Datenintegration

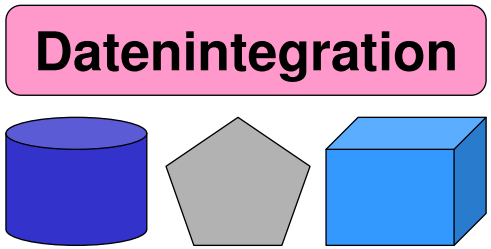

Kapitel 2: Verteilung, Autonomie und Heterogenität

Michael Hartung in Vertretung von **Dr. Andreas Thor**

Wintersemester 2010/11

Universität Leipzig
Institut für Informatik
http://dbs.uni-leipzig.de

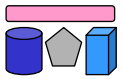

Inhalt

- Verteilung
  - Physikalische Verteilung
  - Logische Verteilung
- Autonomie
  - Designautonomie
  - Kommunikationsautonomie
  - Ausführungsautonomie
- Heterogenität
  - Technische Heterogenität
  - Syntaktische Heterogenität
  - Datenmodellheterogenität
  - Strukturelle Heterogenität
  - Semantische Heterogenität

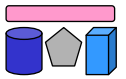

Verteilung (Distribution)

- Ein verteiltes Informationssystem ist eine Sammlung mehrerer, logisch verknüpfter Informationssysteme, die über ein gemeinsames Netzwerk verteilt sind.
  (Özsu, Valduriez: Principles of Distributed Database Systems. Prentice-Hall, 1991)

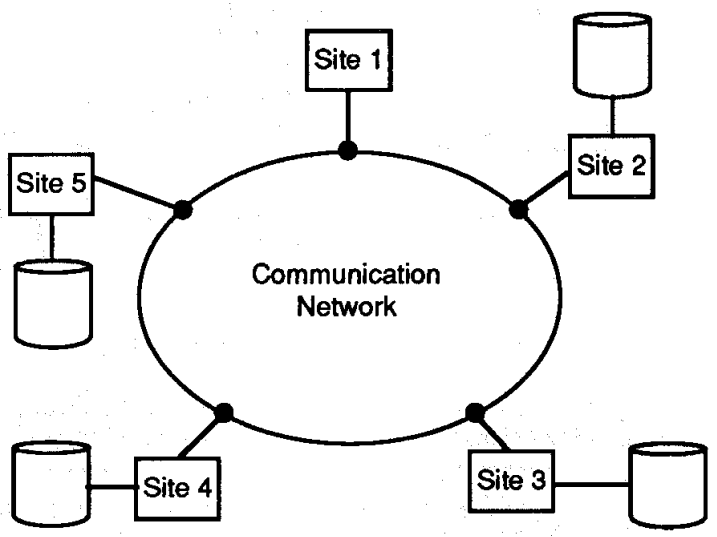

Figure 1.7 DDBS Environment

- Anwendungsentwicklung
  - Ohne Spezifikation der physikalischen Präsenz der Komponenten
  - Häufige Techniken: HTTP, CORBA, …
  - Transparenz bzgl. Speicherort, Netzwerk, …
- Arten von Verteilung
  - Physikalische Verteilung
  - Logische Verteilung

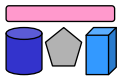

Physikalische Verteilung

- Motivation: Hardwareanforderungen
  - Höhere Sicherheit (desaster protection)
  - Lokale Nähe von Servern zu Clients
  - Historisch begründete Orte
  - Physikalische Einschränkungen (Hitze, Gewicht, Energie)
  - Monetäre Gründe (Grid)
- Server stehen an unterschiedlichen Orten
  - Gleicher Raum, anderer Raum
  - Anderes Gebäude
  - Andere Stadt, anderes Land
- Shared Nothing
  - Server haben keine gemeinsamen, abhängigen Hardwarekapazitäten
    - Memory, Disk, CPU, …
  - Mit Ausnahme des Netzwerks
  - Im Gegensatz zu shared-disk und shared-memory

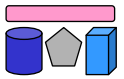

Logische Verteilung

- Motiviert: Anwendungsanforderungen
  - Zuverlässigkeit (bei Ausfall eines Servers)
  - Verfügbarkeit (bei Ausfall eines Netzwerkteils)
  - Effizienz
- Redundanz
  - Replikation
  - Caching
- Partitionierung
  - Vertikal
  - Horizontal

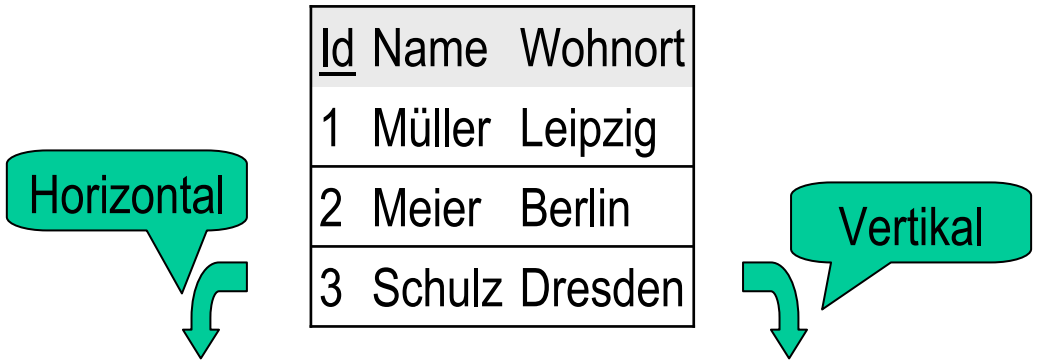

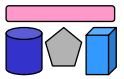

Physische vs. logische Verteilung

- Definition von logischer Verteilung ist anwendungsabhängig, die von physischer Verteilung nicht

