Informationsintegration

Verteilung, Autonomie, Heterogenität, Transparenz

Ulf Leser

Klassifikationsdimensionen [ÖV99]

Eigenschaften von Informationssystemen in Bezug auf deren Integration

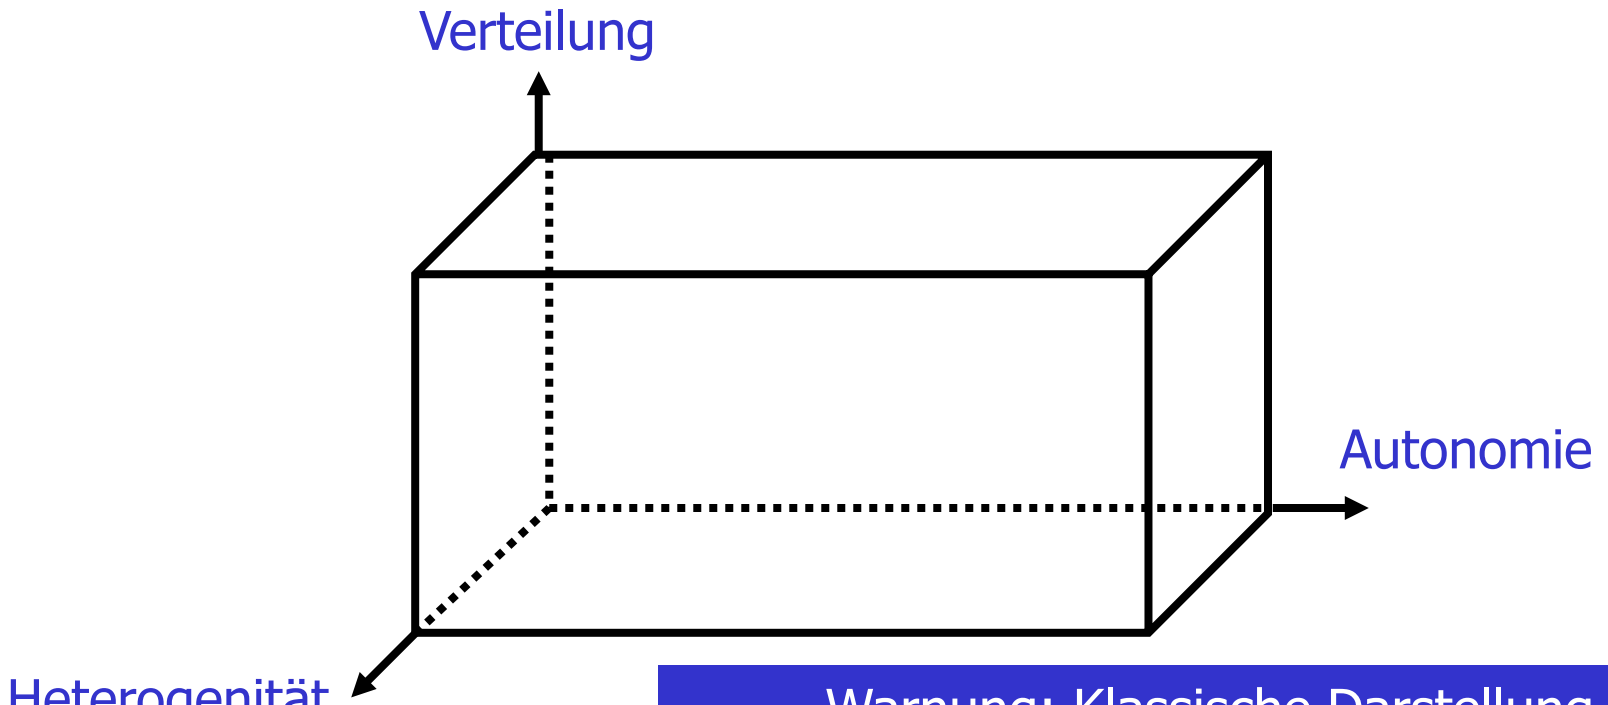

Warnung: Klassische Darstellung
Eigenschaften in Realität nicht orthogonal

Inhalt dieser Vorlesung

- Verteilung
  - Physische Verteilung
  - Logische Verteilung
- Autonomie
- Heterogenität
- Transparenz

Verteilung

- Ein verteiltes Informationssystem ist eine Sammlung mehrerer, logisch verknüpfter Informationssysteme, die zur Erfüllung einer gemeinsamen Aufgabe untereinander kommunizieren

- Zwei Aspekte
  - Physische Verteilung
  - Logische Verteilung

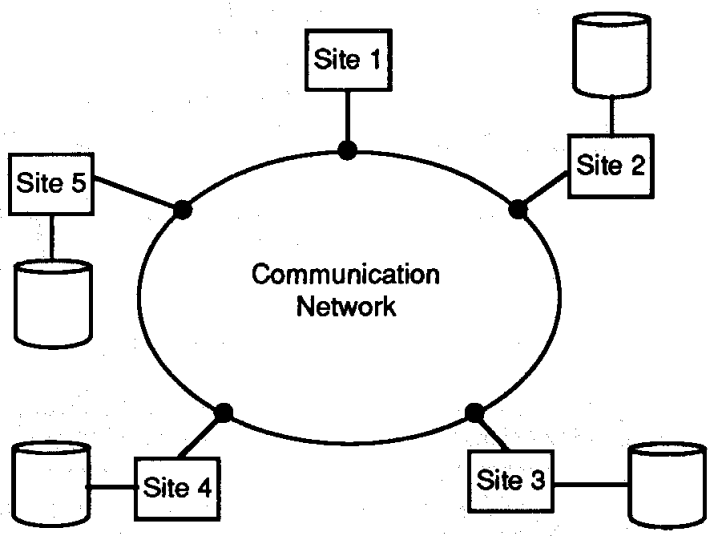

Physische Verteilung

- Server stehen an unterschiedlichen Orten
  - Anderes Land, Gebäude, Raum, Schrank, Rack, …
  - Server sind physikalisch unabhängig (hoffentlich)
- Bedingt „Shared Nothing“
  - Server haben keine gemeinsamen Speicher, Disk, CPU, …
- Gründe / Vorteile
  - Höhere Sicherheit im Katastrophenfall
  - Lastbalancierung
  - Latenz / Bandbreite: Nähe von Servern zu Clients
  - Historisch begründet
  - Physikalische Einschränkungen (Hitze, Gewicht, Energie)

Nachteile

- Daten müssen transportiert werden
  - Netzwerkverkehr statt IO oder Prozesswechsel
- Optimierung von Anfragen schwieriger
  - Latenzen; unterschiedliche Bandbreiten; zeitraubender Datentransport; Schwankungen im Netzwerk
- Schwierigeres Management
  - Keine einheitlichen Konsolen; verschiedene Sicherheitssysteme; verschiedene Managementsysteme; …
- Gefahr schleichend zunehmender Heterogenität

Logische Verteilung

- Daten stehen an verschiedenen logischen „Orten“
  - Können, müssen aber nicht physisch unterschiedlich sein
  - Verschiedene Attribute / Tabellen / Schemata
  - Auch in einem Schema (Tabellen buecher1, buecher2)
- Relationale Normalformen verlangen Verteilung
  - Verschiedene Attribute für Tabellen für verschiedene Daten
  - Verknüpfung verlangt intensionale und extensionale Überlappung (Primary key – foreign key)
- Manchmal: Verteilung semantisch gleicher Daten
  - Historisch gewachsen, Autonomie von Datenquellen
  - Zur Beschleunigung (Partitionierung)
  - Birgt Gefahr von (extensionalen) Duplikaten

Logische Verteilung und Intension

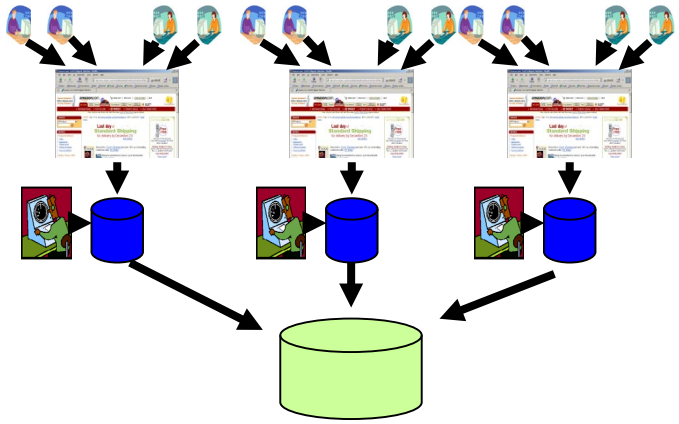

- Logische Verteilung
  - Tabellen „de_verkauf“, „fr_verkauf“ sind kontrolliert verteilt bzgl. des Verkaufsort
  - Damit sind die Daten disjunkt
  - Versucht man aber, alle Verkäufe eines Kunden X aus Strassburg zu erhalten …
    - X kann in Deutschland oder Frankreich eingekauft haben
    - X wird doppelt in den Kundendatenbanken stehen
  - Extensionale Überlappung bzgl. Kunden
  - Keine extensionale Überlappung bzgl. Verkäufen

Vorteile und Nachteile logischer Verteilung

- Vorteile
  - Erfüllung machtpolitischer Vorgaben
  - Kosten sparen – keine Migration
  - Kontrollierte logische Verteilung ist Voraussetzung für geplante physische Verteilung
    - Und der damit einhergehenden Vorteile
- Nachteile (unkontrollierter) Verteilung
  - Daten werden übersehen
  - Daten erscheinen doppelt
  - Daten haben Widersprüche (bei Duplikaten)
  - Daten können heterogen werden

Überwindung

- Integration macht Verteilung unsichtbar oder weniger gravierend
  - Einheitlicher Zugang, einheitliche Daten
- Physische Verteilung
  - Virtualisierte Integration
  - Materialisierung an einem Ort
- Logische Verteilung
  - Semantische Integration
    - Kann unter Beibehaltung physischer Verteilung erfolgen
    - Kann vom System (Mediatoren, Warehouse) oder vom Benutzer (Multidatenbanksprachen) erledigt werden
    - Schemaintegration, Schemamapping, Übersetzungstabellen, logische Formalismen, …

Inhalt dieser Vorlesung

- Verteilung
- Autonomie
- Heterogenität
- Transparenz

Autonomie

- Der Grad, zu dem verschiedene Quellsysteme unabhängig voneinander betrieben und kontrolliert werden
  - Unabhängige Zugriffskontrolle und -methoden, Konfiguration, Modellierung, …
  - Beinhaltet die Freiheit, einmal getroffene Entscheidungen jederzeit zu ändern
- Arten von Autonomie (nicht disjunkt) [ÖV99]
  - Designautonomie
  - Kommunikationsautonomie
  - Ausführungsautonomie

Designautonomie (auch: Entwurfsautonomie)

- Freiheit einer Quelle bezüglich
  - Datenmodell (Relational, hierarchisch, XML, …)
  - Schema
    - Abdeckung der Domäne (universe of discourse)
    - Benennung
    - Schemaentwurf
    - …
  - Gestaltung der Schnittstellen (Funktionsnamen, Parameter, Ergebnistypen, Rückgabeformat, …)

Beispiel

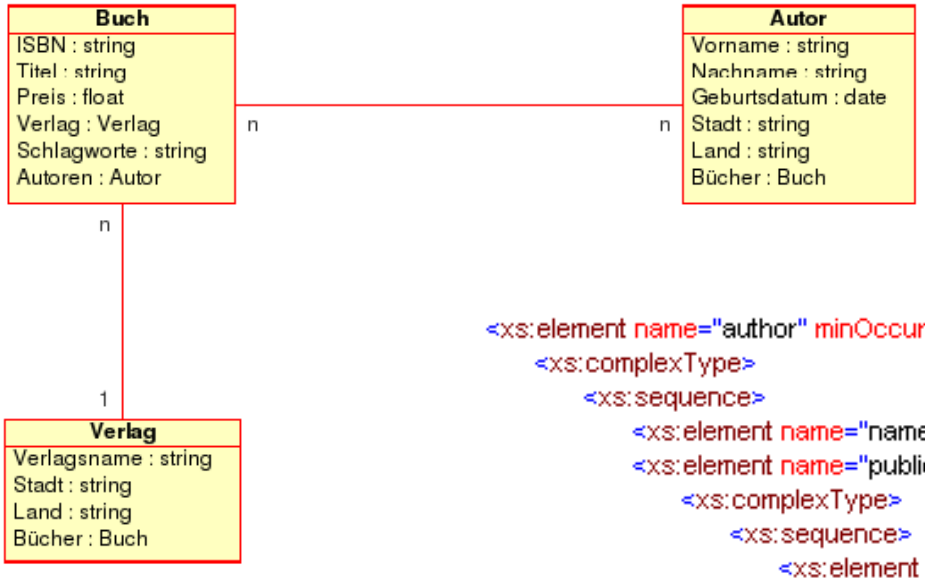


```
<xs:element name="author" minOccurs="0" maxOccurs="unbounded">
    <xs:complexType>
        <xs:sequence>
            <xs:element name="name" type="xs:string"/>
            <xs:element name="publication" minOccurs="0" maxOccurs="unbounded">
                <xs:complexType>
                    <xs:sequence>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

Kommunikationsautonomie

- Freiheit einer Quelle bezüglich
  - Mit welchen Systemen kommuniziert wird
    - Sperren von Clients nach 1200 Zugriffen?
    - Nur bestimmte IP-Räume zulassen?
  - Wann mit anderen Systemen kommuniziert wird
    - Jederzeit Eintritt/Austritt aus integriertem System
    - Zugriff nur in „ruhigen" Zeiten
    - Priorisierung von Zugriffen (Quality of Service)
  - Was (welche Informationen) kommuniziert wird
  - Welche Zugriffsmöglichkeiten zur Verfügung gestellt werden
    - Anfragesprachen, API, Web Services, …

Beispiele

- Voller SQL Zugang
  - z.B. via JDBC
  - Beliebige Queries
    - SQL Injection, Ressourcenverbrauch
  - Lesend (und schreibend?)
  - Schemaveränderungen?

