



Thomas Bartz, Christian Pöllitz

# Routineaufgaben bei der Nutzung von Korpora: Disambiguiieren, Klassifizieren, Annotieren mit KobRA-Verfahren

GEFÖRDERT VOM



Bundesministerium  
für Bildung  
und Forschung



4. KobRA-Tagung, 30.10.2015, BBAW, Berlin



Technische Universität Dortmund  
Institut für deutsche Sprache und Literatur und Lehrstuhl für Künstliche Intelligenz

Thomas Bartz, 11.11.2015: 1

# Gliederung

1. Korpus-basierte Sprachanalyse: Forschungsprozess und Aufgaben
2. KobRA-Verfahren für die Korpus-basierte Sprachanalyse
3. Was leisten die Verfahren aktuell: Nutzwert  
Studien aus dem Bereich Lexikographie/historische Semantik
4. Zusammenfassung

# Korpus-basierter Forschungsprozess



## Statistik-/Visualisierungssoftware

- Überführen in Häufigkeitstabellen
- Berechnung relativer Häufigkeiten/statistischer Kennwerte
- Erzeugen von Visualisierungen

## Annotations-/Analysesoftware

- Aussortieren falsch positiver Treffer
- Annotieren und Klassifizieren
- Disambiguieren

## Korpus-Schnittstelle

- Form- und Phrasensuche, Abstands- und Verknüpfungsoperatoren
- Reguläre Ausdrücke
- Linguistische Informationen: Lemmata, Wortarten, Syntax

# Aussortieren falsch positiver Treffer ③

## Aufgabenstellung

Trefferlisten zu einem sprachlichen Phänomen enthalten häufig noch viele falsch positive Treffer, die vor weitergehenden Analysen ausgesondert werden müssen.



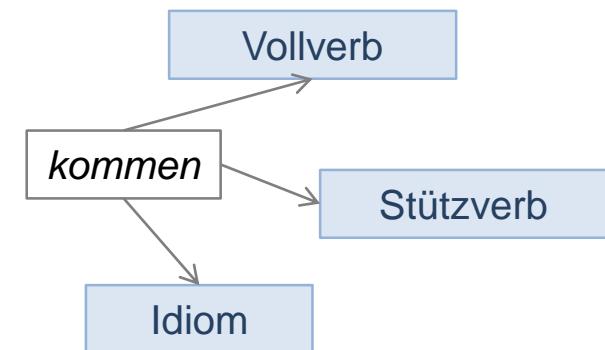
## KWIC-Snippets aus dem diachronen Korpus TüBa-D/DC (,Projekt Gutenberg‘)

... in de Koje wa dat Soltwater twee	<b>toll</b>	af an de Planken klappt. Dat is ...	<b>Sprache</b>
... der letzten Woche ad sidera	<b>tollere</b>	vultus, d.h., die Nase so zu ...	
... Es ward nicht aufgetan.	<b>Toller</b>	telegraphierte aus dem ...	<b>Namen</b>
... dem alten verbummelten Lehrer	<b>Toll</b>	nicht einmal als etwas ...	
... Mythologie. Worauf sich das	<b>toller</b>	beziehet, ist ungewiß; denn ...	
... zu still die Welt. Manchmal zu	<b>toll</b>	.	<b>Metasprache</b>
... von Angouleme. Talleyrand	<b>toll</b>	? Ich weiß nicht.	<b>Kontext</b>

# Annotieren und Klassifizieren ③

## Aufgabenstellung

Sprachliche Phänomene lassen sich häufig nicht zielgenau erheben. Trefferlisten müssen daher oft nachklassifiziert/annotiert werden.



## KWIC-Snippets aus dem DWDS-Kernkorpus des 20. Jh. (BBAW)

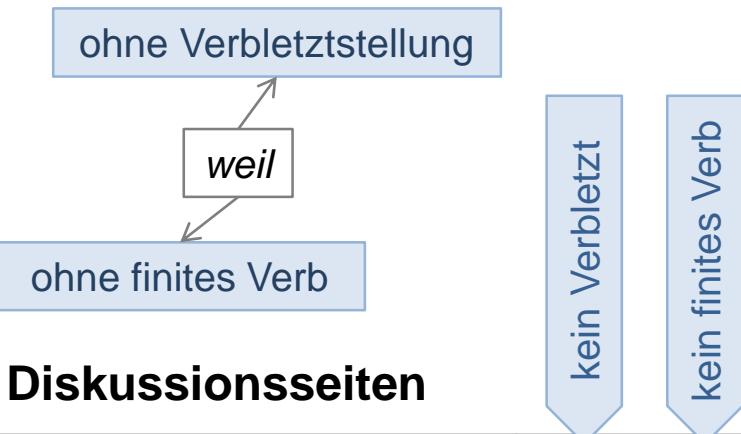
... Portwein erstickte. Es	<b>kamen</b>	Die Damen Buddenbrook, die ...	X	
... führt. <b>Zum Einsatz</b>	<b>kommen</b>	hier fünf Dieseltriebwagen vom ...		X
... darüber. Diese Worte	<b>kamen</b>	ihm einfach <b>über die Lippen</b> ...		X
... Ruhe. Frau Brigitte	<b>kam</b>	noch einmal herauf und holte ...		
... ich, Ingenieur? Was	<b>kommt</b>	mir gerüchteweise <b>zu Ohren</b> ? ...		
... Luft <b>in Berührung</b>	<b>kamen.</b>	Einzig die Knie blühten dunkel ...		
... endlich <b>zum Stehen</b>	<b>kam.</b>	Rote Leuchtbomben, aus denen ...		

