Vorlesung Semantic Web

TECHNISCHE UNIVERSITÄT DARMSTADT

Vorlesung im Wintersemester 2012/2013

Dr. Heiko Paulheim

Fachgebiet Knowledge Engineering

Semantic Web – Aufbau

here be dragons...

Semantic-Web-Technologie (Fokus der Vorlesung)

Technische Grundlagen

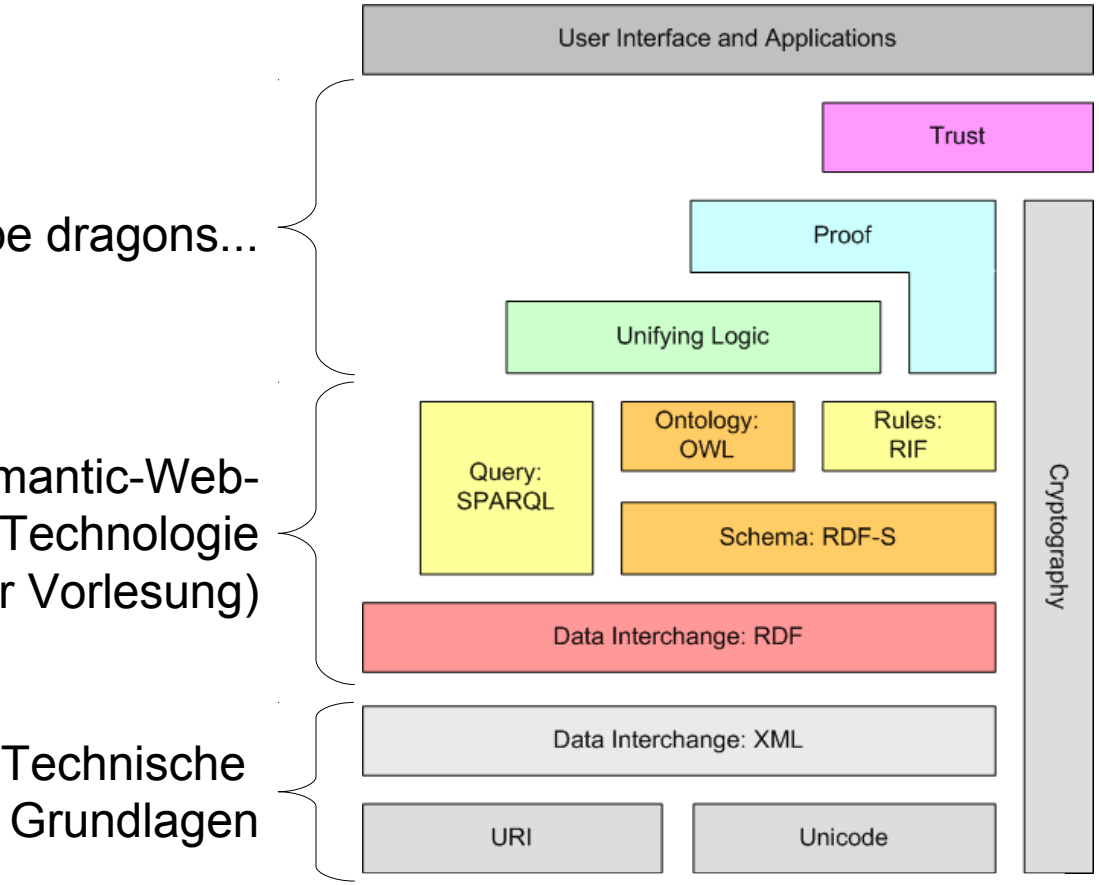

Berners-Lee (2009): *Semantic Web and Linked Data*
http://www.w3.org/2009/Talks/0120-campus-party-tbl/

Was bisher geschah

TECHNISCHE UNIVERSITÄT DARMSTADT

- Daten werden als Linked Data maschinenlesbar bereitgestellt
  - Daten mit RDF (XML/N3)
  - Schemata & Ontologien mit RDFS/OWL
- Man kann darauf Anwendungen programmieren
- ...und mit Reasoning komplexe Sachverhalte ableiten

Warum das alles?

TECHNISCHE UNIVERSITÄT DARMSTADT

aus Sicht des Menschen:

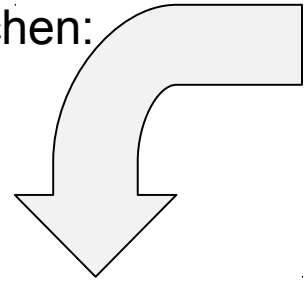

Dr. Mark Smith
Physician
Main St. 14
Smalltown
Mon-Fri 9-11 am
Wed 3-6 pm

```
<html>
  …
  <b>Dr. Mark Smith</b>
  <i>Physician</i>
  Main St. 14
  Smalltown
  Mon-Fri 9-11 am
  Wed 3-6 pm
  …
</html>
```

aus Sicht des Computers:

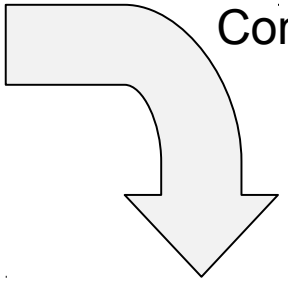

Print in bold: „hmf298hmmhudsa“
Print in italics: „mj2i9ji0“
Print normal: „fdsah
02hfadsh0um2m0adsmf0ihm
asdfjköfdsa298ndsfmij32mio
lk2mjpoimjiofdpmsajiomjm“

Warum das alles?

TECHNISCHE UNIVERSITÄT DARMSTADT

- Kann RDF mehr als XML?

- XML ist eine Auszeichnungssprache für Informationen
- In XML kann man beliebige Tags und Attribute definieren

- XML-Tagnamen haben für den Computer keine Bedeutung

- RDF ist eine Auszeichnungssprache für Informationen
- In RDF kann man beliebige Klassen / Relationen definieren
- RDF-Bezeichner haben für den Computer keine Bedeutung

Warum das alles?

TECHNISCHE UNIVERSITÄT DARMSTADT

- Kann RDFS/OWL mehr als RDF?

- RDF ist eine Auszeichnungssprache für Informationen
- In RDF kann man beliebige Klassen / Relationen definieren
- RDF-Bezeichner haben für den Computer keine Bedeutung

- RDFS/OWL sind Auszeichnungssprachen für RDF-Daten
- In RDFS/OWL kann man beliebige Klassen / Relationen definieren
- RDFS/OWL-Bezeichner (also Klassen- und Propertynamen) haben für den Computer keine Bedeutung

Warum das alles?

TECHNISCHE UNIVERSITÄT DARMSTADT

- Aufgabe:
  - Finde alle Ärzte, die "Mark Smith" heißen
  - Befrage verschiedene Linked Open Data Sets
- Problem:
  - jedes Linked Data Set kann sein eigenes Vokabular benutzen
  - Vokabulare *können*, aber *müssen* nicht wiederverwendet werden

```
:p a foaf:Person .
:p foaf:name "Mark Smith" .
:p bar:profession :Physician .
...
```

Linked Data Set 1

```
:q a foo:Human .
:q foo:called "Mark Smith" .
:q foo:worksAs :MedDoctor .
...
```

Linked Data Set 2

Linked Open Data: Die vier Grundregeln

TECHNISCHE UNIVERSITÄT DARMSTADT

- Vier Grundregeln,
  vorgeschlagen von Tim Berners-Lee (mal wieder)

1. Identifiziere Dinge mit URIs
2. Verwende auflösbare HTTP-URIs
3. Hinterlege an diesen URIs nützliche Informationen,
   verwende dabei Standards
4. Füge Links zu anderen URIs hinzu

gemeint sind hier:
technische Standards,
z.B. RDF

Linked Open Data: Die vier Grundregeln

TECHNISCHE UNIVERSITÄT DARMSTADT

- "Füge Links zu anderen URIs hinzu"
- das wird in der Regel auf Instanzebene gemacht

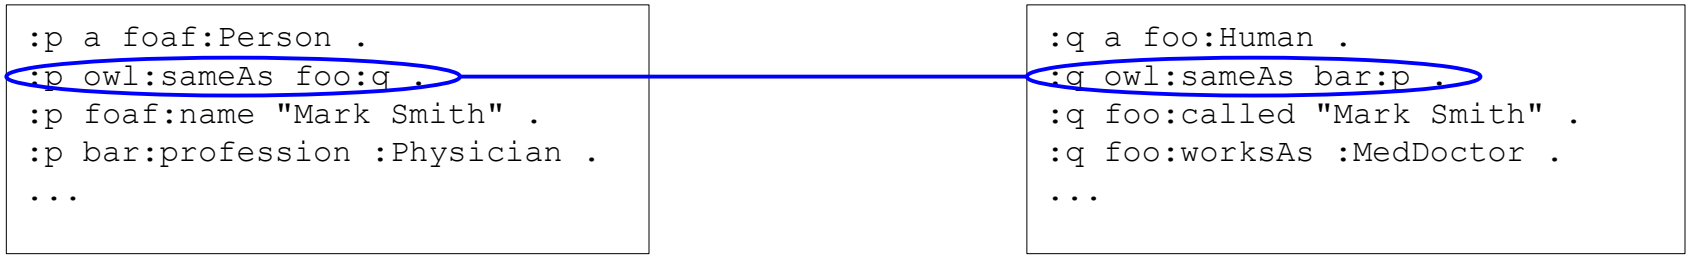

Linked Data Set 1

Linked Data Set 2

Was fehlt?

