



**Hasso
Plattner
Institut**

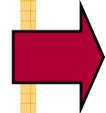
IT Systems Engineering | Universität Potsdam

VL Informationsintegration
Verteilung, Autonomie und
Heterogenität

28.4.2008

Felix Naumann

2



- Verteilung
- Autonomie
- Syntaktische Heterogenität
- Strukturelle Heterogenität
- Semantische Heterogenität
 - Namenskonflikte
 - Identität
 - Datenkonflikte
- Gebundene und Freie Variablen
 - Adornments
 - Anfrageplanung



Klassifikation von Informationssystemen

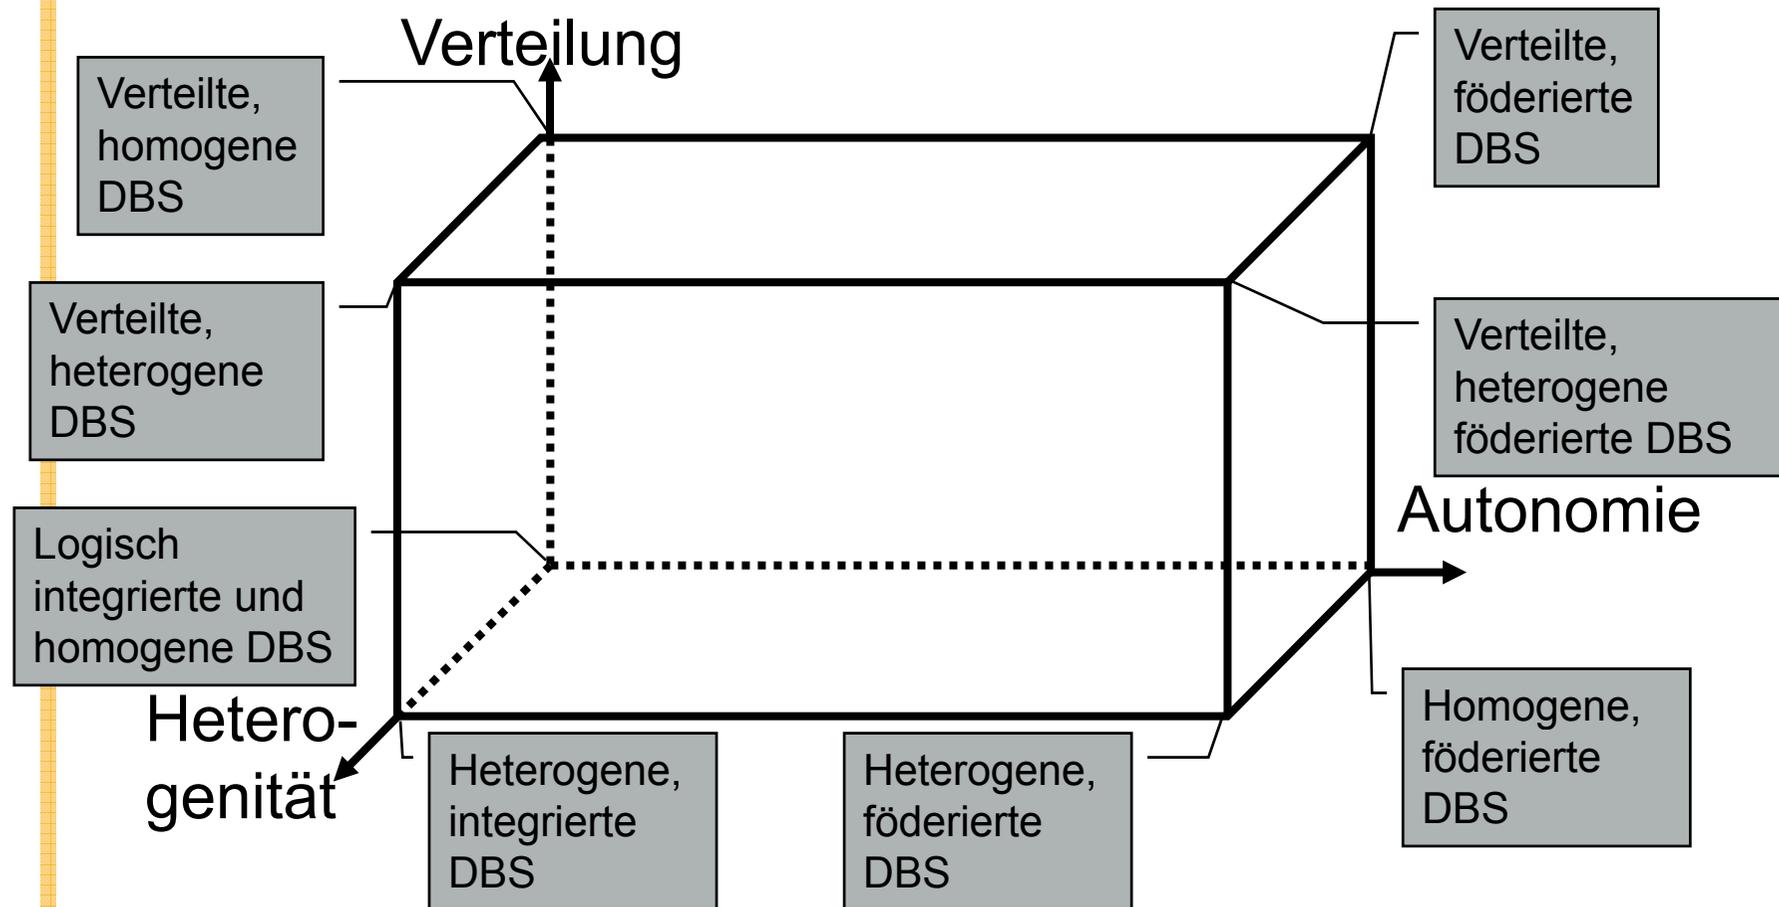
[ÖV99]

3

- Drei orthogonale Dimensionen
 - Verteilung
 - Autonomie
 - Heterogenität

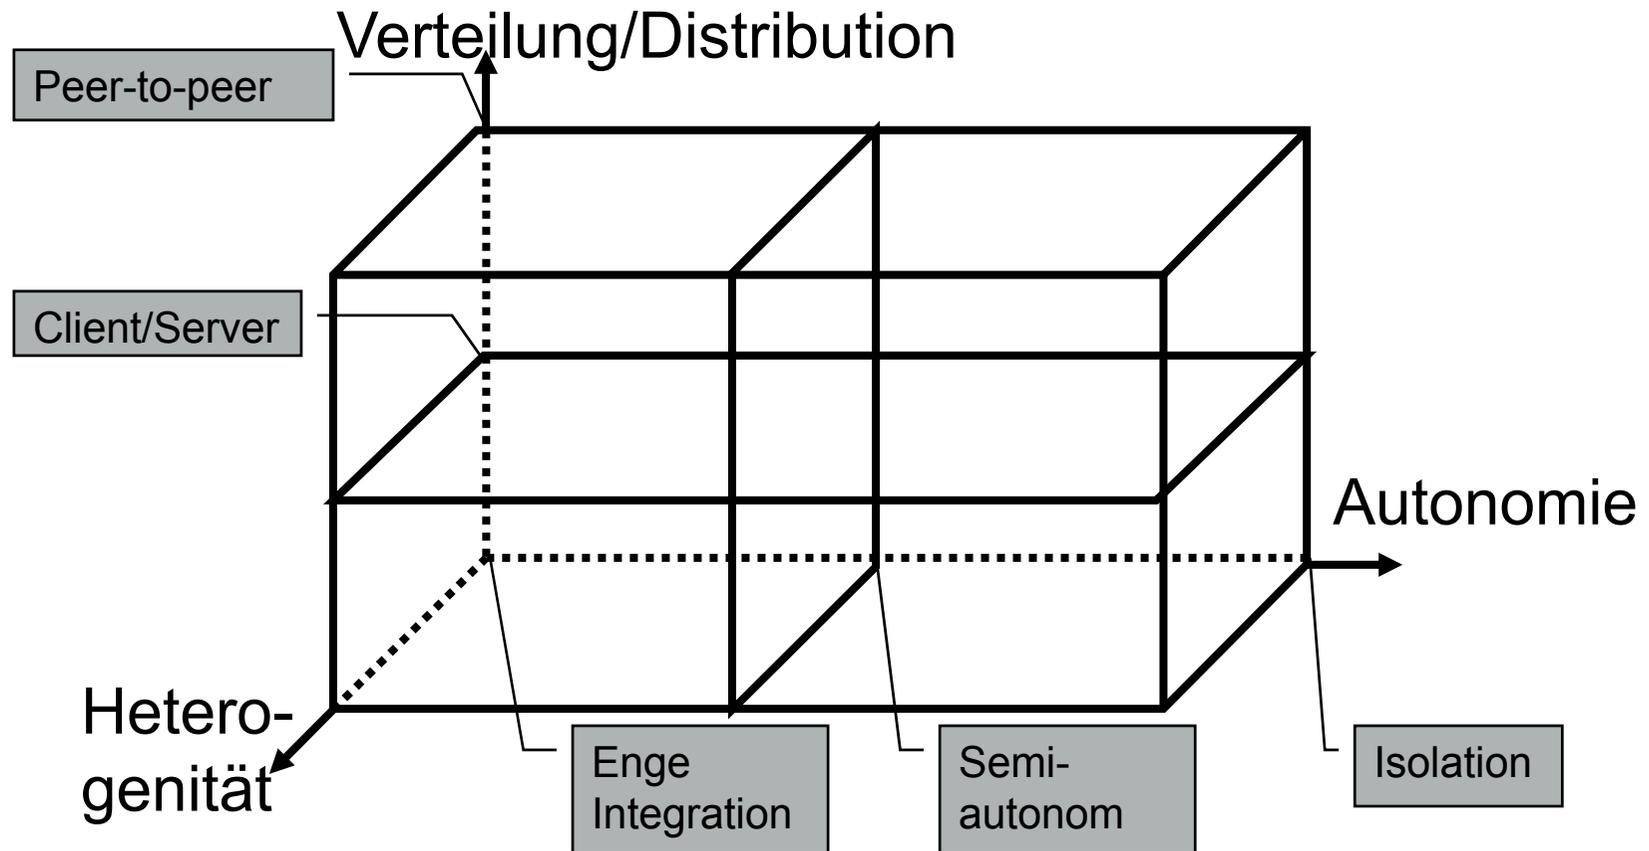
Klassifikation verteilter DBMS [öv91]

4



Klassifikation verteilter DBMS nach [ÖV99]

5



Zusammenhang mit Föderierten DBMS

6

- Verteilung führt zu Autonomie,
 - Intra-Organisation: Historisch
 - Inter-Organisation: Internet & WWW
- und Autonomie führt zu Heterogenität.
 - Verantwortung liegt bei lokalen Administratoren
 - ◇ Systempflege
 - ◇ Nutzbarkeit und Nützlichkeit
 - ◇ Erweiterungen am Informationssystem
 - ◇ Design
 - ◇ ...
- Diskussion
 - Historischer Entwicklung,
 - aber orthogonale Kriterien!

Verteilung (*Distribution*)

7

Ein verteiltes Informationssystem ist eine Sammlung mehrerer, logisch verknüpfter Informationssysteme, die über ein gemeinsames Netzwerk verteilt sind. [ÖV91]

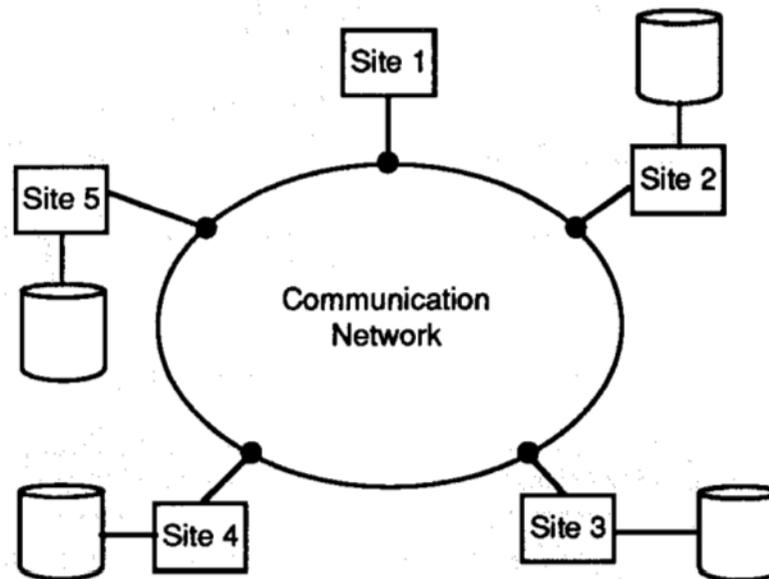


Figure 1.7 DDBS Environment

Physikalische Verteilung

8

- Motiviert durch Hardwareanforderungen (Hardwarebeschränkungen)
- 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

9

- Motiviert durch Anwendungsanforderungen
 - Zuverlässigkeit
 - ◇ Bei Ausfall eines Servers
 - Verfügbarkeit
 - ◇ Bei Ausfall eines Netzwerkteils
 - Effizienz
- Redundanz
 - Replikation
 - Caching
- Partitionierung
 - Vertikal
 - Horizontal

Verteilung – Vor- und Nachteile

10

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

Verteilung – Techniken

11

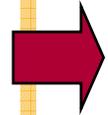
HTTP, CORBA, ... nicht hier.