Vollverb
?
Stützverb
?
Idiom

# Annotieren und Klassifizieren ③

## Aufgabenstellung

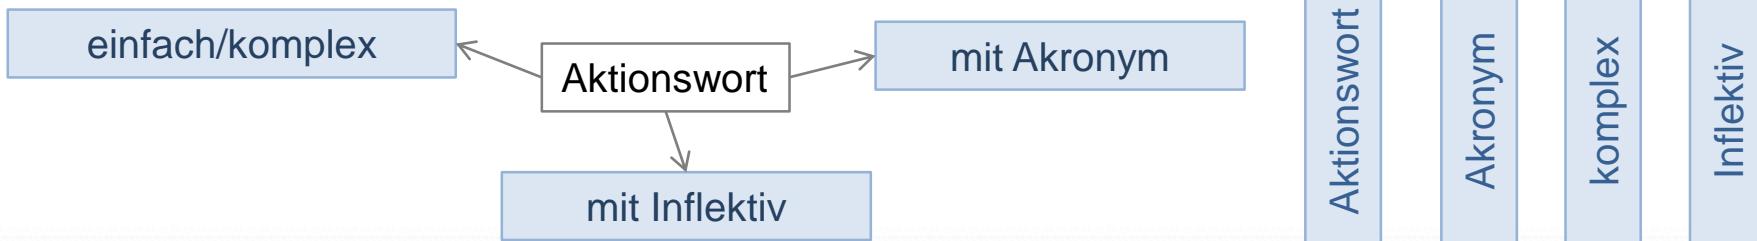
Häufig erfordert auch ein Analyseschritt eine feinere Klassifizierung der Trefferlisten nach vorgegebenen Merkmalen.



## KWIC-Snippets aus Wikipedia-Korpus (IDS), Diskussionsseiten

... So, eigentlich überflüssig, <b>weil</b> eine Wiederholung, allerdings ...	X		X
... wenn auch nur ein Anfang - <b>weil</b> hier geht es ja nicht um die ...	X		X

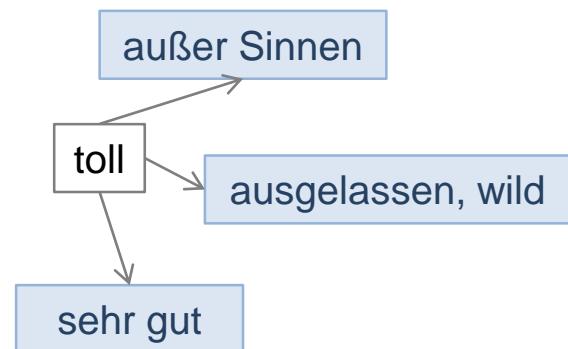
... * <b>ganzganzfiesgrins</b> * da ergibt sich ne tolle Gelegenheit für ...	X		X	X
... und da ist irgendwo hier verschollen bei mir * <b>g</b> *. Und was ...	X	X		
... Kram doch in deutscher Sprache veröffentlichen * <b>wunder</b> * ...	X			X



# Disambiguieren ③

## Aufgabenstellung

Gesuchte Ausdrücke kommen häufig in verschiedenen Bedeutungen vor. Trefferlisten müssen daher meist erst disambiguiert werden.