- Daten können *logisch verteilt* sein, obwohl sie *physisch unverteilt* sind
  - Schema verdoppeln und Daten verteilen
  - Zwei Filmquellen unverändert in ein Schema kopieren
- Daten können *physisch verteilt* sein, obwohl sie *logisch unverteilt* sind
  - Replikation und Caching:
    - Klare Master – Slave Beziehung
  - Performanzsteigerung durch Partitionierung
    - Auftrennung nach festen Kriterien
  - Verteilte Datenbanken
    - Strenge Kontrolle des „wo“ von Daten

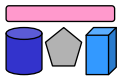

Vor- und Nachteile der Verteilung

- Vorteile aus Sicht der Quellen und des IIS
  - Autonomie (gleich genauer)
  - Performance: Kapazität dort, wo sie gebraucht wird
  - Verfügbarkeit: Bei Ausfall eines Standorts
  - Erweiterbarkeit
  - Teilbarkeit (Verantwortung bei anderen Organisationseinheiten)
- Nachteile aus Sicht des IIS
  - Komplexität (Verwaltung, Optimierung)
  - Kosten
  - Sicherheit
  - Autonomie

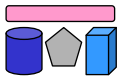

Autonomie

- Der Grad zu dem verschiedene IS unabhängig operieren können
- Bezieht sich auf Kontrolle, nicht auf die Daten selbst
  - (Recht auf) Weiterentwicklung, Administration
- Klassen nach [Özsu, Valduriez: Principles of Distributed Database Systems. Prentice-Hall, 1999]
  - Designautonomie
  - Kommunikationsautonomie
  - Ausführungsautonomie
- Weitere Klassen
  - Schnittstellenautonomie
    - Technischer Zugriff: Webservice+SOAP, Web+HTML, SQL+Tupel, …
  - Zugriffsautonomie
    - Authentifizierung, Rechtevergabe, …
  - Juristische Autonomie
    - Zugriff eingeschränkt für bestimmte Verwendungen (Copyright, Screen Scraping)

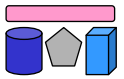

Designautonomie (Entwurfsautonomie)

- Freiheit bezüglich …
  - Datenmodell
    - Relational, hierarchisch, XML
    - (Siehe Beispiel rechts)
  - Schema
    - Abdeckung der Domäne (universe of discourse, miniworld)
    - Grad der Normalisierung
    - Benennung
  - Transaktionsmanagement
- Freiheit dies jederzeit zu ändern!
  - Besonders problematisch!

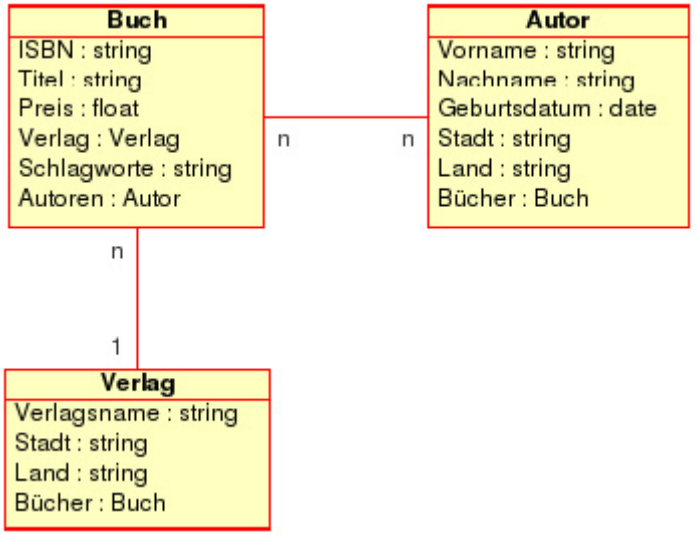


```
<xs:element name="Autor" minOccurs="0" maxOccurs="unbounded">
- <xs:complexType>
  - <xs:sequence>
      <xs:element name="Vorname" type="xs:string" />
      <xs:element name="Nachname" type="xs:string" />
    - <xs:element name="Buch" minOccurs="0" maxOccurs="unbounded">
      - <xs:complexType>
        - <xs:sequence>
            <xs:element name="ISBN" type="xs:string" />
          + <xs:element name="Verlag" minOccurs="1" maxOccurs="1">
          </xs:sequence>
        </xs:complexType>
      </xs:element>
    </xs:sequence>
  </xs:complexType>
</xs:element>
```

Kommunikationsautonomie

- Freiheit bezüglich der Wahl …
  - mit Wem kommuniziert wird
    - z.B. Sperren von Clients bei zu vielen Zugriffen
  - Wann mit anderen Systemen kommuniziert wird
    - jederzeit Eintritt/Austritt aus integriertem System, Priorisierung von Zugriffen
  - Was (welcher Teil der Information) kommuniziert wird
    - z.B. beschränkte Anfrageergebnisse
  - Wie mit anderen Systemen kommuniziert wird (Anfragemöglichkeiten)
    - Anfragesprache und -prädikate, Sortierung, Write

Beispiel	SQL-Zugriff per JDBC	HTML Formular auf Website
Mit Wem?		
Wann?		
Was?		
Wie?		

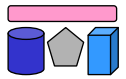

Ausführungsautonomie

- Freiheit bezüglich der Wahl …
  - wann Anfragen ausgeführt werden
  - wie Anfragen ausgeführt werden
  - der Scheduling-Strategien
  - Optimierungs-Strategien
  - ob globale Transaktionen unterstützt werden

- Beispiel:
  - Optimierung und Scheduling
    - Behandlung externer vs. lokaler Anfragen
    - Golden customers
    - Garantierte Antwortzeiten
  - Transaktionen
    - Dirty-read egal?

