



# Data-Mining und Visualisierung zur Erfassung der semantischen Entwicklung von Konstruktionen

Catherine Diederich und Florent Perek, Universität Basel  
Kontakt: catherine.diederich@unibas.ch, florent.perek@unibas.ch

## Ausgangslage

### "Digital Humanities" in der Sprachwissenschaft:

- Korpusanalysen: Gebrauch von grossen digitalen Datenbanken um grosse Mengen von Daten auf grammatikalische Eigenschaften und Muster zu untersuchen.
- Problem: Ein Korpus bietet nur Zugang zu Wortformen → Bedeutung ist nicht direkt beobachtbar

**Fragestellungen:** Inwiefern eignen sich Data-Mining Techniken um den Gebrauch von syntaktischen Konstruktionen diachronisch zu untersuchen? Wie können wir die semantische Entwicklung dieser Konstruktionen aufzeigen?

### Möglicher Ansatz:

- Verteilungsanalysen (distributional analyses)
- Berechnungsmethoden zur automatischen Annotation
- Vektor-Raum Modelle basieren auf der Verteilungs-Hypothese, d.h. **Wörter, die in ähnlichen Kontexten auftreten, zeigen ähnliche Bedeutungen auf**

## Vektor-Raum Modelle

Ausgangspunkt: Aufbau einer Kookkurrenz-Matrix basierend auf Korpus-Daten.

- Die Matrix enthält die Menge an Kookkurrenzen für jedes Vorkommen des Schlagworts in einem festgelegten Kontextfenster
- Funktionswörter werden normalerweise nicht berücksichtigt
- Beispiel: das lexeme *kiss* (Kontextfenster: +/- fünf Wörter)

	frizzy	hair,	felt	him	kiss	me	on	the	cheek	with	
give	her	my	flowers,	to	kiss	her	hand,	but	did	not	
Diana,	and	bent	down	to	kiss	him	on	the	cheek.	She	
towards	him	and	tried	to	kiss	her	on	the	mouth.	Over	
and	I	lean	over	and	kiss	her	on	the	mouth.	I	

Kookkurrenzen

frizzy	1
hair	1
feel	1
cheek	2
give	1
flower	1
hand	1
Diana	1
bend	1
try	1
mouth	2
lean	1

Resultat:  $N_{\text{Wörter}} \times N_{\text{Wörter}}$

- Einschränkung der Dimensionalität auf die informativsten Aspekte der Wortverteilung
- Jedes Wort wird einer Zeile der Matrix zugeordnet
- Die Ähnlichkeit der Reihen reflektiert die semantische Ähnlichkeit

## Anwendung von Vektor-Raum Modellen

Vorteile der Vektor-Raum Modelle

- Das informelle Konzept der semantischen Repräsentation wird in ein empirisch-prüfbares Modell gewandelt
- Erlauben die Quantifizierung der semantischen Ähnlichkeit

Repräsentation von psychologischer Realität

- Resultate korrelieren mit menschlichen Leistungen in verschiedenen Aufgaben: Synonyme beurteilen, Wortassoziationen, semantisches Priming... (Lund et al. 1995, Landauer et al. 1998).

Vektor-Raum Modelle werden seit kurzem in der Linguistik verwendet

- Um semantische Klassen zu bestimmen
- z.B. Gries und Stefanowitsch (2010): Clustering von Verben und ihrer Vorkommnis in Konstruktionen anhand der häufigen Kollokationen

### Frage: Können Vektor-Raum Modelle auch angewendet werden, um syntaktische Produktivität zu untersuchen?

- d.h. um zu analysieren wie Sprachbenutzer auf kreative Weise Wörter kombinieren
- in einer diachronischen Perspektive entspricht Produktivität der lexikalischen Erweiterung einer Konstruktion

## Korpusanalyse: Transitiv-Konstruktion mit hell

**Konstruktion: V the hell out of NP** → z.B. *You scared the hell out of me!*

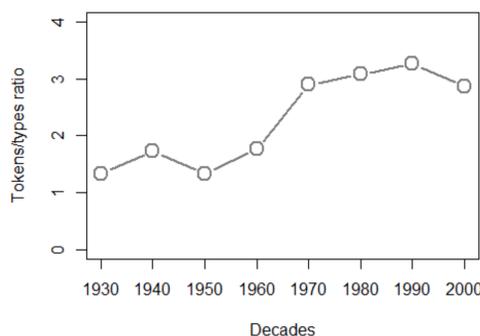
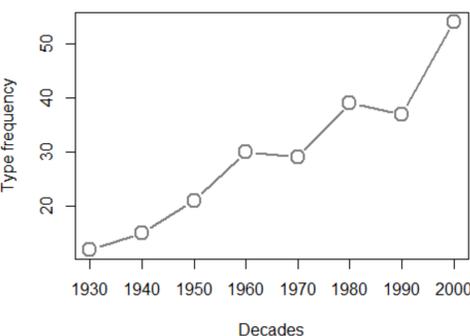
- Vermittelt eine semantische Intensivierung
- Einige vulgäre Varianten, z.B. *crap*, *shit*, oder *fuck* anstelle von *hell*
- Intransitive Verben kommen auch vor, z.B. *I've been listening to the hell out of your tape* (COCA)
- Eignet sich für eine konstruktionsgrammatische Analyse:
  - Die intensivierende Funktion wird in der ganzen Konstruktion vermittelt
  - **Wie hat sich die Konstruktion im Verlauf der Zeit verändert?**

