

## NLP - Analyse des Wissensrohstoffs Text

---

Dr. Andreas Hotho  
Dominik Benz  
Beate Krause

Sommersemester 2008



Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 1

## Organisatorisches

---

### Vorlesung

- Beginn: 8. April 2008
- Dienstag 10.15 h - 11.45 h, in Raum 1607 oder 0443

### Übungen

- Beginn: 16. April 2008
- Mittwochs, 10.15 h - 11.45 h, in Raum 1418 (Altbau WA 73)
- wird als Präsenz- und Praxisübung abgehalten (s. nächste Folie)
- Programmierhausaufgaben

### Unterlagen

- siehe Literatur

### Prüfung

- Die Prüfung wird je nach Teilnehmerzahl mündlich oder schriftlich abgehalten.

Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 2

## Organisatorisches

---

- ♦ Mailingliste für alle Studenten die am Fachgebiet eine Vorlesung hören.
- ♦ Die Mailingliste hat den Namen „kde-stud“
- ♦ Um sich einzutragen gehen sie bitte auf die folgende Webseite:  
<https://mail.cs.uni-kassel.de/mailman/listinfo/kde-stud>
- ♦ Die E-Mail-Adresse der Liste lautet:  
[kde-stud@cs.uni-kassel.de](mailto:kde-stud@cs.uni-kassel.de)
- ♦ Über diese Liste werden wir zusätzliche Ankündigungen und Informationen schicken
- ♦ Sie können dort auch Fragen stellen oder diskutieren

Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 3

## Organisatorisches

---

### Präsenzübung bedeutet

- **selbständiges Bearbeiten** des Übungsblattes in Kleingruppen à 3-4 Personen unter Betreuung des Assistenten
- **kein prinzipielles Wiederholen** des Vorlesungsstoffs
- **kein Vorrechnen** der Musterlösung etc.  
(Diese wird später zur Verfügung gestellt.)
- **Nötig dafür:**
  - selbständige Vorlesungsnachbereitung **vor** der Übung
  - Mitbringen des Skriptes
  - eigene Aktivität entfalten

Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 4

## Organisatorisches

---

### Warum ein neues Übungskonzept?

- aktives Erarbeiten des Vorlesungsstoffes bringt mehr
- Zusammenhänge im Stoff erkennen
- strukturiertes Denken und selbständiges Arbeiten lernen
- Teamarbeit lernen
- Erklären lernen (als Tutor und als Teilnehmer)
- Klausurtraining ;-)
- *Ihr Studium der ... haben Sie abgeschlossen. Zu Ihren persönlichen Stärken zählen Sie Eigeninitiative, Kommunikations- und Kooperationsbereitschaft, Teamarbeit.*  
(Typischer Anzeigentext)

## Organisatorisches

---

### Praxisübung – Implementieren einer Suchmaschine

- Ausgabe der ersten Praxisaufgabe zur ersten Übung am 16.4.2008
- Am 23.4.2008 Fragestunde zur Praxisaufgabe
- Abgabe der ersten Praxisaufgabe **bis 29.4.2008 12:00 per Email**
- **Präsentation des Ergebnisses am folgenden Tag**
- Praxisaufgaben im 14 Tagesrhythmus
- 4 von 5 Aufgaben müssen für einen Notenbonus von 0.3 abgegeben werden

## Organisatorisches

---

### Sprechstunden nach Absprache:

Andreas Hotho:	<a href="mailto:hotho@cs.uni-kassel.de">hotho@cs.uni-kassel.de</a>	0561/804-6252
Dominik Benz:	<a href="mailto:benz@cs.uni-kassel.de">benz@cs.uni-kassel.de</a>	0561/804/6266
Beate Krause:	<a href="mailto:krause@cs.uni-kassel.de">krause@cs.uni-kassel.de</a>	0561/804/6254

FG Wissensverarbeitung, FB Mathematik/Informatik  
Raum 0440, Wilhelmshöher Allee 73

Informationen im Internet: <http://www.kde.cs.uni-kassel.de>

Hier ist u.a. folgendes zu finden:

- aktuelle Ankündigungen
- Folienkopien
- Übungsblätter
- Literaturempfehlungen
- Termine



## Empfohlene Literatur

- ♦ Manning Ch. D./H. Schütze (1999). Foundations of Statistical Natural Language Processing. Cambridge: The MIT Press.
- ♦ Carstensen, K./Ch. Ebert/C. Endriss/S. Jekat/R. Klafunde/H. Langer (2004). Computerlinguistik und Sprachtechnologie. Eine Einführung. 2. Aufl. Heidelberg: Elsevier.
- ♦ Jurafsky, D./J.H. Martin (2000). Speech and Language Processing. An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition. Upper Saddle River: Prentice Hall.