- "Füge Links zu anderen URIs hinzu"
  - beachte das auch für die Schemaebene
  - Schemata werden ja auch als Linked Data bereitgestellt
  - das sollte also eigentlich selbstverständlich sein...

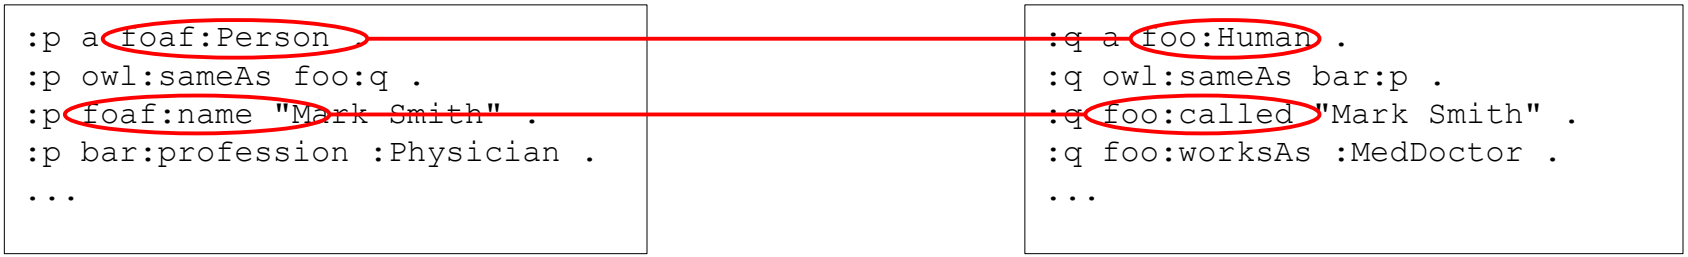

Linked Data Set 1

Linked Data Set 2

Ontology Mappings

TECHNISCHE UNIVERSITÄT DARMSTADT

- Links auf Schemaebene heißen *Ontology Mapping*
  - auch: *Ontology Alignment, Ontology Matching*
  - Abbildungen einer Ontologie auf eine andere
  - Vereinfacht: ein Lexikon zwischen Ontologien
  - sowohl für Klassen als auch für Properties

FOAF	FOO
Person	Human
name	called
...	...

Ausdrücken von Mappings

TECHNISCHE UNIVERSITÄT DARMSTADT

- Formal ist ein Mapping eine Menge von Tripeln $<c_1, c_2, r>$
  - wobei c_1 ein Konzept aus Ontologie 1 ist
  - c_2 ein Konzept aus Ontologie 1 ist
  - r eine Relation zwischen beiden ist
    - In der Regel eines von ≡, ⊑ und ⊒, manchmal auch ≢

- Mappings werden in der Regel nur zwischen gleichartigen Entitäten definiert (Konformität mit OWL Lite/DL!)
  - zwischen Klassen und Klassen
  - zwischen ObjectProperties und ObjectProperties
  - zwischen DatatypeProperties und DatatypeProperties
  - zwischen Instanzen und Instanzen

Mappings im Semantic Web

TECHNISCHE UNIVERSITÄT DARMSTADT

- Asymmetrisch: eine Ontologie enthält Mappings zu einer anderen

```
ex:myOntology owl:imports <http://xmlns.com/foaf/0.1/>
ex:Human a owl:Class ;
  owl:equivalentClass foaf:Person .
ex:hasName a owl:DatatypeProperty ;
  owl:equivalentProperty foaf:name .
ex:mobilePhone a owl:ObjectProperty .
ex:mobilePhone rdfs:subPropertyOf foaf:Phone .
```

- Achtung: durch falsch gesetzte Mappings kann man schnell den Raum von OWL Lite/DL verlassen:

```
ex:mobilePhone a owl:DatatypeProperty .
ex:mobilePhone rdfs:subPropertyOf foaf:Phone .
```
aber: `foaf:Phone a owl:ObjectProperty .`

Mappings im Semantic Web

TECHNISCHE UNIVERSITÄT DARMSTADT

- Symmetrisch:
  - wechselseitige Verweise (2x asymmetrisch)
  - eine Ontologie nur für Mappings ("Bridge-Ontologie")
- Sieht z.B. so aus:

```
ex:bridge a owl:Ontology .
ex:bridge owl:imports <http://example.org/onto1.owl>
ex:bridge owl:imports <http://example.org/onto2.owl>
ex1:Researcher owl:subClassOf ex2:Person .
ex1:worksOn owl:equivalentProperty ex2:involvedIn .
...
```

Mappings im Semantic Web

TECHNISCHE UNIVERSITÄT DARMSTADT

- Linked Open Data:
  - Mappings müssen auffindbar sein
  - Daher müssen Mapping-Axiome immer auch in der Definition enthalten sein
  - kann auch durch Importieren einer Bridge-Ontologie geschehen

- Beschränkungen dieses Ansatzes:
  - Nur OWL-Axiome als Mappings möglich

Mappings im Semantic Web

TECHNISCHE UNIVERSITÄT DARMSTADT

- Beschränkungen des OWL-basierten Ansatzes
  - keine komplexeren Ausdrücke, z.B. zum Matchen von ex1:temperatureInC a owl:DatatypeProperty . ex2:temperatureInF a owl:DatatypeProperty .
  - oder von

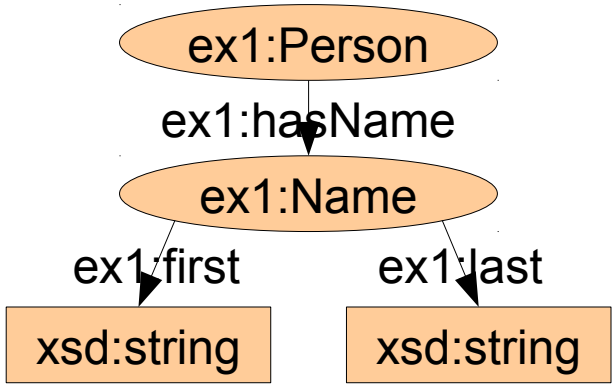

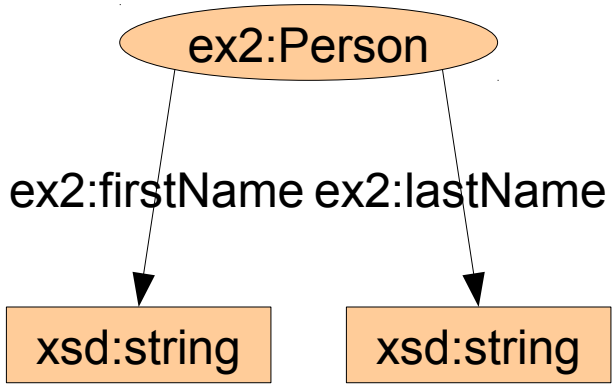

Mappings im Semantic Web

TECHNISCHE UNIVERSITÄT DARMSTADT

- Warum ist das problematisch?
  - Was spricht denn gegen

```
ex1:first owl:equivalentProperty ex2:firstName .
ex2:last owl:equivalentProperty ex2:lastName .
```

- Gegeben

```
ex1:first rdfs:domain ex1:Name .
```

- und

```
ex2:PeterSchmidt ex2:firstName "Peter" .
ex2:PeterSchmidt a Person .
```

- Was folgt daraus?

```
ex2:PeterSchmidt a ex1:Name .
```

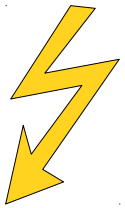

Mappings im Semantic Web

TECHNISCHE UNIVERSITÄT DARMSTADT

- Aktuelle Forschung
  - verwenden komplexerer Repräsentationen
    - z.B. Regeln
  - Fuzzy Mappings
    - z.B. `ex1:Forscher`, `ex2:UniMitarbeiter`
    - nicht alle Forscher sind Uni-Mitarbeiter
    - nicht alle Uni-Mitarbeiter sind Forscher
    - aber trotzdem sind die beiden *zu einem bestimmten Grad ähnlich*

Wie findet man Mappings?

