

Seminar: Business Intelligence –
Teil II: Data Mining & Knowledge Discovery



Anne Jannasch

13.02.2004

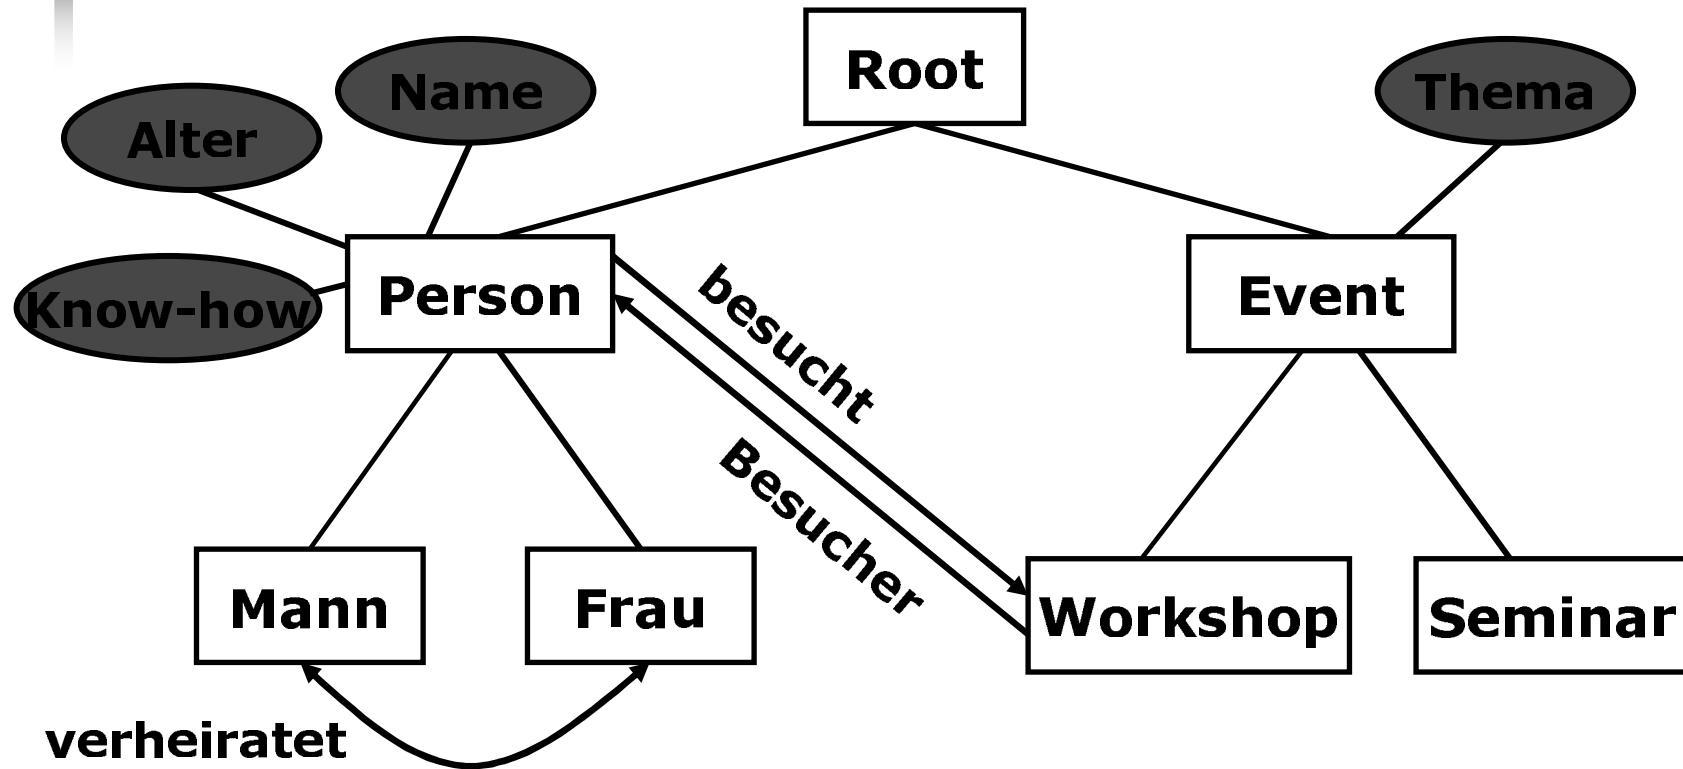
Überblick

- Ontologie-Begriff
- Ontologiesprachen
 - RDF und RDFS
 - OIL
 - F-Logic
- Ontologiewerkzeuge
- Ontologie-basierte Systeme
 - Ontobroker
 - On-To-Knowledge
- Methoden zur Extraktion und Verwendung von taxonomischen Beziehungen

Ontologie-Begriff

- Definition: „Eine Ontologie ist eine Spezifikation einer Konzeptualisierung.“ (Tom Gruber)
- Charakteristika einer Ontologie:
 - Konzepte
 - Beziehungen
 - Eigenschaften
 - Regeln
- Organisation einer Ontologie:
→ Taxonomien
- Wissensbasis = Ontologie + Instanzen

Beispiel für eine Ontologie



- Regeln:
 - „Verheiratet“ ist symmetrisch.
 - „Besucht“ und „Besucher“ sind invers.
 - Wenn eine Person einen Workshop besucht, eignet sie sich Wissen über ein Thema an.

