



Anwendungen der KI  
– Sommersemester 2018 –

# Kapitel 11: Linked Open Data

Prof. Adrian Ulges  
B.Sc. {Angewandte, Medien-, Wirtschafts-}informatik  
Fachbereiche DCSM  
Hochschule RheinMain



- ▶ Wir haben letzte Woche bereits einen **Wissensgraph** kennen gelernt: **WordNet**.
- ▶ WordNet war eine Art **Wörterbuch** mit hochqualitativen Information für einen Standard-Vokabular.
- ▶ WordNet war **klein** → Kaum **Spezialinformation** für Named Entities.
- ▶ Um spezifische Fragen zu beantworten, müssen wir **größer denken...**

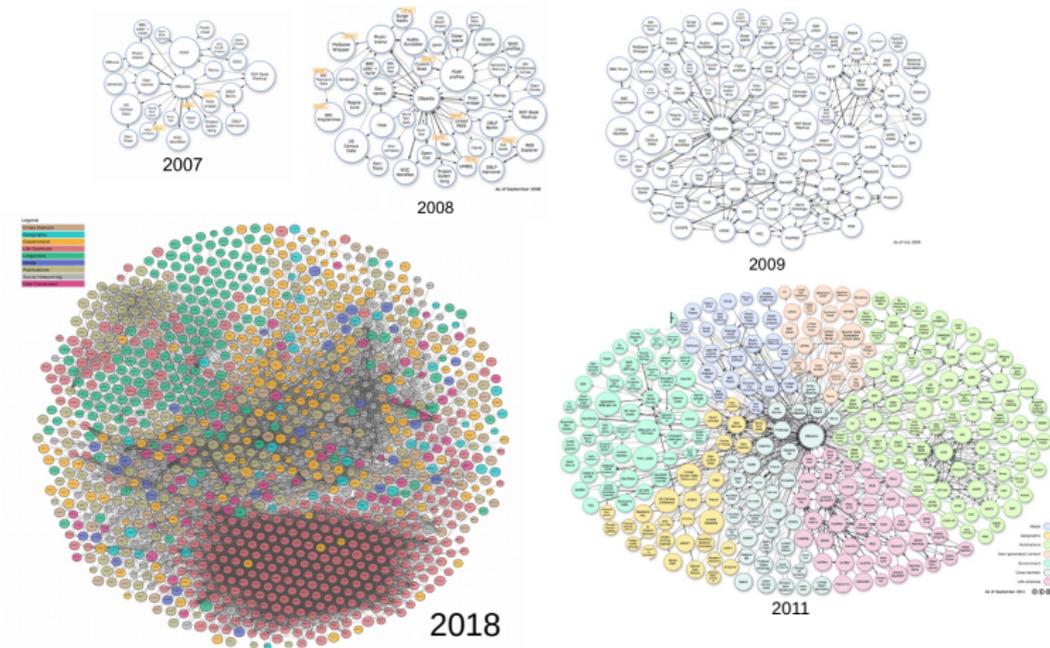
# Linked Open Data



# Linked Open Data



In den letzten 15 Jahren ist ein Netz von großen Wissensgraphen entstanden, die sogenannte **Linked Open Data (LOD) Cloud**<sup>1</sup>



<sup>1</sup><https://lod-cloud.net/>

# Das “Semantic Web”



Woher kommt LOD? → Vision des **Semantic Web**

## Das WWW

- ▶ Seit den frühen 1990ern, exponentielles Wachstum von **User-generated Content**.
- ▶ Zeitalter der **Suchmaschinen**: Computer “rechnen” nicht mehr, sondern sind für ihre User hauptsächlich Portale zu Information.
  - ▶ Chats mit Freunden
  - ▶ Produkte online recherchieren und kaufen
  - ▶ Videos schauen
  - ▶ ...
- ▶ Aktuell ist Content nur **für Menschen** verständlich, aber **nicht/schwer maschinen-interpretierbar**.

# Sind Suchmaschinen “gut genug”?



- ▶ Manche Anwendungen erfordern 100% Precision+Recall!
- ▶ Manche Anwendungen erfordern **detailliertes** Verständnis

## Neue Anwendungsgebiete von KI

- ▶ Detaillierte Auskünfte erteilen (*Automatische Sachbearbeiter*)
- ▶ Personalisierung (*Persönliche Digitale Assistenten*)
- ▶ Verhandeln und Optimieren (*Autonome Services*)
- ▶ Komplexere Fragestellungen (*Trip nach Rom planen*)

## Vision: Das Semantic Web

- ▶ **Ziel: maschinen-interpretierbarer Content!**
- ▶ Vermeide Mehrdeutigkeiten natürlicher Sprache

`'I am a professor of computer science.'` vs.

`'I consider myself an AI lecturer.'`

- ▶ Nehme gegebene harte Fakten an, Fokus auf maschinelle Interpretierbarkeit + Inferenz.

# Semantic Web: History



Der bekannteste Verfechter des Semantic Web ist **Tim Berners-Lee**, der auch das **WWW** in den 1980ern mit entwickelte.

