

# Informationsintegration

Semantic Web

Ulf Leser

# Inhalt dieser Vorlesung

---


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

# Tim Berners-Lee et al.

---

- „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 1.0/2.0

---

- Web Seiten werden in HTML verfasst
- Struktur nur zur Unterstützung des Layouts
  - Gut für Lesbarkeit
  - Nicht automatisch interpretierbar (aber: NLP)
- 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

---

- Anfragen statt Suche, Antworten statt Webseiten
  - Question Answering versus Information Retrieval
  - Liste alle Telefonnummern aller Mitarbeit\*innen der HU Informatik
  - Wann wurde Rembrandt geboren?
- Web Commerce
  - Shopping-Agenten suchen bestes und billigstes Angebot
    - Die billigste Waschmaschine mit Energieklasse A+ in Düsseldorf
  - Online Shops präsentieren Waren zielgerichtet
    - Wer einen Grill kauft, braucht Kohlen
  - Broker vermitteln zwischen Anbieter\*innen und Käufer\*innen
    - Angebote für 10.000 Dübel, 6mm, Hohlkammer
- ...

# Grundprinzipien „Semantic Web“

---


- Semantik wird durch **Annotation** und **Ontologien** spezifiziert
- **Uniform Resource Identifier (URI)**
  - Sage nicht „Farbe“, sage "http://www.pantomime.com/std6#farbe"
  - Definitionen können im Laufe der Zeit ergänzt werden
  - Aber: 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
  - Hochgradig dezentrales und flexibles 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 **globaler 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, ...
  - XSchema: Definition von **Schemata**
    - Erlaubt Konsistenzprüfung von XML Dokumenten
  - Austauschschemma, nicht 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
    - 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

---

- 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
- Meines Wissens nicht umgesetzt



# 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)
  - Wert / 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
  - Entweder manuell oder durch **Blank Nodes** (später)
  - Formal ist das das Skolemisierung (siehe Frozen Facts)
- „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
  - Subjekte und Objekte werden Knoten
  - Prädikate sind Kanten
- Eigenschaften des Graphen
  - (Alle) Knoten haben eindeutige Label (URI oder Wert)
  - Kanten sind gerichtet und haben keine eindeutigen Label
  - Knoten können durch mehr als eine 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_fuer Paramount)
```




film			
ID	regisseur	titel	jahr
MF	Hitchcock	Marnie	1964
arbeitet_fuer			
Hitchcock	Paramount		
hat_produziert			
Paramount	MF		

# 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 gelderwerbstätigkeit)
```




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 gelderwerbstätigkeit)
```



Wo sind unsere Aussagen?  
Was schreiben wir an die neuen Kanten?

# Problem

---




Wer hat was gedreht?

# Offizielle Version

---

- 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.**“



# Aussagen über Aussagen


---

- In RDF kann man Aussagen über Aussagen treffen
  - 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 reifizieren
  - Reification = „Verdinglichung“
  - Eine Aussage wird als Ressource behandelt
- Vorgehen für Aussage (S P O)
  - Man schafft einen neuen Ressource R vom Typ `RDF:Statement`
  - Drei Aussagen: (R subject S) (R predicate P) (R object O)
  - R kann als Ressource verwendet werden: (Joe denkt R)


# Grafisch

---

- „Hitchcock ist der Regisseur von Marnie“




- „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**“
  - Statt URIs und Literalen können auch „Blank Nodes“ als Subjekt und Objekt verwendet werden
    - Bringt formal viele Schwierigkeiten
  - Gutartige Verwendung – **n-arige Prädikate**
  - Beispiel: Adresse mit 5 Elementen



# 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)
- Entworfen für **heterogene, schwach strukturierte und wissensintensive Anwendungen**


# RDFS – Schemata für RDF

---

- Eine RDF Datenbasis ist vollkommen frei in den verwendeten Begriffen
  - Kein Schema – das erschwert die Analyse / Konsistenzprüfung
- 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 Typ hierarchien

# Filmontologie 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="#regisseur"/>
  <rdfs:range rdf:resource="#film"/>
</rdfs:Property>
...
```

# Einschätzung RDFS

---

- RDFS relativ nahe an 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, ...
- Formal ohne Trennung zwischen Modell und Metamodell
  - Eingebaute Sprachelemente können redefiniert werden
    - Z.B.: Range oder domain von rdfs:subClassOf einschränken
- Vorsitz: RDFS Validierung ist idR nicht strikt
  - RDFS definiert Klassen und deren Beziehungen
  - Die können in RDF benutzt werden

# 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 übriggebliebenen Elemente bilden das ResultSet

# Beispiel



- **SELECT ?X**  
**WHERE (**  
 $?X \text{ spielt\_in } \text{"Über den Dächern von Nizza"}$   
 $?X \text{ spielt\_in } \text{"Das Fenster zum Hof"}$ **)**

- **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)
    - Keine Klassifikation / Beachtung von ISA Beziehungen
- Named Graphs
  - Verknüpfung mehrerer Datenquellen (Multi-DB-sprache)
- Schematische Heterogenität seltener
  - Knoten / Kanten
  - Ressource / Wert
- Optional und Union: Für strukturell heterogene Daten
  - Durch nur binäre Prädikate ist strukturelle Heterogenität selten
- Keine Gruppierung oder Aggregation
  - Schlecht für Duplikaterkennung und Fusion

# 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 Instanzen: 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 unentscheidbar
  - Man kann Antinomien formulieren: „Die Klasse K aller Dinge, die nicht zu K gehören“ (aus [HPvH03])

# OWL DL

---

- Gegenüber OWL Full
  - Trennung von Klassen, Instanzen, Rollen und Werten
  - Diverse Einschränkungen
- Gegenüber OWL Lite
  - Neue Sprachelemente (abgeleitete Konzepte, Kardinalitätseinschränkungen, ...)
- Entscheidbare Subsumption
  - Ziel: „So ausdrucksstark wie gerade noch möglich“
  - **Exponentielle Komplexität** Problem bei grossen Ontologien

# Zusammenfassung Semantic Web

---

- Einige Technologien sind da, das Ziel bleibt Vision
- Stärke: **Flexibler Framework** zur Beschreibung komplexer Daten und Hintergrundwissen über diese Daten
  - Mit internen Brüchen, insb. RDF/SparQL – RDFS - OWL
- 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?