

# Tutorial: Einführung in Daten-Web- Technologien

Dr. Jens Lehmann, Dr. Sören Auer

AKSW, Universität Leipzig



# Agenda

## **Teil 1: Einführung in Daten-Web-Technologien (ab 13 Uhr)**

13.00 - 13.45 Uhr Semantic Web Vision, Grundlagen RDF, RDF-Schema

13:45 - 14:45 OWL + Demo Protégé, SPARQL + Triple Stores

14:45 - 15.30 Daten-Web-Beispiele: DBpedia und LinkedGeoData

(15 Minuten Kaffeepause)

## **Teil 2: GoodRelations (ab 15:45 Uhr bis 18 Uhr)**

# Agenda

## **Teil 1: Einführung in Daten-Web-Technologien (ab 13 Uhr)**

13.00 - 13.45 Uhr **Semantic Web Vision**, Grundlagen RDF, RDF-Schema

13:45 - 14:45 OWL + Demo Protégé, SPARQL + Triple Stores

14:45 - 15.30 Daten-Web-Beispiele: DBpedia und LinkedGeoData

(15 Minuten Kaffeepause)

## **Teil 2: GoodRelations (ab 15:45 Uhr bis 18 Uhr)**



# Warum Semantic Web?

**Problem:** Try to search for these things on the current Web:


- Apartments near German-Russian bilingual childcare in Leipzig.
- ERP service providers with offices in Vienna and London.
- Researchers working on multimedia topics in Eastern Europe.

Information is available on the Web, but opaque to current Web search.

**Solution:** complement text on Web pages with structured linked open data & intelligently combine/integrate such structured information from different sources:



# Vom Web der Dokumente zum *Semantic Data Web*



# Data Web (since 2006)

- URI de-referencability
- Web Data integration
- RDF serializations



# Semantic Web

(Vision 1998, starting ???)

