

# Betriebliche Anwendungen

- OLTP
- Data Warehouse
- Data Mining

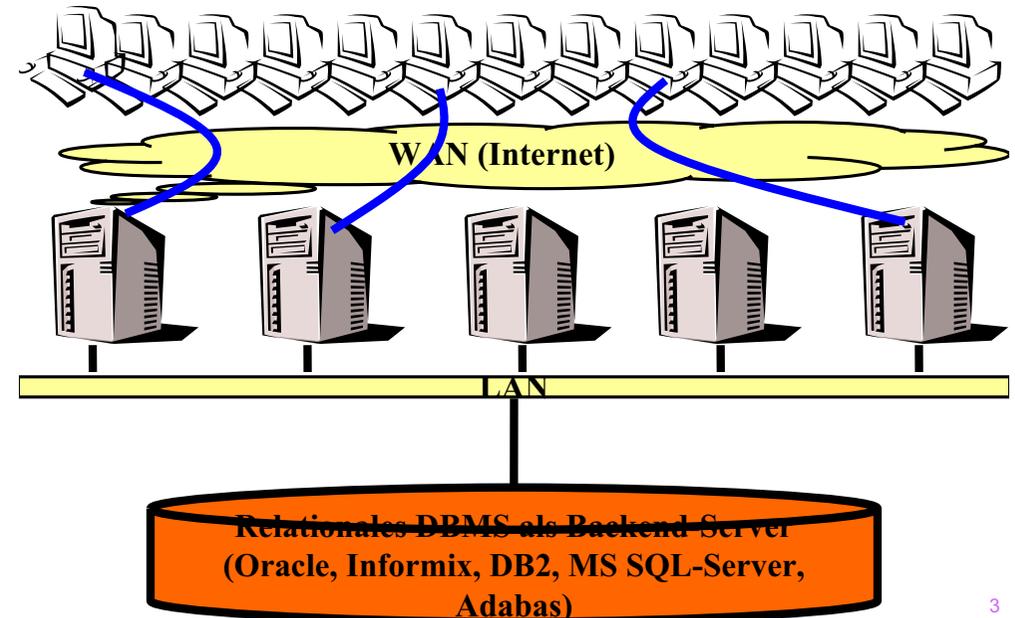


Kapitel 17

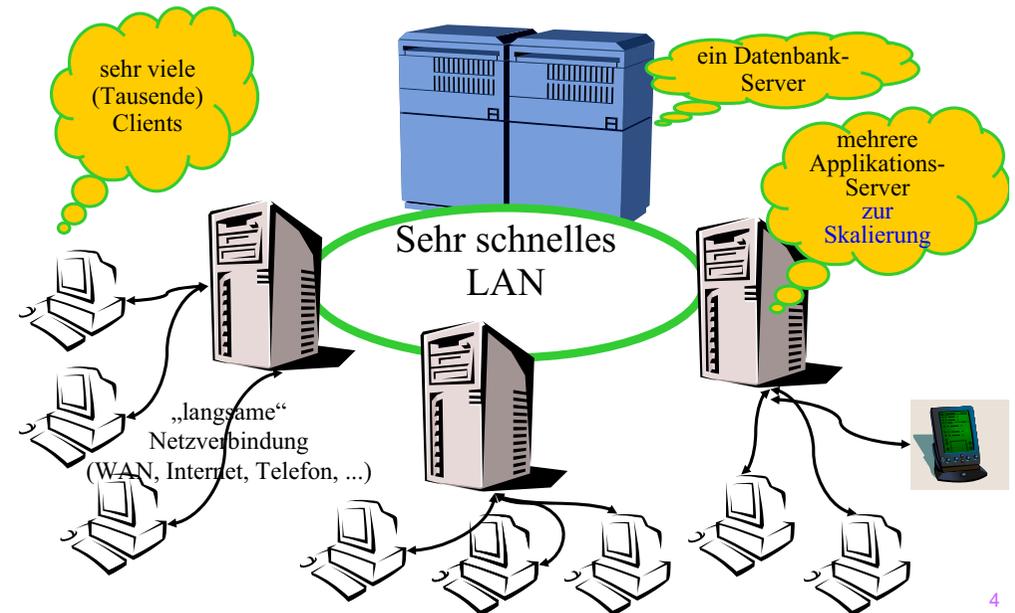
## OLTP: Online Transaction Processing

- Beispiele
  - Flugbuchungssystem
  - Bestellungen in einem Handelsunternehmen
- Charakterisierung
  - Hoher Parallelitätsgrad
  - Viele (Tausende pro Sekunde) kurze Transaktionen
  - TAs bearbeiten nur ein kleines Datenvolumen
  - „mission-critical“ für das Unternehmen
  - Hohe Verfügbarkeit muss gewährleistet sein
- Normalisierte Relationen (möglichst wenig Update-Kosten)
- Nur wenige Indexe (wegen Fortschreibungskosten)

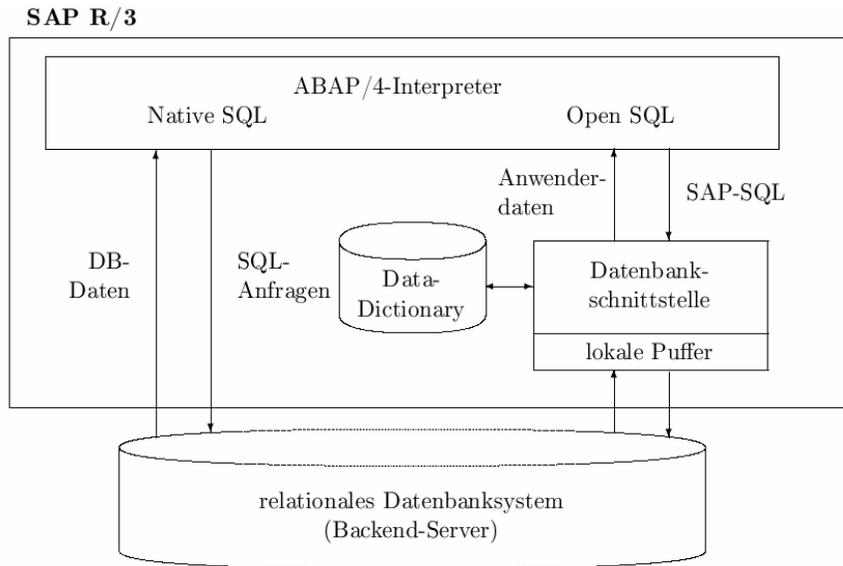
## SAP R/3: Enterprise Resource Modelling (ERP-System)



## Dreistufige Client/Server-Architektur (3 Tier, SAP R/3)



# Interne Architektur von SAP R/3



5

# Data Warehouse-Anwendungen: OLAP~Online Analytical Processing

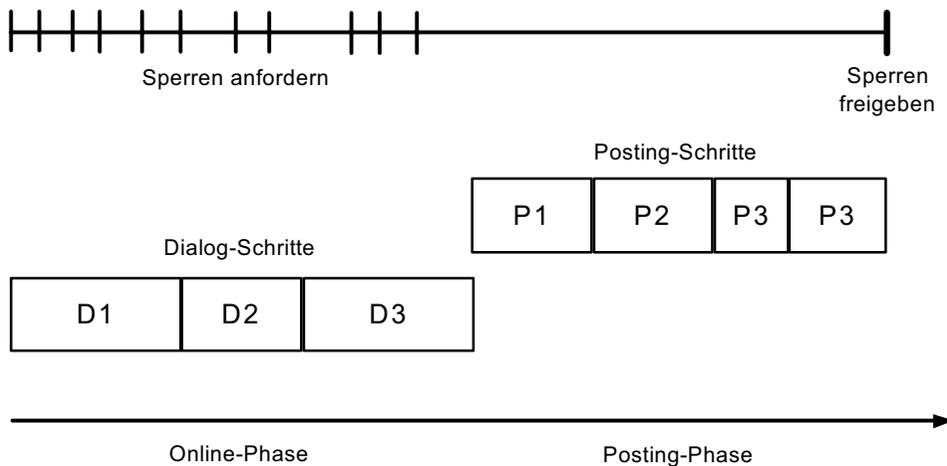
- Wie hat sich die Auslastung der Transatlantikflüge über die letzten zwei Jahre entwickelt?

oder

- Wie haben sich besondere offensive Marketingstrategien für bestimmte Produktlinien auf die Verkaufszahlen ausgewirkt?