TECHNISCHE UNIVERSITÄT DARMSTADT

- z.B. durch Experten
- Nehmen wir mal zwei Ontologien, z.B.
  - YAGO (~100.000 Klassen)
  - OpenCyc (~150.000 Klassen)

- Dieser Ansatz skaliert offenbar nicht besonders gut...

Ontology Matching

TECHNISCHE UNIVERSITÄT DARMSTADT

- Ontology Matching:
  - automatisches Finden von Mappings
  - Gegeben: zwei Ontologien

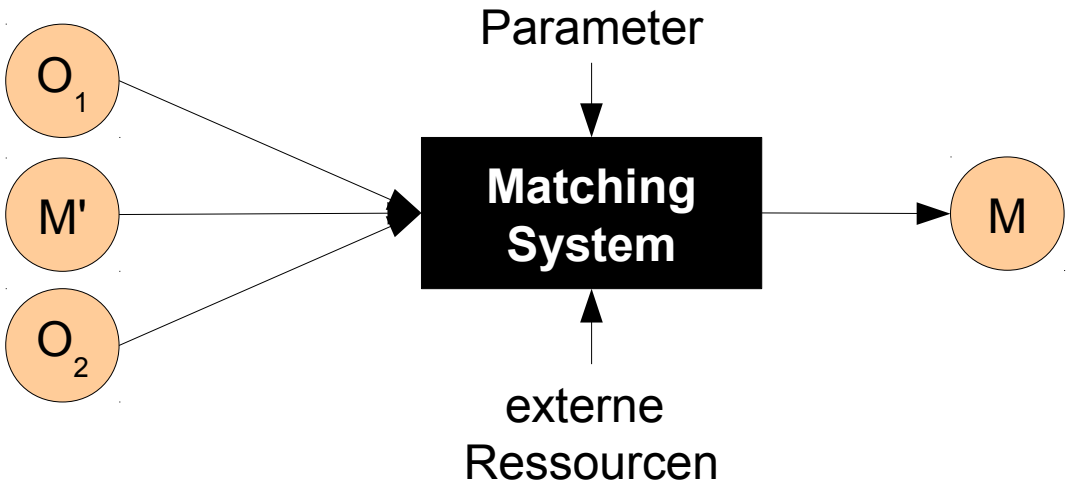

Euzenat & Shvaiko: Ontology Matching (2007)

Ontology Matching

TECHNISCHE UNIVERSITÄT DARMSTADT

- Was ist in der Black Box?
- Finden Sie es heraus!

Ontology Matching

TECHNISCHE UNIVERSITÄT DARMSTADT

- Matcher erzeugen ein Mapping
  - üblicherweise simples Mapping
  - und liefern meist ein zusätzliches Konfidenzmaß
  - Also 4-Tupel der Form $<e_1,e_2,r,c>$
  - z.B. <ex:name, foaf:name, ≡,0.9>

Arten von Matchern

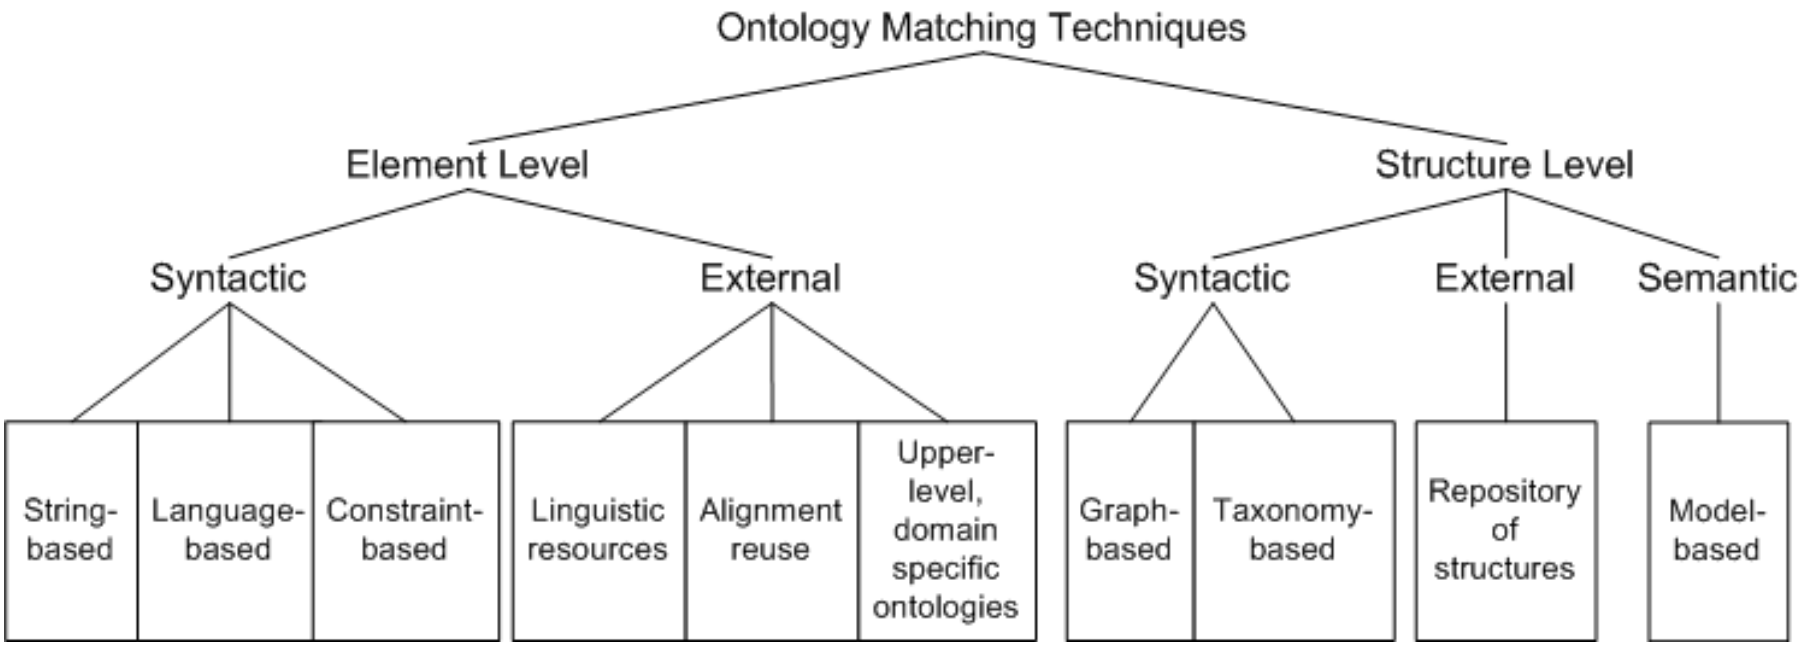

Euzenat & Shvaiko: Ontology Matching (2007)

Arten von Matchern

TECHNISCHE UNIVERSITÄT DARMSTADT

- Element- vs. strukturbasiert:
  - elementbasierte Verfahren: vergleichen nur einzelne Elemente
  - strukturbasierte Verfahren: nutzen auch Struktur aus
    - z.B. Vererbungsbeziehungen

- Syntaktisch vs. extern vs. semantisch
  - syntaktische Verfahren nutzen nur die Ontologien selbst
  - externe Verfahren ziehen weitere Wissensquellen hinzu
  - semantische Verfahren nutzen die inhärente Semantik von Ontologien
    - z.B. mit Reasoning

Simple elementbasierte Techniken

TECHNISCHE UNIVERSITÄT DARMSTADT

- Element-basierte Verfahren vergleichen in der Regel Bezeichner
  - z.B. URI-Fragmente
    - `ex1:name`
    - `ex2:hasName`
  - z.B. Labels
    - `ex1:name rdfs:label "A person's name"@en .`
    - `ex2:hasName rdfs:label "The name of a person"@en .`
  - z.B. comments
    - `ex1:name rdfs:comment "Usually the family name"@en .`
    - `ex2:name rdfs:comment "Usual order: family name, given name"@en .`

String-basierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- Direkte Stringgleichheit
  - z.B. ex1:Person, ex2:Person
- Suche von gemeinsamen Präfixen
  - z.B. ex1:phone, ex2:phoneNumber
- Suche von gemeinsamen Postfixen
  - z.B. ex1:name, ex2:hasName

- Verfeinerung:
  - Längenrelation von gemeinsamem Präfix/Suffix und String als Konfidenzmaß
  - z.B. ex1:phone, ex2:phoneNumber => c = 5/11
  - z.B. ex1:name, ex2:hasName => c = 4/7