## KWIC-Snippets aus dem diachronen Korpus TüBa-D/DC (‘Projekt Gutenberg’)

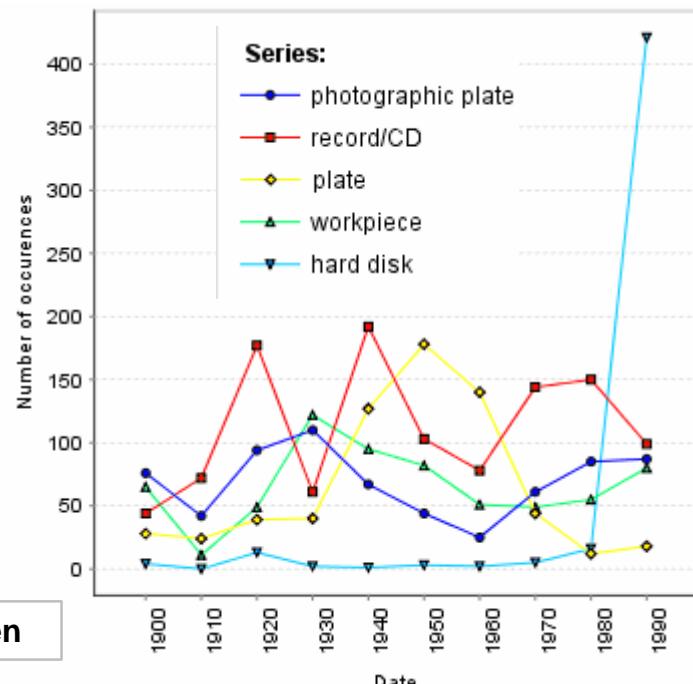
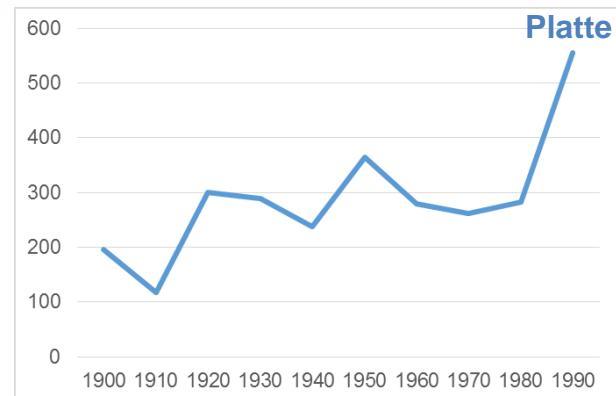
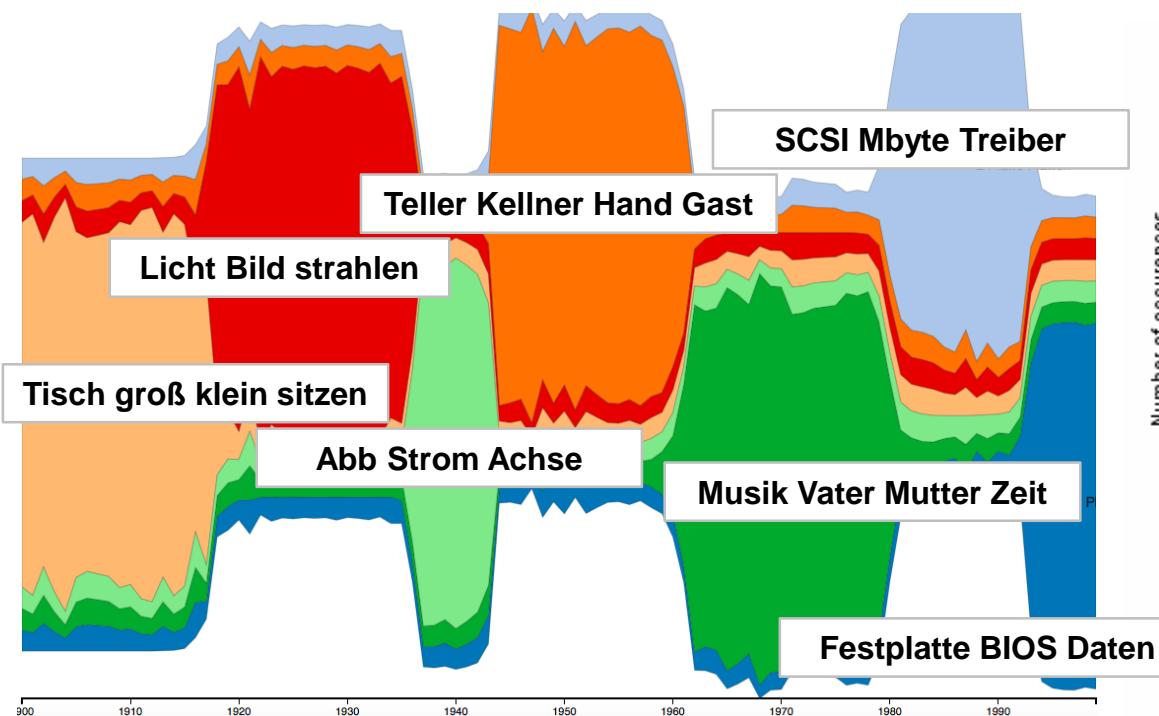
... Billy, den er als kleines Fohlen in	<b>toller</b>	Hetze mit dem Lasso ...	wild
... Nun waren sie	<b>toll</b>	vor Freude, daß sie ...	ausgelassen
... Sechzig Centimes? Du bist wohl	<b>toll?</b>	Für das Geld kriege ...	außer Sinnen
... Außerdem wird es mit den	<b>tollen</b>	Aufstiegschancen ...	sehr gut
... Es war, als wollte sich alles wie	<b>toll</b>	in einen Abgrund stürzen ...	
... geschickt. Ihre Gebieterin war	<b>toll</b>	vor Liebe, berauscht vor Freude ...	
... Witwer; auf der Insel wurden	<b>tolle</b>	Geschichten über sein Eheleben ...	
... kennt er doch beide? das wäre ja	<b>toll</b>	und unvernünftig. Allein wenn es ...	

# Erzeugen von Visualisierungen

4

## Aufgabenstellung

Bei der Visualisierung von Häufigkeitsverteilungen müssen die verschiedenen Bedeutungen eines Ausdrucks berücksichtigt werden.



