

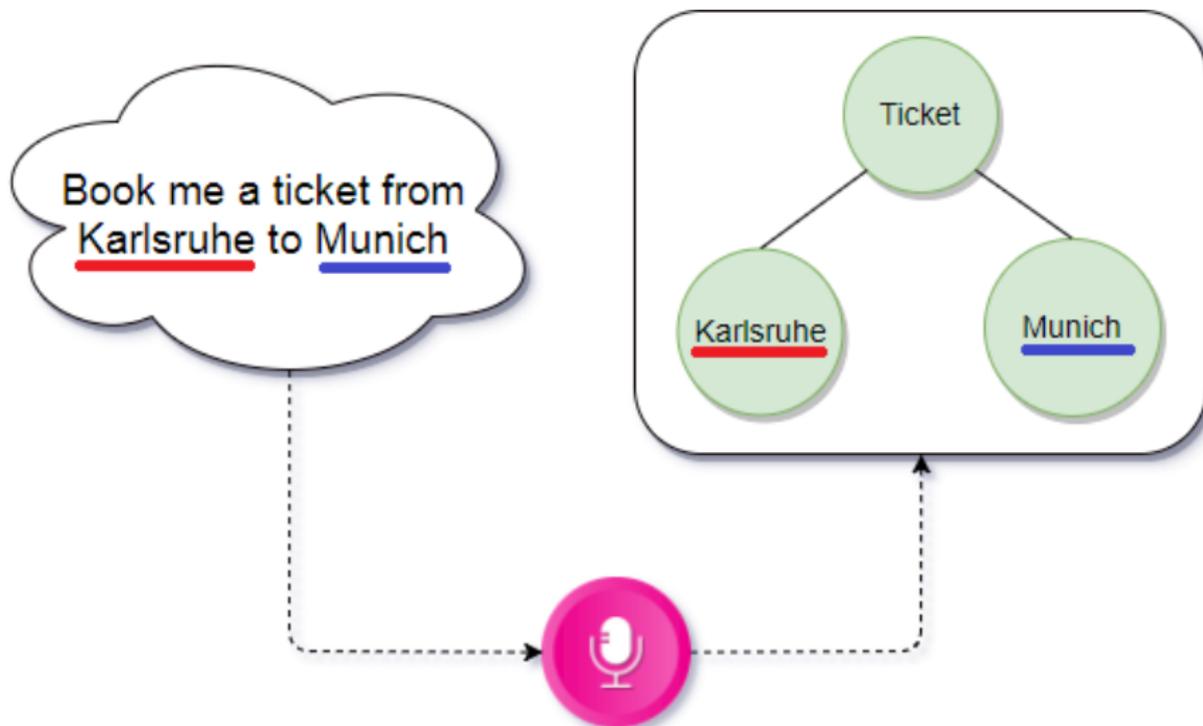
Bachelorarbeit: Wissensbasierte Identifikation von Wertebereichen einer aktiven Ontologie