String-basierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- Edit-Distanz
  - Minimale Anzahl von Editier-Schritten, um von String 1 zu String 2 zu kommen, geteilt durch Länge des längeren Strings
    - ein Zeichen einfügen
    - ein Zeichen löschen
    - ein Zeichen ändern
  - z.B. ex1:hasName, ex2:firstName
    - hasName → fhasName → fhastName → fiastName → firstName
    - Edit-Distanz = 4/9

String-basierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- N-Gramm-Analyse
  - wie viele Buchstabengruppen der Länge n stimmen überein geteilt durch Anzahl n-Gramme in längerem String (= Länge – n + 1)
  - häufig verwendet: n=3
  - z.B. ex1:hasName, ex2:firstName
    - übereinstimmende 3-Gramme: Nam, ame
    - gesamte 3-Gramme: fir, irs, rst, stN, tNa, Nam, ame

      → 3-Gramm-Distanz = 2/7

Sprachbasierte Techniken

TECHNISCHE UNIVERSITÄT DARMSTADT

- Werden insbesondere zur Vorverarbeitung genutzt, um die Treffgenauigkeit zu verbessern
- Linguistische Verfahren
- Eliminierung von Stop-Words
  - ex1:locatedIn → ex1:located
- Lemmatisierung/Stemming:
  - ex1:located, ex2:location
  - beides wird zu locat-
- Zerlegen in Tokens (Tokenization)
  - ex1:graduated_from_university → {graduated,from,university}
    ex2:isGraduateFromUniversity → {is,Graduate,from,University}
  - Tokens werden einzeln weiterverarbeitet

Sprachbasierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- können Treffgenauigkeit verbessern
  - ex1:located, ex2:location
  - Stemming: ex1:locat-, ex2:locat-
  - Edit-Distance: 0 → hohe Ähnlichkeit
- Gegenbeispiel:
  - ex1:locationOf, ex2:locatedIn (Inverse Properties!)
  - Erster Schritt: Eliminierung von Stop-Words: ex1:location, ex2:located
  - Zweiter Schritt: Stemming: ex1:locat-, ex2:locat-
  - Edit-Distance: 0 → hohe Ähnlichkeit
- dagegen Edit-Distance ohne Vorverarbeitung: 0.5 → nicht so hoch

Constraint-basierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- Zusätzlicher Abgleich der Eigenschaften von gemappten Entitäten
  - z.B. verwendete Multiplizitäten von Restriktionen
  - z.B. Datentypen bei DatatypeProperties
- Im letzten Beispiel:
  - ex1:locationOf
    - definiert als InverseFunctionalProperty
    - Kardinalität ist nicht eingeschränkt
  - ex2:locatedIn
    - definiert als FunctionalProperty
    - exactCardinality=1
- Damit können wir die Ähnlichkeit von ex1:locationOf und ex2:locatedIn reduzieren

Matching mit linguistischen Ressourcen

TECHNISCHE UNIVERSITÄT DARMSTADT

- Externes Wissen
- Beispiel: Synonyme
  - ex1:Verfasser, ex2:Autor
  - Edit-Distance: 8/9 (sehr hoch!)
  - Synonymwörterbuch kann hier eine Lösung sein
- Beispiel: Ontologien in unterschiedlichen Sprachen
  - ex1:Stadt, ex2:city
  - Edit-Distance: 1
  - Lexikalische Ressource kann hier eine Lösung sein

Matching mit linguistischen Ressourcen

TECHNISCHE UNIVERSITÄT DARMSTADT

- WordNet
  - strukturiert für englisch
  - Synonyme, Hyponyme, Hyperonyme
  - Holo- und Meronyme

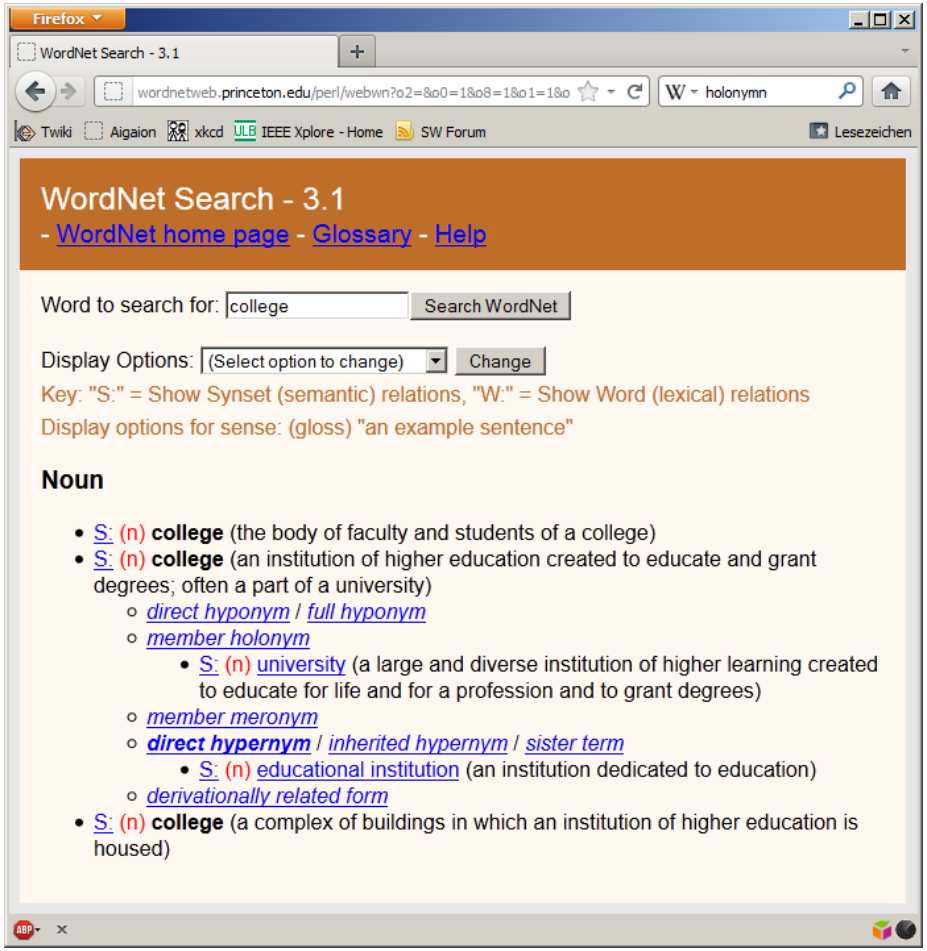

Matching mit linguistischen Ressourcen

TECHNISCHE UNIVERSITÄT DARMSTADT

- Auch domänenspezifisch
  - ex1:ServiceOrientedArchitecture, ex2:SOA
  - Edit-Distance: 0.89 (sehr hoch)
  - Ein Domänenwörterbuch kann hier Abhilfe schaffen

Matching mit Web-Resourcen

TECHNISCHE UNIVERSITÄT DARMSTADT

- WeSeE-Match (TU Darmstadt, 2012)
  - Nutzt Web-Suchmaschinen
  - Zwei Begriffe googeln
  - Trefferlisten ähnlich → Begriffe ähnlich
- WikiMatch (TU Darmstadt, 2012)
  - Nutzt Wikipedia
  - Beide Begriffe in Wikipedia suchen
  - Seiten vergleichen
  - Links zu anderen Sprachen
- Werbung:
  - Vortrag zu Wikimatch: heute, 16:30, E202

Wiederverwendung von Mappings

TECHNISCHE UNIVERSITÄT DARMSTADT

- Betrachten wir folgendes Beispiel:
  - ex:hasCreator, foaf:maker
  - Edit-Distance 0.7
- Für FOAF gibt es aber teilweise schon Mappings zu anderen Ontologien, z.B. Dublin Core
  - foaf:maker owl:equivalentProperty dc:creator
  - Wir können also auch ex:hasCreator mit dc:creator vergleichen
  - Edit-Distance: 0.4

Verwendung von Upper-Level-Ontologien

TECHNISCHE UNIVERSITÄT DARMSTADT

- Upper-Level-Ontologien werden wir noch kennen lernen
- Idee: eine allgemeine Ontologie wiederverwenden
  - ex1:Researcher rdfs:subClassOf upper:Human .
  - ex2:Scientist rdfs:subClassOf upper:Human .
- Eine gemeinsame Oberklasse kann zusätzliches Indiz für ein Mapping sein
- Aber nicht alleiniges Indiz!
  - ex2:Baker rdfs:subClassOf upper:Human .

Graphenbasierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- Ontologien bilden Graphen
- Idee: Ähnlichkeiten in den Graphen propagieren
- z.B.
  - #gemappte Nachbarknoten / #Nachbarknoten
  - #gemappte Kanten / #Kanten

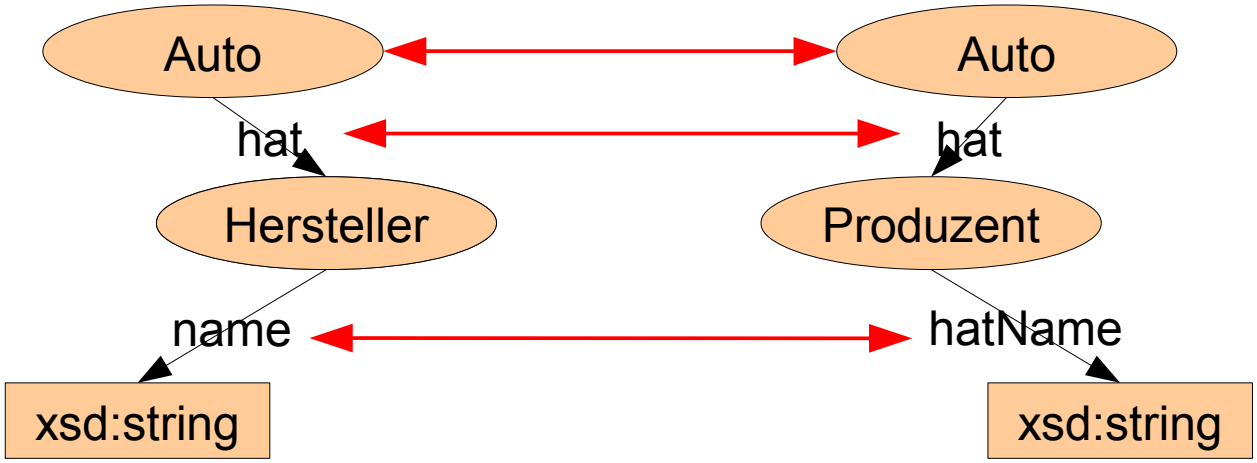

Graphenbasierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- Sind auch geeignet, um Mappings für Properties zu bestimmen oder zu verfeinern:
  - wenn je zwei gemappte Klassen durch ein Property verbunden sind, können diese Properties mit hoher Wahrscheinlichkeit gemappt werden

Taxonomiebasierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- Klassenhierarchien sind essentiell in Ontologien
- Super/Subkonzeptregeln: Kinder und Eltern von gemappten Elementen sind Kandidaten

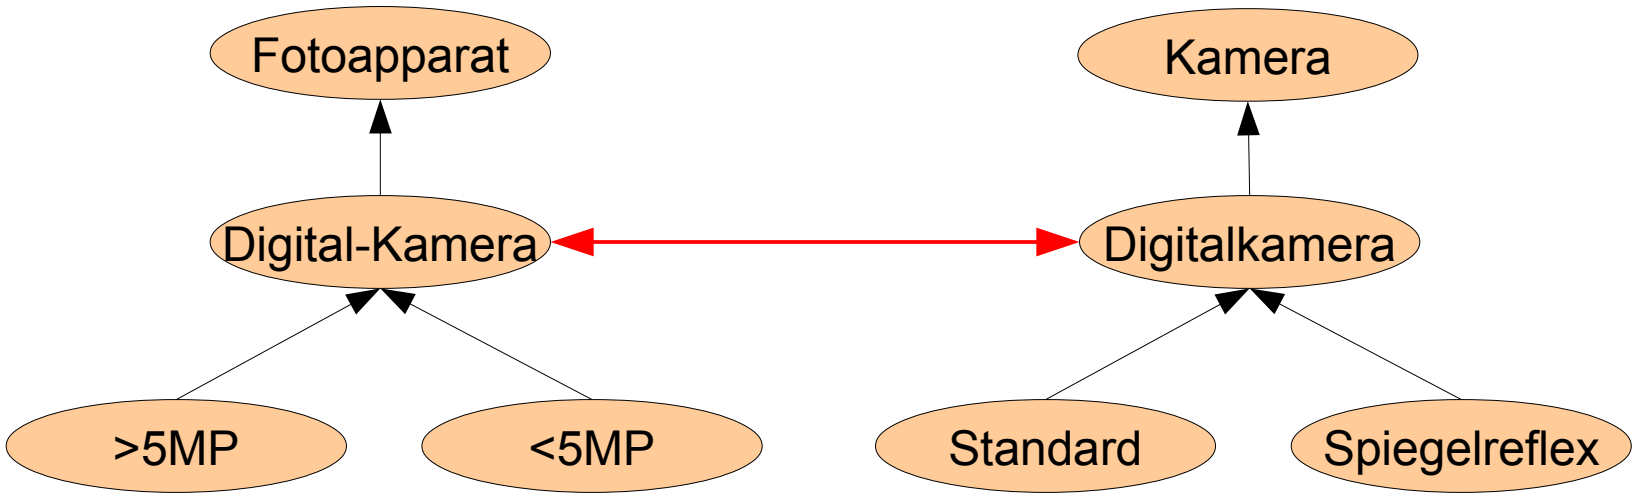

Taxonomiebasierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- Klassenhierarchien sind essentiell in Ontologien
- Bounded Path Matching: Auf Pfaden zwischen gemappten Elementen liegen wahrscheinlich weitere Kandidaten

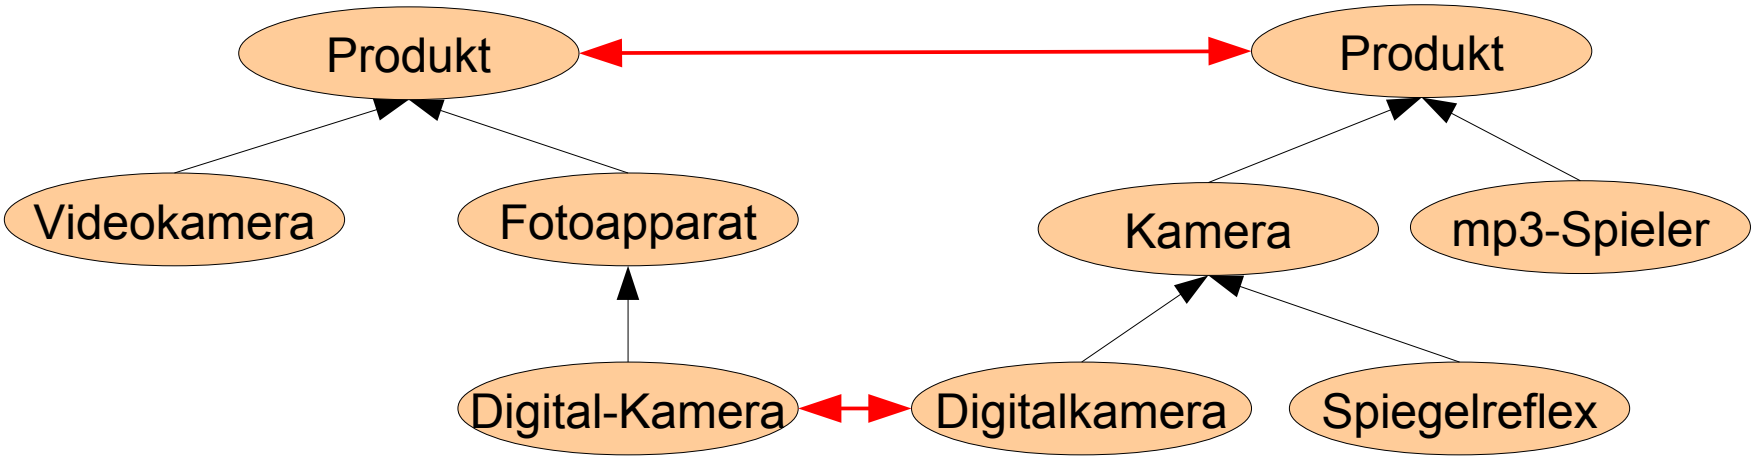

Strukturensammlungen

- Annahme: es gibt bestimmte häufig wiederkehrende Muster
  - z.B.: Person mit Vor- und Nachname
  - z.B.: Adresse mit Straße, PLZ und Ort
- Idee: Suche gezielt nach solchen Mustern
  - wenn in beiden Ontologien gefunden: untersuche diese im Detail

Modellbasierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- Verwendung von einem Reasoner
- Verfahren:
  - beide Ontologien zu einer vereinigen
  - gefundene Mappings einfügen
  - mit Reasoner auf Widerspruchsfreiheit prüfen

