

Computergestützte Korpuslinguistik und die Kollokationstheorie

PS: Computerlinguistik

Kristin Dill

Korpuslinguistik

- Die **Korpuslinguistik** ist ein Bereich der Linguistik, in dem Theorien über Sprache anhand von Belegen oder statistischen Daten aus Textkorpora aufgestellt oder überprüft werden.
- induktive/empirische Methode
- steht im Gegensatz zu deduktiven Methoden:
- Ziel: bestimmte sprachliche Phänomene aufzuzeigen oder bestehende Theorien zu falsifizieren.

Das Korpus/Corpus

- Das Korpus/Corpus
- „[e]ndliche Menge von konkreten sprachlichen Äußerungen, die als empirische Grundlage für sprachwiss. Untersuchungen dienen.“ (Bußmann)
- eine Sammlung bestehend aus Texten mündlicher und/oder schriftlicher Äußerungen
- wurde nach einem bestimmten Verfahren mit einem bestimmten Zweck erstellt
- Beispiele: Zeitungsarchive, Lehrkorpora zu Übungszwecken, Sammlung von Hörtexten oder Hörbeispielen, das Internet, **sehr große digitale Datenbanken**

Beispiele von sehr großen digitalen Datenbanken in der deutschen Sprache

- Leipzig

wortschatz.uni-leipzig.de

- Cosmas II

www.ids-mannheim.de

- Tiger

www.tigersearch.de

- DWDS

www.dwds.de



W O R T S C H A T Z
U N I V E R S I T Ä T L E I P Z I G



DWDS

Benützung:

- Lexik: Herstellung und Verbesserung von Wörterbüchern
- Semantik: Hilfe mit Fremdsprachenlernen
- Linguistik allgemein: sprachwissenschaftliche Untersuchungen,
- statistische Kollokationsbestimmung

Der Kollokationsbegriff und Korpuslinguistik

- eingeführt von J.R. Firth von der Londoner Schule (Kontextualismus)
- seit den 80er und 90er Jahren sind Kollokationen in der Linguistik relevant geworden.



die Zähne reinigen?



Sind die rechten Ausdrücke falsch?

- die Zähne putzen ?die Zähne bürsten
- einen Vortrag halten ?einen Vortrag geben
- den Faden verlieren ?sie verliert schnell einen Faden
- eine Entscheidung fällen ?eine Auswahl/Wahl fällen
- to commit murder ?to perform murder

Was sind Kollokationen?

- Terminus für charakteristische, häufig auftretende Wortverbindungen, deren Miteinandervorkommen auf einer Regelmäßigkeit gegenseitiger Erwartbarkeit beruht, also primär semantisch (nicht grammatisch) begründet wird. (Bußmann)
- besteht aus zwei oder mehreren Wörtern und drückt einen Inhalt aus
- Bestandteile nicht substituierbar und nicht modifizierbar
- auch Begriff für das Miteinandervorkommen von Wörtern

Unterschiedlicher Gebrauch des Begriffes

- Kollokationsbegriff beschreibt eine heterogene Sammlung von Wortverbindungen
- semantische, syntaktische und **statistische** Kriterien zur Ausgrenzung K. gegenüber anderen Wortarten
- freie Wortverbindungen bis Idiome
- benachbarte Konzepte: Sprichwörter (Wer nicht wagt, der nicht gewinnt), Floskeln, (soviel ich weiß, ...) Idiome (an den Nagel hängen), Funktionsverbgefüge (zum Ausdruck kommen)

Wichtiger Bestandteil der Sprache

- **wichtiger Bestandteil der Sprache**
- **vielleicht 70% von Sprachäußerungen in einem Korpus bestehen aus kombinatorischen wiederkehrenden Wortverbindungen (Altenberg)**
- **obwohl Möglichkeit einer unbegrenzten Kombination von einfachen linguistischen Einheiten (Chomsky) existiert, verwenden Sprecher etablierte Mehrwortverbindungen**

Kollokationen in der computergestützten Korpuslinguistik

- empirisch bestimmen, wie oft gewisse Wörter in Kombination mit anderen auftreten (vs. Intuition)
- je mehr Sprachäußerungen und je variabler die Kontexte in dem Korpus, desto besser die Ergebnisse für empirische Untersuchungen
- maschinelle Verarbeitung von sehr großen Textsammlungen vor den 90er Jahren kaum durchführbar

Statistische Kollokationsbestimmung

- statistisch gesehen sind Kollokationen Wörterkombinationen, die signifikant häufiger in einem Text miteinander vorkommen (Kookkurenz), als vom Zufall erwartet werden kann
- statistische Methoden werden angewendet, um eine Liste von Kollokationskandidaten aus einem Korpus zu erzeugen
- dazu braucht man durchsuchbare Textsammlungen: Text Mining, POS-Tagging, Konkordanzprogramme


DWDS: Das digitale Wörterbuch der deutschen Sprache des 20. Jh.