Yauhen Makhotsin, betreut von Martin Blersch

IPD Tichy, Fakultät für Informatik



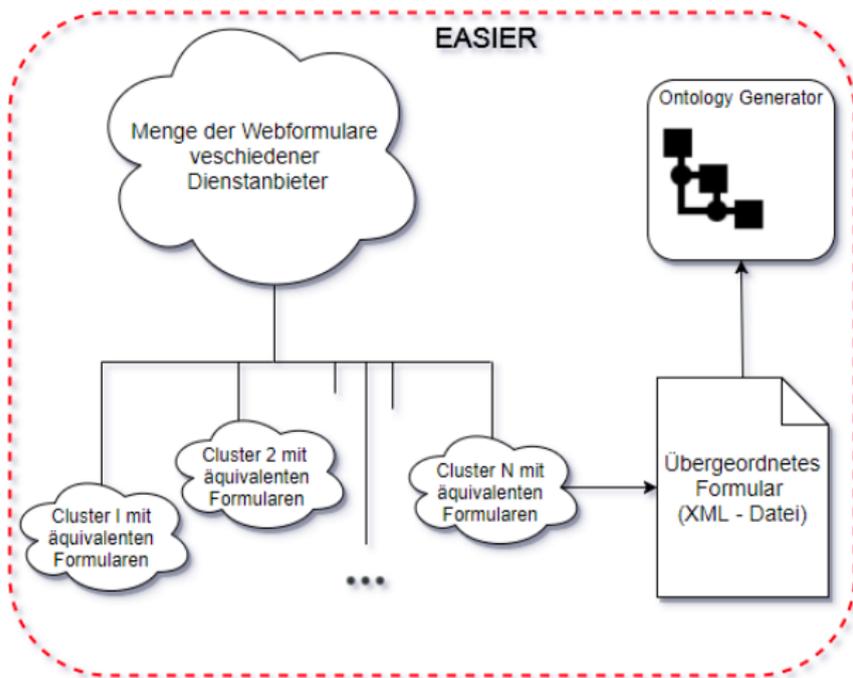
Motivation

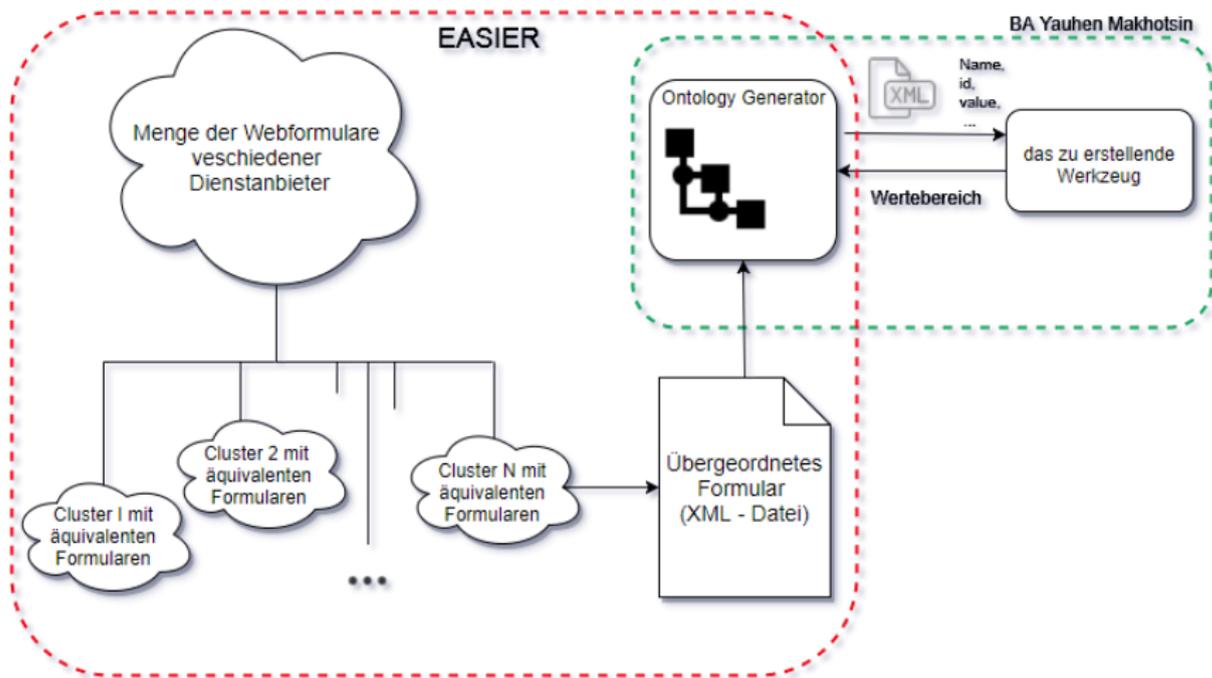






Book me a ticket to **New York**





Unsupervised Domain Ontology Learning from Text [Gee17]

- Suche nach Textkorpora
- Extraktion von Termen
- Extraktion von taxonomischen Relationen
- Extraktion von nicht taxonomischen Relationen
- Ontologieerstellung

Erkennung von Hyperonymie:

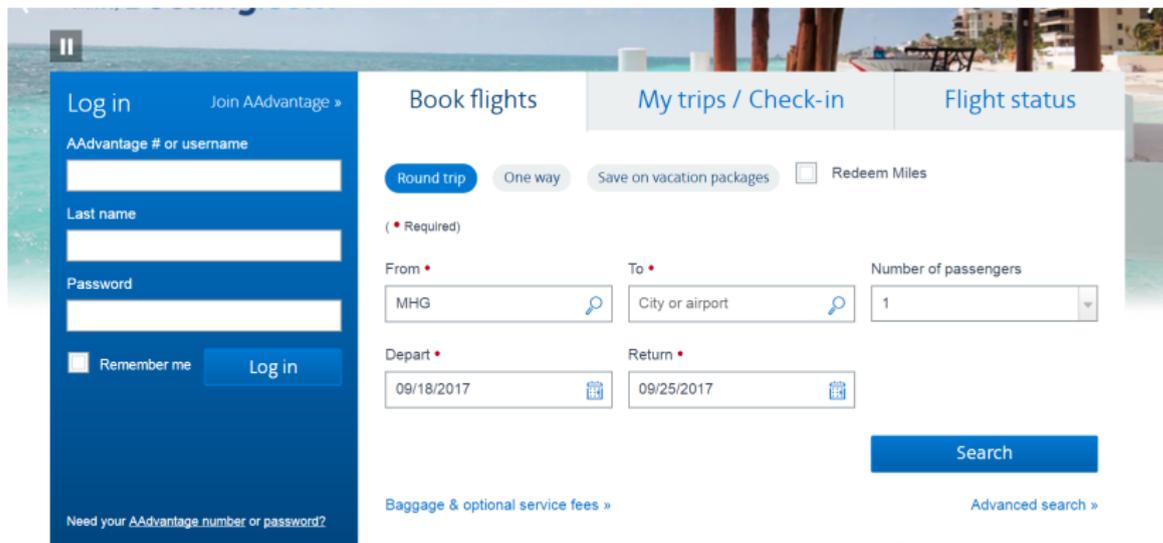
- Bedingungen:
 - **t0** Suffix von **t1**
 - beide Domänenterme
- Folgerung:
 - **t0** Oberbegriff von **t1**
- Beispiel:
 - “polysacharide” Oberbegriff von “homopolysacharide”

Erkennung von Hyperonymie:

- Bedingungen:
 - **t0** ist Kopfterm von **t1**
 - einer ist Domänenterm
- Folgerung:
 - **t0** Oberbegriff von **t1**
- Beispiel:
 - “corn” Oberbegriff von “sweet corn”

Building a Domain Knowledge Base from Wikipedia: a Semi-supervised Approach [**Chen2016BuildingAD**]

- Entdeckung der Domänenkonzepte
 - Auswahl der domänenrelevanten Hashtags von Stackoverflow
 - Vorbereitung der Hashtags
 - Abbildung auf Artikel in Wikipedia
 - Entdeckung weitere Konzepte mithilfe der Kategorien in Wikipedia
- Entdeckung der Relationen
 - Durch semantische Verarbeitung
 - Falls ein Artikel einer Kategorie gehört und beide als Konzepte erkannt, wird eine “subclass of” - Relation erstellt.



The screenshot shows a flight booking interface with a blue header and a white main content area. The header contains a 'Log in' section on the left and navigation tabs for 'Book flights', 'My trips / Check-in', and 'Flight status'. The 'Book flights' section includes options for 'Round trip' (selected), 'One way', and 'Save on vacation packages', along with a 'Redeem Miles' checkbox. Below these are fields for 'From' (MHG), 'To' (City or airport), and 'Number of passengers' (1). There are also 'Depart' (09/18/2017) and 'Return' (09/25/2017) date pickers. A large blue 'Search' button is positioned below the form. At the bottom of the search area, there are links for 'Baggage & optional service fees »' and 'Advanced search »'. A 'Feedback' button is located on the right side of the page.

Log in [Join AAdvantage »](#)

AAdvantage # or username

Last name

Password

Remember me

Need your AAdvantage number or password?

Book flights | My trips / Check-in | Flight status

Round trip | One way | Save on vacation packages | Redeem Miles

(* Required)

From •

To •

Number of passengers ▼

Depart •

Return •

[Baggage & optional service fees »](#) [Advanced search »](#)

Feedback

```
<input type="text" name="originAirport" value="MHG" id="
reservationFlightSearchForm.originAirport" class="
aaAutoComplete" placeholder="City or airport" >
```

```
<input type="text" name="originAirport" value="MHG" id="
reservationFlightSearchForm.originAirport" class="
aaAutoComplete" placeholder="City or airport" >
```

```
<input type="text" name="originAirport" value="MHG" id="
reservationFlightSearchForm.originAirport" class="
aaAutoComplete" placeholder="City or airport" >
```

```
<input type="text" name="originAirport" value="MHG" id="
reservationFlightSearchForm.originAirport" class="
aaAutoComplete" placeholder="City or airport" >
```

```
<input type="text" name="originAirport" value="MHG" id="
reservationFlightSearchForm.originAirport" class="
aaAutoComplete" placeholder="City or airport" >
```