# Korpus-basierter Forschungsprozess mit KobRA-Verfahren

## Exportoperatoren/ Visualisierung



- CSV-, Excel®, Export etc.
- DFR-Browser-Export
- Visualisierung mit Bordmitteln



## 4 Visualisierung/ Exploration

### Annotationsoperator



- Erstellung von Trainingsdaten
- Evaluation

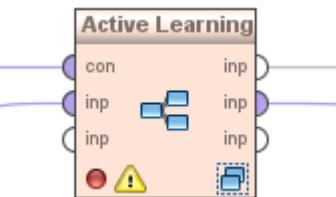


rapidminer



## 3 Analyse der KWIC-Trefferliste

### Data-Mining-Operatoren



- Klassifikation
- Disambiguierung

## 2 Suchanfrage Anfrage-/Importoperatoren



- Abfrage von CLARIN-Ressourcen
- CSV-, Excel®, (TEI-)XML-Import etc.

### Operatoren für die Vorverarbeitung



- linguistische Annotation, z. B. POS-Tags, Syntax

# Was leisten die Verfahren?

## Gütemaß: $F_1$ -Score auf Basis manuell annotierter Stichproben

Gewichtetes harmonisches Mittel aus Präzision (Precision) und Ausbeute (Recall), Präzision und Ausbeute werden gleich gewichtet

$$F_1 = 2 \times \frac{\text{Präzision} \times \text{Ausbeute}}{\text{Präzision} + \text{Ausbeute}}$$

## Überprüfte Gütefaktoren

### Klassifikation

- Menge der (annotierten) Datensätze
- Größe der KWIC-Snippets
- Repräsentation der Daten:
  - Bag-of-Words
  - POS/Syntax
  - Distributionelle Merkmale („Expertenmerkmale“)

### Disambiguierung

- Menge der Datensätze
- Größe der KWIC-Snippets (Kontext)
- Abgefragtes Wort/Wortart
- Menge der Bedeutungen
- Korpus: synchron/diachron
- Sprache

Merkmal-Kategorie	Merkmale: Das Stützverb ...	Beispiele
B1 (Wortart)	ist ein Vollverb (VVF/N) <sup>6</sup>	
	oder tritt in einem Satz als Partizip (VVPP) zusammen mit einem Hilfsverb (VAF/N) auf	1.1.2 1.2.2
	oder tritt in einem Satz als Infinitiv (VVINF) zusammen mit	1.1.5

# Stützverbgefüge: Nur im ‚Juristendeutsch‘?

## Annotieren und Klassifizieren

### KWIC-Snippets aus dem DWDS-Kernkorpus des 20. Jh. (BBAW)

... Portwein erstickte. Es	<b>kamen</b>	Die Damen Buddenbrook, die ...	X	
... führt. <b>Zum Einsatz</b>	<b>kommen</b>	hier fünf Dieseltriebwagen vom ...		X

	Belletristik	Gebrauchsliteratur	Wissenschaft	Zeitung
<b>Anfrage</b> kommen 1% manuell analysiert	71.399	26.068	23.924	33.703
<b>F<sub>1</sub></b> Bag-of-Words	72,4	65,4	74,9	67,5
<b>F<sub>1</sub></b> POS-Tags	74,5	71,1	76,9	67,7
<b>F<sub>1</sub></b> Distributionelle Merkmale	71,6	67,5	69,4	63,7
<b>Anfrage</b> bringen 1% manuell analysiert	18.006	14.301	12.653	19.669
<b>F<sub>1</sub></b> Bag-of-Words	69,7	67,6	72,6	70,3
<b>F<sub>1</sub></b> POS-Tags	67,1	67,2	76,8	71,7
<b>F<sub>1</sub></b> Distributionelle Merkmale	65,4	66,9	63,5	65,5

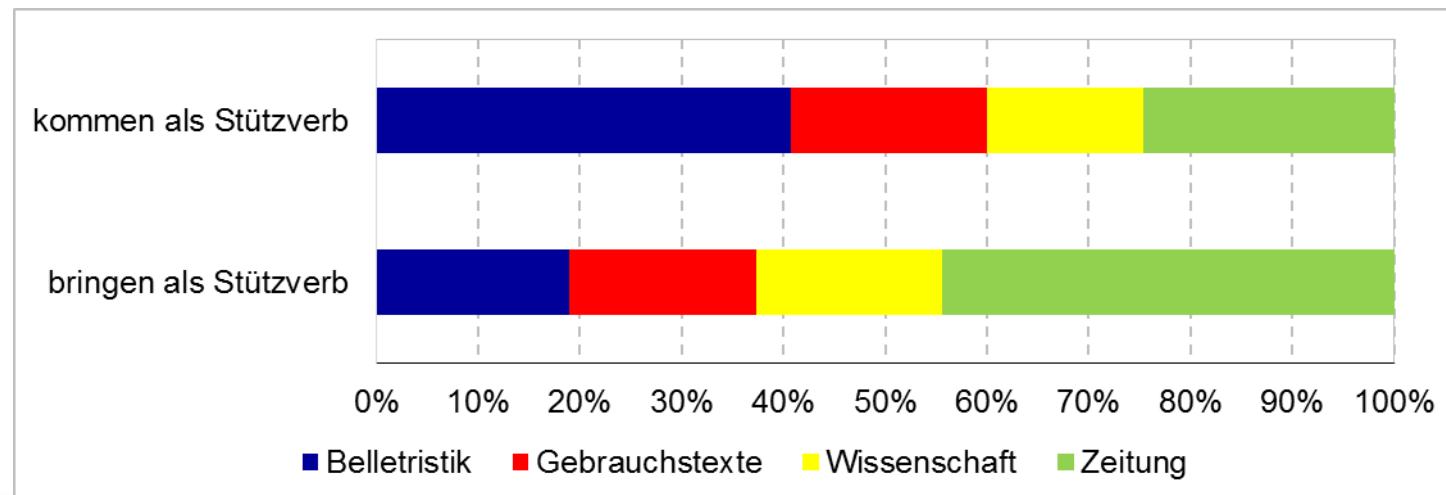
# Stützverbgefüge: Nur im ‚Juristendeutsch‘?