7

# Transaktionsverarbeitung in SAP R/3

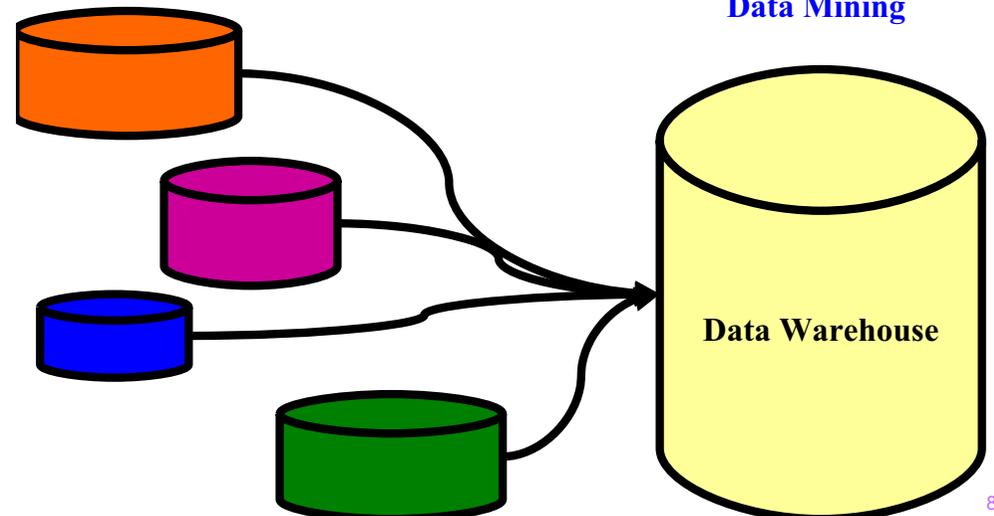


6

# Sammlung und periodische Auffrischung der Data Warehouse-Daten

OLTP-Datenbanken und andere Datenquellen

OLAP-Anfragen  
Decision Support  
Data Mining



8

# Das Stern-Schema

Verkäufe					
VerkDatum	Filiale	Produkt	Anzahl	Kunde	Verkäufer
25-Jul-00	Passau	1347	1	4711	825
...	...	...	...	...	...

Filialen			
Filialenkennung	Land	Bezirk	...
Passau	D	Bayern	...
...	...	...	...

Kunden			
KundenNr	Name	wiealt	...
4711	Kemper	43	...
...	...	...	...

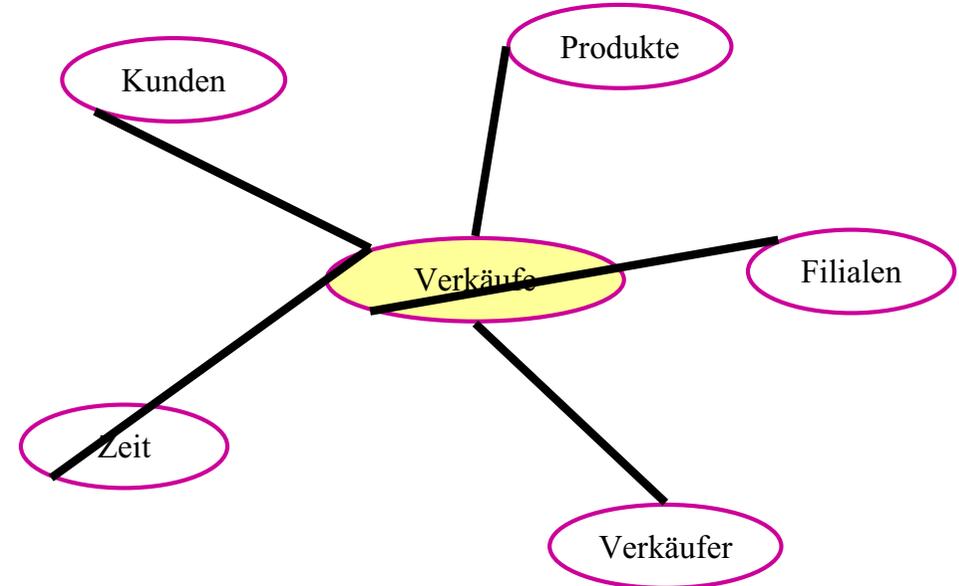
Verkäufer					
VerkäuferNr	Name	Fachgebiet	Manager	wiealt	...
825	Handyman	Elektronik	119	23	...
...	...	...	...	...	...

Zeit								
Datum	Tag	Monat	Jahr	Quartal	KW	Wochentag	Saison	...
25-Jul-00	25	Juli	2000	3	30	Dienstag	Hochsommer	...
18-Dec-01	18	Dezember	2001	4	52	Dienstag	Weihnachten	...
...	...	...	...	...	...	...	...	...

Produkte					
ProduktNr	Produkttyp	Produktgruppe	Produkthauptgruppe	Hersteller	...
1347	Handy	Mobiltelekom	Telekom	Siemens	...
...	...	...	...	...	...

9

# Das Stern-Schema: Handelsunternehmen



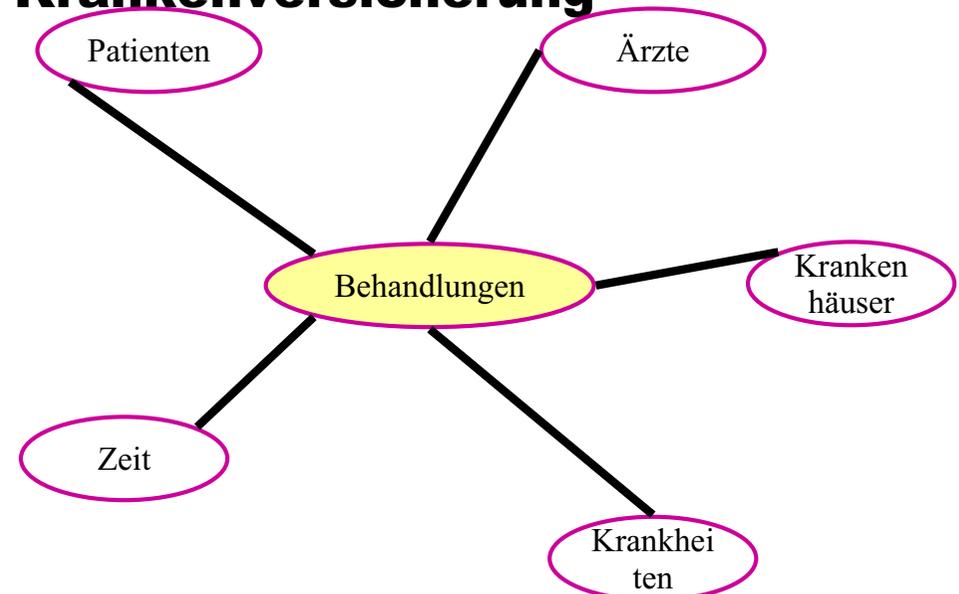
11

# Stern-Schema bei Data Warehouse-Anwendungen

- Eine sehr große Faktentabelle
  - Alle Verkäufe der letzten drei Jahre
  - Alle Telefonate des letzten Jahres
  - Alle Flugreservierungen der letzten fünf Jahre
  - normalisiert
- Mehrere Dimensionstabellen
  - Zeit
  - Filialen
  - Kunden
  - Produkt
  - Oft nicht normalisiert

10

# Das Stern-Schema: Krankenversicherung



12

# Stern-Schema

Verkäufe					
VerkDatum	Filiale	Produkt	Anzahl	Kunde	Verkäufer
25-Jul-00	Passau	1347	1	4711	825
...	...	...	...	...	...