- DWDS-Kerncorpus: zeitlich und nach Textsorten ausgewogenes Corpus des gesamten 20. Jahrhunderts.
- Umfang: 100 Millionen Textwörter (tokens) in 79.830 Dokumenten.
- Textgrundlage: zur Bibliographischen Datenbank der Corpus-Texte
- lemmatisiert, mit Wortartinformationen versehen und mit einer linguistischen Suchmaschine abfragbar
- annotiert gemäß XML/TEI.
- eingebaute statistische Verfahren, um Kollokationen automatisch zu generieren
- <http://www.dwds.de/cgi-bin/rest/loginstart?&kompakt=1&qu=Gefühl>


Automatisch berechnete Kollokationen

- **#w1** **Suchbegriff (Kollokant)**
- **F(w1)** **Frequenz des Kollokants**
- **W2** **Kollokat (node)**
- **F(w2)** **Frequenz des Kollokats**
- **F(w1,w2)** **Frequenz des Bigrams**
- **MI** **Mutual Information**
- **T-Score** **T-Score**
- **Log-L.** **Log-Likelihood**

Automatisch berechnete Kollokationen aus dem DWDS Kerncorpus (lemmabasiert)



Statistik als erster Schritt der Korpuslinguistik



- nur Kookurrenz und Kollokations-Kandidaten
- empirische Basis der Recherche
- qualitative linguistische Analyseverfahren
notwendig: syntaktische und semantische Untersuchungen
- bestimmte sprachliche Phänomene aufzuzeigen oder bestehende Theorien zu falsifizieren

Literatur:

- Anderman, Gunilla M. [Hrsg.] : Incorporating corpora : the linguist and the translator / ed. by Gunilla Anderman - Clevedon [u.a.] : Multilingual Matters , 2008 .
- Bahns, Jens : Kollokationen als lexikographisches Problem : eine Analyse allgemeiner und spezieller Lernerwörterbücher des Englischen / Jens Bahns . - Tübingen : Niemeyer , 1996 .
- Dietrich, Wolf (Philologe) [Hrsg.] : Lexikalische Semantik und Korpuslinguistik / Wolf Dietrich ... (Hrsg.) . - Tübingen : Narr , 2006 .
- Lehr, Andrea : Kollokationen und maschinenlesbare Korpora : ein operationales Analysemodell zum Aufbau lexikalischer Netze / Andrea Lehr . - Tübingen : Niemeyer , 1996 . Porzig, Walter : Das Wunder der
- Ludewig, Petra : Korpusbasiertes Kollokationslernen : Computer-Assisted Language Learning als prototypisches Anwendungsszenario der Computerlinguistik / Petra Ludewig . - Frankfurt a.M. ; Wien [u.a.] : Lang , 2005 .
- Reder, Anna. Kollokationen in der Wortschatzarbeit . Wien: Praesens-Verl. 2006
- Sprache : Probleme, Methoden und Ergebnisse der Sprachwissenschaft / Walter Porzig. Hrsg. von Andreas Jecklin und Heinz Rupp . - 9. Aufl., unveränd. Nachdr. der 8. Aufl. . - Tübingen [u.a.] : Francke , 1993 .



Konkordanz

- Stefanie Preiner
- PS Computerlinguistik
 - WiSe 08/09

Gliederung des Referats

Was ist Konkordanz?

- Begriffsabgrenzung
- Definitionsversuch

Beispiele von Konkordanzen

- Konkordanzen in vordigitalen Zeiten
- Erste computergestützte Auswertungen
- [Internet: Shakespeares gesammelte Werke](#)

Erstellung von Konkordanzen mit dem DWDS

- Konkordanzprogramm DDS
- Das Stuttgart-Tübingen Tagset (STTS)

Was ist Konkordanz?

„Konkordanz (lat.mlat.) *die*,., -en: 1. a) alphabetisches Verzeichnis von Wörtern od. Sachen zum Vergleich ihres Vorkommens u. Sinngeltes an verschiedenen Stellen eines Buches (bes. als Bibelkonkordanz); b)

Vergleichstabelle von Seitenzahlen verschiedener Ausgaben eines Werkes. 2. gleichlaufende Lagerung mehrerer Gesteinsschichten übereinander (Geol.) 3. die Übereinstimmung in Bezug auf ein bestimmtes Merkmal (z.B. von Zwillingen; Biol.). 4. ein Schriftgrad (Maßeinheit von 4 Cicero; Druckw.). 5. (in bestimmten Sprachen) Ausdruck grammatischer Zusammenhänge durch formal gleiche Elemente bes. durch Präfixe (Sprachw.). “

Was ist Konkordanz?

