

Informationsintegration

Semantic Web

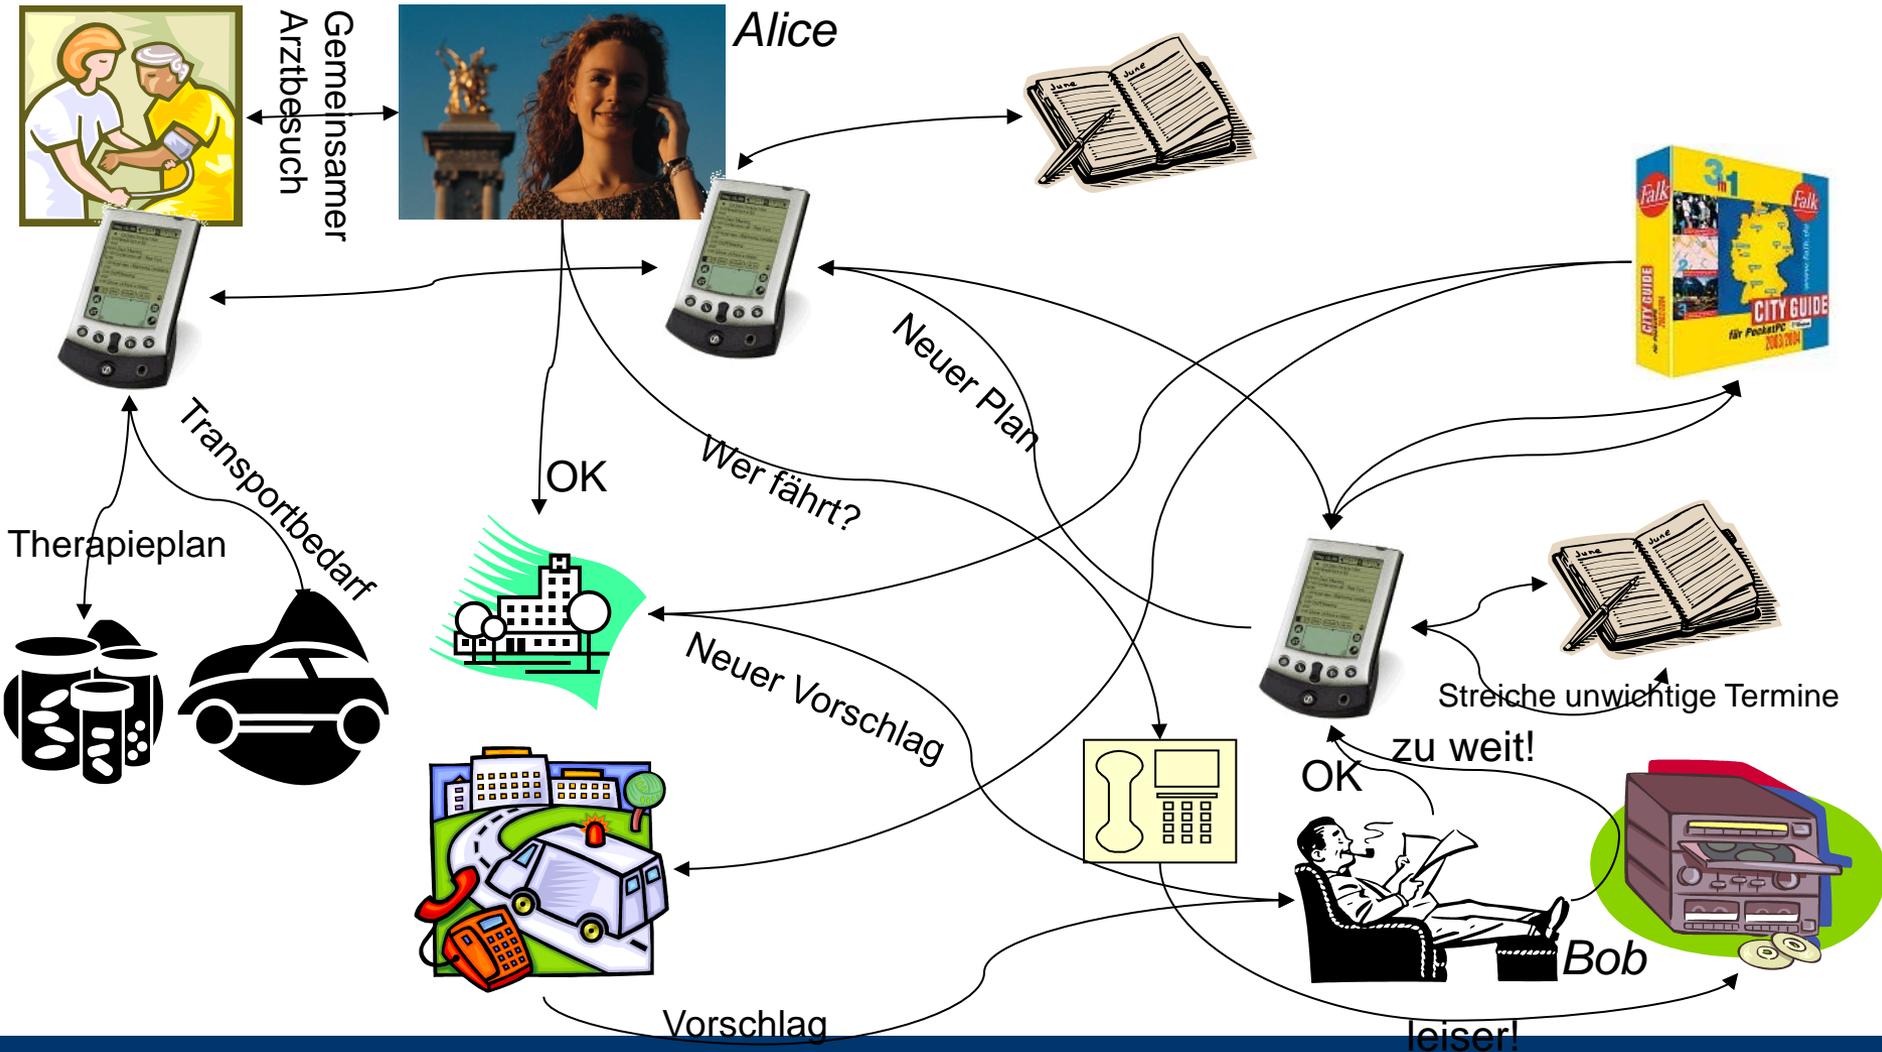
Ulf Leser

Inhalt dieser Vorlesung

- Grundidee des Semantic Web
- Layer Cake
- RDF und RDFS
- SparQL
- Die OWL Sprachfamilie

- „Das Semantic Web ist eine **Erweiterung** des gegenwärtigen Web, in der Informationen eine wohldefinierte **Bedeutung** erhalten, so dass Computer und Menschen besser **zusammenarbeiten** können“
[BHL01]
 - Erweiterung, kein Neudesign; Abwärtskompatibilität ist essentiell
 - Zusammenarbeit zwischen Menschen und Computern und Computern und Computern verbessern
 - Integration von Daten und Anwendungen
 - Intelligentere, persönliche, kontextbezogene, ... Dienste
 - Mittel: Explizite Definition der Bedeutung von Informationen
- Sollte als **Vision** verstanden werden
 - An deren Erfüllung man arbeitet (z.B. W3C)

Szenario [BHL01]