## Annotieren und Klassifizieren

### KWIC-Snippets aus dem DWDS-Kernkorpus des 20. Jh. (BBAW)

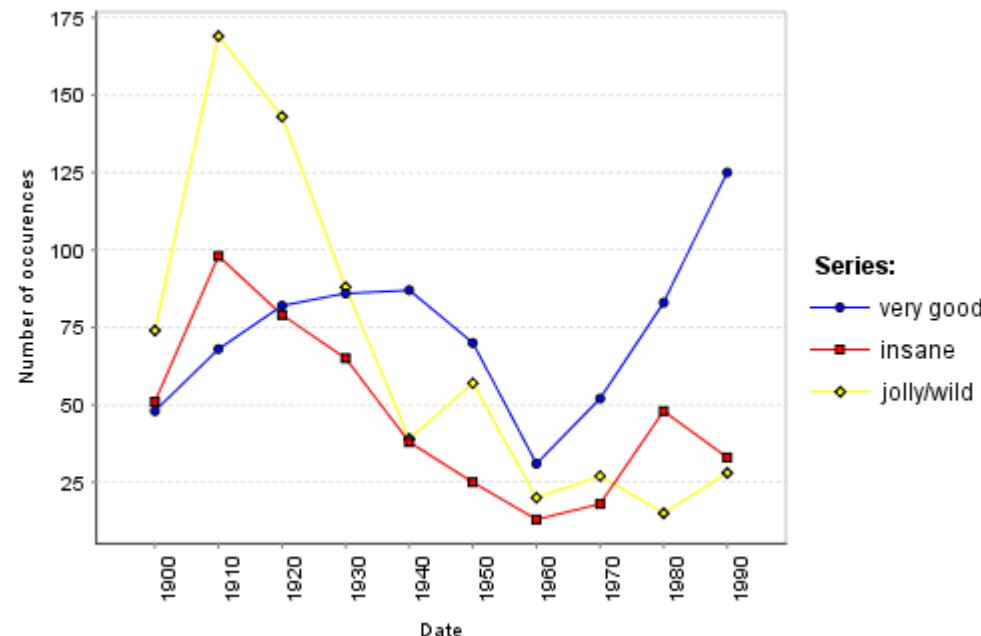
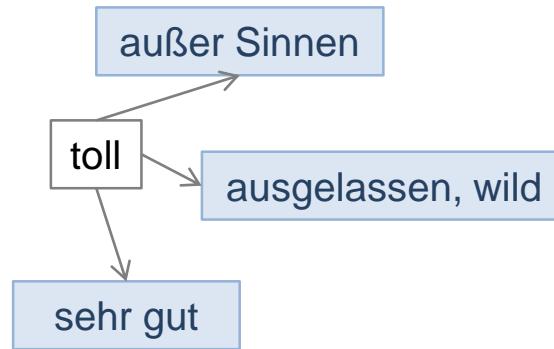
... Portwein erstickte. Es	<b>kamen</b>	Die Damen Buddenbrook, die ...	X	
... führt. <b>Zum Einsatz</b>	<b>kommen</b>	hier fünf Dieseltriebwagen vom ...		X

	Belletristik	Gebrauchsliteratur	Wissenschaft	Zeitung
<b>kommen als Stützverb</b>	15.179	7.187	5.723	9.181
<b>bringen als Stützverb</b>	3.131	3.046	3.025	7.354



