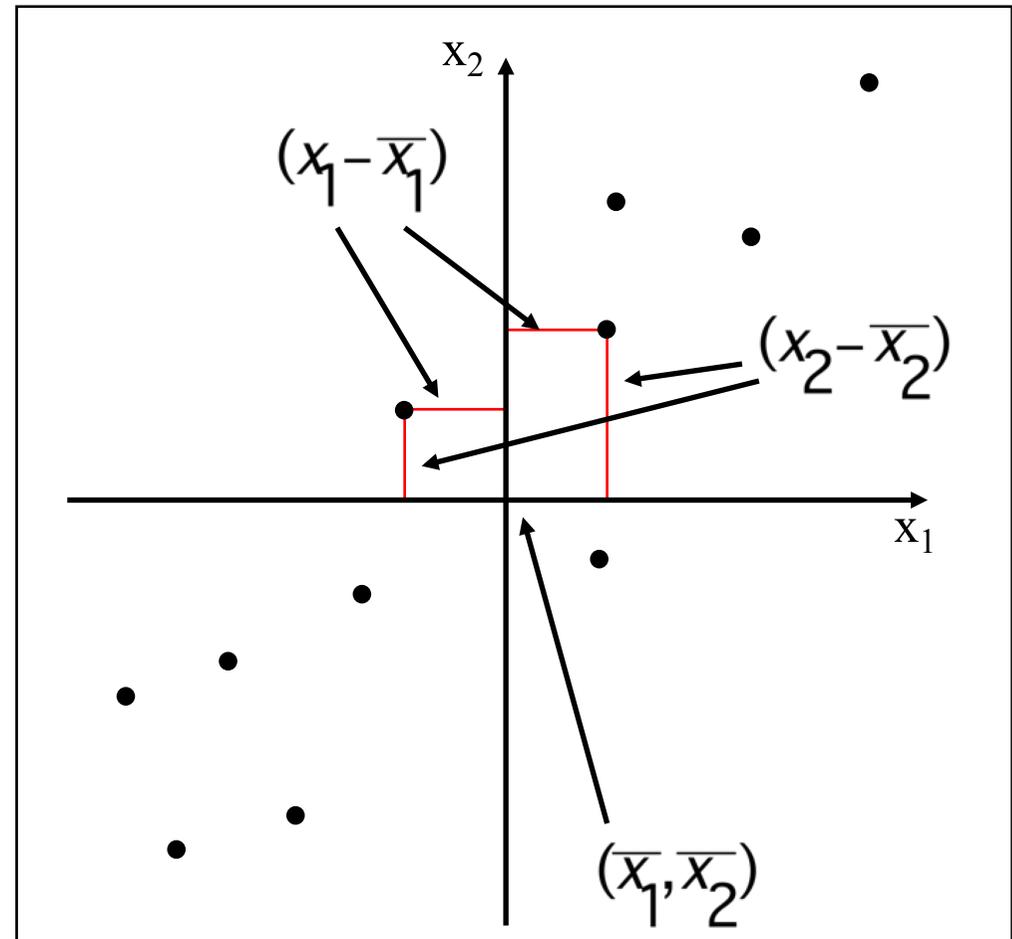
n = Anzahl der Artikel		
x_i = Bewertungskomp. x		y_i = Bewertungskomp. y
\bar{x} = Mittel von x		\bar{y} = Mittel von y
s_x = Standardabweichung x		s_y = Standardabweichung y

