Hasso Plattner Institut

IT Systems Engineering | Universität Potsdam

Datenbanksysteme I

Data Warehouses

13.7.2009

Felix Naumann

Überblick

- Einsatzgebiete
- OLAP versus OLTP
- Multidimensionale Modellierung
- OLAP Operationen
- Relationale Implementierung

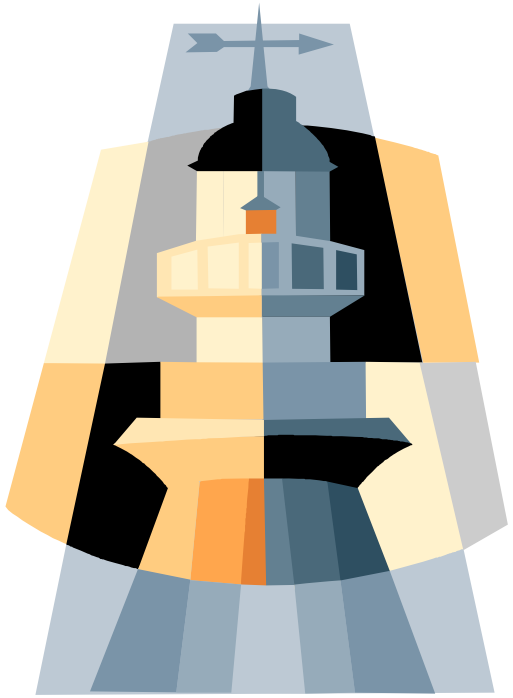

Folien zu DWH: Ulf Leser (HU Berlin)

Beispielszenario

- Ein beliebiges Handelshaus: Spar, Kaufland, ...
- Physikalische Datenverteilung
  - Viele Niederlassungen (bis zu mehrere tausend)
  - Noch mehr Registerkassen
- Aber: Zentrale Planung, Beschaffung, Verteilung
  - Was wird wo und wie oft verkauft?
  - Was muss wann wohin geliefert werden?
    - Bedenke: Verderbliche Waren
- ... nur möglich, wenn
  - Zentrale Übersicht über Umsätze
  - Integration mit Lieferanten / Produktdaten

Handels - DWH

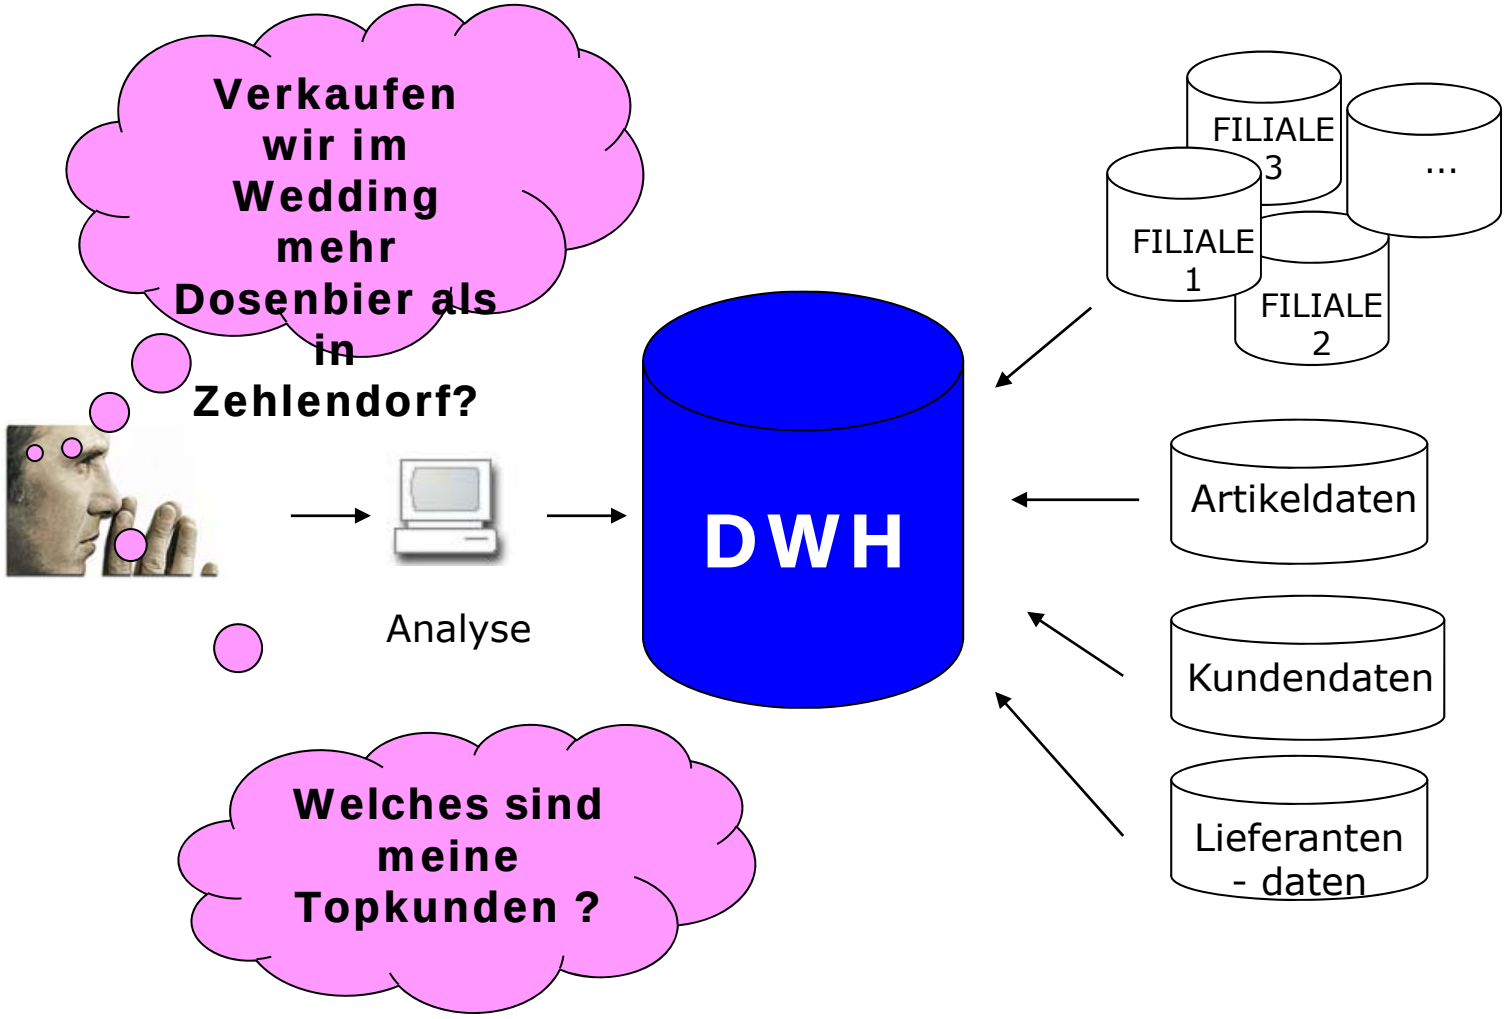
Verkaufen wir im Wedding mehr Dosenbier als in Zehlendorf?
Analyse
DWH
FILIALE 3
...
FILIALE 1
FILIALE 2
Artikeldaten
Kundendaten
Lieferanten - daten
Welches sind meine Topkunden ?

DWH Datenquellen

- Lieferantendatenbanken
  - Produktinformationen: Packungsgrößen, Farben, ...
  - Lieferbedingungen, Rabatte, Lieferzeiten, ...
- Personaldatenbank
  - Zuordnung Kassenbuchung auf Mitarbeiter
  - Stundenabrechnung, Prämien
- Kundendatenbank
  - Kundenklassen: Premium, normal, soziale Brennpunkte, ...
  - Persönliche Vorlieben & Historie
    - Kundenkarten (Safeway, …)
- Weitere Vertriebswege
  - Internet, Katalogbestellung, Verkaufsclubs, ...

Definition DWH

A DWH is a subject-oriented, integrated, non-volatile, and time-variant collection of data in support of management's decisions. [Inm96]

- Subject-oriented: Verkäufe, Personen, Produkte, etc.
- Integrated: Erstellt aus vielen Quellen
- Non-Volatile: Hält Daten unverändert über die Zeit
- Time-Variant: Vergleich von Daten über die Zeit

Erfolg von DWH

- Top-Thema seit Mitte der 90er Jahre
  - Industrie schneller als Forschung
- Voraussetzungen
  - Extreme Verbilligung von Plattenspeicherplatz
  - Relationale Modellierung: Anwendungsneutral
  - Graphische Benutzeroberflächen und Terminals
  - IT in allen Unternehmensbereichen (SAP R/3)
  - Vernetzung und DB Standardisierung (SQL)
- Aber
  - Vision der vollständigen Integration scheitert (immer wieder aufs neue)
  - Soziale versus technische Aspekte

Datenbank

2005 TopTen Award Winners

Winter Corporation recognizes these organizations and their vendors for their achievements in the 2005 TopTen Program.

List of all the winners Frequently Asked Questions

Pick a TopTen Award Category:

Metric: Norm. Data Volume **Platform:** All Environments **Usage:** DW

Display

Norm. Data Volume, All Environments, DW *

Company/Organization	Norm. Data Volume (GB)	DBMS	Platform	Architecture	DBMS Vendor	System Vendor	Storage Vendor
AT&T	330,644	Daytona	UNIX	Federated/SMP	AT&T	HP	HP
AT&T	93,468	Daytona	UNIX	Federated/SMP	AT&T	Sun	Sun
Amazon.com	28,184	Oracle RAC	Linux	Centralized/Cluster	Oracle	HP	HP
Nielsen Media Research	17,969	Sybase IQ	UNIX	Centralized/SMP	Sybase	Sun	EMC
Yahoo!	17,014	Oracle	UNIX	Centralized/SMP	Oracle	Fujitsu Siemens	EMC
Amazon.com	14,849	Oracle RAC	Linux	Centralized/Cluster	Oracle	HP	HP
UBS AG	14,177	Oracle	UNIX	Centralized/SMP	Oracle	Sun	EMC
China Telecom Corporation Co.,Ltd. GuangZhou Research Institute	13,241	Sybase IQ	UNIX	Centralized/SMP	Sybase	Sun	Sun
USDA	11,876	SQL Server	Windows	Centralized/SMP	Microsoft	HP	EMC
Reliance Infocomm Ltd	11,500	Oracle	UNIX	Centralized/SMP	Oracle	Sun	EMC
Cellcom	10,345	Oracle RAC	UNIX	Centralized/Cluster	Oracle	HP	EMC

Normalized Data Volume estimates of the total volume of data managed by the DBMS in GB.

- http://www.wintercorp.com/VLDB/2005_TopTen_Survey/TopTenWinners_2005.asp

2005 TopTen Award Winners

Winter Corporation recognizes these organizations and their vendors for their achievements in the 2005 TopTen Program.

List of all the winners Frequently Asked Questions

Pick a TopTen Award Category:

Metric: Peak Workload **Platform:** All Environments **Usage:** DW

Display

Number of Rows, All Environments, DW *

Company/Organization	Number of Rows (Millions)	DBMS	Platform	Architecture	DBMS Vendor	System Vendor	Storage Vendor
Sprint	2,847,553	NonStop SQL	NonStop OS	Centralized/Cluster	HP	HP	HP
AT&T	1,882,638	Daytona	UNIX	Federated/SMP	AT&T	HP	HP
AT&T	533,723	Daytona	UNIX	Federated/SMP	AT&T	Sun	Sun
Nielsen Media Research	502,407	Sybase IQ	UNIX	Centralized/SMP	Sybase	Sun	EMC
Yahoo!	385,318	Oracle	UNIX	Centralized/SMP	Oracle	Fujitsu Siemens	EMC
Turkcell	181,083	Oracle	UNIX	Centralized/SMP	Oracle	Sun	Hitachi
Anonymous	167,173	Sybase IQ	UNIX	Centralized/SMP	Sybase	Sun	EMC
KT IT-Group	136,641	DB2	UNIX	Centralized/Cluster	IBM	IBM	Hitachi
Anonymous	134,880	Sybase IQ	UNIX	Centralized/SMP	Sybase	HP	HP
China Telecom Corporation Co.,Ltd. GuangZhou Research Institute	133,924	Sybase IQ	UNIX	Centralized/SMP	Sybase	Sun	Sun

Number of Rows is the total number of rows in all tables in the database, in millions.