Ist-Zustand

- Web Seiten werden in HTML verfasst
- Geprägt von Layout-Informationen
 - Gut für Menschen
 - Kaum zu interpretieren für Rechner
- Informationen leben in **zwei Welten**
 - Für Menschen als Konsumenten
 - Gedichte, Filme, Text,...
 - Für Computer als Konsumenten
 - Daten, Programme,...
- Das Web betont den Menschen
- Das **Semantic Web** soll dies ausgleichen

Beispiel-Anwendungen

- Wissensmanagement
 - Intranet mit Millionen Dokumenten
 - Informationsbeschaffung, -wartung und -suche
 - Anfragen statt Suche
 - Liste alle Telefonnummern aller Mitarbeiter der HU Informatik
 - Wann wurde Rembrandt geboren?
 - Wann wurden die großen niederländischen Maler geboren?
- Web Commerce
 - Shopping-Agenten suchen bestes und billigstes Angebot
 - Online Shops präsentieren Waren zielgerichtet (Präferenzen)
 - Broker vermitteln gezielt zwischen Anbietern und Käufern (e-marketplace)
- E-Business
 - Virtuelle Unternehmen

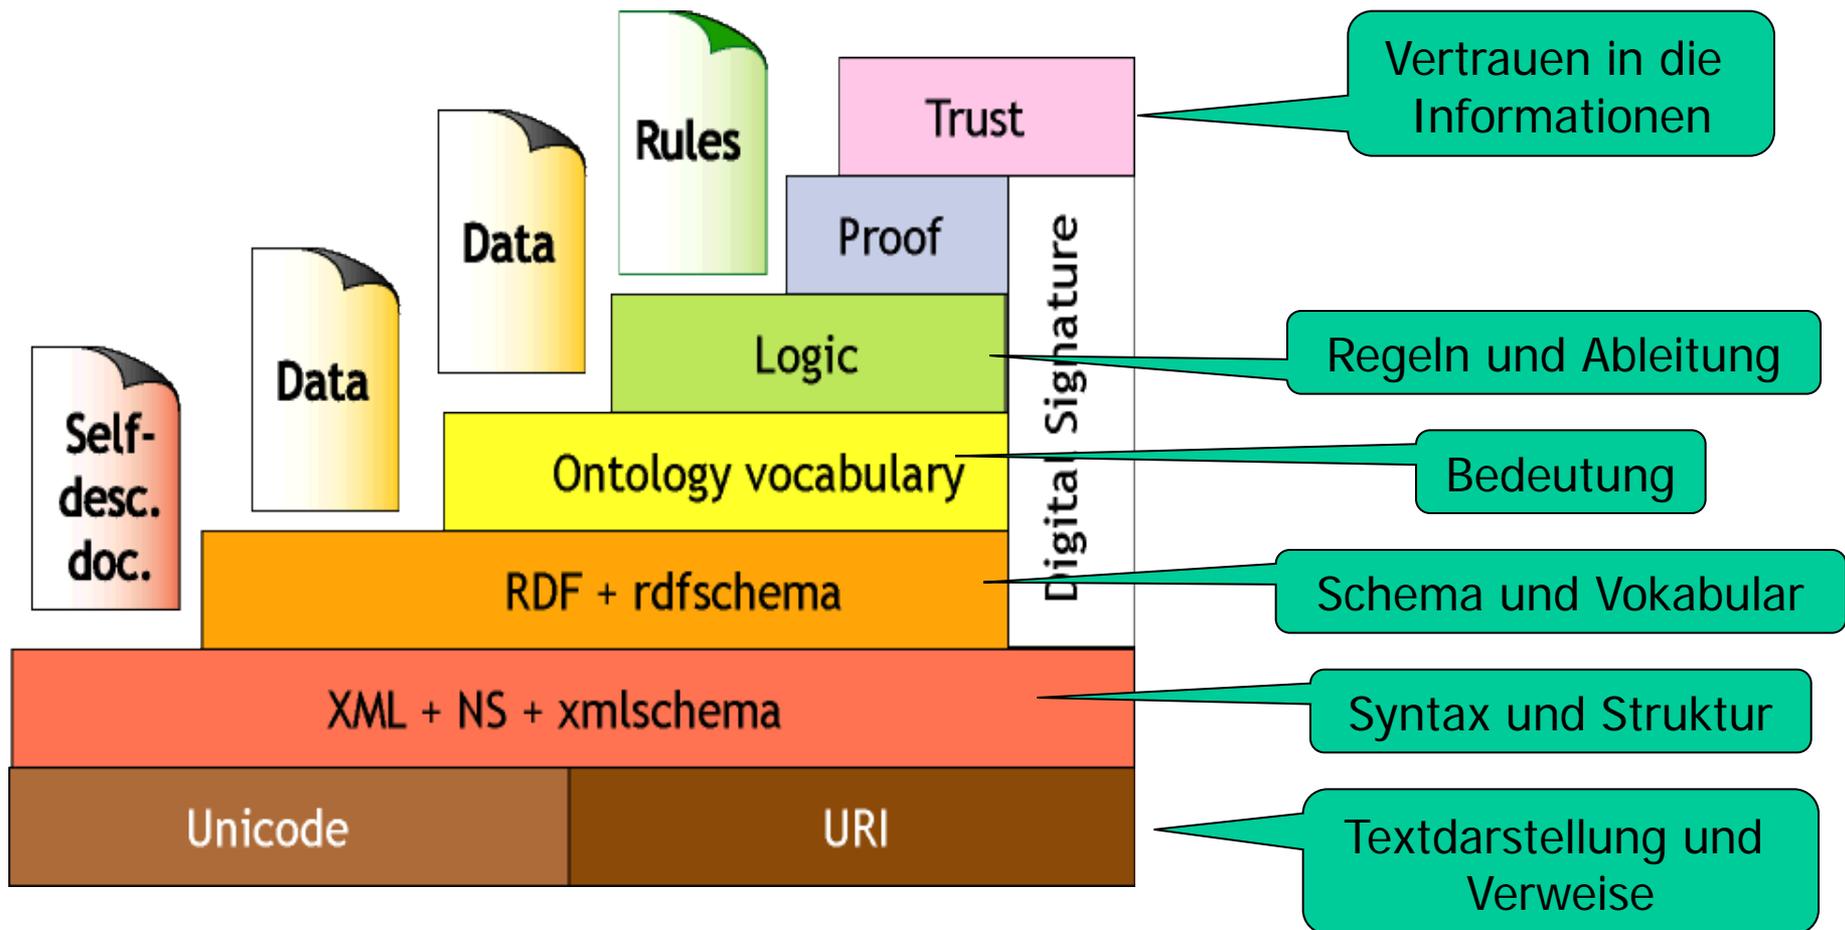
Grundprinzipien „Semantic Web“

- Semantik wird durch **Annotation und Verweise** spezifiziert
- **Uniform Resource Identifier (URI)**
 - Sage nicht „farbe“, sage "http://www.pantomime.com/std6#farbe"
 - Definitionen können im Laufe der Zeit ergänzt werden
 - Definitionen können jederzeit verändert oder ersetzt werden
- **Keine Erzwingung von Konsistenz** oder Kontinuität
 - Ist „http://www.pantomime.com/std6#farbe“ noch dasselbe?
 - Ist „http://www.pantomime.com/std6#farbe“ dasselbe wie „http://www.colors.com/colors“?
 - „Jeder kann **Beliebiges über Beliebiges sagen**“
- **Sehr lose Koppelung**
 - Kein einzelnes System weiß alles
 - Hochgradig dezentrales Design
 - Preis: Keine Sicherstellung von Konsistenz