Korrelationskoeffizient

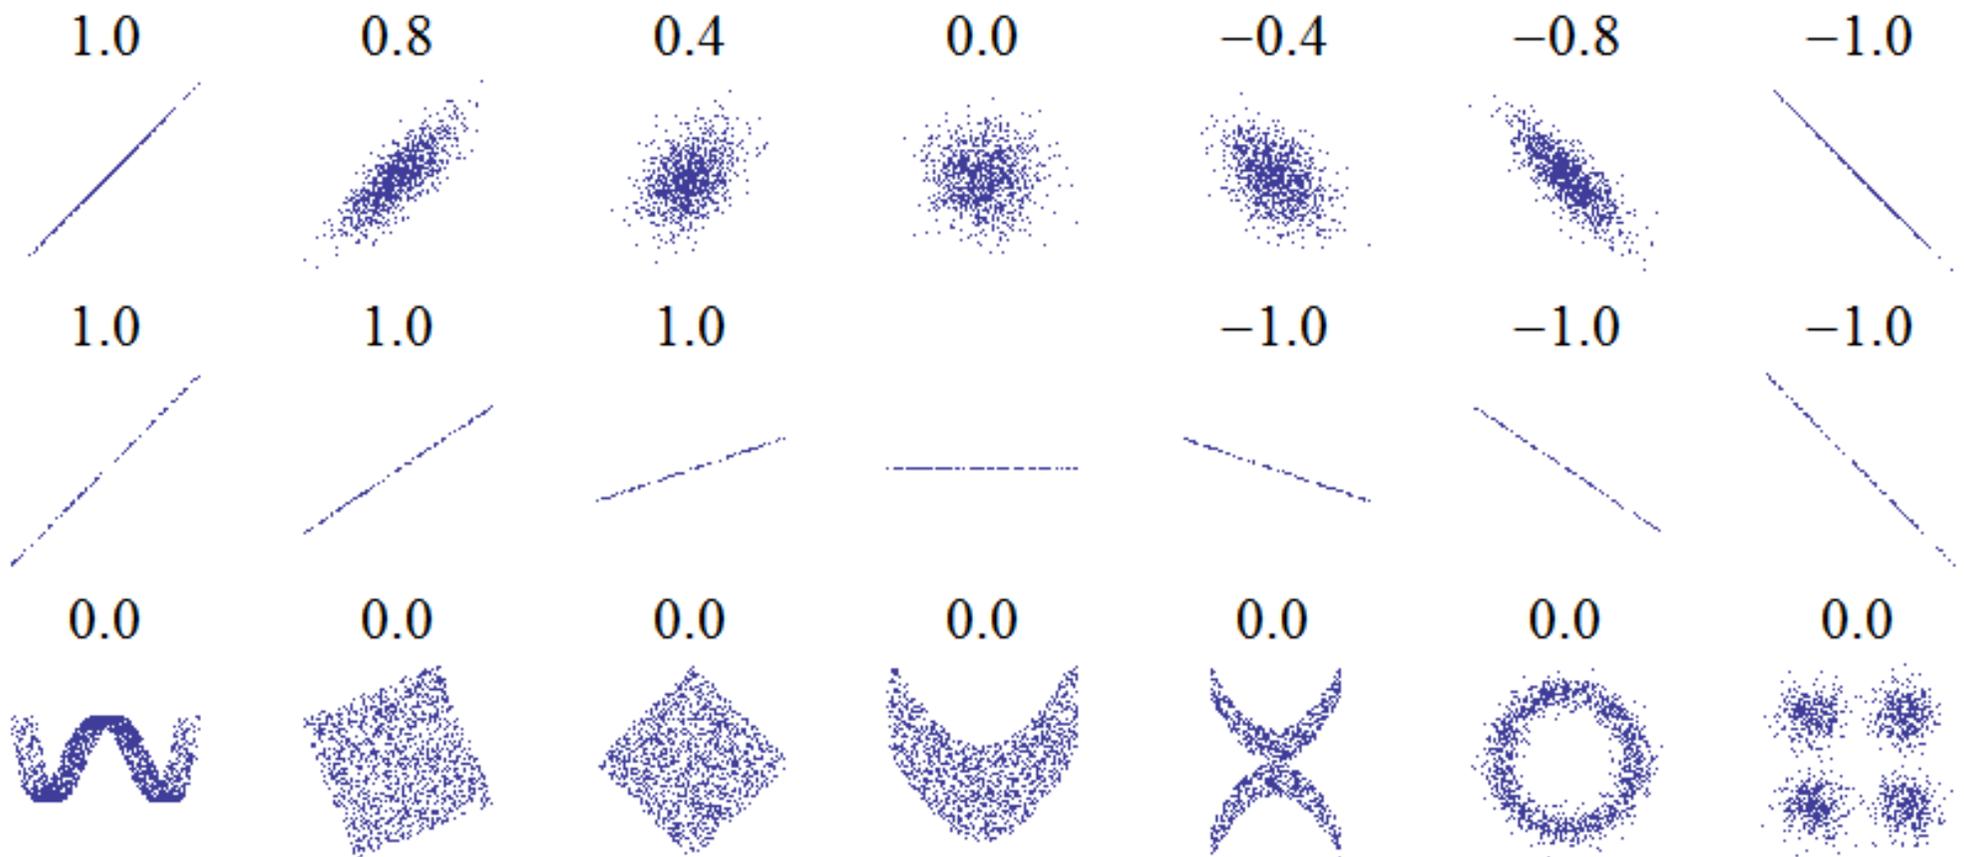
$$s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