```
WITH RECURSIVE TOPIC_PATHS (topic_above, topic_below, level) AS
(SELECT topic_id, topic_id, level FROM TOPIC
UNION ALL
SELECT TOPIC_PATHS.topic_above, TOPIC.topic_id, TOPIC_PATHS.level
FROM TOPIC_PATHS, TOPIC
WHERE TOPIC_PATHS.topic_below = TOPIC.topic_above)

SELECT TOPIC_PATHS.topic_above, DistinctCount (CLASSIFY.Doc_ID)
FROM TOPIC_PATHS, CLASSIFY
WHERE TOPIC_PATHS.topic_below = CLASSIFY.Topic_ID AND
TOPIC_PATHS.level = 1
GROUP BY TOPIC_PATHS.topic_above;
```

- HTML Formular
  - Nur ein (oder mehr) Suchfelder
  - Antwort als HTML Text
  - Nur vordefinierte Daten sichtbar

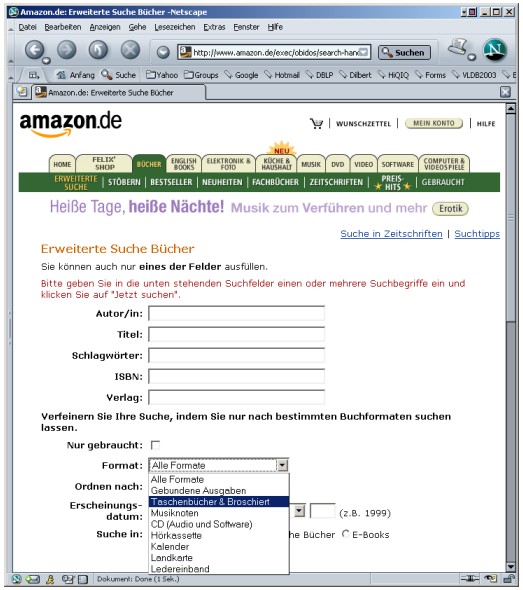

Ausführungsautonomie

- Freiheit einer Quelle bezüglich
  - Wann Anfragen ausgeführt werden (Scheduling)
  - Wie Anfragen ausgeführt werden (Optimierung)
  - Welche Anfragen ausgeführt werden (siehe Binding Pattern)
  - Behandlung von Transaktionen (gibt‘s die?)

Weitere Arten von Autonomie

- Schnittstellenautonomie
  - Festlegung, wie auf die Daten technisch zugegriffen werden kann
  - Web Services und SOAP, Web und HTML, SQL und Tupel, …
- Zugriffsautonomie
  - Festlegung, wer auf die Daten zugreifen darf
  - Authentifizierungsprotokoll, Accounts, Gruppenrechte
- Juristische Einschränkung der Verwendbarkeit
  - Zugriff für bestimmte Verwendungen kann verboten werden
    - Nur akademisch, nur mit Referenz, kein Text Mining, …
  - Bestimmte Zugriffsarten können verboten werden
    - Kein Screen-Scraping, nicht mehr als 10 Anfragen / Sekunde, …

Probleme

- Autonomie ermöglicht unkontrollierte Änderungen
  - Viel Arbeit in Integrationsschicht
  - Z.B.: 24 Quellen, eine Änderung pro Quelle pro Jahr: Ergibt eine Änderung alle zwei Wochen
- Autonomie ist oft unvermeidlich
  - Unabhängige Unternehmen / Unternehmensteile
  - Innerhalb von Unternehmen: Andere Administratoren, andere Abteilung, andere Anforderungen
    - Lokale Erweiterungen, andere Einkaufsprozesse, Besonderheiten in Abteilungen etc.
    - Soziologisch-psychologische Aspekte: Macht
- Gegenbewegung: Standardisierung
  - Vereinheitlichung im und über Unternehmen hinweg

Inhalt dieser Vorlesung

- Verteilung
- Autonomie
- Heterogenität
  - Technische Heterogenität
  - Syntaktische Heterogenität
  - Datenmodellheterogenität
  - Strukturelle Heterogenität
    - Schematische Heterogenität
  - Semantische Heterogenität
- Transparenz

Heterogenität

- Zwei Informationssysteme sind heterogen, wenn sie sich irgendwie unterscheiden
- Verschiedene Ausprägungen von „irgendwie“ => verschiedene Arten von Heterogenität
- Informationsintegration bezweckt auch das Verbergen von Heterogenität
  - Materialisierung: Erstellung eines homogenen Systems
  - Virtuelle Integration: Erweckung des Anscheins eines homogenen Systems

Zwischen Datenquellen

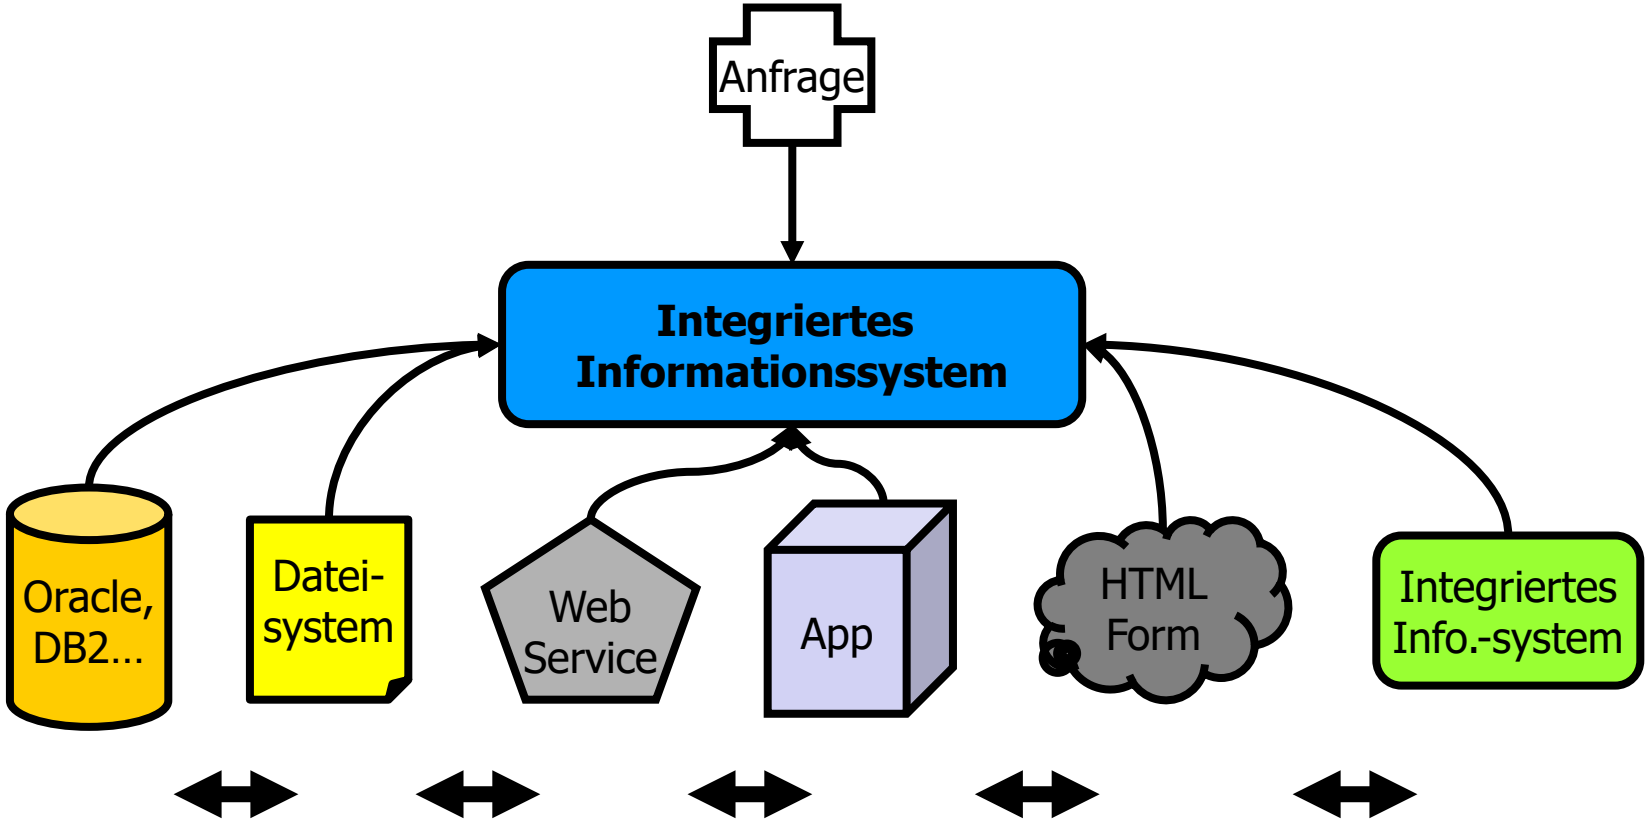

Heterogenität zwischen Datenquellen

Zwischen Schichten

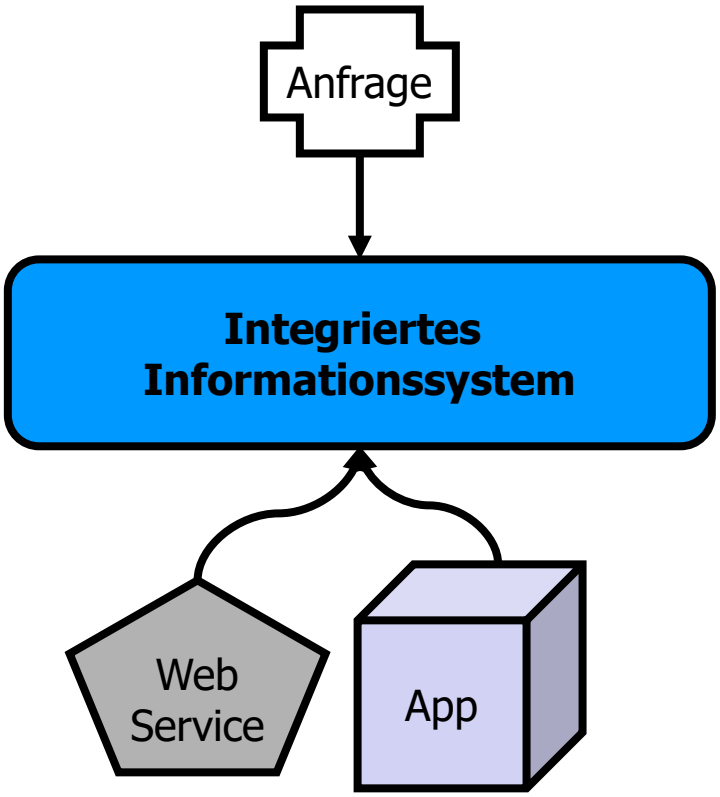

Heterogenität zwischen Integrationsschicht und Datenquellen

Inhalt dieser Vorlesung

- Verteilung
- Autonomie
- Heterogenität
  - Technische Heterogenität
  - Syntaktische Heterogenität
  - Datenmodellheterogenität
  - Strukturelle Heterogenität
    - Schematische Heterogenität
  - Semantische Heterogenität
- Transparenz

Technische Heterogenität

Ebene	Mögliche Ausprägungen
Anfragemöglichkeit	Anfragesprache, parametrisierte Funktionen, Formulare (engl. *canned queries*)
Anfragesprache	SQL, XQuery, Volltextsuche
Austauschformat	Binärdaten, XML, HTML, tabellarisch
Kommunikationsprotokoll	HTTP, JDBC, SOAP

Gründe für Einschränkungen

- Komplexität
  - Negation / Ungleichheit: teuer
  - „=“ oder auch „>,<, ≥, ≤“
  - Konjunktion / Disjunktion (eher teuer)
- Einfache Schnittstellen sind leicht verständlich und einfacher zu entwickeln und zu unterhalten
- Technische Gründe
  - Maximale Länge bei GET Kommandos
  - Maximale Länge von Queries
- Stabilität / Sicherheit
  - Ressourcenhungrige Queries vermeiden
  - SQL-Injektion vermeiden

Beispiel

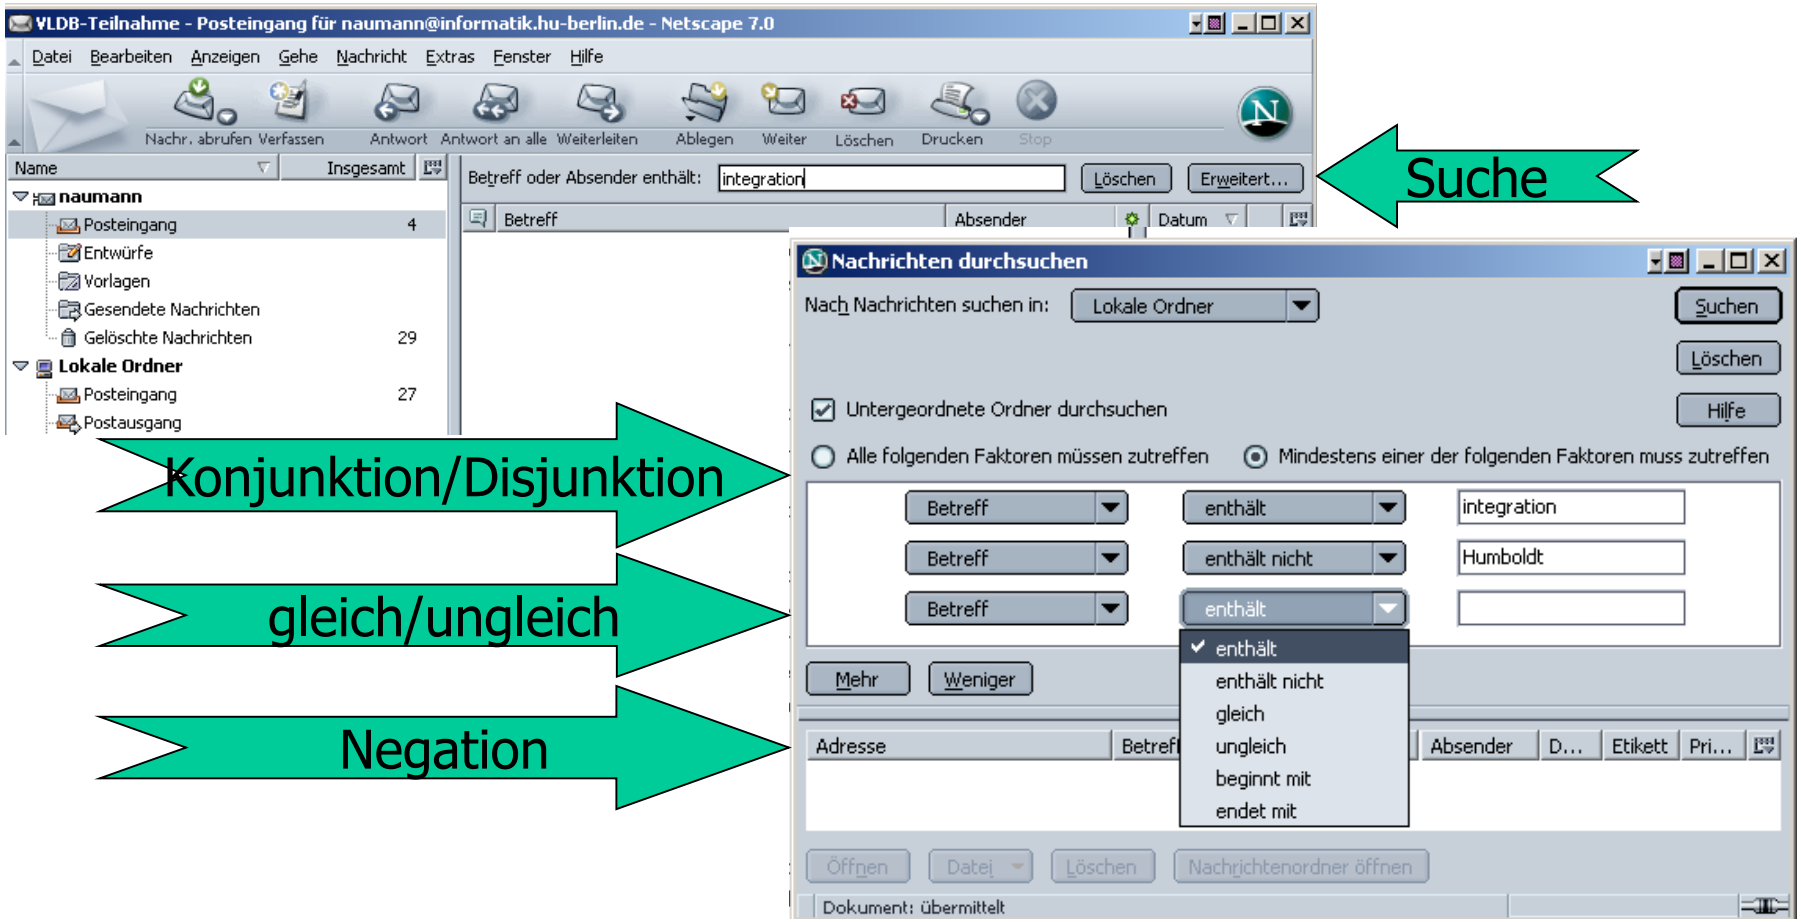
VLDB-Teilnahme - Posteingang für naumann@informatik.hu-berlin.de - Netscape 7.0
Datei Bearbeiten Anzeigen Gehe Nachricht Extras Fenster Hilfe
Nachr. abrufen Verfassen Antwort Antwort an alle Weiterleiten Ablegen Weiter Löschen Drucken Stop
Name Insgesamt
naumann
Posteingang 4
Entwürfe
Vorlagen
Gesendete Nachrichten
Gelöschte Nachrichten 29
Lokale Ordner
Posteingang 27
Postausgang
Betreff oder Absender enthält: integration
Löschen
Erweitert...
Betreff
Absender
Datum
Suche
Konjunktion/Disjunktion
gleich/ungleich
Negation
Nachrichten durchsuchen
Nach Nachrichten suchen in: Lokale Ordner
Suchen
Löschen
Hilfe
Untergeordnete Ordner durchsuchen
Alle folgenden Faktoren müssen zutreffen
Mindestens einer der folgenden Faktoren muss zutreffen
Betreff enthält integration
Betreff enthält nicht Humboldt
Betreff enthält
enthält
enthält nicht
gleich
ungleich
beginnt mit
endet mit
Mehr
Weniger
Adresse
Absender
D...
Etikett
Pri...
Öffnen
Datei
Löschen
Nachrichtenordner öffnen
Dokument: übermittelt

Beispiel

Gebundene Variablen, vorgegebene Disjunktion

Feste Auswahl von Werten, vorgegebene Konjunktion

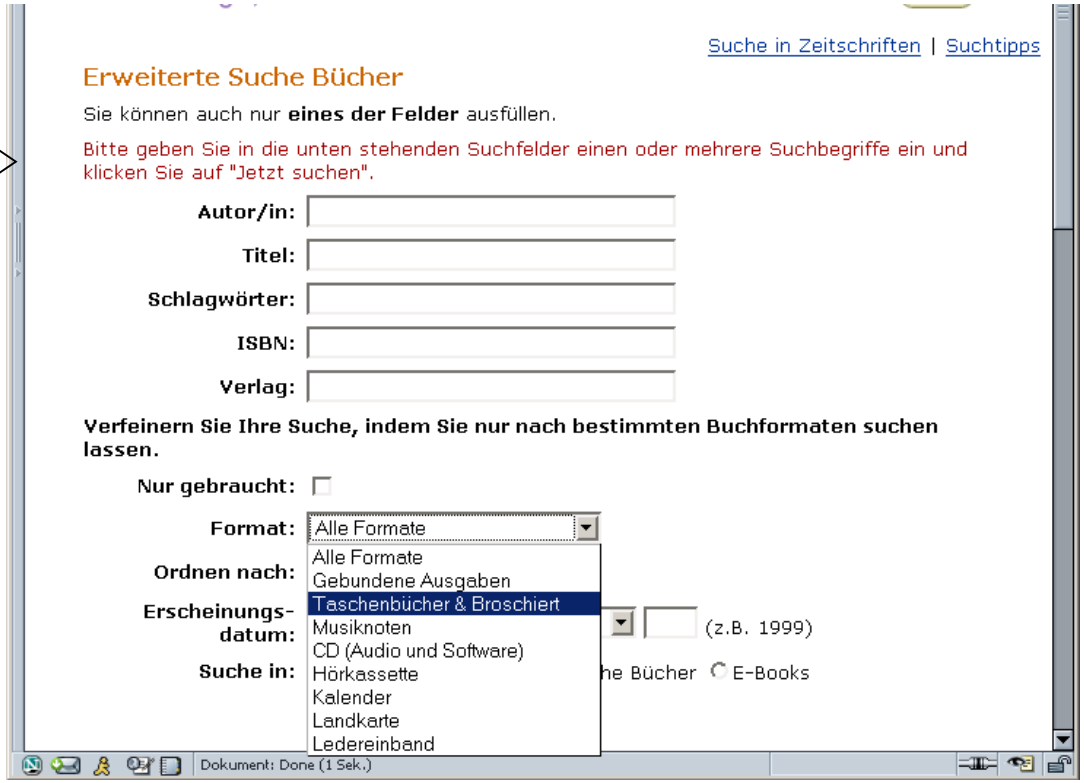

Typische Probleme

- Globale Anfragesprache ist mächtiger als lokale Anfragesprache
  - Anfragen nicht ausführbar oder
  - globales System muss kompensieren
- Einschränkungen bzgl. Variablenbindung
  - Anfragen eventuell nicht ausführbar
  - oder kompensieren (wenn möglich)
- Übersetzung von Anfragesprachen notwendig
  - SQL – XQuery, SQL – viele HTTP/GET, etc.
  - Oft nicht einfach semantikerhaltend möglich
    - Behandlung von NULL; outer-joins; Substringsuche; …

Mächtigere globale Anfragesprache

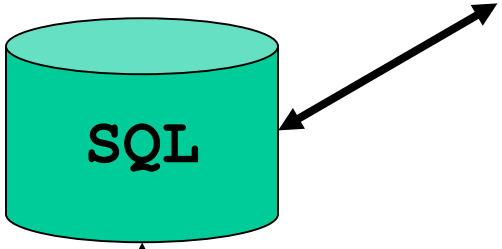