„Concordance: A list of words, normally in alphabetical order, where each occurrence of each word is shown with surrounding context and identified by a reference indicating where it occurs in the text.“

(Lawler / Dry 1998, S. 259)

Darstellungsmöglichkeiten



- Index
- Wortliste
- Konkordanz



Headword	No.
AUS	338
SIND	330
HAT	316
ODER	314
"	304
LEBEN	302
UNS	293
DES	292
KANN	283
A	273
HABE	272
EINEN	271
ALLES	265
IHR	261
DANN	251
DIR	246
NICHTS	242
UM	241
EINEM	238
VOR	237
DOCH	236
WIEDER	234
DICH	231
NACH	226
TO	224
DA	219
HABEN	219
WRD	219
LIEBE	218
SCHON	218
OF	211
ME	209
MY	207
AM	205
ÜBER	204
BIN	190
WERDEN	187
WEIL	183
WILL	183
IHM	178

Context...	w...	...Context	Line
uben Sie mir, mein Lieber, was wir hinzudichten, ist nicht so schlimm wie	das	, was wir weglassen.	6381
Was? du auch? die Gesellschaft, die Verhältnisse?	das	muss ja heutzutage der reinste Wettbewerb sein.	2423
Ehrgeiz nicht aus, das bricht meinem Kopf das Herz und meinem Herzen	das	Genick, Jakob.	6481
	Das	hält mein Ehrgeiz nicht aus, das bricht meinem Kopf das Herz u...	6481
Das hält mein Ehrgeiz nicht aus,	das	bricht meinem Kopf das Herz und meinem Herzen das Genick, J...	6481
Also ich steh mir im Weg, weiterhin. An guten Tagen glaube ich, dass	das	mein Platz auf der Welt ist.	4587
Das hält mein Ehrgeiz nicht aus, das bricht meinem Kopf	das	Herz und meinem Herzen das Genick, Jakob.	6481
Als ich jung war, lebte ich mit der Vorstellung meiner Unschuld,	das	heißt mit gar keiner Vorstellung.	2093
„Das wichtigste ist, das wir hier zu einem verschmelzen. Solange wir	das	tun, gibt es keine Probleme.“	494
„Das wichtigste ist,	das	wir hier zu einem verschmelzen. Solange wir das tun, gibt es k...	494
Ehrgeiz nicht aus, das bricht meinem Kopf das Herz und meinem Herzen	das	Genick, Jakob.“	380
„...“	Das	hält mein Ehrgeiz nicht aus, das bricht meinem Kopf das Herz u...	380
„... Das hält mein Ehrgeiz nicht aus,	das	bricht meinem Kopf das Herz und meinem Herzen das Genick, J...	380
„... Das hält mein Ehrgeiz nicht aus, das bricht meinem Kopf	das	Herz und meinem Herzen das Genick, Jakob.“	380
ommen und ich blieb allein. Du wann wirst du wieder kommen, wann wa...	das	sein?	4303
ommen und ich blieb allein. Du wann wirst du wieder kommen, wann wa...	das	sein?	4299
Boris:	Das	klingt schön. Nur so ein bisschen luftig, so schwerelos,... als k...	212
chrank leerräumen, reinklettern und von innen zu machen. Rausfinden, ob	das	Licht wirklich ausgeht.	1179
„Die Literatur greift immer dem Leben vor. Sie ahmt	das	Leben nicht nach, sondern formt es nach ihrer Absicht.“	5084
„Weiß nicht. Ich habe	das	Gefühl, wenn ich mich immer wieder male, werde ich mich irge...	2839
sich auf. Ich wünschte, ich könnte bis in alle Ewigkeit spielen. Dann wäre	das	Leben erträglich.	6155
„Nein, alles, was du willst, aber nicht	das	. Selbstporträts, selbst so verstümmelte wie dieses hier, behalt...	2837
Ich habe	das	Thema meinen Empfindungen entsprechend abgehandelt und s...	139
Felix: Aber das ist doch gerade	das	Schöne, dass man sich so nah ist und dass einem nichts mehr ...	238
Felix: Aber	das	ist doch gerade das Schöne, dass man sich so nah ist und das...	238
umma summarum, Sie gehen also im Namen einer hypothetischen Zukunft	das	Risiko ein, die Gegenwart zu vermessen.	1453
Erinnerungen sind	das	, was Ihren Körper von Innen wärmt. Zugleich können Erinneru...	488
Vor allem wünschte sie sich ein langes Gespräch,...,	das	so lang wäre, dass es nicht auf das ankäme, was da gesagt ...	118
hte sie sich ein langes Gespräch,..., das so lang wäre, dass es nicht auf	das	ankäme, was da gesagt wurde.	118
Emilia:	Das	ist Bullshit. Das ist nichts als Angst.... Das hat uns umgebracht....	239
„Mir passiert	das	öfter, dass ich zu wenig sage. Bei dir täte es mir leid. Du weißt...	1314
*	Das	Telefonbuch durchblättern, alle Leute mit dem Vornamen Bert a...	1186
Emilia: Das ist Bullshit.	Das	ist nichts als Angst.... Das hat uns umgebracht. Die Sendung mi...	239
Emilia: Das ist Bullshit. Das ist nichts als Angst....	Das	hat uns umgebracht. Die Sendung mit der Maus hat uns umgebr...	239
Aber	das	ist immerhin eine Gewissheit. Mit ihr hat er es zu tun: er will wi...	4980
ir und sagte: „Miss die Zeit nicht, indem du sagst: „Es gab das Gestern, ...	das	Morgen geben.“	58
eitweise sogar leben lassen, wie du wolltest, ohne dich zu stören, das ...	das	ist großmütiger.	2531
dich zeitweise sogar leben lassen, wie du wolltest, ohne dich zu stören,	das	ist mehr, das ist großmütiger.	2531

