



Kundenprojekt Web Technologien

Ontology and Metadata Extraction Metadata Schemas and Upper Ontologies

Dr. Lyndon J B Nixon
Freie Universität Berlin
Institut für Informatik
Netzbasierte Informationssysteme
mailto: nixon@inf.fu-berlin.de
<http://page.mi.fu-berlin.de/nixon>

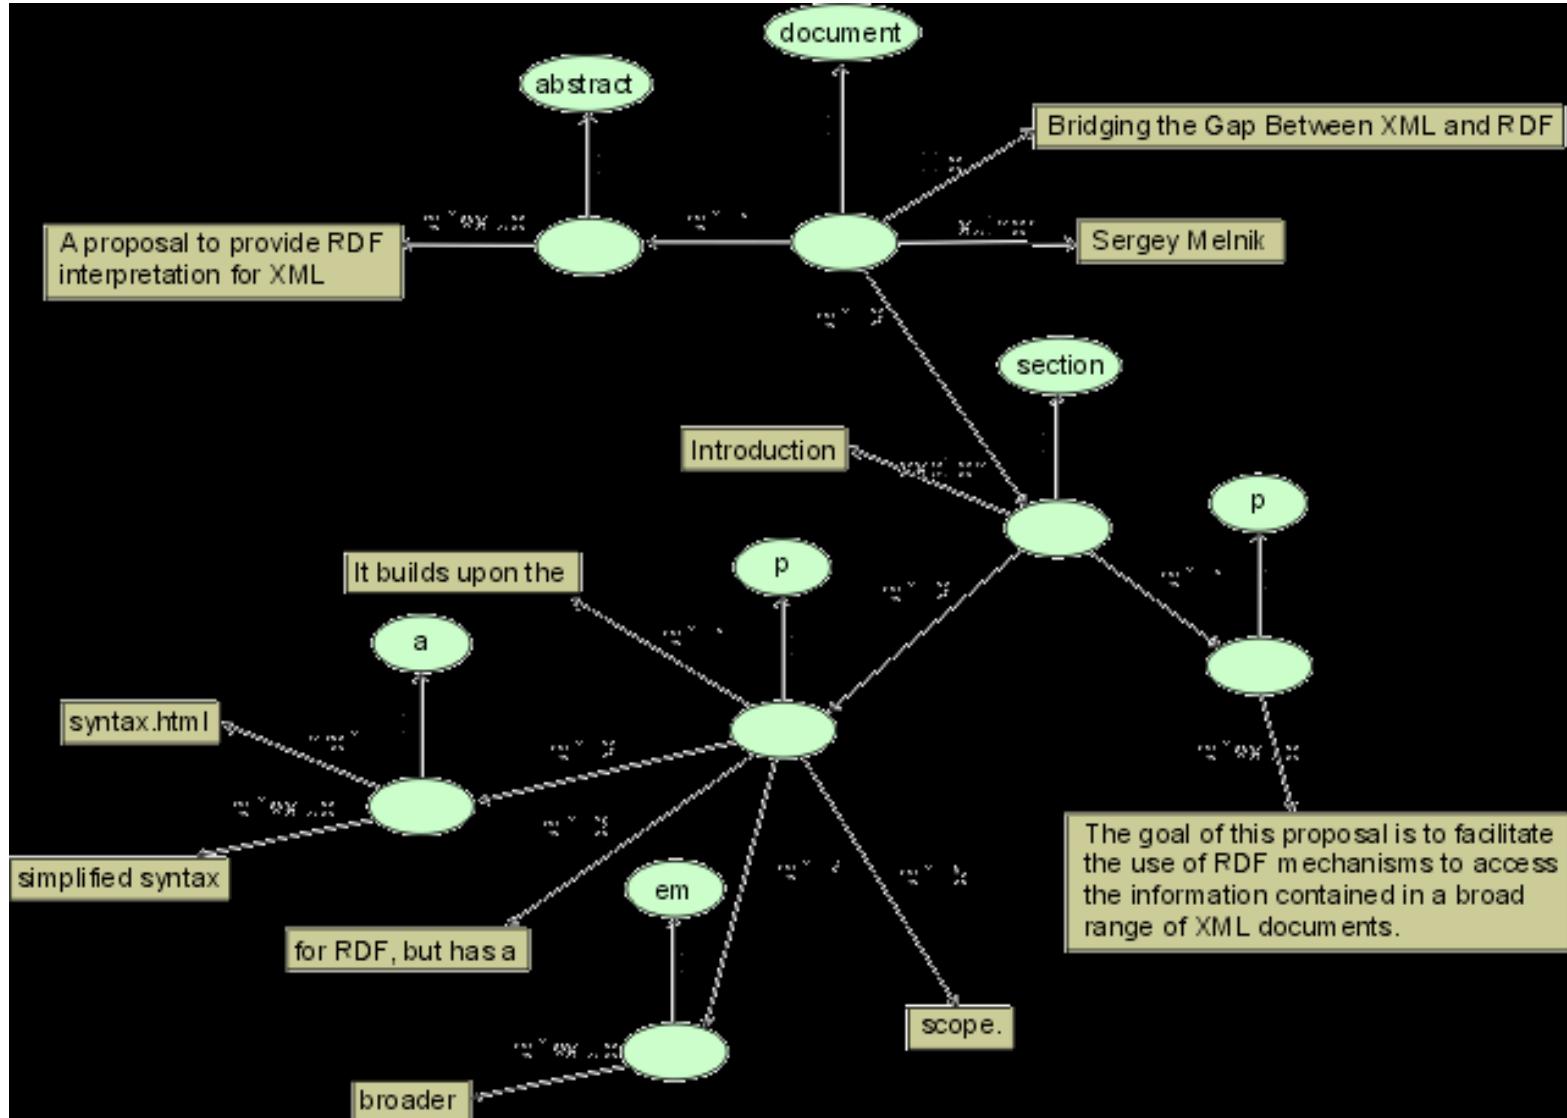
- Ontology Extraction
 - From XML to RDF
- Ontology Engineering
 - Best Practices
- Metadata Extraction
 - GRDDL
 - Concept Mapping
- Metadata Schemas
 - IMDB
- Upper Ontologies
 - Open Directory
 - DBpedia

