


Eigennamenerkennung mit großen lexikalischen Ressourcen

*Jörg Didakowski
BBAW*

Was sind Eigennamen?

Sprachliche Zeichen (Eigennamen)



das Bezeichnete (Named Entity)

Was sind Eigennamen?

Eigennamen bezeichnen ein Ding als Ganzes, ohne ihm bestimmte Eigenschaften zuzuschreiben.

Sie identifizieren Objekte innerhalb gekennzeichneteter Klassen.

Was sind Eigennamen?

- Organisationen
- Personen
- Orte
- Produkte
- Zeitangaben
- Datumsangaben
- Währungsangaben

Was sind Eigennamen?

- Organisationen
- Personen
- Orte
- Produkte
- Zeitangaben
- Datumsangaben
- Währungsangaben

Was sind Eigennamen?

- Organisationen
- Personen
- Orte
- Produkte
- ↳ Gattungsnamen oder Stoffnamen
(Opel/Auto, Esso/Wasser)
- Zeitangaben
- Datumsangaben
- Währungsangaben


Offene Klasse

Eigennamen bilden eine Offene Klasse –
täglich werden neue Namen erfunden

Jedes Wort des allgemeinsprachlichen
Lexikons kann zum Eigennamen gemacht
werden (Ihr Name war Dachziegel)


Morphosyntaktische Besonderheiten

Eigennamen treten im Allgemeinen im Singular auf. Ausnahmen sind:

- **Plural bei Familiennamen** → die Bachs
 Keine Umlautbildung (Bach/Bäche)
- **Plural bei Ortsnamen** → Niederlande, Alpen
 nur im Plural
- **Beim Quantifizieren** → beide Deutschlands, die drei Marias

Morphosyntaktische Besonderheiten

Eigennamen können die Form eines possessiven Genitivs einnehmen:

- Evas Auto, Brandenburgs Seen
 artikellos
- Arturo Uis Aufstieg
- Der Aufstieg des Artuo Ui
- *Der Aufstieg des Arturo Uis

Syntaktische Besonderheiten

Eigennamen treten Allgemein ohne Artikel auf:

- Sie liebt _ Frankreich.
- Sie liebt _ Berlin.
- Sie liebt _ Jürgen Klinsmann.

Syntaktische Besonderheiten

Unter bestimmten Bedingungen kann systematisch ein bestimmter Artikel nötig sein:

- die Schweiz
- der Rhein
- das alte Berlin (Spezifische Kontextbedingungen).
- Wenn ein Organisationsname einen Appellativum enthält:
die (Sozialdemokratische Partei
Deutschland) SPD

Syntaktische Besonderheiten

Bestimmter Artikel bei Personennamen,
regionale Unterschiede :

- im Süddeutschen Sprachgebrauch besteht eine Tendenz des konnotationsfreien Gebrauchs von Personennamen mit Artikel.
- In anderen Regionen kann damit auf besonders bekannte Personen oder auch vertraute Personen verwiesen werden.

Syntaktische Besonderheiten

Verwendung des unbestimmten Artikel signalisiert ganz besondere Interpretationsbedingungen:

- Er ist ein Cäsar → Appellativum

Graphematische Besonderheiten

- Durchgehende Großschreibung am Wortanfang (Schwarzes Meer, Kap der Guten Hoffnung)
- das Schwarze Brett / das schwarze Brett

Homographie

- Eigennamen können mehreren Klassen zugeordnet werden:
Ford → Person (Gerhard Ford)
 - Firma (Ford Motors)
 - Ort (Ford Michigan)
 - (→ Produktname (Automarke))
- Homographie zwischen Eigennamen und Appellativen (Fischer, Hirsch)
- Homographie zwischen Eigennamen und anderen Kategorien wegen Satzanfang (z.B. Als. Da. Kühn)

interne Evidenz

- Dr. Bonobo
- Ich GmbH
- „Michael Schumacher“ ->im Lexikon
- Nicht Homographischer Personennamenname (Sabine)
- Nicht Homographischer Ortsname (Wustermark)

externe Evidenz

Menschenbezeichner/Ortsbezeichner/Organisationsbezeichner als Apposition:

der Rennfahrer Schumacher
Schumacher, der Rennfahrer

der Rennstall Sauber
der Schweizer Sauber

Koreferenz

- Sichere Eigennamen (externe/interne Evidenz)
- Unsichere Eigennamen (alle Kategorieabfolgen für einen potentiellen Eigennamen)
- Stützen von unsicheren Eigennamen wegen bestehender Koreferenz mit einem sicheren Eigennamen

Ressourcen

TAGH-Morphologie (gewichteter Transduktor)

lemmatisiert und zerlegt Wortformen

Erkennungsrate bei neuen Zeitungstexten:
98,5% - 99,5%

Ressourcen

- Nomenlexikon: 88.000 einfache und komplexe Stämme
- Eigennamen:
 - 160.000 geographische Eigennamen,
 - 65.000 Vornamen,
 - 240.000 Familiennamen
- Nomenthesaurus: 60.000 semantisch klassifizierte Nomen
- USW.


Ressourcen

Listen von Mehrwortausdrücken


Ortsnamen (New York)
VIP Namen (Harald Schmidt)

Das System (SynCoP)

- In C++ implementiert
- Basiert auf der Potsdam FSMlib




Eigennamenerkennung




Grammatikanwendung

Klammern und gewichten (Longest Match) von
allen sicheren Eigennamen

Klammern und gewichten (Longest Match) von
allen unsicheren Eigennamen




Umgewichten (sicher/unsicher)



Ermitteln der Besten Analyse
(Beste Pfad Suche)

• 10000 Tokens die Sekunde

• An der Grammatik wird noch entwickelt
 Eine erschöpfende Evaluation wurde noch nicht durchgeführt.

Ende