Words	Tokens	At word	Word sort	Context sort
17188	108666	6	Desc frequency	Asc length

Beispiele von Konkordanzen

- Konkordanzen in vordigitalen Zeiten
- Erste computergestützte Auswertungen
- Internet: Shakespeares gesammelte Werke

Erstellung von Konkordanzen mit dem DWDS

- Beispiel: Konkordanz von „Lehrer“
- Das Stuttgart-Tübingen Tagset

Text Mining und Informationsextraktion

Christian Wimplinger

Gliederung




- Text Mining – Begriffserklärung
- Volltextanalyse
- Analyse von Einzeltexten
- Merkmalsextraktion
- Beispiel für Merkmalsextraktion
- Zusammenfassung

Text Mining – Anwendung

- Aus Textquantität informative Qualität herausfiltern
- Textmaterial ist unstrukturiert
 - Im Gegensatz zu Data Mining: untersucht strukturierte Datenbanken
- Textimmanent und intertextuelle Anwendung
 - Textimmanent: Schlüsselwortextraktion, automatische Textzusammenfassung, etc.
 - Intertextuell: Clusterbildung von semantisch zusammengehörender Texte

Volltextanalyse



- Funktioniert durch Indexbildung
 - (Fast) jedes Wort ein Indexterm
 - Normalisierung der Wörter
 - Stoppworte ausfiltern
- Bei Anfrage wird die Textposition angegeben
 - Komplexe Suche durch Retrievalmodelle

Analyse von Einzeltexten

- Vorbereitung zur besseren Informationsauswertung
 - Textrelevante Daten werden in eine einheitliche Form gebracht.
 - Erkennung des Datenformats
 - Erkennung der Zeichenkodierung
 - Hinweis auf Textstruktur
 - Erkennung der Sprache
- Erstellung einer Merkmalsmatrix

Merkmalsextraktion

- Tokenisierung – Zerlegung in Worte
 - Satzgrenzen erkennen
 - Mittels Wörterbücher rückführen auf Stamm
 - Datumsangaben durch Algorithmen ersetzen
 - Akronyme entschlüsseln
- Semantische Probleme

Beispiel für Merkmalsextraktion

PersonOut

PersonIn

Position

Organisation

TimeOut

TimeIn

Zu verarbeitender Text

„Dr. Hermann Wirth, bisheriger Leiter der Musikhochschule München, verabschiedet sich heute aus dem Amt. Der 65-jährige tritt seinen wohlverdienten Ruhestand an. Als seine Nachfolgerin wurde Sabine Klinger benannt. Ebenfalls neu besetzt wurde die Stelle des Musikdirektors. Annelie Häfner folgt Christian Meindl nach.“

Ausgabe der Merkmalsextraktion

PersonOut

Dr. Hermann Wirth

PersonIn

Sabine Klinger

Position

Leiter

Organisation

Musikhochschule München

TimeOut

Heute

TimeIn



AUS

Literatur:

Dörre, Jochen/Gerstl, Peter/Seiffert, Roland: Volltextsuche und Text Mining. In: *Computerlinguistik und Sprachtechnologie. Eine Einführung*. Hrsg. V. Carstensen/Ebert, u.a., 2., überarbeitete und erweiterte Auflage. München: Elsevier GmbH (2004).