- Erstes Problem: wie wird ein RDF Schema erstellt?
- Lösung → Es gibt schon ein XML Schema als „Grundlage“
- XML und RDF nicht gleich: Baum vs. Graph, Syntax vs. Semantik
- „Ontology Extraction“ heißt
 - Erzeugung einer Ontologie (ihrer Klassen, Prädikaten, Axiomen) durch die Analyse von nicht-ontologischen Dateien, z.B.: Text, Datenbank, XML
- Semiautomatische Verfahren
 - Das Ergebnis braucht in der Regel einige Verbesserungen

- XML hat Elemente, Attribute, Elementinhalte (Character Data)
- RDF hat Klassen, Prädikaten, Axiomen (C1 subClass C2, P1 subProperty P2, P1 domain C1, P2 range C2)
- Mapping definieren: XML Struktur → RDFS Struktur
- Beispiel: Sergey Melnik
<http://www-db.stanford.edu/~melnik/rdf/fusion.html>
 - XML Elemente werden hier als Prädikate interpretiert, außer wenn ein `rdf:instance` darauf hinweist, dass es als Klasse zu interpretieren ist.

```
<?xml version="1.0">
<document> Document hat strukturierten Inhalt
<title>Bridging the Gap between RDF and XML</title>
<author>Sergey Melnik</author>
<abstract>Author hat unstrukturierten Inhalt
XML</abstract>
<section caption="Introduction">
  <p>The goal of this proposal is to facilitate the use of RDF
mechanisms
  to access the information contained in a broad range of
XML documents.</p>
  <p>It builds upon a <a href="syntax.html">simplified
syntax</a> for RDF,
  but has a <em>broader</em> scope.</p>
</section>
</document>
```