- Reasoning
- Logic, Rules
- Trust

## Social Web (since 2003)

- Folksonomies/Tagging
- Reputation, sharing
- Groups, relationships



## Web (since 1992)


- HTTP
- HTML/CSS/JavaScript

# Web 1.0


# Web 2.0

# Web 3.0


**Many Web sites  
containing unstructured,  
textual content**



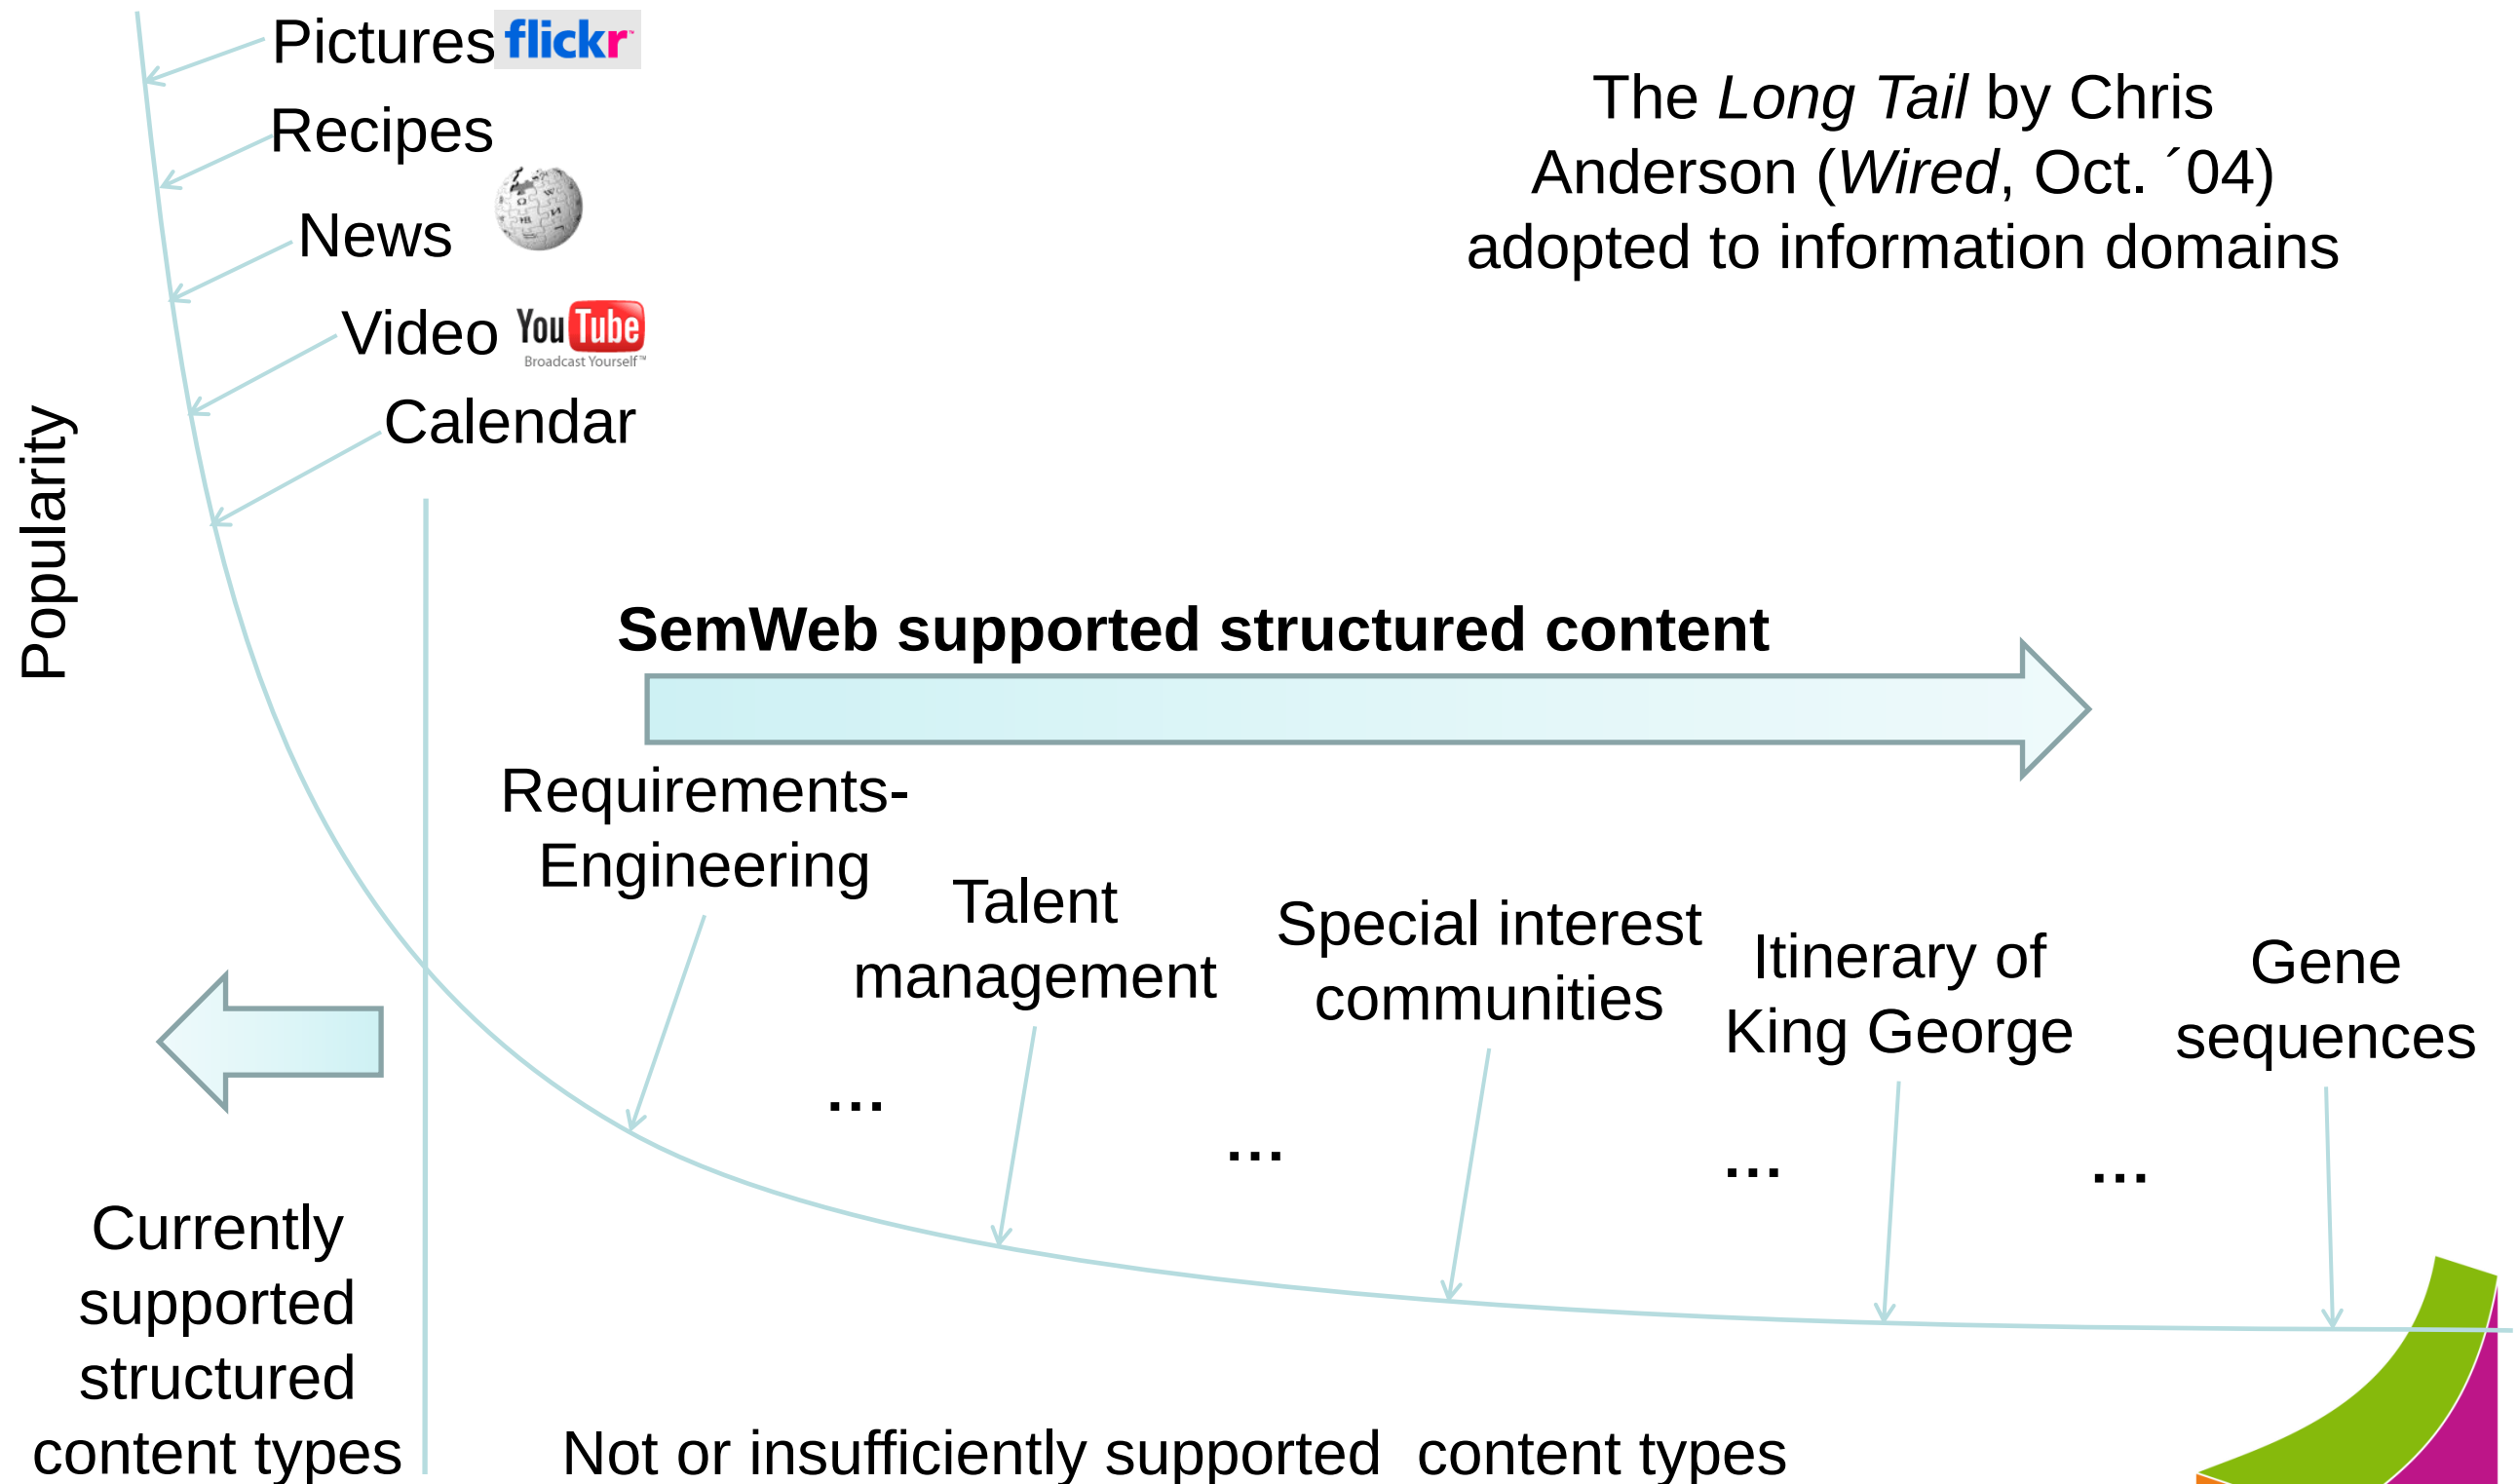
**Few large Web sites  
are specialized on  
specific content  
types**