Faktentabelle (SEHR groß)

Filialen			
FilialenKennung	Land	Bezirk	...
Passau	D	Bayern	...
...	...	...	...

Kunden			
KundenNr	Name	wieAlt	...
4711	Kemper	43	...
...	...	...	...

Dimensionstabellen (relativ klein)

Verkäufer					
VerkäuferNr	Name	Fachgebiet	Manager	wieAlt	...
825	Handyman	Elektronik	119	23	...
...	...	...	...	...	...

# Stern-Schema (cont'd)

Zeit							
Datum	Tag	Monat	Jahr	Quartal	KW	Wochentag	Saison
25-Jul-00	25	7	2000	3	30	Dienstag	Hochsommer
...	...	...	...	...	...	...	...
18-Dec-01	18	12	2001	4	52	Dienstag	Weihnachten
...	...	...	...	...	...	...	...

Produkte					
ProduktNr	Produkttyp	Produktgruppe	Produkthauptgruppe	Hersteller	..
1347	Handy	Mobiltelekom	Telekom	Siemens	..
...	...	...	...	...	..

# Nicht-normalisierte Dimensionstabellen: effizientere Anfrageauswertung

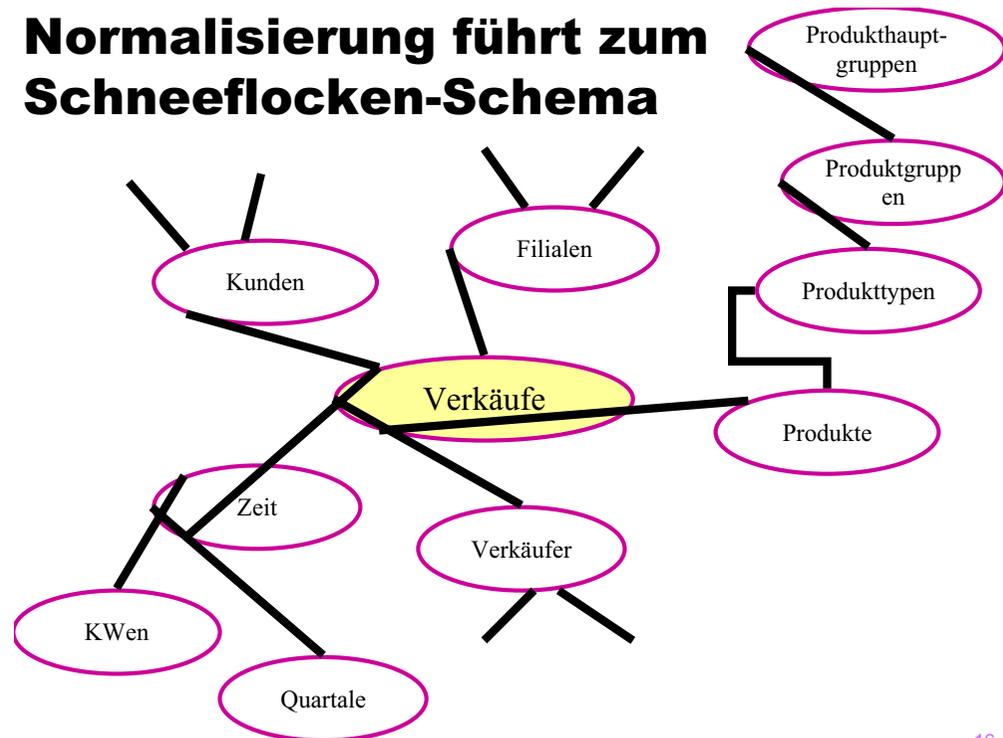
Zeit							
Datum	Tag	Monat	Jahr	Quartal	KW	Wochentag	Saison
25-Jul-00	25	7	2000	3	30	Dienstag	Hochsommer
...	...	...	...	...	...	...	...
18-Dec-01	18	12	2001	4	52	Dienstag	Weihnachten
...	...	...	...	...	...	...	...

Datum → Monat → Quartal

Produkte					
ProduktNr	Produkttyp	Produktgruppe	Produkthauptgruppe	Hersteller	..
1347	Handy	Mobiltelekom	Telekom	Siemens	..
...	...	...	...	...	..

ProduktNr → Produkttyp → Produktgruppe → Produkthauptgruppe

# Normalisierung führt zum Schneeflocken-Schema



## Anfragen im Sternschema

```

select sum(v.Anzahl), p.Hersteller
from Verkäufe v, Filialen f, Produkte p, Zeit z, Kunden k
where z.Saison = 'Weihnachten' and
       z.Jahr = 2001 and k.wieAlt < 30 and
       p.Produkttyp = 'Handy' and f.Bezirk = 'Bayern' and
       v.VerkDatum = z.Datum and v.Produkt = p.ProduktNr and
       v.Filiale = f.FilialenKennung and v.Kunde = k.KundenNr
group by p.Hersteller;
    
```

Einschränkung  
der Dimensionen

Join-Prädikate

17

## Roll-up/Drill-down-Anfragen

```

select Jahr, Hersteller, sum(Anzahl)
from Verkäufe v, Produkte p, Zeit z
where v.Produkt = p.ProduktNr and v.VerkDatum = z.Datum
       and p.Produkttyp = 'Handy'
group by p.Hersteller, z.Jahr;
    
```

```

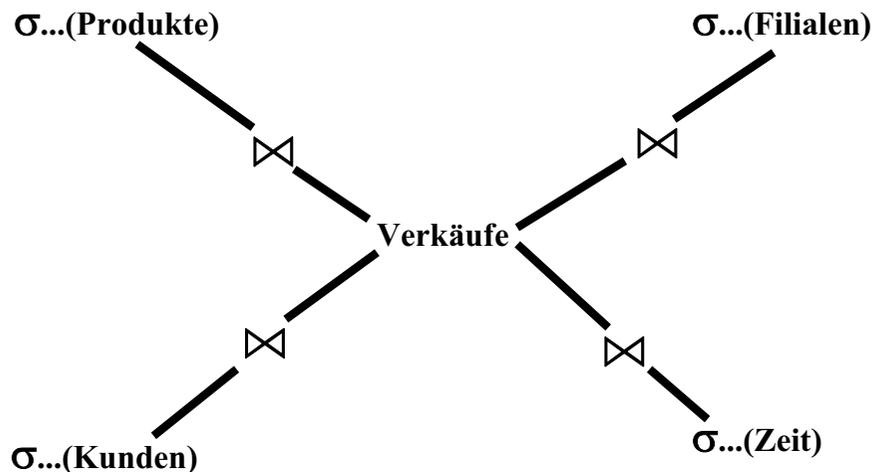
select Jahr, sum(Anzahl)
from Verkäufe v, Produkte p, Zeit z
where v.Produkt = p.ProduktNr and v.VerkDatum = z.Datum
       and p.Produkttyp = 'Handy'
group by z.Jahr;
    
```