# toll: Umwertung der Bedeutung?

## Disambiguiieren



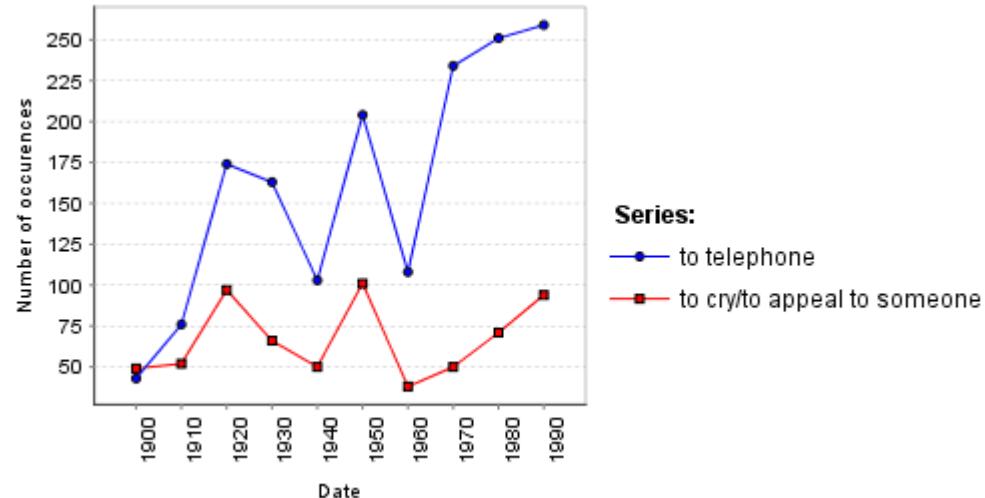
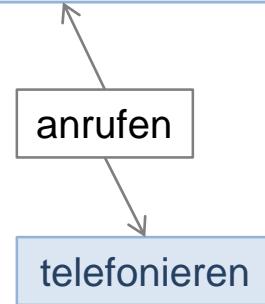
## KWIC-Snippets aus dem DWDS-Kernkorpus des 20. Jh. (BBAW)

	Snippets	<i>außer Sinnen</i>	<i>ausgelassen, wild</i>	<i>sehr gut</i>
<b>Anfrage</b> toll with \$p=ADJ*	2.106	702	772	632
<b>F<sub>1</sub></b> Kontext 20 Wörter		0,519	0,571	0,167
<b>F<sub>1</sub></b> Kontext 30 Wörter		0,714	0,615	0,632
<b>F<sub>1</sub></b> Kontext 40 Wörter		0,625	0,667	0,500
<b>IAA</b> 30% manuell disambiguiert	0,76			

# anrufen: Verschiebung der prototypischen Bedeutung?

## Disambiguiieren

jmdn. bitten, auf sich aufmerksam machen

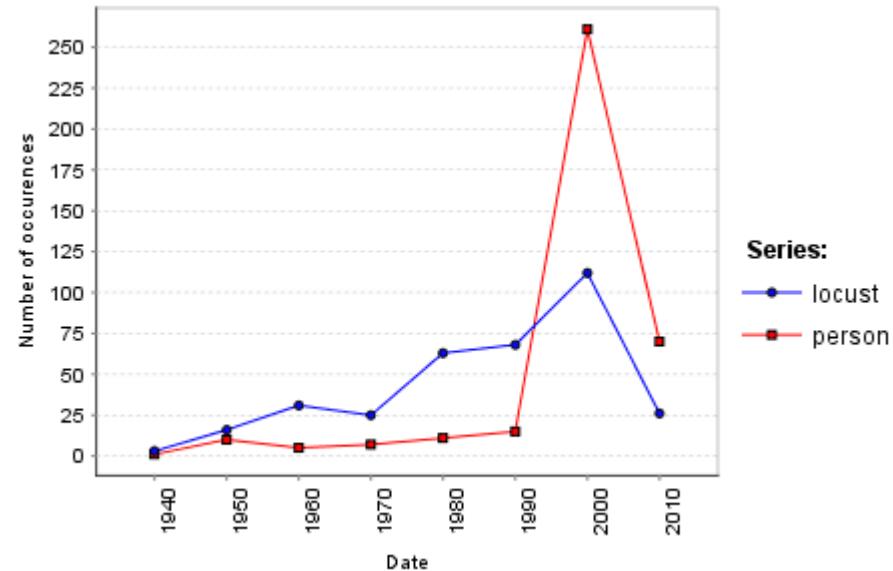
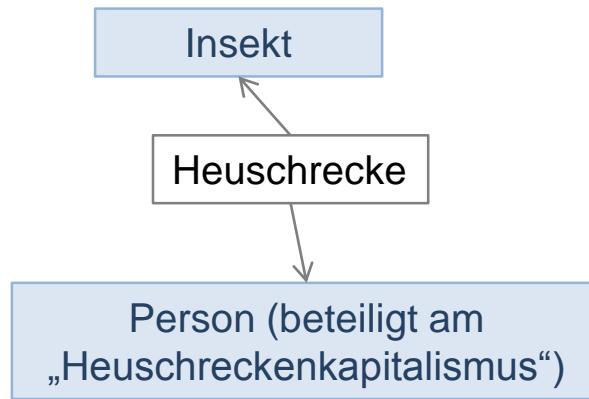


## KWIC-Snippets aus dem DWDS-Kernkorpus des 20. Jh. (BBAW)

	Snippets	bitten etc.	telefonieren
Anfrage anrufen with \$p=VV*	2.958	1.183	1.775
F <sub>1</sub> Kontext 20 Wörter		0,727	0,667
F <sub>1</sub> Kontext 30 Wörter		0,800	0,800
F <sub>1</sub> Kontext 40 Wörter		0,909	0,889
IAA 30% manuell disambiguiert	0,97		