## Übersicht

- Einführung
- Eigenschaften von Text
- Words I: Satzgrenzenerkennung, Tokenization, Kollokationen
- Words II: N-Gram-Modelle, Morphologie
- Tagging I: Transformationsbasiertes Tagging
- Tagging II: Hidden Markov Modelle
- Parsing I: Kontextfreie Grammatiken (CFG)
- Parsing II: probabilistisches Parsing
- Semantik I: Lexikalische Semantik (Lexeme, Homonymie, Homographie, Homophonie...)
- Semantik II: Wortbedeutungsdisambiguierung
- Applikationen I: Text Summarization
- Applikationen II: Textübersetzung, Wortsinnerkennung...

**Viele der Vorlesungsfolien wurden aus der Vorlesung:**

**„Symbolische und statistische Verfahren“**

**übernommen.**



Jan Strunk

## Gegenstand der Computerlinguistik

- ♦ Gegenstand der Computerlinguistik sind Formalismen, Algorithmen und Verfahren zur maschinellen Verarbeitung natürlicher Sprache.
- ♦ Es geht also darum, wie man mit dem Computer natürliche Sprache verarbeiten kann.
- ♦ Sind Ihnen schon Beispiele für Sprachtechnologie begegnet?
  - Maschinelle Übersetzung (z.B. bei Google oder Alta Vista)
  - Spracherkennung (Diktiersoftware, Sprachsteuerung)
  - Rechtschreib- und Grammatikprüfung
  - Einfache Dialogsysteme z.B. beim Telefonbanking
  - ...

## Die (weitentfernten) Ziele der Computerlinguistik

- ♦ Kommunikation mit dem Computer in natürlicher Sprache (Sprachverstehen)
  - Beispiele: Star Trek, HAL, etc.
- ♦ Bearbeitung sprachlicher Aufgaben durch den Computer
  - Automatische Generierung von Texten
  - Übersetzung
  - Korrektur
  - Usw.
- ♦ Erschließung von Wissen aus Texten
  - Semantisches Web
  - Informationsextraktion

## Definition Natural Language Processing (NLP)

- ◆ „Verarbeitung Natürlicher Sprache“ (VNS)
  - ist ein Teilbereich der Computerlinguistik
  - befasst sich mit
    - dem automatischen **Erzeugen** sowie
    - dem automatischen **Verstehen**natürlicher (menschlicher) Sprache (in geschriebener / gesprochener Form)
- ◆ Teilbereiche:
  - Formalismen zur Repräsentation der Bedeutung
  - Algorithmen zur „Transformation“ Bedeutung ↔ Sprache
    - Symbolische / Statistische Ansätze (→ „Statistical NLP“, s.u.)

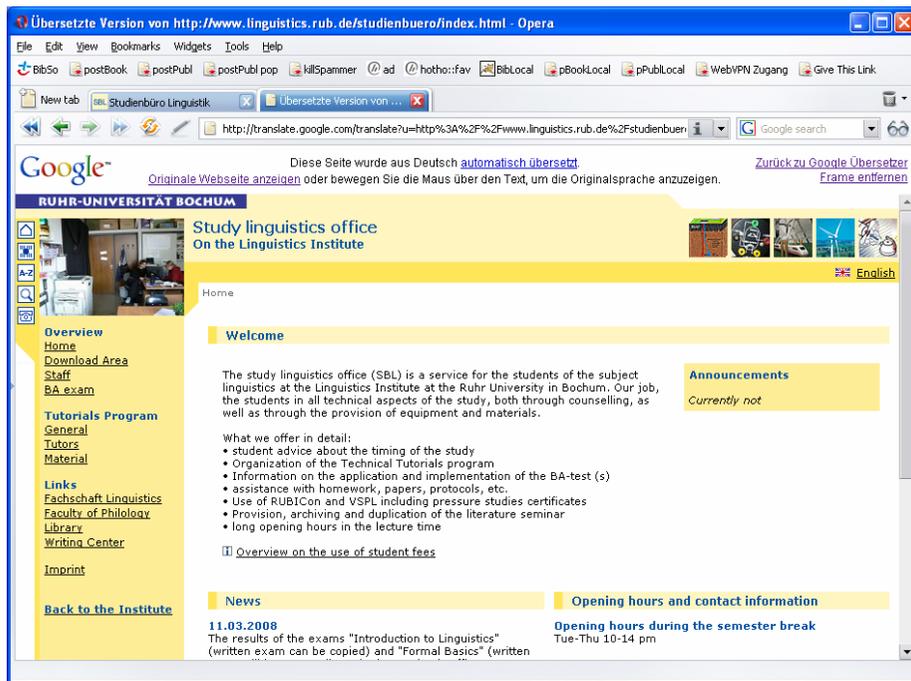
## Gegenstand der Computerlinguistik: Beispiel MÜ