Roll-up

Drill-down

19

## Algebra-Ausdruck



18

## Ultimative Verdichtung

```

select sum(Anzahl)
from Verkäufe v, Produkte p
where v.Produkt = p.ProduktNr and p.Produkttyp = 'Handy';
    
```

20

Handyverkäufe nach Hersteller und Jahr		
Hersteller	Jahr	Anzahl
Siemens	1999	2.000
Siemens	2000	3.000
Siemens	2001	3.500
Motorola	1999	1.000
Motorola	2000	1.000
Motorola	2001	1.500
Bosch	1999	500
Bosch	2000	1.000
Bosch	2001	1.500
Nokia	1999	1.000
Nokia	2000	1.500
Nokia	2001	2.000

Handyverkäufe nach Jahr	
Jahr	Anzahl
1999	4.500
2000	6.500
2001	8.500

Handyverkäufe nach Hersteller	
Hersteller	Anzahl
Siemens	8.500
Motorola	3.500
Bosch	3.000
Nokia	4.500

Abb. 17.7: Analyse der Handyverkaufszahlen nach unterschiedlichen Dimensionen

Hersteller \ Jahr	1999	2000	2001	Σ
Siemens	2.000	3.000	3.500	8.500
Motorola	1.000	1.000	1.500	3.500
Bosch	500	1.000	1.500	3.000
Nokia	1.000	1.500	2.000	4.500
Σ	4.500	6.500	8.500	19.500

Abb. 17.8: Handyverkäufe nach Jahr und Hersteller

Handyverkäufe nach Hersteller und Jahr		
Hersteller	Jahr	Anzahl
Siemens	1999	2.000
Siemens	2000	3.000
Siemens	2001	3.500
Motorola	1999	1.000
Motorola	2000	1.000
Motorola	2001	1.500
Bosch	1999	500
Bosch	2000	1.000
Bosch	2001	1.500
Nokia	1999	1.000
Nokia	2000	1.500
Nokia	2001	2.000

Handyverkäufe nach Jahr	
Jahr	Anzahl
1999	4.500
2000	6.500
2001	8.500

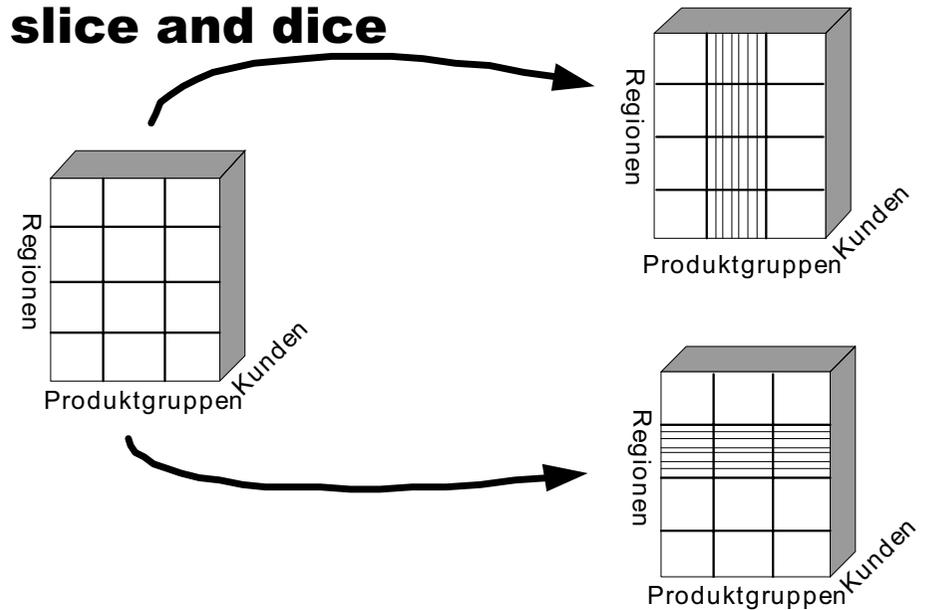
Handyverkäufe nach Hersteller	
Hersteller	Anzahl
Siemens	8.500
Motorola	3.500
Bosch	3.000
Nokia	4.500

Abb. 17.7: Analyse der Handyverkaufszahlen nach unterschiedlichen Dimensionen

Hersteller \ Jahr	1999	2000	2001	Σ
Siemens	2.000	3.000	3.500	8.500
Motorola	1.000	1.000	1.500	3.500
Bosch	500	1.000	1.500	3.000
Nokia	1.000	1.500	2.000	4.500
Σ	4.500	6.500	8.500	19.500

Abb. 17.8: Handyverkäufe nach Jahr und Hersteller

## Flexible Auswertungsmethoden: slice and dice



## Materialisierung von Aggregaten

```

insert into Handy2DCube
( select p.Hersteller, z.Jahr, sum(v.Anzahl)
  from Verkäufe v, Produkte p, Zeit z
  where v.Produkt = p.ProduktNr and p.Produkttyp = 'Handy'
        and v.VerkDatum = z.Datum
  group by z.Jahr, p.Hersteller )
union
( select p.Hersteller, to_number(null), sum(v.Anzahl)
  from Verkäufe v, Produkte p
  where v.Produkt = p.ProduktNr and p.Produkttyp = 'Handy'
  group by p.Hersteller )
union
( select null, z.Jahr, sum(v.Anzahl)
  from Verkäufe v, Produkte p, Zeit z
  where v.Produkt = p.ProduktNr and p.Produkttyp = 'Handy'
        and v.VerkDatum = z.Datum
  group by z.Jahr )
union
( select null, to_number(null), sum(v.Anzahl)
  from Verkäufe v, Produkte p
  where v.Produkt = p.ProduktNr and p.Produkttyp = 'Handy' );

```

## Relationale Struktur der Datenwürfel

Handy2DCube		
Hersteller	Jahr	Anzahl
Siemens	1999	2.000
Siemens	2000	3.000
Siemens	2001	3.500
Motorola	1999	1.000
Motorola	2000	1.000
Motorola	2001	1.500
Bosch	1999	500
Bosch	2000	1.000
Bosch	2001	1.500
Nokia	2000	1.000
Nokia	2001	1.500
Nokia	2001	2.000
null	1999	4.500
null	2000	6.500
null	2001	8.500
Siemens	null	8.500
Motorola	null	3.500
Bosch	null	3.000
Nokia	null	4.500
null	null	19.500

Handy3DCube			
Hersteller	Jahr	Land	Anzahl
Siemens	1999	D	800
Siemens	1999	A	600
Siemens	1999	CH	600
Siemens	2000	D	1.200
Siemens	2000	A	800
Siemens	2000	CH	1.000
Siemens	2001	D	1.400
...	...	...	...
Motorola	1999	D	400
Motorola	1999	A	300
Motorola	1999	CH	300
...	...	...	...
Bosch	...	...	...
...	...	...	...
null	1999	D	...
null	2000	D	...
...	...	...	...
Siemens	null	null	8.500
...	...	...	...
null	null	null	19.500