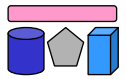

Verteilung → Autonomie → Heterogenität

- Verteilung als „Ursache“ für Autonomie
- Autonomie als „Ursache“ für Heterogenität
  - Gestaltungsfreiheit → Unterschiedliche Entscheidungen → Heterogenität
- Besonders schlimm: Softwareentwickler
  - Das Recht, alles dauernd zu ändern
  - „Not invented here“ Syndrom
  - Wiederverwendung als ewiger Traum
- Standards grenzen Autonomie ein

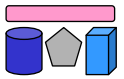

Heterogenität

- Heterogenität herrscht, wenn sich zwei miteinander verbundene Informationssysteme syntaktisch, strukturell oder inhaltliche unterscheiden.
- Heterogenitäten zu überbrücken ist die Kernaufgabe der Informationsintegration.
  - Erstellung oder “Erwecken des Anscheins” eines homogenen Systems
- Arten von Heterogenitäten
  - Technische Heterogenität
  - Syntaktische Heterogenität
  - Datenmodellheterogenität
  - Strukturelle Heterogenität
  - Semantische Heterogenität
- Weitere Klassifikationen möglich
  - Klare Trennung der Arten nicht immer möglich
  - Häufig Kombinationen von mehreren Arten in der Praxis

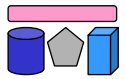

Heterogenitäten: Übersicht

Gelöst, wenn …

- Technische Heterogenität
  - Technische Realisierung des Datenzugriffs (Schnittstelle)
  - Technische Unterschiede in der Darstellung

Das IntInfoSys kann eine Anfrage absetzen und kriegt „was“ zurück

- Syntaktische Unterschiede
  - Unterschiede in der Darstellung
  - Gleiche Dinge syntaktisch verschieden repräsentieren

In dem „was“ sind gleiche Dinge auch gleich dargestellt

- Datenmodellheterogenität
  - Unterschiede im verwendeten Datenmodell (z.B. hierarchisch, relational)

Die Quelle liefert das „was“ im Datenmodell des IntInfoSys

- Strukturelle Heterogenität
  - Strukturelle Unterschiede in der Darstellung
  - Gleiche Dinge verschieden modellieren (z.B. verschiedene DB-Schemas)

Die Quelle liefert das „was“ im Schema des IntInfoSys

- Semantische Heterogenität
  - Bedeutungsunterschiede von Namen (Schema und Daten); Gleiches sagen, verschiedenes meinen (oder andersrum)

Die Quelle meint mit Begriffen dasselbe wie das IntInfoSys

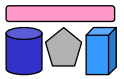

Technische Heterogenität

- Anfragemöglichkeit / Schnittstelle
  - Anfragesprache
    - SQL, XQuery, …
  - parametrisierte Funktionen
    - Webservice-Aufrufe
  - Formulare (“canned queries”)
    - HTML-Formulare
- Austauschformat
  - Binärdaten, XML, HTML, tabellarisch
- Kommunikationsprotokoll
  - HTTP, JDBC, SOAP, …

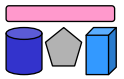

Heterogenität von Anfragesprachen

- Negation vs. keine Negation
  - Oft zu teuer
- Gleichheit / Ungleichheit
  - „=“ oder auch „>,<, ≥, ≤“
- Konjunktion (UND)
  - oder auch Disjunktion (ODER)
- Prädikate nur mit Konstanten (author = „Melville“)
  - Oder auch mit anderen Variablen (ResidenceCountry = Nationality)
- Gebundene und freie Variablen später
  - Feld muss mit Wert belegt sein (gebunden) oder kann unspezifiziert bleiben (frei)
- Andere Einschränkungen
  - Joins über maximal 3 Relationen
  - z.B. Prädikate nur über eine Auswahl von Werten