*"The Semantic Web is an extension of the current web in which information is given well-defined meaning, better enabling computers and people to work in cooperation."*

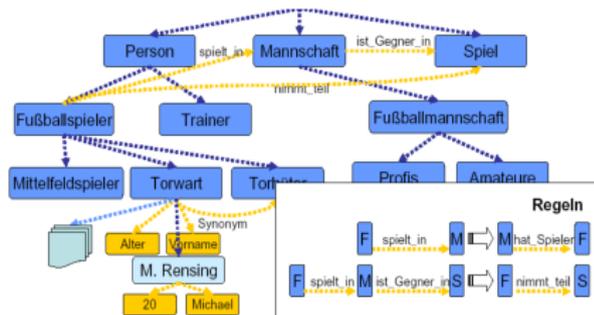
(Tim Berners Lee et al., "The Semantic Web" (Scientific American, 2001))

*"The Semantic Web will not be a new global information highway parallel to the existing World Wide Web; instead it will gradually evolve out of the existing Web."*

(Antoniou, van Harmelen, "A Semantic Web Primer" (2004))

## Grundlage

- ▶ Eine gemeinsame Sprache (Symbole, Konzepte, Relationen)
- ▶ Begriff der **Ontologie** (siehe letzte Vorlesung)



# Semantic Web: Beispiel



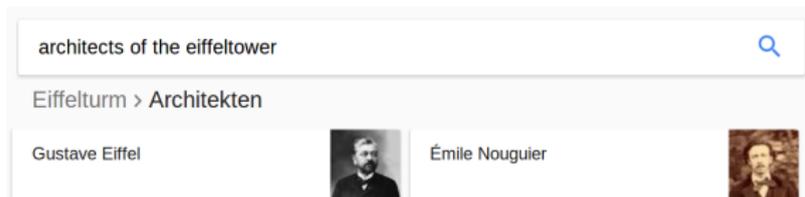
Suche bei einer Web-Suchmaschine Bilder von Gustave Eiffel  
(*dem Erbauer des Eiffelturms*)

> 'architects of the eiffeltower'

Ergebnis 2013



Ergebnis 2018





## Was ist hier passiert?

- ▶ Die Suchmaschine besitzt eine **Ontologie**, u.a. mit Entitäten #EiffelTower und #GustaveEiffel, sowie die Relation `HasArchitect(#Eiffeltower,#GustaveEiffel)`.
- ▶ Die Instanz #Eiffeltower und die Relation `HasArchitect()` wurden in der **Anfrage** identifiziert.
- ▶ Die **Zieldokumente / Bilder** besitzen **Metadaten**, z.B. semantische oder Freitext-Annotationen
- ▶ Durch einen **formalen Query** wird die Instanz #GustaveEiffel gefunden, und hierüber die Zieldokumente/Bilder.

## Vorteile dieses "semantischen" Vorgehens?

- ▶ Höhere Genauigkeit
- ▶ Erklärbarkeit, Transparenz für den Nutzer

# Semantische Methoden: Anwendungsfelder



## Digitale Personal Assistenten

- ▶ Assistenten vereinbaren Arzttermine, planen die Anfahrt, verlegen hierfür weitere Termine, etc.

## Handel

- ▶ Informationen über **Produkte**: “Bis zu welcher Temperatur kann ich Schaltung X betreiben?”
- ▶ Insbesondere im **B2B-Bereich**: Agenten führen automatisch Preisvergleiche durch, wählen Produkte aus und konfigurieren sie (Was sind die Anforderungen an den Stromkreis? Wie lange ist die Garantie?)
- ▶ Agenten interpretieren formal spezifizierte **Verträge**. Beispiel Krankenversicherung: Was wird was bezahlt? Worin unterscheiden sich Tarif A und B?

## Dokumenten- und Wissensmanagement

- ▶ Wer im Betrieb kennt sich mit welchen Konzepten aus?  
→ Reuse von Lösungen, Expertenmanagement
- ▶ Enthalten Dokumente Widersprüche / unterschiedliche Fakten?