Überblick

- ✓ Ontologie-Begriff

→ **Ontologiesprachen**

- RDF und RDFS
- OIL
- F-Logic

- Ontologiewerkzeuge
- Ontologie-basierte Systeme
 - Ontobroker
 - On-To-Knowledge
- Methoden zur Extraktion und Verwendung von taxonomischen Beziehungen

RDF und RDFS

- RDF steht für Resource Description Framework
- Datenmodell zur Repräsentation von Metadaten:
 - Ressourcen
→ Alles, was durch RDF beschrieben werden kann.
 - Eigenschaften
→ Charakteristiken, Attribute oder Relationen einer Ressource.
 - Aussagen
→ Bestehen aus Subjekt, Prädikat und Objekt.

RDF und RDFS

- Beispiel: Die Ressource <http://www.w3.org/Home/Lassila> hat den Autor Ora Lassila.

Subjekt (Ressource)	http://www.w3.org/Home/Lassila
Prädikat (Eigenschaft)	Autor
Objekt (Wert)	„Ora Lassila“

- In XML-Syntax:

```
<?xml version="1.0"?>
<rdf:RDF
  xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#"
  xmlns:s="http://description.org/schema/">
  <rdf:Description about="http://www.w3.org/Home/Lassila">
    <s:Creator>Ora Lassila</s:Creator>
  </rdf:Description>
</rdf:RDF>
```

RDF und RDFS

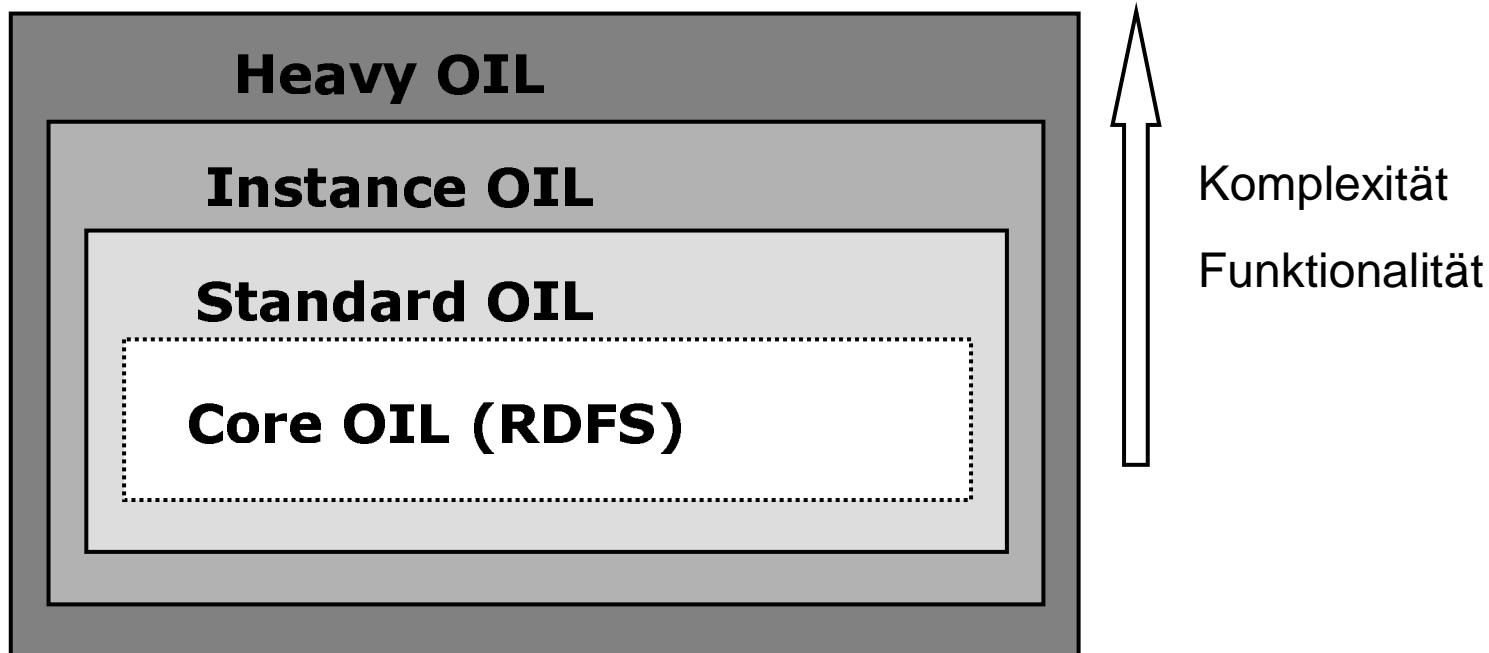
- RDFS steht für RDF-Schema.
 - Erweiterung von RDF
 - Formale Definition von Klassen und Eigenschaften
 - Vererbungshierarchien
 - Einschränkungen
- RDFS bietet Beschreibung von Schemata, die mit Ressourcen instanziert werden können.
 - Semantische Interpretation von Ressourcen

OIL

- OIL steht für Ontology Inference Layer
- OIL führt drei Sprachfamilien zusammen:
 - Frame-basierte Systeme
 - Frames (Klassen)
 - Slots (Attribute)
 - Deskriptive Logik
 - Konzepte
 - Rollen
 - Inferenzen
 - Web-Sprachen
 - RDF und RDFS

OIL

- OIL ist in Schichten eingeteilt:



F-Logic

- Kombination der Repräsentationsformalismen Frames und Prädikatenlogik
- Definition von Inferenzregeln
- Modellierungsprinzipien:

F-Logic	Bedeutung
$C1 :: C2$	$C1$ ist Unterklasse von $C2$.
$O : C$	O ist eine Instanz von C .
$C1[A=>>C2]$	Für die Klasse $C1$ ist ein mehrwertiges Attribut A definiert, dessen Werte eine Instanz der Klasse $C2$ sind.
$->$	Impliziert (wird zur Modellierung von Regeln verwendet).