Inhalt dieser Vorlesung

- Grundidee des Semantic Web
- Layer Cake
- RDF und RDFS
- SparQL
- Die OWL Sprachfamilie

Semantic Web „Layer Cake“



Quelle: [Hen02]

1+2. Unicode, URI und XML

- Unicode / URI
 - Semantikfrei
 - Unicode: Standard zur binären Repräsentation von Zeichen
 - URI: Identifikation von virtuellen oder physischen **Ressourcen**
 - **URI ist ein Schlüssel**
- XML / Namespaces / XML Schema
 - Standard zur Darstellung **strukturierter Daten**
 - Mit geeigneter Kodierung auch für nicht-hierarchische Daten
 - Serialisierung von Daten in XML
 - Z.B. für RDF, OWL, Relationen, ...
 - Definition von **Schemata** (inkl. Datentypen) für Daten
 - Austauschschema, nicht notwendigerweise Daten-/Speicherschema

3. Resource Description Framework

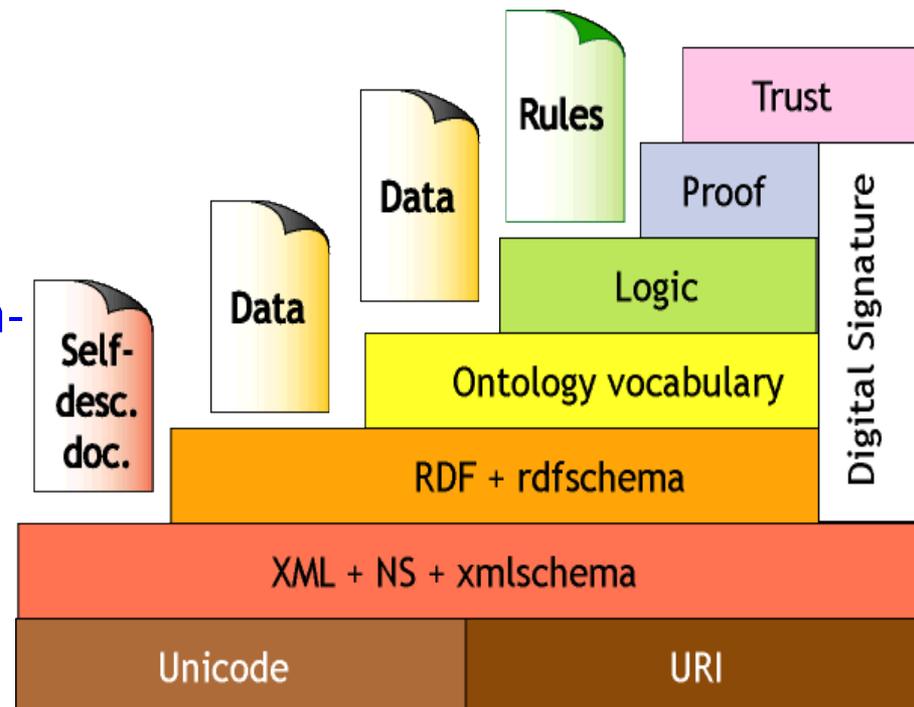
- Graphbasiertes Datenmodell
- Informationen werden als Tripel modelliert
 - (Subjekt Prädikat Objekt)
 - Beschreibung der Werte von Eigenschaften von Ressourcen
 - Erlaubt Aussagen über alles mögliche
 - Insbesondere auch über andere Aussagen -> später
- **RDF Datenbasis** = Menge von Tripeln
- RDFS („RDF Schema“)
 - Festlegung eines **Vokabulars für RDF Datenbasen**
 - Typisierung von RDF Daten
 - Datentypen, Spezialisierung, getypte Beziehungen, ...
- Gleich mehr dazu

4. Ontology Vocabulary

- Konzeptualisierung von Domänen
- Ressourcen erhalten Bedeutung durch **Einbettung in eine formale Ontologie**
- Interoperabilität von RDF Datenbasen durch Verwendung **derselben Ontologie**
 - Beziehungen von Konzepten über Datenbasis-Grenzen hinweg
 - Bei verschiedenen Ontologien: Ontologie-Alignment
- Alles freiwillig, **lose Kopplung**
 - RDF Dokumente müssen nicht zu RDFS-Definitionen konform sein
 - Konzepte müssen nicht durch Ontologien untermauert werden
 - Alles kann sich ständig ändern

5-7. Logic, Proof, Trust

- Klingt gut, aber ...
 - Keine klare Aufteilung
 - Logic: Inferenz einer Wissensrepräsentationssprache wie OWL
 - Proof: ?
- Trust
 - Maßnahmen zur Beurteilung des **Vertrauens** in Daten und Schlüsse
 - Schutz vor **Spam-Seiten, Spam-RDF-Datenbanken, Spam-Ontologien**
 - Sehr schwierige Umsetzung



Inhalt dieser Vorlesung

- Grundidee des Semantic Web
- Layer Cake
- **RDF und RDFS**
- SparQL
- Die OWL Sprachfamilie

RDF Grundlagen

- Grundlegendes Element sind **Aussagen** bestehend aus
 - Ressource (Subjekt)
 - Eigenschaft (Prädikat)
 - Ressource (Objekt)
- Beispiel: „Hitchcock ist der Regisseur von Marnie“
 - RDF-Tripel: (**Hitchcock**, **www.duden.de/regisseur**, **Marnie**)
 - Serialisiert in XML

```
<?xml version="1.0">
<rdf:RDF xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#">
  <rdf:Description rdf:about="Alfred Hitchcock">
    <ist_regisseur_von> Marnie </ist_regisseur_von>
  </rdf:Description>
</rdf:RDF>
```

- **Prädikatenlogik**: **istRegisseur(Hitchcock, Marnie)**

Mehr-arige Prädikate

- RDF Tripel können nur **binäre Prädikate** ausdrücken
- Für ternäre, quartäre, ... Prädikate müssen „künstliche“ Ressourcen erschaffen werden
 - Ein „Schlüssel“ pro Tupel
 - Können als **Blank Nodes** realisiert werden (später)
 - Im Grunde ist das Skolemisierung
- „Hitchcock hat 1964 den Film Marnie gedreht“
 - Neue künstliche Ressource **MarnieFilm**