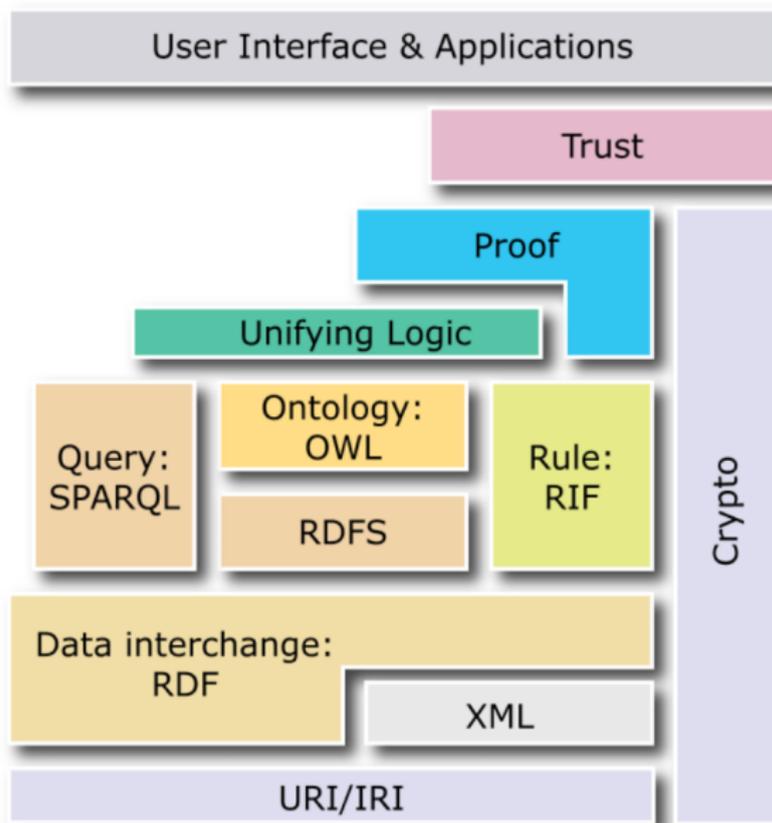
1. Grundlagen: RDF und Turtle

2. DBPedia

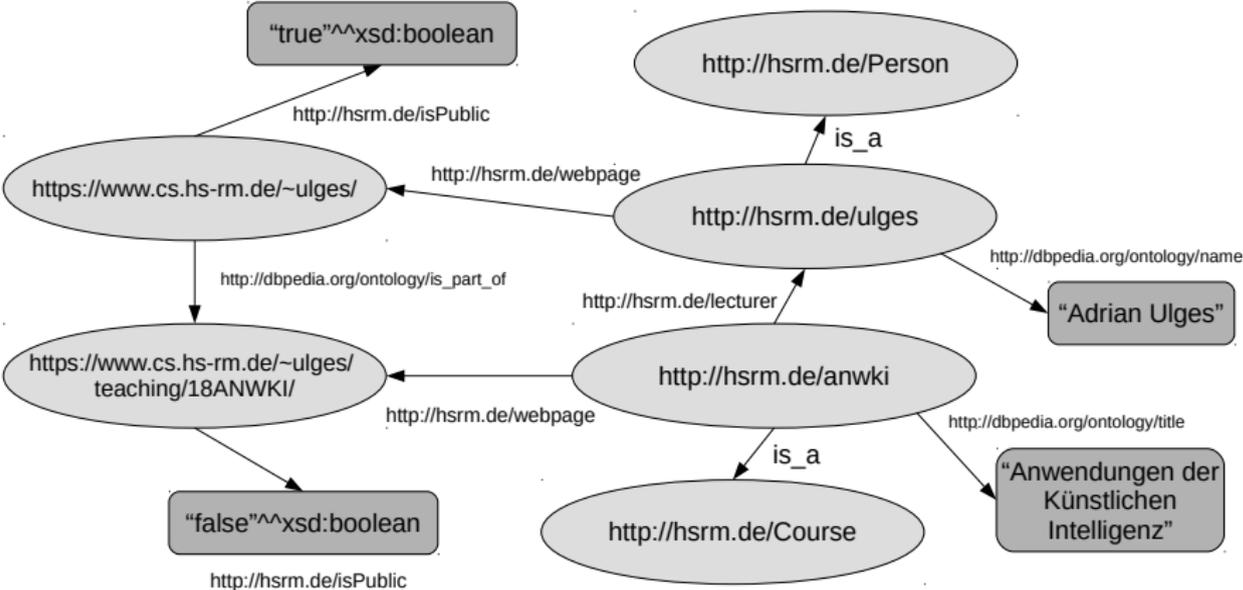
3. SPARQL

4. Kritik

# Der W3C Semantic Web Stack



# Grundlagen: RDF





RDF = Resource Description Framework (vom W3C)

- ▶ **Zweck:** Beschreibung von Ressourcen in relationaler Weise
- ▶ **Bestandteile:** (1) RDF Data Model (resource has property with value). (2) RDF Syntax (Repräsentation eines RDF Data Models, z.B. in XML oder Turtle).

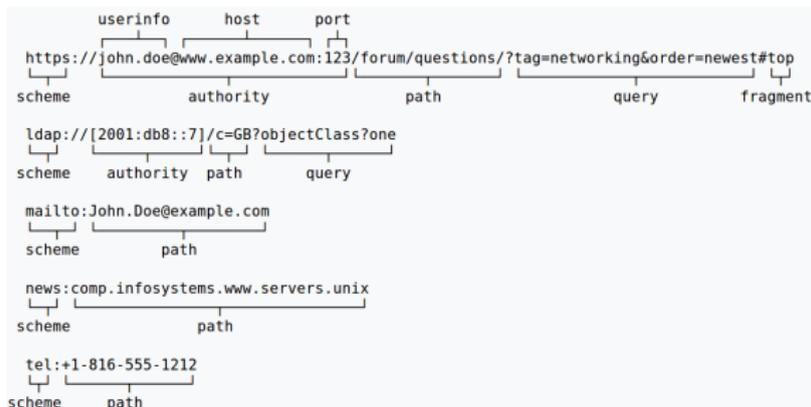
## Ressourcen

- ▶ Eine **Resource** (oder *Knoten*) ist ein Informationsobjekt das mit Metadaten beschrieben wird.
- ▶ Sie wird über einen **Universal Resource Identifier (URI)** identifiziert.
- ▶ **Leere Knoten** sind erlaubt. Sie erlauben Aussagen über eine Entität ohne diese konkret zu benennen.

## URIs

```
URI = scheme:[//authority]path[?query] [#fragment]
authority = [userinfo@]host[:port]
```

- ▶ URIs dienen dazu, Ressourcen **eindeutig zu benamen**.
- ▶ URIs können sich auf **Webdokumente** beziehen (*d.h., auch URLs sind URIs!*), müssen aber nicht!





## Properties

- ▶ Eine Ressource wird durch **Property-Wert-Paare** beschrieben
- ▶ Die Property ist eine **binäre Relation** zwischen der Ressource und dem Wert.

## Literale

- ▶ Literale dienen zur Repräsentation von **Datenwerten**
- ▶ Sie werden als **Zeichenketten** dargestellt (z.B. ‘‘42’’), die zusätzlich **getypt** sein können (‘‘42’’<sup>integer</sup>).