- http

Überblick

- Einsatzgebiete
- OLAP versus OLTP
- Multidimensionale Modellierung
- OLAP Operationen
- Relationale Implementierung

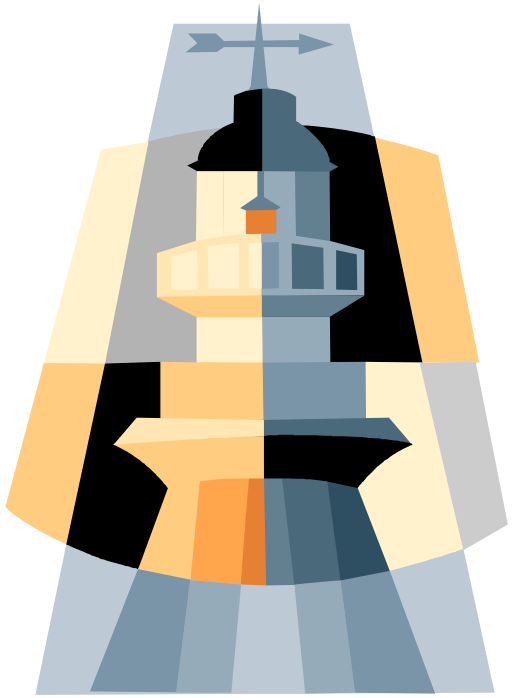

Folien zu DWH: Ulf Leser (HU Berlin)

OLTP Beispiel

Login

```
SELECT pw FROM kunde WHERE login=„...“
UPDATE kunde SET last_acc=date, tries=0 WHERE
COMMIT
```

Willkommen

```
SELECT k_id, name FROM kunde WHERE login=„...“
SELECT last_pur FROM purchase WHERE k_id=...
COMMIT
```

Bestellung

```
SELECT av_qty FROM stock WHERE p_id=...
UPDATE stock SET av_qty=av_qty-1 where ...
INSERT INTO shop_cart VALUES( o_id, k_id, ...
COMMIT
```

Best. löschen

```
DELETE FROM shop_cart WHERE o_id=...
UPDATE stock SET av_qty=av_qty+1 where ...
COMMIT
```

OLAP Beispiele

- Welche Produkte hatten im letzten Jahr im Bereich Potsdam einen Umsatzrückgang um mehr als 10%?
  - Welche Produktgruppen sind davon betroffen?
  - Welche Lieferanten haben diese Produkte?
- Welche Kunden haben über die letzten 5 Jahre eine Bestellung über 50 Euro innerhalb von 4 Wochen nach einem persönlichen Anschreiben aufgegeben?
  - Wie hoch waren die Bestellungen im Durchschnitt?
  - Wie hoch waren die Bestellungen im Vergleich zu den durchschnittlichen Bestellungen des jeweiligen Kunden in einem vergleichbaren Zeitraum?
  - Lohnen sich Mailing-Aktionen?
- Haben solche Zweigstellen einen höheren Umsatz, die gemeinsam gekaufte Produkte nebeneinander platzieren?
  - Welche Produkte werden überhaupt zusammen gekauft – und wo?

OLAP versus OLTP

	OLTP	OLAP
Typische Operationen	Insert, Update, Delete, Select	Select, Bulk-Inserts
Transaktionen	viele, kurze	Lange Lesetransaktionen
Typische Anfragen	Einfache Anfragen, Primärschlüsselzugriff, Schnelle Abfolgen von Selects/inserts/updates/deletes	Komplexe Anfragen: Aggregate, Gruppierung, Subselects, etc. Bereichsanfragen über mehrere Attribute
Daten pro Operation	Wenige Tupel	Mega-/ Gigabyte
Datenmenge in DB	Gigabyte	Terabyte
Eigenschaften der Daten	Rohdaten, häufige Änderungen	Abgeleitete Daten, historisch & stabil
Erwartete Antwortzeiten	Echtzeit bis wenige Sek.	Minuten
Modellierung	Anwendungsorientiert	Themenorientiert
Typische Benutzer	Sachbearbeiter, Kunde	Management

DWH Architektur & Komponenten

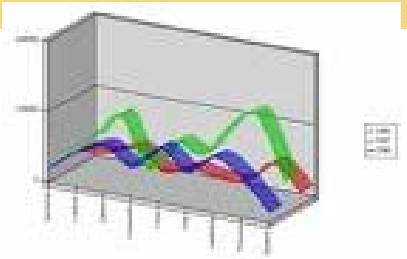

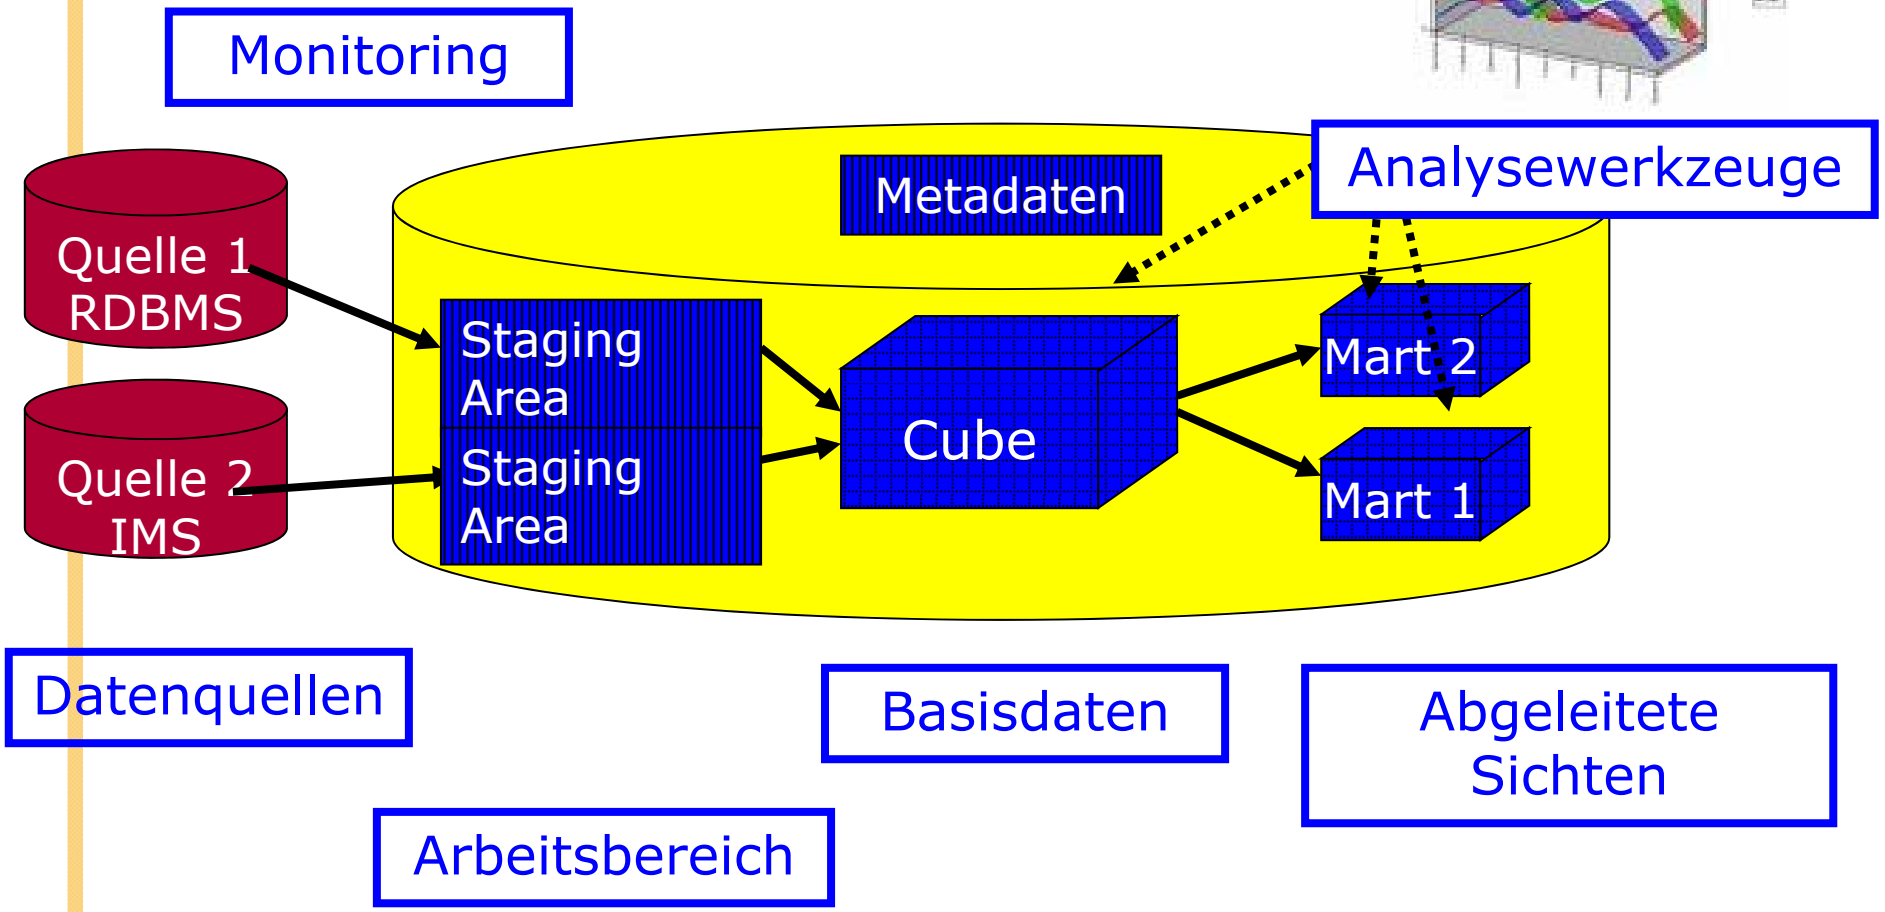

Alternativen

Physikalische Aufteilung variabel

- Data Marts auf eigenen Rechnern (Laptop)
- Staging Area auf eigenen Servern
- Metadaten auf eigenem Server (Repository)

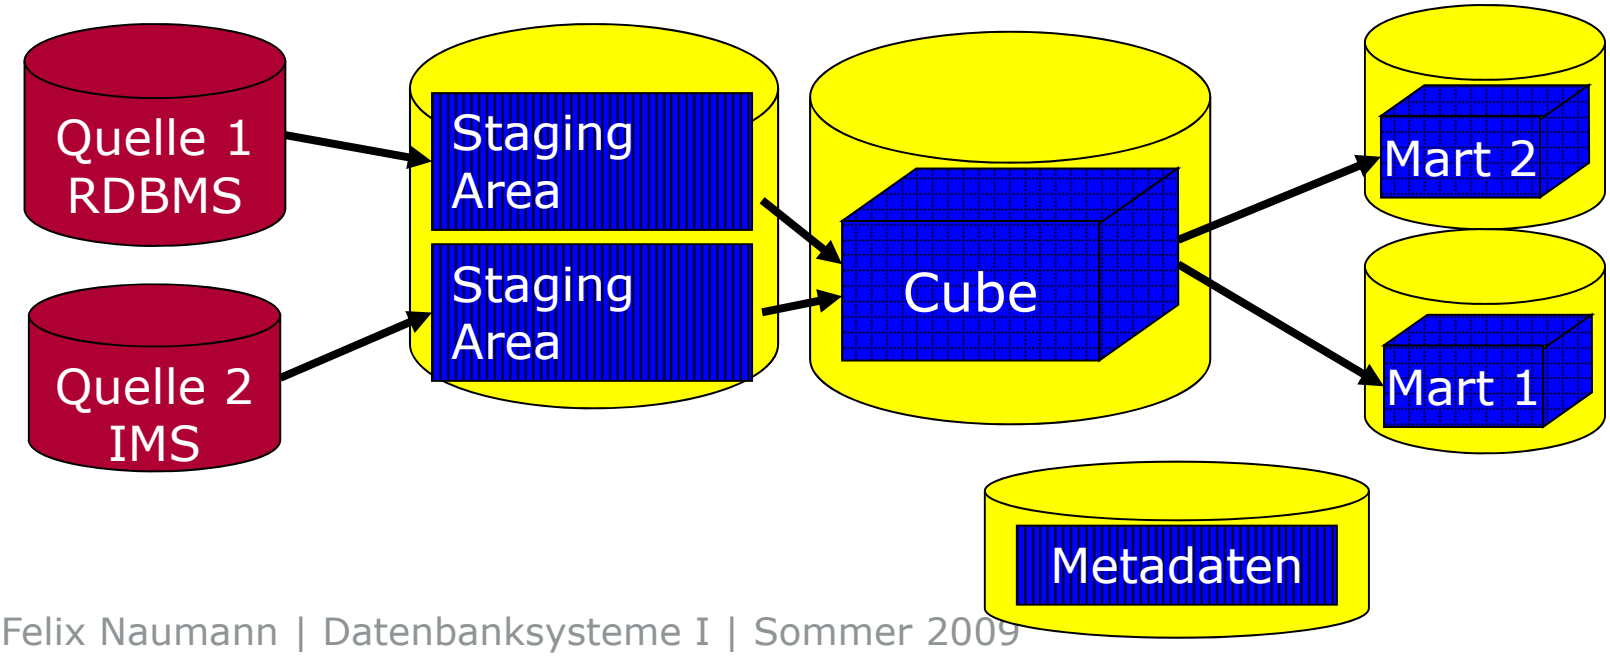

Arbeitsbereich

- Staging Area
  - Temporärer Speicher
  - Quellnahes Schema
- Motivation
  - ETL Arbeitsschritte effizienter implementierbar
    - Mengenoperationen, SQL
  - Zugriff auf Basisdatenbank möglich (Lookups)
  - Vergleich zwischen Datenquellen möglich
  - Filterfunktion: Nur einwandfreie Daten in Basisdatenbank übernehmen