# Heuschrecke: Metapher als Quelle für Neubedeutungen?

## Disambiguiieren

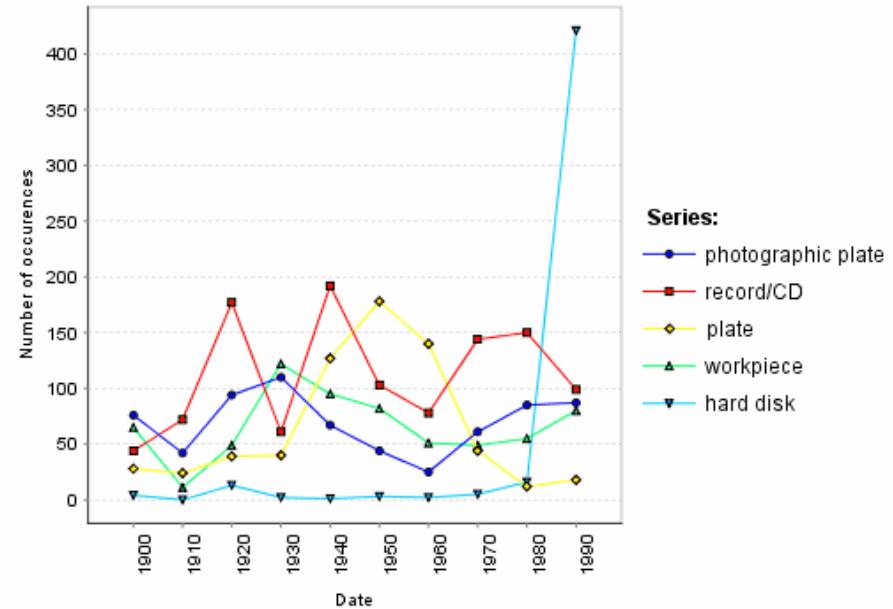
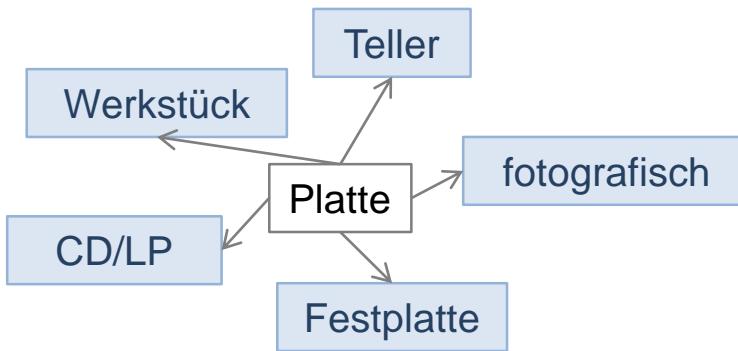


## KWIC-Snippets aus dem ZEIT-Korpus (BBAW)

	Snippets	Insekt	Person
<b>Anfrage</b> Heuschrecke	693	139	554
<b>F<sub>1</sub></b> Kontext 20 Wörter		0,857	0,842
<b>F<sub>1</sub></b> Kontext 30 Wörter		0,800	0,933
<b>F<sub>1</sub></b> Kontext 40 Wörter		0,667	0,727
<b>IAA</b> 30% manuell disambiguiert	0,98		

# Platte: Technische Entwicklung/Bedeutungsentwicklung

## Disambiguieren

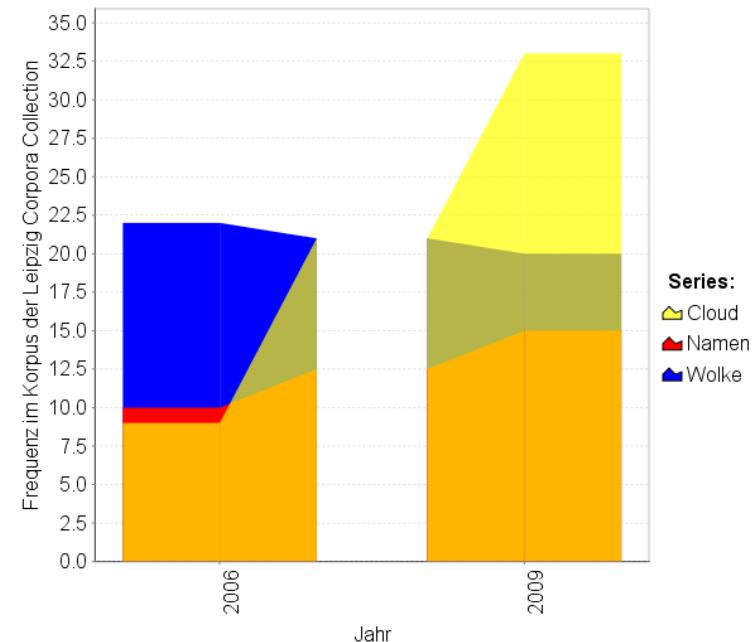
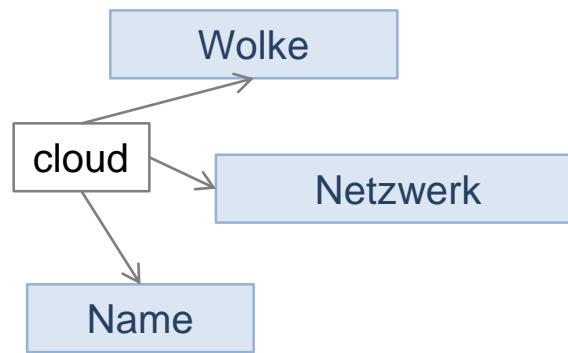