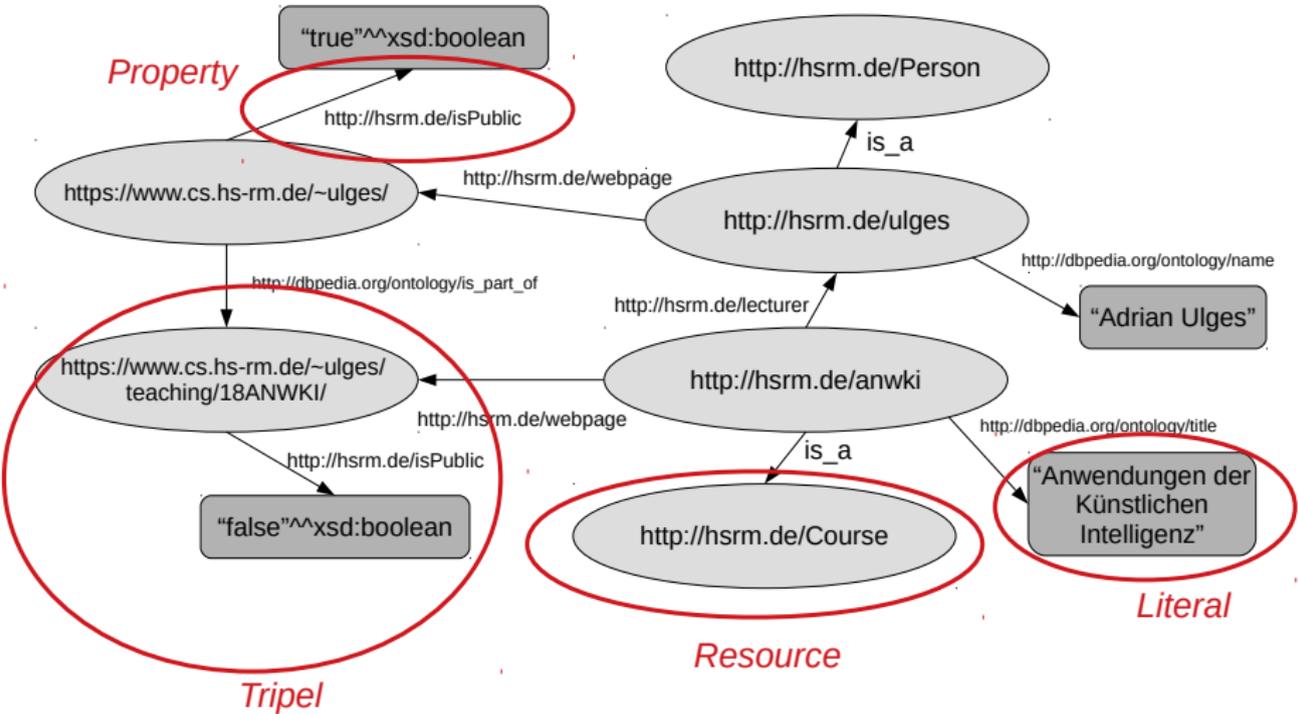
## Statements

- ▶ Ein Statement ist ein **Triple**:

(Subjekt, Prädikat, Objekt)

- ▶ Das **Subjekt** ist eine URI oder ein leerer Knoten
- ▶ Das **Prädikat** (*oder Property*) ist eine URI
- ▶ Das **Objekt** ist eine URI / ein leerer Knoten / ein **Literal**.

# Grundlagen: RDF





# Die Turtle-Syntax

- ▶ Um Wissensgraphen zu **serialisieren**, **auszutauschen** und zu **verarbeiten** ist eine **Standardsyntax** erforderlich.
- ▶ Häufig wird hier **XML** verwendet, eine kompakte Alternative bietet **Turtle** (*“Terse RDF Triple Language”*).
- ▶ Turtle – bzw. eine Variante – wird auch von der **Anfragesprache SPARQL** (*später*) verwendet.

## Turtle: Grundlagen

- ▶ Tripel werden **nacheinander aufgelistet** (Trennung mit “.”).
- ▶ URIs in **spitzen Klammern**, Literale in Anführungszeichen.
- ▶ Leerzeichen+Umbrüche außerhalb Bezeichnern ignorieren.

```
<http://dbpedia.org/resource/Germany>
  <http://dbpedia.org/ontology/areaTotal> “357168.0” .
<http://dbpedia.org/resource/Germany>
  <owl:sameAs> <http://www.wikidata.org/wiki/Q183> .
<http://www.wikidata.org/wiki/Q183>
  <https://www.wikidata.org/wiki/Property:P38>
  <https://www.wikidata.org/wiki/Q4916> .
(im Klartext: <Germany> <currency> <Euro> .)
```

# Die Turtle-Syntax (cont'd)



## Wir können Abkürzungen für Präfixe festlegen

```
@prefix dbr: <http://dbpedia.org/resource/>
```

```
@prefix dbo: <http://dbpedia.org/ontology/>
```

```
dbr:Germany dbo:areaTotal ‘‘357168.0’’ .
```

## Tripel mit gleichem Subjekt zusammenfassen: ';'

```
dbr:Germany dbo:wineRegion dbr:Riesling .
```

```
dbr:Germany dbo:assembly dbr:BMW_i8 .
```

```
entspricht
```

```
dbr:Germany dbo:wineRegion dbr:Riesling ; dbo:assembly dbr:BMW_i8 .
```

## Tripel mit gleichem Subjekt+Prädikat zusammenfassen: ','

```
dbr:Germany dbo:wineRegion dbr:Riesling, dbr:Scheurebe, dbr:Dornfelder ;  
    dbo:assembly dbr:BMW_i8 .
```

# Turtle: Getypte Literale



Literale werden generell in Anführungsstrichen angegeben.  
Sie können **getypt** sein!

## Literale

- ▶ Strings (Typ `xsd:string`): `‘‘plain string’’`
- ▶ Strings können in verschiedenen **Sprachen** angegeben sein:  
`‘‘string with language’’@en`
- ▶ Integers (Typ `tt xsd:integer`): `‘‘13.4’’^^xsd:integer`
- ▶ Boolean: `‘‘true’’^^xsd:boolean`



1. Grundlagen: RDF und Turtle

2. DBPedia

3. SPARQL

4. Kritik



```
{{Infobox_Town_AT |
name = Innsbruck |
image_coa = InnsbruckWappen.png |
image_map = Karte-tirol-1.png |
state = [[Tyrol]] |
regionk = {{{statutory city}}} |
population = 117,342 |
population_as_of = 2006 |
pop_dens = 1,119 |
area = 104.91 |
elevation = 574 |
lat_deg = 47 |
lat_min = 16 |
lat_sec = N |
lon_deg = 11 |
lon_min = 23 |
lon_sec = E |
postal_code = 6010-6080 |
area_code = 0512 |
licence = I |
mayor = Hilde Zach |
website = [http://innsbruck.at]
}}
```