Beispiel: RDF (von Sergey Melnik)



```
<?xml version="1.0">
<document>
  <title>Bridging the Gap between RDF and XML</title>
  <author hasSection range="Section">
    <abstract>A proposal to provide RDF interpretation for
    XML</abstract>
    <section caption="Introduction">
      <p>The goal of this proposal is to facilitate the use of RDF
      mechanisms
        to access the information contained in a broad range of
      XML documents.</p>
      <p>It builds upon a <a href="syntax.html">simplified
      syntax</a> for RDF,
        but has a <em>broader</em> scope.</p>
    </section>
  </document>
```

- Option 1: automatisiertes Mapping
 - z.B. XSLT, weil RDF eine XML Serialisierung hat
 - XPath wählt XML nodes
 - XSLT Templates erzeugen RDF Schema Statements
- Option 2: manuelles Mapping → Arbeitsweise
 - Entscheiden, ob Elemente/Attribute als Klassen oder Prädikate zu mappen sind
 - Entscheiden, welche Axiome hinzufügen sind
 - Entscheiden, ob es mehr Arbeit wäre, die Mappings in XSLT zu schreiben oder manuell RDF Schema zu formulieren

- Ontology Engineering ist ein Fachgebiet, in dem Methoden, Verfahren und Tools für die Erstellung von Ontologien erforscht werden.
- Siehe auch
http://ontoworld.org/wiki/Ontology_Engineering
- Gutes Anfänger dokument „**Ontology Development 101: A Guide to Creating Your First Ontology**“
http://protege.stanford.edu/publications/ontology_development/ontology101-noy-mcguinness.html

- 1) There is no one correct way to model a domain there are always viable alternatives. The best solution almost always depends on the application that you have in mind and the extensions that you anticipate.
- 2) Ontology development is necessarily an iterative process.
- 3) Concepts in the ontology should be close to objects (physical or logical) and relationships in your domain of interest. These are most likely to be nouns (objects) or verbs (relationships) in sentences that describe your domain.

- Ontology Best Practices heisst
 - „non-enforceable guidelines for ensuring quality of the ontology“
- Grundsätzliche Entscheidungen können später große Folgen haben
 - Klasse vs. Instanz
 - subClass/subProperty Verhältnisse
 - Klasse vs. Prädikat
- Komplexere Fragen zu Ontologieerstellung

- Ist ein Konzept als eine **Klasse** oder eine **Instanz von einer Klasse** zu modellieren?
 - Ist Chardonnay eine Instanz von WhiteWine oder ist es eine Klasse (subClassOf WhiteWine)?
- Entscheidung hängt vom Anwendungsgebiet und Ziel der Ontologie:
 - Welche Granularität wird gewünscht? Instanzen sind die **meist spezifischen** Konzepte in einer Ontologie.
 - Beispiel:
 - eine Ontologie für Weinempfehlungen hat Weinsorten als meist spezifische Konzept → Chardonnay hier wäre eine Instanz.
 - Eine Ontologie für ein Restaurant, wo einzelne Weinflaschen als Konzepte modelliert wird, hätte Chardonnay als Klasse.
 - Konzepte, die zusammen eine Hierarchie bilden, sind besser als Klassen zu modellieren.

- Ontologien erlauben Klassen- oder Prädikathierarchie zu bilden und diese als Inferenz zu benutzen.
- *subClassOf: A subclass of a class represents a concept that is a "kind of" the concept that the superclass represents (**Spezialisierung**)*
- Wann eine neue Subklasse?
 - „(1) have additional properties that the superclass does not have, or
 - (2) restrictions different from those of the superclass, or
 - (3) participate in different relationships than the superclasses“

- **Siblings** (Geschwister) - zwei Klassen mit der selben Superklasse: *All the siblings in the hierarchy must be at the same level of generality*
- Wieviele Siblings?
 - eine Klasse mit nur einer Subklasse ist vielleicht unnötig oder unvollständig;
 - eine Klasse mit zu vielen Subklassen benötigt vielleicht Zwischenklassen