Basisdatenbank

- Zentrale Komponente des DWH
  - Begriff „DWH“ meint oft nur die Basisdatenbank.
- Speichert Daten in feinster Auflösung
  - Einzelne Verkäufe
  - Einzelne Bons
- Historische Daten
- Große Datenmengen
  - Spezielle Modellierung
  - Spezielle Optimierungsstrategien

Überblick

- Einsatzgebiete
- OLAP versus OLTP
- Multidimensionale Modellierung
- OLAP Operationen
- Relationale Implementierung

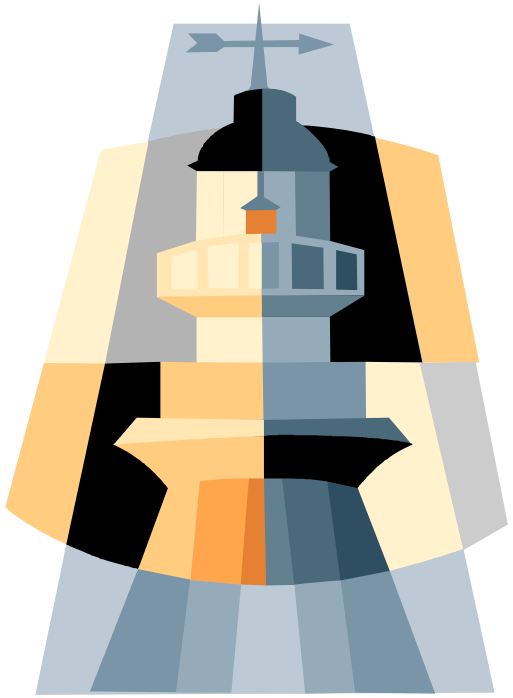

Folien zu DWH: Ulf Leser (HU Berlin)