`(MarnieFilm, gedreht_von, Hitchcock)`

`(MarnieFilm, hat_titel, Marnie)`

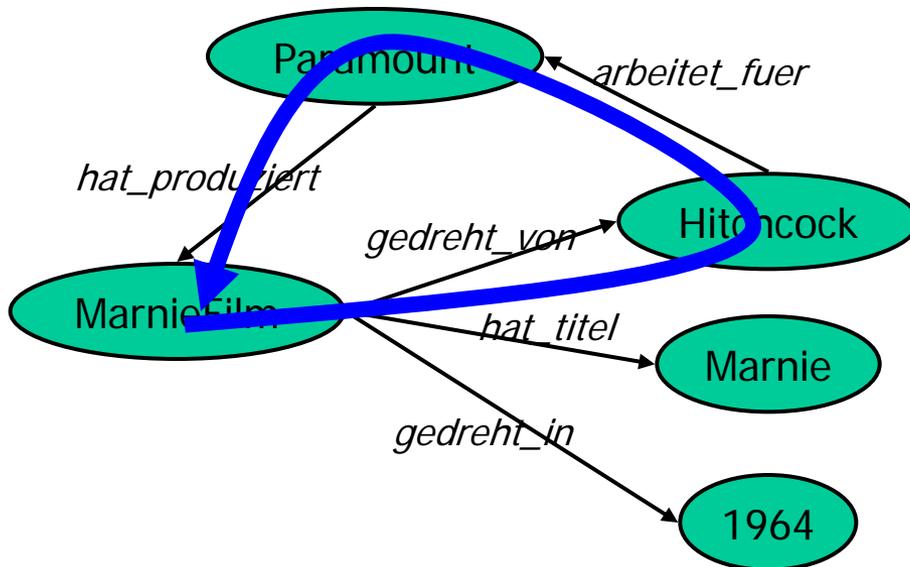
`(MarnieFilm, gedreht_in, 1964)`

RDF als Graph

- Graphen als natürliche Repräsentation von RDF
- Naiver Ansatz (so stand es in den W3C Dokumenten)
 - **Subjekte und Objekte** werden Knoten
 - **Prädikate** sind Kanten
- Eigenschaften des Graphen
 - (Alle) Knoten haben eindeutige Label (URI oder Literal)
 - Kanten sind gerichtet und haben keine eindeutigen Label
 - Knoten können durch mehr als einer Kante verbunden sein (**Multigraph**)

RDF als Graph

(MarnieFilm gedreht_von Hitchcock)
(MarnieFilm hat_titel Marnie)
(MarnieFilm gedreht_in 1964)
(Paramount hat_produziert MarnieFilm)
(Hitchcock arbeitet_für Paramount)



Problem

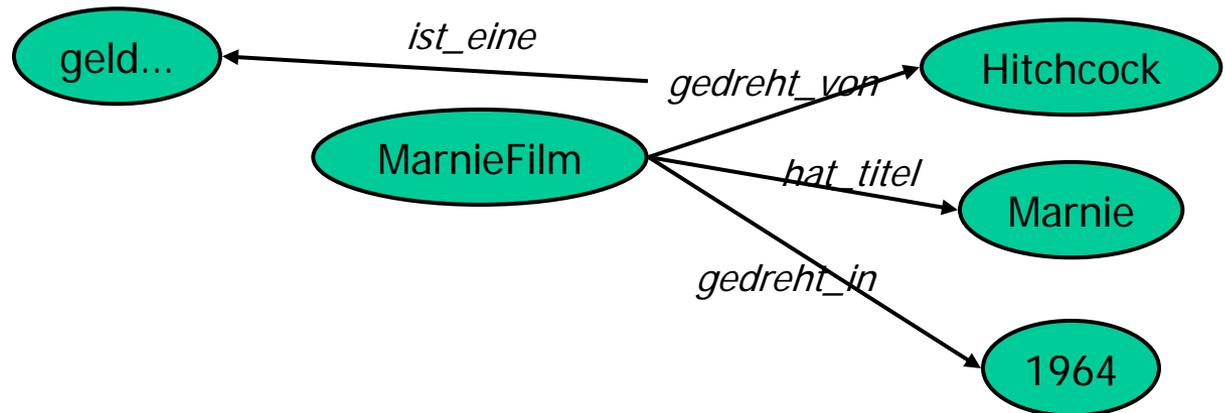
- Auch **Prädikate sind Ressourcen**
- Über die kann man Aussagen machen
- Erfordert **Kanten von/auf Kantenlabel**

(MarnieFilm gedreht_von Hitchcock)

(MarnieFilm hat_titel Marnie)

(MarnieFilm gedreht_in 1964)

(gedreht_von ist_eine gelderwerbstaetigkeit)



Warum ist **gedreht_von** kein Knoten?

Problem

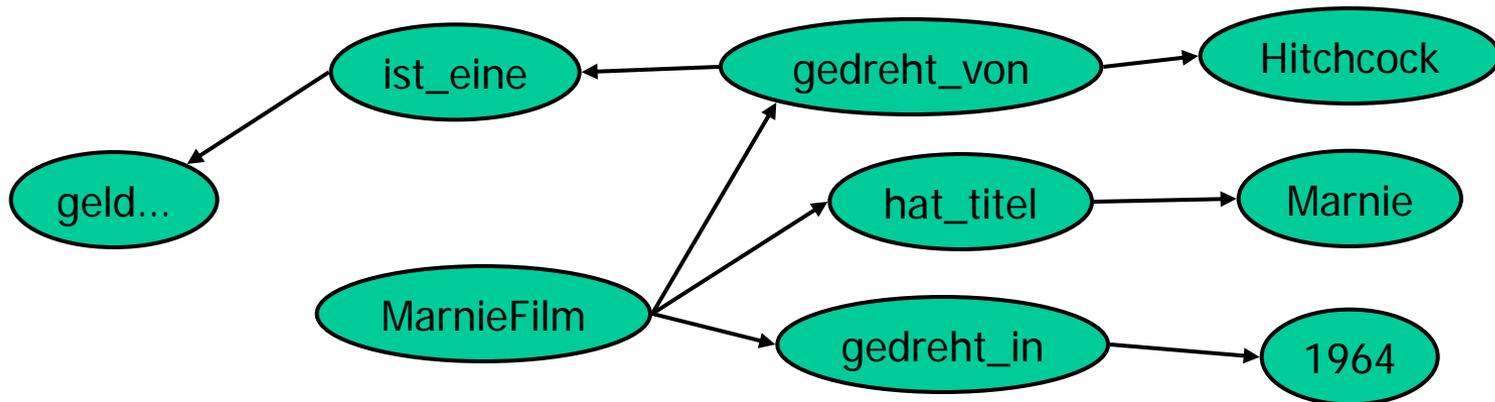
- Auch Prädikate sind Ressourcen
- Über die kann man Aussagen machen
- Erfordert Kanten von/auf Kantenlabel

(MarnieFilm gedreht_von Hitchcock)

(MarnieFilm hat_titel Marnie)

(MarnieFilm gedreht_in 1964)

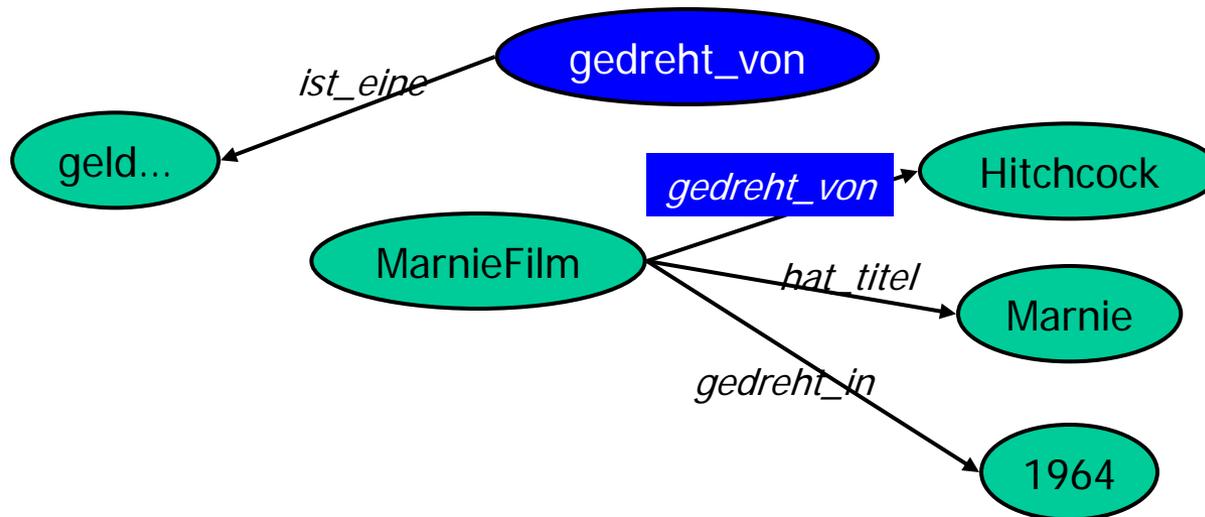
(gedreht_von ist_eine gelderwerbstaetigkeit)



Wo sind unsere Aussagen?