```
SELECT      *
FROM        Books
WHERE       Author = „Defoe“
AND         PubYear = 1979
```

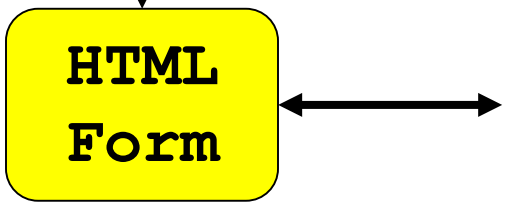

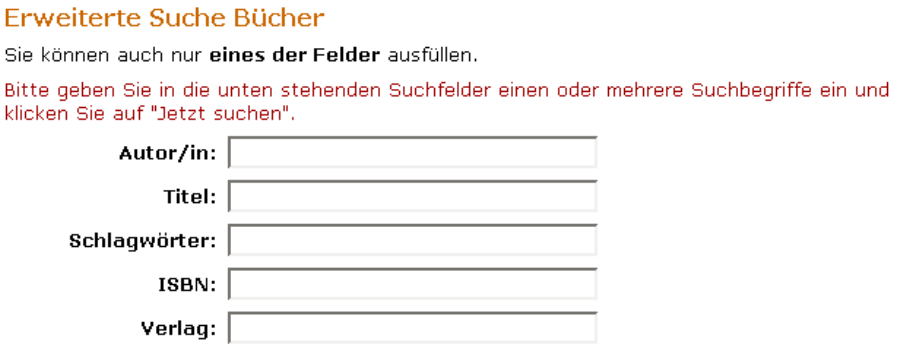

Kompensation

```
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
```

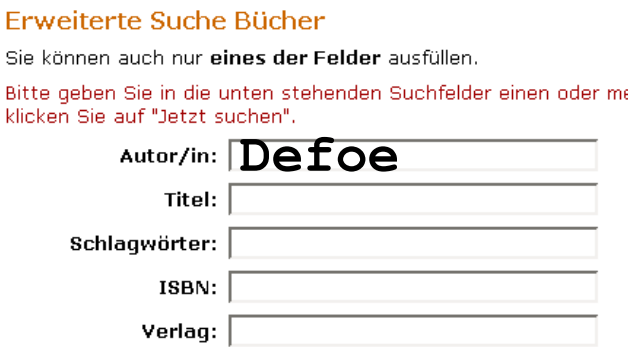

Kompensation nicht möglich

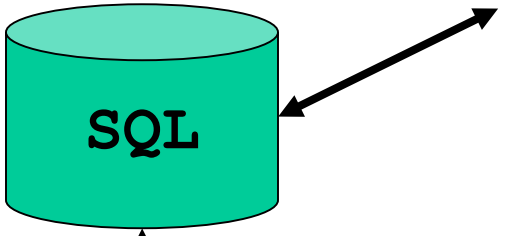


```
SELECT      *
FROM        Books
WHERE       Price < 10 Euro
```

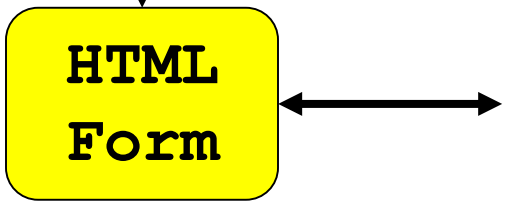

Erweiterte Suche Bücher

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:	

Inhalt dieser Vorlesung

- Verteilung
- Autonomie
- Heterogenität
  - Technische Heterogenität
  - Syntaktische Heterogenität
  - Datenmodellheterogenität
  - Strukturelle Heterogenität
    - Schematische Heterogenität
  - Semantische Heterogenität
- Transparenz

Syntaktische Heterogenität

- Unterschiedliche Darstellung desselben Sachverhalts
  - Dezimalpunkt oder –komma
  - Euro oder €
  - Comma-separated oder tab-separated
  - HTML oder ASCII oder Unicode oder …
  - Notenskala 1-6 oder „sehr gut“, „gut“, …
  - Binärcodierung oder Zeichen
  - Datumsformate (12. September 2006, 12.9.2006, 9/12/2006, …)
- Überwindung in der Regel nicht problematisch
  - Umrechnung, Übersetzungstabellen, …

Datenmodellheterogenität

- Typische Datenmodelle
  - Flach: CSV, EXCEL, …
  - Relational: Tupel
  - Hierarchisch: XML, HTML, …
  - Domänenspezifisch: EXPRESS, OPEN-GIS, …
- Modell zum Austausch oder zur persistenten Datenhaltung
  - Black-Box-Sicht: Entscheidend ist, was die Quelle liefert (also Austauschformat)
- Konvertierung z.T. nicht semantikerhaltend möglich
  - m:n Relationen in XML?
  - Verschiedene Tabellen in eine CSV Datei?

Beispiel

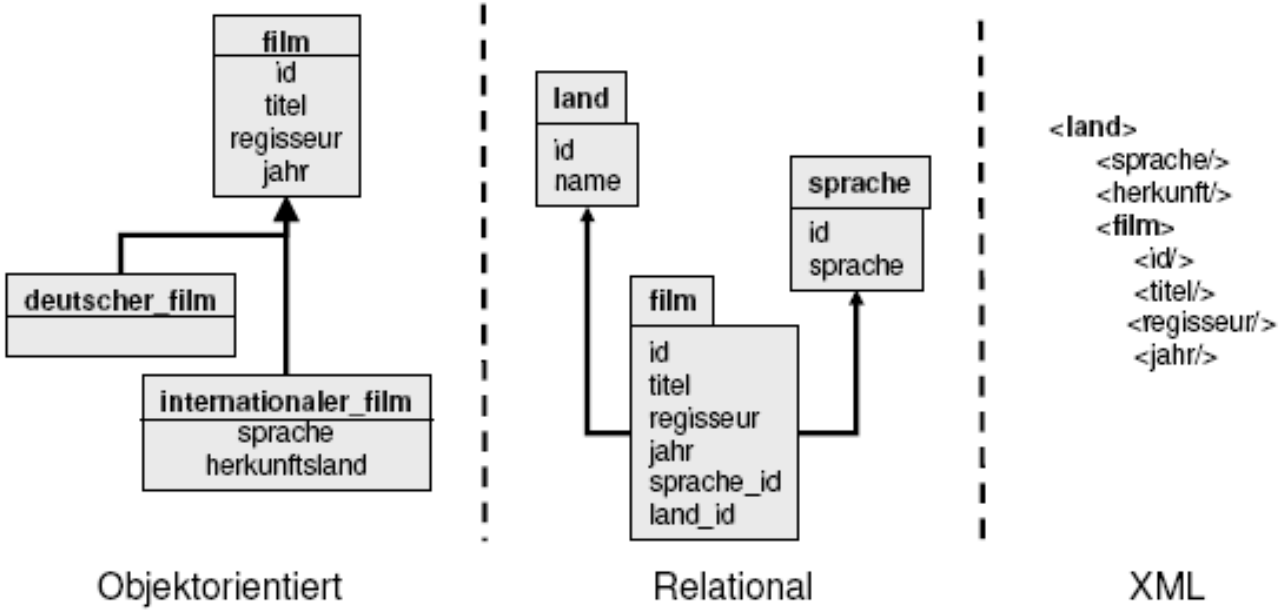

„Fast" dasselbe in verschiedenen Datenmodellen - Unterschiede?

Inhalt dieser Vorlesung

- Verteilung
- Autonomie
- Heterogenität
  - Technische Heterogenität
  - Syntaktische Heterogenität
  - Datenmodellheterogenität
  - Strukturelle Heterogenität
    - Schematische Heterogenität
  - Semantische Heterogenität
- Transparenz

Strukturelle Heterogenität

- Gleiche Dinge in unterschiedlichen Schemata ausdrücken
  - Andere Aufteilung von Attributen auf Tabellen
  - Fehlende / neue Attribute
- Inhärent bei Datenmodellheterogenität
- Sehr oft mit semantischer Heterogenität verbunden
- Spezialfall: Schematische Heterogenität
  - Verwendung anderer Elemente desselben Datenmodells
  - Besonderheit: Kann durch Anfragen idR nicht überwunden werden

Spezialfall: Schematische Heterogenität

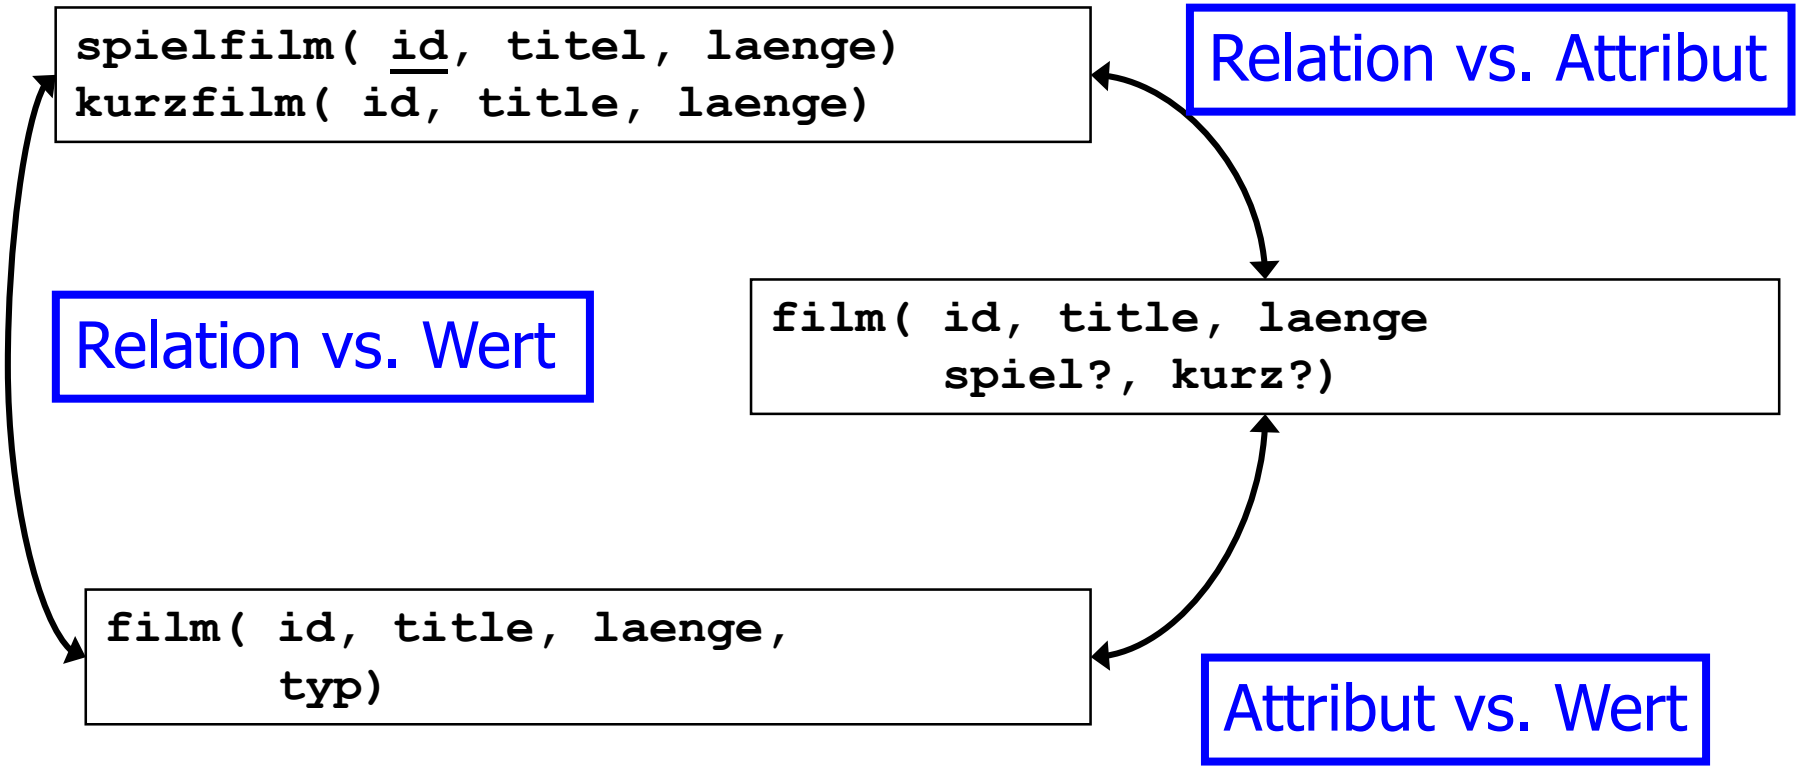

Schematische Konflikte sind schwierig

Modellierung als Relationen