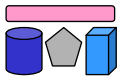

Heterogenität von Anfragesprachen: Beispiele

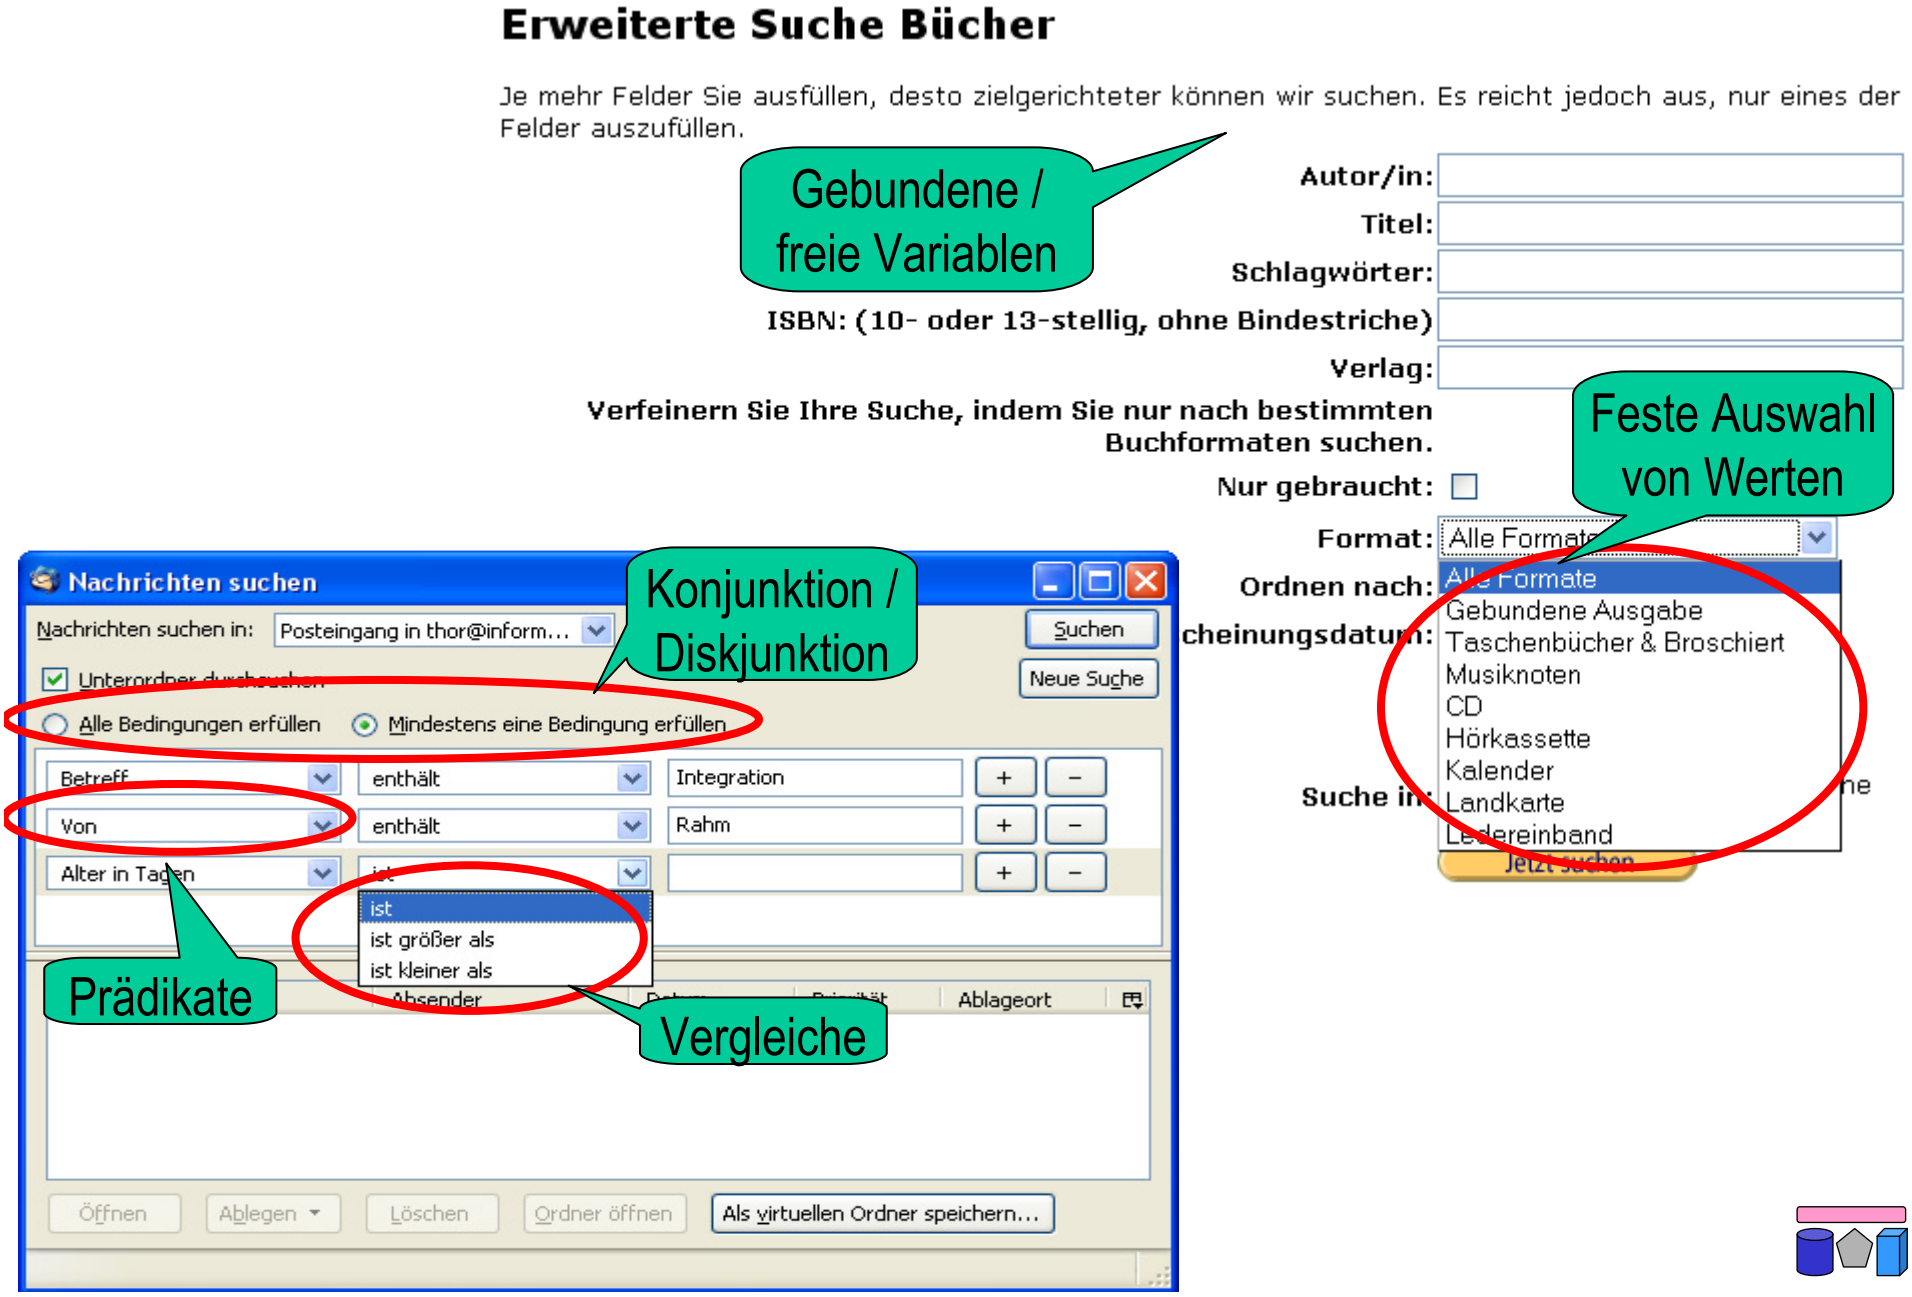

Heterogenität von Anfragesprachen: Probleme

- In einzelnen Systemen kein Problem
- Aber: Probleme für integrierte Systeme
  - Überwindung der Heterogenität zwischen globaler Anfragesprache des integrierten Systems und lokaler Anfragesprache der Quelle

1. Globale Anfragesprache ist mächtiger als lokale Anfragesprache
   - Anfragen eventuell nicht ausführbar
   - Oder globales System muss kompensieren
2. Lokale Anfragesprache ist mächtiger als globale Anfragesprache