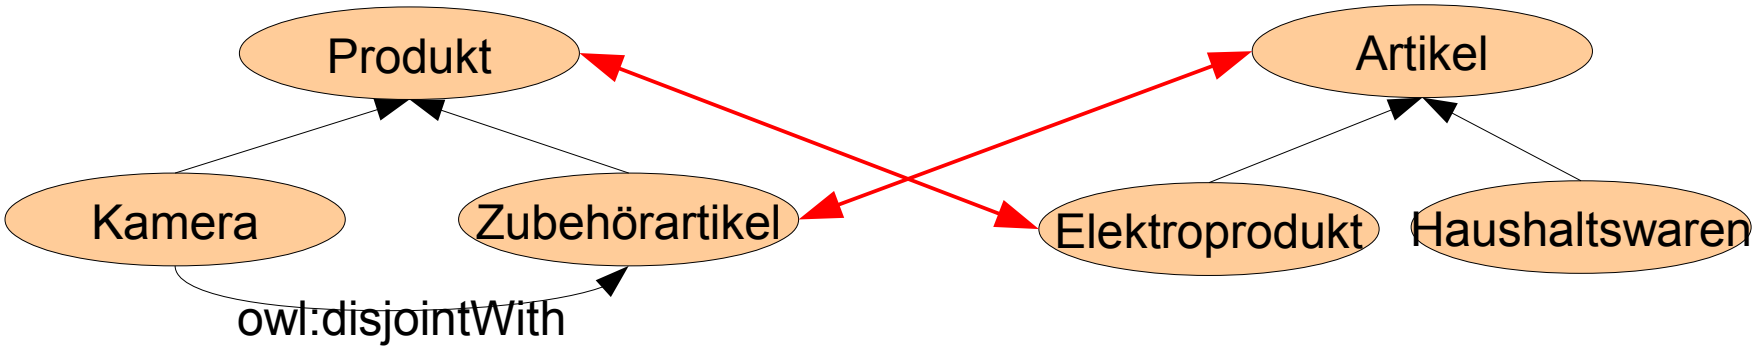

Modellbasierte Verfahren

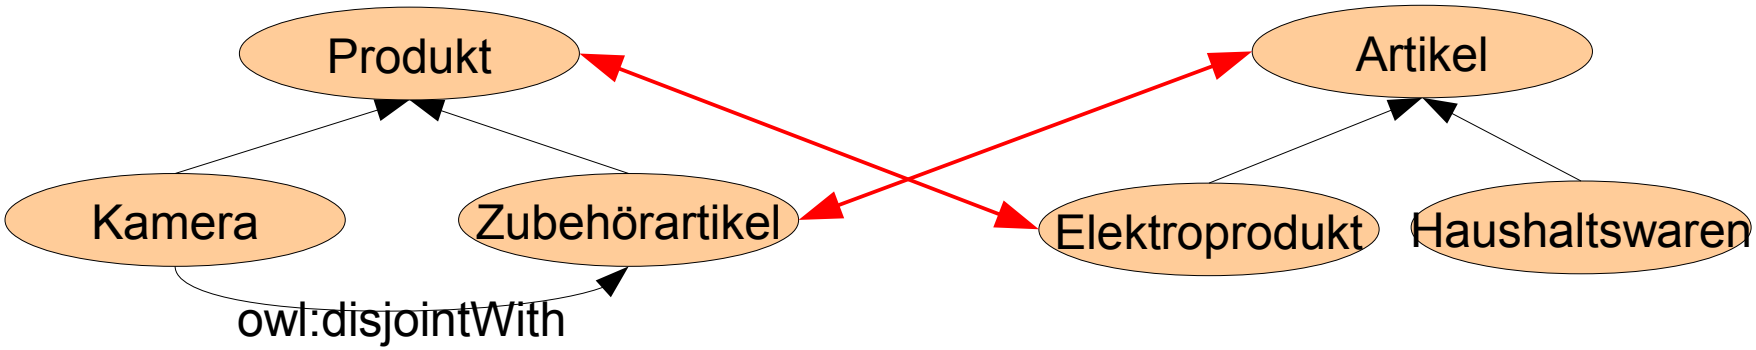


```
:Kamera
  rdfs:subClassOf :Produkt .
:Zubehörartikel
  rdfs:subClassOf :Produkt .
:Kamera owl:disjointWith
  :Zubehörartikel .
```

```
:Elektroprodukt
  rdfs:subClassOf :Artikel .
:Haushaltswaren
  rdfs:subClassOf :Artikel .
```

```
ex1:Produkt owl:equivalentClass
  ex2:Elektroprodukt.
ex1:Zubehörartikel
  owl:equivalentClass ex2:Artikel .
```

Modellbasierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- Lassen wir das den Reasoner mal untersuchen

```
ex1:Kamera rdfs:subClassOf ex1:Produkt .
+ ex1:Produkt owl:equivalentClass ex2:Elektroprodukt .
→ ex1:Kamera rdfs:subClassOf ex2:Elektroprodukt .
+ ex2:Elektroprodukt rdfs:subClassOf ex2:Artikel .
→ ex1:Kamera rdfs:subClassOf ex2:Artikel .
+ ex2:Artikel owl:equivalentClass ex1:Zubehörartikel .
→ ex1:Kamera rdfs:subClassOf ex1:Zubehörartikel .
```

- Gleichzeitig soll gelten:

```
ex1:Kamera owl:disjointWith ex1:Zubehörartikel .
```

- Widerspruch gefunden!
- Lösung: ein Mapping-Element entfernen
  - z.B. das mit der niedrigeren Konfidenz

Instanzbasierte Verfahren

TECHNISCHE UNIVERSITÄT DARMSTADT

- Bis jetzt haben uns Instanzen noch nicht gekümmert
  - nur schemabasierte Ansätze
  - das ist die Mehrzahl
- Linked Open Data bietet viele Instanzdaten
  - die können auch hilfreich sein:

    ex1:Peter a ex1:Human .
    ex1:Peter owl:sameAs ex2:Pete .
    ex2:Pete a ex2:Person .
  - mit genügend solcher Instanzen kann man auf ein Mapping schließen

Instanzbasierte Verfahren

- Ansatz z.B. über Accuracy:
  - #(ex1:Human ⊓ ex2:Person) / #(ex1:Human ⊔ ex2:Person)
  - im Beispiel: 18/23 → Mapping-Konfidenz von ~0.78
- Gut geeignet, um nicht-triviale Mappings zu finden
  - z.B. dbpedia:Park ↔ yago:ProtectedArea

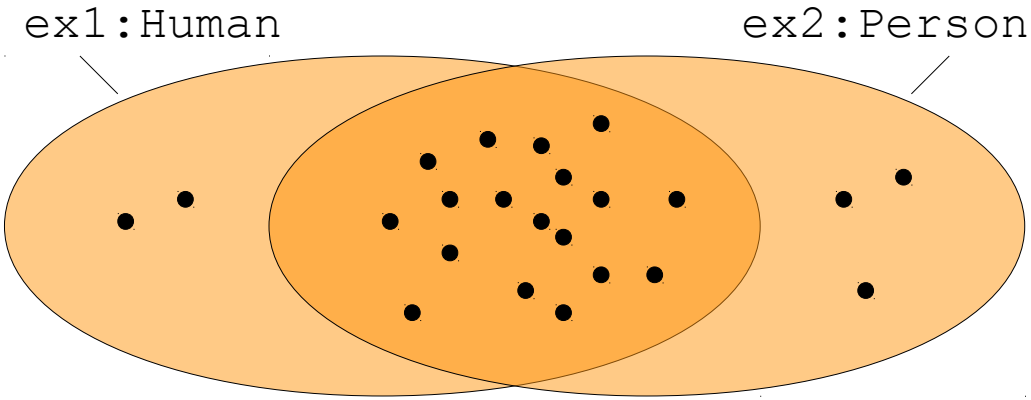

Finalisierung der Mapping-Ergebnisse

TECHNISCHE UNIVERSITÄT DARMSTADT

- Ontology Matcher liefert
  - $<e_1,e_2,r,c>$
  - Übliches Verfahren: Rückgabe aller Mappings, für die c ≥ t gilt
  - Auch möglich: Filtern mit Plausibilitätsprüfung