```
spielfilm      ( id, titel, laenge)
dokumentarfilm( id, titel, laenge)
```

```
SELECT 'dpielfilm', AVG(laenge)
FROM   spielfilm
UNION
SELECT 'doku', AVG(laenge)
FROM   dokumentarfilm
UNION
...
```

Modellierung als Attribute

```
film( id, titel, laenge, spielfilm, doku)
```

```
SELECT 'dpielfilm', AVG(laenge)
FROM   film
WHERE  spielfilm = TRUE
UNION
```

Modellierung als Attributwerte

```
film( id, titel, laenge, typ)
```

```
SELECT   typ, AVG(laenge)
FROM     film
GROUP BY typ;
```

Integrierte Sicht

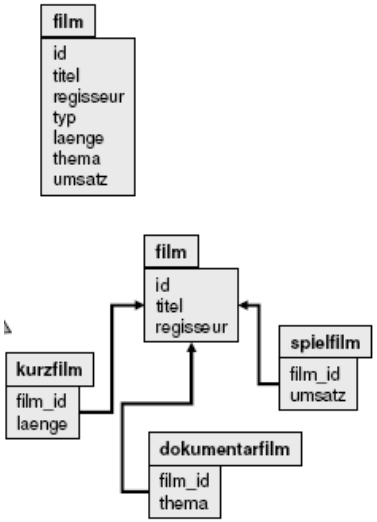