   - Verpasste Chance, lokale (effiziente) Ausführung auszunutzen
3. Gebundene und freie Variablen sind inkompatibel
   - Anfragen eventuell nicht ausführbar
4. Übersetzung von Anfragesprachen notwendig
   - SQL – XQuery, SQL – HTTP, Web-Service – SQL, etc.
   - Oft nicht einfach möglich, da unterschiedliche Konzepte

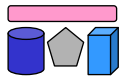

Globale Anfragesprache mächtiger als lokale

- Beispiel: Integr.System erlaubt SQL, Datenquelle “nur” HTML-Formular

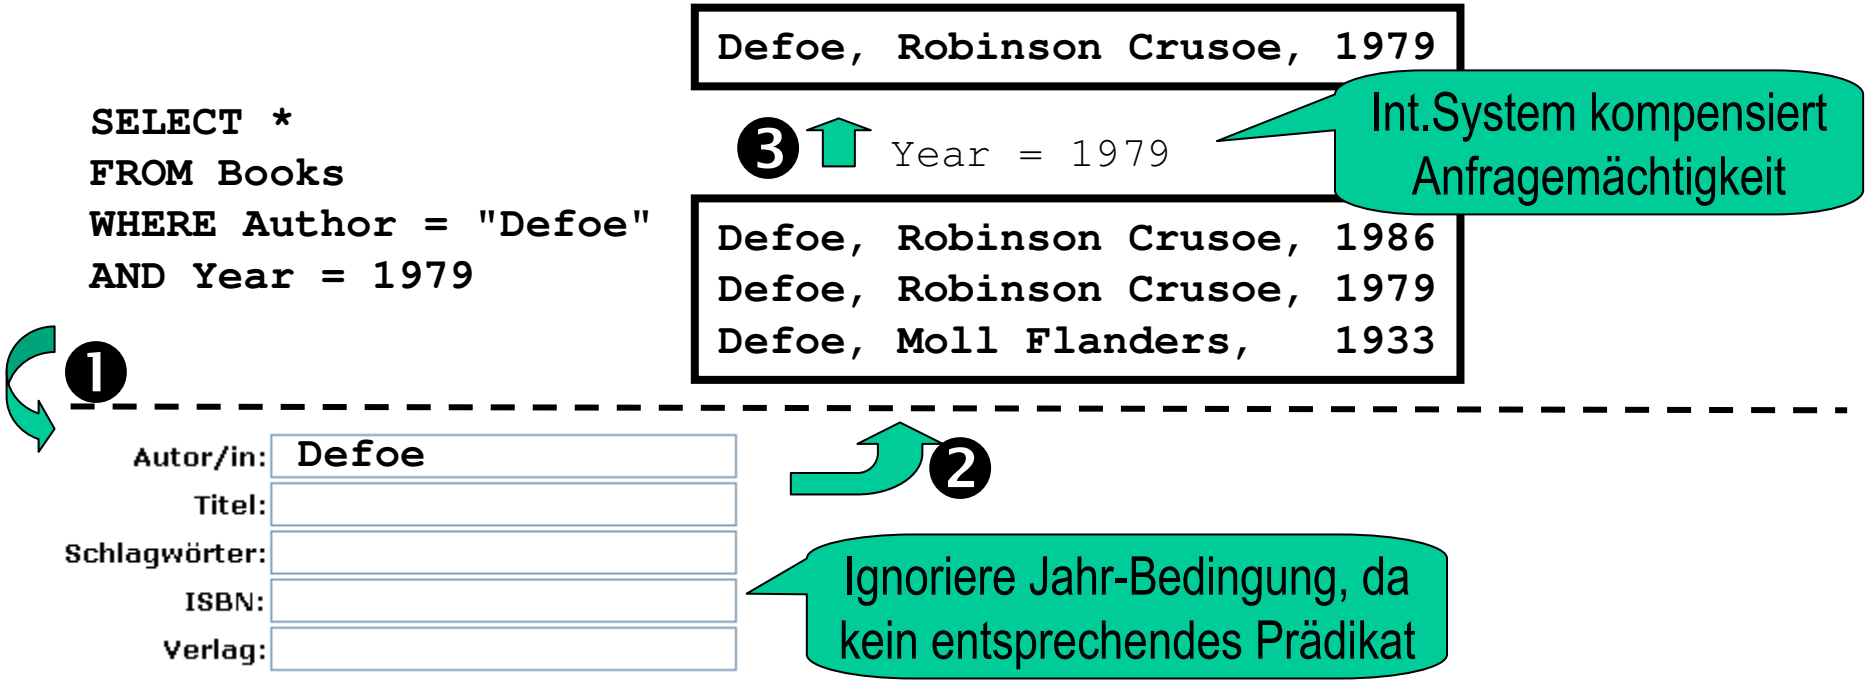

Was passiert bei anderen Anfragen?