- Anwendungsentwicklung ohne Spezifikation der physikalischen Präsenz der Komponenten

Annahmen an Transparenz

- Datenunabhängigkeit (jedes DBMS)
 - auch Speicherorttransparenz
- Netzwerktransparenz
- Replikationstransparenz
- Fragmentationstransparenz
 - auch Partitionierungstransparenz

12



- Verteilung
- Autonomie
- Syntaktische Heterogenität
- Strukturelle Heterogenität
- Semantische Heterogenität
 - Namenskonflikte
 - Identität
 - Datenkonflikte
- Gebundene und Freie Variablen
 - Adornments
 - Anfrageplanung



Autonomie (*Autonomy*)

13

Der Grad zu dem verschiedene DBMS unabhängig operieren können.
Bezieht sich auf Kontrolle, nicht auf Daten.

Klassen nach [ÖV99]

- Design-Autonomie
- Kommunikations-Autonomie
- Ausführungs-Autonomie

Design-Autonomie

14

- Auch: Entwurfsautonomie
- Freiheit des lokalen DBMS bezüglich
 - Datenmodell
 - ◇ Relational, hierarchisch, XML
 - Schema
 - ◇ Abdeckung der Domäne (*universe of discourse, miniworld*)
 - ◇ Grad der Normalisierung
 - ◇ Benennung
 - Transaktionsmanagement
 - ◇ Sperrprotokolle
- Freiheit dies jederzeit zu ändern.
 - Besonders problematisch!

Design-Autonomie – Beispiel

15

- Schema und Datenmodell 1

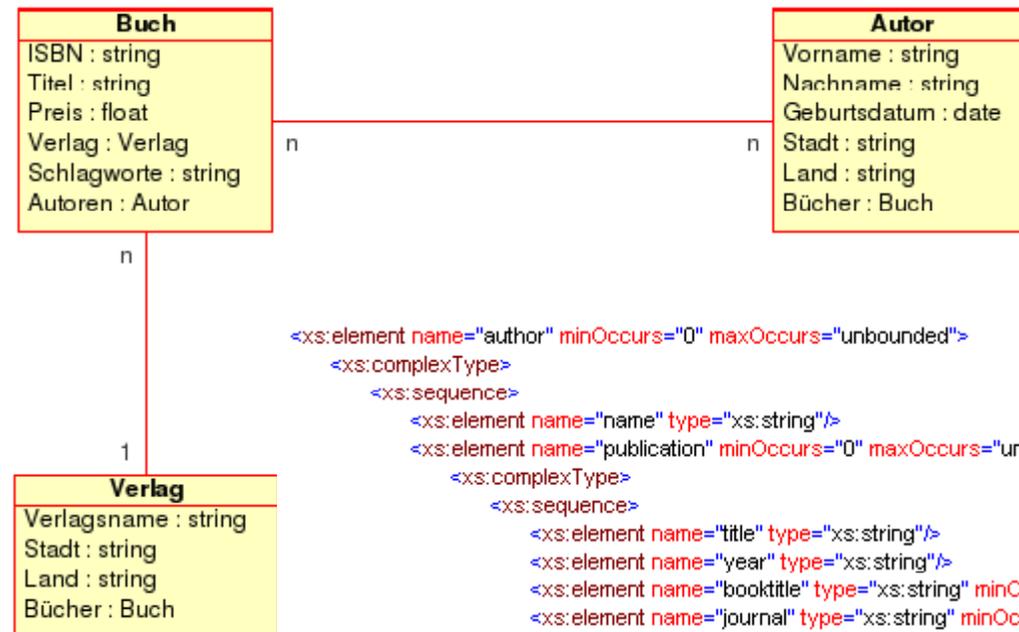
- (Fast) relational

- Flach

- Schema und Datenmodell 2

- XML

- hierarchisch



```

<xs:element name="author" minOccurs="0" maxOccurs="unbounded">
  <xs:complexType>
    <xs:sequence>
      <xs:element name="name" type="xs:string"/>
      <xs:element name="publication" minOccurs="0" maxOccurs="unbounded">
        <xs:complexType>
          <xs:sequence>
            <xs:element name="title" type="xs:string"/>
            <xs:element name="year" type="xs:string"/>
            <xs:element name="booktitle" type="xs:string" minOccurs="0"/>
            <xs:element name="journal" type="xs:string" minOccurs="0"/>
          </xs:sequence>
        </xs:complexType>
      </xs:element>
    </xs:sequence>
  </xs:complexType>
</xs:element>
  
```

Kommunikations-Autonomie

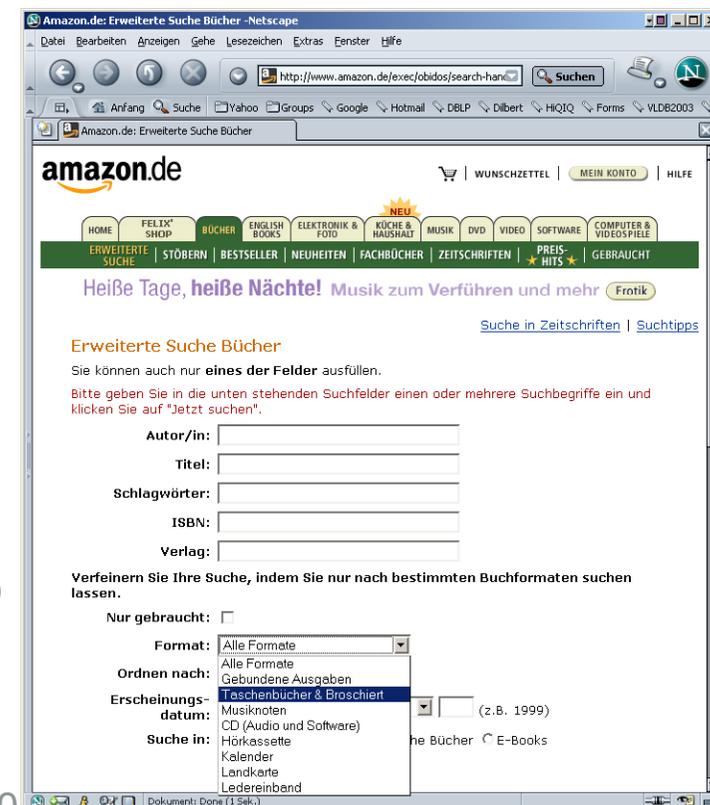
16

- DBMS frei bezüglich
 - Wahl mit welchen Systemen kommuniziert wird
 - Wahl wann mit anderen Systemen kommuniziert wird
 - ◇ Jederzeit Eintritt/Austritt aus integriertem System
 - Wahl was (welcher Teil der Information) kommuniziert wird
 - Wahl wie mit anderen Systemen kommuniziert wird
 - ◇ Anfragesprache
 - Wahl welcher Teil der Anfragemöglichkeiten zur Verfügung gestellt werden
 - ◇ Prädikate
 - ◇ Sortierung
 - ◇ Write
 - ◇ ...

Kommunikations-Autonomie – Beispiel

17

- Extrem 1: Voller SQL Zugang
 - z.B. via JDBC
 - Transaktionen
 - Optimierung
 - Lesend (und Schreibend?)
 - Schemaveränderungen?
 - Antwort als Ergebnisrelation
- Extrem 2: HTML Formular
 - Nur ein (oder mehr) Suchfelder
 - Antwort als HTML Text
 - Nur Teile der Daten (public area)



Ausführungs-Autonomie

18

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

Ausführungs-Autonomie – Beispiel

19

- Optimierung und Scheduling
 - Behandlung externer vs. lokaler Anfragen
 - *Golden customers*
 - Garantierte Antwortzeiten

- Transaktionen
 - Dirty-read egal?



Autonomie → Heterogenität

20

- Verteilung als „Ursache“ für Autonomie
- Autonomie als Ursache für Heterogenität:
 - Autonome Systeme
 - ⇒ Gestaltungsfreiheit
 - ⇒ Unterschiedliche Entscheidungen
 - ⇒ Heterogenität

Heterogenität (*Heterogeneity*)

21

Heterogenität herrscht, wenn sich zwei miteinander verbundene Informationssysteme syntaktisch, strukturell oder inhaltlich unterscheiden.

- Syntaktische Heterogenität
 - Auch: „Technische Heterogenität“
- Strukturelle Heterogenität
- Semantische Heterogenität

Heterogenitäten zu überbrücken ist die Kernaufgabe der Informationsintegration.

Heterogenitätsklassen

22

- Auch andere Klassifikationen möglich, z.B. [BKLW99]
 - Syntaktische Heterogenität
 - Datenmodell Heterogenität
 - Logische Heterogenität

- Oder nach [SPD92]
 - Semantische Konflikte
 - Beschreibungskonflikte
 - Heterogenitätskonflikte
 - Strukturelle Konflikte
 - Datenkonflikte

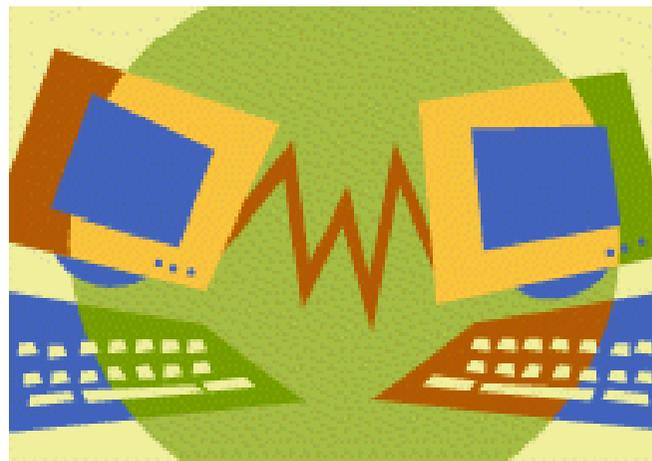
- Verteilung
- Autonomie
- ➔ ■ Syntaktische Heterogenität
- Strukturelle Heterogenität
- Semantische Heterogenität
 - Namenskonflikte
 - Identität
 - Datenkonflikte
- Gebundene und Freie Variablen
 - Adornments
 - Anfrageplanung



Syntaktische Heterogenität

24

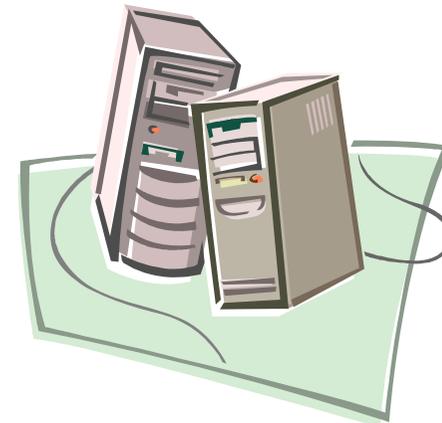
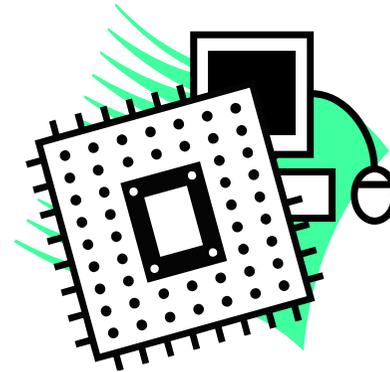
- Hardware-Heterogenität
- Software-Heterogenität
- Schnittstellen-Heterogenität



Hardware Heterogenität

25

- Bandbreite
- Hauptspeicher
- CPU
 - Art
 - Geschwindigkeit



Nicht hier

Software Heterogenität

26

- Betriebssystem
- Dateisystem
- Protokolle
 - HTTP, ODBC, Java API, CORBA, etc.
- Zustandsbehaftet vs. zustandsfrei
- Sicherheit
 - Security level
 - Log-on Prozedur



Software Heterogenität – Beispiel

27

```
String sqlQuery = „SELECT Name, Strasse FROM Hersteller  
WHERE PLZ = 69115“;  
...  
Connection jdbcCon = DriverManager.getConnection(dbURL, ...);  
Statement stmt = jdbcCon.createStatement();  
ResultSet table = stmt.executeQuery(sqlQuery);  
...
```

```
String webQuery = „plz=69115“;  
...  
URL url = new URL(„http://www.system2.de/cgi-bin  
/search.cgi“ + „?“ + webQuery);  
URLConnection urlCon = new url.openConnection();  
InputStreamReader reader = new InputStreamReader(  
    urlCon.openStream());  
...
```

Nicht hier

Quelle: VL: Föderierte
Datenbanksysteme
Peter Tomczyk, FZI &
Uni Karlsruhe

Schnittstellen Heterogenität

28

Schnittstellen von Informationssystemen sind im wesentlichen deren
Anfragensprache:

- HTML Formular,
- „Google“-Sprache (+, - , ...),
- SQL,
- XQuery,
- etc.

Jetzt hier!

Schnittstellen Heterogenität

29

- 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 [RSU95,LC00,YLGU99]
 - später
- Andere Einschränkungen
 - Joins über maximal 3 Relationen
 - z.B. Prädikate nur über eine Auswahl von Werten

Schnittstellen Heterogenität - Beispiel

30

The screenshot shows the Netscape 7.0 email interface. The search dialog box is open, showing the search criteria: "Nach Nachrichten suchen in: Lokale Ordner". The search logic is set to "Mindestens einer der folgenden Faktoren muss zutreffen". The search criteria are: "Betreff" "enthält" "integration", "Betreff" "enthält nicht" "Humboldt", and "Betreff" "enthält" (with a dropdown menu open showing options: "enthält", "enthält nicht", "gleich", "ungleich", "beginnt mit", "endet mit").