$$r = \frac{\sum_{i=1}^n (x_{i1} - \bar{x}_1)(x_{i2} - \bar{x}_2)}{\sqrt{\sum_{i=1}^n (x_{i1} - \bar{x}_1)^2} \sqrt{\sum_{i=1}^n (x_{i2} - \bar{x}_2)^2}}$$

$$-1 \leq r \leq +1$$



Korrelationskoeffizient: Veranschaulichung



Bewertungsschätzungen

- Sei D die Menge der k ähnlichsten Nutzer zu c , die Artikel s bewertet haben
- Definiere Schätzfunktion für Bewertung von s :
 - $r_{cs} = 1/k \sum_{d \in D} r_{ds}$ oder
 - $r_{cs} = (\sum_{d \in D} \text{sim}(c,d) \cdot r_{ds}) / (\sum_{d \in D} \text{sim}(c,d))$
 - ...

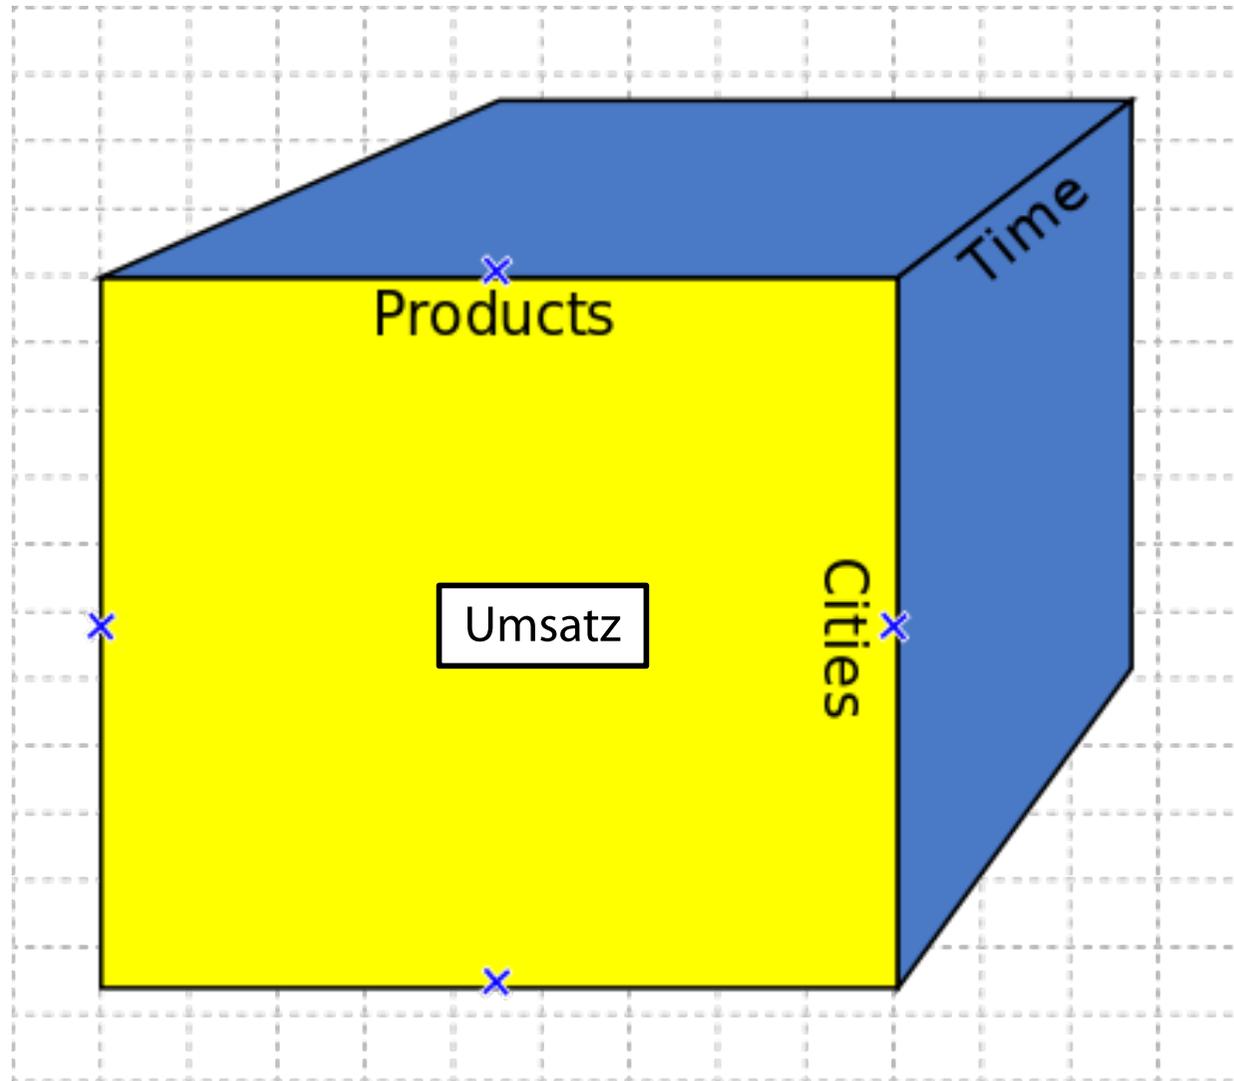
Aufwand?