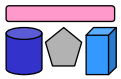

Syntaktische Heterogenität

- Unterschiedliche Darstellung desselben Sachverhalts
  - Dezimalpunkt oder –komma
  - Euro oder €
  - Comma-separated oder tab-separated
  - HTML oder ASCII oder Unicode
  - Notenskala 1-6 oder „sehr gut“, „gut“, …
  - Binärcodierung oder Zeichen
  - Datumsformate (18. April 2008, 18.4.2008, 4/18/2008, …)
- Überwindung in vielen (einfachen) Fällen nicht problematisch
  - Umrechnung, Übersetzungstabellen, …
- Probleme u.a. bei “nicht-standardisierten” Darstellungen
  - Beispiel: Konferenznamen
    - “VLDB 2008”, “Very Large Databases, 2008”, “34. VLDB”, …

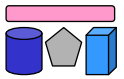

Datenmodellheterogenität

- Typische Datenmodelle
  - Relational, XML, Objektorientiert
    - Siehe Beispiel rechts
  - Domänenspezifisch (OPEN-GIS, …)
  - Proprietär (UniProt, …)
- Unterschied: Zum Austausch oder zur Speicherung
  - XML als Speicherformat?
  - Black-Box-Sicht – was zählt, ist was die Quelle liefert
- Erfordert Konvertierung
  - Spezielle Semantik geht unter Umständen verloren
  - XML-Schachtelung im relationalen Modell? Part-of? Is-a?

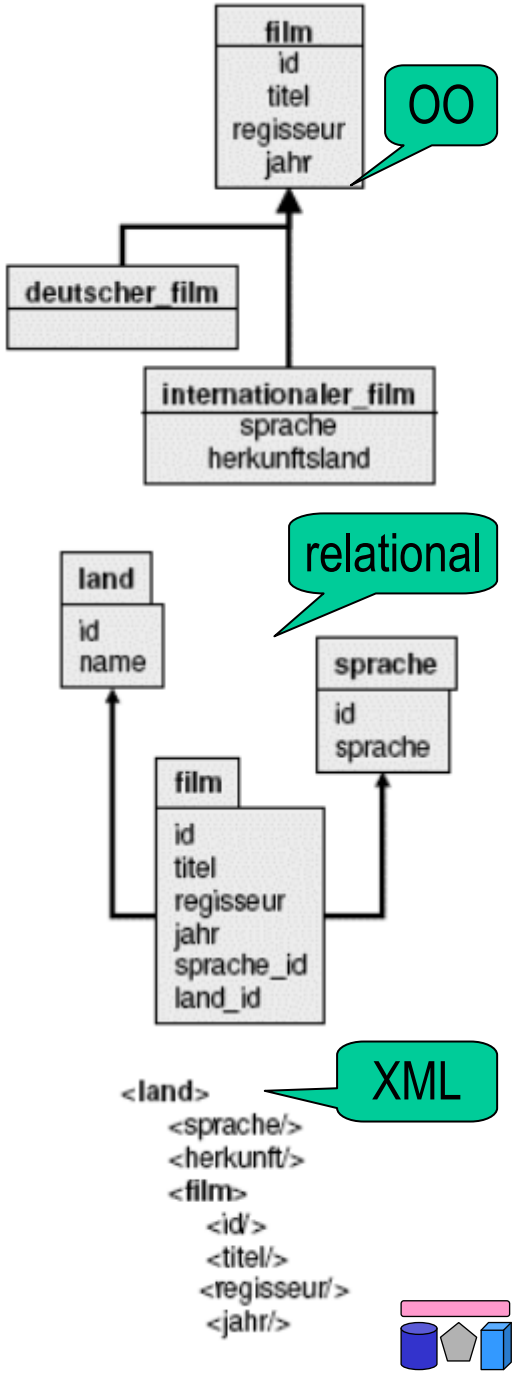

Strukturelle Heterogenität

- Allgemein
  - Gleiche Dinge in unterschiedlichen Schemata ausdrücken
    - Andere Aufteilung von Attributen auf Tabellen
    - Fehlende / neue Attribute (wenn Intension nicht betroffen ist)
    - Setzt intensionale Überlappung voraus („gleiche Dinge“)
  - Meistens mit semantischer Heterogenität verbunden
    - Ausnahme: 1:1 Beziehungen
- Spezialfall: Schematische Heterogenität
  - Verwendung anderer Elemente eines Datenmodells
  - Kann meist nicht durch Anfragesprachen überwunden werden

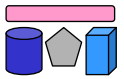

Strukturelle Heterogenität: Beispiel

- Heterogenität auf Grund unterschiedlichen Abbildungen eines OO-Modells in ein relationales Modell
- Gleichwertig? Ja, aber nur durch zusätzliche Integritätsbedingungen
  - 1: Typ hat nur bestimmte Werte annehmen
  - 1: Umsatz nicht immer belegt (abh. Vom Typ)
  - 2: Keine gleichen Film_Id's in Tabellen
- Anfragen: "Anzahl der Filme pro Filmtyp"