## KWIC-Snippets aus dem DWDS-Kernkorpus des 20. Jh. (BBAW)

	Snipp.	Werkstück	Teller	fotografisch	CD/LP	Festpl.
Anfrage Platte with \$p=NN && ! @Platt && ! \$l=Platter	2.008	373	387	357	440	451
F <sub>1</sub> Kontext 20 Wörter		0,800	0,800	0,667	0,287	0,857
F <sub>1</sub> Kontext 30 Wörter		0,984	0,875	0,500	0,381	0,983
F <sub>1</sub> Kontext 40 Wörter		0,733	0,600	0,750	0,353	0,800
IAA 30% manuell disamb.	0,98					

# cloud: Beispiel aus dem Englischen

## Disambiguieren



## KWIC-Snippets aus der Leipzig-Corpora-Collection (englisch)

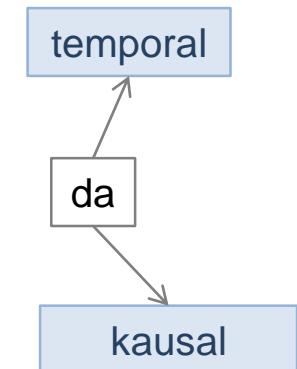
	Snippets	Wolke	Netzwerk	Name
Anfrage cloud	1.486	966	280	240
F <sub>1</sub> Kontext 20 Wörter		0,526	0,500	0,471
F <sub>1</sub> Kontext 30 Wörter		0,783	0,631	0,615
F <sub>1</sub> Kontext 40 Wörter		0,467	0,545	0,684
IAA 30% manuell disambiguiert	0,92			

# da: Ab wann auch kausal?

## Disambiguiieren

### KWIC-Snippets aus dem diachronen Korpus TüBa-D/DC (,Projekt Gutenberg‘)

temporal	... losgebrochen, <b>da</b> sie eben das Haus erreicht ...
kausal	... abschlagen, <b>da</b> ich an der Sache beteiligt bin ...



	Snippets	<i>temporal</i>	<i>kausal</i>
<b>Anfrage</b> da with \$p=KOUS	123.496	67.923	55.573
<b>F<sub>1</sub></b> Kontext 20 Wörter		0,471	0,556
<b>F<sub>1</sub></b> Kontext 30 Wörter		0,353	0,529
<b>F<sub>1</sub></b> Kontext 40 Wörter		0,400	0,611
<b>IAA</b> 30% manuell disambiguiert	0,75		

# Zusammenfassung

- Mithilfe der erprobten Verfahren in RapidMiner lassen sich **Routineaufgaben bei der korpusbasierten Sprachanalyse** wie z.B. das Klassifizieren oder Disambiguieren von KWIC-Snippets eines gesuchten Ausdrucks **mit akzeptabler Genauigkeit** automatisieren.
  - Die Genauigkeit wird **begünstigt** durch KWIC-Snippets mit einem **Kontext mittleren Umfangs** (ca. 30 Wörter); die Menge der Datensätze in einem Bereich zwischen 500 und 3000 zeigte keine Auswirkung auf das Ergebnis.
  - Aus linguistischer Sicht überraschend: Die evaluierten Verfahren erzielten mit einer **Bags-of-Words-Repräsentation** der Daten im Schnitt bessere Ergebnisse als mit einer Repräsentation, die weitere sprachliche Merkmale wie Wortartenzuordnungen oder Syntax berücksichtigt.
- Die Einbettung in die Umgebung RapidMiner ermöglicht auch die **unmittelbare aufgabenbezogene Annotation, Evaluation und Visualisierung der Ergebnisse**.
- Dadurch ist die Voraussetzung geschaffen, dass sich Korpus-Nutzer **schneller auf die eigentlich interessanten linguistischen Fragestellungen konzentrieren** können.



# Literatur (Auswahl)

**Bartz, T., Pöltz, C., Morik, K., Storrer, A.** (2014). Using Data Mining and the CLARIN Infrastructure to Extend Corpus-based Linguistic Research. In: Jan Odijk (Ed): *Selected Papers from the CLARIN 2014 Conference*, Linköping: Linköping University Electronic Press, 1–13.

**Bartz, T., Pöltz, C. and Radtke, N.** (2013). *Automatische Klassifikation von Stützverbgefügen mithilfe von Data-Mining*. Technischer Bericht, Technische Universität Dortmund.

**Blei, D. M., Ng, A. Y. and Jordan, M. I.** (2003). Latent dirichlet allocation, *Journal of Machine Learning Research*, 3: pp. 993–1022.

**Goldstone, A.** (o.J.): dfr-browser. Take a MALLET to disciplinary history.

**Joachims, T.** (2002). *Learning to Classify Text Using Support Vector Machines*. Dissertation, Dordrecht: Kluwer.

**Mierswa, I., Wurst, M., Klinkenberg, R., Scholz, M. and Euler, T.** (2006): YALE: Rapid Prototyping for Complex Data Mining Tasks. In *Proceedings of the 12th International Conference on Knowledge Discovery and Data Mining*. Philadelphia, USA.

Herzlichen Dank