## Bsp.: Deutsche Musiker die in Berlin geboren wurden

PREFIX dbo: <<http://dbpedia.org/ontology/>>

```
SELECT ?name ?birth ?description ?person WHERE {
  ?person dbo:birthPlace :Berlin .
  ?person <http://purl.org/dc/terms/subject>
  <http://dbpedia.org/resource/Category:German\_musicians> .
  ?person dbo:birthDate ?birth .
  ?person foaf:name ?name .
  ?person rdfs:comment ?description .
  FILTER (LANG(?description) = 'en') .
}
ORDER BY ?name
```

- ▶ Initiative der Uni Leipzig, der Freien Universität Berlin und der Firma OpenLink Software
- ▶ **Regelbasierte Extraktion** formaler semantischer Daten aus **Wikipedia-Infoboxen**
- ▶ **Lizenz:** Creative Commons 3.0 and GNU
- ▶ Deckt **viele Domänen** ab → Mächtige Breite an  
Beispiel-Fragen: “Nenne Städte mit mehr als 100,000 Einwohnern in New Jersey”, “Nenne italienische Musiker des 18. Jahrhunderts”.



## Umfang<sup>2</sup>

- ▶ 125 Sprachen, **38.3 Mio. Entitäten** und **3 Mrd. Tripel**.
- ▶ **Englisch: 4.5 Mio. Entitäten** und **580 Mio. Tripel**.

# Personen	1.450.000	# Orte	735.000
# Filme,Songs,...	411.000	# Organisationen	241.000
# Spezies	251.000	# Krankheiten	6.000

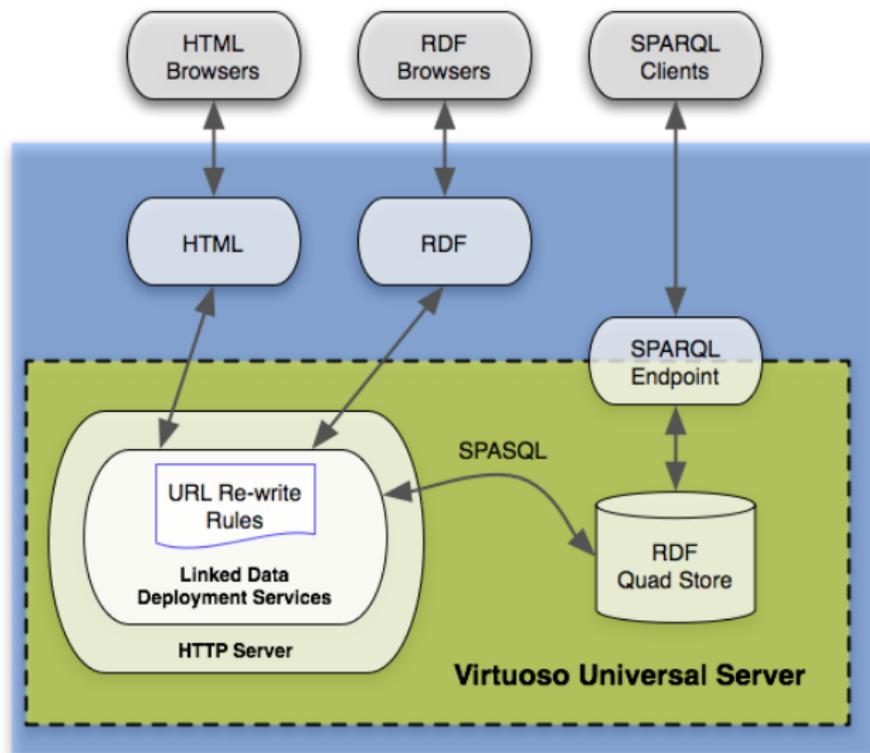
## Vernetzung

- ▶ DBPedia ist eng **vernetzt** mit vielen anderen Ontologien (*ca. 50 mio. Tripeln zu anderen Ontologien*), und kann deshalb als eine Art **zentraler Hub** der LOD-Cloud verstanden werden.

---

<sup>2</sup><https://wiki.dbpedia.org/about>

# Zugang zu DBPedia



# Zugang zu DBPedia



## 1. Zugang per Browser

Germany (/ˈdʒɜːrməni/; German: Deutschland, pronounced [ˈdɔʏtʃlant]), officially the Federal Republic of Germany (German: Bundesrepublik Deutschland, ), is a federal parliamentary republic in central-western Europe. It includes 16 constituent states, covers an area of 357,021 square kilometres (137,847 sq mi), and has a largely temperate seasonal climate. With about 82 million inhabitants, Germany is the most populous member state of the European Union. After the United States, it is the second most popular immigration destination in the world. Germany's capital and largest metropolis is Berlin. Major urban areas include Ruhr, Hamburg, Munich, Cologne, Frankfurt and Stuttgart.

Property	Value
<span>dbpedia:PopulatedPlace/areaTotal</span>	<ul style="list-style-type: none"><li>357022.0910454866</li><li>357168.0</li></ul>
<span>dbpedia:PopulatedPlace/populationDensity</span>	<ul style="list-style-type: none"><li>225.09755843024595</li><li>227.0</li></ul>

## 2. Zugang per SPARQL

- ▶ Öffentlich zugänglicher Endpoint:  
<https://dbpedia.org/sparql>



1. Grundlagen: RDF und Turtle

2. DBPedia

3. SPARQL

4. Kritik

# SPARQL (*sprich engl. "sparkle"*)<sup>3</sup>



- ▶ ... steht für **SPARQL Protocol and RDF Query Language** (*rekursive Namensdefinition*).
- ▶ ... ist eine **Anfragesprache** zur Abfrage von Entitäten aus **RDF-Dokumenten**.
- ▶ seit 2013 W3C Recommendation.