**Many Web sites  
containing &  
semantically syndicating  
arbitrarily structured  
content**




# The Long Tail of Information Domains





# Die Vision: ein Web Vernetzter Daten





# Conceptual Level

## Data Access and Integration

### Data Integration

#### Enterprise Information Integration

sets of heterogeneous data sources appear as a single, homogeneous data source

#### Data Warehousing

- Based on extract, transform load (ETL)
- Global-As-View (GAV)

#### Research

Mediators  
Ontology-based  
P2P  
Web service-based

#### Data Web

- URIs as entity identifiers
- HTTP as data access protocol
- Local-As-View (LAV)

### Data Access

#### Object-relational mappings (ORM)Procedural APIs

- NeXT's EOF / WebObjects
- ADO.NET Entity Framework
- Hibernate
- ODBC
- JDBC

#### Linked Data

- de-referencable URIs
- RDF serialization formats

#### Query Languages

- Datalog, SQL
- **SPARQL**
- XPATH/XQuery

### Data Models

#### RDBMS

- Organize data in relations, rows, cells
- Oracle, DB2, MS-SQL

#### Column-oriented DBMS

- Collocates column values rather than row values
- Vertica, C-Store, MonetDB

#### Triple/Quad Stores

- RDF data model
- Virtuoso, Oracle, Sesame


#### Entity-attribute-value (EAV)

- HELP medical record system, TrialDB

#### Others

- XML, hierarchical, tree, graph-oriented DBMS

# Semantic Web - Standards



| Standardization Semantic Web |                                                                                                                                                                                                                                                                                  |
|------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>1994</b>                  | <ul style="list-style-type: none"> <li>First public presentation of the Semantic Web idea</li> </ul>                                                                                                                                                                             |
| <b>1998</b>                  | <ul style="list-style-type: none"> <li>Start of standardization of data model (RDF) and a first ontology languages (RDFS) at W3C</li> </ul>                                                                                                                                      |
| <b>2000</b>                  | <ul style="list-style-type: none"> <li>Start of large research projects about ontologies in the US and Europe (DAML &amp; Ontoknowledge)</li> </ul>                                                                                                                              |
| <b>2002</b>                  | <ul style="list-style-type: none"> <li>Start of standardization of a new ontology language (OWL) based on research results</li> </ul>                                                                                                                                            |
| <b>2004</b>                  | <ul style="list-style-type: none"> <li>Finalization of the standard for data (RDF) and ontology (OWL)</li> </ul>                                                                                                                                                                 |
| <b>2006</b>                  | <ul style="list-style-type: none"> <li>Standardization of a query language (SPARQL, 6. April 2006)</li> <li>Ongoing work on rule languages (SWRL, DL-safe rules, RIF)</li> <li>Extension of OWL to OWL 1.1 / 2.0</li> <li>Ontology language of OMG based on UML (ODM)</li> </ul> |
| <b>2008</b>                  | <ul style="list-style-type: none"> <li>•RDFa</li> </ul>                                                                                                                                                                                                                          |
| <b>2009</b>                  | <ul style="list-style-type: none"> <li>•OWL2</li> </ul>                                                                                                                                                                                                                          |

