

---

# Kapitel 6

# Einführung in Data Warehouses

Vorlesung: PD Dr. Peer Kröger

Dieses Skript basiert auf den Skripten zur Vorlesung Datenbanksysteme II an der LMU München von Prof. Dr. Christian Böhm (Sommersemester 2007), PD Dr. Peer Kröger (Sommersemester 2008) und PD Dr. Matthias Schubert (Sommersemester 2009)

[http://www.dbs.ifi.lmu.de/cms/Datenbanksysteme\\_II\\_13](http://www.dbs.ifi.lmu.de/cms/Datenbanksysteme_II_13)

# 6 Einführung in Data Warehouses

---

## Übersicht

6.1 Einleitung

6.2 Datenmodellierung

6.3 Anfragebearbeitung

# 6 Einführung in Data Warehouses

---

## Übersicht

6.1 Einleitung

6.2 Datenmodellierung

6.3 Anfragebearbeitung

# 6.1 Einleitung

---

## Zwei Arten von DB-Anwendungen

- Online Transaction Processing (OLTP)
  - Routinetransaktionsverarbeitung
  - Realisierung des operationalen Tagesgeschäfts wie
    - “Buchen eines Flugs”
    - “Verarbeitung einer Bestellung”
    - “Ein- und Verkauf von Waren”
    - ...
  - Charakteristik:
    - Arbeitet auf dem jüngsten, aktuellsten Zustand der Daten
    - Änderungstransaktionen (kurze Lese-/Schreibzugriffe)
    - Zugriff auf sehr begrenzte Datenmenge
    - Sehr kurze Antwortzeiten erwünscht (ms-s)
  - OLTP-Datenbanken optimieren typischerweise den logischen und physischen DB-Entwurf hinsichtlich dieser Charakteristik

# 6.1 Einleitung

---

## Zwei Arten von DB-Anwendungen (cont.)

- Online Analytical Processing (OLAP)
  - Bilden Grundlage für strategische Unternehmensplanung (Decision Support)
  - Anwendungen wie
    - „Entwicklung der Auslastung der Transatlantik-Flüge über die letzten 2 Jahre?“
    - „Auswirkungen spezieller Marketingaktionen auf Verkaufszahlen der Produkte?“
    - „Voraussichtliche Verkaufszahl eines Produkts im nächsten Monat?“
    - ...
  - Charakteristik:
    - Arbeitet mit „historischen“ Daten (lange Lesetransaktionen)
    - Zugriff auf sehr große Datenmengen
    - Meist Integration, Konsolidierung und Aggregation der Daten
    - Mittlere Antwortzeiten akzeptabel (s-min)
  - OLAP-Datenbanken optimieren typischerweise den logischen und physischen DB-Entwurf hinsichtlich dieser Charakteristik

# 6.1 Einleitung

---

## Zwei Arten von DB-Anwendungen (cont.)

- OLTP- und OLAP-Anwendungen sollten nicht auf demselben Datenbestand ausgeführt werden
  - Unterschiedliche Optimierungsziele beim Entwurf
  - Komplexe OLAP-Anfragen könnten die Leistungsfähigkeit der OLTP-Anwendungen beeinträchtigen
- Data Warehouse
  - Datenbanksystem, indem alle Daten für OLAP-Anwendungen in konsolidierter Form gesammelt werden
  - Integration von Daten aus operationalen DBs aber auch aus Dateien (Excel, ...), ...
  - Daten werden dabei oft in aggregierter Form gehalten
  - Enthält historische Daten
  - Regelmäßige Updates (periodisch)

# 6.1 Einleitung

---

## Operationales DBS vs. Data Warehouse

	<b>operationales DBS</b>	<b>Data Warehouse</b>
<b>Ziel</b>	Abwicklung des Geschäfts	Analyse des Geschäfts
<b>Focus auf</b>	Detail-Daten	aggregierten Daten
<b>Versionen</b>	nur aktuelle Daten	gesamte Historie der Daten
<b>DB-Größe</b>	~ 1 GB	~ 1 TB
<b>DB-Operationen</b>	Updates und Anfragen	nur Anfragen
<b>Zugriffe pro Op.</b>	~ 10 Datensätze	~ 1.000.000 Datensätze
<b>Leistungsmaß</b>	Durchsatz	Antwortzeit