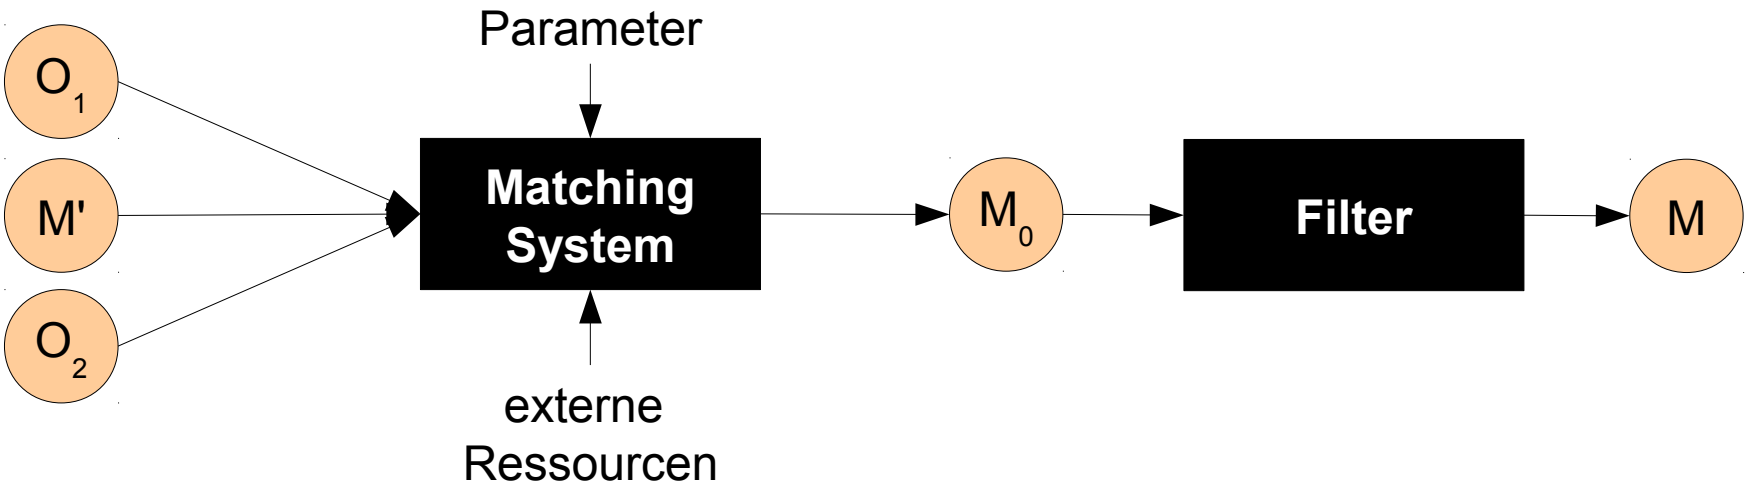

Kombination von Matchern

TECHNISCHE UNIVERSITÄT DARMSTADT

- Was wir bis jetzt gesehen haben
  - eine Reihe von Strategien
  - jede hat Stärken und Schwächen
  - in der Regel werden mehrere Verfahren kombiniert

Kombination von Matchern

- Reihenschaltung
  - gut für Matcher, die Kandidaten benötigen:
    - Strukturbasierte Verfahren, z.B. Bounded Path
    - Modellbasierte Verfahren (Validierung von Kandidaten)