- Im Formular enthalten:

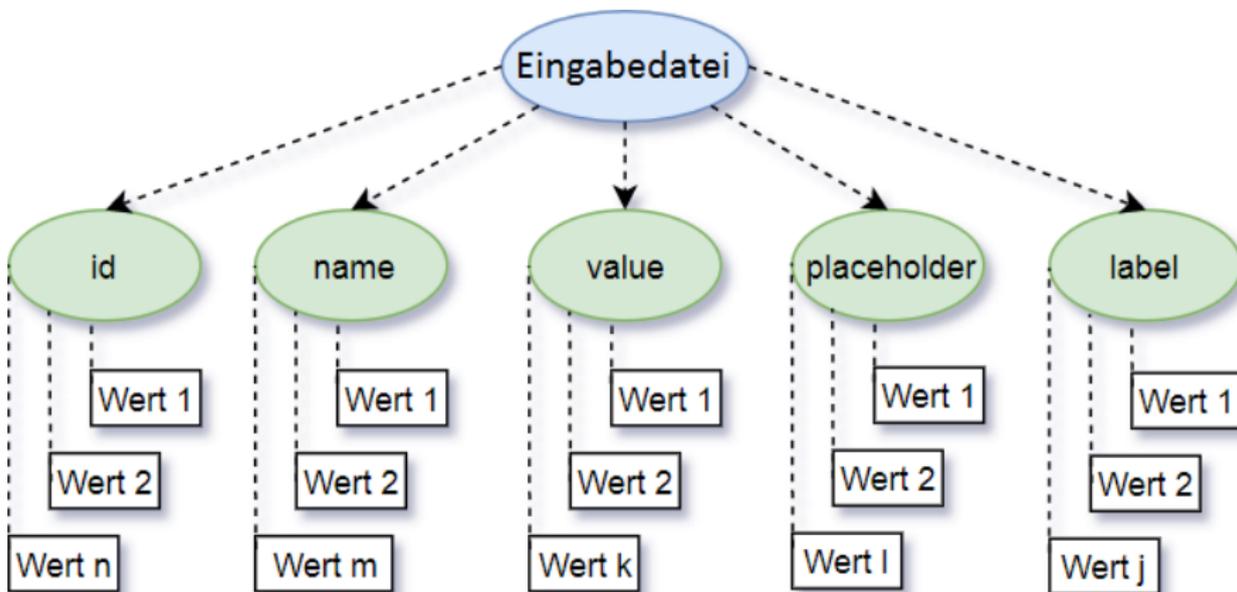
- 1 Oberbegriffe: **City**, **Airport**
- 2 Domänenwert: **MHG**

- Zu untersuchen:

- 1 Welche Unterbegriffe von **City** und **Airport** gibt es?
- 2 Was ist **MHG**?
- 3 Welche ähnliche Begriffe zu **MHG** gibt es?

Identifikation der Domäne:

- 1 Klassifikation der übermittelten Attributwerte in mögliche Oberbegriffe und Domänenwerte
- 2 Filterung der resultierenden Listen
- 3 Befragung der externen Datenquellen
- 4 Konsolidierung der Ergebnisse



Klassifizierung der Attributwerte:

- Klasse von der Attributart abhängig
- Zuweisung einer Bewertung
- Beispiel
 - Der Wert des Labels ist ein **Oberbegriff**
 - Der Wert des Elements **value** ist entweder ein **Oberbegriff** oder ein **Domänenwert**

Tabelle: Wahrscheinlichkeiten des Auftretens der Oberbegriffe und Domänenwerte

Parameter	P(Oberbegriff)	P(Domänenwert)	P(irrelevant)
label	0.4	0	0,6
value	0.25	0.75	0
placeholder	0.46	0.08	0,46
name	0.35	0	0,65
id	0.43	0	0,57

Präfixe:

- Suche nach Präfixen
- Das Präfix wird gelöscht
- Der Wert wird in die richtige Liste verschoben
- Bewertung erhöhen
- Beispiel:
 - “Enter the city” —> “city” ist ein Oberbegriff
 - “Example: Mannheim” —> “Mannheim” ist ein Domänenwert