## Die SPARQL-Spezifikation enthält...

1. Die Anfragesprache (*Thema dieser Vorlesung*)
2. Das Ergebnisformat (*in XML*)
3. Das Protokoll (*Übermittlung von Anfrage und Ergebnissen*)

---

<sup>3</sup><https://www.w3.org/TR/sparql11-overview/>

# SPARQL: Einfache Beispiel-Anfrage



```
1 SELECT ?title ?author
2 WHERE {
3   ?buch ?r <http://sp.com/Verl> .
4   ?buch <http://example/org/titel> ?titel .
5   ?buch <http://example/org/autor> ?author .
6 }
```

- ▶ **WHERE: Anfragemuster** von **Tripeln** in Turtle-Syntax  
(*Lösungen müssen auf alle Tripel passen*)
- ▶ **Variablen** ?title, ?buch, ?r, ?author
- ▶ Optional Schlüsselwort **PREFIX**: Definiert Abkürzungen,  
die im Query verwendet werden können  
(<http://example/org/titel> → ex:titel)

```
1 PREFIX ex: <http://example/org>
2 PREFIX mylibrary: <http://mylibrary.org>
3 SELECT ?title ?author
4 WHERE {
5   ?buch ex:verleger <http://springer.com/Verlag> .
6   ?buch mylibrary:titel ?titel .
7   ?buch ex:autor ?author .
8 }
```

# SPARQL: Einfache Beispiel-Anfrage



Ergebnis der Anfrage: **Tabelle** mit einer Zeile je Ergebnis

title	author
Pattern Recognition and Machine Learning	Chris Bishop
Understanding Cryptography	Christof Paar
Computer Vision	Richard Szeliski
Real-Time C++	Christopher Kormanyos

## Syntax

- ▶ TURTLE-Abkürzungen mit ',' sind zulässig:

```
?p ?rel ?q . ?p ?rel2 ?q2
```

entspricht

```
?p ?rel ?q ; ?rel2 ?q2
```

- ▶ Statt ?variable können wir auch \$variable schreiben.



```
1 PREFIX dbo: <http://dbpedia.org/ontology/>
2 PREFIX dbr: <http://dbpedia.org/resource/>
3 SELECT ?city
4 {
5   ?city a dbo:City .
6   ?city dbo:country dbr:Germany
7 }
```

## Abkürzungen

- ▶ <http://dbpedia.org/ontology> (dbo:)  
**Klassen, Relationen** (TBox): dbo:City, dbo:country ...
- ▶ <http://dbpedia.org/property> (dbp:)  
**Weitere Properties:** dbp:north ...
- ▶ <http://dbpedia.org/resource> (dbr:)  
**Konkrete Dinge** (ABox): dbr:India ...

city
<a href="http://dbpedia.org/resource/Haaren_(Aachen)">http://dbpedia.org/resource/Haaren_(Aachen)</a>
<a href="http://dbpedia.org/resource/Albstadt">http://dbpedia.org/resource/Albstadt</a>
<a href="http://dbpedia.org/resource/Mücheln">http://dbpedia.org/resource/Mücheln</a>
<a href="http://dbpedia.org/resource/Eppelheim">http://dbpedia.org/resource/Eppelheim</a>

# SPARQL aus Python



```
1 from SPARQLWrapper import SPARQLWrapper, JSON
2
3 sparql = SPARQLWrapper("http://dbpedia.org/sparql")
4 sparql.setQuery("""
5     PREFIX dbo: <http://dbpedia.org/ontology/>
6     PREFIX dbr: <http://dbpedia.org/resource/>
7     SELECT ?city
8     {
9         ?city a dbo:City .
10        ?city dbo:country dbr:Germany
11    }
12    """)
13
14 sparql.setReturnFormat(JSON)
15 results = sparql.query().convert()
16
17 for result in results['results']['bindings']:
18     print(result['city']['value'])
19
20 # http://dbpedia.org/resource/Haaren_(Aachen)
21 # http://dbpedia.org/resource/Albstadt
22 # http://dbpedia.org/resource/Muecheln
23 # http://dbpedia.org/resource/Eppelheim
24 # ...
```

## Do-SPARQL-Yourself



Finde Staatschefs in DBPedia, die nicht in dem von ihnen regierten Land geboren sind.



- ▶ Viele Anfragen sind auch mit komplexen Graph-Mustern alleine **nicht möglich**.
- ▶ **Lösungsmechanismus: Filter.**

*Welche Personen sind zwischen 18 und 23 Jahren alt?  
Der Nachname welcher Person enthält einen Bindestrich?  
Welche Texte in Deutscher Sprache gibt es?*

## Filter-Beispiel

```
PREFIX ex: <http://example.org/>
SELECT ?buch WHERE {
    ?buch ex:verleger <http://springer.com/Verlag>
    ?buch ex:preis ?preis
    FILTER (?preis < 35) }
```

- ▶ Schlüsselwort FILTER, gefolgt von Bedingung in Klammern.
- ▶ FILTER und Tripel in beliebiger Reihenfolge.



- ▶ **Arithmetische Operatoren** (+, -, \*, /)

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

- ▶ **Vergleiche** (<, <=, =, >=, >, !=)

(Ordnung für String, DateTime, Boolean ist die jeweils natürlichen Reihenfolge, ansonsten nur =, != verfügbar).

- ▶ **Logische Verknüpfung** von Bedingungen (&&, ||, !)

- ▶ **Anmerkung:** Konjunktion entspricht der Angabe mehrerer Filter, Disjunktion Filtern in verschiedenen Mustern.