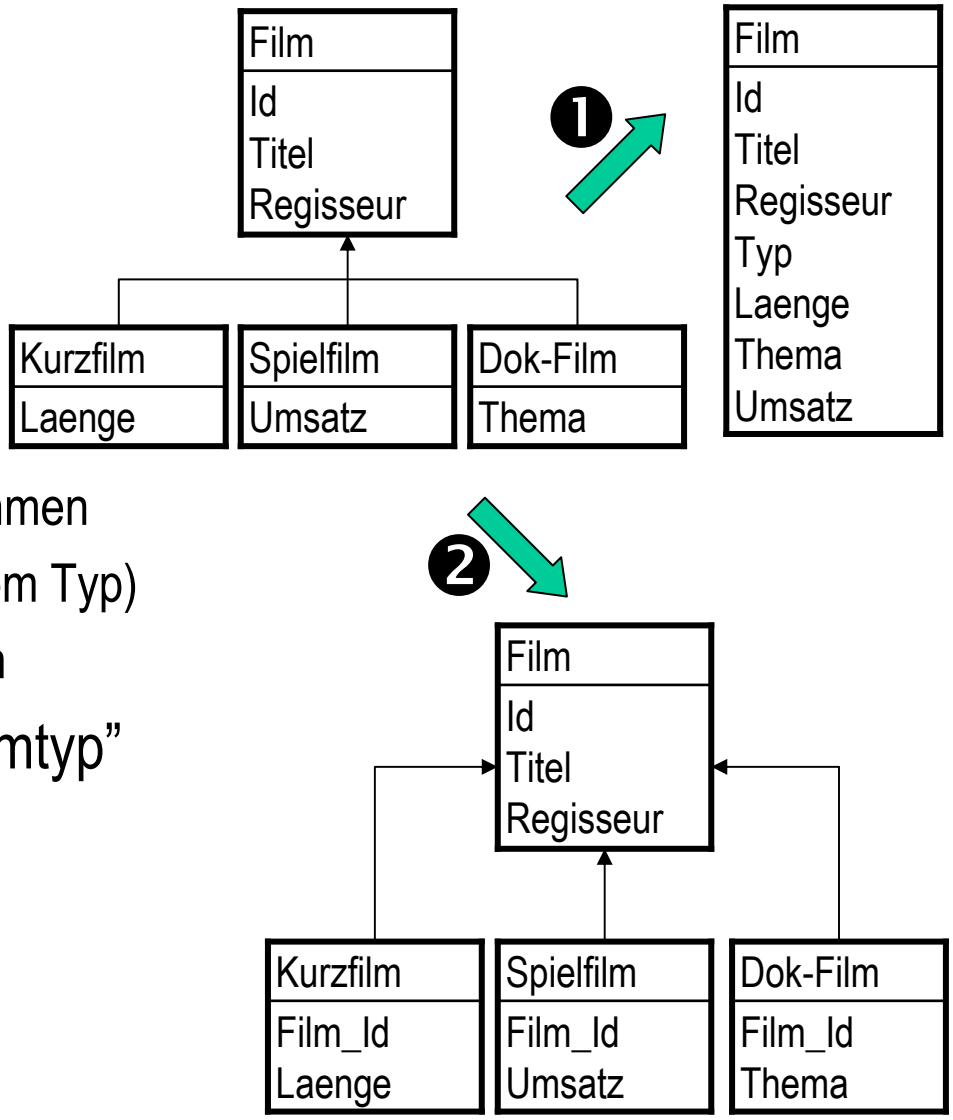

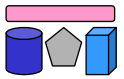

Schematische Heterogenität: Problemfälle

- Modellierung
  - Relation vs. Attribut
  - Relation vs. Wert
  - Attribut vs. Wert
  - Siehe Beispiel rechts

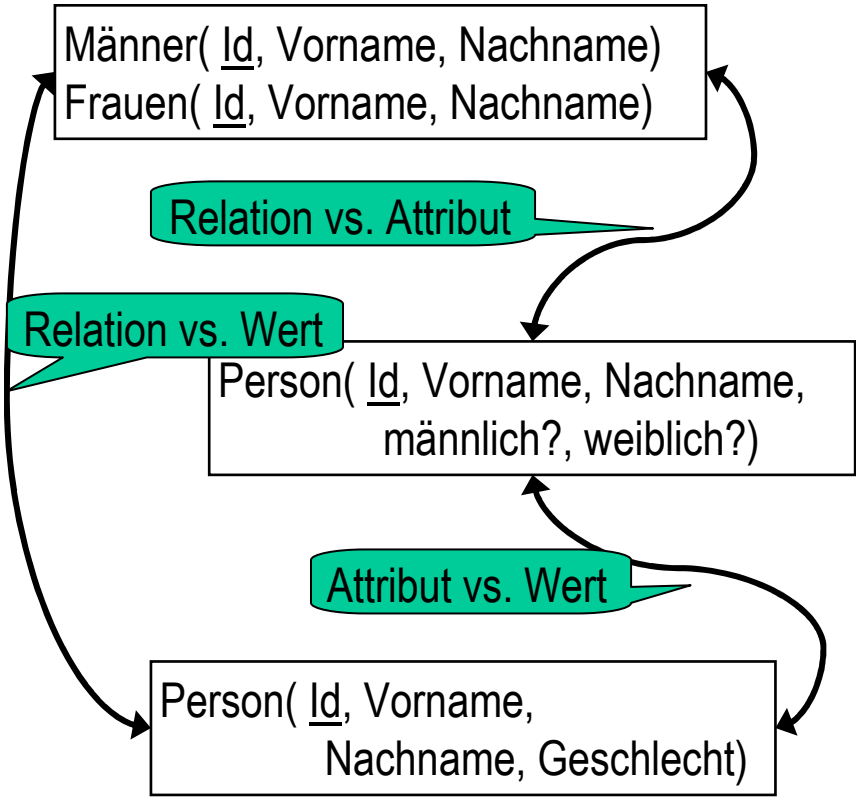

- Normalisiert vs. Denormalisiert
  - Attribut im Tupel vs. Auslagern in Tabelle
- Geschachtelt vs. Fremdschlüssel
  - 1:N-Assoziationen
- Weitere Konflikte
  - Fehlende (evtl. ableitbare) Attribute
  - Integritätsbedingungen, z.B. unterschiedliche Datentypen