Überblick

- ✓ Ontologie-Begriff
- ✓ Ontologiesprachen
 - RDF und RDFS
 - OIL
 - F-Logic

→ **Ontologiewerkzeuge**

- Ontologie-basierte Systeme
 - Ontobroker
 - On-To-Knowledge
- Methoden zur Extraktion und Verwendung von taxonomischen Beziehungen

Ontologiewerkzeuge

- Hoher Arbeitsaufwand beim Erstellen von Ontologien
- Ontologiewerkzeuge helfen bei der Entwicklung und Verwendung von Ontologien
 - Lokal installierbar
 - Web-basierend

Protégé-2000

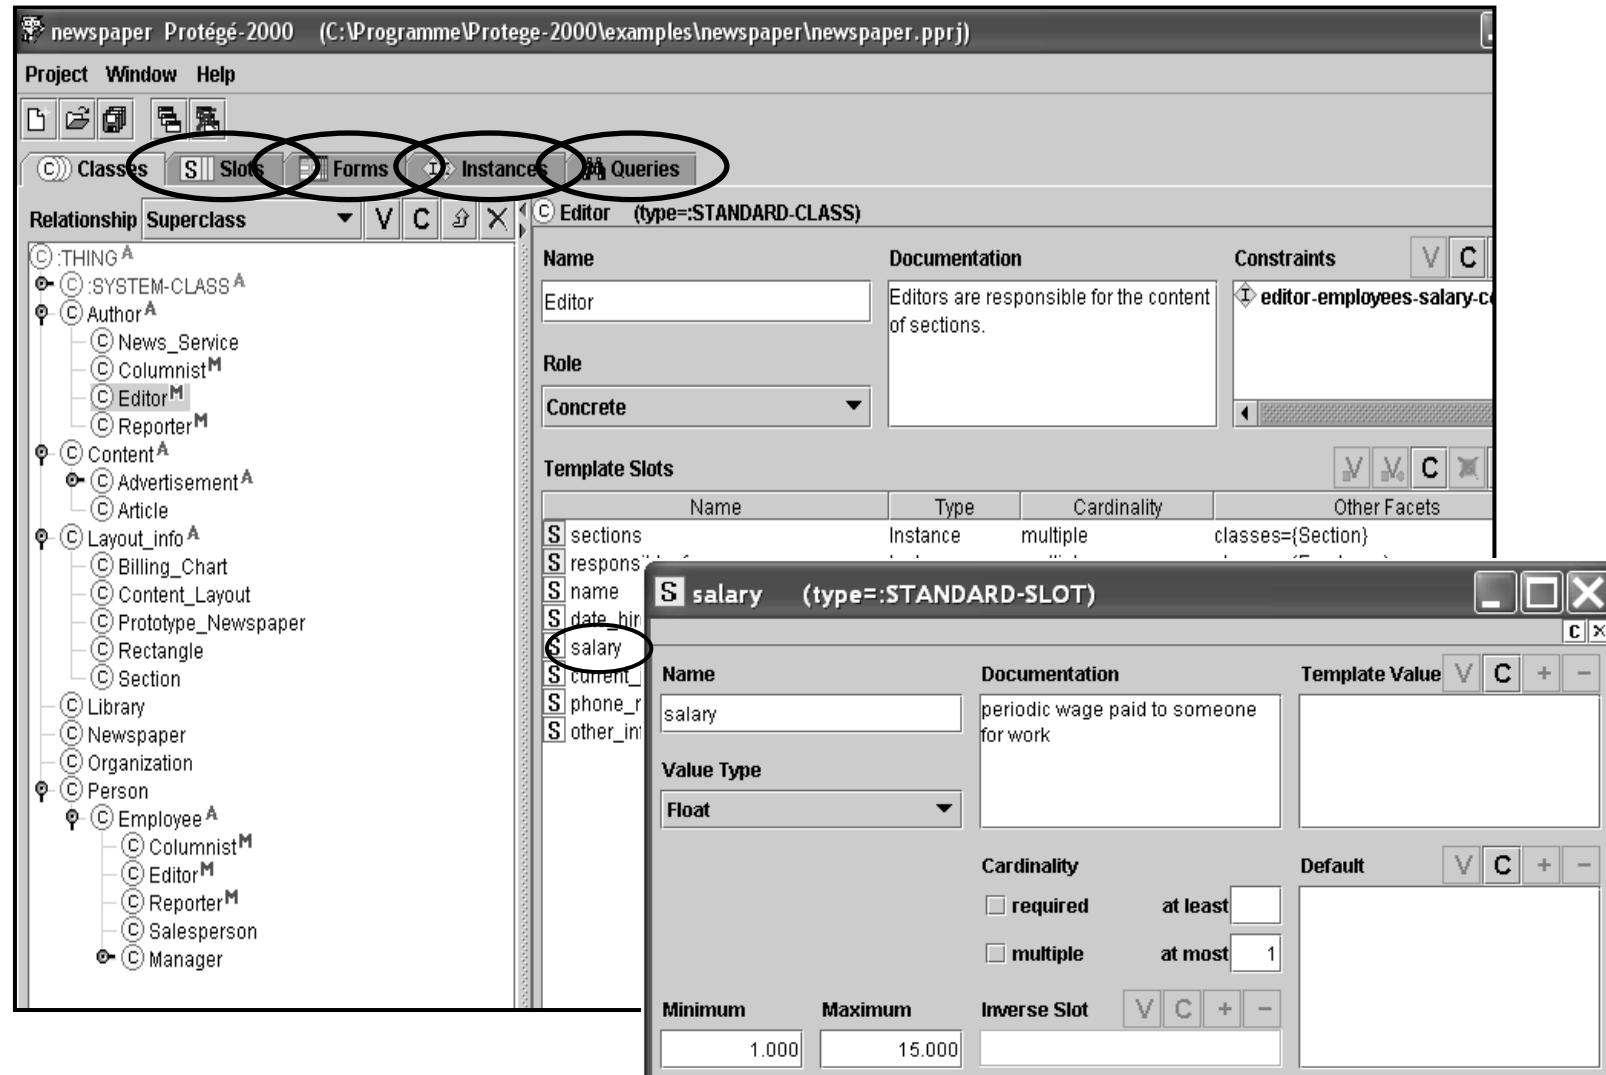
- Protégé-2000

- Ontologie-Editor der Universität Stanford
- Kostenlos im Internet erhältlich
- In Java geschrieben
- Erweiterbar durch Plugins

Protégé-2000

- Wissensmodell
 - Frame-basiert
 - Protégé-2000 Ontologien bestehen aus:
 - Klassen: Konzepte aus dem zu modellierenden Weltausschnitt
 - Slots: Attribute der Klassen
 - Facetten: Eigenschaften von Slots
 - Axiome: Zusätzliche Einschränkungen
- Speicherarten der erstellten Wissensbasis
 - Standard Text File
 - RDF
 - JDBC

Protégé-2000



Thema: Web Knowledge Management

Überblick

- ✓ Ontologie-Begriff
- ✓ Ontologiesprachen
 - RDF und RDFS
 - OIL
 - F-Logic
- ✓ Ontologiewerkzeuge
- **Ontologie-basierte Systeme**
 - Ontobroker
 - On-To-Knowledge
- Methoden zur Extraktion und Verwendung von taxonomischen Beziehungen

Ontologie-basierte Systeme

- Wissensmanagement ist kritischer Erfolgsfaktor für Unternehmen
- Dokument-Management-Systeme mit Schwächen