- Aufwendige Suche nach k ähnlichsten Nutzern
 - Betrachtung aller Nutzer
- Kann kaum zur "Laufzeit" erfolgen
 - Vorausberechnung nötig
- Alternative zur Berechnung von r_{cs} ?
 - Suche nach ähnlichen Artikeln
 - Artikel-Artikel-kollaborative-Filterung
 - Sonst gleiches Vorgehen
 - Suche Assoziationsregeln mit s als Vorbedingung
 - Suche häufige Artikelmengeten mit s als Element

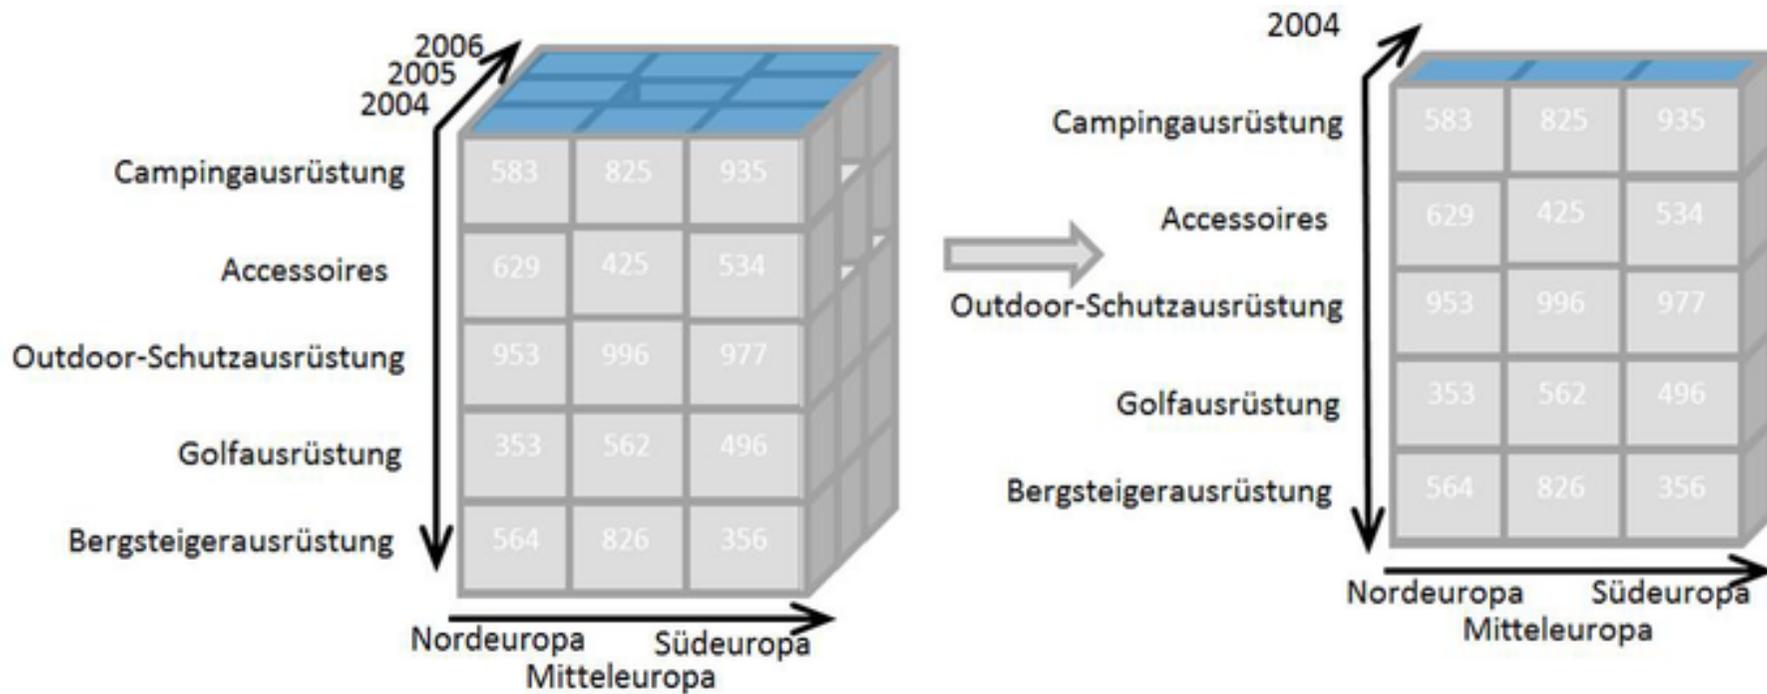
Online Analytical Processing (OLAP)