- Ist ein Konzept besser als eine Klasse oder durch hinzufügen eines Prädikats zu modellieren?
 - z.B. ist `WhiteWine` als neue Klasse zu modellieren oder führen wir auf `Wine` ein Prädikat `colour` mit Wert `white`?
- Entscheidung liegt an der Wichtigkeit des Konzepts in der Ontologie
 - Haben `WhiteWines` andere Verhältnisse als `Wines`?
 - Wenn wir Axiomen beschränkt auf `WhiteWines` brauchen, dann muss sie eine Klasse sein.
 - Werden Instanzen von `WhiteWine` oft ihre Klasse ändern müssen?
 - Wenn wir Prädikaten nutzen, deren Wert sich ändern könnte, ist es nicht sinnvoll, das Konzept mit einer Klasse zu ersetzen, z.B. `AvailableWine`.
 - *„Usually numbers, colours, locations are properties and do not cause the creation of new classes.*

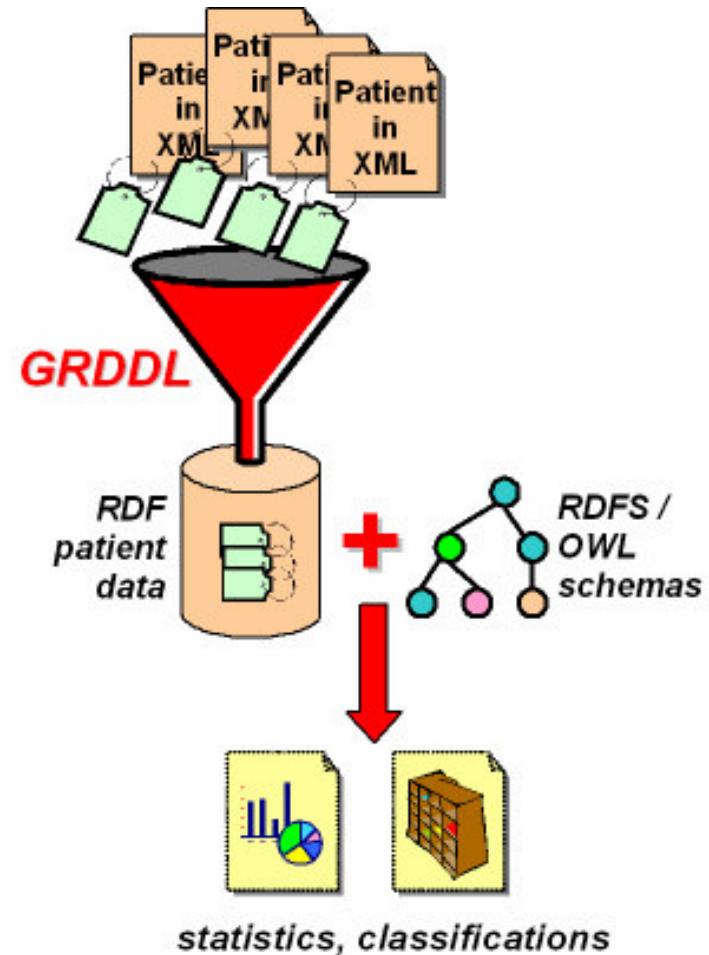
- Semantic Web Best Practices and Deployment (SWBPD) Working Group sammelt komplexere Fragen von Ontologiee-Entwickler
- Siehe <http://www.w3.org/2001/sw/BestPractices/>
- Working Group Notes zu:
 - Defining N-ary Relations on the Semantic Web: Use With Individuals
 - Representing Classes As Property Values on the Semantic Web
 - XML Schema Datatypes in RDF and OWL
 - A Semantic Web Primer for Object-Oriented Software Developers
- Am besten: vermeide komplexere Fragen!