# Agenda

## **Teil 1: Einführung in Daten-Web-Technologien (ab 13 Uhr)**

13.00 - 13.45 Uhr Semantic Web Vision, **Grundlagen RDF, RDF-Schema**

13:45 - 14:45 OWL + Demo Protégé, SPARQL + Triple Stores

14:45 - 15.30 Daten-Web-Beispiele: DBpedia und LinkedGeoData

(15 Minuten Kaffeepause)

## **Teil 2: GoodRelations (ab 15:45 Uhr bis 18 Uhr)**

# URIs - Idee

- **URI** = Uniform Resource Identifier
- dienen zur weltweit eindeutigen Bezeichnung von Ressourcen
- Ressource kann jedes Objekt sein, was (im Kontext der gegebenen Anwendung) eine klare Identität besitzt (z.B. Bücher, Orte, Menschen, Verlage, Beziehungen zwischen diesen Dingen, abstrakte Konzepte usw.)
- in bestimmten Domänen ähnliches bereits realisiert: ISBN für Bücher

<http://aksw.org/Events/2011/LeipzigerSemanticWebDay>

# URIs - Syntax

- Erweiterung des URL-Konzeptes; nicht jede URI bezeichnet aber ein Webdokument (umgekehrt wird als URI für Webdokumente häufig deren URL verwendet)
- Beginnt mit dem sogenannten URI-Schema das durch ":" vom nachfolgenden Teil getrennt ist (z.B.: http, ftp, mailto)
- häufig hierarchisch aufgebaut

`http://aksw.org/Events/2011/LeipzigerSemanticWebDay`



# Selbstdefinierte URIs

- nötig, wenn für eine Ressource (noch) keine URI existiert (bzw. bekannt ist)
- Strategie zur Vermeidung von (ungewollten) Überschneidungen: Nutzung von http-URIs einer eigenen Domäne/Webseite
- ermöglicht auch Ablegen einer Dokumentation zur URI an dieser Stelle



# Beschreibendes vs. Beschriebenes

- Trennung von URI für Ressource und deren Dokumentation durch URI-Referenzen (durch "#" angehängte Fragmente) oder content negotiation
- z.B.: als URI für Shakespeares "Othello"  
<http://de.wikipedia.org/wiki/Othello>  
nicht geeignet, besser  
<http://de.wikipedia.org/wiki/Othello#URI>



# Bestandteile von RDF-Graphen

## URIs

- zur eindeutigen Referenzierung von Ressourcen
- bereits im Rahmen von XML behandelt

## Literale

- beschreiben Datenwerte denen keine separate Existenz zukommt


## leere Knoten (blank nodes)

- erlauben Existenzaussagen über ein Individuum mit gewissen Eigenschaften ohne es zu benennen




# RDF-Tripel

- Bestandteile eines RDF-Tripels




- angelehnt an linguistische Kategorien, aber nicht immer stimmig
- erlaubte Belegungen:  
Subjekt : URI oder leerer Knoten  
Prädikat: URI (auch Propertys genannt)  
Objekt : URI oder leerer Knoten oder Literal
- Knoten- und Kantenbezeichner eindeutig, daher ursprünglicher Graph aus Tripel-Liste rekonstruierbar

# Literale



- zur Repräsentation von Datenwerten
- Darstellung als Zeichenketten
- Interpretation erfolgt durch *Datentyp*
- Literale ohne Datentyp
  - werden wie Zeichenketten behandelt
  - können optional mit Sprachtag versehen werden


# Graph als Menge von Tripeln



- verschiedene Darstellungsmöglichkeiten für Graphen
- hier verwendet: Liste von (Knoten-Kante-Knoten)-Tripeln



# Turtle: Einfache Syntax für RDF



## Direkte Auflistung der Tripel:

```
<http://aksw.org>          <http://aksw.org/event/organizes>    <http://aksw.org/LSWT> .  
<http://aksw.org/LSWT>    <http://aksw.org/event/takesPlaceAt>  "20110505"^^xsd:date .  
<http://aksw.org/LSWT>    <http://aksw.org/event/takesPlaceIn>  <http://dbpedia.org/Leipzig> .
```

## Syntax in Turtle:

- URIs in spitzen Klammern
- Literale in Anführungszeichen
- Tripel durch Punkt abgeschlossen
- Leerzeichen und Zeilenumbrüche außerhalb von Bezeichnern werden ignoriert

```
@prefix ev:  <http://aksw.org/event/>  
@prefix dbp: <http://dbpedia.org/resource/>  
<http://aksw.org>          ev:organizes  
<http://aksw.org/LSWT>    ev:takesPlaceAt  
<http://aksw.org/LSWT>    ev:takesPlaceIn
```

```
<http://aksw.org/LSWT> .  
"20110505"^^xsd:date .  
dbp:Leipzig .
```

# Klassen und Instanzen

**ex:LSWT2011 rdf:type ex:Veranstaltung .**

- charakterisiert „LSWT2010“ als Instanz der (neu definierten) Klasse „Veranstaltung“

- Klassenzugehörigkeit ist nicht exklusiv, z.B. mit o.g. Tripel gleichzeitig möglich:

**ex:LSWT2011 rdf:type ex:Unterhaltsam .**


- allgemein: a priori syntaktisch keine eindeutige Unterscheidung zwischen Individuen- und Klassenbezeichnern möglich