→ Ontologie-basierte Systeme

- Verbinden Wissen mit Hilfe von Ontologien
- Leiten neues Wissen ab

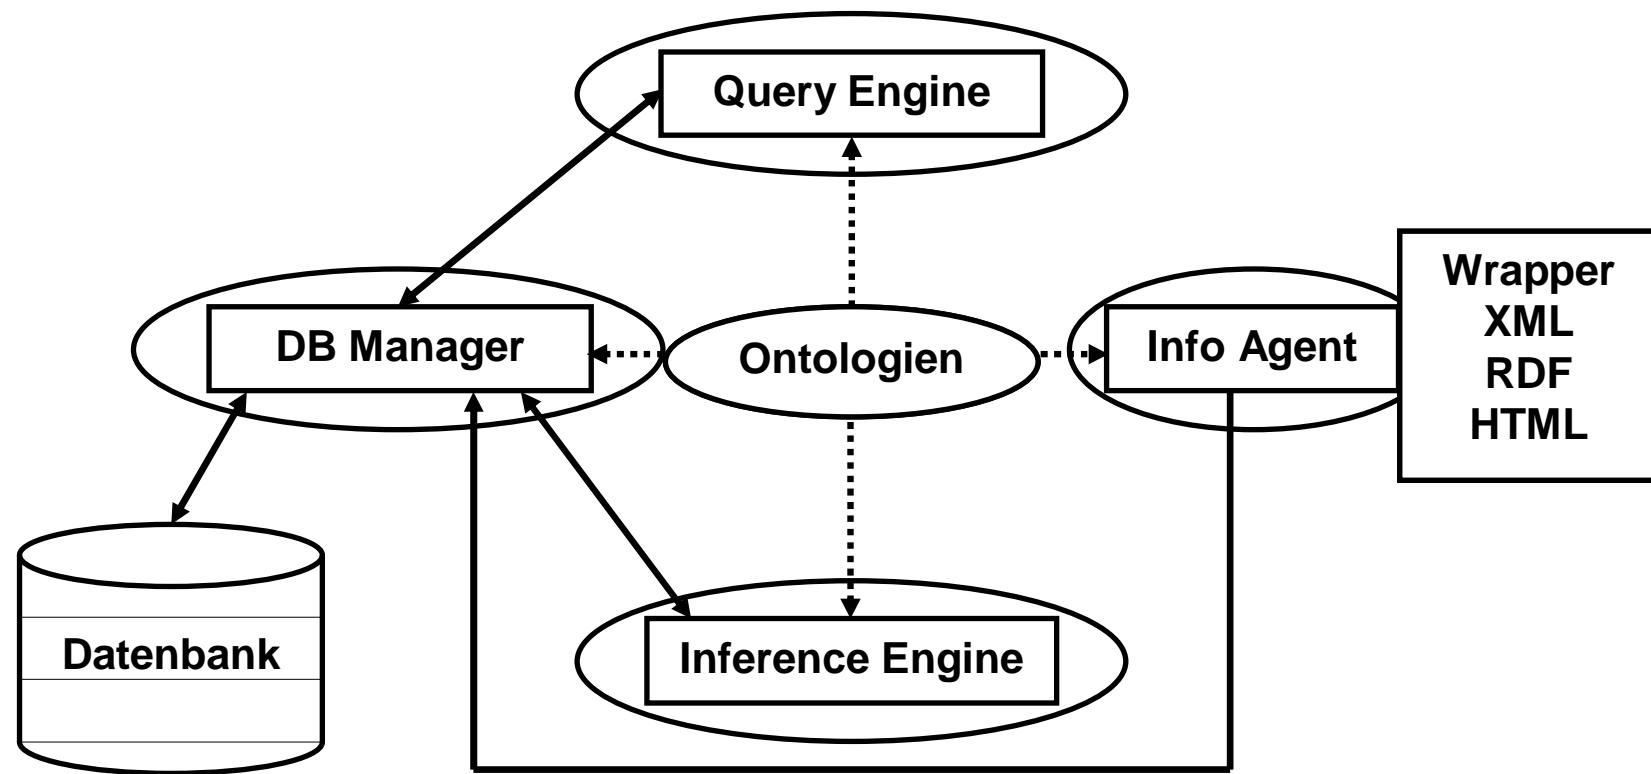


Ontobroker

- Firma Ontoprise in Karlsruhe
 - Ontologie-basiertes Wissensmanagement-System
 - Zugriff auf verschiedenartige Quellen
 - Ableiten von neuem Wissen aus vorhandenen Fakten
- 

Ontobroker

- Aufbau von Ontobroker



Ontobroker

The image shows a screenshot of the Ondepad application interface. On the left, there is a toolbar with various icons, a URL bar containing "file:///H:/onto/example/~richard.html", and a main window displaying a portrait of a man (Richard Benjamins) and some descriptive text. Below the portrait, there is a link to his affiliation at the Artificial Intelligence Research Institute (IIIA). On the right, the corresponding HTML code is shown, with several parts highlighted by black ovals:

```
<HTML>
<HEAD>
  <TITLE>
    Richard Benjamins
  </TITLE>
</HEAD>

<H1>
<A HREF="pictures/id_rich.gif">
<IMG align="middle"