Offizielle Version?

- Unklar [W3C Spezifikationen]
 - „The nodes of an RDF graph are its subjects and objects.”
 - „A URI reference or literal used as a node identifies what that node represents. A URI reference used as a predicate identifies a relationship between the things represented by the nodes it connects. **A predicate URI reference may also be a node in the graph.**”



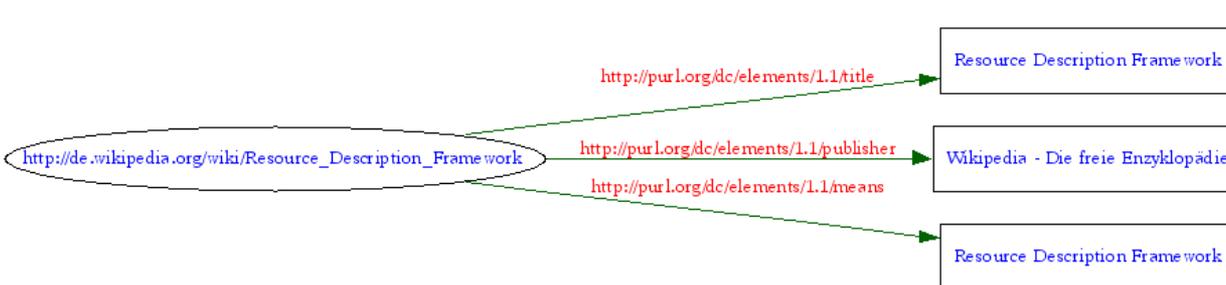
Eindeutigkeit von Labels

- Unklar

- „An *RDF graph* is a set of RDF triples.
- The set of *nodes* of an RDF graph is the set of subjects and objects of triples in the graph.“
- Aber: W3C's RDF Validator

```
1: <?xml version="1.0" encoding="UTF-8" ?>
2: <rdf:RDF xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#"
3:     xmlns:dc="http://purl.org/dc/elements/1.1/">
4:   <rdf:Description rdf:about="http://de.wikipedia.org/wiki/Resource_Description_Framework">
5:     <dc:title>Resource Description Framework</dc:title>
6:     <dc:publisher>Wikipedia - Die freie Enzyklopädie</dc:publisher>
7:   </rdf:Description>
8:   <rdf:Description rdf:about="http://de.wikipedia.org/wiki/Resource_Description_Framework">
9:     <dc:means>Resource Description Framework</dc:means>
10:   </rdf:Description>
11: </rdf:RDF>
```

Graph of the data model

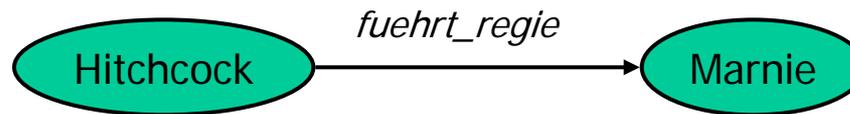


Aussagen über Aussagen

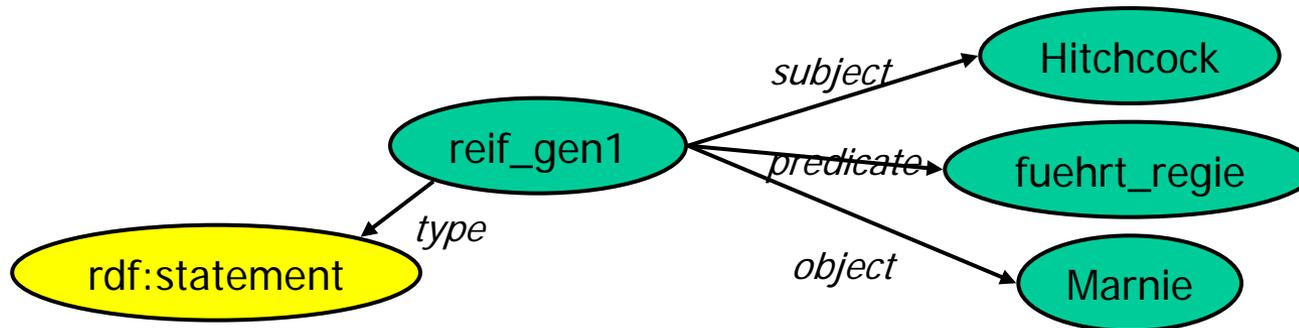
- In RDF kann man **Aussagen über Aussagen** machen
 - Hitchcock ist der Regisseur von Marnie
 - **Joe denkt**, dass Hitchcock der Regisseur von Marnie ist
- Um eine Aussage über eine Aussage X machen zu können, muss man X **reififizieren**
 - Reification = „Verdinglichung“
 - Eine Aussage wird als Ressource behandelt
- Vorgehen für Aussage (S P O)
 - Man schafft einen **neue Ressource R** vom Typ `RDF:Statement`
 - Drei Aussagen: `(R subject S) (R predicate P) (R object O)`
 - R kann normal verwendet werden: `(Joe denkt R)`

Grafisch

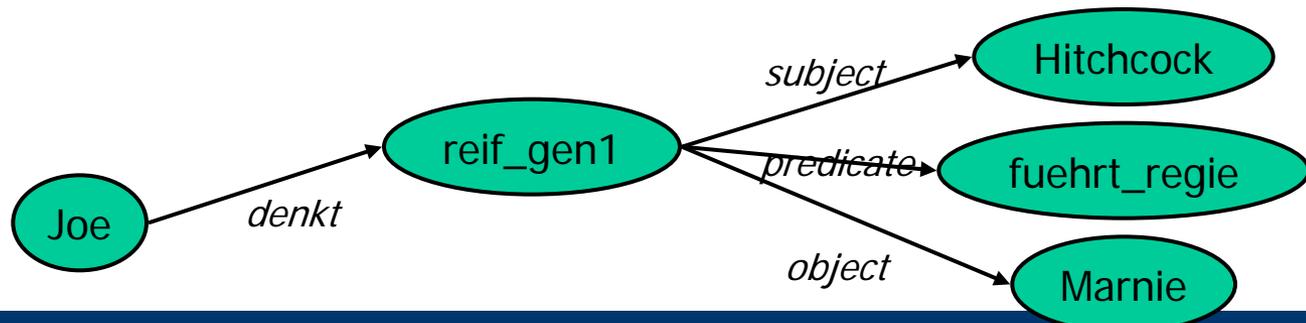
- „Hitchcock ist der Regisseur von Marnie“