Beispiel: Normalisiertes Schema

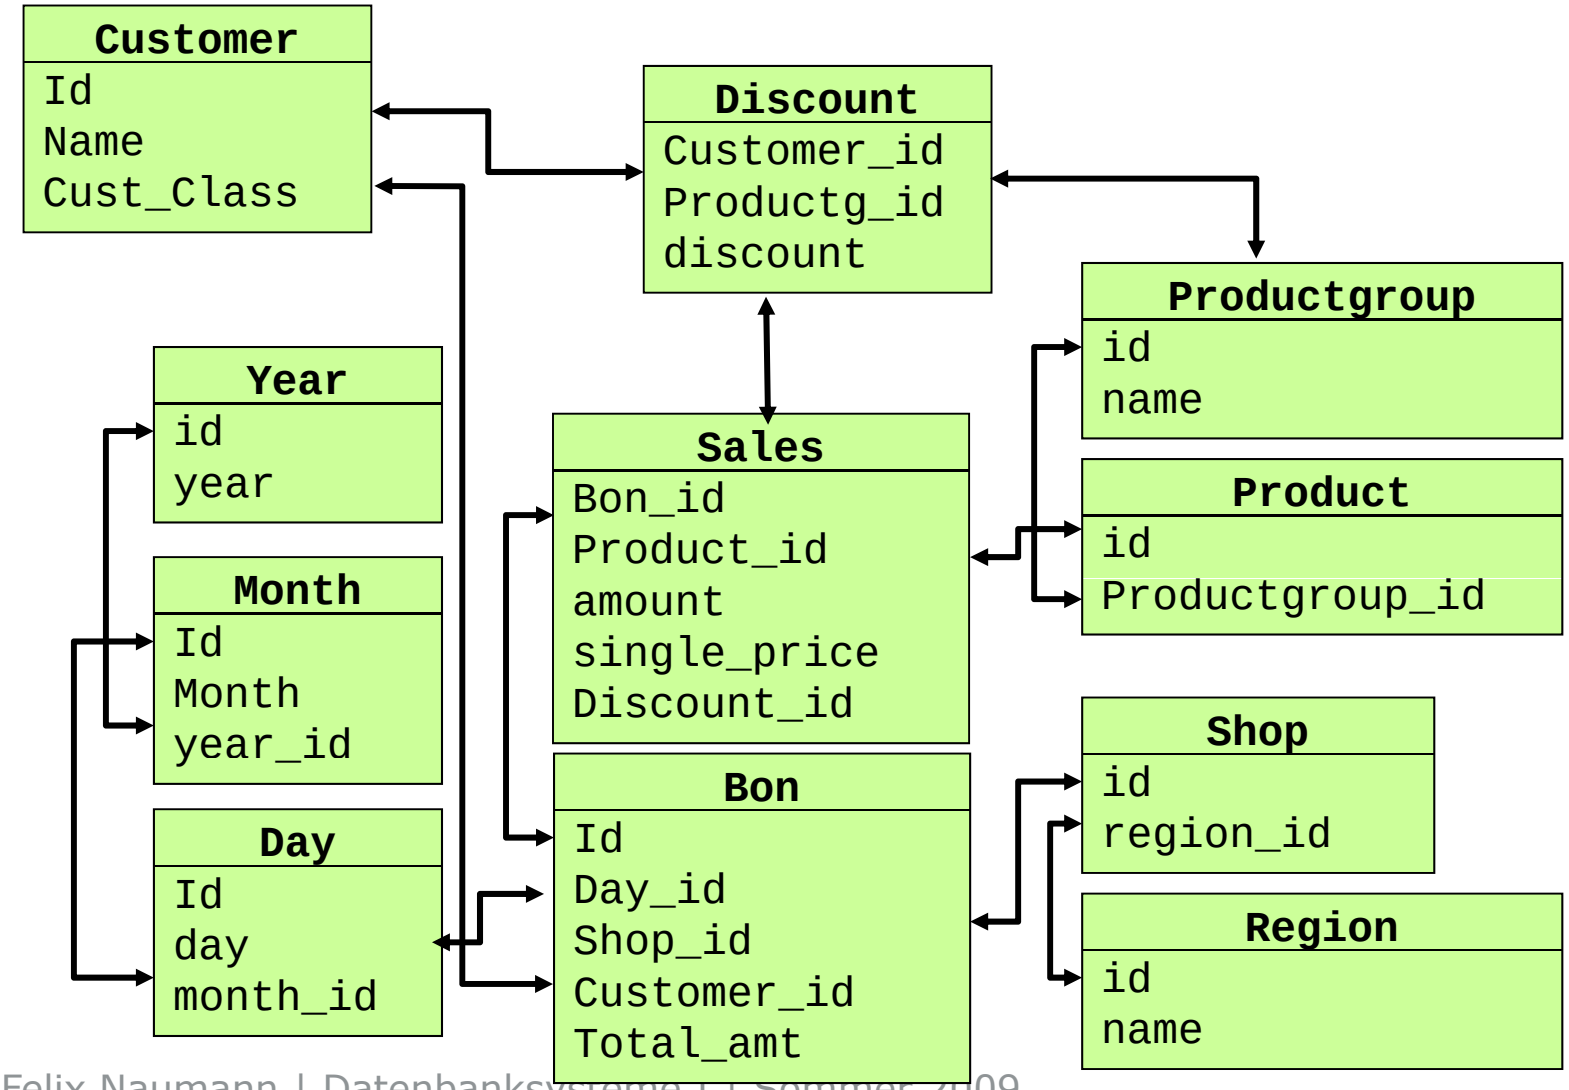

Multidimensionales Schema

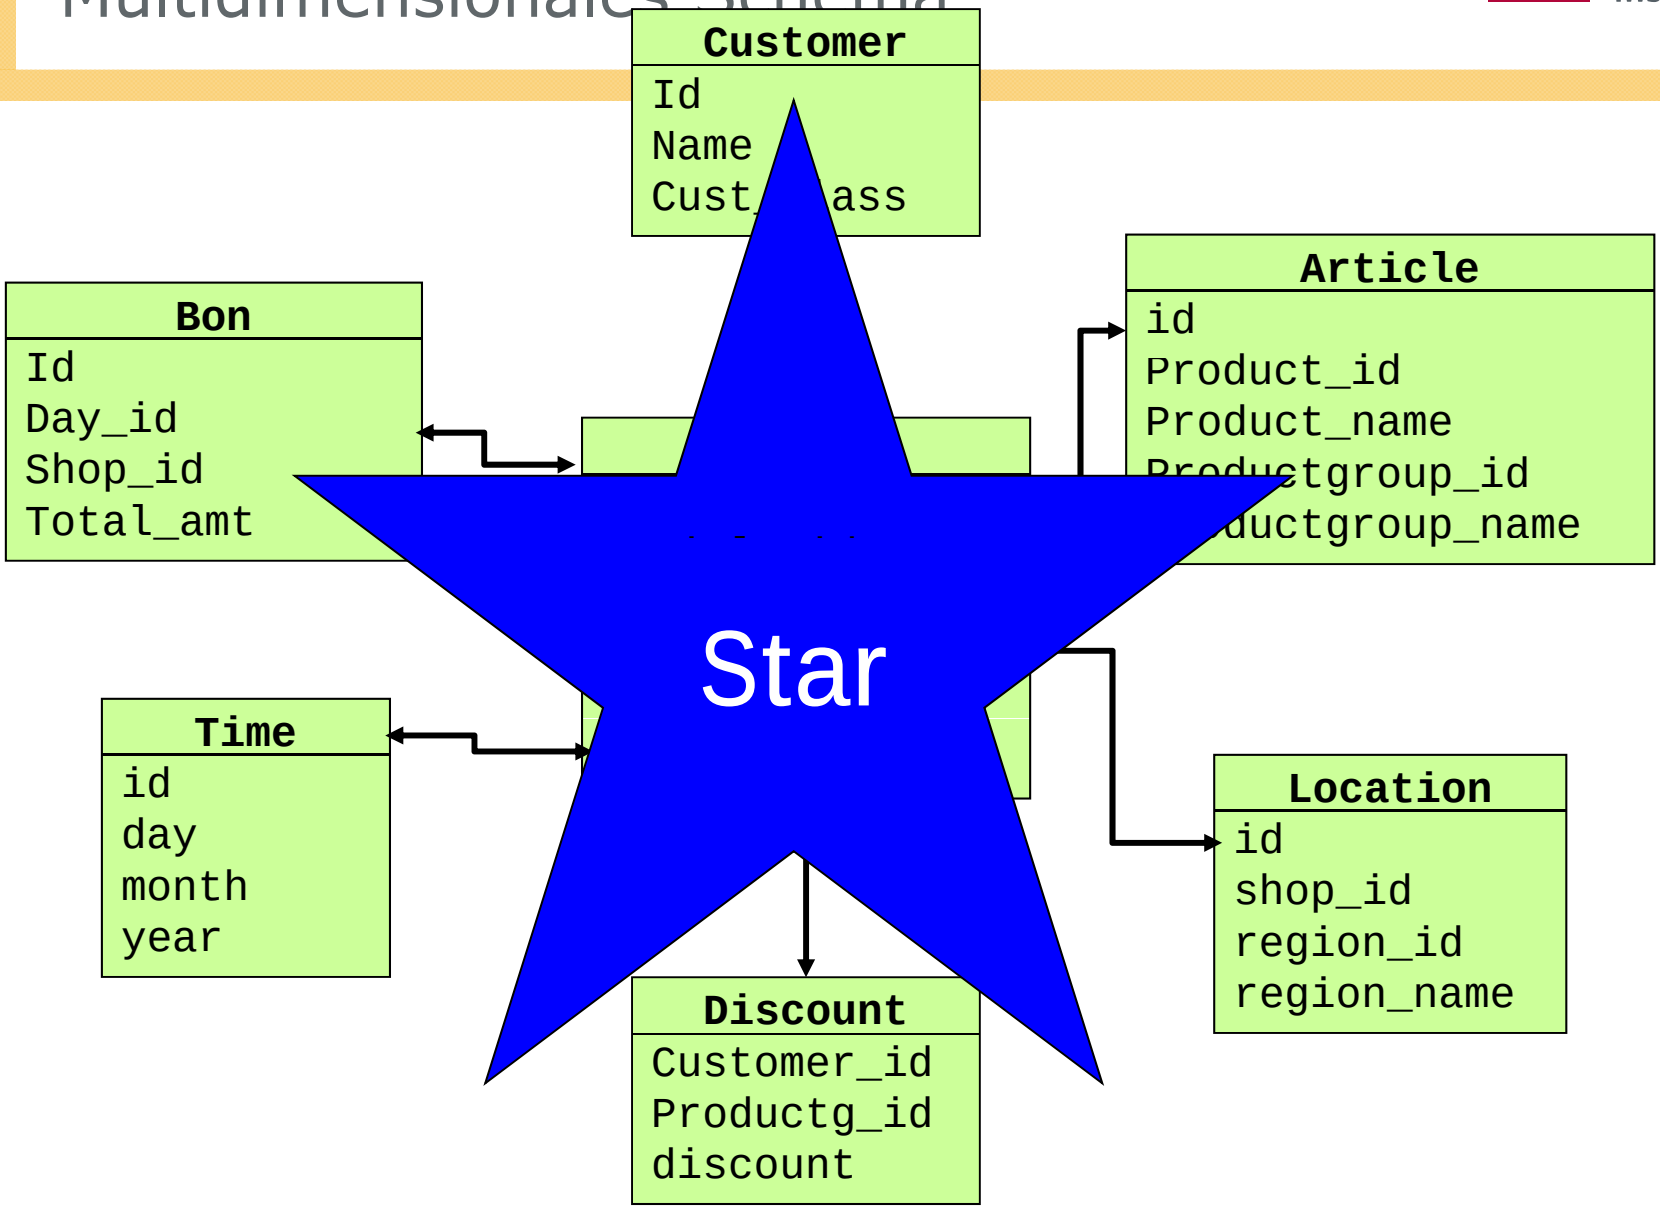

Begriffe

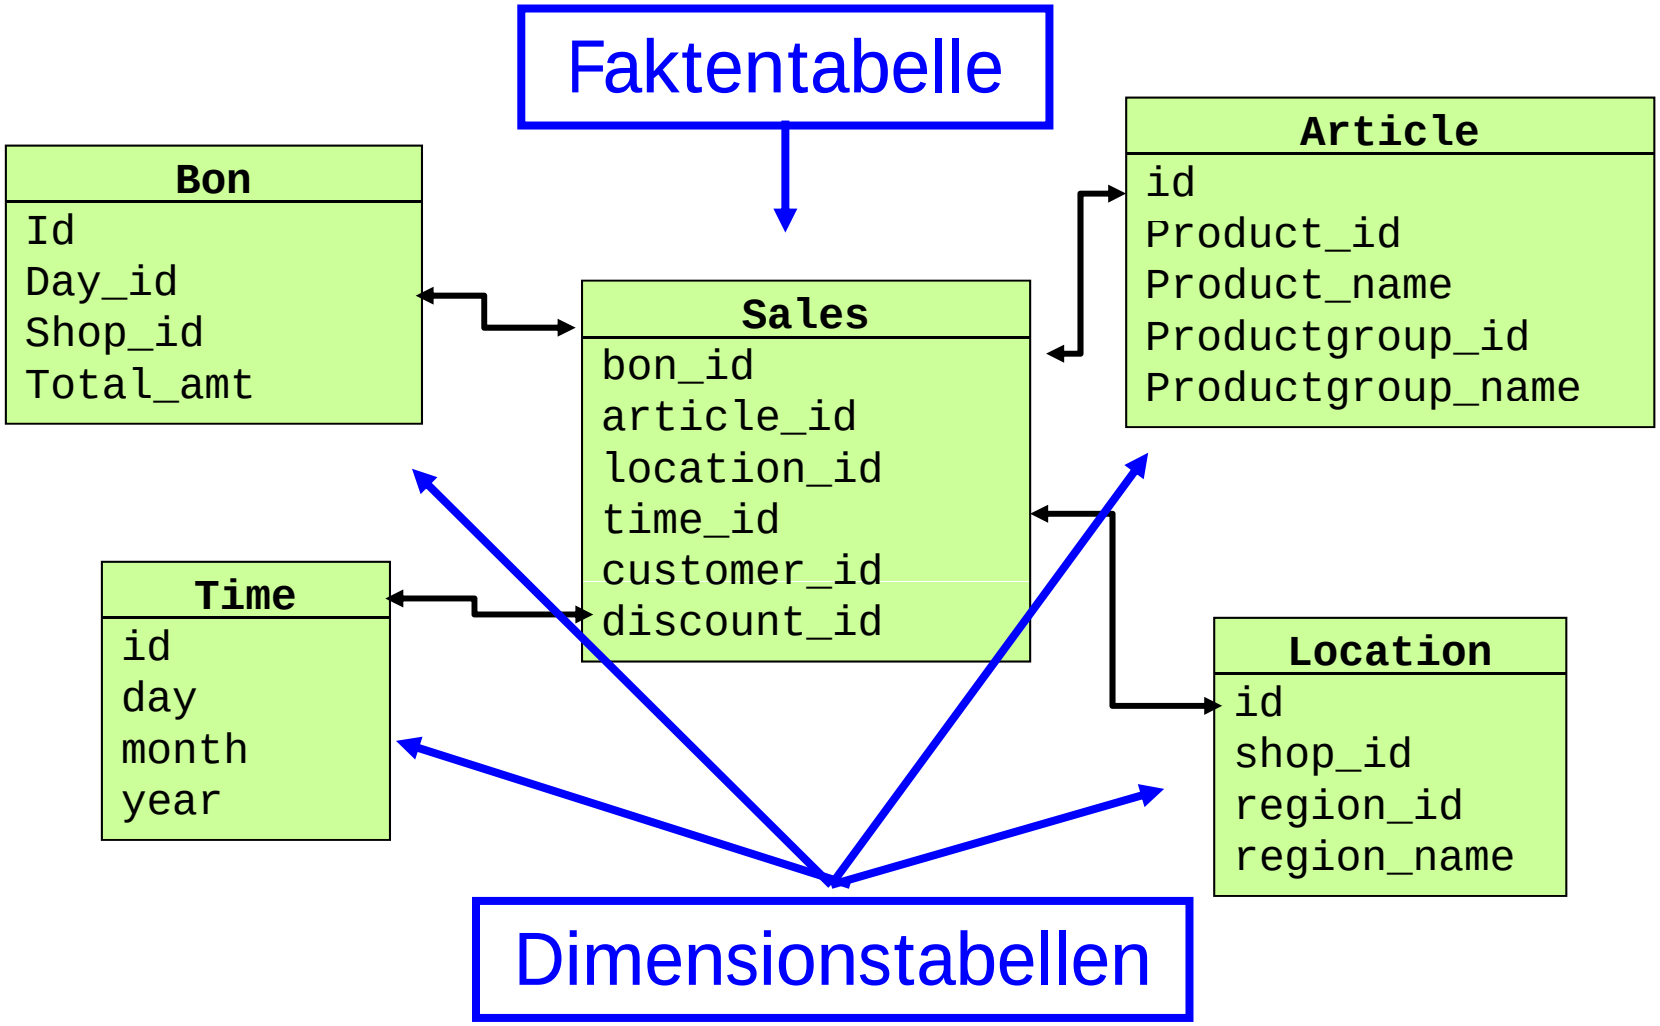
Faktentabelle
Bon
Id
Day_id
Shop_id
Total_amt
Sales
bon_id
article_id
location_id
time_id
customer_id
discount_id
Article
id
Product_id
Product_name
Productgroup_id
Productgroup_name
Time
id
day
month
year
Location
id
shop_id
region_id
region_name
Dimensionstabellen

Cube

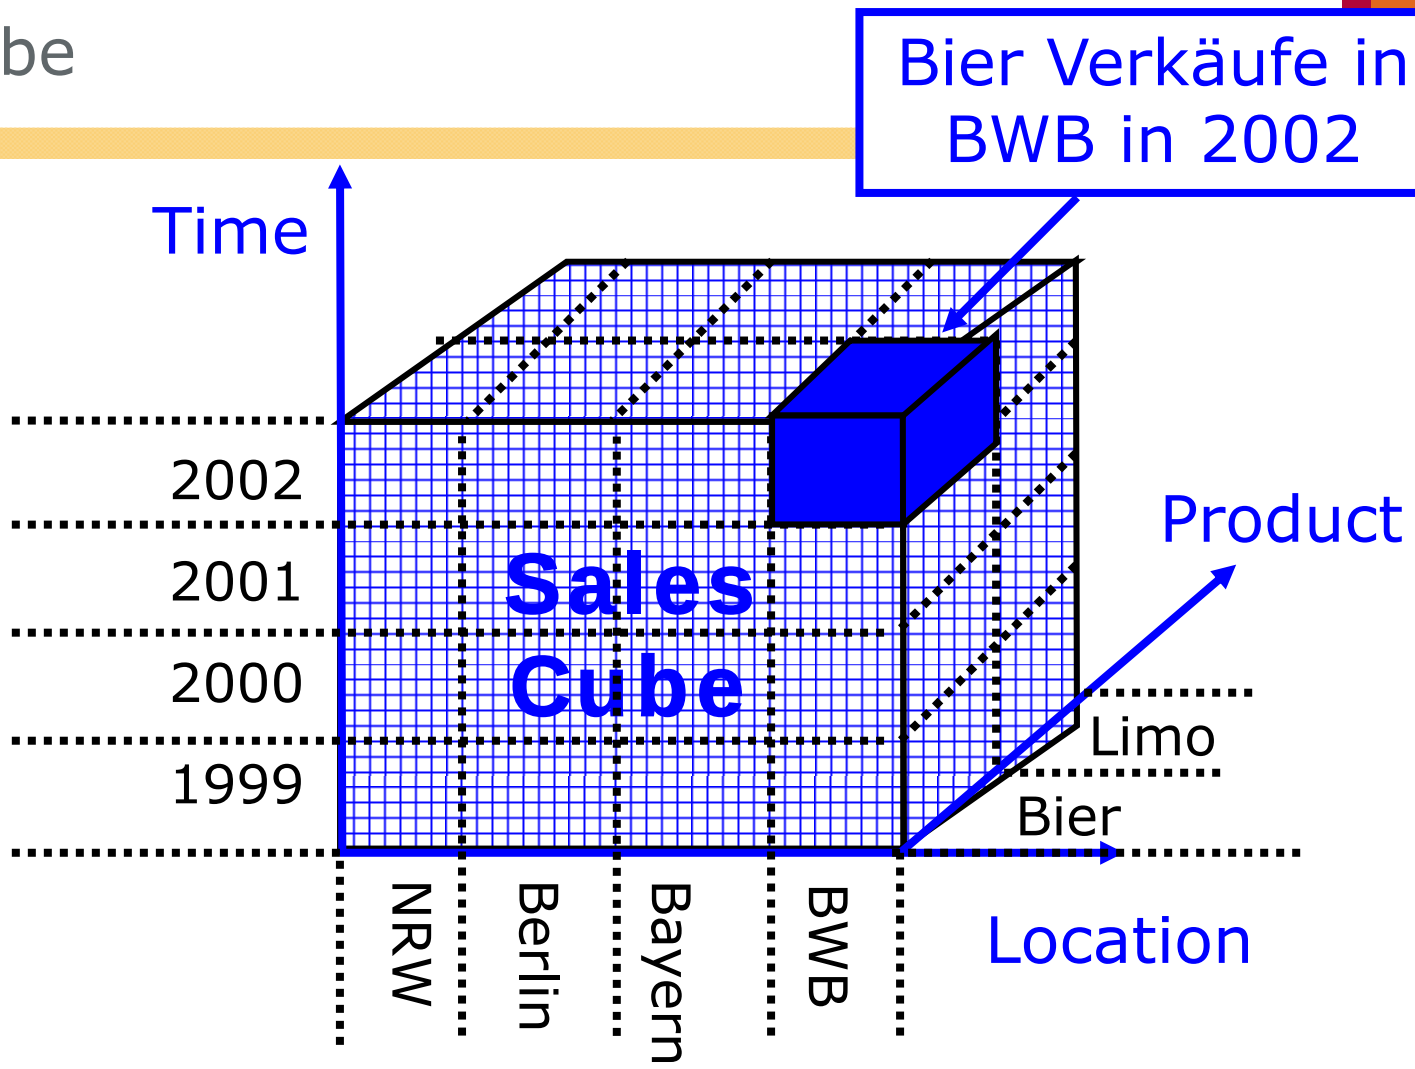

Cube -> Hypercube: Bon / Lieferant / Kunde / ...