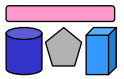

Semantische Heterogenität

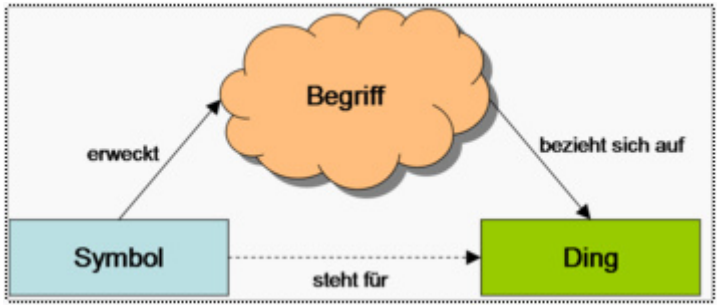

- Fremdwörterduden zu “Semantik”
  - „Teilgebiet der Linguistik, das sich mit den Bedeutungen sprachlicher Zeichen und Zeichenfolgen befasst“
  - „Bedeutung, Inhalt eines Wortes, Satzes oder Textes“
- „Semantische Heterogenität ist ein überladener Begriff ohne klare Definition. Er bezeichnet die Unterschiede in Bedeutung, Interpretation und Art der Nutzung.“ [Özsu, Valduriez: Principles of Distributed Database Systems. Prentice-Hall, 1991]
- Semantik vs. Syntax
  - Programmiersprachen
    - Syntax: EBNF, Grammatiken, …
    - Semantik: Wirkung der Ausführung (operationale Semantik, Fixpunktsemantik, …)
  - Natürliche Sprachen
    - Syntax: formale Struktur (Worte, Phrasen, Sätze) → “Ich esse Butterbrot ein.”
    - Semantik: inhaltliche Struktur (Referenz, Bedeutung) → “Ich esse einen Schrank.”

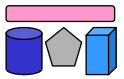

Semantik vs. Struktur

- Strukturelle Heterogenität
  - Betrifft Schemas, Bedeutung der Labels im Schema egal
  - Annahme bisher: Gleiche Label -> Gleiche Semantik

```
Männer( Id, Vorname, Nachname)
Frauen( Id, Vorname, Nachname)
```

```
A( Id, X, Y)
B( Id, X, Y)
```

```
Person( Id, Vorname, Nachname,
          Männlich, weiblich)
```

```
P( Id, X, Y, a, b)
```

- Semantische Heterogenität
  - Betrifft Daten, d.h deren „Bedeutung“

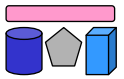

Semantische Heterogenität: Problemfälle

- Definition von Konzepten/Begriffen
  - Uneinigkeit, was ein Konzept ist (Gen, Transaktion, Bestellung, Mitarbeiter, …)
  - Semantisch überlappende Weltausschnitte mit einander entsprechenden Klassen
- “-nym” Worte
  - Synonym: verschiedene Worte, gleiche Semantik (Bsp: senkrecht, vertikal)
  - Homonym: gleiche Worte, verschiedene Semantik (Bsp: Bank, Schloss)
  - Auto-Antonym: gleiche Worte, gegenteilige Semantik (Bsp: Untiefe, übersehen)
  - …
- Einheiten
  - cm vs. inch, $ vs. €

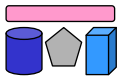

Konzepte und Kontext (Beispiel)

- Wieviele Mitarbeiter hat IBM?
  - Konzept: Mitarbeiter
  - Konzept: IBM
  - Weitere Konzepte, z.B. Zeitpunkt

Auch temporäre MA, Diplomanden, Berater? Stellen oder Köpfe?

Welche Region? Welcher Geschäftsbereich?

- Wann machen Studenten der Uni Leipzig ihren Abschluss?
  - Konzept: Studiendauer
  - Konzept: Student

Mit Urlaubssemester? Zählen Semester an anderen Unis? Fach- oder Studiensemester?

Diplom? Bachelor? Master? Nebenfach? Promotion? Lehramt?

- Semantik eines Namens hängt vom Kontext ab
  - Bsp: “England = Großbritannien?” → Ja für uns, Nein für Schotten
- Wie definiert man die Bedeutung eines Namens?
  - Formale Wissensrepräsentation (Ontologien, OWL)
  - Dokumentieren (mit lauter Namen)
  - Standards vereinbaren (schwierig)

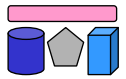

Zusammenfassung

- Verteilung
  - Physikalische und logische Verteilung
- Autonomie
  - Designautonomie, Kommunikationsautonomie, Ausführungsautonomie
  - “Eigenständigkeit” der Informationssysteme
- Heterogenität = Folge von Verteilung und Autonomie
  - Überbrückung = wichtiger Schritt bei Integration
  - Unterschiedliche Arten von Heterogenität, die “aufeinander aufbauen”
  - Technisch $\rightarrow$ Syntaktisch $\rightarrow$ Datenmodell $\rightarrow$ Strukturell $\rightarrow$ Semantisch