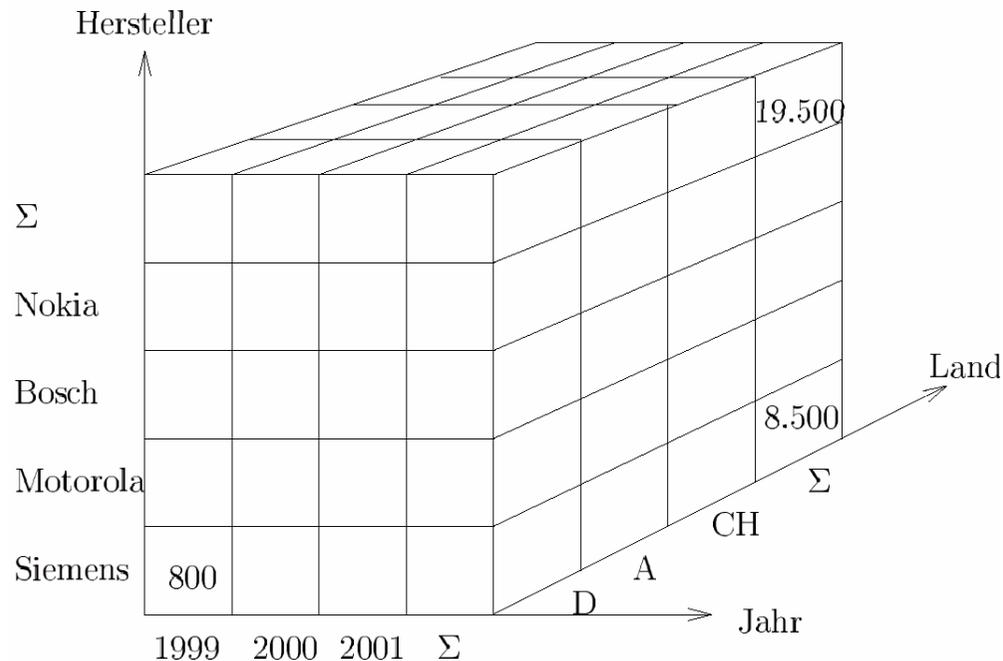
25

## Der **cube**-Operator

```
select p.Hersteller, z.Jahr, f.Land, sum(v.Anzahl)
from Verkäufe v, Produkte p, Zeit z, Filialen f
where v.Produkt = p.ProduktNr and p.Produkttyp = 'Handy'
and v.VerkDatum = z.Datum and v.Filiale = f.Filialenkennung
group by cube (z.Jahr, p.Hersteller, f.Land);
```

27

## Würfeldarstellung



## Wiederverwendung von Teil-Aggregaten

```
insert into VerkäufeProduktFilialeJahr
( select v.Produkt, v.Filiale, z.Jahr, sum(v.Anzahl)
from Verkäufe v, Zeit z
where v.VerkDatum = z.Datum
group by v.Produkt, v.Filiale, z.Jahr );
```

Wie kann die folgende Anfrage nun effizient beantwortet werden?

```
select v.Produkt, v.Filiale, sum(v.Anzahl)
from Verkäufe v
group by v.Produkt, v.Filiale
```

28

## Wiederverwendung von Teil-Aggregaten

```
select v.Produkt, v.Filiale, sum(v.Anzahl)
from Verkäufe v
group by v.Produkt, v.Filiale
```



```
select v.Produkt, v.Filiale, sum(v.Anzahl)
from VerkäufeProduktFilialeJahr v
group by v.Produkt, v.Filiale
```

29

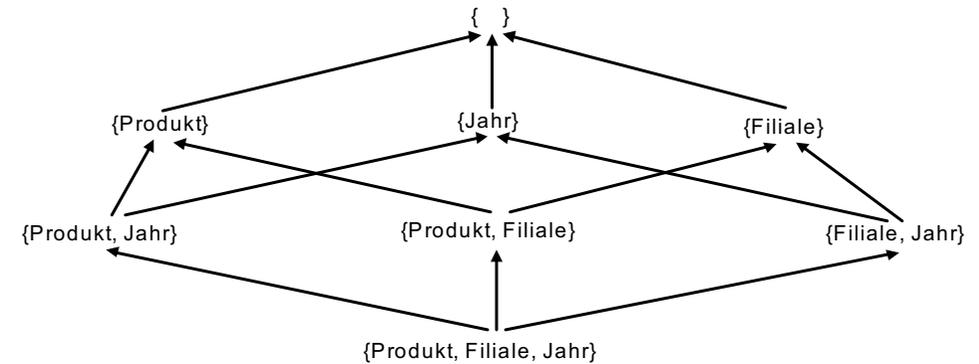
## Wiederverwendung von Teil-Aggregaten

```
select v.Produkt, z.Jahr, sum(v.Anzahl)
from Verkäufe v, Zeit z
where v.VerkDatum = z.Datum
group by v.Produkt, z.Jahr
```

... kann ähnlich mit VerkäufeProduktFilialeJahr rationalisiert werden.  
(Wie? → gute Übung!)

30

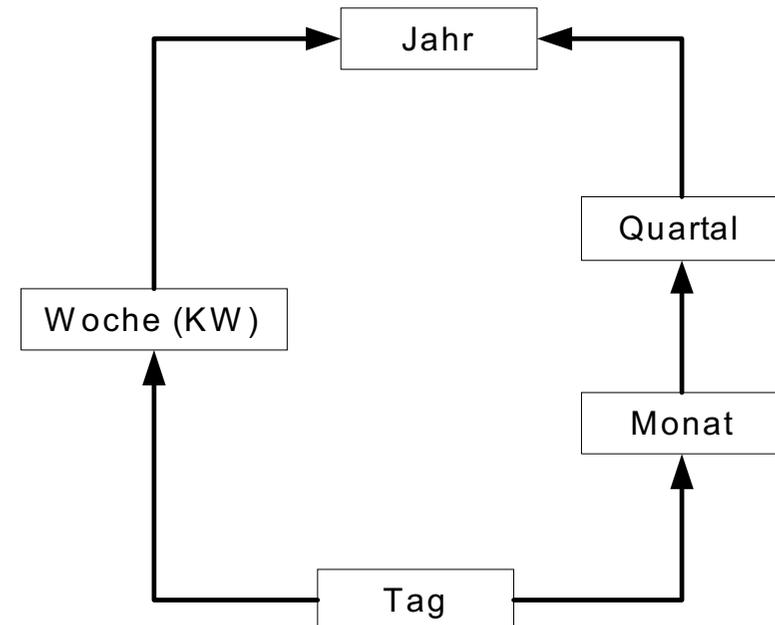
## Die Materialisierungs-Hierarchie



- Teilaggregate T sind für eine Aggregation A wiederverwendbar wenn es einen gerichteten Pfad von T nach A gibt
- Also  $T \rightarrow \dots \rightarrow A$
- Man nennt diese Materialisierungshierarchie auch einen Verband (Engl. *Lattice*)

31

## Die Zeit-Hierarchie



32

# Bitmap-Indexe

$w_{18}$	$w_{19}$	Kunden					$G_m$	$G_w$
<b>18</b>	<b>19</b>	KundenNr	Name	wiealt	Geschlecht	...	<b>m</b>	<b>w</b>
0	0	007	Bond	43	m	...	1	0
1	0	4013	Mini	18	w	...	0	1
1	0	4315	Mickey	18	m	...	1	0
0	0	4711	Kemper	43	m	...	1	0
0	1	5913	Twiggy	19	w	...	0	1
...	...	...	...	...	...	...	...	...