## Beispiel: Vor 1953 geborene Deutsche Staatschefs

```
1 PREFIX dbo: <http://dbpedia.org/ontology/>
2 PREFIX dbr: <http://dbpedia.org/resource/>
3 SELECT ?person ?date
4 {
5   ?country a dbo:Country .
6   ?country dbo:leader ?person .
7   ?person dbo:birthDate ?date .
8   FILTER (?country = dbr:Germany && ?date < "1953-00-00T00
9     :00:00+00:00"^^xsd:dateTime)
```

## Filter in SPARQL: Operatoren (cont'd)



SPARQL unterstützt weitere **RDF-spezifischer Operatoren**

BOUND(A)	wahr gdw. A eine gebundene Variable ist
isURI(A)	wahr gdw. A eine URI ist
isLITERAL(A)	wahr gdw. A ein RDF-Literal ist
STR(A)	lexikalische Darstellung (xsd:string) von URIs+Literalen
LANG(A)	Sprachcode eines RDF-Literals (z.B. 'en') oder leerer String (falls kein Sprachcode vorhanden)
DATATYPE(A)	Datentyp-URI eines RDF-Literals, hilfsweise xsd:string
LANGMATCHES(A,B)	wahr gdw. die Sprachangabe von A auf das Muster B passt
REGEX(A,B)	wahr gdw. in der Zeichenkette A der reguläre Ausdruck B gefunden wird.



## Deutschsprachige Buchrezensionen

```
1 PREFIX ex: <http://example.org/>
2 SELECT ?buch
3 WHERE {
4     ?buch ex:rezension ?text .
5     FILTER LANGMATCHES( LANG(?text), "de" )
6 }
```

Einfache Graph-Muster können durch { ... } **gruppiert** werden.  
Dies bewirkt erstmal *nichts*, sondern nur unter Verwendung  
zusätzlicher Konstrukte wie UNION oder OPTIONAL.

## Beispiel

```
1 WHERE {  
2   ?buch ex:verleger <http://springer.com/verlag> .  
3   ?buch ex:titel ?titel .  
4   ?buch ex:autor ?autor .  
5 }
```

... ist äquivalent zu ...

```
1 WHERE {  
2   { ?buch ex:verleger <http://springer.com/verlag> .  
3     ?buch ex:titel ?titel . }  
4   ?buch ex:autor ?autor .  
5 }
```

# SPARQL: Vereinigung



Das Schlüsselwort UNION erlaubt die Angabe **alternativer Teile** eines Musters.

## Beispiel

- Finde Schauspieler **oder** Regisseure **oder** Producer von "Interstellar".

```
1 PREFIX interstellar:
2   <http://dbpedia.org/resource/Interstellar_(film)>
3 SELECT ?p
4 {
5   { interstellar: dbo:director ?p . } UNION
6   { interstellar: dbo:starring ?p . } UNION
7   { interstellar: dbo:producers ?p . }
8 }
```

# SPARQL: Optionale Teil-Patterns



Das Schlüsselwort **OPTIONAL** erlaubt die Angabe **optionaler Teile** eines Musters.

## Beispiel

Finde Staatschefs und – **soweit bekannt** – ihre Geburtsorte.

```
1 PREFIX dbo: <http://dbpedia.org/ontology/>
2 PREFIX dbr: <http://dbpedia.org/resource/>
3 SELECT ?person ?place
4 {
5   ?country a dbo:Country .
6   ?country dbo:leader ?person .
7   OPTIONAL { ?person dbo:birthPlace ?place }
8 }
```

person	place
<a href="http://dbpedia.org/resource/Alok_Sharma">http://dbpedia.org/resource/Alok_Sharma</a>	<a href="http://dbpedia.org/resource/India">http://dbpedia.org/resource/India</a>
<a href="http://dbpedia.org/resource/Barack_Obama">http://dbpedia.org/resource/Barack_Obama</a>	<a href="http://dbpedia.org/resource/Hawaii">http://dbpedia.org/resource/Hawaii</a>
<a href="http://dbpedia.org/resource/Barack_Obama">http://dbpedia.org/resource/Barack_Obama</a>	<a href="http://dbpedia.org/resource/Honolulu">http://dbpedia.org/resource/Honolulu</a>
<a href="http://dbpedia.org/resource/Ali_Al-Daqbaashi">http://dbpedia.org/resource/Ali_Al-Daqbaashi</a>	
<a href="http://dbpedia.org/resource/Britt_Bohlin_Olsson">http://dbpedia.org/resource/Britt_Bohlin_Olsson</a>	
<a href="http://dbpedia.org/resource/Guðbjartur_Hannesson">http://dbpedia.org/resource/Guðbjartur_Hannesson</a>	
<a href="http://dbpedia.org/resource/Höskuldur_Pórhallsson">http://dbpedia.org/resource/Höskuldur_Pórhallsson</a>	
<a href="http://dbpedia.org/resource/Vladimir_Putin">http://dbpedia.org/resource/Vladimir_Putin</a>	<a href="http://dbpedia.org/resource/Soviet_Union">http://dbpedia.org/resource/Soviet_Union</a>
<a href="http://dbpedia.org/resource/Vladimir_Putin">http://dbpedia.org/resource/Vladimir_Putin</a>	<a href="http://dbpedia.org/resource/Saint_Petersburg">http://dbpedia.org/resource/Saint_Petersburg</a>



## Sortierung von Ergebnissen mit Schlüsselphrase ORDER BY

```
1 SELECT ?buch, ?preis
2 WHERE {
3   ?buch <http://example.org/preis> ?preis .
4 }
5 ORDER BY ?preis
```