- auch in der Realität Charakterisierung manchmal schwierig, beispielsweise für


<http://www.un.org/#URI>

# RDF Vokabulare: Klassen & Eigenschaften Hierarchien

|                     |                 |                     |
|---------------------|-----------------|---------------------|
| Beer                | rdf:type        | rdfs:Class          |
| BottomFermentedBeer | rdfs:subClassOf | Beer                |
| Bock                | rdfs:subClassOf | BottomFermentedBeer |
| Lager               | rdfs:subClassOf | BottomFermentedBeer |
| Pilsner             | rdfs:subClassOf | BottomFermentedBeer |




|                        |                    |               |
|------------------------|--------------------|---------------|
| hasContent             | rdf:type           | rdfs:Property |
| hasAlcoholicContent    | rdfs:subPropertyOf | hasContent    |
| hasOriginalWortContent | rdfs:subPropertyOf | hasContent    |



# RDF-S Instanzen

- Instanzen sind einer oder mehreren Klassen zugeordnet:



# Property

- andere Bezeichnungen: Relationen, Beziehungen
- Achtung: Property sind in RDF(S) nicht (wie in OOP) speziellen Klassen zugeordnet
- Property-Bezeichner in Tripeln üblicherweise an Prädikatsstelle
- charakterisieren, auf welche Art zwei Ressourcen zueinander in Beziehung stehen
- mathematisch oft dargestellt als Menge von Paaren:  
verheiratet\_mit = {(Adam,Eva),(Brad,Angelina),...}
- URI wird als Property-Bezeichner gekennzeichnet durch entsprechende Typung:  
**ex:hasContent      rdf:type      rdf:Property      .**

# Interproperty

- ähnlich zu Unter-/Oberklassen auch Unter-/Oberproperty denkbar und sinnvoll
- Darstellung in RDFS mittels `rdfs:subPropertyOf` z.B.:

```
ex:glücklichVerheiratetMit rdfs:subPropertyOf rdf:verheiratetMit .
```

- erlaubt, aus dem Tripel

```
ex:Markus    ex:glücklichVerheiratetMit    ex:Anja    .
```

zu schlussfolgern, dass

```
ex:Markus    ex:verheiratetMit    ex:Anja    .
```

# Domain und Range

- Properties werden unabhängig von Klassen definiert

|                     |                    |                    |
|---------------------|--------------------|--------------------|
| hasAlcoholicContent | rdfs:domain        | Beer               |
| hasAlcoholicContent | rdfs:range         | xsd:float          |
| hasAlcoholicContent | rdfs:subPropertyOf | hasContent         |
| brews               | rdf:type           | owl:ObjectProperty |
| brews               | rdfs:domain        | Brewery            |
| brews               | rdfs:range         | Beer               |


- **Domain:** Verknüpfung mit einer oder mehreren Klassen
- **Range:** definiert Werte, welche die Property annehmen kann
  - Instanzen einer bestimmten Klasse
  - Literale, z.B. typisiert nach XML-Schema-Datentypen





# Vokabulare: Friend-of-a-Friend (FOAF)

- defines classes and properties for representing information about people and their relationships

|        |                   |                                                                   |
|--------|-------------------|-------------------------------------------------------------------|
| Soeren | rdf:type          | foaf:Person                                                       |
| Soeren | currentProject    | <a href="http://OntoWiki.net">http://OntoWiki.net</a>             |
| Soeren | foaf:homepage     | <a href="http://aksw.org/Soeren">http://aksw.org/Soeren</a>       |
| Soeren | foaf:knows        | <a href="http://sembase.at/Tassilo">http://sembase.at/Tassilo</a> |
| Soeren | foaf:mbox_sha1sum | 09ac456515dee                                                     |




# Vokabulare: Semantically Interlinked Online Communities.




# Vokabulare: Simple Knowledge Organization System (SKOS)

- support the use of thesauri, classification schemes, subject heading systems and taxonomies




# Linked Data Web

## 1. Nutzt (in der Regel) RDF als Datenmodell



## 2. Nutzt dereferenzierbare HTTP-URIs, z.B. Content-negotiation



## 3. Links auf Ressourcen (in anderen Wissensbasen)

# Agenda

## **Teil 1: Einführung in Daten-Web-Technologien (ab 13 Uhr)**

13.00 - 13.45 Uhr Semantic Web Vision, Grundlagen RDF, RDF-Schema

13:45 - 14:45 **OWL + Demo Protégé**, SPARQL + Triple Stores

14:45 - 15.30 Daten-Web-Beispiele: DBpedia und LinkedGeoData

(15 Minuten Kaffeepause)

## **Teil 2: GoodRelations (ab 15:45 Uhr bis 18 Uhr)**

# Ontologie –philosophisch

- Begriff existiert nur in der Einzahl (es gibt also keine „Ontologien“)
- bezeichnet die „*Lehre vom Sein*“
- zu finden bei Aristoteles (Sokrates), Thomas von Aquin, Descartes, Kant, Hegel, Wittgenstein, Heidegger, Quine, ...

# Ontologie – informatisch

Gruber (1993):

„An Ontology is a

formal specification

of a shared

conceptualization

of a domain of interest“

- maschinell interpretierbar
- beruht auf Konsens
- beschreibt Begrifflichkeiten
- bezogen auf ein „Thema“ (Gegenstandsbereich)



# Ontologie – praktisch

- Instanziierung von Klassen durch Individuen
- Begriffshierarchien (Taxonomien, „Vererbung“): Klassen, Begriffe
- binäre Relationen zwischen Individuen: Properties, Roles
- Eigenschaften von Relationen (z.B. range, transitive)
- Datentypen (z.B. Zahlen): concrete domains
- logische Ausdrucksmittel
- klare Semantik!