- Reifiziert

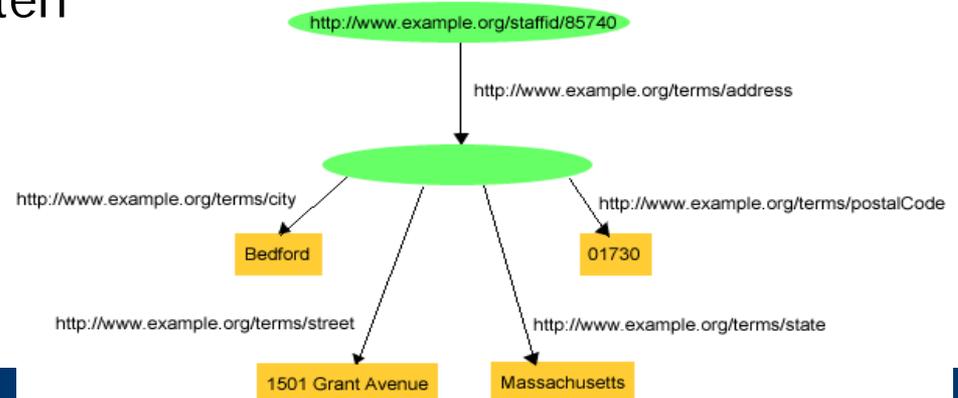


- „Joe denkt, dass Hitchcock der Regisseur von Marnie ist“



Weitere RDF Konzepte

- Aussagen über **Mengen von Ressourcen**
 - Gruppierung von Aussagen in Bags und (geordneten) Sequenzen
- Ressourcen können einen **Typ** haben
 - Wird im Allgemeinen nicht weiter interpretiert
 - Spezielle interpretierte Typen wie `rdf:statement`, `rdf:bag`, ...
- „**Blank Nodes**“ – oft ignoriert
 - Statt URIs und Literalen können auch „Blank Nodes“ als Subjekt und Objekt verwendet werden
 - Bringt viele Schwierigkeiten
 - Gutartige Verwendung – **n-arige Prädikate**
 - Beispiel: Adresse mit 5 Elementen



Probleme mit Blank Nodes

- Blank Nodes identifizieren sich nur über ihre Umgebung
- Sie nehmen praktisch die Rolle von Variablen ein

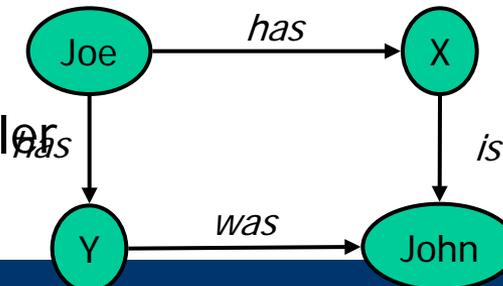
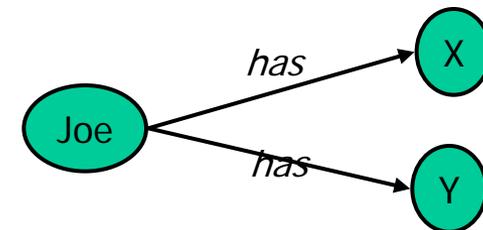
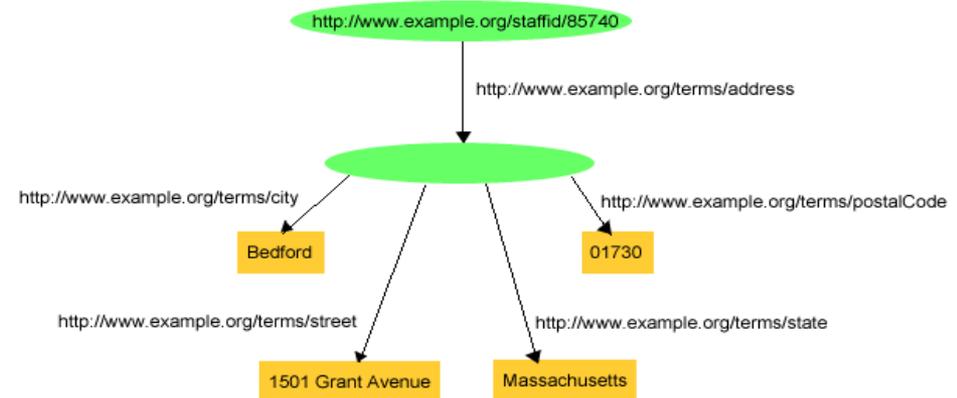
- (Peter address ?)
- (? City Bedford)
- (? Street „Grant Avenue“)
- (...)
- (Paul address ?)

- Besser

- (Peter address X)
- (X City Bedford)
- (X Street „Grant Avenue“)
- (...)
- (Paul address Y)

- RDF-Graphen nicht eindeutig

- Verschiedene Graphen – Ergebnisse aller möglichen Anfragen sind gleich



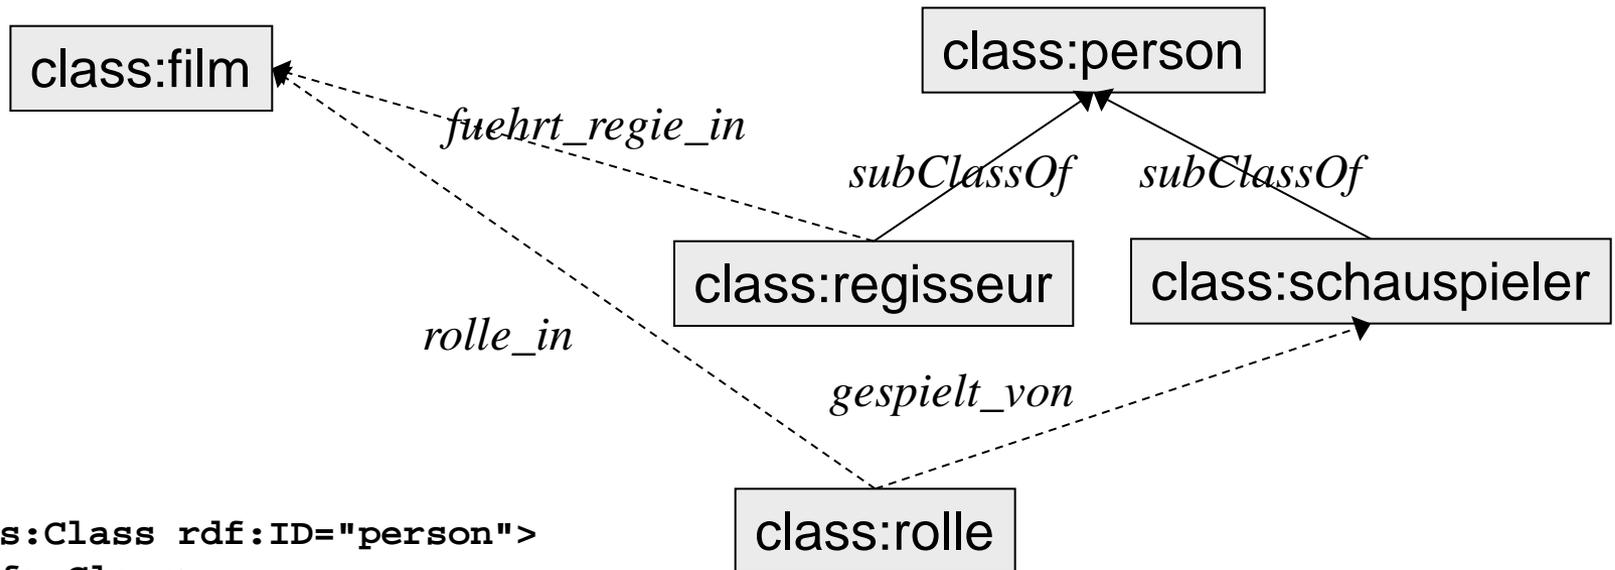
Bewertung von RDF

- Sehr **flexibles Datenmodell**
 - Keine Trennung von Dingen und Beziehungen
 - Blank nodes für n-arige Relationen
 - Sagen nur: Es existiert ein Knoten, der ... (aber geben keine Identifikation)
 - RDF Graphen sind eine Mischung aus Extension und Intension
 - Reifikation
 - Kann man **nicht auf Aussagen in PL-I** abbilden
- Für Massendaten nicht geeignet (und nicht gedacht)
- Geeignet für **heterogene, schwach strukturierte und wissensintensive** Anwendungen
 - Format zur Definition Semantischer Netze

