

Zählen & Zerlegen

Ein Algorithmus zur morphologischen Segmentierung von Texten

FELIX GOLCHER betreut von ANKE LÜDELING

Humboldt-Universität zu Berlin — Institut für deutsche Sprache und Linguistik — Korpuslinguistik



Worum geht's?

- Die Zerlegung eines Textes in seine Einzelteile ist Voraussetzung jeder maschinellen Verarbeitung.
 - Leerzeichen trennen Worte, aber nicht Morpheme.
 - Nicht alle Sprachen verwenden Leerzeichen.
- ⇒ Das Problem ist wichtig und keineswegs trivial.
Hier wird kein Lexikon verwendet, nur unannotierter Trainingstext.

Grundprinzip

Nach vorne


- Das **h** nach **accomplis** ist vorhersagbar.
- Das dann folgende **e** viel weniger.

Nach hinten

- Das **Leerzeichen** vor **accomplish** ist vorhersagbar.
- Das **S** davor viel weniger.

⇒ Der Satz wird vollständig in Zeichenketten mit dieser Eigenschaft zerlegt.

h e h a s a c c o m p l i s h e d s o m e



Was das Bild bedeutet

- Die Grautöne bedeuten Häufigkeiten.
- Je dunkler, desto häufiger.
- Das Leerzeichen ist am häufigsten.
- Dann kommt das **e**.
- Der rote Punkt markiert **COM**.
- Schwarze und weiße Punkte kennzeichnen Segmente für die die Vorhersagbarkeit vorne und hinten abfällt.
- Die weißen Punkte ergeben sinnvolle Segmentierungen des ganzen Satzes.

Wie der Algorithmus arbeitet

- Der von **gelb**→**rote** Pfad ist der Weg des Algorithmus.
- Startpunkt ist links oben.
- Nach rechts bis die Vorhersagbarkeit in beide Richtungen abfällt.
- Nach unten bis zur Diagonalen.
- Von vorne.
- Falls eine Sackgasse ("X") vorliegt, springen wir zurück.

Was dann noch passiert

- Dieses Verfahren liefert noch ambige Segmentierungen.
⇒ Im Bild als gestrichelte Linien gezeigt.
- Verschieden(st)e Heuristiken zur Disambiguierung wurden verglichen.
- Übrig bleibt:

([he] [has])([{accomp} {lish}] [ed])(some)

Literatur

Bebel, August (2004). *Aus meinem Leben – Erster Teil*¹. URL: <http://www.gutenberg.org/files/12267/12267-8.txt> (besucht am 17. 11. 2006).

Harris, Zellig S. (1955). "From Phoneme to Morpheme". In: *Language* 31.2. reprinted in Hiž 1970, S. 190–222.

Hiž, Henry, Hrsg. (1970). *Papers in Structural and Transformational Linguistics*. Holland: Dordrecht.

R Development Core Team (2011). *R: A Language and Environment for Statistical Computing*. ISBN 3-900051-07-0. R Foundation for Statistical Computing. Vienna, Austria. URL: <http://www.R-project.org/>.