

# Wie aus Korpora ermittelte Grundformhäufigkeiten und Kookkurrenzen bei der Beschreibung des Sprachgebrauchs helfen können

Rainer Perkuhn

Neues aus der korpuslinguistischen Forschung  
am Institut für Deutsche Sprache

Tokyo, 19.3.2008

---


---

# Beispiel: grammis

## Grammatik in Fragen und Antworten

- Projektgruppe:  
Bruno Strecker, Elke Donalies,  
Marek Konopka, Jacqueline Kubczak
  - Erstellung von Artikeln zu grammatisch relevanten Fragestellungen
  - Mischung konkret/grundsätzlich
  - seit ca. einem Jahr online
-

# Fragen ...



---

# Fragen bearbeiten


- Grammatiken heranziehen
    - ✍ Sachverhalt und geschichtlichen Hintergrund beschreiben
  - Daten befragen
    - DEREKO, speziell neue Rechtschreibung
    - World Wide Web über google, speziell Chatrooms
  - quantitativ bewerten, ggf. Tendenzen
    - ✍ Trend beschreiben, Empfehlung formulieren
-

---

# Beispiel


- heißt es „backte“ oder „buk“?
  - Sprachgebrauch weicht von Grammatiken ab
  - nicht „entweder-oder“, sondern „sowohl-als-auch“
  - zeitliche Entwicklung
  - ggf. andere Dimensionen interessant, bisher noch nicht systematisch methodisch unterstützt
-

# Zeitliche Entwicklung



backte

vs.



buk

---

# Probleme

- Anfragen schwierig exakt zu formulieren
    - Wortformen
    - Paradigmen einer Grundform (bukst, bukest?)
    - Wortkombinationen (Stellung und Variabilität)
  - Dimensionen erkennen, in Einflussfaktoren zerlegen
    - gesprochene vs. geschriebene Sprache
    - Zeit, Region, Dialekt
  - im World Wide Web so gut wie unmöglich
  - in geeigneten Korpora grundsätzlich machbar
    - Daten fortschreiben, Methodik verfeinern
-

---

# WWW vs. DEREKO

- schnelle Suche in großen Datenmengen
    - mit Hilfe von Google um Informationen (Webseiten) zu finden
    - mit Hilfe von COSMAS um sprachlichen Phänomenen nachzuspüren
  - Zusammensetzung der Daten (nicht) kontrollierbar
  - Bedeutung von Sonderzeichen?
  - Behandlung von Funktionswörtern?
  - Behandlung von Wortbildung?
  - Verknüpfungen (logisch, Abstand)?
-

---

# Gebrauch vs. Norm

- d.. Nutella?
  - wegen dem Ändern der Rechtschreibung braucht der einzige Papst noch lange nach Aldi gehen, um der Nutella kaufen
  - wer „brauchen“ ohne „zu“ gebraucht, braucht „brauchen“ gar nicht zu gebrauchen
  - der Dativ ist dem Genitiv sein Tod
-


---

# „Gebrauch“ von „ge-/brauchen“ oder „Brauch“?

- Sprachgebrauch setzt sich über Normen hinweg und hat eigene Gesetzmäßigkeiten (brauchen wir ein Wort für „nicht durstig“?)
  - das, worüber wir nur im Einzelfall stolpern (weil unser Gefühl sich einmischt), steht stellvertretend für all die Schwierigkeiten, die beim Erlernen (oder Begreifen) der Sprache auftreten ...
-


---

# Bedarf und geteilter Brauch




# Aussagekraft?

Anteil von  
Gebrauch mit  
Artikel



# Aussagekraft?

Anteil  
Gebrauch  
insgesamt



---

# „Deutung“

- kaum Aussagekraft
    - „der“ ist aus dem Rennen
    - ob Tendenz für „die“ abzulesen ist, bleibt fragwürdig, zumal „die“ mehr als drei Mal häufiger ist als „das“ (50 Mio. vs. 14.5 Mio.)
  - wenig Gebrauch mit Artikel
    - gibt es überhaupt Bedarf sich zu einigen?
    - ist die Frage in diesem Fall relevant?
-

---

# Präferenzen

- ob Notwendigkeit besteht, sich auf eine präferierte Form zu einigen, zeigt sich
    - über einen längeren Zeitraum ...
    - über viele Menschen hinweg ...
  - gut beobachtbar:  
öffentlicher Schriftsprachgebrauch  
(Medien prägen stärker als Literatur)
-

---

# Sprachgebrauch beschreiben

- korpusbasiert (DEREKO bekannt)
  - Methodik bereits angesprochen
  - nicht betrachtet:
    - alle Vorkommen werden beschrieben
    - nur einzelne Beispiele werden willkürlich ausgewählt
  - zur Bewertung Typikalitäts- bzw. Relevanzbegriff erforderlich
-