- Nachdem man ein RDF Schema erzeugt hat, kann man Metadaten nach diesem Schema erstellen
- Option 1: alles manuell schreiben
 - Langweilig und aufwendig!
- Option 2: RDF Statements aus anderen Daten extrahieren
 - Verfahren definieren und durchführen
 - Ergebnisse prüfen
- Metadata Extraction heisst
 - „Erzeugung von Metadata (RDF Statements, die gültig nach einem RDF Schema sind) durch die Analyse von nicht-ontologischen Dateien, z.B. Text, Datenbank, XML“

- Spezifikation für RDF Metadata Erzeugung mit XSLT Stylesheets
- Fokus ist eher für das Web (XHTML Seiten, Microformats) aber
- kann uns zeigen, wie RDF von XML erzeugt werden könnte
- Siehe <http://www.grddl.org/>

- Siehe <http://www.w3.org/TR/2007/NOTE-grddl-scenarios-20070406/>

1. Eine Transformation von XML zu RDF wurde erstellt
2. GRDDL ermöglicht einem Client diese Transformation zu finden
3. Mit einem XSLT Processor wird RDF Data aus den XML Dateien extrahiert
4. Mit dem RDF Schema kann man diese RDF Metadata semantisch abfragen



- XML → RDF mit XSLT: Grundlagen
 - 1. XML Elemente wählen, die Klassen in dem RDFS sind
 - 2. Instanz von dieser Klasse erzeugen (mit eindeutiger URI oder als Blank Node, d.h. ohne URI)

```
<_0> rdf:type s:Wine
```
 - 3. Kinderelemente wählen, die Prädikate in dem RDFS sind
 - 4. Statements mit dieser Instanz als Subject erzeugen

```
<_0> dc:title „This is a title“
```
 - 5. Kinderelemente wählen, die Klassen in dem RDFS sind, einem Instanz erzeugen (Schritt 2) und dann Statement mit diesem Instanz als Objekt erzeugen
(Beachte schon erzeugte Instanzen!)

```
<_1> rdf:type s:Vineyard
```



```
<_0> s:hasVineyard <_1>
```

- Quelldokumente: Konzepte sind Wörter in natürlicher Sprache
- RDF: Konzepte sind eindeutig durch ein URI zu identifizieren und können einer RDF Klasse zugeordnet werden
- Problem: wie findet man Konzepte in den Quelldokumenten und wie werden ihnen URIs zugeordnet
- XML: z.B. <actor>Will Smith</actor>
- RDF, könnte man das noch als „Literal“ (simple datatype, hier String) interpretieren
 - <s:hasActor>Will Smith</s:hasActor>
- Was ist wenn wir auch über Will Smith reden wollen?

```
<s:hasActor  
rdf:resource="http://www.imdb.com/WillSmith"/>
```

- Man nutzt eine Heuristik – es ist nicht immer garantiert, dass es funktioniert
- Mapping: String → URI
- Mapping könnte klassenspezifisch sein
 - Actors kommen vielleicht aus einem anderen Namensraum als Tennisspieler
- Wenn möglich, kleine Unterschiede in der natürlichen Sprache berücksichtigen
 - Will Smith und Will E. Smith sind vielleicht dieselbe Person
- Wenn die Quelldokumenten konsistent sind, umso besser für ein Mapping!
- Algorithm: String Parsing, dann URI Auswahl

- Anderer Vorschlag von Ontology Engineering 101:

Ontologien wiederverwenden, dort wo möglich!

- Also, gibt es schon andere Ontologien, die für Sie relevant sein könnten?
 - IMDB in RDF
 - Open Directory Project
 - DBpedia

- IMDB Struktur als RDF Schema

<http://www.csd.abdn.ac.uk/~ggrimnes/dev/imdb/IMDB.rdfs>

- Anderer Versuch

<http://www.cs.umbc.edu/~skallu1/IMDb.pdf> (Leider ist die RDFS Datei nicht mehr erhältlich)

- Nicht vollständig, vielleicht gibt aber Ideen ☺
- Konzept URIs: IMDB gibt eine eindeutige URI zu jeder Instanz (Film, Schauspieler, Regisseur...)