Annotations:

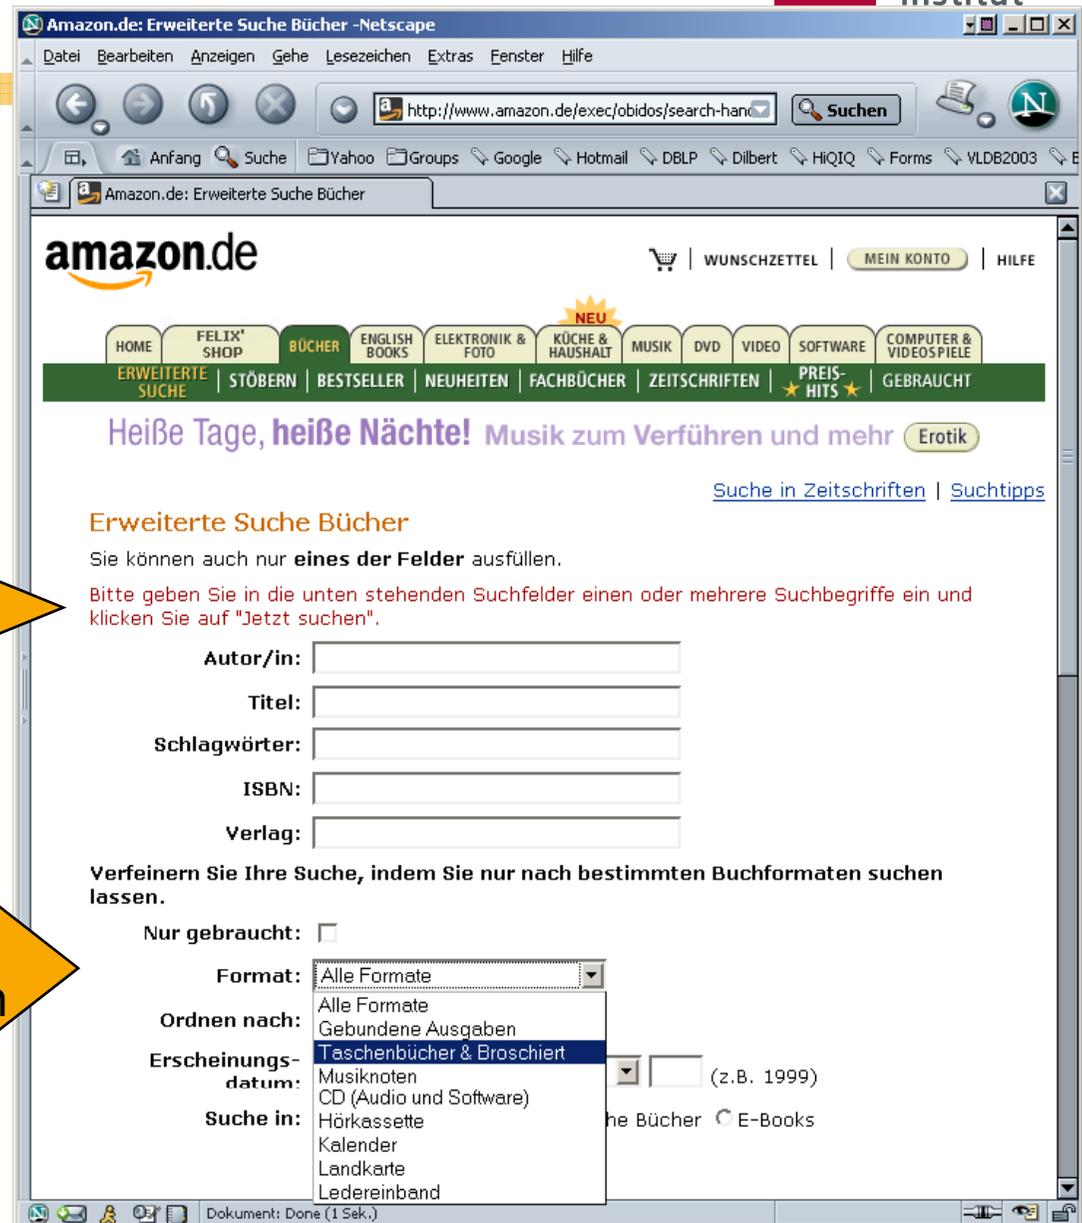
- Suche**: Points to the search input field containing "integration".
- Konjunktion/Disjunktion**: Points to the search logic options: "Alle folgenden Faktoren müssen zutreffen" and "Mindestens einer der folgenden Faktoren muss zutreffen".
- gleich/ungleich**: Points to the comparison operators in the dropdown menu: "gleich" and "ungleich".

Schnittstellen-Heterogenität – Beispiel

31

Gebundene Variablen

Prädikat nur mit
Auswahl von Werten



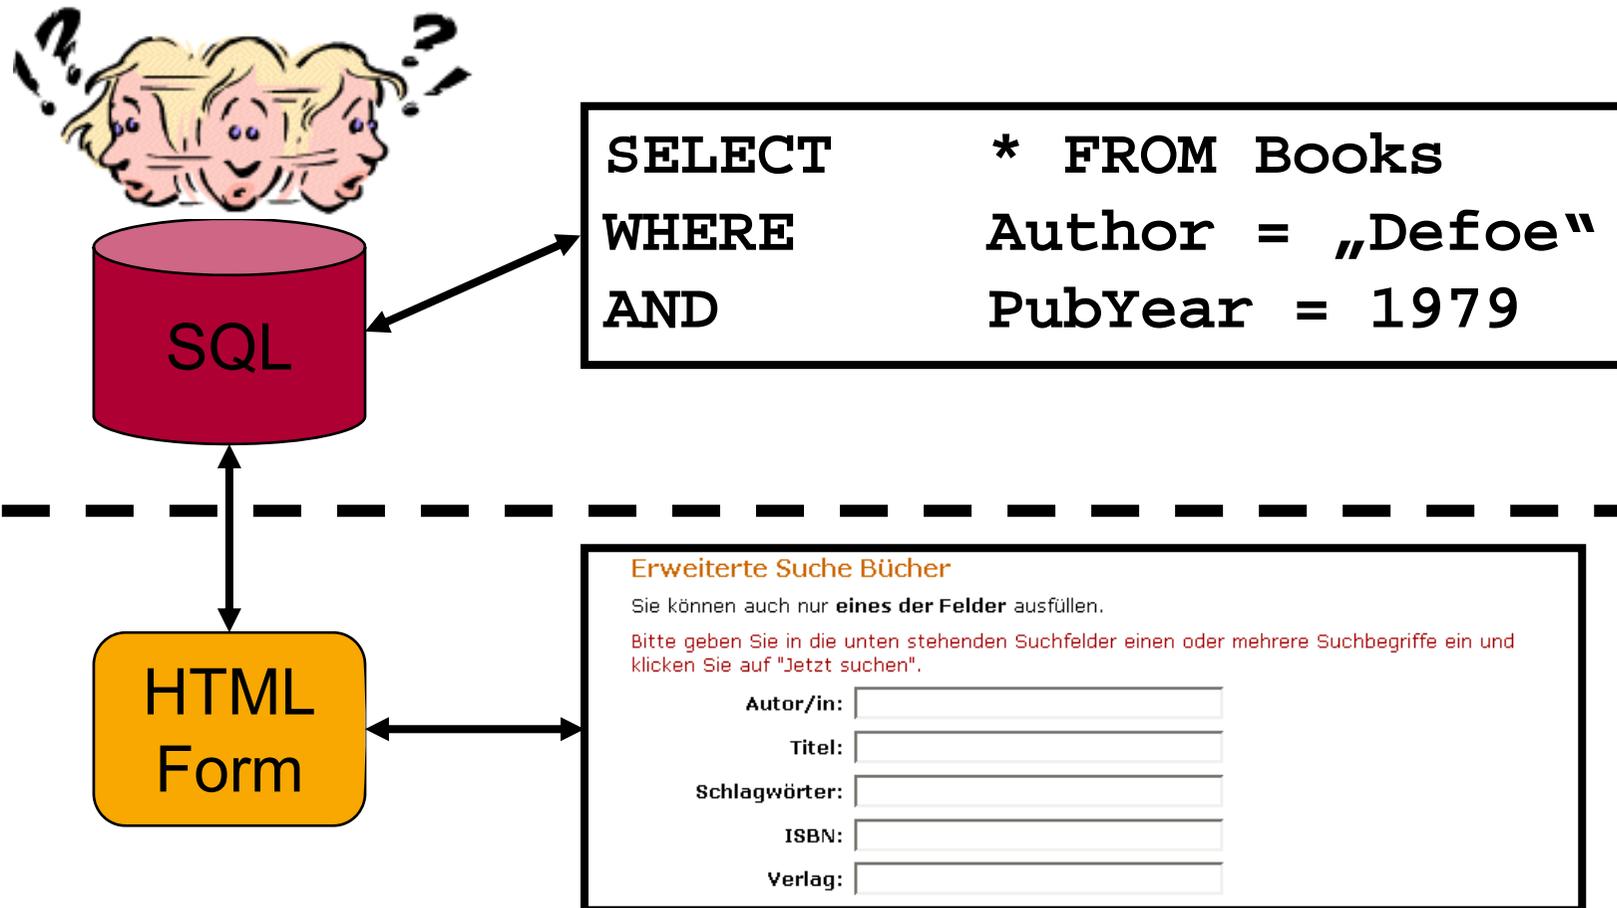
Schnittstellen Heterogenität

32

- In einzelnen Systemen kein Problem
- Probleme für integrierte Systeme
 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

Mächtige globale Anfragesprache

33



Mächtige globale Anfragesprache

34

```
SELECT * FROM Books
WHERE Author = „Defoe“
AND PubYear = 1979
```

```
Daniel Defoe, Robinson Crusoe, 1979
```

```
PubYear = 1979
```

```
Daniel Defoe, Robinson Crusoe, 1986
Daniel Defoe, Robinson Crusoe, 1979
Daniel Defoe, Moll Flanders, 1933
```

Erweiterte Suche Bücher

Sie können auch nur **eines der Felder** ausfüllen.

Bitte geben Sie in die unten stehenden Suchfelder einen oder mehrere Begriffe ein und klicken Sie auf "Jetzt suchen".

Autor/in:

Titel:

Schlagwörter:

ISBN:

Verlag:

Mächtige globale Anfragesprache

35

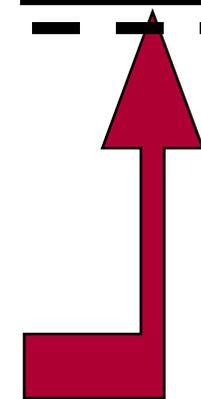
```
SELECT * FROM Books
WHERE Author = „Defoe“
AND PubYear > 1979
```

```
Daniel Defoe, Robinson Crusoe, 1979
Daniel Defoe, Robinson Crusoe, 1986
```



PubYear > 1979

```
Daniel Defoe, Robinson Crusoe, 1986
Daniel Defoe, Robinson Crusoe, 1979
Daniel Defoe, Moll Flanders, 1933
```



Erweiterte Suche Bücher

Sie können auch nur **eines der Felder** ausfüllen.
 Bitte geben Sie in die unten stehenden Suchfelder einen oder mehrere Begriffe ein und klicken Sie auf "Jetzt suchen".

Autor/in:

Titel:

Schlagwörter:

ISBN:

Year:

Mächtige lokale Anfragesprache

36



HTML Form

Erweiterte Suche Bücher
Sie können auch nur **eines der Felder** ausfüllen.
Bitte geben Sie in die unten stehenden Suchfelder einen oder mehrere Suchbegriffe ein und klicken Sie auf "Jetzt suchen".

Autor/in:
Titel:
Schlagwörter:
ISBN:
Verlag:

SQL

```
SELECT * FROM Books  
WHERE Author = „Defoe“
```

Verpasste Chancen.

Gebundene & Freie Variablen

37

- **Gebundene Variablen** müssen bei einer Anfrage gebunden werden.
 - z.B.: „Search“-Feld bei Google
- **Freie Variablen** müssen nicht gebunden werden.
 - z.B. „Autor“-Feld bei Amazon.de, falls Titel gebunden ist.

Gebundene & Freie Variablen – Beispiel & Ausblick

38

SONGS	Song	CD
	Friends	Life
	Friends	Love

CDs	CD	Künstler	Preis
	Love	Lucy	15
	Story	Snoopy	14

Künstler	CD	Künstler	Preis
	Story	Lucy	13
	Love	Snoopy	10
	Life	Charlie	8

Bastelaufgabe 1:
Wie teuer ist die billigste CD mit einem Song namens "Friends"?

Quelle: [LC00]

Gebundene & Freie Variablen – Beispiel & Ausblick

39

SONGS	<u>Song</u>	CD
	Friends	Life
	Friends	Love

CDs	<u>CD</u>	Künstler	Preis
	Love	Lucy	15
	Story	Snoopy	14

Künstler	CD	<u>Künstler</u>	Preis
	Story	Lucy	13
	Love	Snoopy	10
	Life	Charlie	8

Unterstrichen
= gebundene
Variable

Bastelaufgabe 2:
Welches ist die billigste CD mit einem Song namens "Friends", *die Sie anfragen können?*

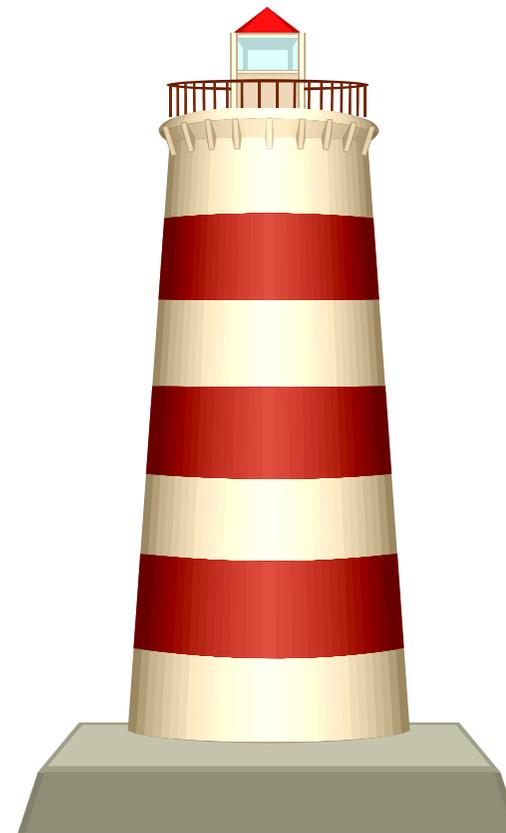
Mehr später...