- Optimierung durch Komprimierung der Bitmaps
- Ausnutzung der dünnen Besetzung
  - Runlength-compression
    - Grundidee: speichere jeweils die Länge der Nullfolgen zwischen zwei Einsen
  - Mehrmodus-Komprimierung:
    - bei langen Null/Einsfolgen speichere deren Länge
    - Sonst speichere das Bitmuster

# Beispiel-Anfrage und Auswertung

```
select k.Name, ...
from Kunden k
where k.Geschlecht = 'w' and
      k.wiealt between 18 and 19;
```

# Bitmap-Operationen

$w_{18}$	$w_{19}$	$w_{18} \vee w_{19}$	$(w_{18} \vee w_{19}) \wedge G_w$
<b>18</b>	<b>19</b>	<b>18 .. 19</b>	
0	0	0	0
1	0	1	1
1	0	1	1
0	0	0	0
0	1	1	1
...	...	...	...

$w_{18} \vee w_{19}$	$G_w$	$(w_{18} \vee w_{19}) \wedge G_w$
<b>18 .. 19</b>	<b>w</b>	<b>Ergebnis</b>
0	0	0
1	1	1
1	0	0
0	0	0
1	1	1
...	...	...

33

35

Verkäufe			Join-Index		Kunden		
TID	...	KundenNr	TID-V	TID-K	TID	KundenNr	...
<i>i</i>	...	007	<i>i</i>	<i>II</i>	<i>I</i>	4711	...
<i>ii</i>	...	4711	<i>ii</i>	<i>I</i>	<i>II</i>	007	...
<i>iii</i>	...	007	<i>iii</i>	<i>II</i>	<i>III</i>	...	...
<i>iv</i>	...	007	<i>iv</i>	<i>II</i>	...	...	...
<i>v</i>	...	4711	<i>v</i>	<i>I</i>	...	...	...
<i>vi</i>	...	007	<i>vi</i>	<i>II</i>	...	...	...
...	...	...	...	...	...	...	...

bb. 17.17: Klassischer Join-Index

$$(w_{18} \vee w_{19}) \wedge G_w$$

## Bitmap-Join-Index

Verkäufe			$J_I$	$J_{II}$	$J_{III}$	Kunden		
TID	...	KundenNr				TID	KundenNr	...
<i>i</i>	...	007	0	1	...	<i>I</i>	4711	...
<i>ii</i>	...	4711	1	0	...	<i>II</i>	007	...
<i>iii</i>	...	007	0	1	...	<i>III</i>	...	...
<i>iv</i>	...	007	0	1	...	...	...	...
<i>v</i>	...	4711	1	0	...	...	...	...
<i>vi</i>	...	007	0	1	...	...	...	...
...	...	...	...	...	...	...	...	...

34

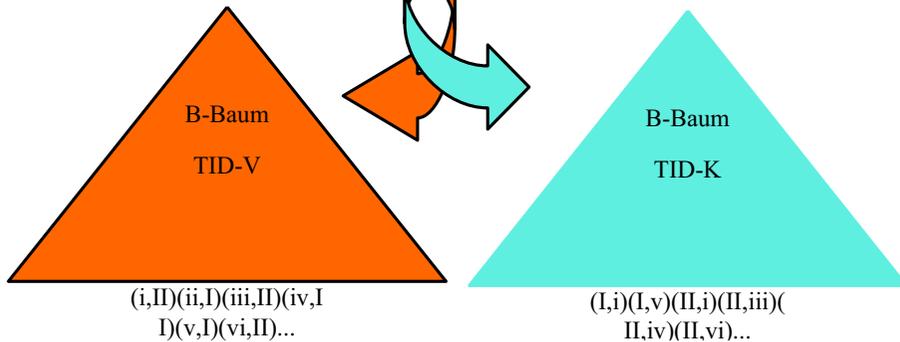
36

Verkäufe		
TID	...	KundenNr
<i>i</i>	...	007
<i>ii</i>	...	4711
<i>iii</i>	...	007
<i>iv</i>	...	007
<i>v</i>	...	4711
<i>vi</i>	...	007
...	...	...

Join-Index	
TID-V	TID-K
<i>i</i>	<i>II</i>
<i>ii</i>	<i>I</i>
<i>iii</i>	<i>II</i>
<i>iv</i>	<i>II</i>
<i>v</i>	<i>I</i>
<i>vi</i>	<i>II</i>
...	...

Kunden		
TID	KundenNr	...
<i>I</i>	4711	...
<i>II</i>	007	...
<i>III</i>	...	...
...	...	...

bb. 17.17: Klassischer Join-Index

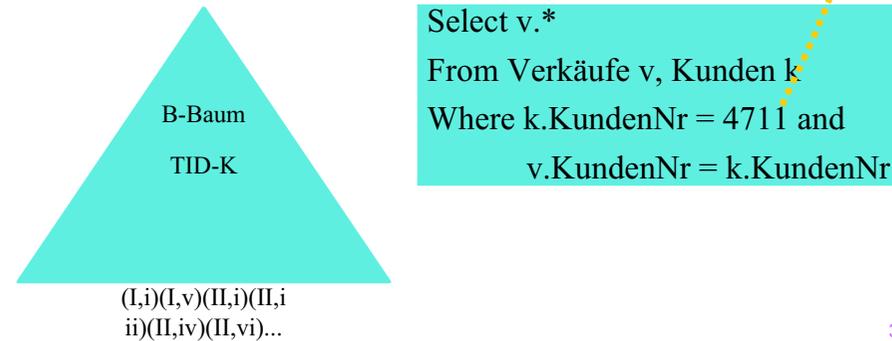


Verkäufe		
TID	...	KundenNr
<i>i</i>	...	007
<i>ii</i>	...	4711
<i>iii</i>	...	007
<i>iv</i>	...	007
<i>v</i>	...	4711
<i>vi</i>	...	007
...	...	...

Join-Index	
TID-V	TID-K
<i>i</i>	<i>II</i>
<i>ii</i>	<i>I</i>
<i>iii</i>	<i>II</i>
<i>iv</i>	<i>II</i>
<i>v</i>	<i>I</i>
<i>vi</i>	<i>II</i>
...	...

Kunden		
TID	KundenNr	...
<i>I</i>	4711	...
<i>II</i>	007	...
<i>III</i>	...	...
...	...	...

bb. 17.17: Klassischer Join-Index

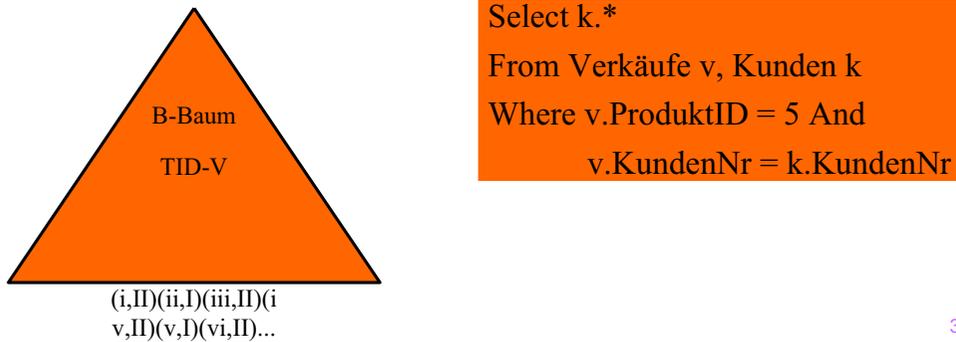


Verkäufe		
TID	...	KundenNr
<i>i</i>	...	007
<i>ii</i>	5	4711
<i>iii</i>	...	007
<i>iv</i>	...	007
<i>v</i>	...	4711
<i>vi</i>	5	007
...	...	...

Join-Index	
TID-V	TID-K
<i>i</i>	<i>II</i>
<i>ii</i>	<i>I</i>
<i>iii</i>	<i>II</i>
<i>iv</i>	<i>II</i>
<i>v</i>	<i>I</i>
<i>vi</i>	<i>II</i>
...	...