- Was sind Upper Ontologies?
 - „*an ontology which describes very general concepts that are the same across all domains*,“
- Nutzlich als Quelle für URIs, die Konzepte identifizieren
- Open Directory Project (ODP) als Quelle für Kategorien
- DBpedia (Wikipedia in RDF!) als Quelle für individuelle Konzepte, z.B. Personen, Orte

- Eine offene Directory von Web Links, organisiert unter Kategorien ähnlich zu Yahoo's Directory

dmoz open directory project

[about dmoz](#) | [suggest URL](#) | [help](#) | [link](#) | [editor login](#)

[Search](#) [advanced](#)

Arts Movies, Television, Music...	Business Jobs, Real Estate, Investing...	Computers Internet, Software, Hardware...
Games Video Games, RPGs, Gambling...	Health Fitness, Medicine, Alternative...	Home Family, Consumers, Cooking...
Kids and Teens Arts, School Time, Teen Life...	News Media, Newspapers, Weather...	Recreation Travel, Food, Outdoors, Humor...
Reference Maps, Education, Libraries...	Regional US, Canada, UK, Europe...	Science Biology, Psychology, Physics...
Shopping Autos, Clothing, Gifts...	Society People, Religion, Issues...	Sports Baseball, Soccer, Basketball...
World Deutsch, Español, Français, Italiano, Japanese, Nederlands, Polska, Dansk, Svenska...		

[Become an Editor](#) Help build the largest human-edited directory of the web

Copyright © 1998-2006 Netscape

5,199,707 sites - 71,053 editors - over 590,000 categories



- Inhalt wird auch als RDF Dump angeboten
- Siehe <http://rdf.dmoz.org/>
- [structure.rdf.u8.gz](http://rdf.dmoz.org/structure.rdf.u8.gz) gibt den Kategorienstruktur in RDF
- Beispiel:

```
<Topic r:id="Top/Arts/Movies">
  <narrow r:resource="Top/Arts/Movies/Characters"/>
  <narrow r:resource="Top/Arts/Movies>Showtimes"/>
  <narrow r:resource="Top/Arts/Movies/Reviews"/>
</Topic>
```

- Mit Namensraum <http://dmoz.org/RDF> ergibt z.B. die URI für Movies:<http://dmoz.org/RDF/Top/Arts/Movies>
- Könnte Berechnung von semantischer „Ähnlichkeit“ ermöglichen – Suche nach Movie Reviews bedeutet Showtimes auch relevant, oder Movies selber.

- The DBpedia project [extracts] structured information from Wikipedia and by making this information available on the Semantic Web.
- The DBpedia dataset currently provides information about more than 1.95 million “things”, including at least 80,000 persons, 70,000 places, 35,000 music albums, 12,000 films. Altogether, the DBpedia dataset consists of 103 million pieces of information (RDF triples).
- Siehe <http://dbpedia.org/>
- Beispieldokument Woody Allen
http://dbpedia.org/page/Woody_Allen

- Vergibt jedem Wikipedia-Konzept eine eindeutige URI
 - Wie in Wikipedia, Konzepte wurde unterschieden
 - <http://dbpedia.org/page/Apple> ist das Obst
 - http://dbpedia.org/page/Apple_Inc ist die Firma
- Bietet ein SPARQL Endpoint, damit eine Anwendung Konzepte abfragen könnte
 - Möglichkeit um Konzepte zu finden, z.B. Konzepte mit Namen „Woody Allen“
- Durch dynamische Abfragen (u.a. mit JavaScript oder PHP im Web), Inhalt über ein Konzept immer aktuell halten
- Kurz: durch die Nutzung von DBpedia URIs entsteht die Möglichkeit, Ihre Metadata mit anderen Metadata im Web zu erweitern!

Das Ende

- Fragen?