  SRC="pictures/richard.gif"></A>
</H1> <P>

<A onto="page[photo=href]"
  href="http://www.iiia.csic.es/~richard/
  pictures/richard.gif" ></A>

<A onto="page[firstName=body]">
  Richard</A>
<A onto="page[lastName=body]">
  Benjamins </A>
</H1> <P>

<A onto="page[affiliation=body]"
  href="#card">
  Artificial Intelligence Research Institute
  (IIIA)</A> -
<A HREF="http://www.csic.es/">CSIC</a>, Barcelona,
  Spain <BR>
  and <BR>
  ...

```

Arrows point from the highlighted code sections to the corresponding elements in the Ondepad interface: the first oval points to the photo in the main window, the second to the affiliation link, and the third to the names "Richard" and "Benjamins".

Ontobroker

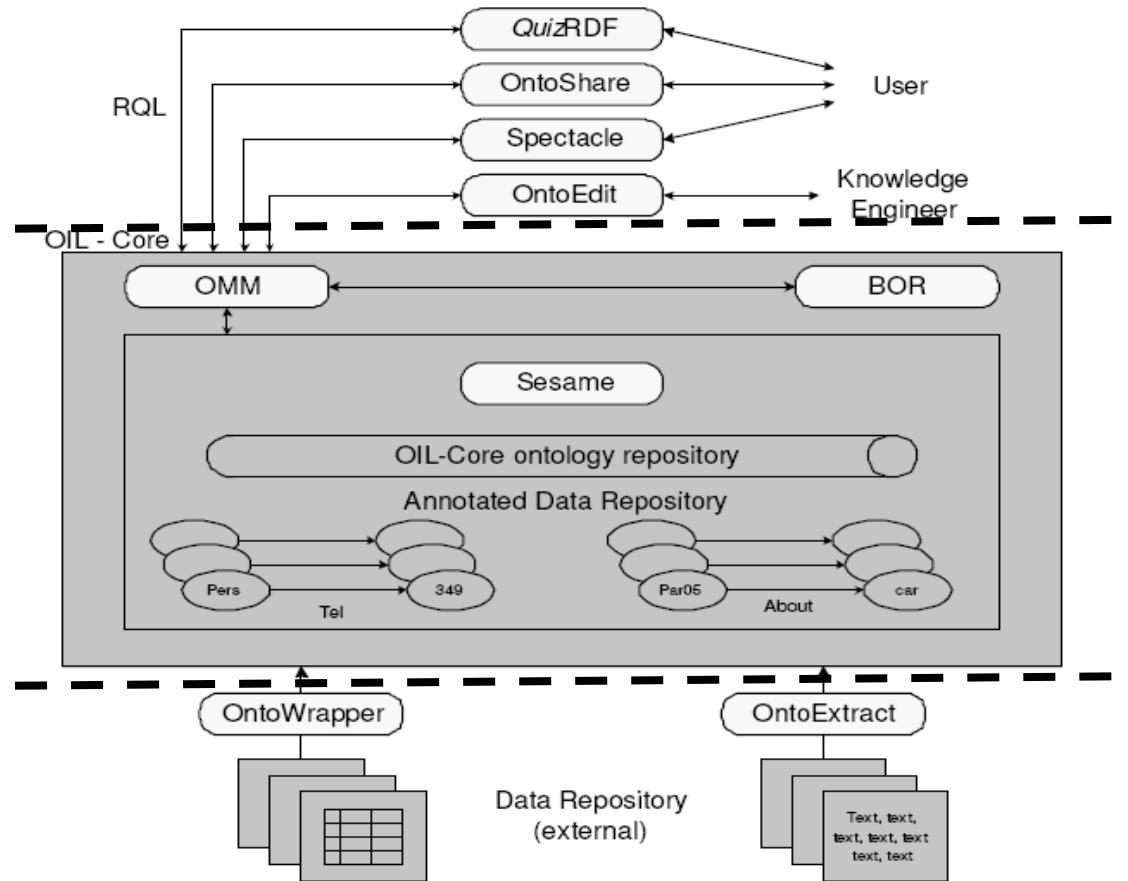
- Funktionsweise von Ontobroker
 - Eigenständige Java-Anwendung
 - Server
 - Anwendungen
 - (KA)2 Initiative
 - Integration nur bei annotierten Seiten
 - Verschiedene „Ontogruppen“
 - Kein Ersatz für Suchmaschinen
- Schwerpunkt liegt auf Integration in Anwendungen einzelner Gruppen