# Object Properties

Zugehoerigkeit `rdf:type owl:ObjectProperty`

## Domain und Range abstrakter Rollen

Zugehoerigkeit `rdfs:domain` Person

Zugehoerigkeit `rdfs:range` Organisation

# Datatype Properties

Datatype Properties haben Datentypen im Range

**Vorname    `rdf:type`    `owl:DatatypeProperty`**

Domain und Range konkreter Rollen

**Vorname    `rdfs:domain`    `Person`**

**Vorname    `rdfs:range`    `xsd:string`**

XML Datentypen (und selbst definierte) können verwendet werden



# Propertyeigenschaften

- Domain
- Range
- Transitivität, d.h.  
 $r(a,b)$  und  $r(b,c)$  impliziert  $r(a,c)$
- Symmetrie, d.h.  
 $r(a,b)$  impliziert  $r(b,a)$
- Funktionalität  
 $r(a,b)$  und  $r(a,c)$  impliziert  $b=c$
- Inverse Funktionalität  
 $r(a,b)$  und  $r(c,b)$  impliziert  $a=c$

# Einfache Klassenbeziehungen

**Disjunkt:**

**Mann**      `owl:disjointWith`      **Frau**

**Äquivalenz:**

**Auto**      `owl:equivalentClass`      **Automobil**



# Logische Klassenkonstruktoren

- logisches Und (Konjunktion):  
`owl:intersectionOf`
- logisches Oder (Disjunktion):  
`owl:unionOf`
- logisches Nicht (Negation):  
`owl:complementOf`
- Werden verwendet, um komplexe Klassen aus einfachen Klassen zu konstruieren.

# Beziehungen zwischen Individuen

Gleichheit von Individuen:

**SebastianDietzold owl:sameAs**

**SebastianTramp**

Verschiedenheit von Individuen:

**SoerenAuer**

**owl:differentFrom**

**SebastianTramp**



# Propertyeinschränkungen (allValuesFrom)

dienen der Definition komplexer Klassen durch Properties:

|                        |                          |                              |
|------------------------|--------------------------|------------------------------|
| <b>Wissenschaftler</b> | <b>rdf:type</b>          | <b>owl:Restriction</b>       |
| <b>Wissenschaftler</b> | <b>owl:onProperty</b>    | <b>authorOf</b>              |
| <b>Wissenschaftler</b> | <b>owl:allValuesFrom</b> | <b>WissenschaftlichePubl</b> |

# Rolleneinschränkungen (someValuesFrom)

|                         |                           |                        |
|-------------------------|---------------------------|------------------------|
| <b>BestSellerAuthor</b> | <b>rdf:type</b>           | <b>owl:Restriction</b> |
| <b>BestSellerAuthor</b> | <b>owl:onProperty</b>     | <b>authorOf</b>        |
| <b>BestSellerAuthor</b> | <b>owl:someValuesFrom</b> | <b>BestSeller</b>      |

# Rolleneinschränkungen (Kardinalitäten)

|         |                       |                              |
|---------|-----------------------|------------------------------|
| Ehemann | <code>rdf:type</code> | <code>owl:Restriction</code> |
|---------|-----------------------|------------------------------|

|         |                             |                             |
|---------|-----------------------------|-----------------------------|
| Ehemann | <code>owl:onProperty</code> | <code>verheiratetMit</code> |
|---------|-----------------------------|-----------------------------|

|         |                              |                           |
|---------|------------------------------|---------------------------|
| Ehemann | <code>owl:Cardinality</code> | <code>"1"^^xsd:int</code> |
|---------|------------------------------|---------------------------|

|             |                       |                              |
|-------------|-----------------------|------------------------------|
| Kinderreich | <code>rdf:type</code> | <code>owl:Restriction</code> |
|-------------|-----------------------|------------------------------|

|             |                             |                      |
|-------------|-----------------------------|----------------------|
| Kinderreich | <code>owl:onProperty</code> | <code>hatKind</code> |
|-------------|-----------------------------|----------------------|

|             |                                 |                           |
|-------------|---------------------------------|---------------------------|
| Kinderreich | <code>owl:MinCardinality</code> | <code>"3"^^xsd:int</code> |
|-------------|---------------------------------|---------------------------|

# Rolleneinschränkungen (hasValue)

|           |                             |                              |
|-----------|-----------------------------|------------------------------|
| Leipziger | <code>rdf:type</code>       | <code>owl:Restriction</code> |
| Leipziger | <code>owl:onProperty</code> | <code>hatWohnOrt</code>      |
| Leipziger | <code>owl:hasValue</code>   | <code>Leipzig</code>         |

# OWL Werkzeuge

## Editoren

- Protegé, <http://protege.stanford.edu>
- SWOOP, <http://www.mindswap.org/2004/SWOOP/>
- OWL Tools, <http://owltools.ontoware.org/>

## Inferenzmaschinen

- Pellet, <http://www.mindswap.org/2003/pellet/index.shtml>
- KAON2, <http://kaon2.semanticweb.org>
- FACT++, <http://owl.man.ac.uk/factplusplus/>
- Racer, <http://www.racer-systems.com/>
- Cerebra, <http://www.cerebra.com/index.html>

# Agenda

## **Teil 1: Einführung in Daten-Web-Technologien (ab 13 Uhr)**

13.00 - 13.45 Uhr Semantic Web Vision, Grundlagen RDF, RDF-Schema

13:45 - 14:45 OWL + Demo Protégé, **SPARQL + Triple Stores**

14:45 - 15.30 Daten-Web-Beispiele: DBpedia und LinkedGeoData

(15 Minuten Kaffeepause)