```
CREATE VIEW q1_q2
SELECT id, titel, regisseur, typ
FROM   q1.film
UNION
SELECT id, titel, regisseur, 'spielfilm' AS typ
FROM   q2.spielfilm
UNION
SELECT id, titel, regisseur, 'kurzfilm' AS typ
FROM   q2.kurzfilm
UNION
SELECT id, titel, regisseur, 'doku' AS typ
FROM   q2.dokumentarfilm;
```

- Sichtanpassung nötig, wenn neue Filmtypen vorliegen
  - Datenänderung bedingt Query-/Schemaänderung
  - Das will man vermeiden
  - Entscheidung, was Daten und was Metadaten sind

Exotische Probleme?

- Schema zur Speicherung von Filmen des Verleihers „XYZ“
  - **ACTORS** als **VARCHAR**
  - **ORIGINAL** – bedeutet was?
  - **TITLE**, **YEAR**, … an drei Stellen
  - ID-Räume **DEUTSCH** und **ORIGINAL** getrennt?
  - **GENRE** ist **VARCHAR**
  - …

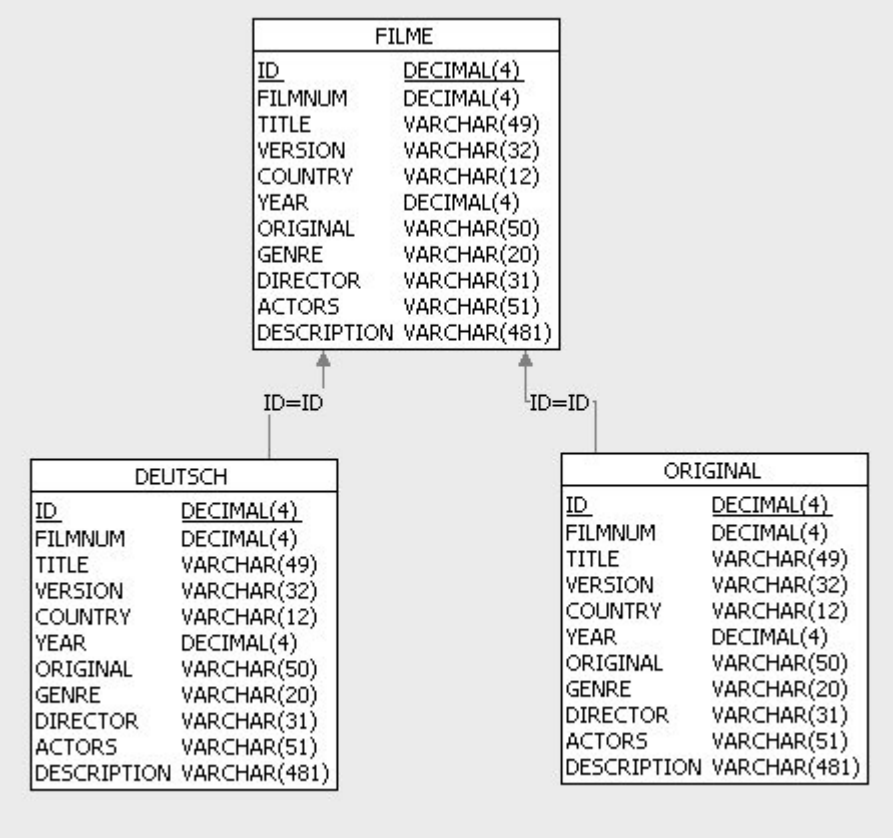

Exotische Probleme?

- Schema von eachmovie (HP)
  - Eine einzige Tabelle für Filme
  - Zusätzliche Informationen über Benutzer des Web-Systems
  - Wenig Infos über Filme, aber Links zu weiteren Quellen
  - **`GENRE`** sind boolsche Attribute
  - …

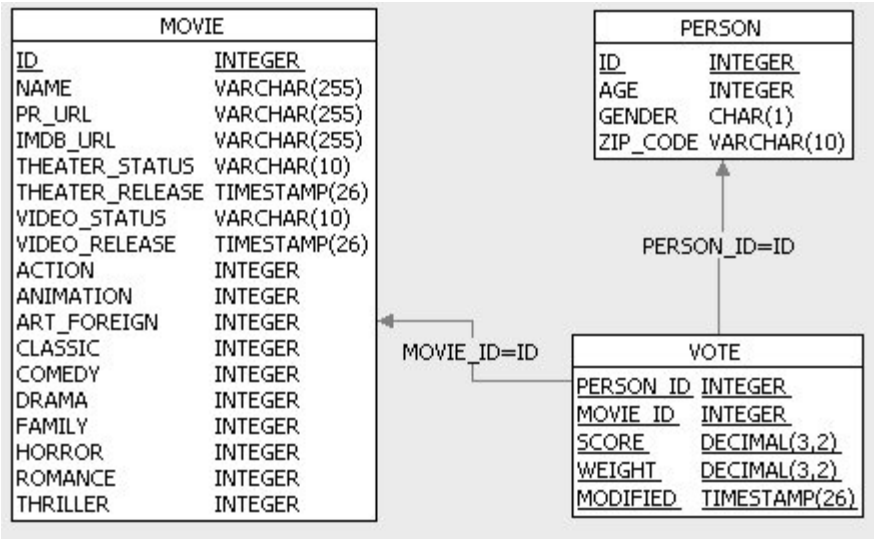

Exotische Probleme?

- Schema von movielens.umn.edu
  - Praktisch keine Informationen über Filme
  - Eigene Tabelle für **`GENRE`**
  - **`FILM-GENRE`** ist **`m:n`**
  - Mehr Informationen über Benutzer
  - Keine externen Links
  - …

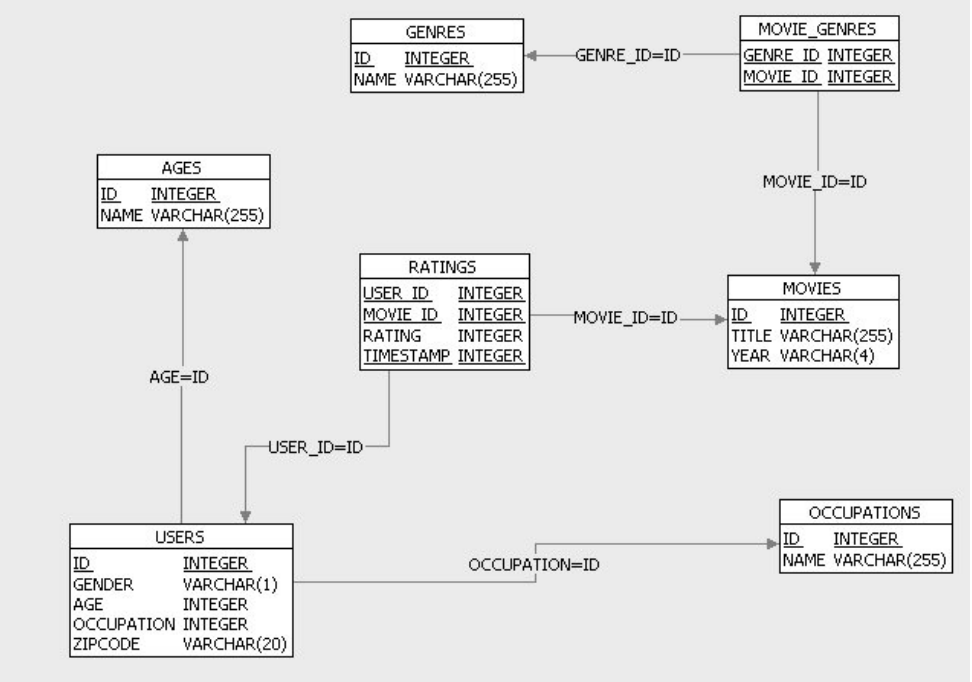

Schema des Filmdienst

FILM-PERSONEN ist **m:n**

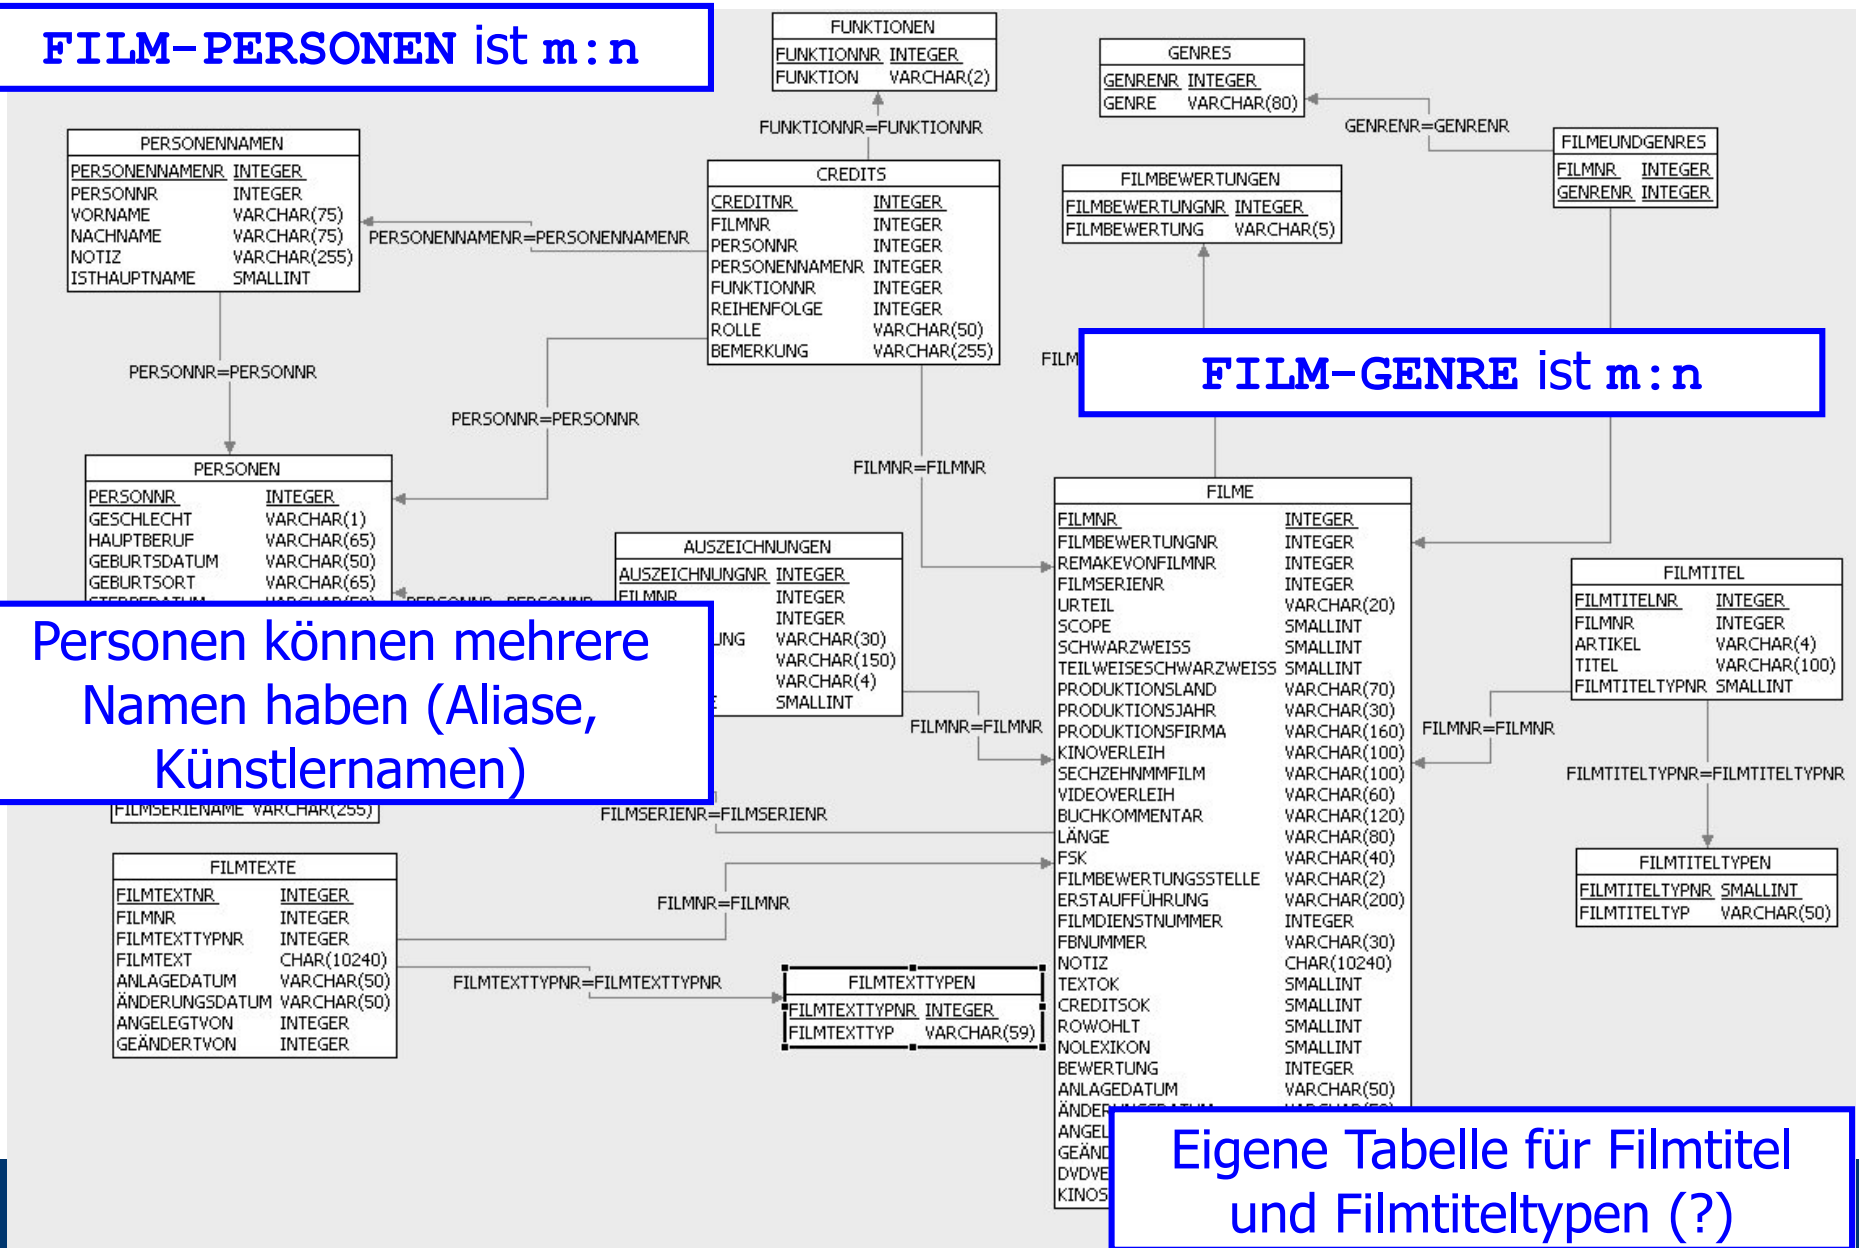

FILM-GENRE ist **m:n**

Personen können mehrere Namen haben (Aliase, Künstlernamen)

Eigene Tabelle für Filmtitel und Filmtiteltypen (?)

Schema der IMDB (vor vielen Jahren)

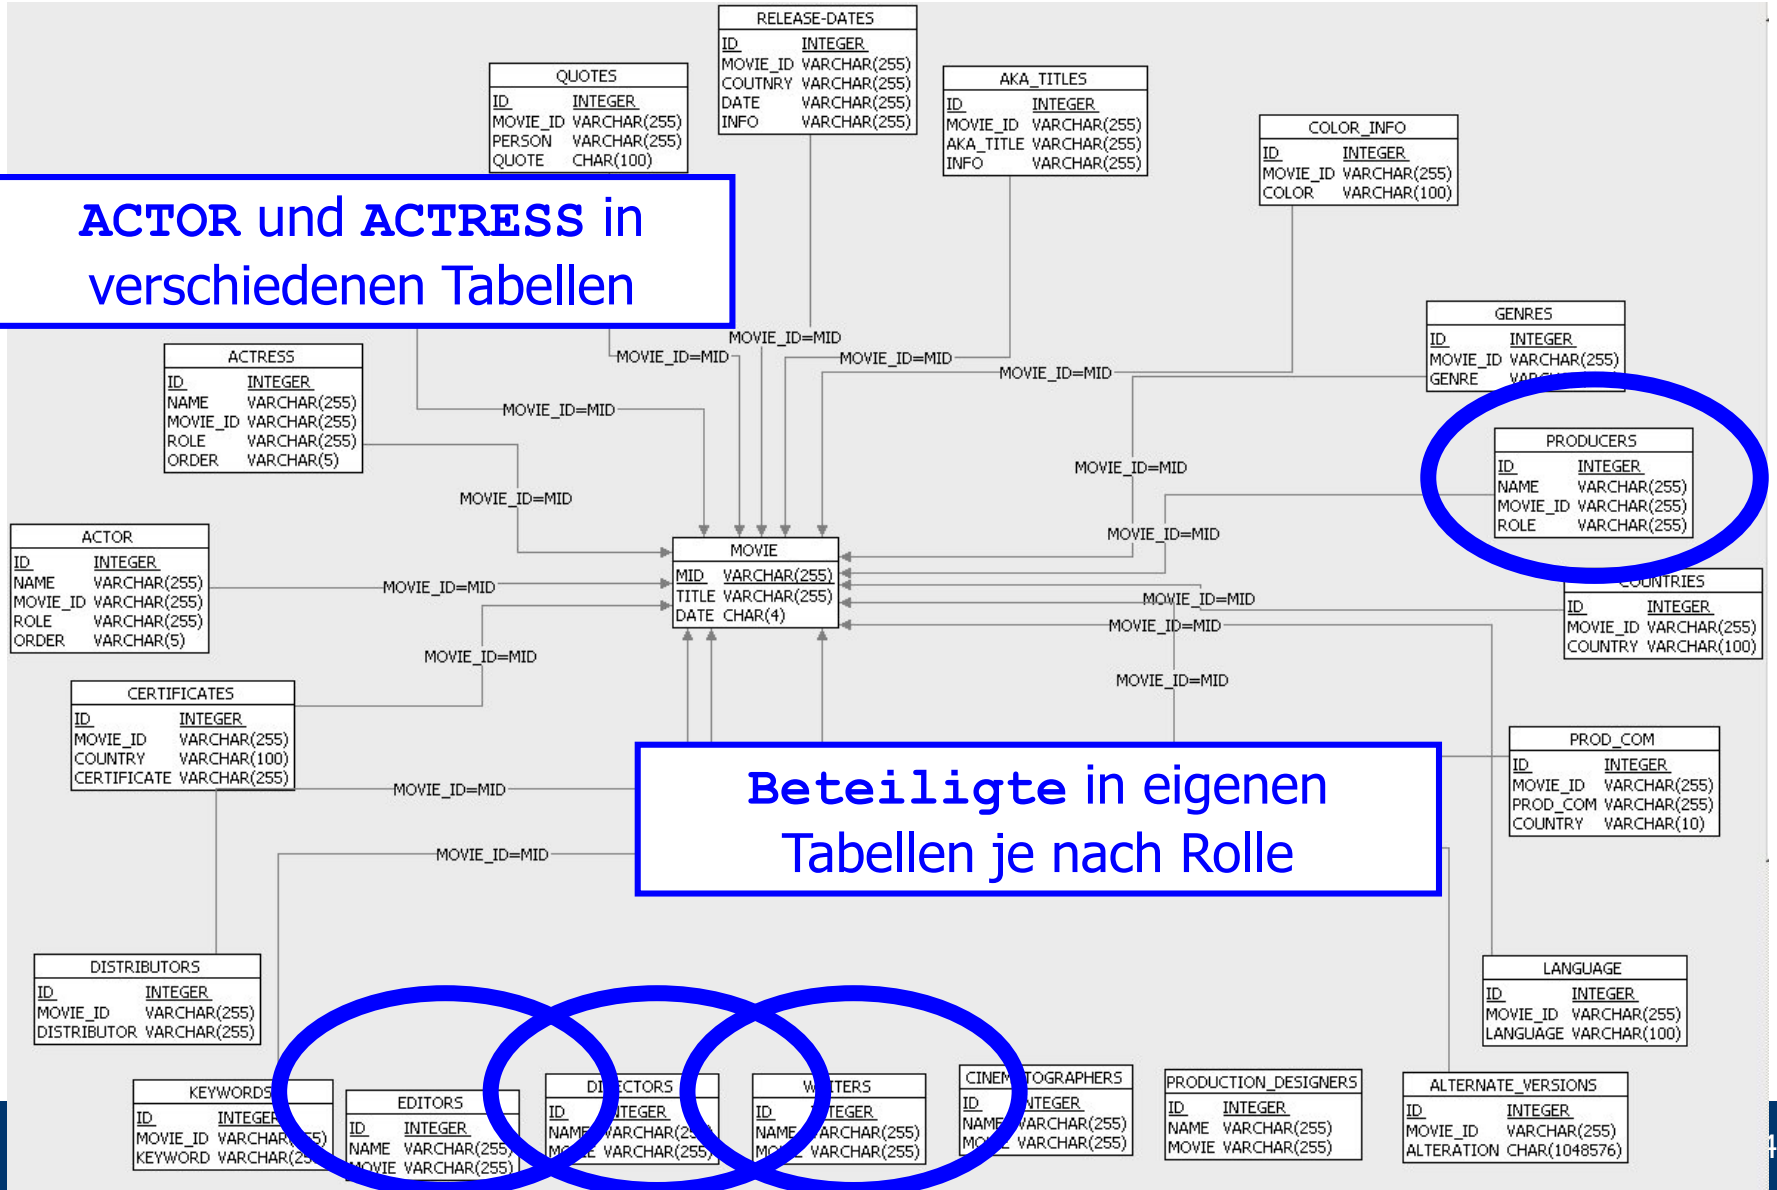

Inhalt dieser Vorlesung

- Verteilung
- Autonomie
- Heterogenität
  - Technische Heterogenität
  - Syntaktische Heterogenität
  - Datenmodellheterogenität
  - Strukturelle Heterogenität
    - Schematische Heterogenität
  - Semantische Heterogenität
- Transparenz

Semantik

- „Teilgebiet der Linguistik, das sich mit den Bedeutungen sprachlicher Zeichen und Zeichenfolgen befasst“
- „Bedeutung, Inhalt eines Wortes, Satzes oder Textes“
  - [Beides Fremdwörterduden]
- Programmiersprachen