# 6.1 Einleitung

---

## Data Warehouses

- Begriff:

*A Data Warehouse is a subject-oriented, integrated, non-volatile, and time variant collection of data to support management decisions*

[W.H. Inmon, 1996]

# 6.1 Einleitung

---

## Data Warehouses (cont.)

- Begriff: *A Data Warehouse is a **subject-oriented**, integrated, non-volatile, and time variant collection of data to support management decisions*  
[W.H. Inmon, 1996]
- Fachorientierung (**subject-oriented**)
  - System dient der Modellierung eines spezifischen Anwendungsziel (meist Entscheidungsfindung in Unternehmen)
  - System enthält nur Daten, die für das Anwendungsziel nötig sind. Für das Anwendungsziel irrelevante Daten werden weggelassen.

# 6.1 Einleitung

---

## Data Warehouses (cont.)

- Begriff: *A Data Warehouse is a subject-oriented, **integrated**, non-volatile, and time variant collection of data to support management decisions.*

[W.H. Inmon, 1996]

- Fachorientierung (subject-oriented)
  - System dient nicht der Erfüllung einer Aufgabe (z.B. Verwaltung von Personaldaten)
  - System dient der Modellierung eines spezifischen Anwendungsziel
- Integrierte Datenbasis (**integrated**)
  - Verarbeitung der Daten aus unterschiedlichen Datenquellen

# 6.1 Einleitung

---

## Data Warehouses (cont.)

- Begriff: *A Data Warehouse is a subject-oriented, integrated, **non-volatile**, and time variant collection of data to support management decisions.* [W.H. Inmon, 1996]
- Nicht-flüchtige Datenbasis (**non-volatile**)
  - Stabile, persistente Datenbasis
  - Daten im Data Warehouse werden nicht mehr entfernt oder geändert

# 6.1 Einleitung

---

## Data Warehouses (cont.)


- Begriff: *A Data Warehouse is a subject-oriented, integrated, non-volatile, and **time variant** collection of data to support management decisions*

[W.H. Inmon, 1996]

- Nicht-flüchtige Datenbasis (non-volatile)
  - Stabile, persistente Datenbasis
  - Daten im Data Warehouse werden nicht mehr entfernt oder geändert
- Historische Daten (**time variant**)
  - Vergleich der Daten über die Zeit möglich
  - Speicherung über längeren Zeitraum

# 6.1 Einleitung

## Architektur eines Data Warehouse



# 6.1 Einleitung

---

## Data Warehouses und Data Marts

- Manchmal kann es sinnvoll sein, nur eine inhaltlich beschränkte Sicht auf das Data Warehouse bereitzustellen (z.B. für eine Abteilung)

=> Data Mart

### - Gründe:

Eigenständigkeit, Datenschutz, Lastenverteilung, ...

### - Realisierung:

Verteilung der DW-Datenbasis

### - Klassen:

- Abhängige Data Marts: Verteilung eines bestehenden DWs

=> Analysen auf DM konsistent zu Analysen auf gesamten DW

- Unabhängige Data Marts: unabhängig voneinander entstandene „kleine“ DWs, nachträgliche Integration zum globalen DW

=> unterschiedliche Analysesichten

# 6 Einführung in Data Warehouses

---

## Übersicht

6.1 Einleitung

6.2 Datenmodellierung

6.3 Anfragebearbeitung

# 6.2 Datenmodellierung

---

## Motivation

- Datenmodell sollte bzgl. Analyseprozess optimiert werden
- Datenanalyse im Entscheidungsprozess
  - Betriebswirtschaftliche Kennzahlen stehen im Mittelpunkt (z.B. Erlöse, Gewinne, Verluste, Umsätze, ...)  
=> **Fakten**
  - Betrachtung dieser Kennzahlen aus unterschiedlichen Perspektiven (z.B. zeitlich, regional, produktbezogen, ...)  
=> **Dimensionen**
  - Unterteilung der Auswertungsdimensionen möglich (z.B. zeitlich: Jahr, Quartal, Monat; regional: Bundesländer, Bezirke, Städte/Gemeinden; ...)  
=> **Hierarchien, Konsolidierungsebenen**