RDFS – Schemata für RDF

- Eine RDF Datenbasis ist vollkommen frei in den verwendeten Begriffen
 - Kein Schema – das erschwert die Analyse
- RDFS
 - RDFS: [RDF Vocabulary Description Language](#)
 - Spezifikation von
 - Typen von Ressourcen (rdfs:class)
 - [Subtypbeziehungen](#) zwischen Typen (rdfs:subClassOf)
 - [Eigenschaften](#) eines Typen (rdfs:property)
 - [Erlaubte Typen](#) in Subjekt und Objekt von Prädikaten (rdfs:domain, rdfs:range)
 - ...
- Damit: Inferenz in Typhierarchien

Filmtologie in RDFS



```
<rdfs:Class rdf:ID="person">
</rdfs:Class>
<rdfs:Class rdf:ID="regisseur">
  <rdfs:subClassOf rdf:resource="#person"/>
</rdfs:Class>
...
<rdfs:Property rdf:ID="fuehrtRegieIn">
  <rdfs:domain rdf:resource="#regisser"/>
  <rdfs:range rdf:resource="#film"/>
</rdfs:Property>
...
```

Einschätzung RDFS

- RDFS ist relativ nahe an klassischen objektorientierten Modellen
 - Und eher weiter weg von Description Logics
- Man kann z.B. nicht
 - Klassen auf Basis anderer Klassen definieren
 - Union, Schnitt, Komplement, ...
 - Eigenschaften von Eigenschaften definieren
 - Transitivität, Symmetrie, ...
- Dafür gibt es eine **keine Trennung zwischen Modell und Metamodell**
 - Eingebaute Sprachelemente können **redefiniert** bzw. erweitert werden
 - Z.B.: Range oder domain von `rdfs:subClassOf` einschränken

RDFS versus XML

- Konformität mit einem Schema
 - RDFS definiert Klassen und deren Beziehungen
 - Die können in RDF benutzt werden
 - Man kann aber auch beliebige andere (undefinierte) benutzen
- Subklassenbeziehung versus Schachtelung
 - Schachtelung ist ein syntaktisches Konstrukt
 - Bezeichnet eine 1:n Beziehung, über die man nichts weiter weiß
 - Subklassen erben Eigenschaften der Superklasse und sind extensional eingeschlossen

Inhalt dieser Vorlesung

- Grundidee des Semantic Web
- Layer Cake
- RDF und RDFS
- [SparQL](#)
- Die OWL Sprachfamilie

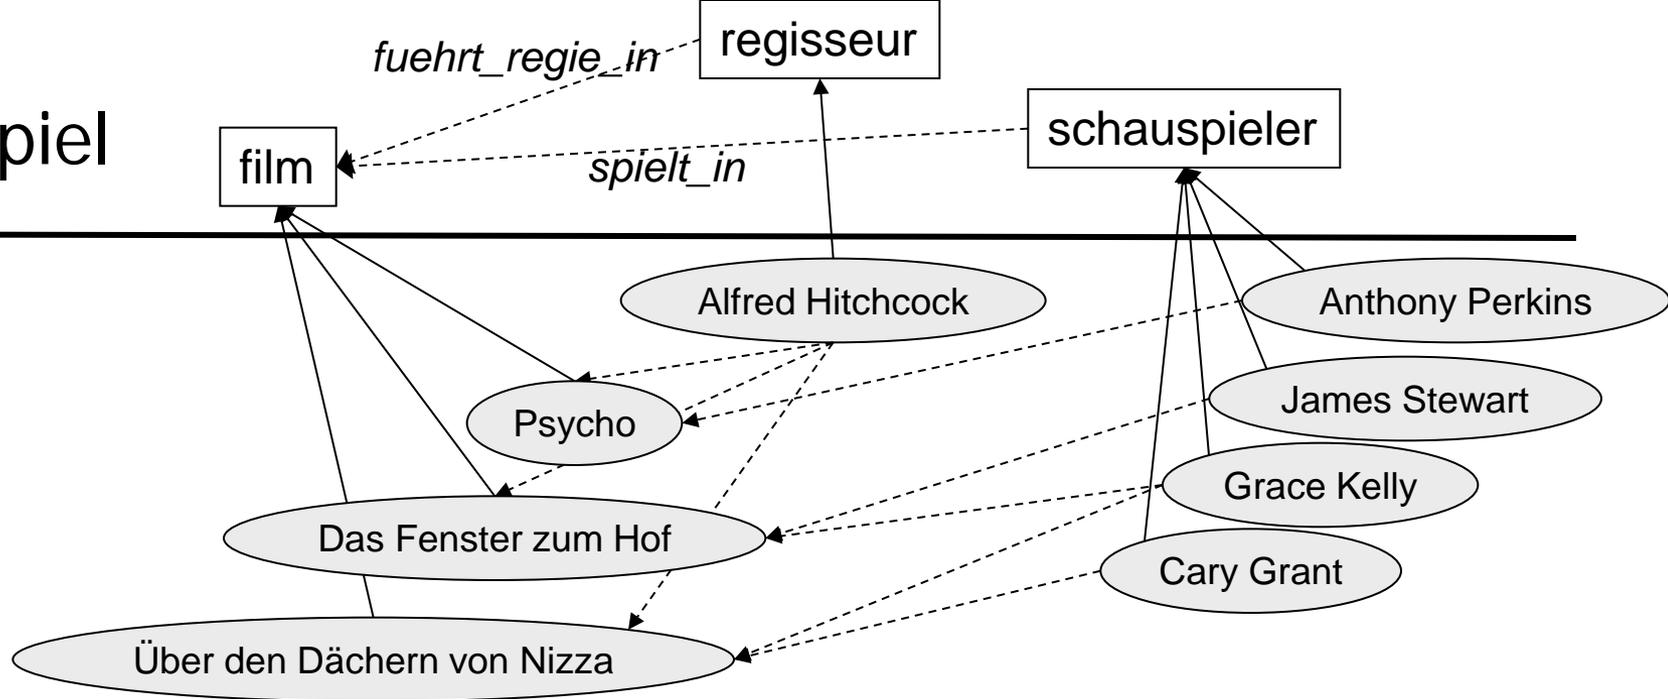
Anfragesprachen für RDF

- Historisch sind eine ganze Reihe von Sprachen entstanden
 - RQL, RDQL, SesamQL, ...
- W3C standard: SPARQL
 - *SPARQL Protocol and RDF Query Language*
 - Wir behandeln nur den „QL“ Teil
 - Eine SPARQL Anfrage Q ist im Kern ein **Graphmuster** aus Knoten und Kanten, beschriftet mit Konstanten oder Variablen
 - Q auf RDF-Datenbasis D: Alle zu Q **isomorphen Subgraphen**
- Grundkonzept: **Anfragetripel** (X Y Z)
 - X,Y,Z können Literale/URI's oder Variable sein
 - Anfragetripel Q **matched ein RDF-Datentripel R**, wenn es eine Funktion s gibt, die Konstante auf Konstante und Variable auf Konstante abbildet und für die gilt: $s(Q)=R$