- Hypothesengestützte Analysemethode
- Daten aus den operationalen Datenbeständen eines Unternehmens oder aus einem Data-Warehouse (Datenlager)
- Ziel: Durch multidimensionale Betrachtung dieser Daten ein entscheidungsunterstützendes Analyseergebnis in Bezug auf die Hypothese zu gewinnen
- zugrundeliegende Struktur ist ein OLAP-Würfel (englisch cube), der aus der operationalen Datenbank erstellt wird

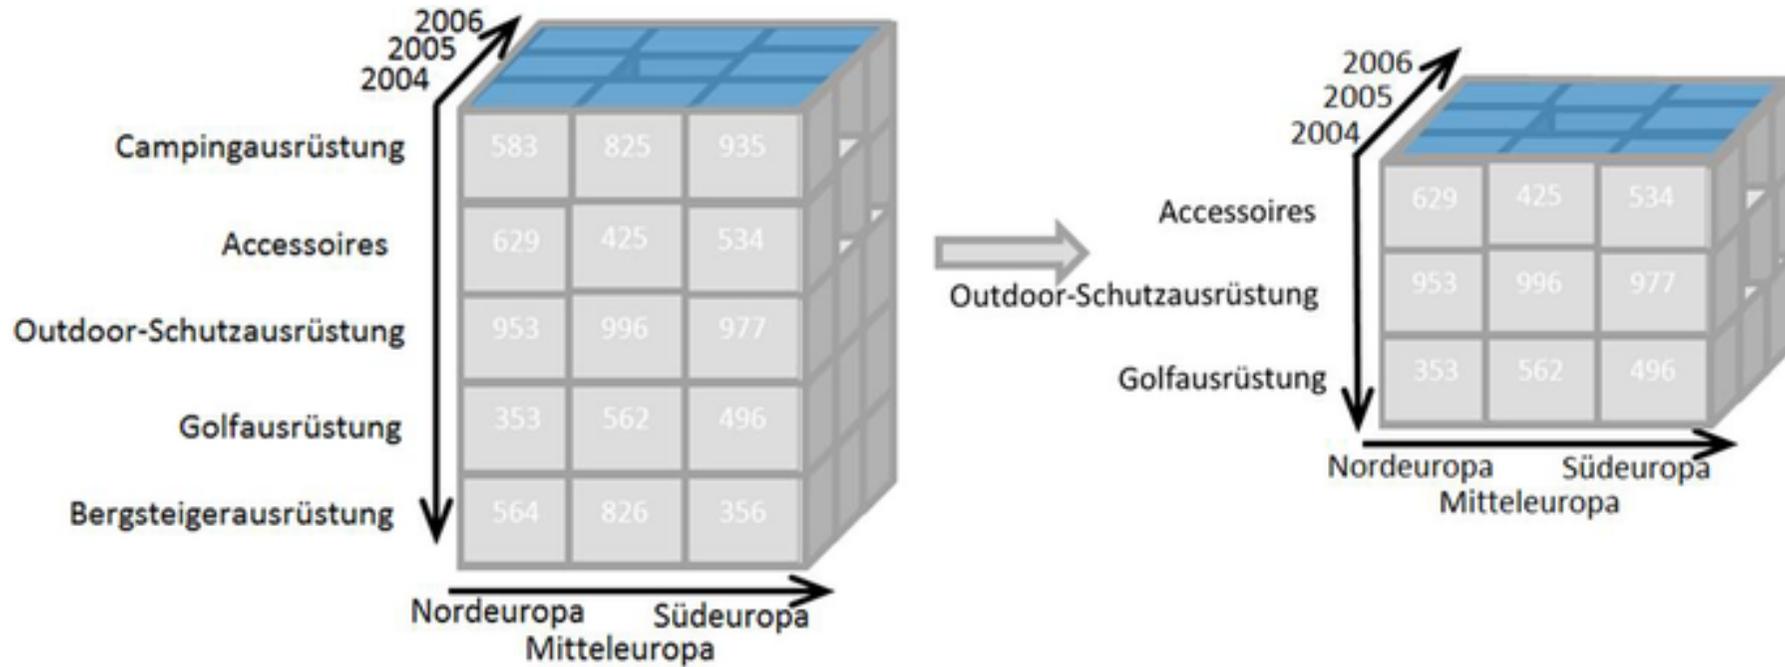
OLAP-Würfel