On-To-Knowledge

- Europäisches Projekt, 2000 – 2002
- Entwicklungsziele:
 - Werkzeugumgebung
 - Ontologiesprache OIL
 - Methodologie
- Zentrales Ergebnis:
 - Ontologie-basierte Werkzeug-Umgebung für Wissensmanagement
 - Unterstützung von Firmen-Netzwerken und Internet

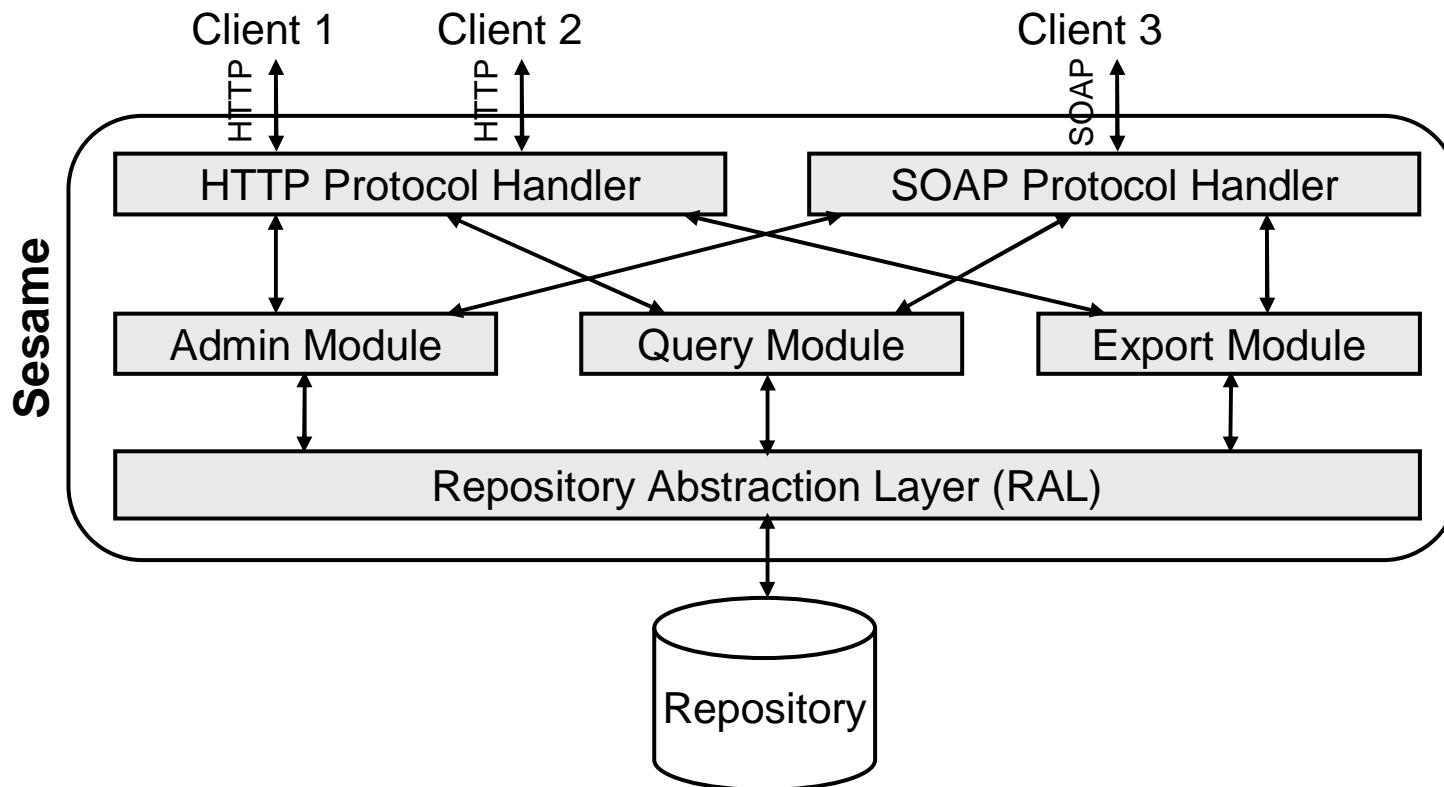
On-To-Knowledge

■ Aufbau



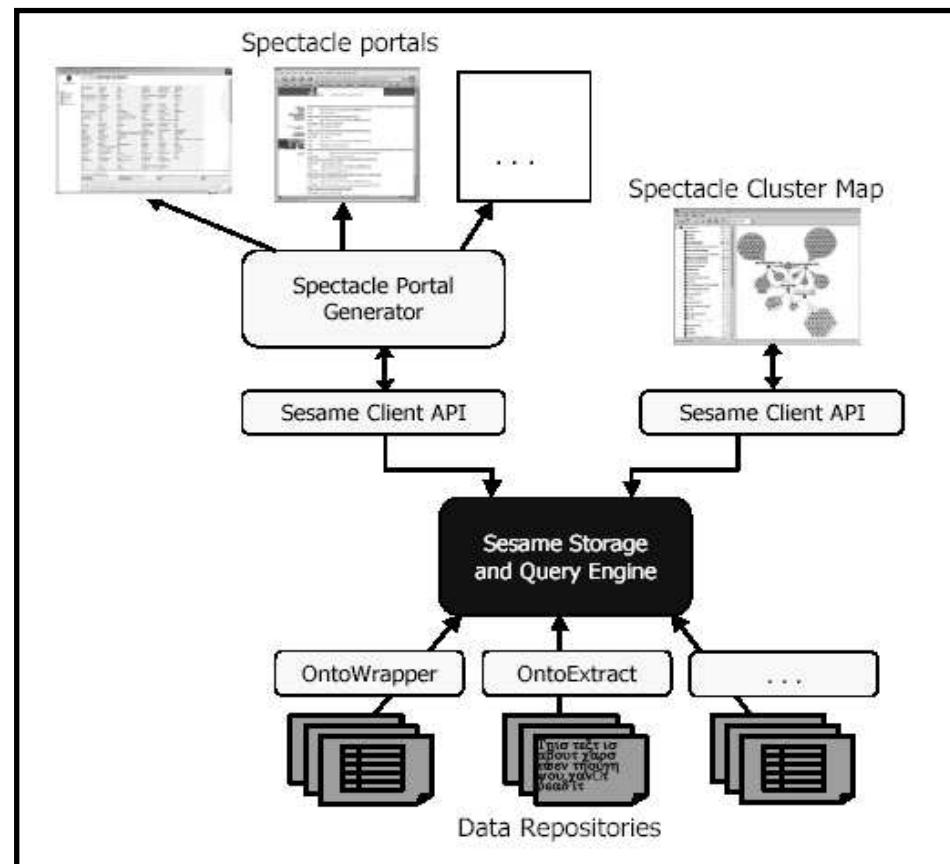
On-To-Knowledge

- Sesame
 - Persistentes Speichern, Archivierung und Abfrage von RDF und RDFS-Daten