Kunden		
TID	KundenNr	...
<i>I</i>	4711	...
<i>II</i>	007	...
<i>III</i>	...	...
...	...	...

bb. 17.17: Klassischer Join-Index



Verkäufe					
VerkDatum	Filiale	Produkt	Anzahl	Kunde	Verkäufer
25-Jul-00	Passau	1347	1	4711	825
...	...	...	...	...	...

Filialen			
Filialenkennung	Land	Bezirk	...
Passau	D	Bayern	...
...	...	...	...

Kunden			
KundenNr	Name	wiealt	...
4711	Kemper	43	...
...	...	...	...

Verkäufer					
VerkäuferNr	Name	Fachgebiet	Manager	wiealt	...
825	Handyman	Elektronik	119	23	...
...	...	...	...	...	...

Zeit								
Datum	Tag	Monat	Jahr	Quartal	KW	Wochentag	Saison	...
...	...	...	...	...	...	...	...	...
25-Jul-00	25	Juli	2000	3	30	Dienstag	Hochsommer	...
...	...	...	...	...	...	...	...	...
18-Dec-01	18	Dezember	2001	4	52	Dienstag	Weihnachten	...
...	...	...	...	...	...	...	...	...

Produkte					
ProduktNr	Produkttyp	Produktgruppe	Produkthauptgruppe	Hersteller	...
1347	Handy	Mobiltelekom	Telekom	Siemens	...
...	...	...	...	...	...

# Beispielanfrage auf dem Sternschema: Stern-Verbund -- Star Join

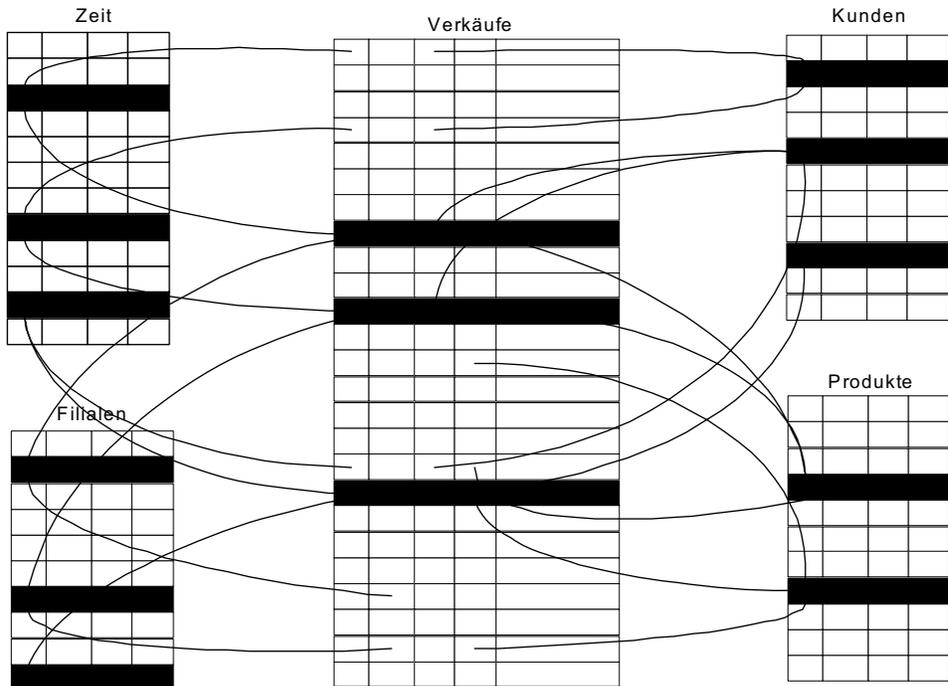
```

select sum(v.Anzahl), p.Hersteller
from Verkäufe v, Filialen f, Produkte p, Zeit z, Kunden k
where z.Saison = 'Weihnachten' and
      z.Jahr = 2001 and k.wieAlt < 30 and
      p.Produkttyp = 'Handy' and f.Bezirk = 'Bayern' and
      v.VerkDatum = z.Datum and v.Produkt = p.ProduktNr and
      v.Filiale = f.FilialenKennung and v.Kunde = k.KundenNr
group by p.Hersteller;
    
```