Aufteilung in Teilbegriffe:

- Nach Großschreibung. Z.B:
 - originCity —> {origin, city, origin city}
 - airportName —> {airport, name, airport name}
- Nach Trennzeichen. Z.B:
 - desired location —> {desired, location, desired location}
 - arrival_time —> {arrival, time, arrival time}
- Abschließende Entfernung der Stoppwörter wie:
 - Attributnamen (z.B. Label, Placeholder, ID usw)
 - Artikel

Lexikalische Analyse:

- Eigennamen ermitteln
- Substantive ermitteln
- Zusammensetzungen mit Substantiven ermitteln
- Rest löschen

Verarbeitung der Eingabe

Ergebnis:

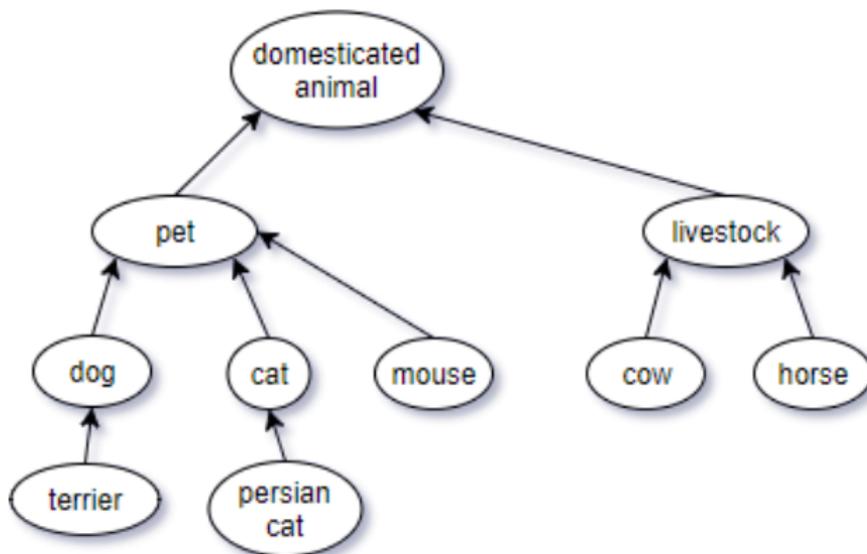
- Liste der möglichen Oberbegriffe
- Liste der möglichen Domänenwerte

Befragung der externen Datenquellen

Befragte Datenquellen:

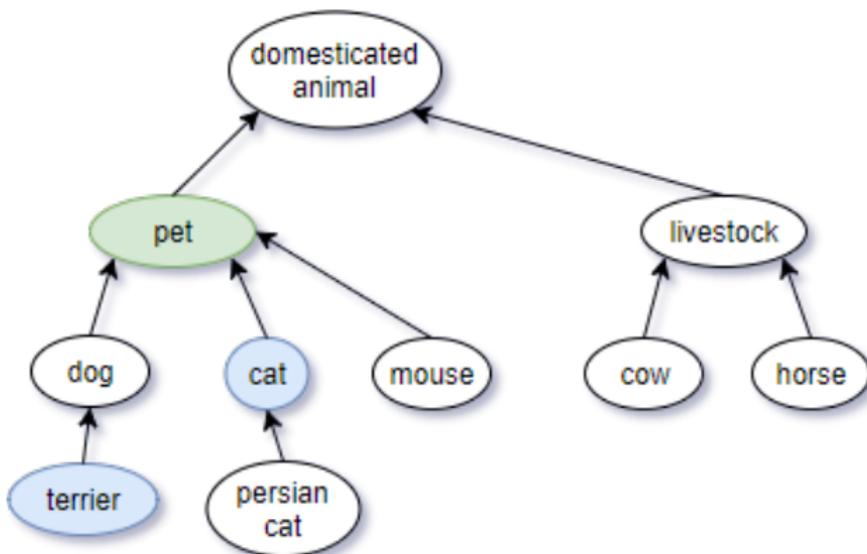
- WordNet
- Wikipedia
- ResearchCyc

WordNet:



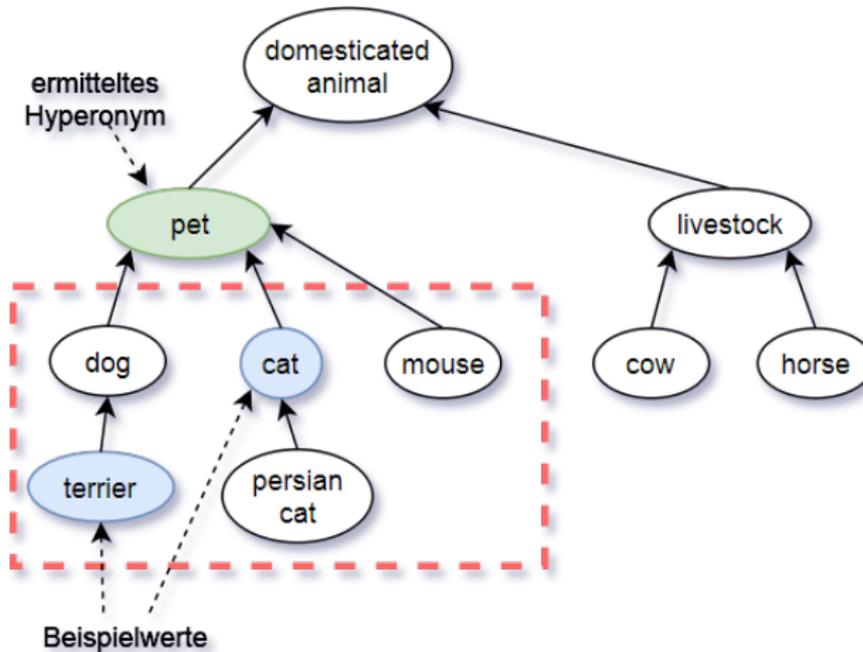
Befragung der externen Datenquellen

WordNet:



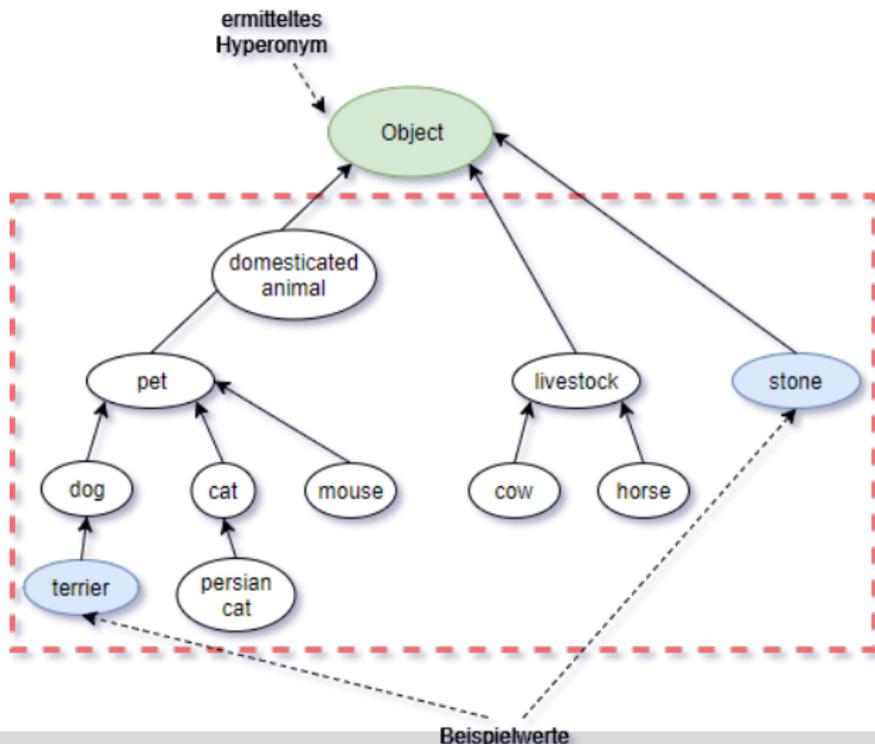
Befragung der externen Datenquellen

WordNet:



Befragung der externen Datenquellen

WordNet:



Semantische Ähnlichkeit (Similarity):