Syntaktische Heterogenität - Zusammenfassung

40

- Hardware Heterogenität
 - Bandbreite, CPU, ...
- Software Heterogenität
 - Protokolle, Sicherheit, ...
- Schnittstellen Heterogenität
 - Mächtigkeit der Anfragesprachen
 - Gebundene & freie Variablen

- Verteilung
- Autonomie
- Syntaktische Heterogenität
- Strukturelle Heterogenität
- Semantische Heterogenität
 - Namenskonflikte
 - Identität
 - Datenkonflikte
- Gebundene und Freie Variablen
 - Adornments
 - Anfrageplanung



Strukturelle Heterogenität

42

- Datenmodell-Heterogenität
 - Unterschiedliche Semantik
 - Unterschiedliche Struktur
- Schematische Heterogenität
 - Integritätsbedingungen, Schlüssel, Fremdschlüssel, etc.
 - Schema (Attribut vs. Relation etc.)
 - Struktur (Gruppierung in Tabellen)

Datenmodell-Heterogenität

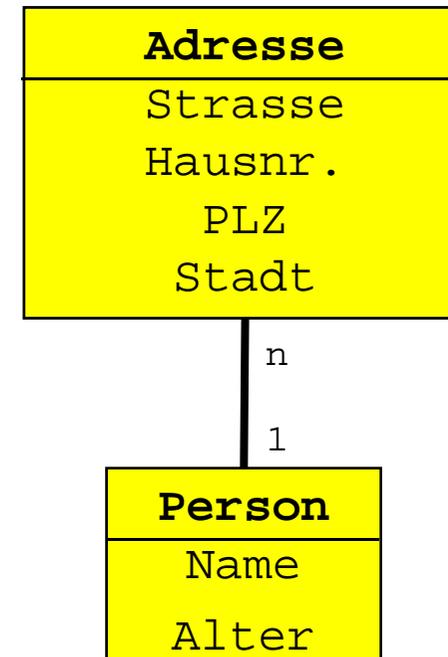
43

Datenmodelle

- Relationales Modell
- XML Modell
- OO Modell
- Hierarchisches Modell

```
Adresse(PersonId, Strasse,
        Hausnr., PLZ, Stadt)
```

```
Person( Id, Name, Alter)
```



Schematische Heterogenität

44

- Struktur
 - Modellierung
 - ◇ Relation vs. Attribut
 - ◇ Attribut vs. Wert
 - ◇ Relation vs. Wert
 - Benennung
 - ◇ Relationen
 - ◇ Attribute
 - ◇ Jeweils Homonyme und Synonyme
 - Normalisiert vs. Denormalisiert
 - Geschachtelt vs. Fremdschlüssel

- Diese Probleme sogar bei gleichem Datenmodell!

Schematische Heterogenität

45



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

Relation vs. Attribut

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

Relation vs. Wert

```
Person( Id, Vorname,
        Nachname, Geschlecht)
```

Attribut vs. Wert

Schematische Heterogenität

46

Tabellen-Tabellen Konflikte

- Namenskonflikte
 - Semantisch gleiche Tabellen mit verschiedenen Namen (Synonym)
 - Verschiedene Tabellen mit gleichem Namen (Homonym)
- Strukturkonflikte
 - fehlende Attribute
 - fehlende, aber ableitbare Attribute
- IC-Konflikte (Integrity-Constraint = Integritätsbedingungen)

Schematische Heterogenität – Beispiel

47

mitarbeiter			
p_id	vorname	nachname	funktion
1	Peter	Müller	Sachbearb.
5	Petra	Weger	Sekr.
...

mitarbeiter (leitend)		
p_id	vorname	name
2	Stefanie	Meier
2	Petra	Weger
2	Andreas	Zwickel
...

Homonym

Fehlendes (ableitbares) Attribut

IC Konflikt (Eindeutigkeit)

Schematische Heterogenität

48

Attribut-Attribut Konflikte

- Namenskonflikte
 - Verschiedene Namen für gleiche Attribute (Synonyme)
 - Gleiche Namen für verschiedene Attribute (Homonyme)
- Default-Wert-Konflikte
- IC-Konflikte
 - Datentypkonflikte
 - Bedingungskonflikte

Schematische Heterogenität – Beispiel

49

mitarbeiter			
p_id	Vorname VARCHAR(35)	nachname	alter
1	Wolfgang	Meyer	33
5	Klaus	Schmidt	NULL
...

IC: alter > 18

mitarbeiter			
p_id	Vorname VARCHAR(20)	name	alter
1	Peter	Müller	0
5	Petra	Weger	17
...

Synonym

Default Werte

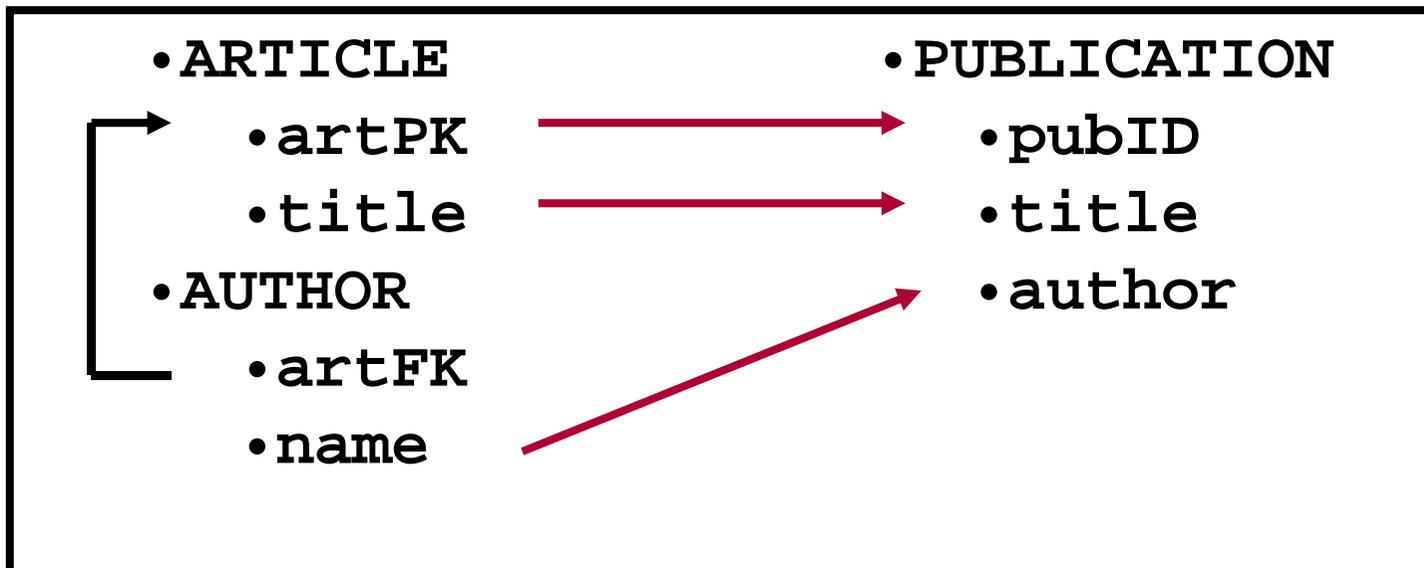
Datentypkonflikt

Schematische Heterogenität - Beispiel

50

Normalisiert vs. Denormalisiert

- 1:1 Assoziationen zwischen Werten wird unterschiedlich dargestellt
 - Durch Vorkommen im gleichen Tupel
 - Durch Schlüssel-Fremdschlüssel Beziehung

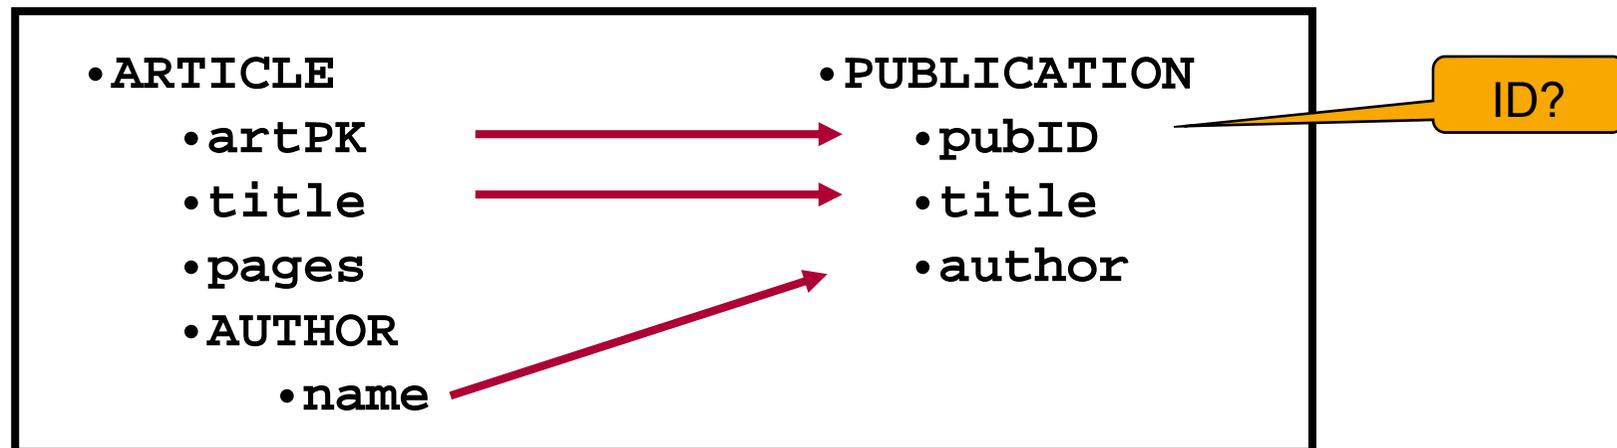


Schematische Heterogenität - Beispiel

51

Geschachtelt vs. Flach

- 1:n Assoziationen werden unterschiedlich dargestellt
 - Als geschachtelte Elemente
 - Als Schlüssel-Fremdschlüssel Beziehung



Schematische Heterogenität - Lösungen

52

- Problem
 - Einheitlich auf beide Schemas zugreifen
 - ◇ Auf Schemaebene: Schema Mapping und Schema-Sprachen
 - ◇ Auf Datenebene: Virtuelle Integration
 - Beide Schemas in eine gemeinsames neues Schema integrieren
 - ◇ Auf Schemaebene: Schemaintegration
 - ◇ Auf Datenebene: Materialisierte Integration
- Für die materialisierte Integration
 - Schemaintegration
 - ETL
- Für die virtuelle Integration
 - Schema-Sprachen
 - ◇ Z.B. SchemaSQL, MSQL, CPL
 - Schema Mapping
 - ◇ Z.B. Clio, RONDO, u.a.