## **Teil 2: GoodRelations (ab 15:45 Uhr bis 18 Uhr)**

# Triple Stores

## Aufgaben

- Laden und Serialisieren von RDF
- Persistente Speicherung von RDF  
Wissensbasen – oft als Quad (G,S,P,O)
- Performantes Abfragen (via SPARQL)
- Teilweise Inferenz





# Arten von Triple Stores

## Native

- Speziell optimiert für das RDF-Datenmodell
- Vertreter: OWLIM, YARS

## Datenbankbasierte

- Relationales DB-Schema zum Speichern
- Vertreter: Sesame/SDB, OntoWiki/Erfurt

## Mischformen


- Relationale Datenbanken erweitert um spezielle Datentypen und Indizes
- Vertreter: Oracle, Virtuoso





# Vergleich DB vs. RDF/Ontologien

|                                | Relational Databases  | RDF & Ontologies  |
|--------------------------------|----------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------|
| Data Model                     | Relational<br>(tables, columns, rows)                                                                    | Triples<br>(subject, predicate, object)                                                              |
| Schema and data separation     | <input checked="" type="checkbox"/>                                                                      | <input type="checkbox"/>                                                                             |
| Implicit information           | <input type="checkbox"/>                                                                                 | <input checked="" type="checkbox"/>                                                                  |
| Scalability                    | <input checked="" type="checkbox"/>                                                                      | <input type="checkbox"/>                                                                             |
| Schema flexibility             | <input type="checkbox"/>                                                                                 | <input checked="" type="checkbox"/>                                                                  |
| Web data integration readiness | <input type="checkbox"/>                                                                                 | <input checked="" type="checkbox"/>                                                                  |



# Relationales Schema für RDF

## Viele Varianten möglich:


- Normalisiert
- Unnormalisiert
- Mischformen

## Hilfstabellen – materialisierte Views

- für bestimmte Properties, Listen, OWL-Konstrukte

## Verschiedene Indizierungen

- z.B. GSP, GPO, GOS etc.



# Typische Vertreter

## Open Source:

- **Virtuoso** - komplette Middleware (inkl. DB, Web-Server, Web Services ...)
- **Jena TDB** – Persistenzschicht für Jena API, pure-Java, memory mapped I/O, angepasste B+Tree-Implementierung, optimierte range filter für XSD

## Proprietär:

- **YARS2**: A Federated Repository for Querying Graph Structured Data from the Web distributed architecture, scalability experiments up to 7bn LUBM(50000)
- **BigOWLIM** – supports forward-chaining inference, 3bn LUBM(25000)
- **AllegroGraph**
- **Oracle 11G**

Mehr unter: <http://esw.w3.org/topic/LargeTripleStores>



# SPARQL

SPARQL (sprich engl. sparkle) steht für

- **SPARQL Protocol And RDF Query Language**

W3C-Spezifikation (seit 15. Januar 2008)

Anfragsprache zur Abfrage von Instanzen aus RDF-Dokumenten

große praktische Bedeutung

Teile der SPARQL-Spezifikation

- Anfragesprache: Thema dieser Vorlesung
- Ergebnisformat: Darstellung von Ergebnissen in XML
- Anfrageprotokoll: Übermittlung von Anfragen und Ergebnissen



# Einfache Beispielanfrage

```
PREFIX ex: <http://example.org/>
SELECT ?titel ?autor WHERE {
    ?buch ex:VerlegtBei <http://springer.com/Verlag> .
    ?buch ex:Titel      ?titel .
    ?buch ex:Autor      ?autor .
}
```

Hauptbestandteil ist ein Anfragemuster (WHERE)

- Anfragemuster verwenden die Turtle-Syntax für RDF
- Muster dürfen Variablen enthalten (?variable)

Kurzschreibweisen für URIs möglich (PREFIX)

Anfrageergebnis durch Auswahl von Variablen (SELECT)


# Graph-Muster

## RDF Graph:

```
...
JensLehmann    rdf:type      foaf:person
JensLehmann    foaf:knows    SoerenAuer
JensLehmann    foaf:birthDay "10.4.1981"
SebastianTramp rdf:type      foaf:person
SebastianTramp foaf:knows    SoerenAuer
...
```

## Graph pattern (SPARQL core):

```
?person rdf:type      foaf:person
?person foaf:knows    http://aksw.org/SoerenAuer
```



# OPTIONAL

Das Schlüsselwort OPTIONAL erlaubt die Angabe optionaler Teile eines Musters.

Beispiel:

```
{ ?buch ex:VerlegtBei
  <http://springer.com/Verlag> .
OPTIONAL { ?buch ex:Titel ?titel . }
OPTIONAL { ?buch ex:Autor ?autor . }
}
```

Teile eines Anfrageergebnisses können ungebunden sein:

| ?buch                                                           | ?titel                     | ?autor                                                            |
|-----------------------------------------------------------------|----------------------------|-------------------------------------------------------------------|
| <a href="http://example.org/buch1">http://example.org/buch1</a> | "Semantic Web for Dummies" | <a href="http://example.org/autor1">http://example.org/autor1</a> |
| <a href="http://example.org/buch2">http://example.org/buch2</a> | "Faust 1"                  |                                                                   |
| <a href="http://example.org/buch3">http://example.org/buch3</a> |                            | Schiller                                                          |



# UNION

Das Schlüsselwort UNION erlaubt die Angabe alternativer Teile eines Musters.