- Nur semantisch ähnliche Werte verwenden
- $\text{Similarity}(\text{Auto}, \text{Fahrrad}) > \text{Similarity}(\text{Auto}, \text{Baum})$
- Semantische Ähnlichkeit nach Wu-Palmer:

$$\text{Similarity} = 2 * \frac{\text{depth}(\text{kleinster gemeinsamer Oberbegriff})}{\text{depth}(\text{Konzept 1}) + \text{depth}(\text{Konzept 2})} \quad (1)$$

- Für jede zwei semantische Ähnliche Domänenwerte (z.B. **Berlin** und **Las Vegas**)
 - Kleinsten Oberbegriff ermitteln (**City**)
- Für jeden Wert in der Liste der Oberbegriffe (z.B. **City**):
 - Seine Kinder in die Liste der Domänenwerte aufnehmen (**Frankfurt, Moscow, Sydney** usw.)
 - Falls dieser Wert im ersten Schritt ermittelt wurde, werden seine Kinder bis zur Tiefe **n** ausgegeben.
 - **n** - Maximaler Abstand zwischen dem Oberbegriff und Domänenwerten

Befragung der externen Datenquellen

Wikipedia:



The screenshot shows the German Wikipedia article for 'Durlach'. Annotations include:

- Titel**: A red box around the word 'Durlach' in the article title.
- Text**: A red box around the first paragraph of the article.
- Hyperlink**: A red box around the link 'Landeshauptstadt' in the text.

Sources [edit]

(incomplete)

- Chisholm, Hugh, ed. (1911). "Durlach". *Encyclopædia Britannica* (11th ed.). Cambridge University Press. This work in turn cites:
 - Fecht, *Geschichte der Stadt Durlach* (Heidelberg, 1869)

Anderer Einträge in der Kategorie



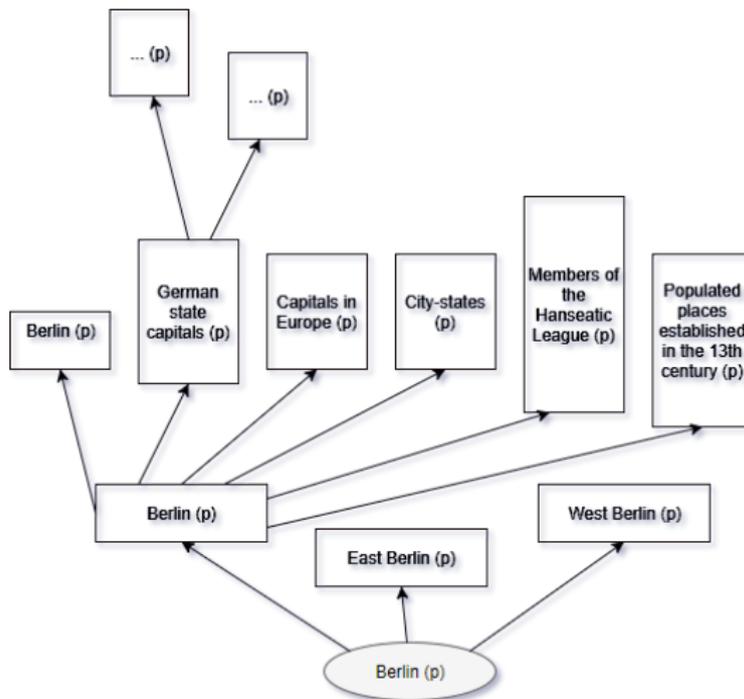
The screenshot shows the 'Boroughs of Karlsruhe (city)' category page. A red box highlights the category title and the list of boroughs: Beertheim-Bulach, Daxlanden, Durlach, Grötzingen, Grünwettersbach, Grünwinkel, Hagfeld, Höhenwettersbach, Innenstadt-Ost, Innenstadt-West, Knielingen, Mühlburg, Neureut, Nordstadt, Nordweststadt, Oberreit, Oststadt, Palmbach, Rintheim, Rippurt, Slupferich, Südstadt, Südweststadt, Waldstadt, Weherfeld-Dammerstock, Weststadt, Wolfartswaser.