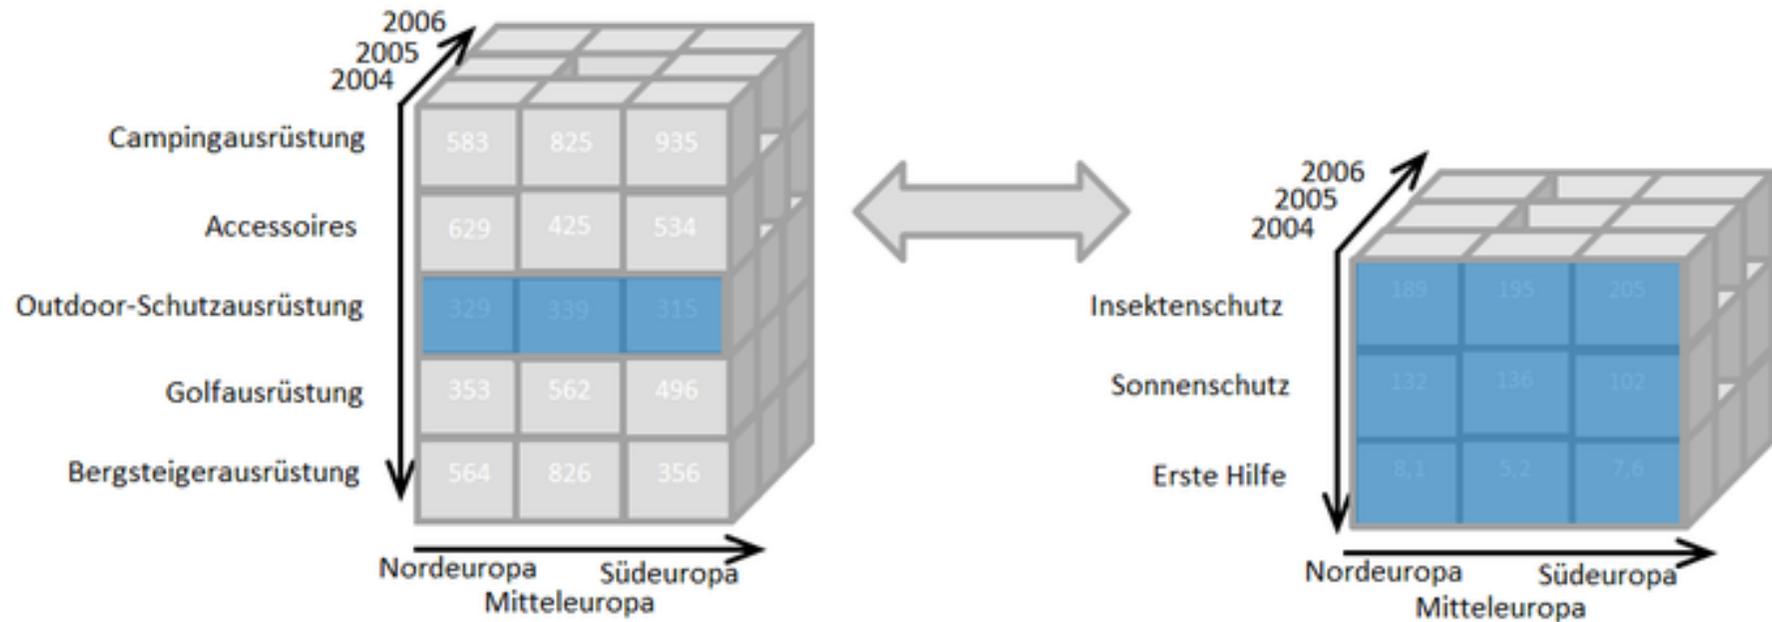
OLAP Slicing



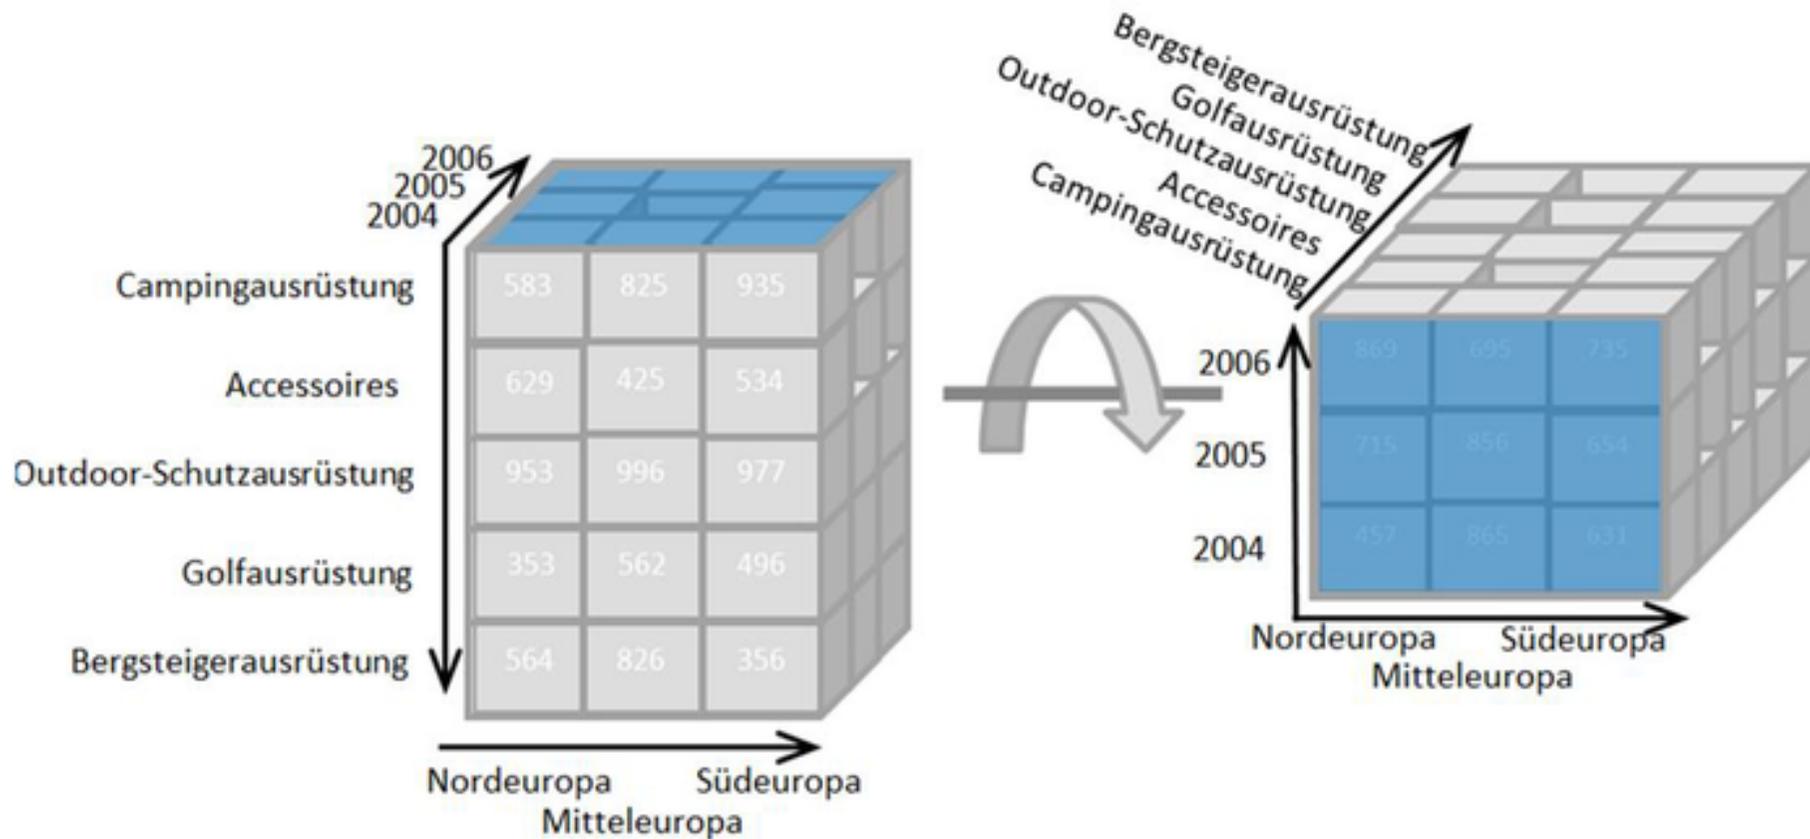
OLAP Dicing



OLAP Drill-down



OLAP Pivoting



Daten und Normalisierung

Auswertung beeinflusst durch verzogene Daten

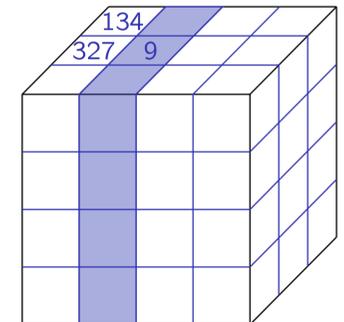
Parent				
ID	Age	Sex	Married	Income
1	40	Male	Yes	400,000
2	59	Female	No	200,000

Child			
ID	Parent	Sex	Subsidy
1	1	Male	ES
2	1	Female	NO
3	2	Female	RE

flattening ↓

Π Child.ID AS ID, Child.Sex AS Sex,