Beispiel:

```
{ ?buch ex:VerlegtBei <http://springer.com/Verlag> .  
  
{ ?buch ex:Autor      ?autor . } UNION  
  
{ ?buch ex:Verfasser  ?autor . }  
  
}
```

Ergebnis entspricht Vereinigung der Ergebnisse mit einer der beiden Bedingungen

Gleiche Variablennamen in beiden Teilen von UNION beeinflussen sich nicht



# Filter

Viele Anfragen sind auch mit komplexen Graph-Mustern nicht möglich:

- „Welche Personen sind zwischen 18 und 23 Jahre alt?“
- „Der Nachname welcher Personen enthält einen Bindestrich?“
- „Welche Texte in deutscher Sprache sind in der Ontologie angegeben?“

Filter als allgemeiner Mechanismus für solche Ausdrucksmittel



# Filter in SPARQL

Beispiel:

```
PREFIX ex: <http://example.org/>
```

```
SELECT ?buch WHERE
```

```
{ ?buch ex:VerlegtBei <http://springer.com/Verlag> .  
  ?buch ex:Preis ?preis
```

```
FILTER (?preis < 35)
```

```
}
```

Schlüsselwort FILTER, gefolgt von Filterausdruck in Klammern

Filterbedingungen liefern Wahrheitswerte (und ev. auch Fehler)

Viele Filterfunktionen nicht durch RDF spezifiziert / Funktionen teils aus XQuery/XPath-Standard für XML übernommen

# Filterfunktionen: Vergleiche und Arithmetik

Vergleichoperatoren:  $<$ ,  $=$ ,  $>$ ,  $<=$ ,  $>=$ ,  $!=$

- Vergleich von Datenliteralen gemäß der jeweils natürlichen Reihenfolge
- Unterstützung für numerische Datentypen, xsd:dateTime, xsd:string (alphabetische Ordnung), xsd:Boolean ( $1 > 0$ )
- für andere Typen und sonstige RDF-Elemente nur  $=$  und  $!=$  verfügbar
- kein Vergleich von Literalen inkompatibler Typen (z.B. xsd:string und xsd:integer)

Arithmetische Operatoren:  $+$ ,  $-$ ,  $*$ ,  $/$

- Unterstützung für numerische Datentypen
- Verwendung zur Kombination von Werten in Filterbedingungen

Bsp.: `FILTER( ?gewicht/(?groesse * ?groesse) >= 25 )`



# SPARQL Ausgabeformate

Bisher waren alle Ergebnisse Tabellen: Ausgabeformat SELECT

Kodierung von Ergebnissen in RDF-Graphen: Ausgabeformat  
CONSTRUCT

```
CONSTRUCT { ?person    ex:mailbox    ?email .  
             ?person    ex:telefon    ?telefon . }  
WHERE      { ?person    ex:email      ?email .  
             ?person    ex:tel        ?telefon . }
```

SPARQL unterstützt zwei weitere Ausgabeformate:

- ASK prüft nur, ob es Ergebnisse gibt, keine Parameter
- DESCRIBE (informativ) liefert zu jeder gefundenen URI eine RDF-Beschreibung (anwendungsabhängig)

# Ergebnisse sortieren

Sortierung von Ergebnissen mit Schlüsselwort ORDER BY

```
SELECT ?buch, ?preis
```

```
WHERE { ?buch <http://example.org/Preis> ?preis . }
```

```
ORDER BY ?preis
```

- Sortierung wie bei Filter-Vergleichoperatoren,
- Sortierung von URIs alphabetisch als Zeichenketten
- Reihenfolge zwischen unterschiedlichen Arten von Elementen:  
Ungebundene Variable < leere Knoten < URIs < RDF-Literale
- nicht jede Möglichkeit durch Spezifikation definitert

Weitere mögliche Angaben:

- ORDER BY DESC(?preis): absteigend
- ORDER BY ASC(?preis): aufsteigend, Voreinstellung
- ORDER BY DESC(?preis), ?titel: hierarchische Ordnungskriterien

# LIMIT, OFFSET und DISTINCT

Einschränkung der Ergebnismenge:

- LIMIT: maximale Anzahl von Ergebnissen (Tabellenzeilen)
- OFFSET: Position des ersten gelieferten Ergebnisses
- SELECT DISTINCT: Entfernung von doppelten Tabellenzeilen

```
SELECT DISTINCT ?buch, ?preis
```

```
WHERE { ?buch <http://example.org/Preis> ?preis . }
```


```
ORDER BY ?preis LIMIT 5 OFFSET 25
```

LIMIT und OFFSET nur mit ORDER BY sinnvoll!



# SPARQL Beschränkungen

- Keine Daten Manipulation, d.h. Insert, Update, Delete Anfragen  
SPARUL Erweiterung - <http://jena.hpl.hp.com/~afs/SPARQL-Update.html>
- Keine Daten- und Zugriffs-Kontrolle, d.h. GRANT, REVOKE etc.
- Keine Anfrageintrospektion (ala SQL DESCRIBE etc.)
- Keine Subqueries
- Keine Anfrageparametrisierung (Prepare)
- Keine Cursors
- Keine Volltextsuche (bif:contains Erweiterung)
- Keine Aggregatfunktionen





# Agenda

## **Teil 1: Einführung in Daten-Web-Technologien (ab 13 Uhr)**

13.00 - 13.45 Uhr Semantic Web Vision, Grundlagen RDF, RDF-Schema

13:45 - 14:45 OWL + Demo Protégé, SPARQL + Triple Stores

14:45 - 15.30 **Daten-Web-Beispiele: DBpedia und LinkedGeoData**

(15 Minuten Kaffeepause)

## **Teil 2: GoodRelations (ab 15:45 Uhr bis 18 Uhr)**