Schematische Heterogenität – Lösungen (Ausblick)

53

SchemaSQL [LSS96]

- Erweiterung von SQL
- Daten und Metadaten werden gleich behandelt
- Umstrukturierungen innerhalb der Anfrage
- Dynamische Sicht-Definition
- Horizontale Aggregation

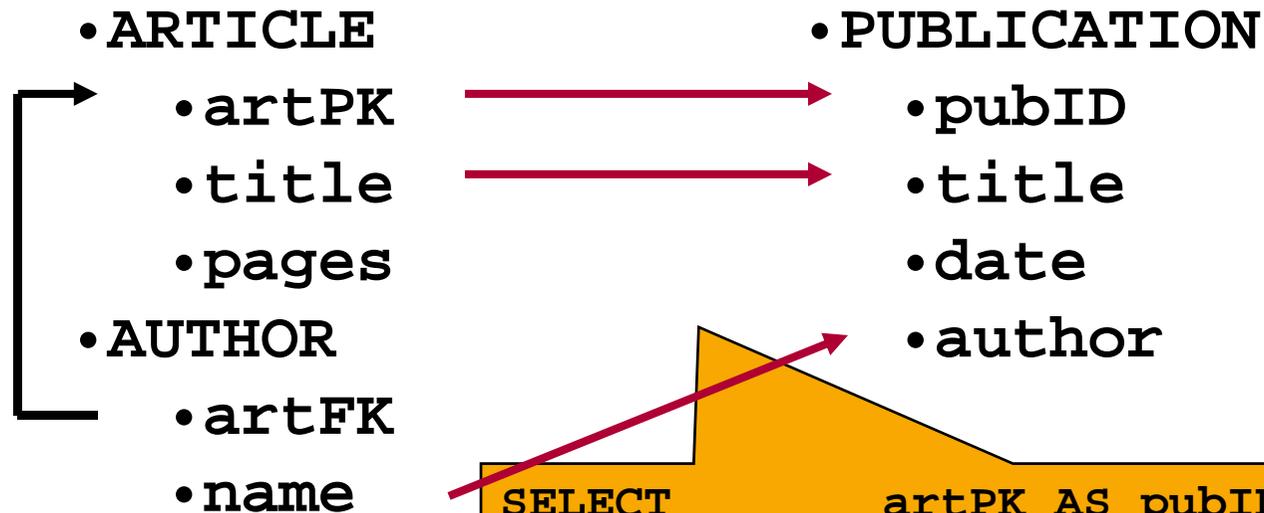
```
SELECT RelA
FROM uniA->RelA, uniA::RelA A, uniB::grundgehalt B
WHERE RelA = B.institut
AND A.Kategorie = „Student“
AND A.grundgehalt > B.Student
```

High-order Join

Schematische Heterogenität – Lösungen (Ausblick)

54

Schema Mapping



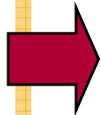
```
SELECT      artPK AS pubID
            title AS title
            null AS date
            name AS author
FROM        ARTICLE, AUTHOR
WHERE       ARTICLE.artPK = AUTHOR.artFK
```

Zusammenfassung

55

- Verteilung
- Autonomie
 - Design-Autonomie
 - Kommunikations-Autonomie
 - Ausführungs-Autonomie
- Heterogenität
 - Syntaktische Heterogenität
 - ◇ Hardware Heterogenität
 - ◇ Software Heterogenität
 - ◇ Schnittstellen Heterogenität
 - Strukturelle Heterogenität
 - ◇ Datenmodell-Heterogenität
 - ◇ Schematische Heterogenität

- Verteilung
- Autonomie
- Syntaktische Heterogenität
- Strukturelle Heterogenität
- Semantische Heterogenität
 - Namenskonflikte
 - Identität
 - Datenkonflikte
- Gebundene und Freie Variablen
 - Adornments
 - Anfrageplanung



Fremdwörterduden "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.“

[ÖV91]

Semantik vs. Struktur

58

Strukturelle Heterogenität

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

Männer(<u>Id</u> , Vorname, Nachname)	A(<u>Id</u> , X, Y)
Frauen(<u>Id</u> , Vorname, Nachname)	B(<u>Id</u> , X, Y)
Person(<u>Id</u> , Vorname, Nachname, Männlich, weiblich)	P(<u>Id</u> , X, Y, a, b)

Semantische Heterogenität

- Betrifft Daten
- Betrifft „Bedeutung“

Unterschiedliche Namen

59

- Die Probleme (Überblick)
 - Konzept (z.B. Gen)
 - ◇ Definition des Konzepts
 - Synonyme (z.B. surname vs. last name)
 - Homonyme (z.B. biweekly)
 - Einheiten (z.B. cm vs. inch)
 - Werte (z.B. „manager“)
- Eher auf Schema Ebene

Konzept

60

- Definition eines Konzepts
 - Noch nicht einmal hier sind sich immer alle einig.
 - Gen, Transaktion, Bestellung, Mitarbeiter
- Semantisch überlappende Weltausschnitte mit einander entsprechenden Klassen
- Korrespondenzarten zwischen Klassenextensionen:
 - $A = B$ Äquivalenz
 - $A \subseteq B$ Inklusion
 - $A \cap B$ Überlappung
 - $A \neq B$ Disjunktion

„Wie viele Mitarbeiter hat IBM?“

- Definition Mitarbeiter:
 - temporäre MA
 - Diplomanden
 - Berater
 - Studentische Mitarbeiter
 - Stellen oder Köpfe?
- Definition IBM
 - Welche Region? Welcher Geschäftsbereich?
 - Informix?
 - PWC?
- Welcher Zeitpunkt?
- Definition der Zählung:
 - Doppelte Zählung bei mehreren Anstellungen?

„Wieviele Hardware haben
wir ans HPI verkauft?“

Synonyme

62

- Verschiedene Worte mit gleicher Bedeutung
- Im Kontext der zu integrierenden Datenbanken

DB1:

Angestellter(Id, Vorname, Name, männlich, weiblich)

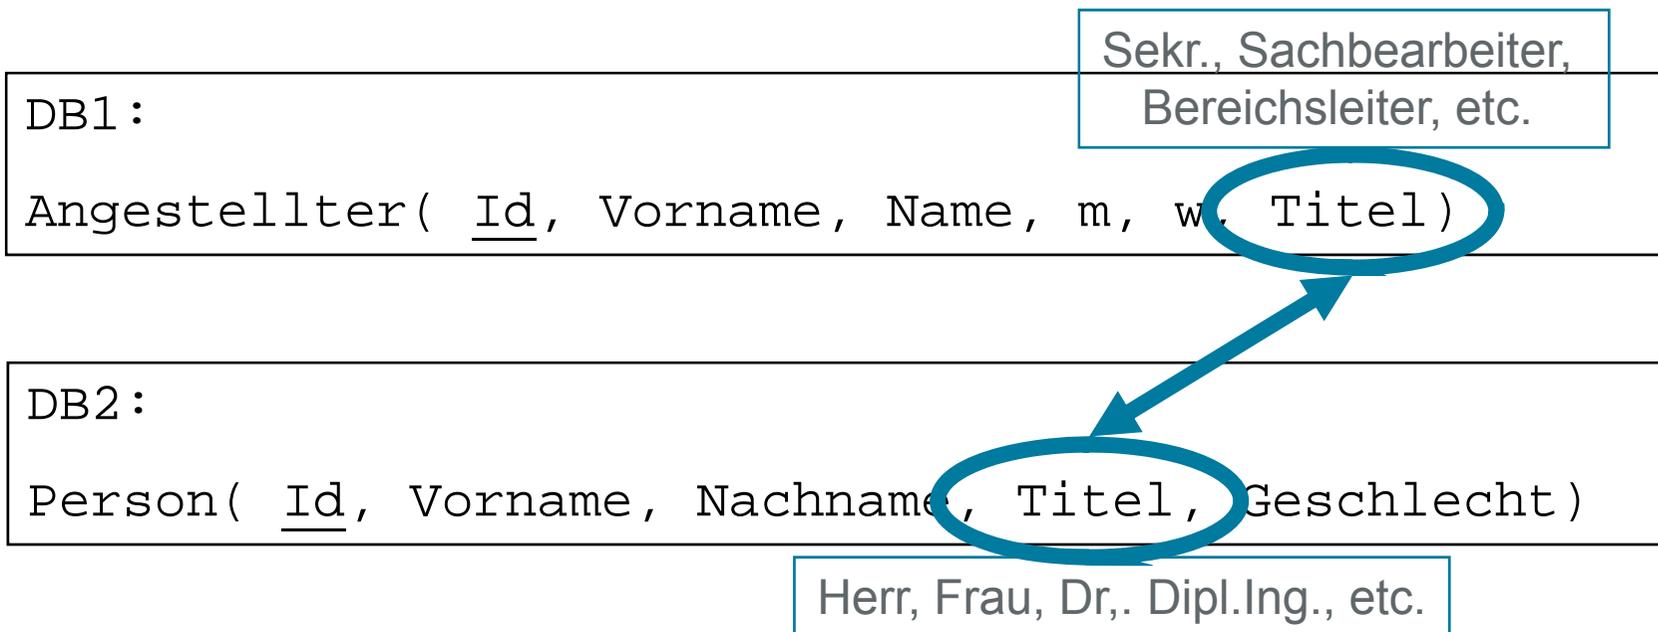
DB2:

Person(Id, Vorname, Nachname, Geschlecht)

Homonyme

63

- Gleiche Worte verschiedener Bedeutung
- Andere Domäne
- Andere Bedeutung



Andere -nym Wörter

64

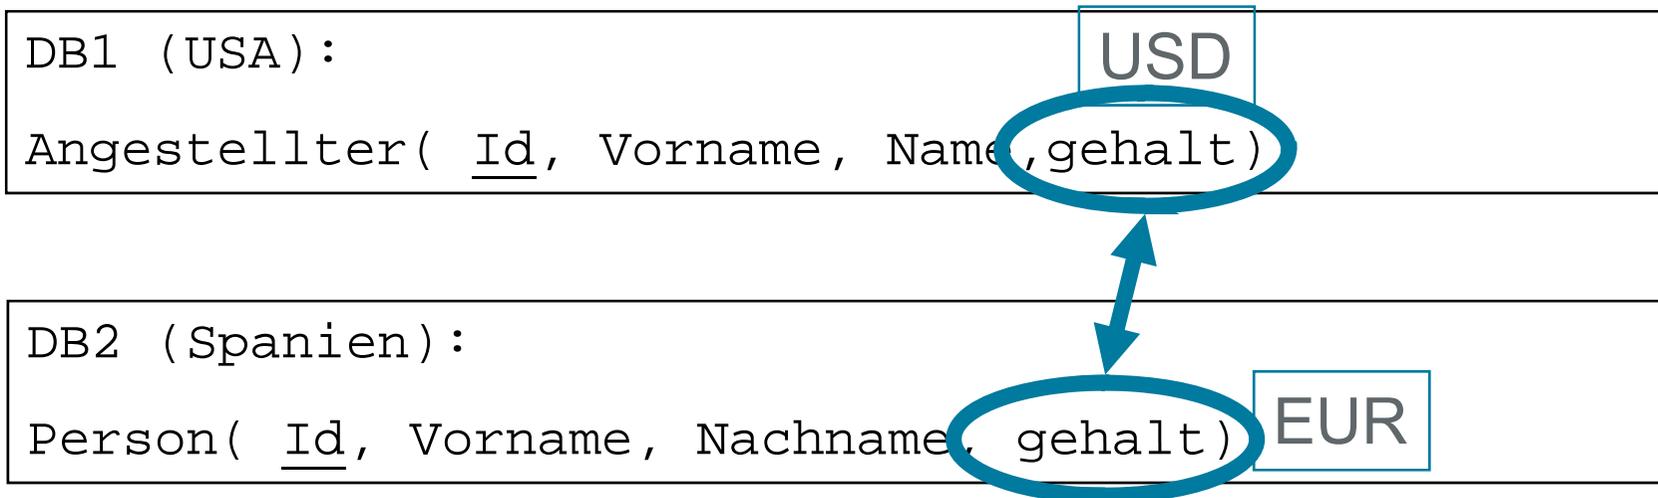
- Synonym
 - Verschiedene Wörter, gleiche Semantik
- Homonym
 - Gleiche Wörter, verschiedene Semantik
- Antonym
 - Verschiedene Wörter, gegenteilige Semantik
- Auto-Antonym:
 - ◇ Gleiche Wörter, gegenteilige Semantik
 - ◇ Transparenz, aufheben, umfahren, Quantensprung, Kriegsgegner, ...
 - ◇ Overlook
- Heteronym
 - Gleiche Schreibung, verschiedene Aussprache, verschiedene Semantik
 - ◇ Read, lead, bass, close, ...
- Autonym (selbstbeschreibend, Wort = Semantik, „Substantiv“)
- Pseudonym u.v.a.m.

- http://www.fun-with-words.com/nym_words.html

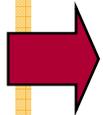
Einheiten

65

- Gleiche „Bedeutung“ aber anderes Maß.
- Werden auch als Homonym bezeichnet, da anderes Maß eine andere Bedeutung erzeugt.



- Verteilung
- Autonomie
- Syntaktische Heterogenität
- Strukturelle Heterogenität
- Semantische Heterogenität
 - Namenskonflikte
 - Identität
 - Datenkonflikte
- Gebundene und Freie Variablen
 - Adornments
 - Anfrageplanung

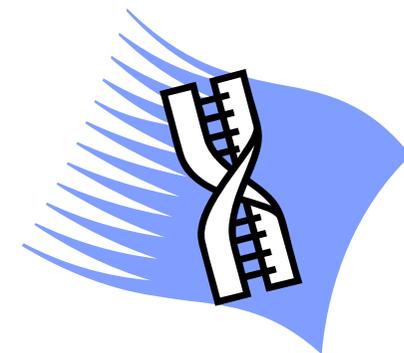


- Drei zentrale Fragen
 - Was ist ein Objekt?
 - ◇ XML: Über mehrere Schachtelungsebenen hinweg
 - ◇ Relationales Modell: Über mehrere Relationen hinweg
 - Repräsentiert Objekt A die gleiche Entität wie Objekt B?
 - Wie finde ich effizient gleiche Repräsentationen?
- Namen des Problems
 - Duplikaterkennung 
 - Objektidentifikation
 - Record Linkage
 - Data Cleansing
 - ...
- Auf Datenebene

Typische Anwendungen

68

- Personen- und Adressdaten
 - Volkszählungen
 - Werbeaktionen
 - Kundenpflege
- Molekularbiologische Daten
- Bibliographische Daten
 - Zentrale Register
- Typische Merkmale zur Entstehung:
 - Gleiches Objekt mehrfach beobachtet
 - Manuelle Erfassung der Daten
 - Objekt ändert Eigenschaften von Zeit zu Zeit
 - Keine global konsistente ID
 - ◇ ISBN, IBAN, URL, ISO, EAN, SSN, etc.