  - Syntax: EBNF, Grammatiken
  - Semantik: Wirkungen der Ausführung
    - Operationale Semantik, Fixpunktsemantik, …
- Sprache
  - Syntaktisch falsch: „Ich esse Butterbrot ein“
  - Semantisch falsch: „Ich esse einen Schrank“

Semantik in dieser Vorlesung

- „Semantische Heterogenität ist ein überladener Begriff ohne klare Definition. Er bezeichnet die Unterschiede in Bedeutung, Interpretation und Art der Nutzung.“ [ÖV91]
- Wir meinen intuitive Semantik: Bedeutung von
  - Modellelementen (selten - Metamodellierung)
  - Schemaelementen (meistens)
  - Daten / Werten
- Vor allem wichtig: Gleiche / unterschiedliche Semantik
  - Beschreibung des Verhältnis der Semantik unterschiedlicher Elemente
  - Identität; Teilmenge; Schnittmenge; disjunkt; …

Semantik von was?

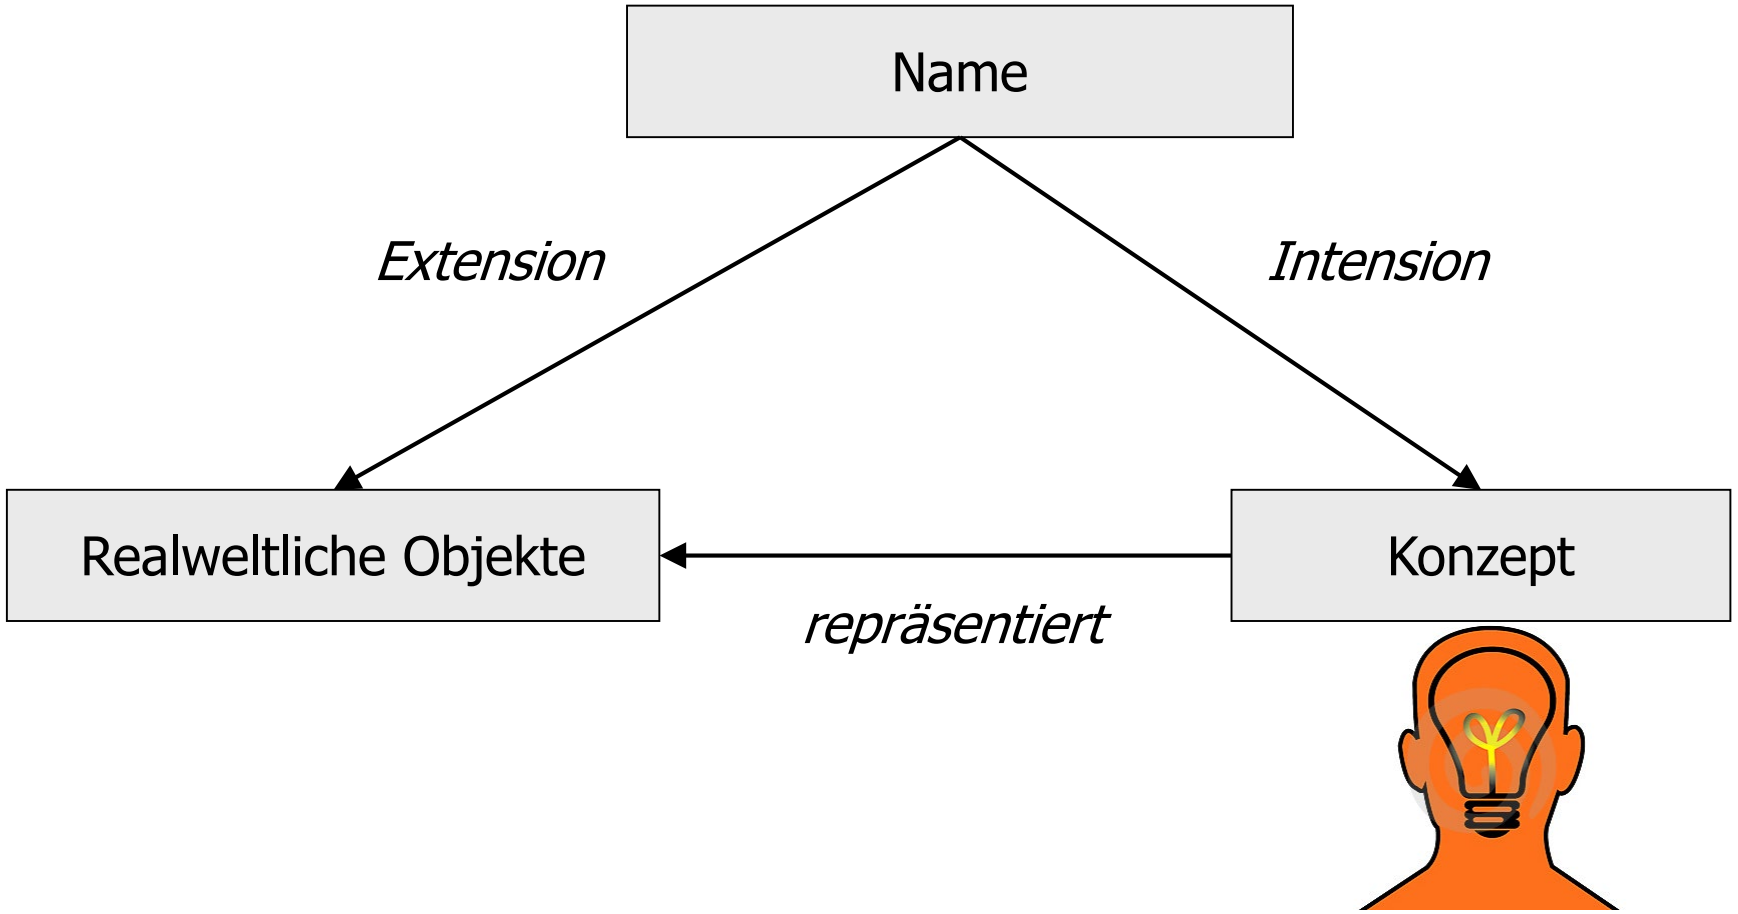

Beispiel

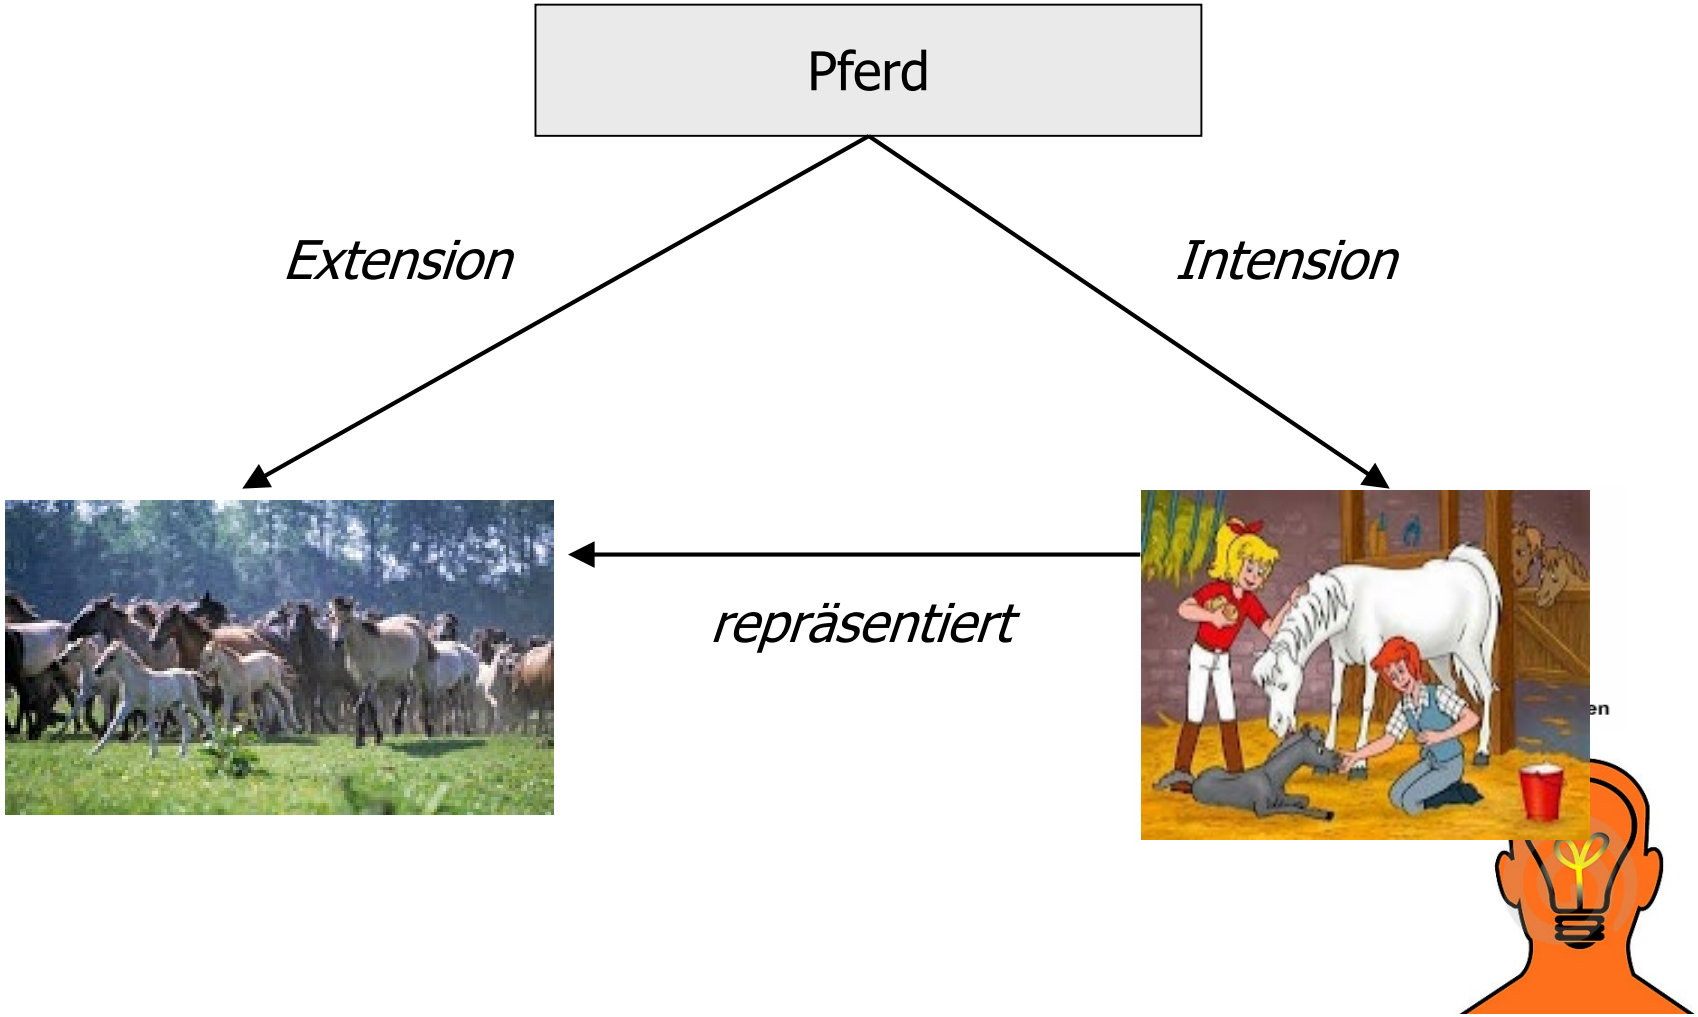

Leider

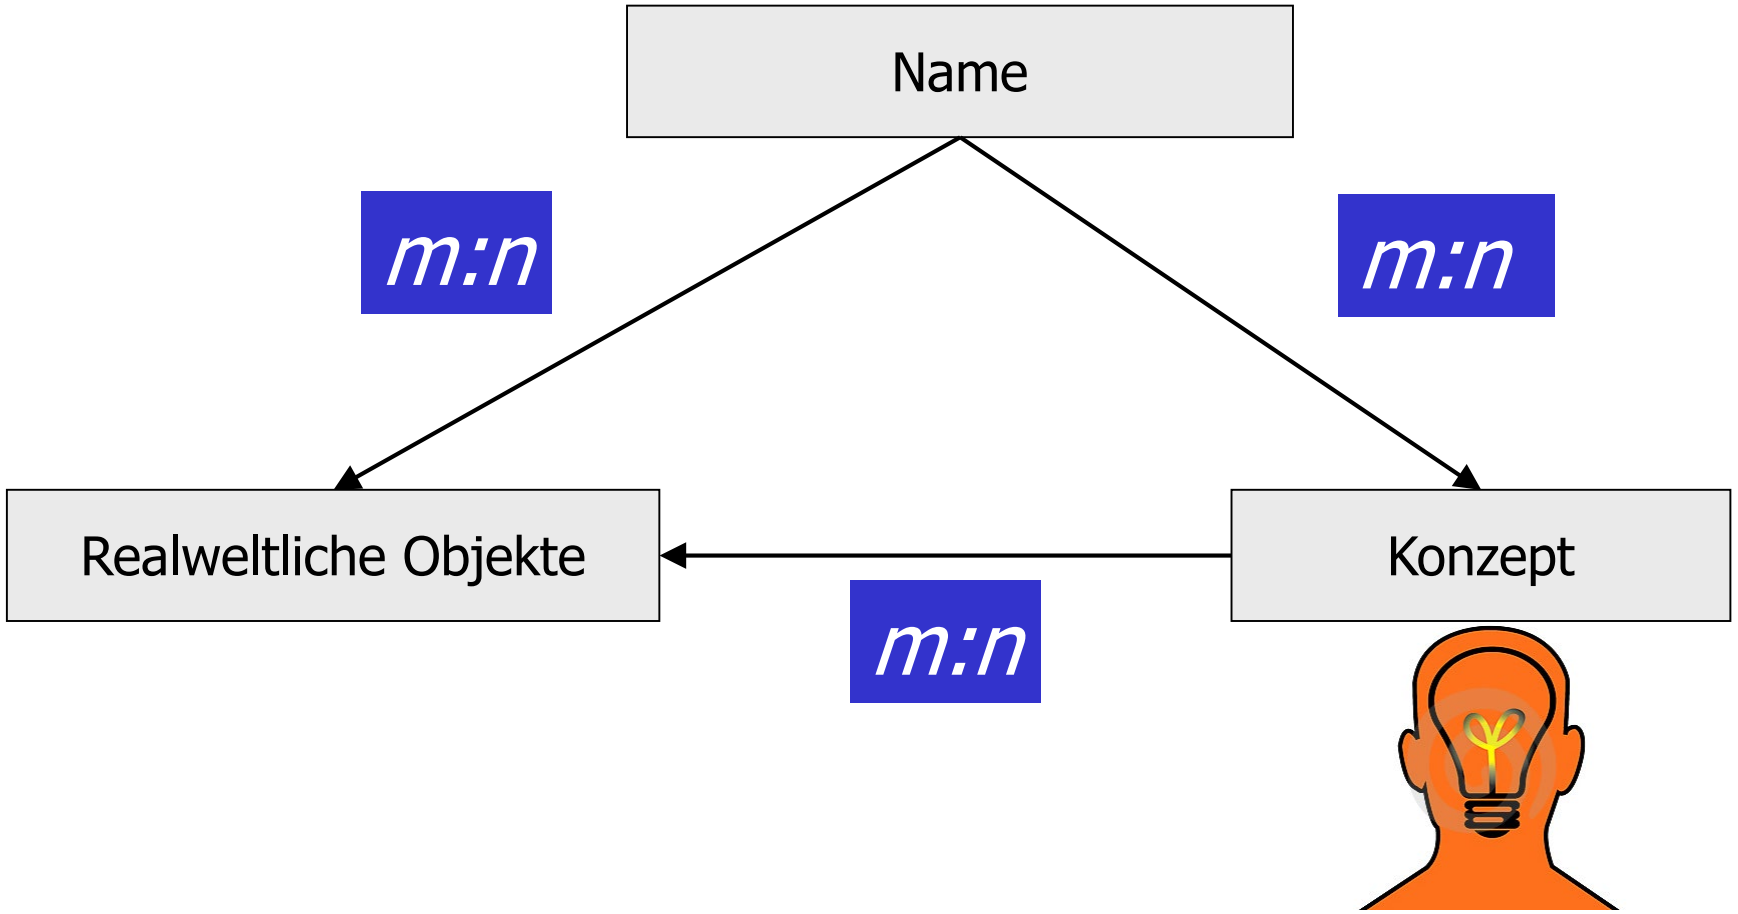

Synonyme

- Verschiedene Namen für dasselbe Konzept
  - Hoffentlich auch für dieselbe Extension
  - Synonyme können aber auch individuell sein
  - Kontext beachten

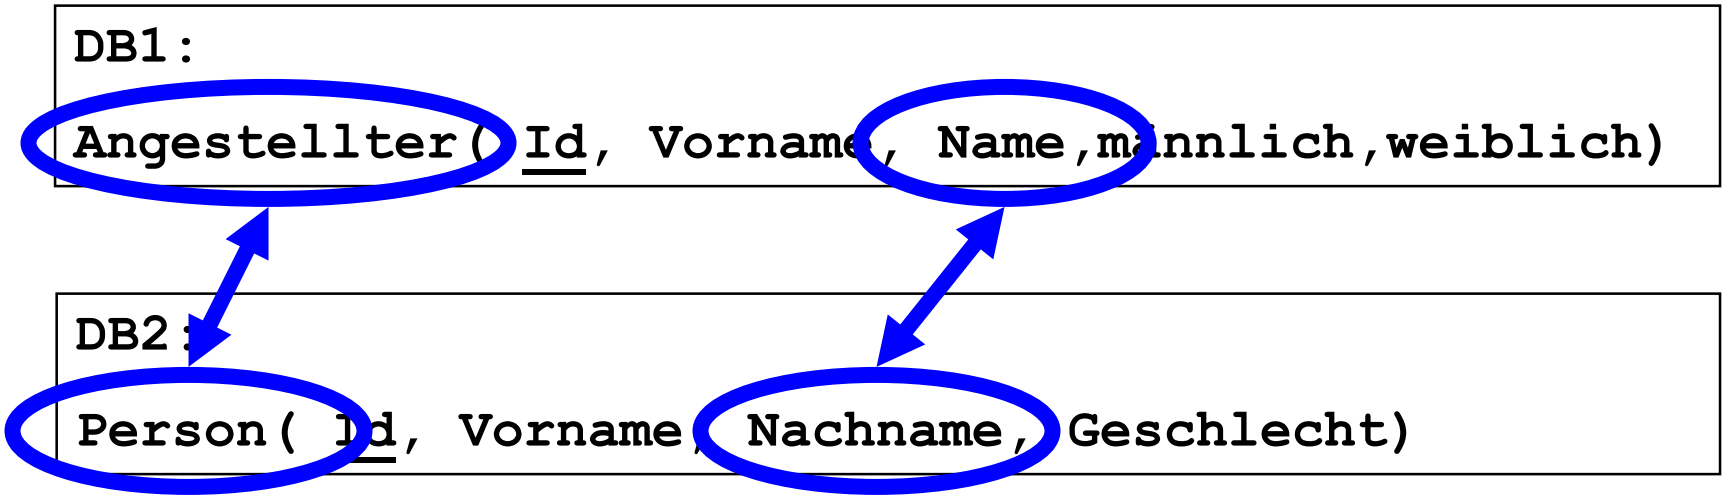

Homonyme

- Gleiche Namen für verschiedene Konzepte
  - Treten oft bei Überschreitung von Domänengrenzen auf

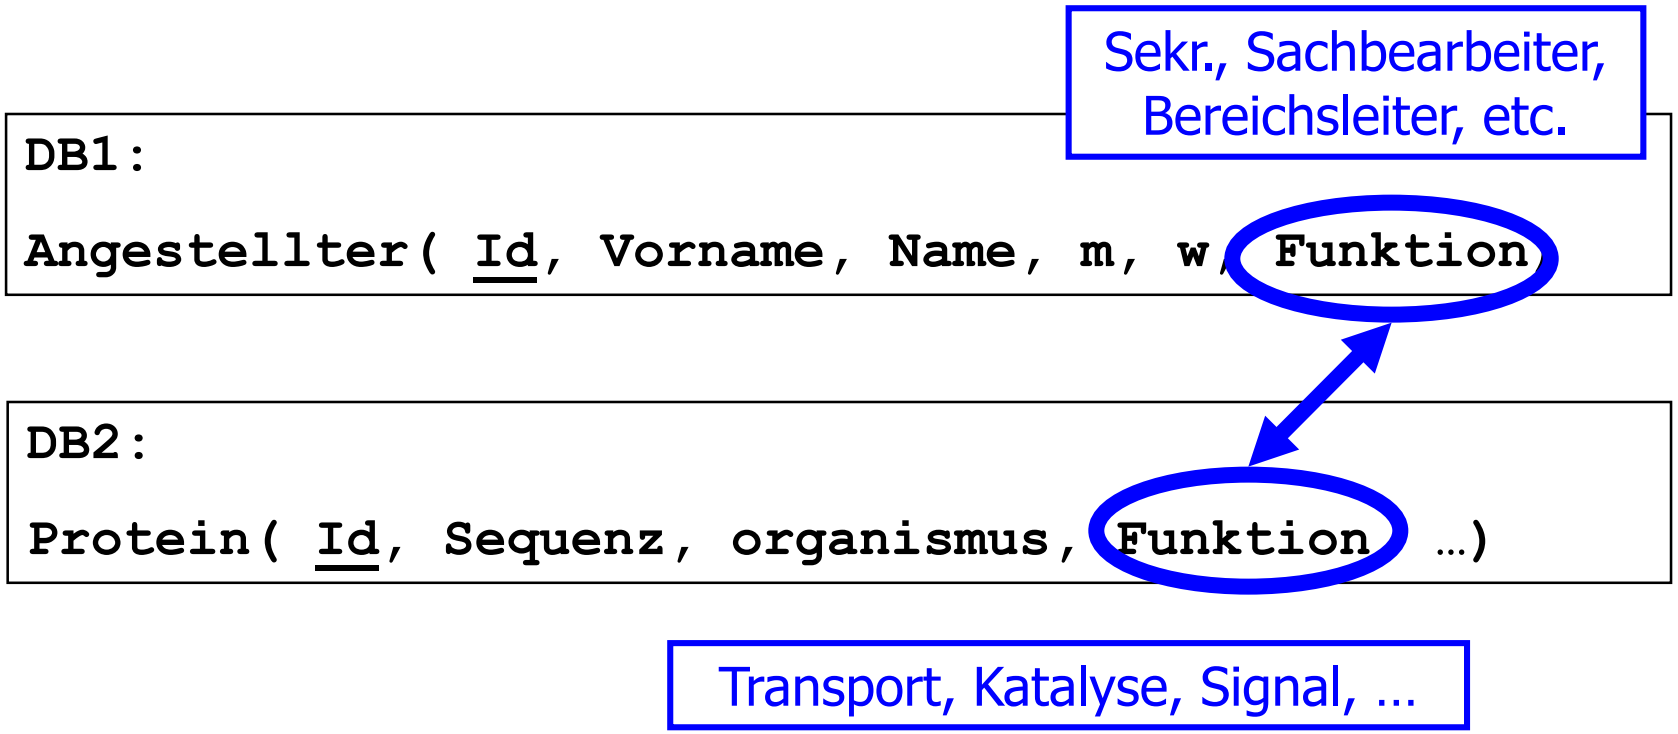

Konstellationen

- Seien a,b zwei Namen, a≠b, für die Konzepte A, B
- A=B: a und b sind Synonyme
  - Kreditinstitut-Bank? Schuppen-Scheune? Billig – preiswert?
- A⊆B: b ist Hyperonym (Oberbegriff); a ist Hyponym zu b
  - Tochter ⊆ Kind
- A ∩ B ≠ ∅ ∧ A≠B (Überlappung): Schwierigster Fall
  - Küche-Kochnische; Haus-Gebäude
- A ∩ B = ∅ (Disjunktion): a und b sind nicht verwandt
  - Schrank - Arbeitnehmer

Weitere -nym Wörter

- Antonym: Verschiedene Namen, gegenteilige Semantik
  - Hell-dunkel, billig-teuer, …
- Auto-Antonym: Gleiche Namen, gegenteilige Semantik
  - Transparenz
  - Left (bleiben, weggehen), clip (anhängen, ausschneiden)
- Heteronym: Gleiche Schreibung, verschiedene Aussprache, verschiedene Semantik
  - „It's the referee's job to record the new world record."
  - Moderne Kunst – modernde Baumstämme
- …
- http://www.fun-with-words.com/nym_words.html