SPARQL Grundaufbau

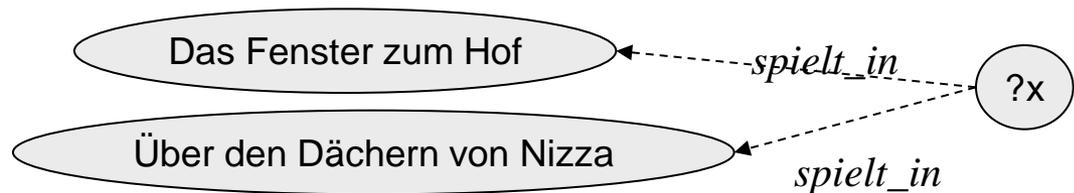
- Eine einfache SPARQL Anfrage ist eine **Menge von Anfragetripeln**
- Semantik
 - Anfragetripel werden an alle matchenden Datentripel gebunden
 - Bilde kartesisches Produkt aller Bindungen
 - Streiche alle Elemente, in denen eine Variable an verschiedene Werte gebunden wird
 - Gleiche Variable in verschiedenen Tripeln erzeugen also **Joins**
 - Alle übrigen Elemente bilden das Result Set der Anfrage

Beispiel



- `SELECT ?X`
`WHERE (`
 `?X spielt_in „Über den Dächern von Nizza“`
 `?X spielt_in „Das Fenster zum Hof“)`

- Als Graph



- Berechnet: „Grace Kelly“

Erweiterungen

- WHERE Klausel
 - **Optionals**: Optionale Tripel
 - Wichtig wegen der fehlenden Strukturierung von RDF Daten
 - Vergleichbar Outer-Join (bzw. der Union von zwei Anfragen)
 - **Filter** für Wertebedingungen (=, <, >, REGEXP, ...)
 - **Union**: Logisches ODER
- SELECT Klausel
 - Ausgabe von Variablenbindungen oder Tripelmengen
 - Sortierung der Ergebnisse
- FROM Klausel
 - Implizite Annahme einer Default RDF Datenbasis
 - **Named Graphs** – Queries über Tripel verschiedener Datenbasen

SparQL/RDF und Informationsintegration

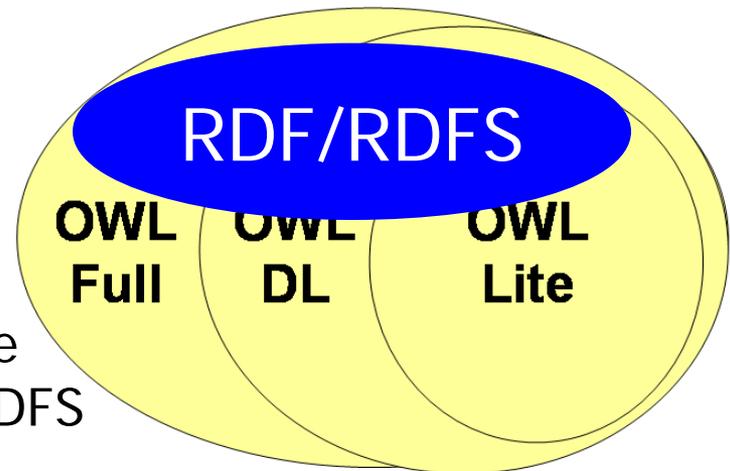
- Sehr flexibles **Datenmodell**
 - Subsumiert Tabellen (relational) und Bäume (XML)
 - Basiert auf RDF, nicht auf RDFS (oder OWL)
- **Named Graphs**
 - Verknüpfung mehrerer Datenquellen in einer Anfrage (Multi-DB-sprache)
 - Keine Vorkehrungen zur prädikatbasierten Identifikation von Quellen
- **Schematische Heterogenität** gibt es nicht (Graph)
- **Optional und Union**: Für strukturell heterogene Daten
- Keine **Gruppierung** oder Aggregation
 - Schlecht für Duplikaterkennung und Fusion
- Tools vorhanden

Inhalt dieser Vorlesung

- Grundidee des Semantic Web
- Layer Cake
- RDF und RDFS
- SparQL
- Die OWL Sprachfamilie

Ontology Web Language: OWL

- Historisch: DAML + OIL → DAML+OIL → OWL
- Formal basierend auf der DL SHIQ
 - DL mit transitiven und inversen Rolleneigenschaften sowie numerischen Kardinalitätseinschränkungen
- „Eigentlich“ fußt OWL auf RDF und RDFS
 - Erweiterung um Inferenz auch außerhalb der subClass-Beziehung
 - Aber nicht durchgehalten
- **Drei Stufen**
 - OWL Lite – Einfache Sprache für Taxonomien plus Constraints
 - OWL DL – Subsumption entscheidbar
 - OWL Full – Unentscheidbar, als einzige Sprache **abwärtskompatibel** zu RDF/RDFS



OWL Lite

- Trennung von Klassen, Werten und Instanzen
 - Die macht **RDFS nicht**
- Großteil der RDFS-Elemente
 - class, subclassOf, property, range, domain, ...
- Verhältnisse von Konzepten (class) und Rollen (property)
 - **Zwischen Klassen: intersectionOf**
 - Zwischen Klassen oder zwischen Beziehungen: equivalent
 - Zwischen Objekten: sameAs, differentFrom
- **Eigenschaften von Rollen**
 - inverseOf, transitive, symmetric, functional
- Rolleneinschränkungen
 - allValuesOf, someValuesOf, max/minCardinality (0 oder 1)
- **Es fehlen** z.B. \sqcup , \neg

OWL Full

- Abwärtskompatibel zu RDF
- Vermischung von Klassen, Instanzen, Rollen und Werten
 - Klassen können Instanzen anderer Klassen sein
 - Das wird von RDFS „geerbt“
- Weitere Sprachelemente
 - disjointWith: Schnitt zweier Klassen muss leer sein
 - unionOf, complementOf, intersectionOf für Klassen
 - ...
- Subsumption ist **unentscheidbar**
 - Man kann **Antinomien** formulieren: „Die Klasse K aller Dinge, die nicht zu K gehören“ (aus [HPvH03])

- Gegenüber OWL Full
 - Trennung von Klassen, Instanzen, Rollen und Werten
 - Diverse Einschränkungen
- Gegenüber OWL Lite
 - Neue Sprachelemente (Klassendefinitionen, Kardinalitäten, ...)
- Entscheidbare Sprache
 - „So ausdrucksstark wie gerade noch möglich“

Zusammenfassung Semantic Web

- Einige Technologien sind da, das Ziel bleibt Vision
- Stärke: **Relativ geschlossener Framework** zur Beschreibung komplexer Daten und Hintergrundwissen über diese Daten
- Hindernisse
 - Welche Benutzer können Sprachen wie **OWL lernen** und einsetzen?
 - Wer soll all die Ontologien schreiben?
 - **Ontologieheterogenität** als neue Art Heterogenität?
 - **Welchen Vorteil** bietet es für einen Webseitenbetreiber, Daten als RDF zu publizieren?
 - Wie integriert man 100 Millionen verteilte RDF Datenquellen?