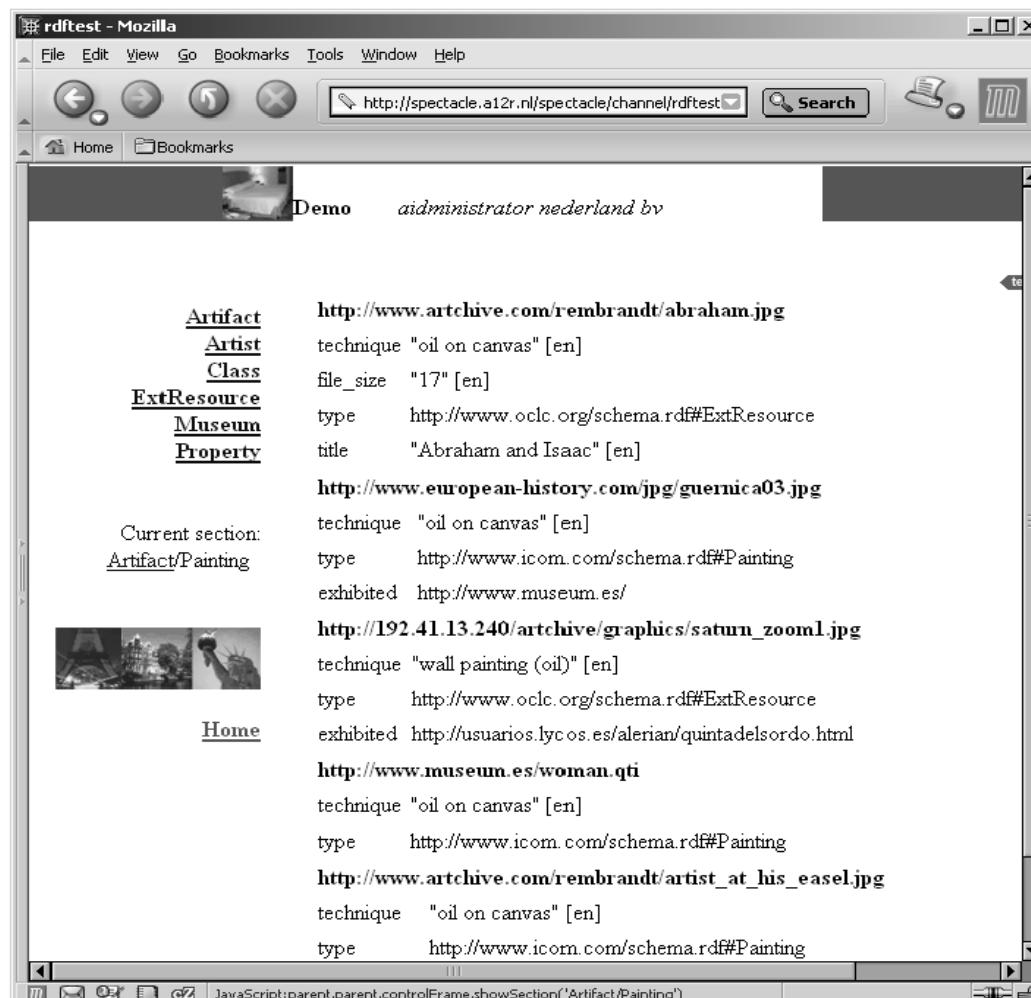
On-To-Knowledge

- Spectacle
 - Plattform mit maßgeschneideter Informationsdarstellung
 - Erzeugen von Informationsrepräsentationen
 - Formatiert und gegliedert
 - „Navigieren“



On-To-Knowledge

- Spectacle
→ RDF-Explorer



On-To-Knowledge

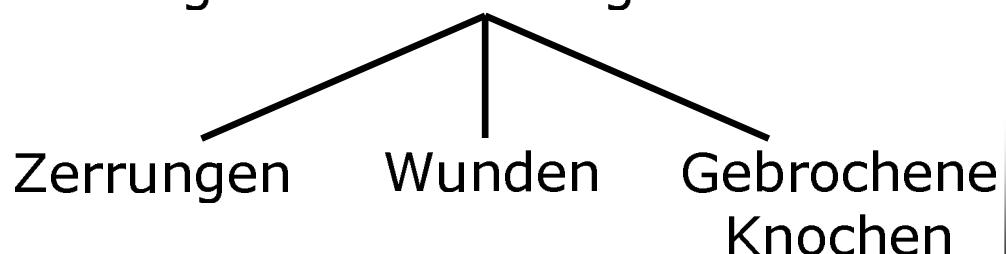
- OntoShare
 - Gemeinsamer Zugriff einer Arbeitsgruppe
 - Interessen als Anwenderprofil
 - Speichern, Wiedergewinnen und Zusammenfassen von Informationen
 - Informieren anderer Anwender
- Funktionalitäten
 - E-Mail Benachrichtigung
 - Suchen im gemeinsamen Speicher
 - Personalisierte Information

Überblick

- ✓ Ontologie-Begriff
 - ✓ Ontologiesprachen
 - RDF und RDFS
 - OIL
 - F-Logic
 - ✓ Ontologiewerkzeuge
 - ✓ Ontologie-basierte Systeme
 - Ontobroker
 - On-To-Knowledge
- **Methoden zur Extraktion und Verwendung von taxonomischen Beziehungen**

Extraktion taxonomischer Beziehungen

- Syntaktische Analyse
 - Suche nach Instanzen von lexikalisch-syntaktischen Mustern
- Beispiel:
 - Muster: ...NP {,NP} * {,} oder andere NP ...
 - Satz: „Zerrungen, Wunden, gebrochene Knochen oder andere Verletzungen kommen häufig vor.“
 - Taxonomische Beziehungen: Verletzungen



Extraktion taxonomischer Beziehungen

- Statistisch basierte Analyse
 - Erstellen von taxonomischen Beziehungen
 - Folgern der Semantik einer neuen Klasse