# 6.2 Datenmodellierung

---

## Kennzahlen/Fakten

- Kennzahlen/Fakten
  - Numerische Messgrößen
  - Beschreiben betriebswirtschaftliche Sachverhalte
- Beispiele: Umsatz, Gewinn, Verlust, ...
- Typen
  - Additiv: (additive) Berechnung zwischen sämtlichen Dimensionen möglich (z.B. Bestellmenge eines Artikels)
  - Semi-additiv: (additive) Berechnung möglich mit Ausnahme temporaler Dimension (z.B. Lagerbestand, Einwohnerzahl)
  - Nicht-Additiv: keine additive Berechnung möglich (z.B. Durchschnittswerte, prozentuale Werte, ...)

# 6.2 Datenmodellierung

---


## Dimensionen

- Dimension
  - Beschreibt mögliche Sicht auf die assoziierte Kennzahl
  - Endliche Menge von  $d \geq 2$  Dimensionselementen (Hierarchieobjekten), die eine semantische Beziehung aufweisen
  - Dient der orthogonalen Strukturierung des Datenraums
- Beispiele: Produkt, Geographie, Zeit

# 6.2 Datenmodellierung

## Hierarchien in Dimensionen

- Dimensionselemente sind Knoten einer Klassifikationshierarchie
- Klassifikationsstufe beschreibt Verdichtungsgrad
- Darstellung von Hierarchien in Dimensionen über Klassifikationsschema
- Formen
  - Einfache Hierarchien: höhere Ebene
    - enthält die aggregierten Werte genau
    - einer niedrigeren Hierarchiestufe
  - Parallele Hierarchien: innerhalb einer
    - Dimension sind mehrere verschiedene
    - Arten der Gruppierung möglich



# 6.2 Datenmodellierung


---

## Data-Cubes

- Grundlage der multidimensionalen Datenanalyse:  
Datenwürfel (*Data-Cube*)
- Kanten des Cubes: Dimensionen
- Zellen des Cubes: ein oder mehrere Kennzahlen (als Funktion der Dimension)
- Anzahl der Dimensionen: Dimensionalität des Cubes
- Visualisierung
  - 2 Dimensionen: Tabelle
  - 3 Dimensionen: Würfel
  - >3 Dimensionen: Multidimensionale Domänenstruktur

# 6.2 Datenmodellierung


## Beispiel: 3D Data-Cube



# 6.2 Datenmodellierung

## Standardoperationen zur Datenanalyse

- Pivottisierung/Rotation
  - Drehen des Data-Cube durch Vertauschen der Dimensionen
  - Datenanalyse aus verschiedenen Perspektiven
  - Beispiel:



## 6.2 Datenmodellierung

---


### Standardoperationen zur Datenanalyse (cont.)

- Roll-Up
  - Erzeugen neuer Informationen durch Aggregation der Daten entlang der Klassifikationshierarchie in einer Dimension  
(z.B. Tag => Monat => Quartal => Jahr)
  - Dimensionalität bleibt erhalten
- Drill-Down
  - Komplementär zu Roll-Up
  - Navigation von aggregierten Daten zu Detail-Daten entlang der Klassifikationshierarchie
- Drill-Across
  - Wechsel von einem Cube zu einem anderen

# 6.2 Datenmodellierung

Standardoperationen zur Datenanalyse (cont.)

- Beispiel: Roll-Up, Drill-Down



## 6.2 Datenmodellierung

---

### Standardoperationen zur Datenanalyse (cont.)

- Slice und Dice
  - Erzeugen individueller Sichten
  - Slice:
    - Herausschneiden von „Scheiben“ aus dem Cube (z.B. alle Werte eines Quartals)
    - Verringerung der Dimensionalität
  - Dice:
    - Herausschneiden eines „Teil-Cubes“ (z.B. Werte bestimmter Produkte und Regionen)
    - Erhaltung der Dimensionalität
    - Veränderung der Hierarchieobjekte

# 6.2 Datenmodellierung

## Standardoperationen zur Datenanalyse (cont.)

- Beispiel: Slice