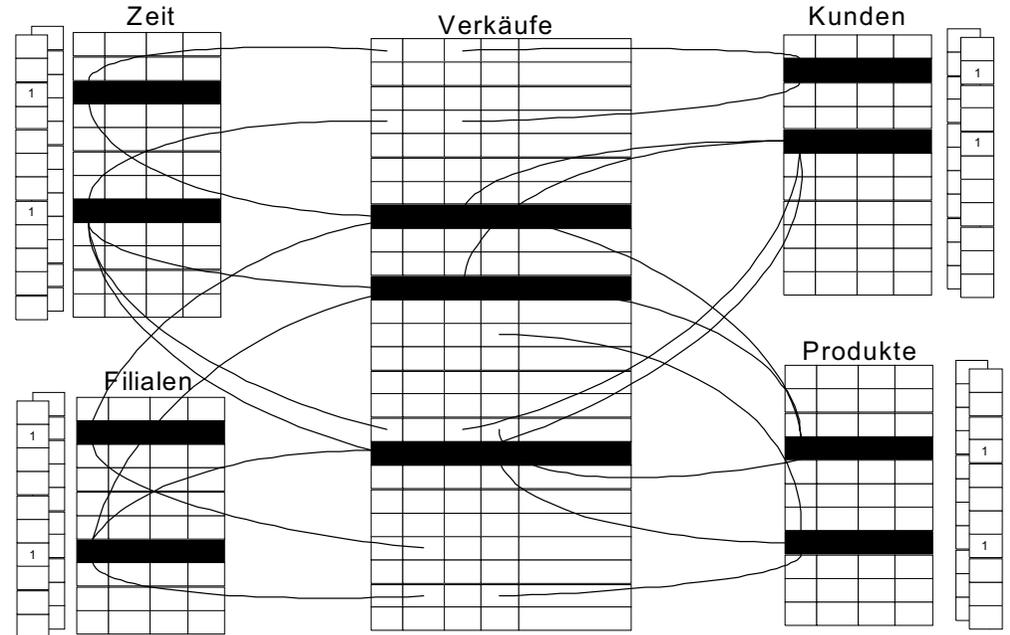
Einschränkung  
der Dimensionen

Join-Prädikate

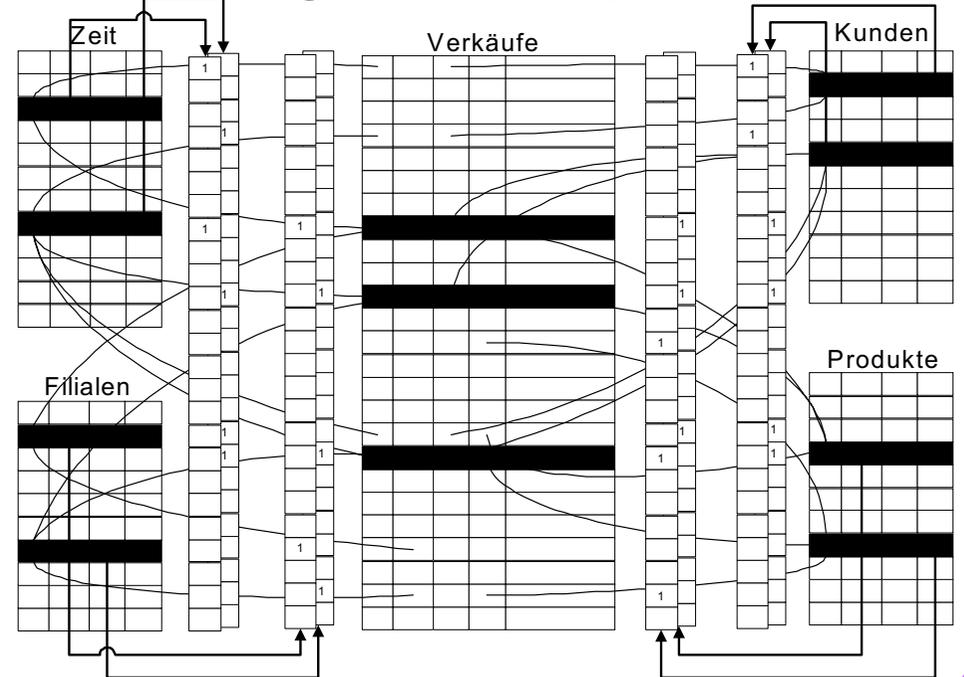
## Illustration des Star Join



## Bitmap-Indexte für die Dimensions- Selektion



## Ausnutzung der Bitmap-Join-Indexte



## Weitere Decision-Support Anfrage-Typen

- Top N-Anfragen
  - Ich will nur die N besten Treffer erhalten und nicht alle 5 Millionen
  - Muss bei der Anfrageoptimierung berücksichtigt werden
- Online Aggregation
  - Man berechnet das Ergebnis approximativ
  - Je länger die Anfrage läuft, desto genauer wird das Ergebnis

45

## Top N-Anfragen

**Select** A.\*  
**From** Angestellte A, Abteilungen abt  
**Where** A.Abtteilung = abt.AbtteilungsNr and abt.Ort = Passau  
**Order by** A.Gehalt  
**Stop after** 20

46

## Online-Aggregation

**Select** abt.Ort, avg(A.Gehalt)  
**From** Angestellte A, Abteilungen abt  
**Where** A.Abtteilung = abt.AbtteilungsNr  
**Group by** abt.Ort

47

## Data Mining

Data-Mining-Verfahren sind das Kernthema der Vorlesung "Knowledge Discovery", die regelmäßig vom Fachgebiet Wissensverarbeitung angeboten wird.

Hier stellen wir nur drei wesentliche Fragestellungen des Data Mining/Knowledge Discovery vor:

- Klassifikation
- Assoziationsregeln
- Clustering

48

# Klassifikationsregeln

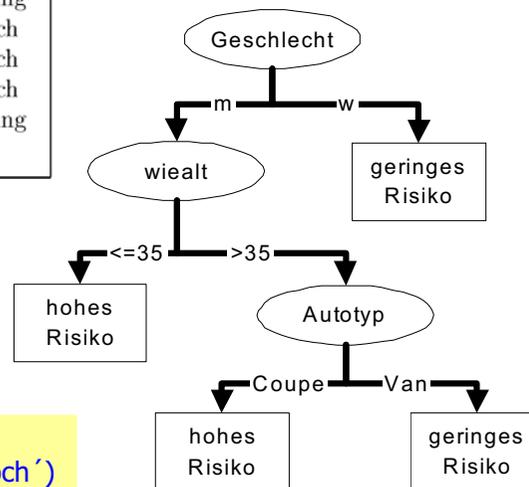
- Vorhersageattribute
  - $V_1, V_2, \dots, V_n$
- Vorhergesagtes Attribut A
- Klassifikationsregel
  - $P_1(V_1) \wedge P_2(V_2) \wedge \dots \wedge P_n(V_n) \rightarrow A = c$
  - Prädikate  $P_1, P_2, \dots, P_n$
  - Konstante c
- Beispielregel

$(\text{wieAlt} > 35) \wedge (\text{Geschlecht} = \text{'m'}) \wedge (\text{Autotyp} = \text{'Coupé'}) \rightarrow (\text{Risiko} = \text{'hoch'})$

49

# Klassifikations/Entscheidungsbaum

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
⋮	⋮	⋮	⋮



$(\text{wieAlt} > 35) \wedge (\text{Geschlecht} = \text{'m'}) \wedge (\text{Autotyp} = \text{'Coupé'}) \rightarrow (\text{Risiko} = \text{'hoch'})$

# Wie werden Entscheidungs-/Klassifikationsbäume erstellt

- Trainingsmenge
  - Große Zahl von Datensätzen, die in der Vergangenheit gesammelt wurden
  - Sie dient als Grundlage für die Vorhersage von „neu ankommenden“ Objekten
  - Beispiel: neuer Versicherungskunde wird gemäß dem Verhalten seiner „Artgenossen“ eingestuft
- Rekursives Partitionieren
  - Fange mit einem Attribut an und spalte die Tupelmenge
  - Jede dieser Teilmengen wird rekursiv weiter partitioniert, bis nur noch gleichartige Objekte in der jeweiligen Partition sind

51

# Assoziationsregeln

- Beispielregel
  - Wenn jemand einen PC kauft, dann kauft er/sie meistens auch einen Drucker.
- Konfidenz
  - Dieser Wert legt fest, bei welchem Prozentsatz der Datenmenge, bei der die Voraussetzung (linke Seite) erfüllt ist, die Regel (rechte Seite) auch erfüllt ist.
  - Eine Konfidenz von 80% für unsere Beispielregel sagt aus, dass vier Fünftel der Leute, die einen PC gekauft haben, auch einen Drucker dazu gekauft haben.
- Support
  - Dieser Wert legt fest, wieviele Datensätze überhaupt gefunden wurden, um die Gültigkeit der Regel zu verifizieren.
  - Bei einem Support von 1% wäre also jeder Hundertste Verkauf ein PC zusammen mit einem Drucker.

52

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

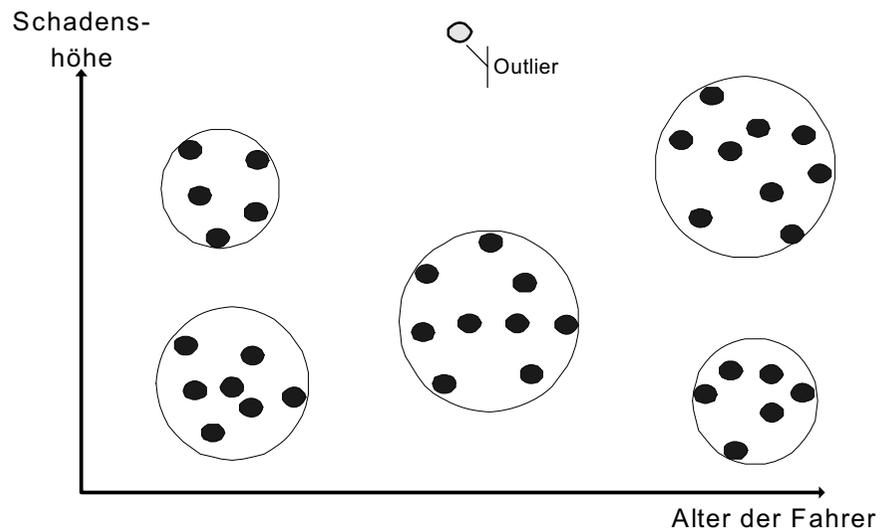
## Verkaufstransaktionen Warenkörbe

### Aufgabe:

- Finde alle Assoziationsregeln  $L \rightarrow R$ 
  - mit einem Support größer als **minsupp** und
  - einer Konfidenz von mindestens **minconf**

53

## Clustering



54