Dimensionen

- Eindeutige Strukturierung des Datenraums
- Jede Dimension hat ein Schema
  - Tag, Woche, Jahr
  - Landkreis, Land, Staat
  - Produkt, Produktgruppe, Produktklasse, Produktfamilie
- ... und Wertebereiche
  - (1, 2, 3, ..., 31), (1, ... 52), (1900, ..., 2003)
  - (...), (Berlin, NRW, Department-1, ...), (BRD, F, ...)

Überblick

- Einsatzgebiete
- OLAP versus OLTP
- Multidimensionale Modellierung
- OLAP Operationen
- Relationale Implementierung

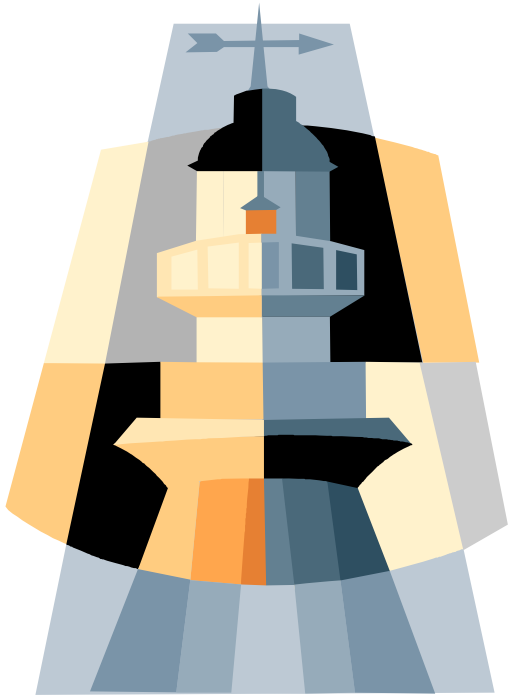

Folien zu DWH: Ulf Leser (HU Berlin)

Beispiel: Aggregation (Roll-Up)

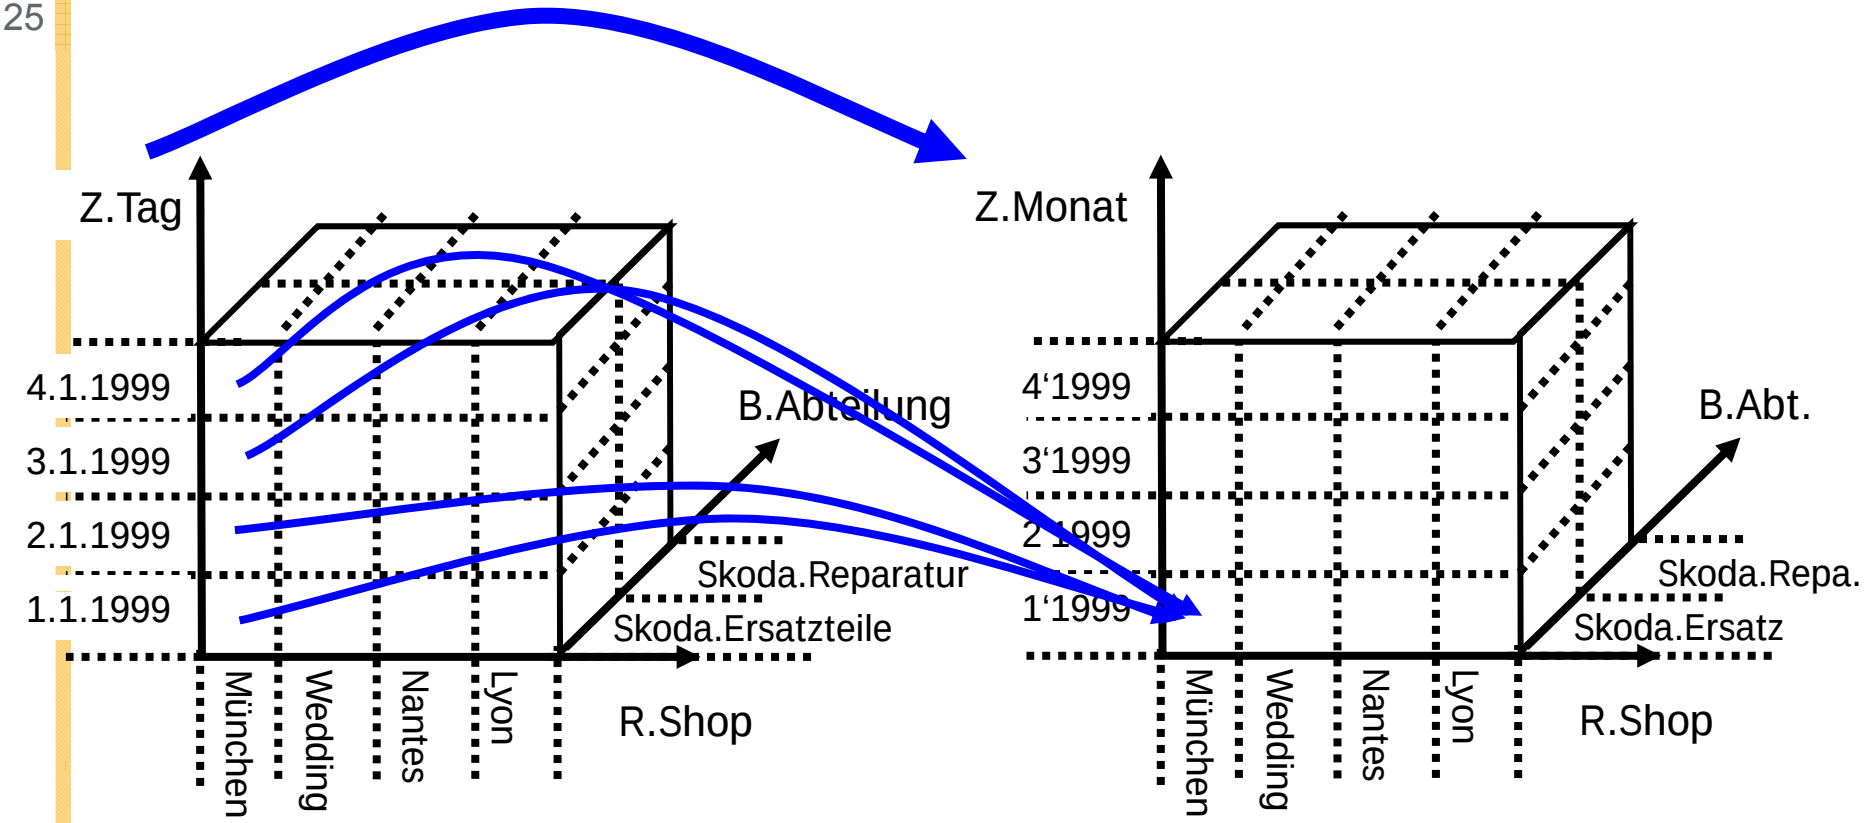

Beispiel: Verfeinerung (Drill-Down)