---

# Relevanz?

- Beschreibungen unterschiedlichster Art
  - Nachschlagewerke und Lehrmaterial
  - lehrer- oder schülerzentriert
  - Sprachverstehen oder -erzeugen
  - Alltagssituation oder Standardsprache
-

---

# Mögliche Kriterien

- Häufigkeiten („Frequenzen“)
  - Kookkurrenzen
  - Grundwortschätze
  - Verwendungssituationen  
(vgl. Referenzrahmen)
-

---

# Worthäufigkeiten

- Wortformen vs. Grundformen
  - Wortformen unnötig umfangreich
  - Ungleichverteilung bei der Vielfalt im Paradigma
  - vgl. Lemmabegriff in der Lexikografie
  - vgl. Geläufigkeit in der Psychologie
-

---

# Übersicht über Problembereiche

- Groß-/Kleinschreibung
  - Trennzeichen/Bindestrich-schreibungen
  - Neubildungen/Neologismen
  - Fremdwörter/Anglizismen
  - diskontinuierliche Konstituenten
  - Eigennamen
  - adjektivisch gebrauchte Partizipien
  - Regionalismen
  - Varianten/Varietäten (sprachlich regional, dialektal, Reform: Getrennt-/Zusammenschreibung)
  - Kurzwörter
  - Akronyme, Abkürzungen z.B.
  - unselbstständige Morpheme
  - Verschmelzungen
  - Movierung
  - Häufigkeitsklassen (grafik!!)
  - Grundformnennung
-

---

# „Schiefelage“ in den Daten

- „Unausgewogenheit“ in der Zusammensetzung der Daten („zuviel Sport oder Polizeiberichte“)
  - virtuelles Korpus mit entsprechend gedämpften Anteilen
-

---

# Regionalismen

- regional Überrepräsentiertes  
(aus dem Großraum Mannheim)
  - Ausreißer statistisch abschätzen und  
menschlich bewerten
  - ggf. aufgrund Vergleichswerte anderer  
Daten Frequenz anpassen
-

---

# Präverbfügungen

- aka: abtrennbare Präfixe
  - diskontinuierliche Konstituenten nicht zuverlässig automatisch zu erkennen
  - Verteilung, welche Formen wie oft mit/ohne Präfix vorkommen, anhand von Testdaten abschätzen
  - Werte für betroffene Grundformen neu abschätzen (Fügung↑, Präposition↓, Grundverb↓)
-

---

# Eigennamen

- für welche Werke überhaupt relevant?
  - Überlappungen verfälschen Frequenzen:  
„Kohl“ als Bundeskanzler oder als  
Gemüse
  - stichprobenartig Vorkommen einordnen,  
Verteilung abschätzen und auf Gesamtheit  
hochrechnen
-

---

# Lemmatisieren

- prinzipiell theoretisch verstanden
  - Flektion, Derivation, Komposition
  - aber:
    - Mehrdeutigkeiten („Floh“ von „fliehen“ oder „Floh“)
    - sprachliche Kreativität überschreitet Grenzen („einzig“ doch steigerbar?)
    - Sprachwandel kann nicht vorausgeahnt werden
-

---

# Adjektivisch gebrauchte Partizipien

- „spannend“ vs. „entspannend“:  
eigene Grundform (da Adjektiv) oder nur  
Teil des Paradigmas des Verbs?
-

---

# Neubildungen/Neologismen

- unbekannte Paradigmen bzw. Erweiterung
  - Abweichen von bisher nicht durchbrochenen Konventionen (z.B. „politischste“)
  - neue Paradigmen empirisch erschließen
-

---

# Nennung der Grundform

- immer dieselbe Form aus dem Paradigma?
  - selbst wenn diese gar nicht belegt ist?
  - selbst wenn diese nicht alle Formen des Paradigmas suggeriert?
-

---

# Wörterbuchabgleich

- Probleme: Lücken und Leichen
- Abgleich kaum aussagekräftig
  - kein Sortierkriterium für Relevanz
  - Vergleichswörterbücher stehen nicht in beliebigem Umfang zur Verfügung



---

# Angabe der Häufigkeit

- Häufigkeiten, egal ob absolut oder relativ, sind keine aussagekräftigen Größen
    - nicht vergleichbar mit anderen Korpora gleicher oder unterschiedlicher Größe
  - bewährt haben sich Häufigkeitsklassen, die das Verhältnis zur Frequenz des häufigsten Eintrags ausdrücken („der/die/das“)
    - vergleichbar mit anderen Korpora gleicher oder unterschiedlicher Größe
-