Duplikaterkennung

69

- Duplikate in Relationen
 - Zwei Tupel, die das gleiche real-world Objekt repräsentieren
 - Semantik!
 - Attributwerte dürfen sich unterscheiden.
- Formales Problem
 - Eine Tabelle (der Größe N), potentiell mit Duplikaten
 - Erzeuge für jedes Tupel einen Identifier, so dass Duplikate gleiche Identifier erhalten
- Problemerweiterungen
 - Zwei Tabellen mit unterschiedlichem Schema
 - Ein XML Dokument mit Duplikaten

Duplikaterkennung

70

- Praktisches Problem
 - Wie entscheide ich, ob zwei Tupel das gleiche Objekt repräsentieren?
 - Ähnlichkeitsmaße und Klassifikation
 - ◇ Edit-Distance
 - ◇ N-grams
 - ◇ IDs
 - ◇ Wahrscheinlichkeitstheoretische Ansätze
 - ◇ Maschinelles Lernen
 - ◇ Augenschein

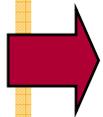
Duplikaterkennung

71

- Praktisches Problem
 - Sehr große Datenmenge
 - ◇ Millionen Tupel
 - Kein quadratischer Algorithmus
 - Kein Hauptspeicher-Algorithmus
- Als SQL Anfrage
 - Sei R die Relation mit Duplikaten
 - `SELECT C1.*, genID(C1,C2)`
`FROM R as C1, R as C2`
`WHERE M(C1,C2)`
- Schwieriger als normaler Join
 - Ähnlichkeitsmaß ist nicht nur Gleichheit
- Algorithmen zur Objektidentifikation in SE „Duplikaterkennung“ und Übung



- Verteilung
- Autonomie
- Syntaktische Heterogenität
- Strukturelle Heterogenität
- Semantische Heterogenität
 - Namenskonflikte
 - Identität
 - Datenkonflikte
- Gebundene und Freie Variablen
 - Adornments
 - Anfrageplanung



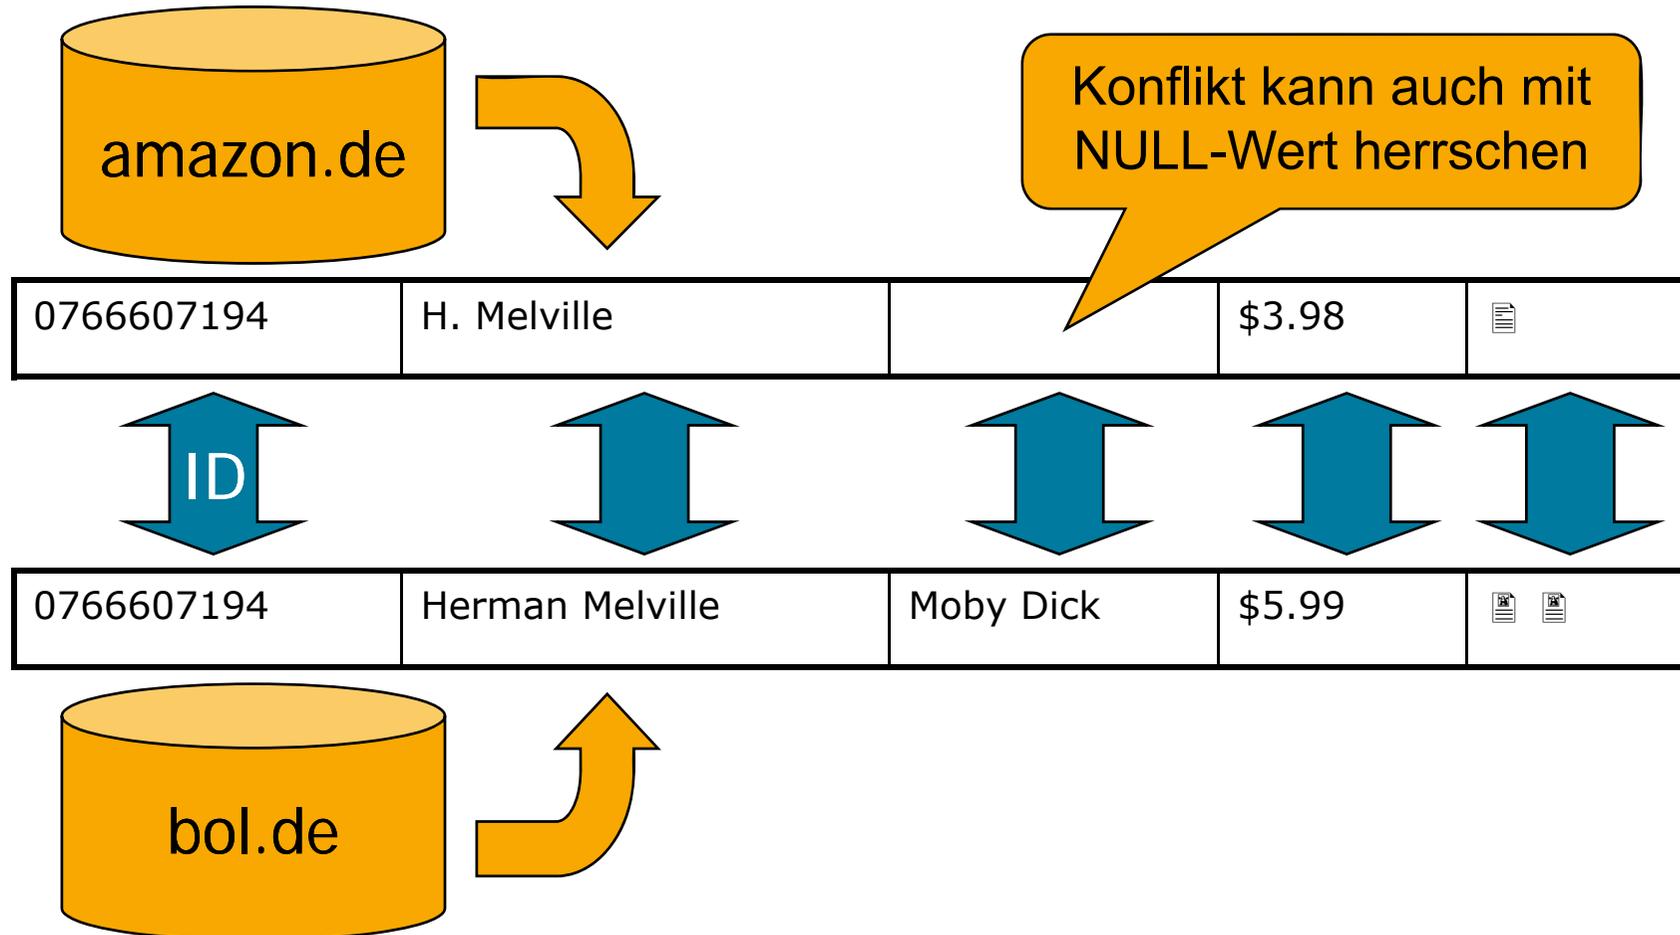
Datenkonflikte

73

- Datenkonflikt:
 - Zwei Duplikate haben unterschiedliche Attributwerte für ein semantisch gleiches Attribut.
 - Im Gegensatz zu Konflikten mit Integritätsbedingungen
- Datenkonflikte entstehen
 - innerhalb eines Informationssystems (intra-source) und
 - bei der Integration mehrerer Informationssysteme (inter-source).
- Voraussetzung:
 - Duplikat!
 - d.h. Identität schon festgestellt.

Datenkonflikte - Beispiel

74



Datenkonflikte – Entstehung

75

Innerhalb eines Informationssystems

- Mangels Integritätsbedingungen oder Konsistenz-Checks
- Bei redundanten Schemata
- Bei Entstehung von Duplikaten
- Nicht korrekte Einträge
 - Tippfehler, Übertragungsfehler
 - Falsche Rechenergebnisse
- obsoleete Einträge
 - div. Aktualisierungszeitpunkte
 - ◇ ausreichende Aktualität einer Quelle
 - ◇ verzögerte Aktualisierung
 - vergessene Aktualisierung

Datenkonflikte – Entstehung

76

Innerhalb eines Informationssystems

- bei div. Datentypen (mit/ohne Codierung)
 - 1,2,...,5 bzw. "sehr gut", "gut", ..., "mangelhaft"
- bei gleichem Datentyp
 - Schreibvarianten
 - ◇ Kantstr. Kantstrasse Kant Str. Kant Strasse
 - ◇ Kolmogorov Kolmogoroff Kolmogorow
 - Typische Verwechslungen $U \Leftrightarrow V$,
 $0 \Leftrightarrow o$, usw. (OCR)

Datenkonflikte – Behebung

77

- Referenztabelle für exakte Wertabbildung
 - Z.B. Städte, Länder, Produktnamen, Codes...
- Ähnlichkeitsmaße
 - bei Tippfehlern
 - bei Sprachvarianten (Meier, Mayer,...)
- Standardisieren und transformieren
- Nutzung von Hintergrundwissen (Metadaten)
 - bzgl. von Konventionen (landestypische Schreibweisen)
 - Ontologien zur Behandlung von Zusammenhängen
 - Thesauri, Wörterbücher zur Behandlung von Homonymen, Synonymen, ...

Datenkonflikte – Entstehung

78

Bei der Integration von Informationssystemen

- Lokal konsistent aber global inkonsistent
- Duplikate (extensionale Redundanz)
- Andere Datentypen
- Lokale Schreibweisen/Konventionen

Datenkonflikte – Behebung

79

- Präferenzordnung über Datenquellen
 - nach Aktualität, Trust (Vertrauen), Öffnungszeiten usw.
- Informationsqualität
- Konfliktlösfunktionen

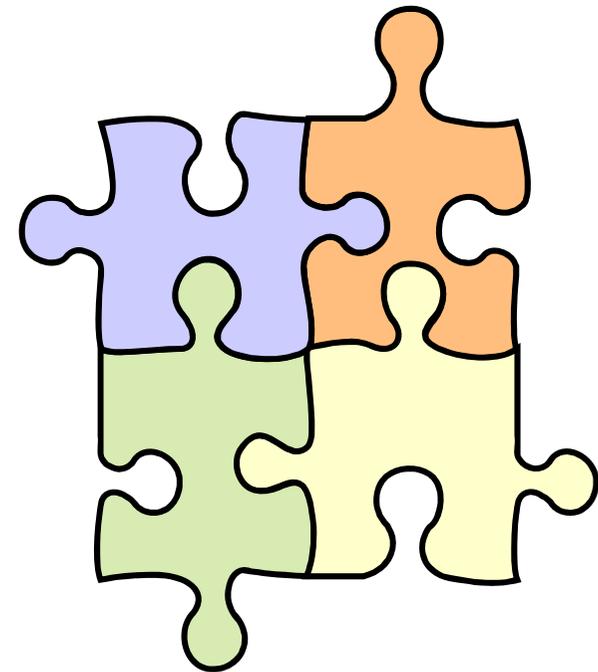
- Wie implementieren?

Relationale Objektintegration

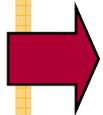
80

- Union (Vereinigung)
 - Duplikat-Eliminierung
- Minimum Union
 - Eliminierung sub-summierter Tupel

- Aber keine
 - Duplikatintegration
 - Konfliktlösung
- Mehr dazu in VL „Datenfusion“



- Verteilung
- Autonomie
- Syntaktische Heterogenität
- Strukturelle Heterogenität
- Semantische Heterogenität
 - Namenskonflikte
 - Identität
 - Datenkonflikte
- Gebundene und Freie Variablen
 - Adornments
 - Anfrageplanung



Gebundene & Freie Variablen

82

Gebundene Variablen müssen bei einer Anfrage spezifiziert werden.

- z.B.: „Search“-Feld bei Google

Freie Variablen müssen nicht gebunden werden.

- z.B. „Autor“-Feld bei Amazon.de, falls Titel gebunden ist.

Einordnung:

- Heterogenität
 - Syntaktische Heterogenität
 - ◇ Schnittstellenheterogenität

Gebundene und Freie Variablen – Adornments

83

- Jede Quelle exportiert eine oder mehrere relationale Sichten.
- IIS erlaubt Anfragen auf diese Sichten mittels Join, Union, Selektion und Projektion.



Quelle: [YLGU99]

Gebundene und Freie Variablen – Adornments

84

Z gebunden

Beispiel Quelle 1:

$R_1(X, Y, Z)$

Daten:

(x_1, y_1, z_1)

(x_1, y_2, z_1)

(x_2, y_2, z_2)

Beispiel Anfrage 1:

$Q_1(X, Y, z_1)$

Beispiel Ergebnis:

(x_1, y_1, z_1)

(x_1, y_2, z_1)

Beispiel Anfrage 2:

$Q_2(X, y_1, Z)$

Beispiel Ergebnis:

(x_1, y_1, z_1)

5 Quellen (für später):

$R_1(X, Y, Z)$

$R_2(X, Y, Z)$

$R_3(X, Y, Z)$

$R_4(Z, U)$

$R_5(U, V, W)$

Quelle: [YLGU99]

Gebundene und Freie Variablen – Adornments

85

- Anfragefähigkeiten der Quellen als templates
 - Wie ein WWW Formular
 - Templates bestehen aus einem adornment für jedes Attribut
- Anhänge (adornments = Verzierungen) an Attribute schränken ein:
 - f: free
 - ◇ Frei: Kann in Anfrage spezifiziert werden, muss aber nicht.
 - u: unspecifiable
 - ◇ Unbestimmbar: Kann nicht spezifiziert werden.
 - ◇ Ist aber Teil des Ergebnisses.
 - b: bound
 - ◇ Gebunden: Muss spezifiziert werden.
 - c[s]: constant
 - ◇ Auswahl aus einer Menge s von Konstanten
 - ◇ Implizit bound: muss spezifiziert werden
 - o[s]: optional
 - ◇ Auswahl aus einer Menge s von Konstanten
 - ◇ Implizit free: Muss nicht spezifiziert werden.