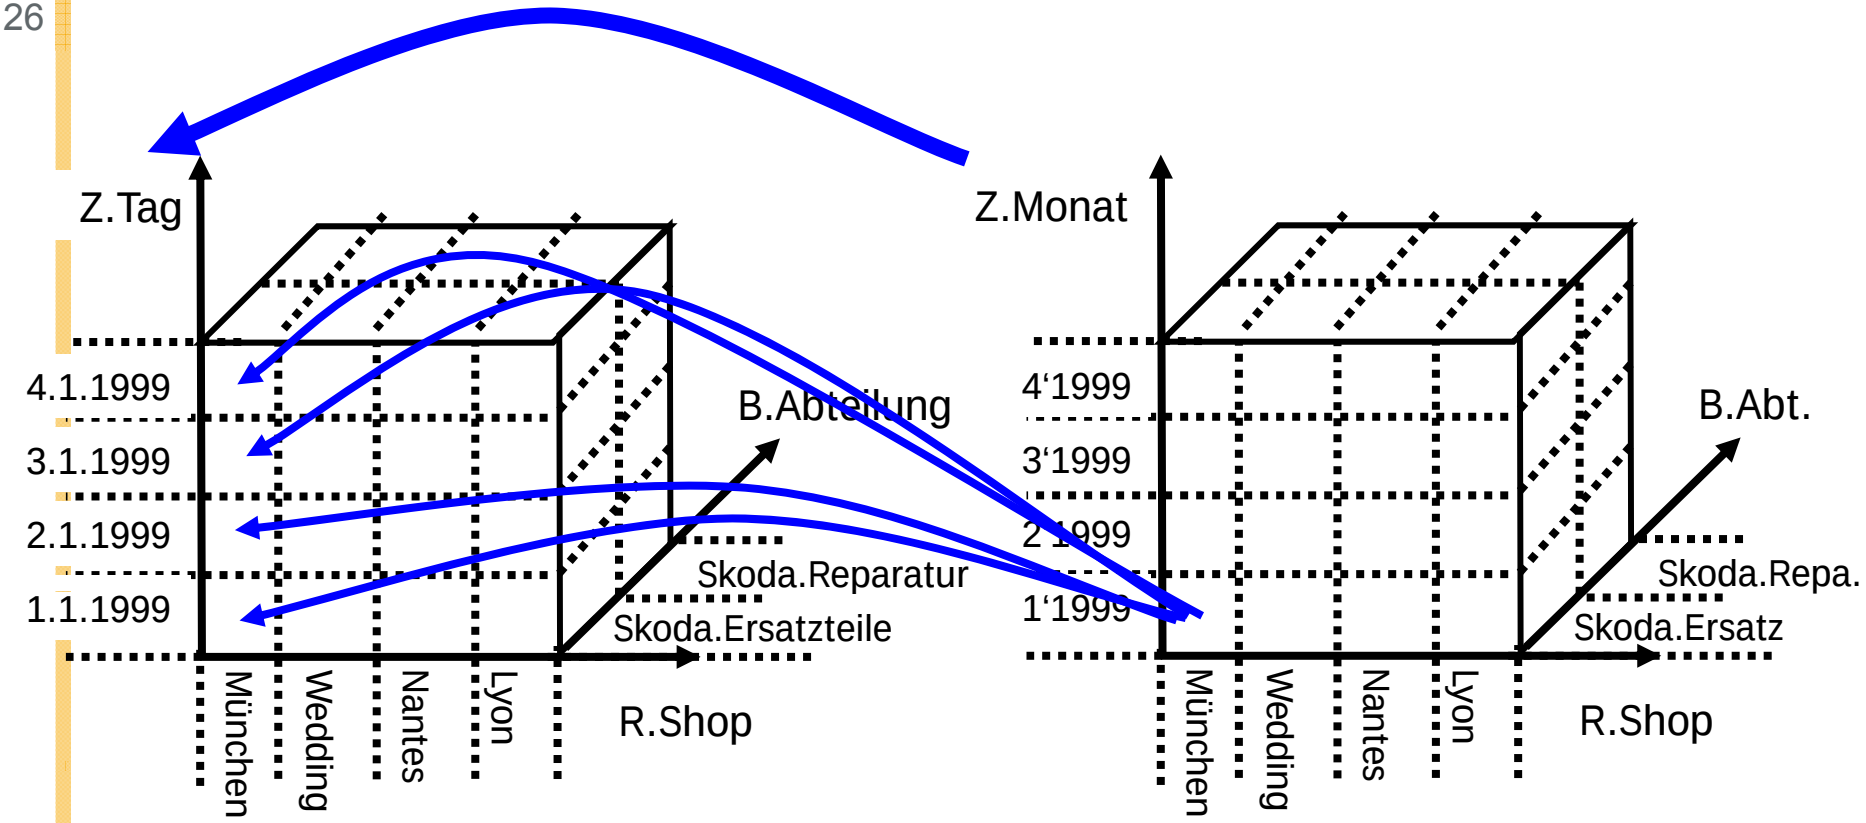

Aggregation bis TOP

Summe Umsatz pro Tag und Abteilungen über alle Shops

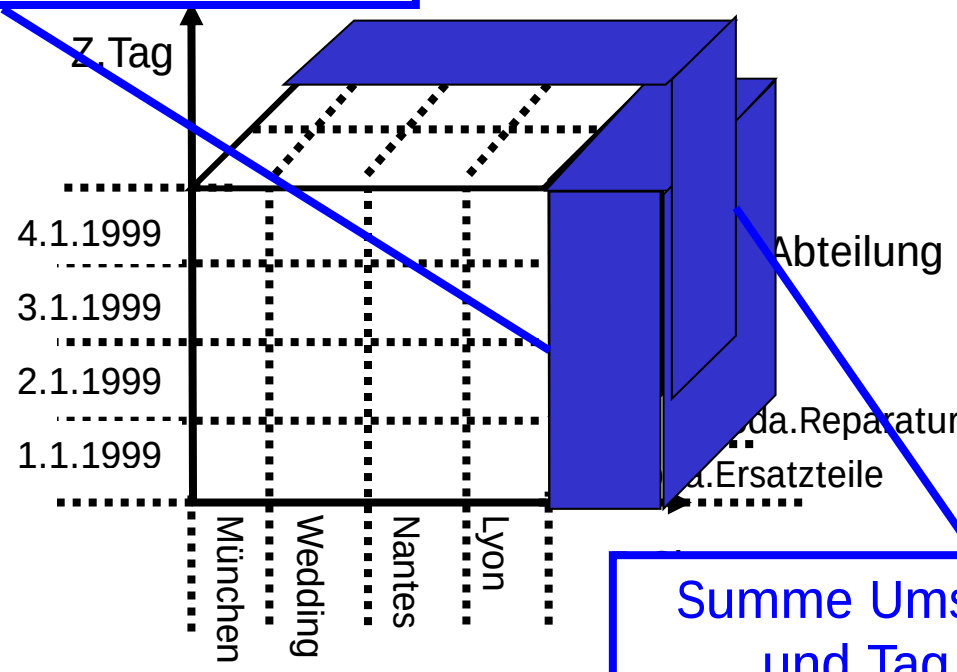

Summe Umsatz pro Shop und Tag, über alle Abteilungen

... in mehreren Dimensionen

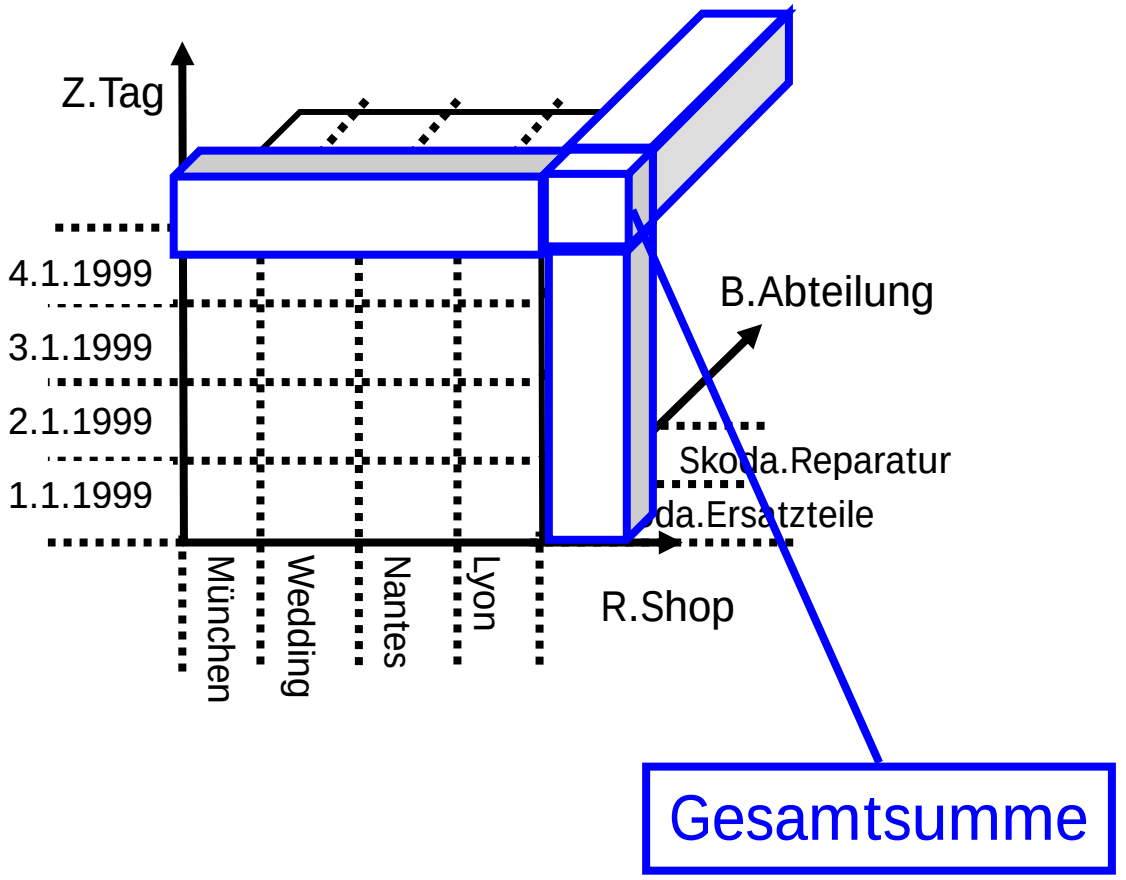

Selektion einer Scheibe (*Slicing*)

Verkäufe von Peugeot pro Jahr und Kontinent

Verkäufe in Asien pro Jahr und Marke

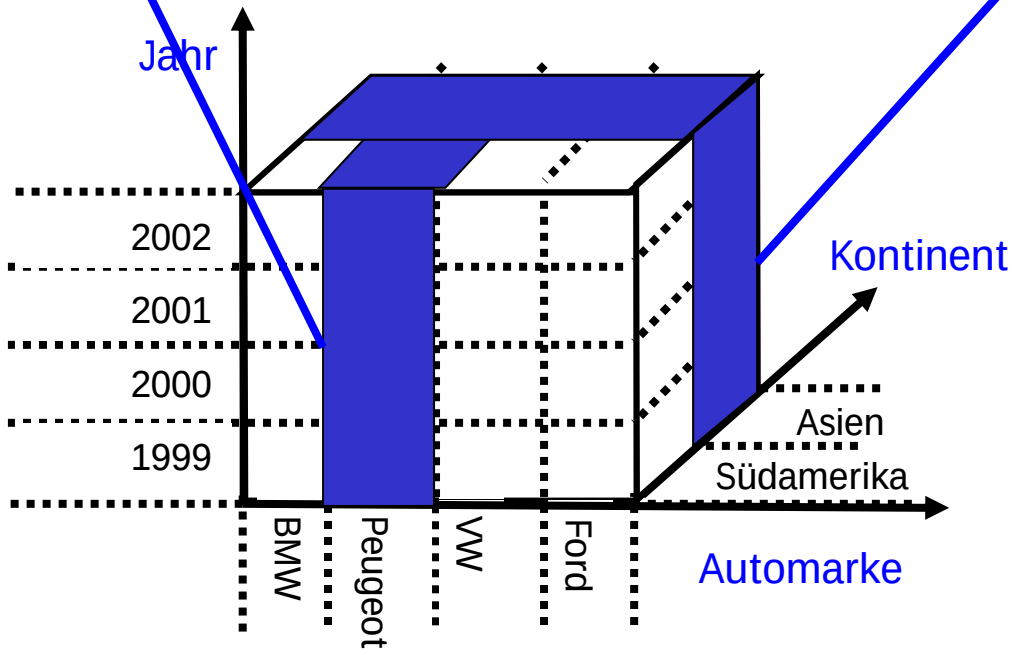

Auswahl von Unterwürfeln (*Dicing*)

Verkäufe von (Peugeot, VW) in (2000, 2001) pro Kontinent

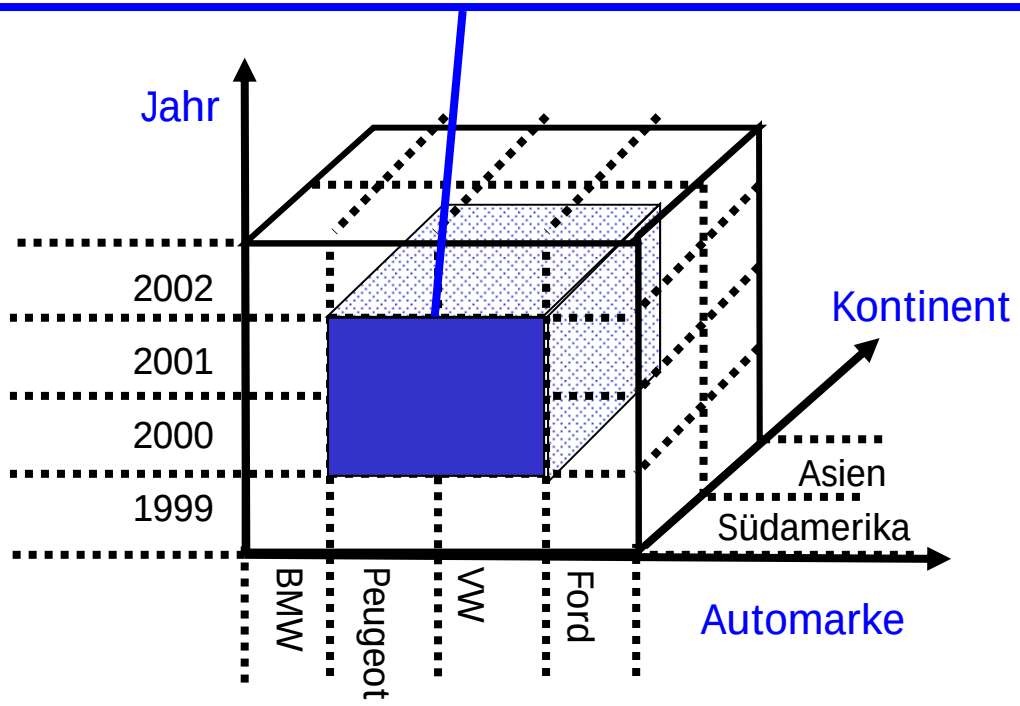

Überblick

- Einsatzgebiete
- OLAP versus OLTP
- Multidimensionale Modellierung
- OLAP Operationen
- Relationale Implementierung

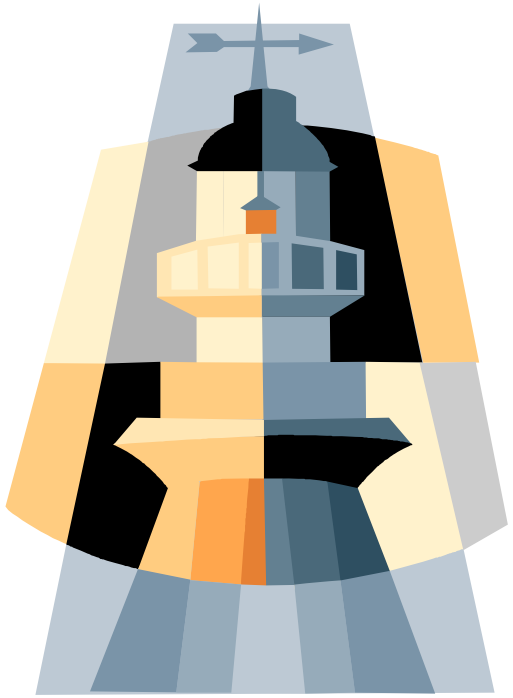

Folien zu DWH: Ulf Leser (HU Berlin)