Authority control WorldCat Identifiers · VAF: 140882507 · GND: 4070638-2 ⓘ

Categories: Towns in Baden-Württemberg Karlsruhe **Kategorien**

Befragung der externen Datenquellen

Wikipedia:



Befragung der externen Datenquellen

- Gefundener Artikel: “Moscow (city)”
- “(city)” ist ein bekannten Domänenwert
- “Moscow” aufnehmen und die Bewertung von Moscow erhöhen

ResearchCyc:

- **Ontologie des Allgemeinwissens**
- **Besteht aus Konzepten (Cyc-Konstanten)**
- **Regeln**
 - Student ist ein Mensch
- **Inferenzmaschine**
 - Fakt 1: Student ist ein Mensch
 - Fakt 2: Michael ist Student
 - Schlussfolgerung: Michael ist ein Mensch

Befragung von ResearchCyc:

- Für jeden möglichen Oberbegriff (z.B. **City**)
 - Abfragen, welche Konzepte dieser Oberbegriff sein können
 - Beispiel: Was kann ein City sein? Antwort: Berlin ist ein City, Moskau ist ein City usw.
- Für die bekannten Domänenwerte (z.B. **Frankfurt** und **Moskau**)
 - Abfragen, was sowohl **Frankfurt** als auch **Moskau** sind.
 - Antwort: Stadt, Megalopolis, Ort, geographische Entität.
 - Abfragen, welche Konzepte allen ermittelten Gruppen gehören:
 - In diesem Fall: Was noch gleichzeitig eine Stadt, Megalopolis, Ort und geographische Entität sind?
 - Antwort: **New York, Sydney, Philadelphia** usw.

Konsolidierung der Ergebnisse

- Zusammenführung der Domänenwerte in eine Liste
- Wenn ein Domänenwert auf einen bekannten Oberbegriff endet, Bewertung erhöhen

- Eingabe: Attributewerte der Textfelder
- Die ersten 10, 50, 100 Ausgabewerte betrachtet
- Jeder Wert manuell überprüft
- Testfall 1: Fluckticketanbieter
 - Gesucht: Menge der Städte, Länder, Flughafenamen und -Kodierungen
- Testfall 2: Bahnticketanbieter
 - Gesucht: Menge der Bahnhalttestellen
- Testfall 3: Hotelbuchung
 - Gesucht: Menge der Städte, Hotelnamen und Örtlichkeiten

Tabelle: Trefferquoten bei Testfall 1, Flugticketanbieter

Verwendete Datenquelle	Trefferquote (Top 10)	Trefferquote (Top 50)	Trefferquote (Top 100)
WordNet	0.8	0.76	0.73
Wikipedia	0.8	0.76	0.49
ResearchCyc	0.8	0.96	0.98
Alle Datenquellen	0.9	0.84	0.92

Tabelle: Trefferquoten bei Testfall 2, Bahnhaltestellen

Verwendete Datenquelle	Trefferquote (Top 10)	Trefferquote (Top 50)	Trefferquote (Top 100)
WordNet	0	0	0
Wikipedia	1.0	1.0	1.0
ResearchCyc	0	0	0
Alle Datenquellen	0	0	0

Tabelle: Trefferquoten bei Testfall 3, Hotels

Verwendete Datenquelle	Trefferquote (Top 10)	Trefferquote (Top 50)	Trefferquote (Top 100)
WordNet	0.5	0.52	0.41
Wikipedia	0.6	0.3	0.26
ResearchCyc	10	1.0	0.84
Alle Datenquellen	0.6	0.64	0.62

- Aufgabe der Arbeit:
 - Ermittlung der Wertebereiche von Textfeldern mithilfe der externen Datenquellen
- Lösung:
 - Klassifizierung der Attributwerte auf Oberbegriffe und Domänenwerte
 - Lexikalische Filterung
 - Ermittlung weitere Oberbegriffe der bekannten Domänenwerte
 - Ermittlung weitere Domänenwerte
- Datenquellen:
 - ResearchCyc
 - Wikipedia
 - WordNet
- Die entwickelte Lösung:
 - Liefert eine große Anzahl der Ergebnisse
 - Geeignet für mehrere Anwendungsdomänen

- Weitere Datenquellen sind zu überlegen
 - YAGO, Wikidata, Google Knowledge Graph
 - Listen in Wikipedia (z.B. "List of cities")
- Mehr Stichproben zur Verbesserung der Konfigurationsparameter

Geetha, TV (2017). “Unsupervised Domain Ontology Learning from Text”. In: *Mining Intelligence and Knowledge Exploration: 4th International Conference, MIKE 2016, Mexico City, Mexico, November 13-19, 2016, Revised Selected Papers*. Bd. 10089. Springer, S. 132.