Scheune

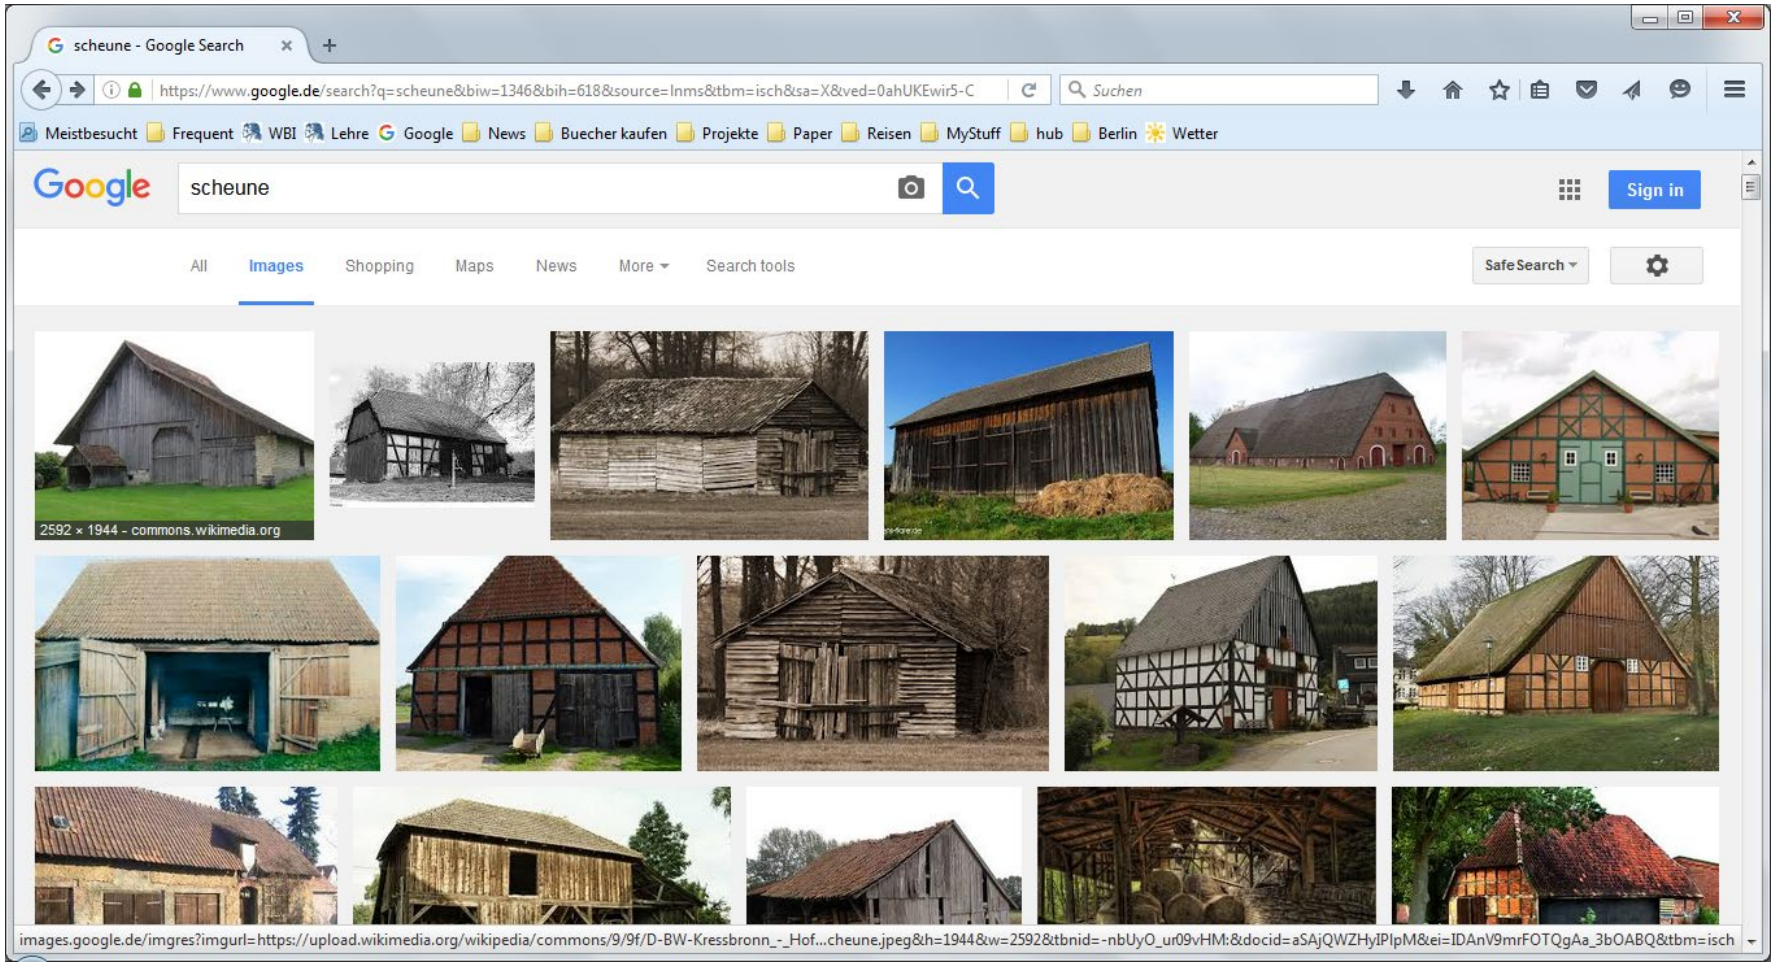
scheune - Google Search
https://www.google.de/search?q=scheune&biw=1346&bih=618&source=lnms&tbm=isch&sa=X&ved=0ahUKEwir5-C
Suchen
Meistbesucht Frequent WBI Lehre Google News Buecher kaufen Projekte Paper Reisen MyStuff hub Berlin Wetter
Google
scheune
Sign in
All Images Shopping Maps News More Search tools
Safe Search
2592 × 1944 - commons.wikimedia.org
images.google.de/imgres?imgurl=https://upload.wikimedia.org/wikipedia/commons/9/9f/D-BW-Kressbronn_-_Hof...cheune.jpeg&h=1944&w=2592&tbnid=-nbUyO_ur09vHM:&docid=aSAjQWZHyIPlpM&ei=IDAnV9mrFOTQgAa_3bOABQ&tbm=isch

Schuppen

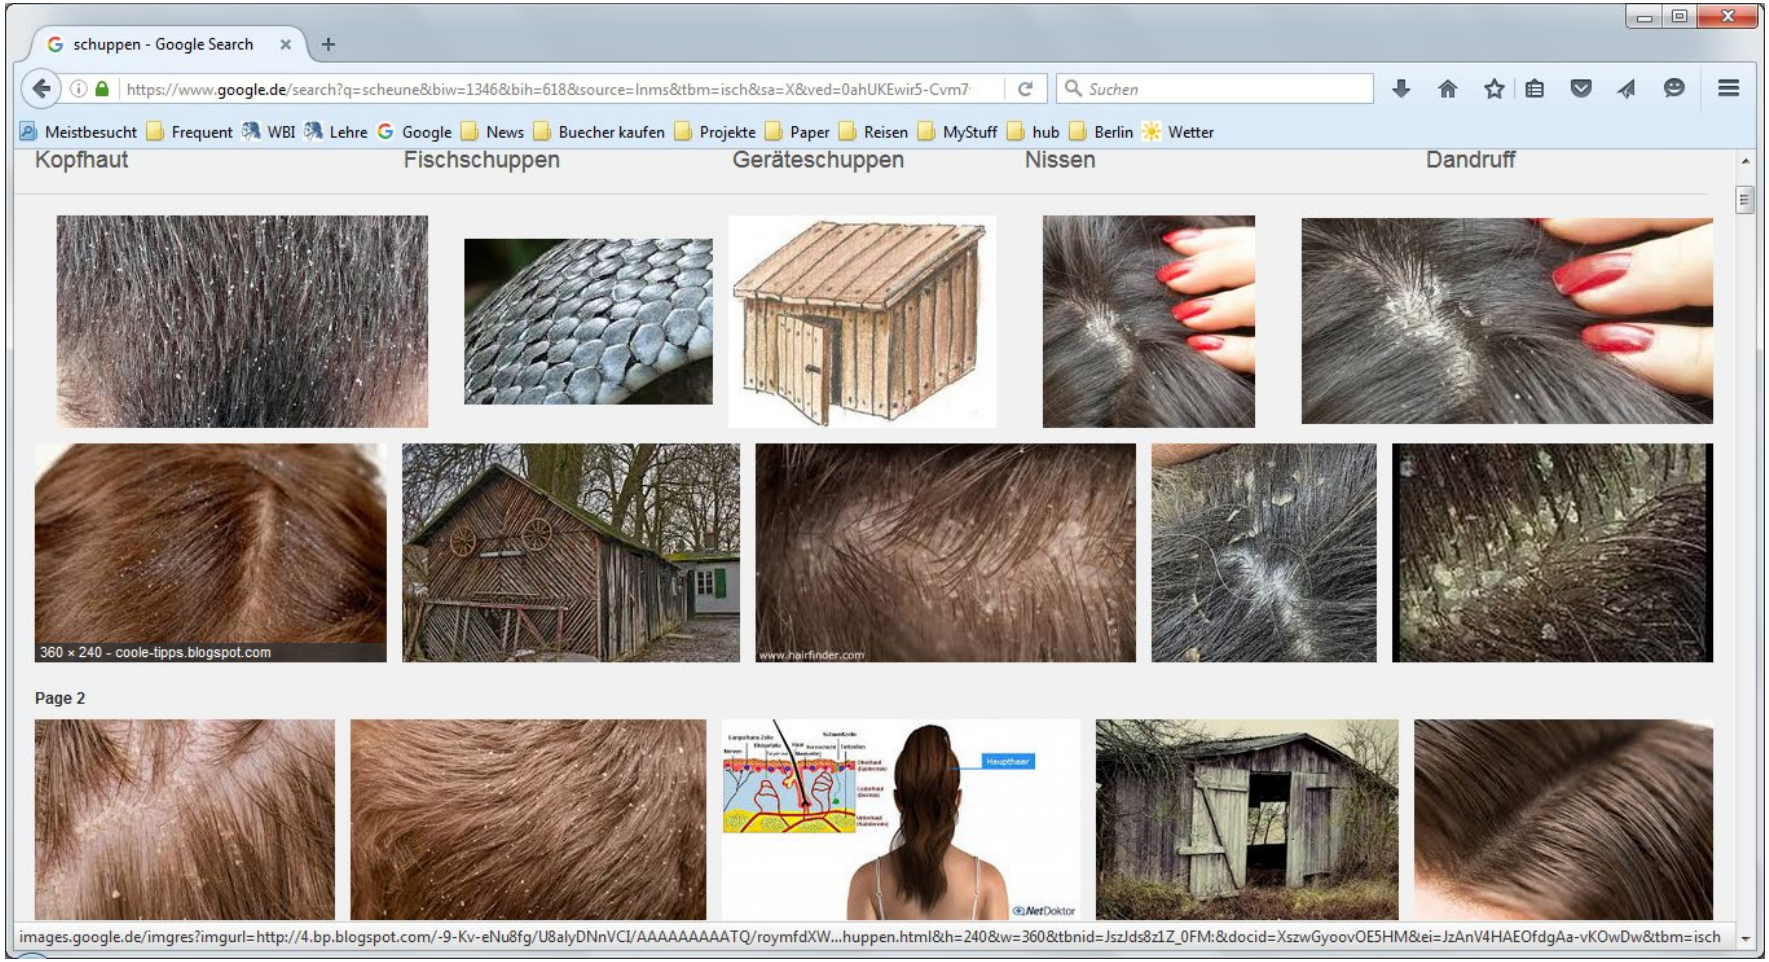
schuppen - Google Search
https://www.google.de/search?q=scheune&biw=1346&bih=618&source=lnms&tbm=isch&sa=X&ved=0ahUKEwir5-Cvm7
Suchen
Meistbesucht Frequent WBI Lehre Google News Buecher kaufen Projekte Paper Reisen MyStuff hub Berlin Wetter
Kopfhaut
Fischschuppen
Geräteschuppen
Nissen
Dandruff
360 × 240 - coole-tipps.blogspot.com
www.hairfinder.com
Page 2
Haupthaar
images.google.de/imgres?imgurl=http://4.bp.blogspot.com/-9-Kv-eNu8fg/U8alyDNnVCI/AAAAAAAAATQ/roymfdXW...huppen.html&h=240&w=360&tbnid=JszJds8z1Z_0FM:&docid=XszwGyoovOE5HM&ei=JzAnV4HAEOfdgAa-vKOwDw&tbm=isch

Schuppen Hütte

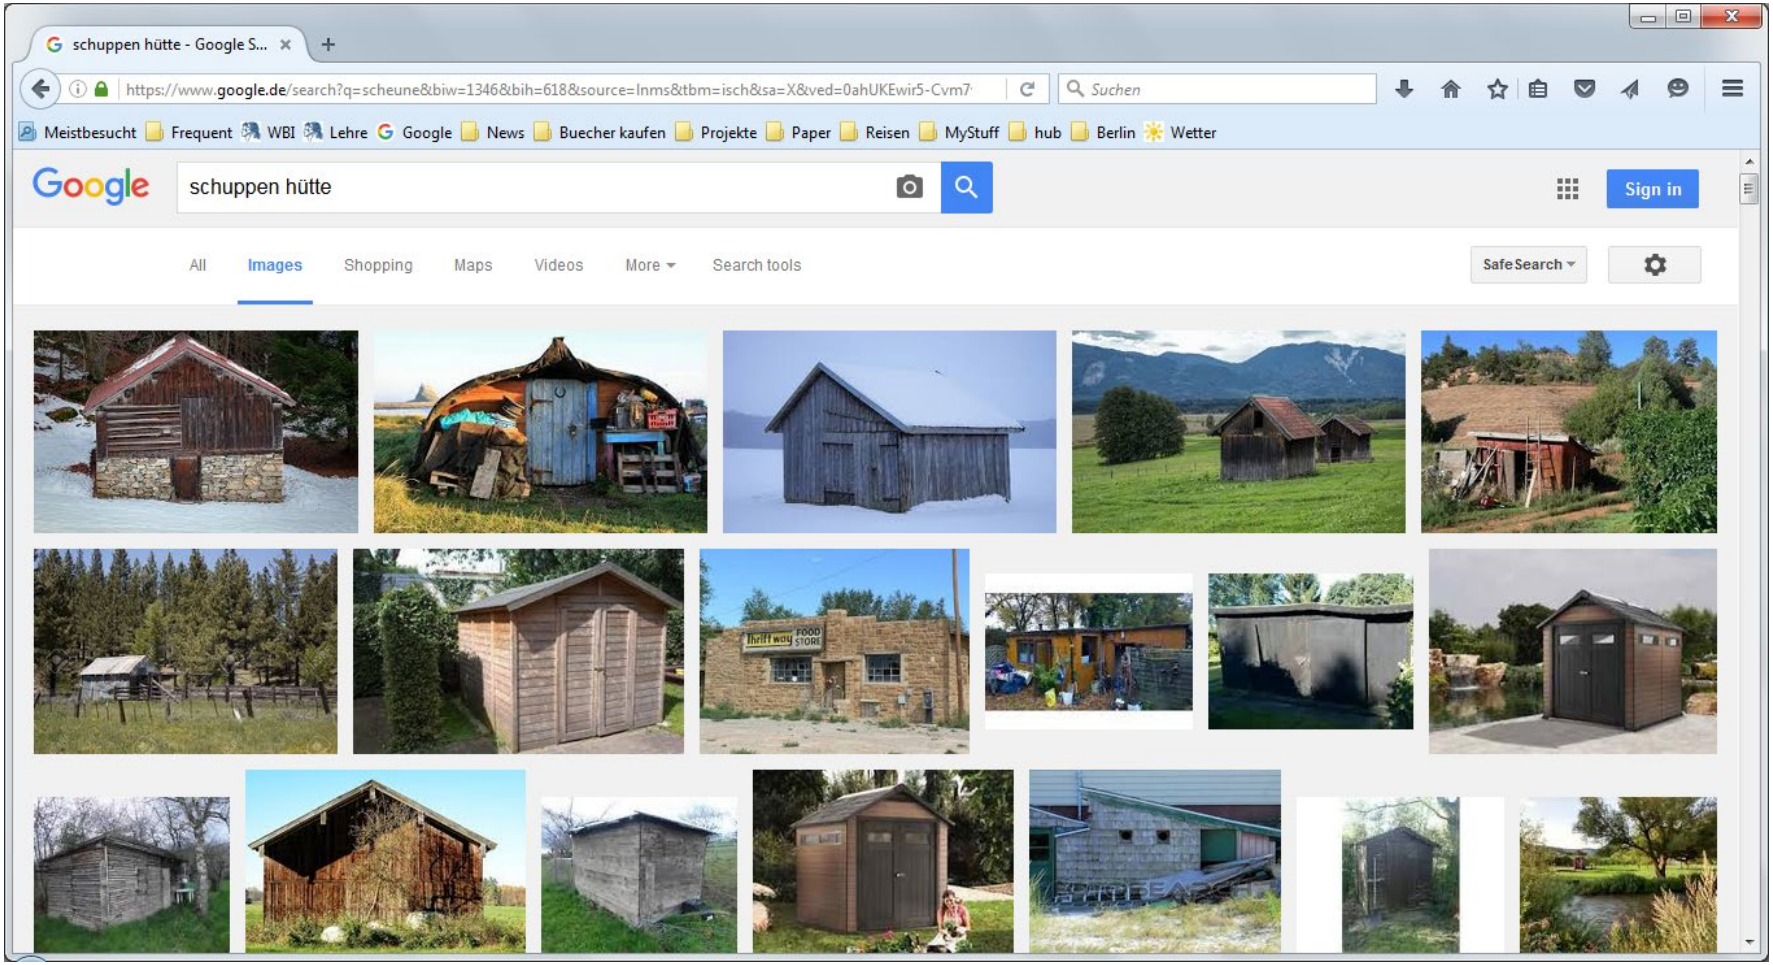

Semantik von Schemaelementen

- Schemaelemente sind nur Namen
- Was bestimmt die Semantik (Intension) eines Namens?
- Für Attributnamen
  - Datentyp
  - Constraints (Schlüssel, FK, unique, CHECK, …)
  - Zugehörigkeit zu einer Relation
  - Andere Attribute dieser Relation
  - Beziehung der Relation zu anderen Relationen
  - Dokumentation
  - Vorhandene Werte
  - Wissen über den Anwendungsbereich
  - Zusammen: Kontext

Bedeutung kann sich ändern

- Synonyme?
  - Prince, „The artist formerly known as prince“
  - Ja – dieselbe Person
  - Nein – dieselbe Person zu verschiedenen Zeiten
  - Temporale Abhängigkeit
- Synonyme?
  - England, Großbritannien
  - Ja – für uns
  - Nein – für Schotten
  - Abhängig vom kulturellen Hintergrund

Kontext

- Semantik eines Namens hängt vom Kontext ab
- Beispiel
  - Unternehmen A: angestellte(…)