- ▶ Sortierung wie bei Filter-Vergleichsoperatoren, Sortierung von URIs alphabetisch als Zeichenketten
- ▶ Reihenfolge **unterschiedlicher Arten** von Elementen:  
Ungebundene Variable < leere Knoten < URIs < RDF-Literale.
- ▶ Weitere mögliche Angaben
  - ▶ ORDER BY DESC (?preis): absteigend
  - ▶ ORDER BY ASC (?preis): aufsteigend (=Default-Verhalten)
  - ▶ ORDER BY DESC(?preis), ?titel: Hierarchische Kriterien

# SPARQL: LIMIT, OFFSET, DISTINCT



## LIMIT

- ▶ Beschränke die maximale Anzahl gelieferter Treffer
- ▶ **Sehr nützlich**, insbesondere aus **Performance-Gründen!**

## OFFSET

- ▶ Position des **ersten** gelieferten Ergebnisses
- ▶ Ermöglicht in Kombination mit LIMIT und ORDER BY ein **Paging** durch die Ergebnisse.

## SELECT DISTINCT

- ▶ entfernt Mehrfach-Treffer.

```
1 SELECT DISTINCT ?buch
2 WHERE {
3   ?buch <http://example.org/preis> ?preis .
4 }
5 ORDER BY ?preis
6 LIMIT 5
7 OFFSET 25
```



Um Knoten/Relationen zu finden (z.B. wenn in einer Frage 'Angela Merkel' erwähnt wird) bieten **Triple Stores** (z.B. *Virtuoso*) eine **Volltext-Indexierung** mit verschiedenen Abfragemöglichkeiten:

## Exakter Match, z.B. über `rdfs:label`

```
1 SELECT ?person
2 {
3   ?person rdfs:label "Angela Merkel"@de }
```

## Per Regexp-Filter

```
1 SELECT ?x
2 {
3   ?x rdfs:label ?label .
4   FILTER( regex(?label, "Angela") ) }
```

## Spezieller Operator `bif:contains`<sup>4</sup>

```
1 SELECT ?x
2 {
3   ?x rdfs:label ?label .
4   ?label bif:contains "'Angela '" . }
```

---

<sup>4</sup><http://docs.openlinksw.com/virtuoso/rdfsparqlrulefulltext/>

# SPARQL: Typmatching von Literalen



**Achtung:** Beim Matching von Literalen ist eine **genaue Übereinstimmung** des **Datentyps** gefordert!

## Beispiel

```
?entity1 ex:name 'Bob' .  
?entity2 ex:name 'Bob'^^xsd:string .  
?entity3 ex:name 'Bob'@en .  
?entity4 ex:age '42'^^xsd:integer .
```

- ▶ Im Beispiel liefert die Anfrage { ?x ex:name 'Bob' } **nur** entity1, d.h. es wird z.B. unterschieden zwischen Strings und Strings mit Sprach-Tags.

## Ausnahmen

- ▶ Abkürzungen für Zahlenwerte sind möglich

```
{ ?x ex:age 42 . } → klappt ✓
```

- ▶ Der Datentyp wird hierbei aus der syntaktischen Form des Literals bestimmt (z.B. xsd:integer vs. xsd:double).

# SPARQL: Vorgestellte Features im Überblick



## Grundstruktur

PREFIX

WHERE

## Ausgabeformate

SELECT

CONSTRUCT

ASK

DESCRIBE

## Graph-Muster

Einfache Graph-Muster

{...}

OPTIONAL

UNION

## Filter

BOUND

isURI

isBLANK

isLITERAL

STR

LANG

DATATYPE

sameTERM

langMATCHES

REGEX

## Modifikatoren

ORDER BY

LIMIT

OFFSET

DISTINCT



1. Grundlagen: RDF und Turtle

2. DBPedia

3. SPARQL

4. Kritik



Kritiker der “Semantic Web” - Strömung führen u.a. folgende Argumente an<sup>5</sup>:

- ▶ **People are lazy**: Erheblicher Annotationsaufwand (z.B. **Verdoppelung** des Aufwands für die Content-Erstellung). User sind **Opportunisten!**
- ▶ Insbesondere die Erfassung von **common sense knowledge** ist extrem aufwändig (*“Wenn’s regnet, ist die Wiese nass”*).
- ▶ **People are stupid**: Qualität / Genauigkeit / Korrektheit der Metadaten oft fragwürdig. Insbesondere keine Methodik zur Beurteilung der **Signifikanz** von Fakten.

```
dbr:Germany dbo:leader dbr:Angela_Merkel .  
dbr:Germany dbo:leader dbr:Andreas_Voßkuhle .
```

- ▶ **People lie**: SPAM-Problematik, Kampf um Meinungshoheit.

---

<sup>5</sup>C. Doctorov (2001): “Metacrap: Putting the Torch to seven Straw-men of the Meta-Utopia”



## Limitierte Verbreitung

- ▶ Die Vision des **offenen, standardisierten, geteilten** Semantic Web (*siehe oben*) hat sich **bisher noch nicht durchgesetzt**.
- ▶ Tendenz zu **geschlossenen, proprietären** Ökosystemen (Facebook, Amazon, Google, ...).

*“ The semantic web idea [...] has turned out to be the opposite of what Tim Berners-Lee anticipated in the early 1990s. [...] TBL hoped for a giant **structured open web**. What we got first was a bunch of **closed structured webs** and a **mixed web** that still isn't very well structured. The open part of the web lives on, but isn't where most web users dwell nowadays.”*

(Daniel Lemire. *When bad ideas will not die: from classical AI to Linked Data* (2014))

*Ten years go by and **hardly anything** (outside academic conferences) comes out of this Semantic Web. Tens of thousands of research papers get written. Hardly anyone ever uses any of the technology produced [...]. Not to worry, Berners-Lee **rebrands** whatever remains as 'Linked Data'.*

*Semantics are not going away though you may not always recognize its offspring ... it's in the background as a proud parent.*