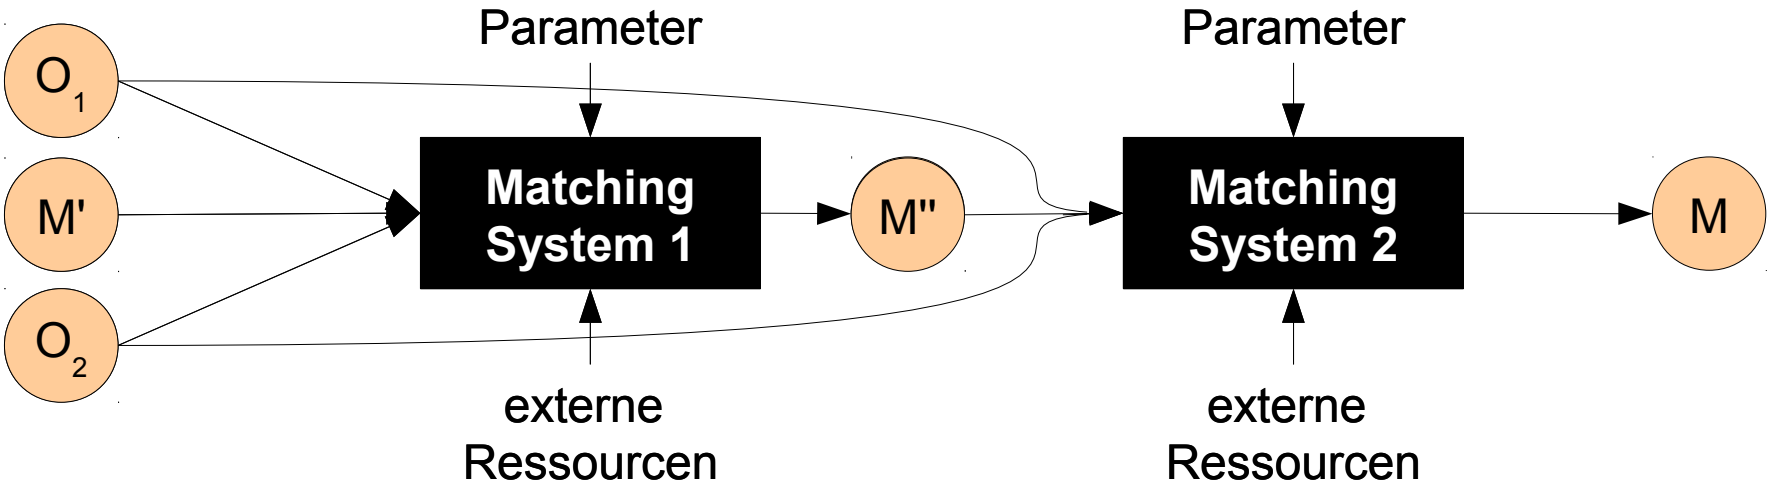

Kombination von Matchern

- Parallelschaltung

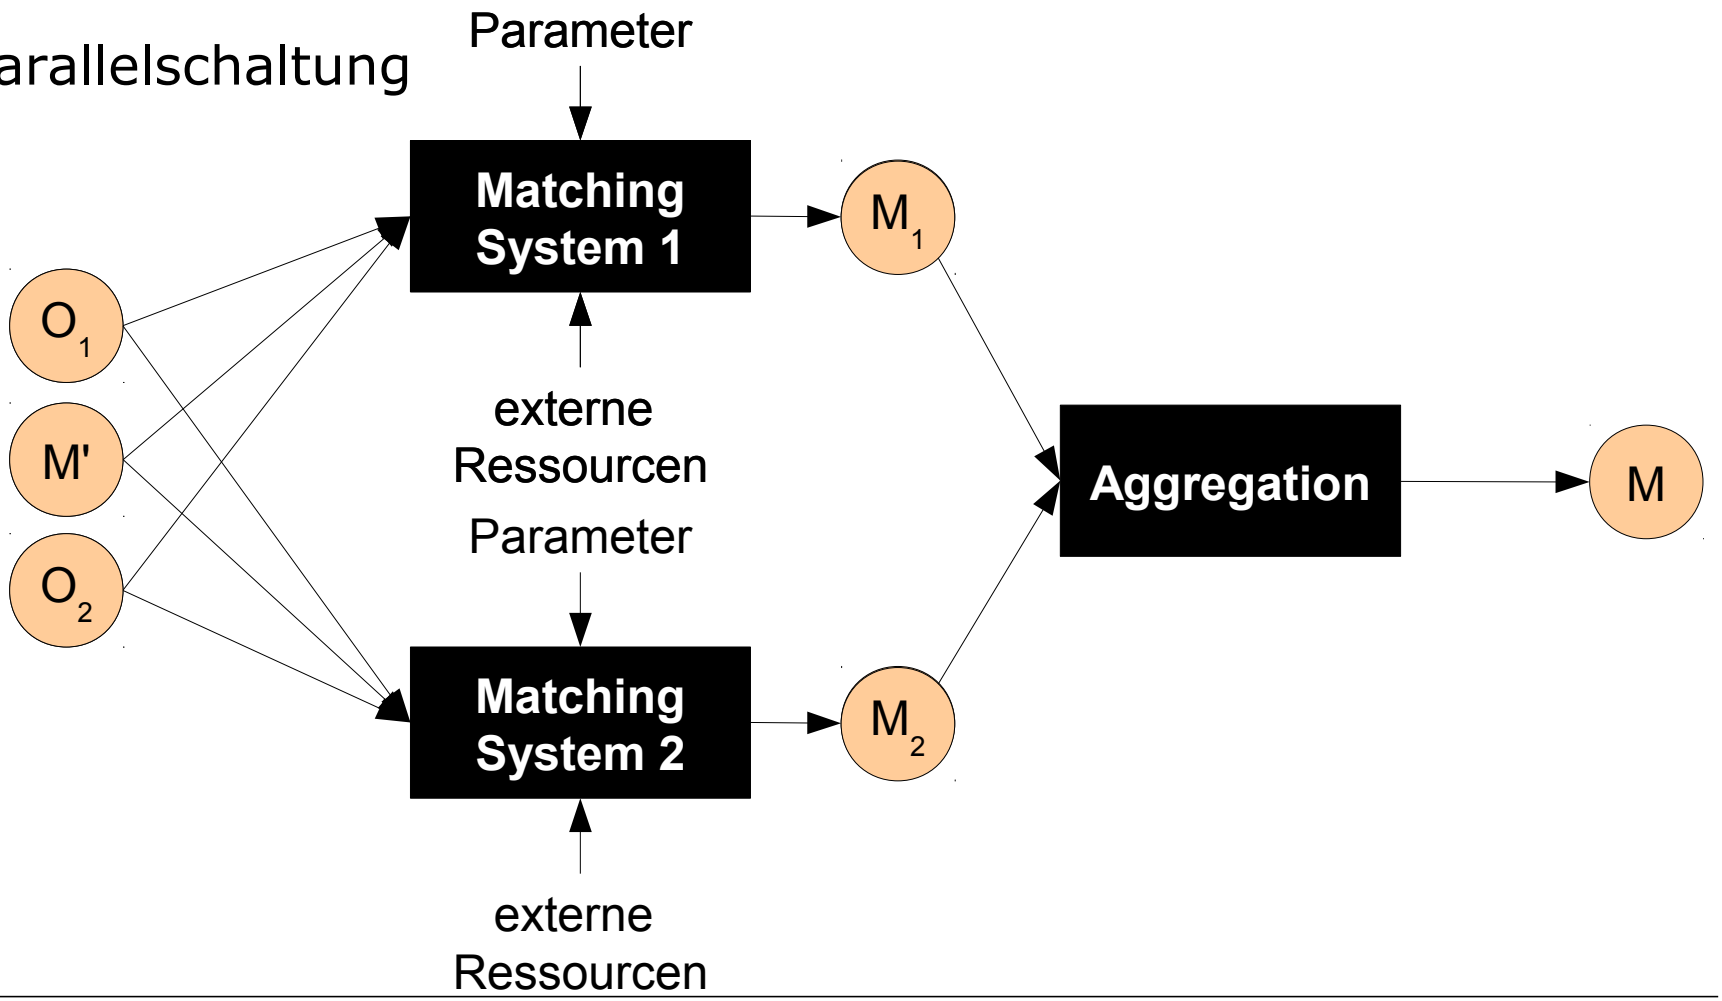

Kombination von Matchern

TECHNISCHE UNIVERSITÄT DARMSTADT

- Parallelschaltung
- ermöglicht
  - z.B. verschiedene elementbasierte Techniken
  - unterschiedliche Techniken auf unterschiedlichen Ontologieteilen
- Aggregation der Ergebnisse
  - auf Basis der Konfidenz
  - z.B. gewichtetes Mittel, Minimum, Maximum
  - z.B. probabilistische Summe, decaying sum, ...

Auswertung von Mappings

- Gegeben:
  - das vom Matcher gefundene Mapping (M)
  - das tatsächliche Referenz-Mapping (R)
- Recall: der Anteil der gefundenen Elemente des Referenz-Mappings
  - rec = #(R ∩ M) / #R
  - im Beispiel: rec = 8/10 = 0.8

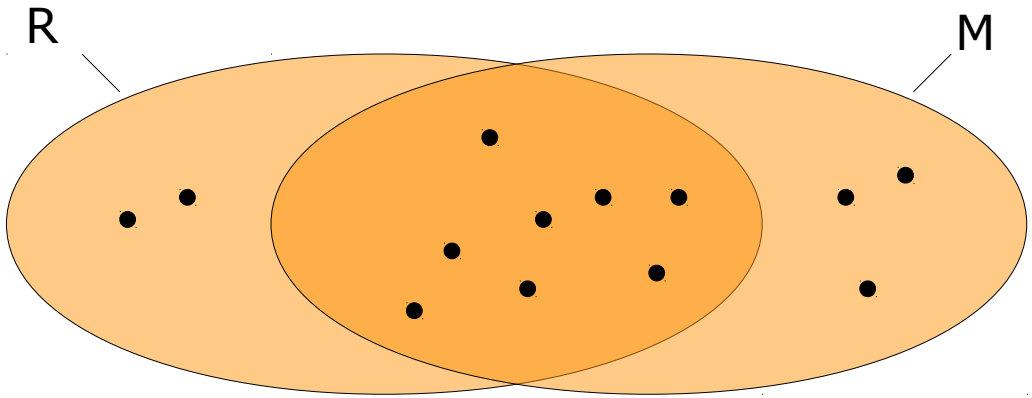

Auswertung von Mappings

- Gegeben:
  - das vom Matcher gefundene Mapping (M)
  - das tatsächliche Referenz-Mapping (R)
- Precision: der Anteil der korrekten Elemente unter den gefundenen
  - rec = #(R ∩ M) / #M
  - im Beispiel: rec = 8/11 = 0.73

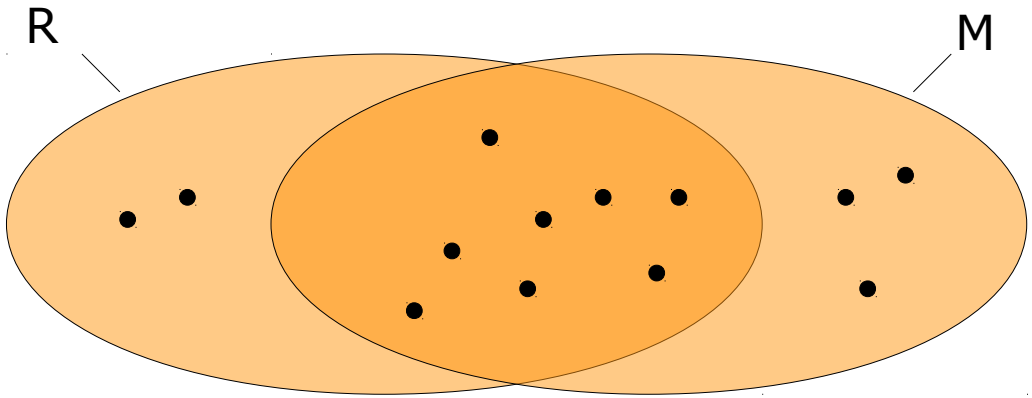

Auswertung von Mappings

TECHNISCHE UNIVERSITÄT DARMSTADT

- Recall und Precision sind allein leicht zu optimieren
  - Recall: gib einfach alle möglichen Mappings zurück (Kreuzprodukt)
  - → rec = 1
- Precision
  - gib nur Elemente zurück, die fast sicher stimmen
  - → prec nahe 1 sehr wahrscheinlich

- Zwischen beidem existiert offenbar ein Trade-off
- Daher in der Praxis oft genutzt: F-Measure
  - harmonisches Mittel von Recall und Precision
  - 2*prec*rec / (prec +rec)

Auswertung von Mappings

TECHNISCHE UNIVERSITÄT DARMSTADT

- Warum harmonisches Mittel
- ...und nicht einfach arithmetisches Mittel?

- Harmonisches Mittel macht es schwerer, schlechten Recall durch gute Precision auszugleichen
  - Und umgekehrt

- Beispiel: rec=0.1, prec=1.0
  - Arithmetisches Mittel: 0.55
  - Harmonisches Mittel: 0.18

Aktuelle Trends und Herausforderungen

TECHNISCHE UNIVERSITÄT DARMSTADT

- Performance verbessern
  - Jährlicher Wettbewerb: OAEI
  - Manche Probleme nur ~40% F-Measure
  - z.B. Multilinguale Probleme
- Externes Wissen automatisch finden
  - z.B. im Web, in Linked Open Data, …
- Matcher automatisch kombinieren und konfigurieren
- Nutzerfeedback sinnvoll nutzen

Zusammenfassung

TECHNISCHE UNIVERSITÄT DARMSTADT

- Ontology Mappings liefern fehlende Semantik über Datenset-Grenzen
  - Abbildung von Schemata
- Ontology Matching: automatisches Finden von Mappings
  - elementbasiert
  - strukturbasiert
  - mit und ohne externe Quellen

- ...now get your hands dirty!

Vorlesung Semantic Web

TECHNISCHE UNIVERSITÄT DARMSTADT

Vorlesung im Wintersemester 2012/2013

Dr. Heiko Paulheim

Fachgebiet Knowledge Engineering