  - Unternehmen B: mitarbeiter(…)
  - Mitarbeiter und Angestellte kann man als Synonyme betrachten
  - Aber: A.angestellte ∩ B.mitarbeiter = ∅
    - Wenn Personen nicht in zwei Unternehmen beschäftigt sind
  - Erst bei einem Merger von A und B werden A.angestellte und B.mitarbeiter zu Synonymen
  - Sollten dann zu einer Tabelle integriert werden

Semantik ist individuell

- Konzepte existieren nur im Kopf
- Man kann sie beschreiben, aber meint man auch dasselbe?
  - Individuelle Kenntnisse und Erfahrungen
- Also: Reden, reden, reden
- Dann: So gut wie möglich definieren
- Wie definiert man die Bedeutung eines Namens?
  - Formale Wissensrepräsentation (Ontologien, OWL – später)
  - Modellierungs- und Spezifikationssprachen (UML, Petri-Netze, Z, …)
  - Dokumentieren (mit lauter Namen)
- Standards definieren Bedeutung
  - Deshalb sind sie so schwierig und langweilig

Inhalt dieser Vorlesung

- Verteilung
- Autonomie
- Heterogenität
- Transparenz

Transparenz

- Verteilung, Autonomie, Heterogenität können in unterschiedlichem Maße überwunden werden
  - Ortstransparenz
    - Benutzer müssen den Ort der integrierten Systeme nicht kennen
    - Keine URLs, Datenbankpräfixe, …
  - Quellentransparenz, Verteilungstransparenz
    - Benutzer weiß nicht, welche Quelle für eine Anfrage benutzt wurde oder benutzt werden kann (Datenherkunft)
    - Setzt ein globales Schema voraus
  - Schnittstellentransparenz
    - Benutzer kann verschiedene Quellen gleich ansprechen
    - Keine Kenntnis lokaler Anfragesprachen, Protokolle, …
  - Schematransparenz (Spezialfall von Verteilungstransparenz)
    - Benutzer kennt die Schemata lokaler Quellen nicht
    - Anfragen richten sich nur an das (homogene) globale Schema

Transparenz ist nicht immer erwünscht

- Oft strebt man maximale Transparenz an
- Oft ist aber kontraproduktiv
  - Benutzer kennen und vertrauen bestimmte(n) Datenquellen
  - Datenherkunft ist wichtigstes Kriterium für Einschätzung der Qualität der Informationen
  - Globales Schemas bedeutet, dass Benutzer neues Schema lernen müssen
  - Globale Schemata können sehr kompliziert werden
- Transparenz bedingt auch Informationsverlust