- ◆ Was sind Teilaufgaben bei der maschinellen Übersetzung?
  - Analyse der Struktur des Satzes in der Ursprungssprache
  - Analyse der Bedeutung in der Ursprungssprache
  - Übertragung der Bedeutung in die Zielsprache
    - Auswahl geeigneter Lexeme und Konstruktionen
  - Generierung einer grammatischen Struktur in der Zielsprache
- ◆ Besondere Herausforderungen, die die automatische Sprachverarbeitung schwierig machen
  - Ambiguität (Mehrdeutigkeit)
    - Lexikalisch oder strukturell
  - Produktivität (unbegrenzte Anzahl von möglichen Sätzen und Wörtern)
  - Kontextabhängigkeit von Bedeutung und Form

## Gegenstand der Computerlinguistik: Beispiel MÜ

- ◆ Beispiel:
  - Lassen Sie von Google die Seite des Studienbüros der Linguistik vom Deutschen ins Englische übersetzen
  - <http://www.linguistics.rub.de/studienbuero/index.html>
  - [http://translate.google.com/translate\\_t?hl=de](http://translate.google.com/translate_t?hl=de)
- ◆ Auftretende Probleme:
  - Unvollständige oder falsche syntaktische Analyse
  - Lexikalische Ambiguität (Mehrdeutigkeit)  
*Ablauf = Verlauf und Ablauf = Ende*
  - Unbekannte Wörter (z.B. *Studienbüro*)
  - Korrekte Interpretation des Pronomens *ihr* abhängig vom Kontext  
*Ab sofort findet ihr auf unserer Seite auch Infos zur B.A.-Prüfung.*  
*From now finds her on our side also about the B.A.-Prüfung.*

The screenshot shows a web browser window titled "Studienbüro Linguistik - Opera". The address bar displays "http://www.linguistics.rub.de/studienbuero/index.html". The page content includes a navigation menu on the left with links like "Übersicht", "Startseite", "Downloadbereich", "Mitarbeiter", "B.A.-Prüfung", "Tutorienprogramm", "Allgemeines", "Tutorien", "Material", "Links", "Fachschaft Linguistik", "Fakultät für Philologie", "Bibliothek", "Schreibzentrum", and "Impressum". The main content area features a "Herzlich Willkommen" section, an "Ankündigungen" section with the text "momentan keine", and an "Aktuelles" section dated "11.03.2008" regarding exam results. A "Öffnungszeiten und Kontaktdaten" section at the bottom right lists the office hours and location: "Raum GB 3/157 (Gebäude GB, Etage 3, Raum 157)".



## Gegenstand des Kurses

- ◆ Wir werden uns in diesem Kurs allerdings nicht intensiv mit solch komplexen Problemen wie der automatischen Übersetzung oder der Steuerung des Computers mittels natürlicher Sprache beschäftigen
- ◆ Beschränkung auf die Verarbeitung geschriebener Sprache
- ◆ Betrachtung von grundlegenden Problemen bei der Verarbeitung natürlicher Sprache
  - Auflösung von Ambiguität (Disambiguierung)
  - Umgang mit Produktivität
  - Modellierung von Kontextabhängigkeit

Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 18

## Gegenstand des Kurses

- ◆ Vorstellung grundlegender Algorithmen und Ansätze zur Lösung dieser Probleme
  - Vorverarbeitung von Textdaten
  - Strukturelle Analyse (Parsing)
  - Klassifikation (z.B. zur Disambiguierung)
  - Maschinenlernverfahren
- ◆ Verfahren zum Testen und zur Evaluation von computerlinguistischen Systemen

Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 19

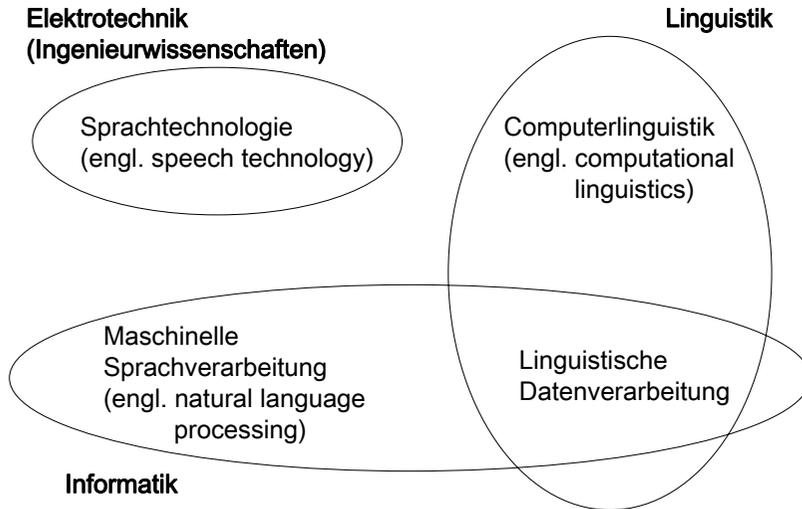
## Gegenstand des Kurses

- ◆ Am Ende des Kurses sollten Sie also gelernt haben
  - Welche Herausforderungen bei der Verarbeitung natürlicher Sprache auftreten,
  - Was gängige Ansätze zur Lösung dieser Herausforderungen sind (illustriert an Hand einzelner Teilprobleme),
  - Was es für Standards und Verfahren bei der Evaluation computerlinguistischer Systeme gibt.
  - Einblicke in einige der typischen Anwendungsfelder der Computerlinguistik bekommen haben.
- ◆ Sie sollten dann auch fähig sein, kleinere computerlinguistische Systeme selbständig zu implementieren und zu evaluieren.

Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 20

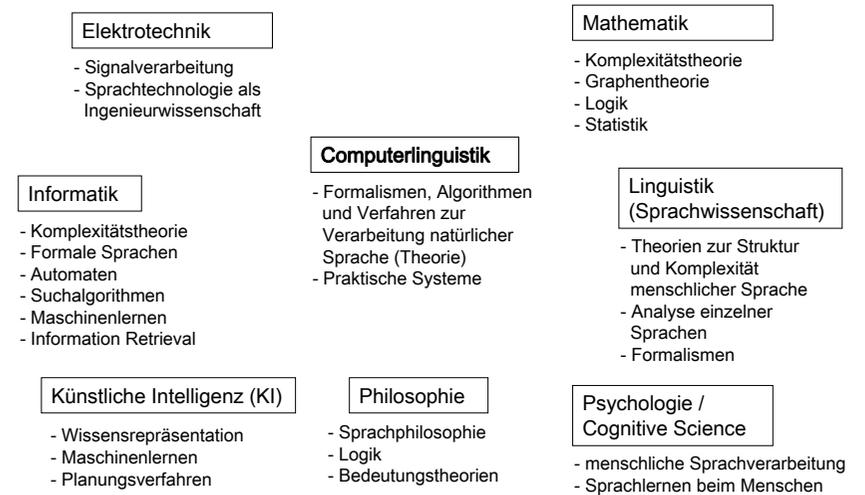
## Beschäftigung mit der Verarbeitung menschlicher Sprache



Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 21

## Computerlinguistik und ihre Nachbardisziplinen



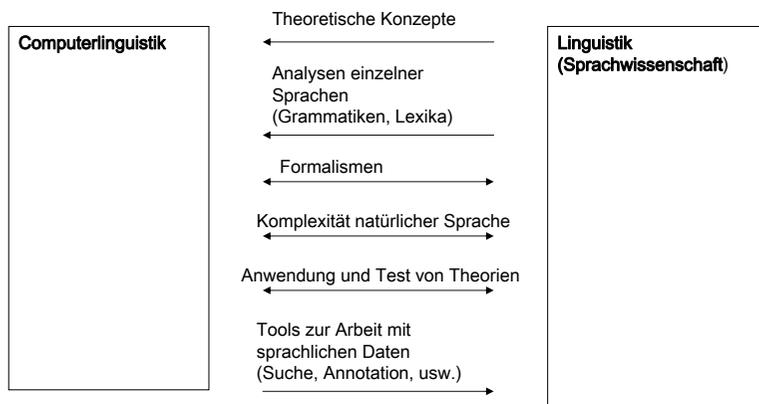
(Frei nach Klabunde et al. 2004)

Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 22

## Computerlinguistik und ihre Nachbardisziplinen

- ◆ Verhältnis von Computerlinguistik und theoretischer Linguistik



Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 23

## Symbolische und statistische Verfahren

- ◆ Symbolische Verfahren
  - Basieren auf Regeln
  - Was sind mögliche / unmögliche Strukturen?
  - Regeln werden meist von menschlichen Experten formuliert
  - Beispiel: Strukturanalyse (Parsing) eines Satzes mit Hilfe einer formalen Grammatik
- ◆ Statistische (stochastische) Verfahren
  - Basieren auf statistischen Modellen, die auf einer großen Menge von Daten trainiert werden („datengetrieben“)
  - Was sind wahrscheinliche / unwahrscheinliche Strukturen?
  - Daten werden oft von menschlichen Experten annotiert
  - Beispiel: Sprachmodelle – z.B. im Handy „Welches Wort ist am wahrscheinlichsten gegeben eine Folge von mehrdeutigen Eingaben und den vorangegangenen Kontext?“

Vorlesung: NLP - Analyse des Wissensrohstoffs Text

Folie: 24

## Symbolische und statistische Verfahren – Geschichtlicher Abriss

- ◆ Erste Überlegungen zur MÜ auf Basis der Informationstheorie (Stochastik)
- ◆ Chomskys (1957) Behauptung, dass statistische Ansätze nicht der Produktivität der Sprache gerecht werden:  
*Colorless green ideas sleep furiously.* vs.  
*\*Furiously sleep ideas green colorless.*  
(Nach Chomskys Ansicht beide gleich unwahrscheinlich)
- ◆ Symbolische Verfahren in der syntaktischen und semantischen Analyse und in der maschinellen Übersetzung
- ◆ Statistische Verfahren bei der Erkennung gesprochener Sprache
- ◆ Heute: Kombination symbolischer und statistischer Verfahren, um die Vorteile beider Paradigmen zu kombinieren
  - Z.B. Probabilistische kontextfreie Grammatiken
  - Vermehrte Einbindung von linguistischem Wissen in Sprachmodelle zur automatischen Spracherkennung

## Geschichte der Computerlinguistik

2005	Dokumentenretrieval für gesprochene Sprache
2000	Integration von flacher und tiefer Verarbeitung Fragebeantwortung für offene Textkorpora MÜ für gesprochene Sprache
	Informationsextraktion
1990	stochastisches Parsing stochastisches Tagging Constraint-basierte Grammatiken Vererbung im Lexikon Unifikationsgrammatiken, Zweibenenmorphologie
1980	Dialektsrepräsentationstheorie
	MÜ im Routineeinsatz Rechtschreibfehlerkorrektur
1970	ATN-Grammatiken natürlichsprachliche Datenbankabfrage Automatische Silbentrennung
	Morphologische Analyse
1960	syntaktisches Parsing mit CFG
	experimentelle MÜ Sprachverarbeitung als Zeichenkettenmanipulation
1950	Erste Gedankenexperimente

Abbildung 1.1: Zeitliche Entwicklung der Computerlinguistik-Konzepte (links) und Anwendungen (rechts)

(aus Klabunde et al. 2004, S. 22)

## Heutige Bedeutung der Computerlinguistik

- ◆ Handys
  - Texteingabe (T9)
- ◆ Sprachausgabe
  - Navigationsgeräte
- ◆ Sprachsteuerung
  - Navigationsgeräte
  - Handys
  - Dialogsysteme (Telefonservice)
- ◆ Internet
  - Texttechnologie
  - Informationsextraktion
  - Information Retrieval
  - Übersetzung
- ◆ Semantic Web
  - Suche nach Konzepten statt nach Wörtern
  - Automatische Informationserschließung