Variante 1 - Snowflake

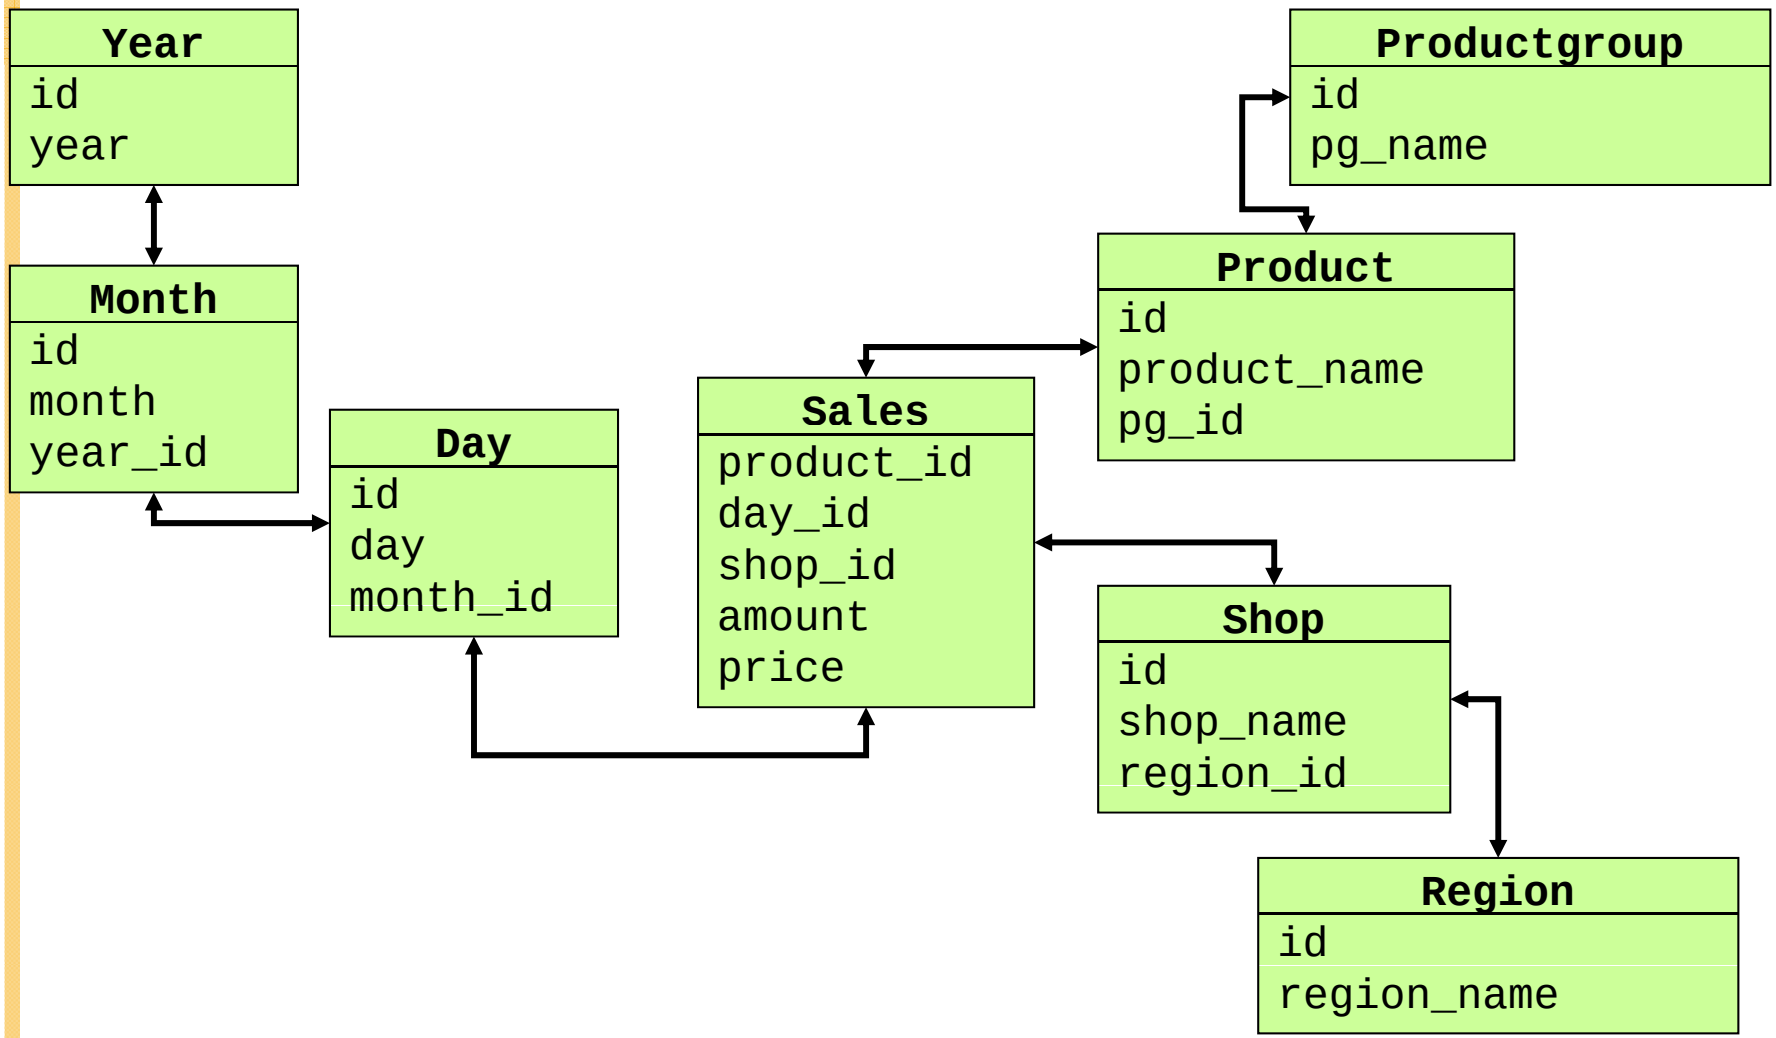

Variante 2: Star Schema

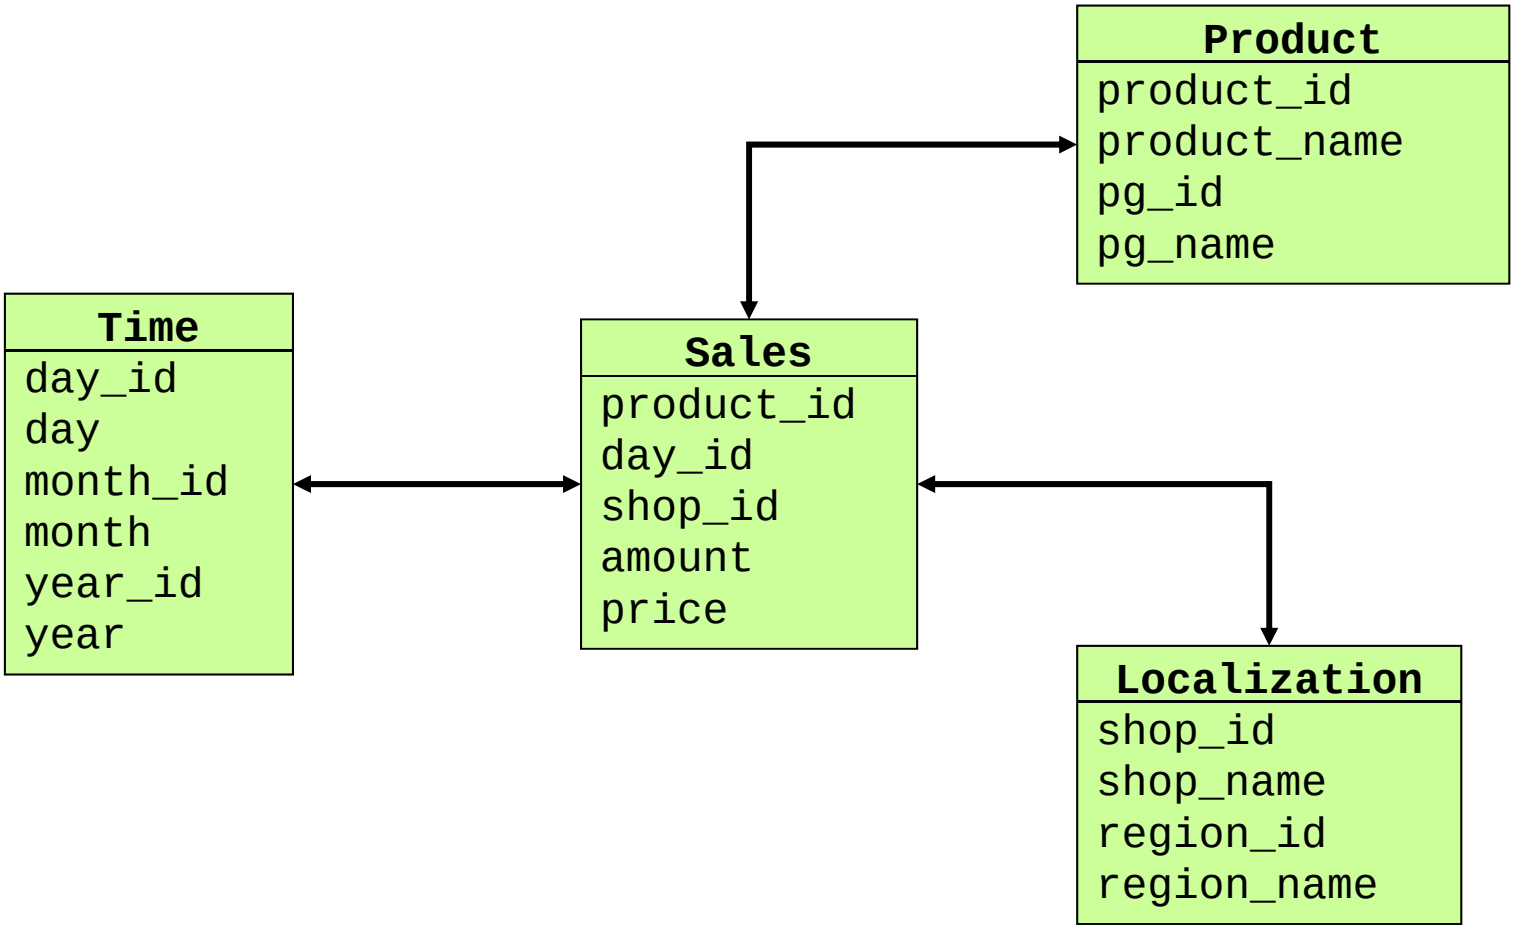

Variante 3: Fullfact

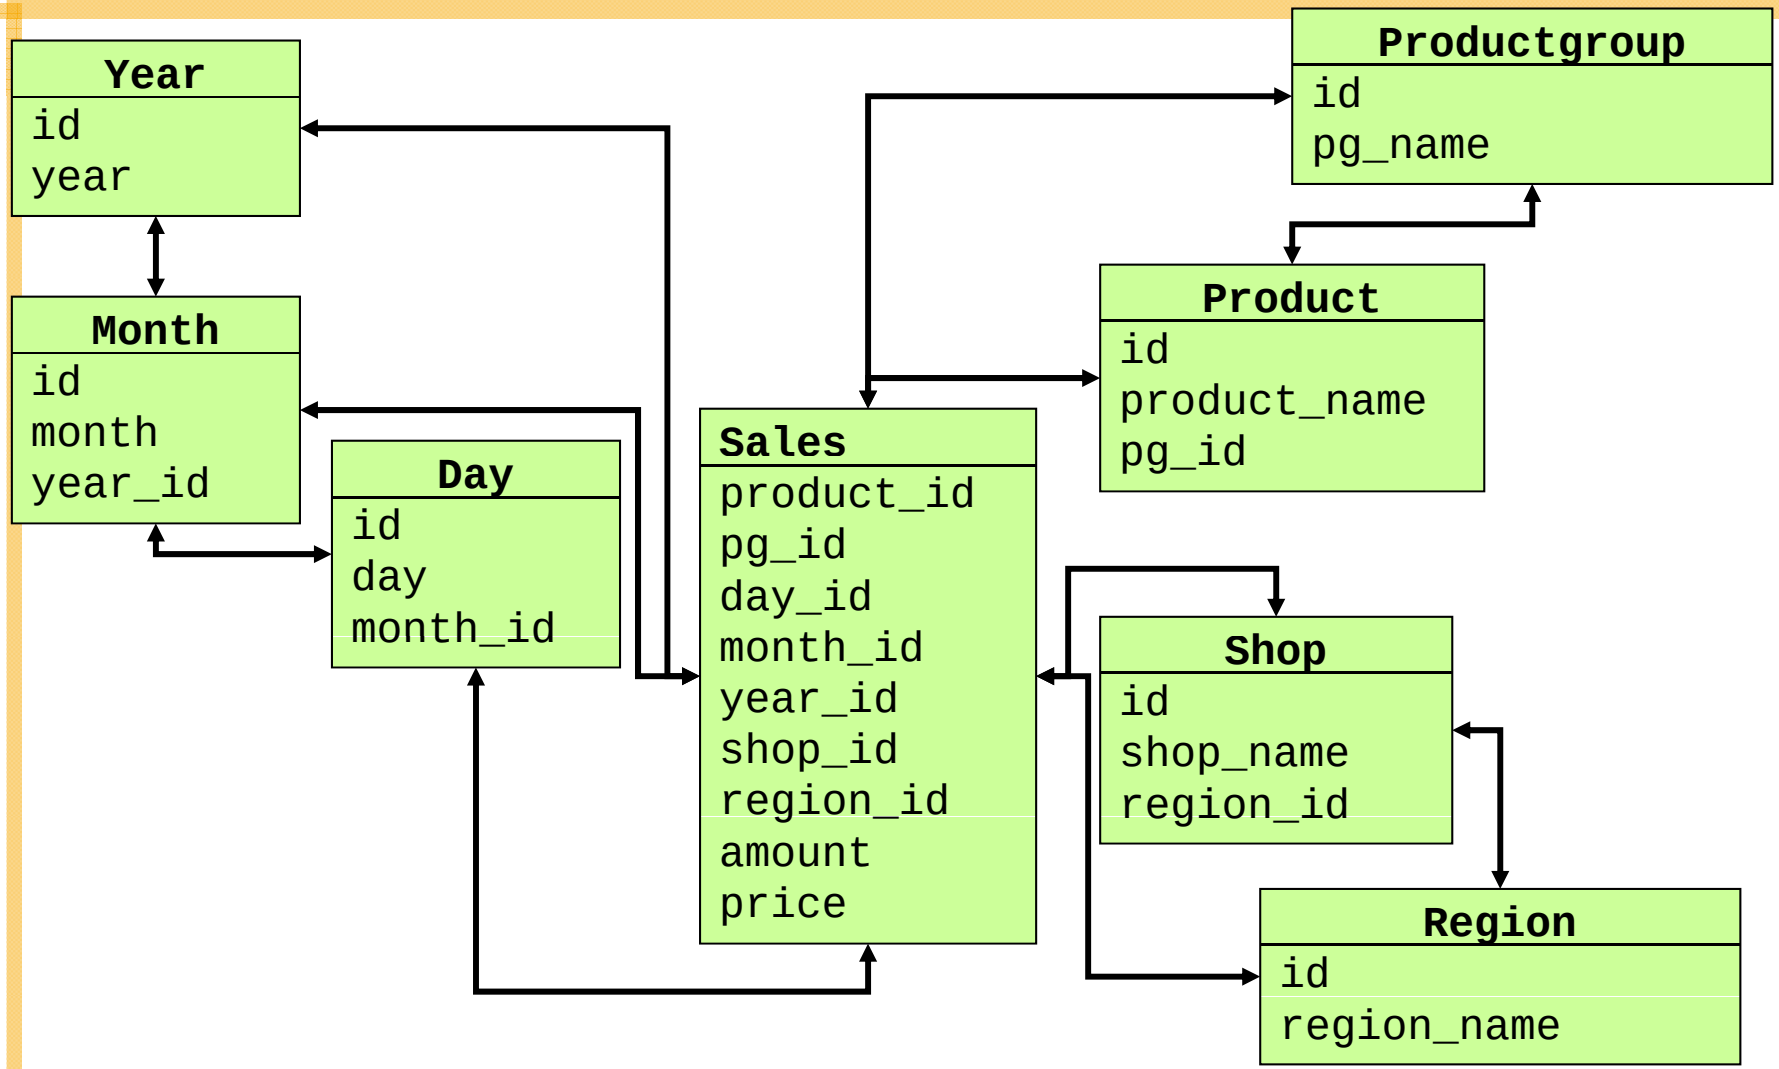

Fazit – Speicher und Query

- Speicherverbrauch Snowflake / Star praktisch identisch
  - Wenn Bedarf für Dimensionen vernachlässigbar
- Fullfact mit deutlich höherem Speicherverbrauch
  - Faktentabelle wird breiter
  - Dafür minimale Anzahl Joins
- Anzahl Joins: FullFact < Star < Snowflake
- Laufzeitverhalten hängt von mehr Faktoren als dem Schema ab
  - Bereichs- oder Punktanfrage
  - Indexierung
  - Selektivität der Bedingungen
  - Gruppierung und Aggregation
  - ...
- … aber Joins sind tendenziell teuer

Roll-Up Operationen: Hierarchische Aggregation

- Wunsch: Verkaufsumsatz der Produktgruppe „Wein“ nach Tagen, Monaten und Jahren
-
```
SELECT T.year_id, T.month_id, T.day_id,
       sum(s.amount)
FROM   Sales S, Product P, Time T
WHERE  P.pg_name=„Wein“
AND    P.product_id = S.product_id
AND    T.day_id = S.day_id
GROUP BY T.year_id, T.month_id, T.day_id
```
- Summe nur für Tage (unterteilt nach Monaten/Jahren)
- Keine Summen pro Monat / pro Jahr
- Wunsch nicht in einer Anfrage formulierbar

1997	1	1	150
1997	1	2	130
1997	1	3	145
1997	1	4	122
...	...	...	...
1997	1	31	145
1997	2	1	133
1997	2	2	122
...	...	...	...
1997	3	10	180
1997	12	31	480
1998	1	1	240
...	...	...	...
2003	6	18	345

Hierarchische Aggregation –2-

- Alle Verkäufe der Produktgruppe „Wein" nach Tagen, Monaten und Jahren
- Benötigt UNION und eine Anfrage pro Klassifikationsstufe

```
SELECT T.day_id, sum(amount*price)
FROM   Sales S, Product P
WHERE  P.pg_name=„Wein“ and
       P
GROUP BY
```

```
SELECT T.month_id, sum(amount*price)
FROM   Sales S, Product P, Time T
WHERE  P.pg_name=„Wein“ and
       P.pro
       T.day_
GROUP BY T.m
```

```
SELECT T.year_id, sum(amount*price)
FROM   Sales S, Product P, Time T
WHERE  P.pg_name=„Wein“ and
       P.product_id = S.product_id and
       T.day_id = S.day_id
GROUP BY T.year_id
```

ROLLUP Operator

- Herkömmliches SQL
  - Dimension mit k Stufen – Union von k Queries
  - k Scans der Faktentabelle
    - Keine Optimierung wg. fehlender Multiple-Query Optimierung in kommerziellen RDBMS
  - Schlechte Ergebnisreihenfolge

- ROLLUP Operator
  - Hierarchische Aggregation mit Zwischensummen
  - Summen werden durch „ALL“ als Wert repräsentiert

ROLLUP Beispiel


```
SELECT T.year_id, T.month_id, T.day_id, sum(...)