 - Klasse in Beziehung zu vorhandenen Klassen setzen
 - Distributionale Daten
 - Keine Muster-Erstellung, sondern Automatisierung
→ Automatische Klassifikationsmethoden
- Verfahren der k-nächsten Nachbarn
 - Neues Objekt in Klasse mit meisten „k-nächsten Nachbarn“
→ Neue Klasse in taxonomische Struktur
→ Hyponym jener Klasse mit größter Anzahl von Hyponymen mit nächsten Nachbarn

Verwendung taxonomischer Beziehungen

- Kombination der Informationen über taxonomische Struktur mit statistischen Daten über Konzepte
- Tree Descending Algorithmus
 - Semantik jeder Klasse spiegelt wichtigste semantische Eigenschaften ihrer Hyponyme wieder
 - Abstieg von Wurzel zu Blättern
 - Neues Objekt in Klasse mit größter Anzahl ähnlicher Objekte
- Tree Ascending Algorithmus
 - Kombination taxonomischer und distributionaler Ähnlichkeit zwischen nächsten Nachbarn

Zusammenfassung

- ✓ Ontologie-Begriff
 - „Spezifikation einer Konzeptualisierung“
- ✓ Ontologiesprachen
 - Formale Darstellung von Ontologien
- ✓ Ontologiewerkzeuge
 - Entwicklung und Bearbeitung von Ontologien
- ✓ Ontologie-basierte Systeme
 - Verbinden und leiten neues Wissen mit Ontologien ab
- ✓ Methoden zur Extraktion und Verwendung von taxonomischen Relationen
 - Automatisierung des Ontologie-Erzeugungsprozesses



**Vielen Dank
für
Ihre Aufmerksamkeit !**