Quelle: [YLGU99]

Adornments - Beispiele

86

Beispiel Quelle 1:
 $R_1(X, Y, Z)$

Anfragemöglichkeit 1:

X muss spezifiziert werden

Y kann nicht spezifiziert werden

Z kann spezifiziert werden

Template:

buf

Anfragemöglichkeit 2:

X kann nicht spezifiziert werden

Y kann spezifiziert werden

Z ist entweder z_1 oder z_2

Template:

ufc[z_1, z_2]

Adornments – Anfragebearbeitung

87

Anfragebearbeitung

- $R1(X,Y,Z)$: bff,ffb
- $R2(X,Y,Z)$: fbf
- Sei $M = R1 \cup R2$ eine integrierte Sicht des IIS, gegen die man Anfragen stellen kann.
- Annahme über Anfragebearbeitung:
 - Anfragen werden übersetzt in je eine Anfrage pro Quelle (gebundene Variablen werden weitergereicht)
 - Ergebnisse werden entsprechen der Sicht verknüpft (hier \cup)
- Frage: Was ist das Template der Sicht M ?

$$\begin{array}{c} \mathbf{bff} \\ \cup \\ \mathbf{fbf} \\ = \end{array} \quad \text{---}$$

$$\begin{array}{c} \mathbf{ffb} \\ \cup \\ \mathbf{fbf} \\ = \end{array} \quad \text{---}$$

Quelle: [YLGU99]

Adornments – Verknüpfung durch UNION

88

3 Sichten und deren Adornments:

$R_1(X,Y,Z)$: bff, ffb

$R_2(X,Y,Z)$: fb

$R_3(X,Y,Z)$: ffc[s₁], c[s₂]ff

$R_1 \cup R_2$:

bff \cup fb = bb

ffb \cup fb = fbb

$(R_1 \cup R_2) \cup R_3$:

bbf \cup ffc[s₁] = bbc[s₁] usw.

\cup	f	o[s₃]	b	c[s₄]	u
f	f	o[s ₃]	b	c[s ₄]	u
o[s₁]	o[s ₁]	o[s ₁ \cap s ₃]	c[s ₁]	c[s ₁ \cap s ₄]	u
b	b	c[s ₃]	b	c[s ₄]	-
c[s₂]	c[s ₂]	c[s ₂ \cap s ₃]	c[s ₂]	c[s ₂ \cap s ₄]	-
u	u	u	-	-	u

Quelle: [YLGU99]

Adornments – Verknüpfung durch Join (\bowtie)

89

- Unterschied zu UNION
 - Nicht jedes Attribut der integrierten Sicht ist auch Attribut jeder beteiligten Quelle.
 - Beispiel: $R1(X,Y,Z)$ und $R4(Z,U)$
 - Sicht: $M(X,Y,Z,U) = R1(X,Y,Z) \bowtie R4(Z,U)$
- Berechnung des Templates der Sicht
 - Adornments der nicht-Join-Attribute werden kopiert.
 - Adornments der Join-Attribute werden gemäß der UNION Tabelle vereint.

Adornments – Selektion und Projektion

90

■ Selektion

- Sicht im IIS selektiert mit Prädikaten.
 - ◇ $X = \text{'Test'}$ oder $U > 1999$
- Prädikate werden auf Ergebnisse der Quellen angewandt.
- Deshalb: Kein Einfluss auf adornments

■ Projektion

- Einfach projizierte Attribute weglassen.
- Aber: Falls Attribut mit b oder c adornment durch Projektion wegfallen soll \Rightarrow Sicht des IIS nicht ausführbar
- Sonst: Adornments bleiben erhalten

Adornments – Anfragebearbeitung

91

- Problem

- UNION-Matrix zu restriktiv

	f	o[s₃]	b	c[s₄]	u
f	f	o[s ₃]	b	c[s ₄]	u
o[s₁]	o[s ₁]	o[s ₁ ∩ s ₃]	c[s ₁]	c[s ₁ ∩ s ₄]	u
b	b	c[s ₃]	b	c[s ₄]	-
c[s₂]	c[s ₂]	c[s ₂ ∩ s ₃]	c[s ₂]	c[s ₂ ∩ s ₄]	-
u	u	u	-	-	u

- Idee: Erhöhung der Menge beantwortbarer Anfragen

- durch Post-Processing
- durch Passing Bindings

Adornments und Postprocessing

92

$R_1(X,Y,Z): \text{bfu}$
 $R_2(X,Y,Z): \text{buf}$
 $R_1 \cup R_2 = \text{buu}$

Anfrage 1: (x_1, Y, Z) beantwortbar?
Anfrage 2: (x_1, y_1, z_1) beantwortbar?

Idee: (x_1, y_1, Z) an R_1
 (x_1, Y, z_1) an R_2
Dann im Mediator filtern:
 $Z=z_1$ bzw. $Y=y_1$

Was ist neu?

$u = f$: durch nachträgliches Filtern (postprocessing)

$o[s] = f$: falls Bindung nicht in s , weglassen und später

Filtern

Zusammen: $R_1 \cup R_2 = \text{bff}$

Adornments – Verknüpfung durch UNION

93

Vorher:

	f	o[s₃]	b	c[s₄]	u
f	f	o[s ₃]	b	c[s ₄]	u
o[s₁]	o[s ₁]	o[s ₁ ∩ s ₃]	c[s ₁]	c[s ₁ ∩ s ₄]	u
b	b	c[s ₃]	b	c[s ₄]	-
c[s₂]	c[s ₂]	c[s ₂ ∩ s ₃]	c[s ₂]	c[s ₂ ∩ s ₄]	-

Nachher:

	f	o[s₃]	b	c[s₄]	u
f	f	f	b	c[s ₄]	f
o[s₁]	f	f	b	c[s ₄]	f
b	b	b	b	c[s ₄]	b
c[s₂]	c[s ₂]	c[s ₂]	c[s ₂]	c[s ₂ ∩ s ₄]	c[s ₂]
u	f	f	b	c[s ₄]	f

Quelle: [YLGU99]

Adornments und Passing Bindings

94

JOIN über templates ohne
passing bindings

$R_1(X, Y, Z) : \text{fbf}$

$R_5(Z, U) : \text{bf}$

$R_1 \bowtie R_2 = \text{fbbf}$

Anfrage 1: (X, y_1, z_1, U) beantwortbar?

Anfrage 2: (X, y_1, Z, U) beantwortbar?

Idee: (X, y_1, Z) an R_1
 $(z_1, U) \dots (z_n, U)$ an R_5

Passing Bindings: Ergebnisse einer Sicht werden vom Mediator in die gebundene Variable der nächsten Sicht eingetragen.

JOIN über templates mit *passing bindings*:

$R_1 \triangleright \triangleleft R_5 = \text{fbff}$

Quelle: [YLGU99]

Adornments und Passing Bindings

95

Vorher:

	f	o[s₃]	b	c[s₄]	u
f	f	o[s ₃]	b	c[s ₄]	u
o[s₁]	o[s ₁]	o[s ₁ ∩ s ₃]	c[s ₁]	c[s ₁ ∩ s ₄]	u
b	b	c[s ₃]	b	c[s ₄]	-
c[s₂]	c[s ₂]	c[s ₂ ∩ s ₃]	c[s ₂]	c[s ₂ ∩ s ₄]	-
u	u	u	-	-	u

Zweite Quelle

Nachher:

	f	o[s₃]	b	c[s₄]	u
f	f	f	f	c[s ₄]	f
o[s₁]	f	f	f	c[s ₄]	f
b	b	b	b	c[s ₄]	b
c[s₂]	c[s ₂]	c[s ₂]	c[s ₂]	c[s ₂ ∩ s ₄]	c[s ₂]
u	f	f	f	c[s ₄]	f

Erste Quelle

Quelle: [YLGU99]

Adornments – Selektion mit Postprocessing

96

Variante 1: $R_1(X, Y, Z)$, $X < x_1$: bfu

$Q(x_2, Y, Z)$ beantwortbar?
 $Q(x_2, Y, z_1)$ beantwortbar?
 $Q(X, y_1, z_1)$ beantwortbar?

bfu wird zu bff mit postprocessing

Variante 2: $R_1(X, Y, Z)$, $X = x_1$: bfu

$Q(X, y_1, z_1)$ beantwortbar?

$Q(X, y_1, z_1) = Q(x_1, y_1, z_1)$
wegen Prädikat
bfu wird zu bff wird zu fff

Quelle: [YLGU99]

Adornments – Selektion mit Postprocessing

97

Vorher Nachher

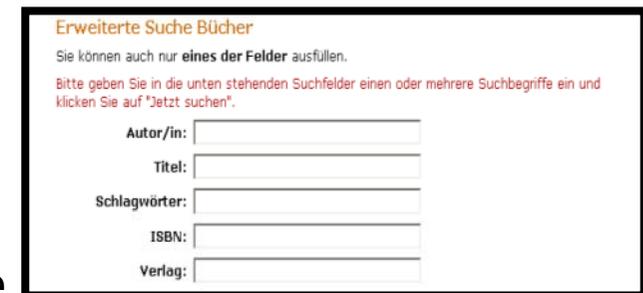
Base View Adornment	Sel. Attribute Adornment
f	f
o[s ₁]	f
b	f or b
c[s ₁]	f or c[s ₁]
u	f

Quelle: [YLGU99]

Viele Templates

98

- Problem: Quellen exportieren oft mehrere templates
 - Beispiel: Amazon (Autor, Titel, Schlagwort, ISBN, Verlag)
 - bffff, fbfff, ffbff, fffbf, ffffb
 - Beispiel: Verlage (Verlag, Ort)
 - bf, fb
 - Sicht im IIS: Amazon \bowtie Verlag Verlage
 - Templates der Sicht aus jeder Kombination:
 - ◇ bffff, fbfff, ffbff, fffbf, ffffb
 - ◇ bffffb, fbfffb, ffbffb, fffbfb, fffbb
 - ◇ + fffffb (ffffb \bowtie fb mit passing binding)
- Lösung:
 - Einige templates sind redundant



Erweiterte Suche Bücher

Sie können auch nur **eines der Felder** ausfüllen.

Bitte geben Sie in die unten stehenden Suchfelder einen oder mehrere Suchbegriffe ein und klicken Sie auf "Jetzt suchen".

Autor/in:

Titel:

Schlagwörter:

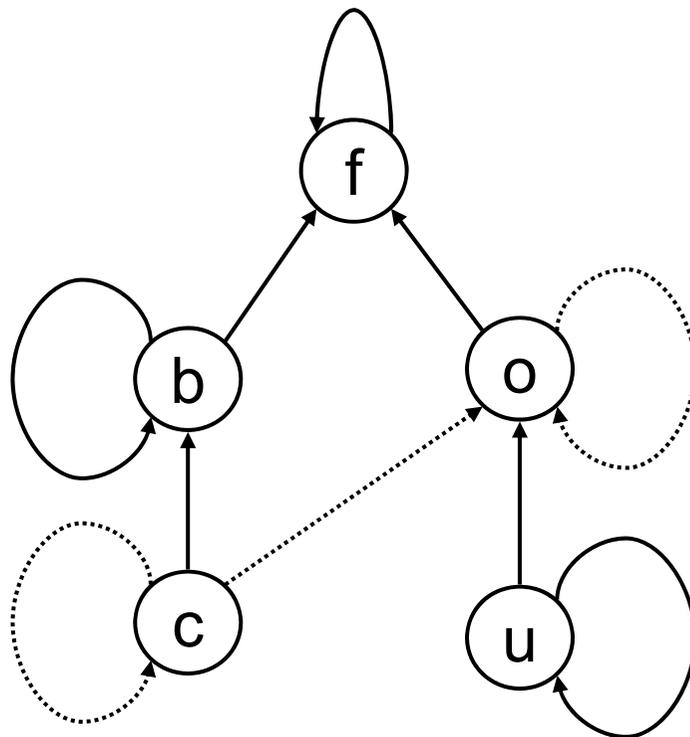
ISBN:

Verlag:

Quelle: [YLGU99]

Redundanz in Templates

99



—————> Weniger restriktiv

.....> Weniger restriktiv falls Auswahllisten Teilmengen sind

- bfffff, fbffff, ffbfff, fffbff, fffbfb
- bffffb, fbfffb, ffbffb, fffbfb, fffbfb

Algorithmus zur Entfernung redundanter templates.