FROM   Sales S, Time T
WHERE  T.day_id = S.day_id
GROUP BY ROLLUP(T.year_id, T.month_id, T.day_id)
```

1997	Jan	1	200
1997	Jan	...	
1997	Jan	31	300
1997	Jan	ALL	31.000
1997	Feb	...	
1997	March	ALL	450
1997	...	...	
1997	ALL	ALL	1.456.400
1998	Jan	1	100
1998	...	...	
1998	ALL	ALL	45.000
...	...	...	
ALL	ALL	ALL	12.445.750

Multidimensionale Aggregation

	1998	1999	2000	Gesamt
Weine	15	17	13	45
Biere	10	15	11	36
Gesamt	25	32	24	81

- `sum() ... GROUP BY pg_id, year_id`
- `sum() ... GROUP BY pg_id`
- `sum() ... GROUP BY year_id`
- `sum()`

Cube Operator

- *d* Dimensionen, jeweils eine Klassifikationsstufe
  - Jede Dimension kann in Gruppierung enthalten sein oder nicht
  - 2^d Gruppierungsmöglichkeiten
- Herkömmliches SQL
  - Viel Schreibarbeit
  - 2^d Scans der Faktentabelle (wieder keine Optimierung möglich)
- CUBE Operator
  - Berechnung der Summen von sämtlichen Kombinationen der Argumente (Klassifikationsstufen)
  - Summen werden durch „ALL“ repräsentiert

Einfacher SQL Ansatz


```
SELECT Marke, Farbe, SUM(Verkäufe)
FROM AutoTab
GROUP BY (Marke, Farbe)

UNION

SELECT Marke, ALL, SUM(Verkäufe)
FROM AutoTab
GROUP BY (Marke)

UNION

SELECT ALL, Farbe, SUM(Verkäufe)
FROM AutoTab
GROUP BY (Farbe)

UNION

SELECT ALL, ALL, SUM(Verkäufe)
FROM AutoTab;
```

Marke	Farbe	Verkäufe
VW	Blau	32
VW	Weiß	17
VW	Rot	5
Opel	Blau	24
Opel	Weiß	19
Opel	Rot	12
VW	ALL	54
Opel	ALL	55
ALL	Blau	56
ALL	Weiß	36
ALL	Rot	17
ALL	ALL	109

Folie: Mark Liebetrau (HPI)

Ansatz mit CUBE-Operator

- **Neuer Ansatz**
- SELECT Marke, Farbe, SUM(Verkäufe) FROM AutoTab GROUP BY CUBE(Marke, Farbe);

- Unterschiede in der Syntax:
  - keine UNIONs mehr notwendig
    ⇒ einfachere Anfrage
- Unterschiede in der Semantik:
  - Keine

Bisheriger Ansatz

```
SELECT Marke, Farbe, SUM(Verkäufe)
FROM AutoTab
GROUP BY (Marke, Farbe)

UNION

SELECT Marke, ALL, SUM(Verkäufe)
FROM AutoTab
GROUP BY (Marke)

UNION

SELECT ALL, Farbe, SUM(Verkäufe)
FROM AutoTab
GROUP BY (Farbe)

UNION

SELECT ALL, ALL, SUM(Verkäufe)
FROM AutoTab;
```


Folie: Mark Liebetrau (HPI)

Ansatz mit CUBE-Operator

- **Ableitbarkeit der Gruppen**
  - Beziehung lässt sich mithilfe eines Aggregationsgitters darstellen
  - (X,Y) ≙ Gruppierung über X und Y

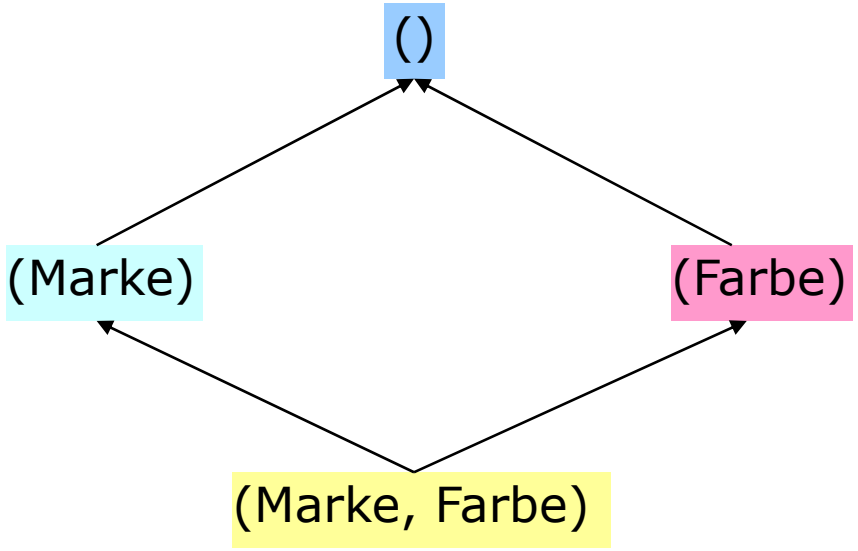

Marke	Farbe	Verkäufe
VW	Blau	32
VW	Weiß	17
VW	Rot	5
Opel	Blau	24
Opel	Weiß	19
Opel	Rot	12
VW	ALL	54
Opel	ALL	55
ALL	Blau	56
ALL	Weiß	36
ALL	Rot	17
ALL	ALL	109

Folie: Mark Liebetrau (HPI)