**Daten:** Corpus of Historical American English (COHA, Davies 2010)

- 1810 – 2009, ca. 20 Mio. Wörter pro Jahrzehnt, Amerikanisches English
- Geschriebene Sprache aus verschiedenen Gattungen: Zeitungen, Magazine, Belletristik, Sachbücher

- Neue Konstruktion: Erste Befunde in den 1930er
- Die Konstruktion zentriert sich auf zwei Verben: *scare* und *beat* (30% und 25% in 2000)
- Andere Beispiele:
  - Then I [...] avoided the hell out of his presence*
  - But you drove the hell out of it!*
  - The Russians understood the hell out of that.*

## Resultate/ Visualisierungen



- Ein **Vektor-Raum Modell** um die Verben in der *hell*-Konstruktion semantisch zu evaluieren
- **Visualisierung** des Vektor-Raumes anhand **„multidimensional scaling“** (MDS; zweidimensional)

- Im Verlauf der Zeit kommen immer mehr verschiedene Verben in der Konstruktion vor
- Daraus resultierende Fragen:
  - Welche Art von Verben sind dazugekommen und wann?
  - Werden bestimmte semantische Domänen von der Konstruktion bevorzugt und hat sich dies im Verlaufe der Zeit verändert?

## Diskussion

Es werdet vorwiegend **psychologische Verben** bevorzugt (v.a. mit einem Stimulus-Subjekt)

- Sie bilden von Anfang an (1930er-) ein dichtes Cluster
- Meist besiedelte „Region“ in allen Jahrzehnten
- Diese Gruppe zieht regelmässig neue Mitglieder an

Was ist mit den anderen semantischen Domänen?

- Weniger dicht besiedelt, d.h. niedrige Type-Frequenz, hohe semantische Variabilität
- Weniger vertreten von 1930 – 1940
- Anfangs ziehen diese Domänen wenig neue Mitglieder an
- Die lexikalische Produktivität nimmt mit der Zeit zu, z.B.:
  - konkrete Handlungen in den 1970er – 1980er
  - abstrakte Handlungen in den 1990er – 2000er

Die Ergebnisse entsprechen den aktuellen usage-based Modellen der Produktivität

- d.h. Produktivität ist ein Produkt der Type-Frequenz und der semantischen Variabilität
- Dicht besiedelte Regionen ziehen am ehesten neue Mitglieder an
- In weniger dicht besiedelten Regionen ist eine kritische Masse an Verben notwendig um Produktivität anzukurbeln
- Token-Frequenz ist nicht besonders entscheidend für Produktivität:
  - z.B. das häufig vorkommende Verb *kick* bleibt weitgehend isoliert
  - Gelegentlich erscheinen neue Verben in der Nähe von *kick*: Vermutlich analoge Ausweitungen eines prominenten Modells (Barðdal 2008; Bybee and Eddington 2006)

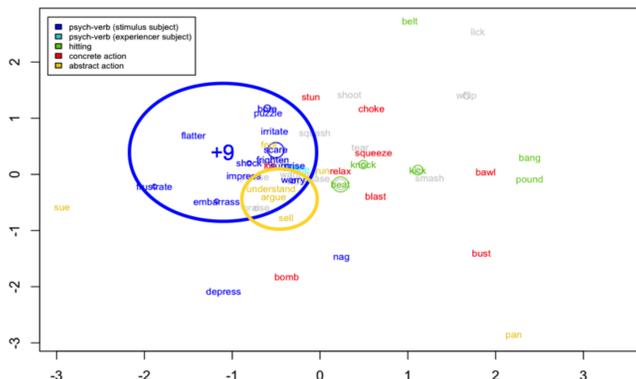
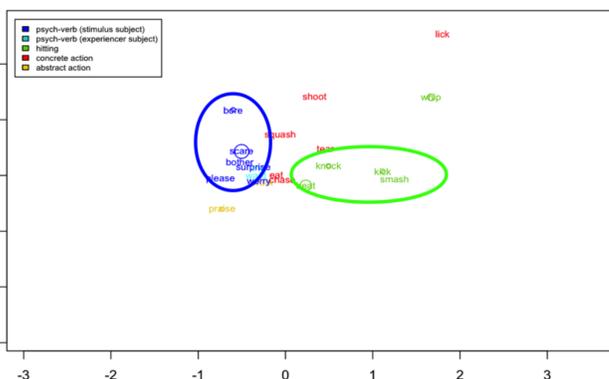
## Referenzen

- Barðdal, J. (2008). *Productivity: Evidence from Case and Argument Structure in Icelandic*. Amsterdam: John Benjamins.
- Bybee, J. and D. Eddington (2006). A usage-based approach to Spanish verbs of 'becoming'. *Language* 82 (2), 323–355.
- Davies, M. (2010-). *The Corpus of Historical American English: 400 million words, 1810-2009*. Available online at <http://corpus.byu.edu/coha/>.
- Gries, S. and A. Stefanowitsch (2010). Cluster analysis and the identification of collexeme classes. In S. Rice & J. Newman (eds.), *Empirical and experimental methods in cognitive/functional research*, 73–90. Stanford, CA: CSLI.

### Diachronische Analyse → vier Zeiträume von je 20 Jahren:

#### The hell-construction in diachrony: 1930s-1940s

#### The hell-construction in diachrony: 1950s-1960s



#### The hell-construction in diachrony: 1970s-1980s

#### The hell-construction in diachrony: 1990s-2000s