Quelle: [YLGU99]

Adornments – Fallbeispiel

100

■ Amazon

- Formular 1: Mindestens eine Spezifikation aus author, title, subject, format (format aus Auswahlliste)
- Formular 2: ISBN spezifizieren
- Formular 3: Mindestens eine Spezifikation aus keyword, publisher, date
- Antwortrelation: author, title, ISBN, publisher, date, format, price, shipping info

■ Barnes & Noble

- Formular 1: Mindestens eine Spezifikation aus author, title, keywords; optionale Spezifikation in format, subject, price, age (alles aus Auswahllisten)
- Formular 2: ISBN spezifizieren

Quelle: [YLGU99]

Adornments - Fallbeispiel

101

Amazon

author	title	format	subject	KW	ISBN	pub	date	price	ship
b	f	o	f'	u'	u	u	u	u	u
f	b	o	f'	u'	u	u	u	u	u
f	f	c	f'	u'	u	u	u	u	u
f	f	o	b'	u'	u	u	u	u	u
u	u	u	u'	u'	b	u	u	u	u
u	u	u	u'	f'	u	b	f	u	u
u	u	u	u'	b'	u	f	f	u	u
u	u	u	u'	f'	u	f	b	u	u

Barnes & Noble

author	title	format	subject	KW	ISBN	pub	date	price	ship	age
f	b	o	o'	f'	u	u	u	o	u	o'
b	f	o	o'	f'	u	u	u	o	u	o'
f	f	o	o'	b'	u	u	u	o	u	o'
u	u	u	u'	u'	b	u	u	u	u	u'

IIS

author	title	format	subject	KW	ISBN	pub	date	price	ship	age
f	f	f	u'	u'	b	f	f	f	f	u'
f	f	f	u'	b'	f	f	f	f	f	u'
b	f	f	o'	u'	f	f	f	f	f	u'
f	b	f	o'	u'	f	f	f	f	f	u'
b	f	f	u'	f'	f	b	f	f	f	u'
f	b	f	u'	f'	f	b	f	f	f	u'
f	b	f	u'	f'	f	f	b	f	f	u'
b	f	f	u'	f'	f	f	b	f	f	u'

Quelle: [YLGU99]

Adornments - Fallbeispiel

102

IIS

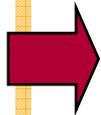
author	title	format	subject	KW	ISBN	pub	date	price	ship	age
f	f	f	u'	u'	b	f	f	f	f	u'
f	f	f	u'	b'	f	f	f	f	f	u'
b	f	f	o'	u'	f	f	f	f	f	u'
f	b	f	o'	u'	f	f	f	f	f	u'
b	f	f	u'	f'	f	b	f	f	f	u'
f	b	f	u'	f'	f	b	f	f	f	u'
f	b	f	u'	f'	f	f	b	f	f	u'
b	f	f	u'	f'	f	f	b	f	f	u'

Ableiten von 4 Formularen im IIS nach [YLGU99]

- Spezifikation der ISBN (template 1)
- Spezifikation des keyword (template 2)
- Mindestens author oder title spezifizieren (templates 3 und 4)
- Mindestens author oder title und mindestens publisher oder date spezifizieren (templates 5-8)

Quelle: [YLGU99]

- Verteilung
- Autonomie
- Syntaktische Heterogenität
- Strukturelle Heterogenität
- Semantische Heterogenität
 - Namenskonflikte
 - Identität
 - Datenkonflikte
- Gebundene und Freie Variablen
 - Adornments
 - Anfrageplanung



Gebundene & Freie Variablen – Beispiel

104

$v_1(\text{Song}, \text{CD})$

<Friends, Life>

<Friends, Love>

$v_2(\text{CD}, \text{Artist}, \text{Price})$

<Love, Lucy, \$15>

<Story, Snoopy, \$14>

$v_3(\text{CD}, \text{Artist}, \text{Price})$

<Story, Lucy, \$13>

<Love, Snoopy, \$10>

<Life, Charlie, \$8>

Bastelaufgabe 1:
Wie teuer ist die billigste CD mit einem Song namens "Friends"?



Quelle: [LC00]

Gebundene & Freie Variablen – Beispiel

105

$v_1(\text{Song}, \text{CD})$

<Friends, Life>

<Friends, Love>

$v_2(\text{CD}, \text{Artist}, \text{Price})$

<Love, Lucy, \$15>

<Story, Snoopy, \$14>

$v_3(\text{CD}, \text{Artist}, \text{Price})$

<Story, Lucy, \$13>

<Love, Snoopy, \$10>

<Life, Charlie, \$8>

Bastelaufgabe 2:
 Welches ist die billigste CD mit einem Song namens "Friends", *die Sie anfragen können?*

Gebundene & Freie Variablen – Beispiel

106

$v_1 \bowtie v_2: \{\$15\}$

$v_1(\text{Song}, \text{CD})$

$\langle \text{Friends}, \text{Life} \rangle$

$\langle \text{Friends}, \text{Love} \rangle$

$v_2(\text{CD}, \text{Artist}, \text{Price})$

$\langle \text{Love}, \text{Lucy}, \$15 \rangle$

$\langle \text{Story}, \text{Snoopy}, \$14 \rangle$

$v_3(\text{CD}, \text{Artist}, \text{Price})$

$\langle \text{Story}, \text{Lucy}, \$13 \rangle$

$\langle \text{Love}, \text{Snoopy}, \$10 \rangle$

$\langle \text{Life}, \text{Charlie}, \$8 \rangle$

$v_1 \bowtie v_3$: empty, no binding
for Artist.

Quelle: [LC00]

Gebundene & Freie Variablen – Beispiel

107

$v_1(\text{Song}, \text{CD})$ 

<Friends, Life>

<Friends, Love>

$v_2(\text{CD}, \text{Artist}, \text{Price})$

<Love, Lucy, \$15>

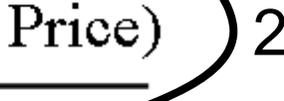
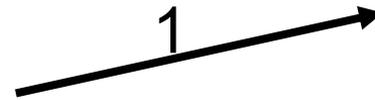
<Story, Snoopy, \$14>

$v_3(\text{CD}, \text{Artist}, \text{Price})$

<Story, Lucy, \$13>

<Love, Snoopy, \$10>

<Life, Charlie, \$8>

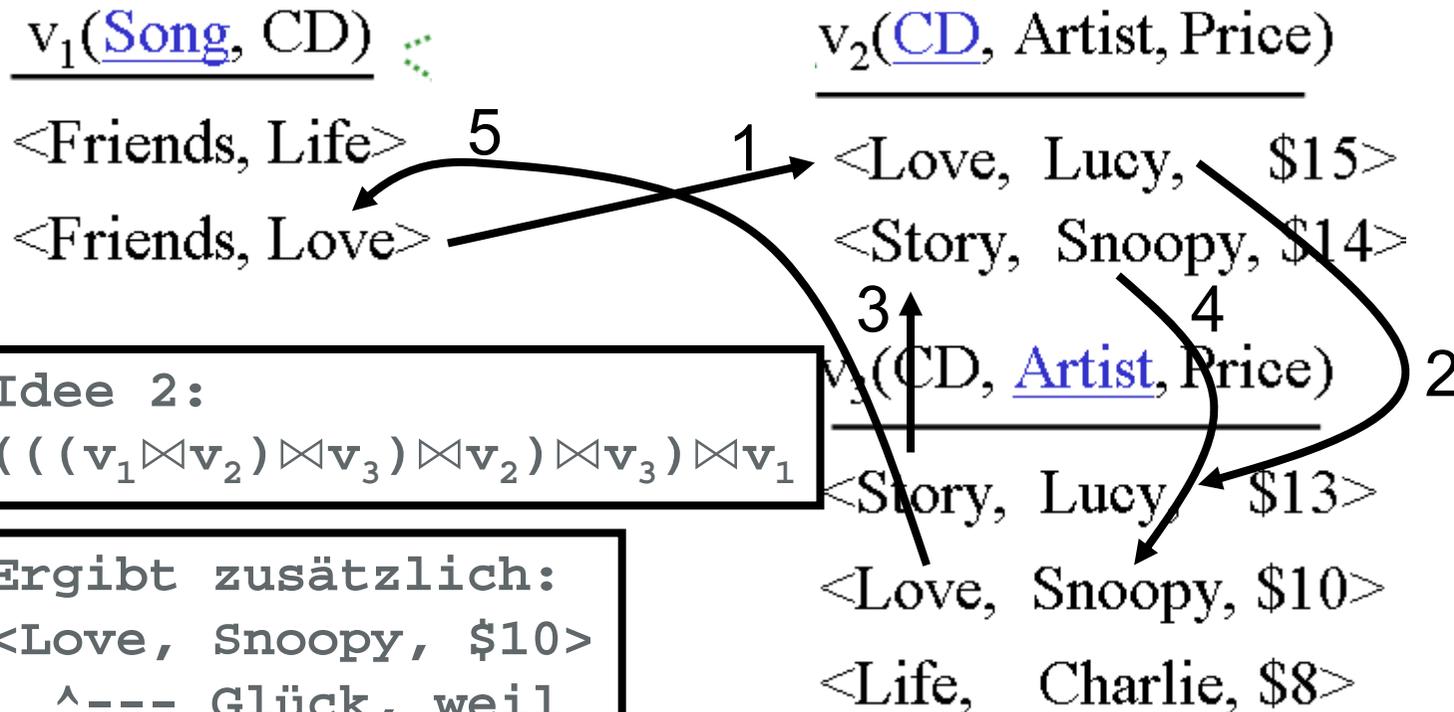


Idee 1:
 $(v_1 \bowtie_{\text{CD}} v_2) \bowtie_{\text{Artist}} v_3$

Ergibt zusätzlich:
 <Story, Lucy, \$13>
 ^ --- PECH

Gebundene & Freie Variablen – Beispiel

108



Idee 2:
 $((v_1 \bowtie v_2) \bowtie v_3) \bowtie v_2 \bowtie v_3 \bowtie v_1$

Ergibt zusätzlich:
 <Love, Snoopy, \$10>
 ^--- Glück, weil
 auch in v_1 !

Gebundene & Freie Variablen – Beispiel: Semantik

109

$v_1(\text{Song}, \text{CD})$ 

$\langle \text{Friends}, \text{Life} \rangle$

$\langle \text{Friends}, \text{Love} \rangle$

$v_2(\text{CD}, \text{Artist}, \text{Price})$

$\langle \text{Love}, \text{Lucy}, \$15 \rangle$

$\langle \text{Story}, \text{Snoopy}, \$14 \rangle$

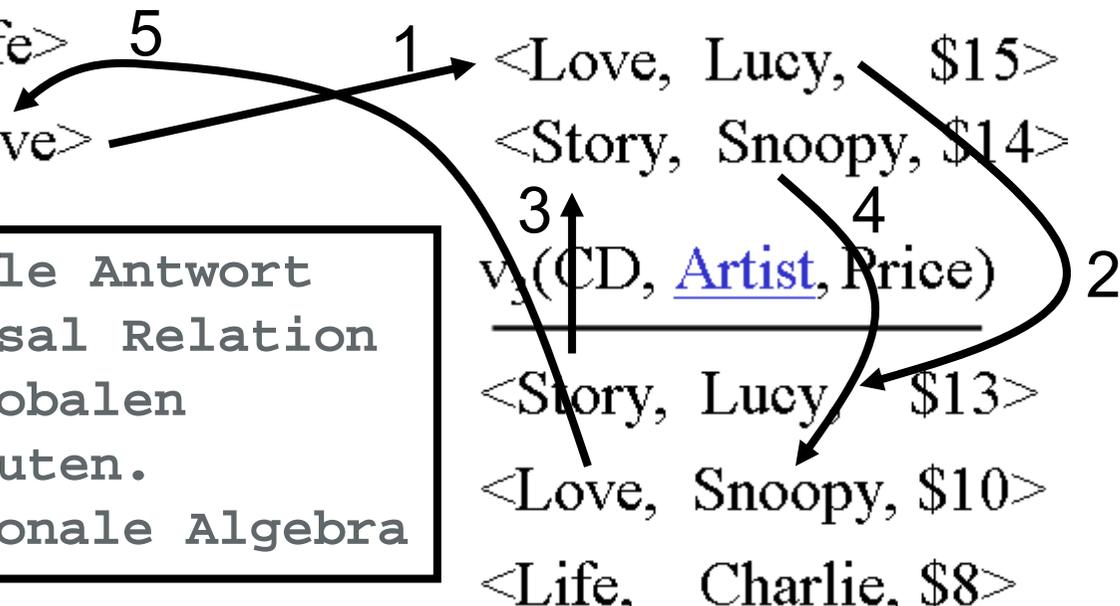
$v_3(\text{CD}, \text{Artist}, \text{Price})$

$\langle \text{Story}, \text{Lucy}, \$13 \rangle$

$\langle \text{Love}, \text{Snoopy}, \$10 \rangle$

$\langle \text{Life}, \text{Charlie}, \$8 \rangle$

Ziel: Maximale Antwort
Annahme: Universal Relation mit globalen Attributen.
Semantik: Relationale Algebra



Gebundene & Freie Variablen – Beispiel: Semantik

110

$v_1(\text{Song}, \text{CD})$

$\langle \text{Friends}, \text{Life} \rangle$

$\langle \text{Friends}, \text{Love} \rangle$

$v_2(\text{CD}, \text{Artist}, \text{Price})$

$\langle \text{Love}, \text{Lucy}, \$15 \rangle$

$\langle \text{Story}, \text{Snoopy}, \$14 \rangle$

$v_3(\text{CD}, \text{Artist}, \text{Price})$

$\langle \text{Story}, \text{Lucy}, \$13 \rangle$

$\langle \text{Love}, \text{Snoopy}, \$10 \rangle$

$\langle \text{Life}, \text{Charlie}, \$8 \rangle$

Schon Schritt 1 macht eine Annahme.
Schritte 2-5 überwinden nur Binding-Muster. Direkter Join über $v_1 \bowtie v_3$ hätte gleiches Resultat.
Wichtig deshalb: Data Lineage und Visualisierung

Wichtigste Literatur

- [BKLW99] Busse, Kutsche, Leser, Weber, Federated Information Systems: Concepts, Terminology and Architectures. Forschungsbericht 99-9 des FB Informatik der TU Berlin, 1999.
Online: http://www.informatik.hu-berlin.de/~leser/publications/tr_terminology.ps
- [ÖV99] Principles of Distributed Database Systems
M. Tamer Özsu, Patrick Valduriez, Prentice Hall, (1991/)1999.
Kapitel 1 und 4
- [YLGU99] Ramana Yerneni, Chen Li, Hector Garcia-Molina, Jeffrey D. Ullman, „Computing Capabilities of Mediators“, SIGMOD 1999

Weitere Literatur

- [Con97] Föderierte Datenbanksysteme. Konzepte der Datenintegration
Stefan Conrad, Springer Verlag, 1997
- [LC00] Chen Li, Edward Chang „Query Planning with Limited Source Capabilities“, ICDE 2000