---

# Häufigkeitsklassen

- Verhältnis logarithmisch (wie oft zu verdoppeln?)

$$N = \text{hk}(\text{lemma}) := \lfloor \log_2(f(d-)/f(\text{lemma})) \rfloor$$

$$\text{also: } f(\text{lemma}) \approx f(d-)/2^N$$

N =	0	1	2	3	4	5		10		17
2 <sup>N</sup> =	2 <sup>0</sup>	2 <sup>1</sup>	2 <sup>2</sup>	2 <sup>3</sup>	2 <sup>4</sup>	2 <sup>5</sup>	...	2 <sup>10</sup>	...	2 <sup>17</sup>
2 <sup>N</sup> =	1	2	4	8	16	32		1024		131072
Bsp.	d-	...	und	von	als	Jahr		aktuell		Lachmuskel

---

- 
- Zusammenspiel von Einheiten in Welt und Sprache und innerhalb der Sprache in vielen Aspekten nicht formal definierbar oder regelgeleitet ...
-

---

# „Fürwahr“

- Wiebke, 9 Jahre:  
[als Reaktion auf ein scherzhaftes  
„Wohl bekomm’s“]  
„Fürwahr ... ich weiß zwar nicht, was es  
bedeutet, aber ich finde, es passt  
irgendwie ...“
-








---

# Annahme

- die fundamentalen Mechanismen der Sprache  
(sicher: ihres Erwerbs,  
vermutlich auch: ihrer kognitiven Verarbeitung)
    - sind nicht direkt oder per Introspektion zu erheben
    - sind partiell funktional äquivalent zu einer statistischen  
Bewertung des Kontextverhaltens der Wörter im  
,Sprachinput'
  - vgl. Mathematik beim Straßenüberqueren
-



$$S_{auto} = v_{auto} \cdot t_{auto}$$

$$S_{ich} = v_{ich} \cdot t_{ich}$$

$$\tan(\alpha) = \frac{S_{auto}}{S_{ich}}$$

$$\tan(\alpha) = \frac{v_{auto} \cdot t_{auto}}{v_{ich} \cdot t_{ich}}$$

$$\tan(\alpha) \cdot \frac{v_{ich}}{v_{auto}} = \frac{t_{auto}}{t_{ich}}$$

$$t_{ich} < t_{auto} \Leftrightarrow 1 < \frac{t_{auto}}{t_{ich}}$$

$$1 < \tan(\alpha) \cdot \frac{v_{ich}}{v_{auto}}$$

---

# Kookkurrenz wichtig, weil ...

- Annäherung an Bündelung von Ereignissen, die Musterhaftes enthalten als Input für unseren „kognitiven Apparat“
  - kompakte Präsentation kann den langwierigen Prozeß des Wartens auf „vergleichbare Ereignisse“ verkürzen
-

---

# Kookkurrenz

- bezogen auf eine bestimmte Datengrundlage
  - hier: ideal für Beschreibung mit Ziel
    - Verstehen geschriebene Standardsprache
  - anzupassen für andere Ziele
  - Bezugswörter oder Kookkurrenzpartner auf bestimmte Wortschätze (z.B. Referenzrahmen A1) filtern
-

---


# Wortschatz/Referenzrahmen

- Wortschatz „veraltet“
  - Referenzrahmen nicht extensional
  - Reflektion anhand Häufigkeiten
  - welche Wörter werden häufig in den vom Referenzrahmen beschriebenen Situationen eingesetzt? (hier fehlt die Vorarbeit!!!)
-

---

# Entscheidung?

- Entscheidung aus Zusammenspiel aller Mitspieler
  - Häufigkeit in Wechselwirkung mit Referenzwortschätzen
  - Kookkurrenzen
-



---

# Nicht gelöst ...

- Rezeption vs. Produktion
  - (mündliche) private Kommunikation vs. (schriftlicher) öffentlicher Diskurs
  - regional vs. überregional
  - literarische Sprache lesen können vs. bei (oder auch nach 😊) Geschäftsverhandlungen sicher auftreten können
-

---

## Nicht gelöst ...

- „Helferlein-Wörter“, nicht unbedingt standard-nahe Wörter, die Verstehens- oder Formulierungsprobleme überspielen helfen
    - vgl. „truc“ = „Ding“
    - „machen“, „tun“
-

---

# Vielen Dank ...

... für Ihre Aufmerksamkeit.

Informationen zur Methodik:

<http://www.ids-mannheim.de/kl/>

[korpuslinguistik@ids-mannheim.de](mailto:korpuslinguistik@ids-mannheim.de)

---