 Child.Subsidy AS Subsidy, Parent.Sex AS Psex,
 Parent.Married AS Pmarried, Parent.Income AS Pincome
 Child \bowtie Child.Parent = Parent.ID Parent

ChildParent						
ID	Sex	Subsidy	PAge	PSex	PMarried	Pincome
1	Male	ES	40	Male	Yes	400,000
2	Female	NO	40	Male	Yes	400,000
3	Female	RE	59	Female	No	200,000



Redundanzen! Bsp. Assoziationsregel
 {Pincome=400,000} → {PSex=male}??
 Support und Konfidenz werden
 verzerrt!

OLAP hilft hier nicht

Zusammenfassung

- Datenanalyse kann sehr aufwendig sein
- Brute-Force-Ansätze scheitern auf großen Datenmengen
- Genaue Analyse der Problemstellung und Aufteilung in Teilprobleme ermöglichen praxistaugliche Verfahren
- Datenrepräsentation ist entscheidend

Ausblick

- Müssen wir immer alle Daten betrachten um bestimmte Größen zu bestimmen (wie z.B. $u(c, s)$)?
- Wenn nein, welche Daten müssen wir betrachten, um bestimmte Aussagen treffen zu können?
- Welche Daten sollten wir wie erfassen?
- Führt uns auf: Statistik