

Korpus- und Computerlinguistik

Vorlesungsreihe *Recht durch Maschinen und Künstliche Intelligenz*

Philippe Heinrich

Lehrstuhl für Korpus- und Computerlinguistik

17. November 2022

1. Grundlagen

- 1.1 Computerlinguistik
- 1.2 Korpora
- 1.3 Korpuslinguistik

2. Ausgewählte Anwendungen

- 2.1 Tracking the Infodemic
- 2.2 Financial Narrative Processing
- 2.3 Argumentation Mining

1. Grundlagen

- 1.1 Computerlinguistik
- 1.2 Korpora
- 1.3 Korpuslinguistik

2. Ausgewählte Anwendungen

- 2.1 Tracking the Infodemic
- 2.2 Financial Narrative Processing
- 2.3 Argumentation Mining

The screenshot shows the Google Translate interface. At the top, there's a yellow banner with the text "Testen Sie einen neuen Browser mit automatischer Übersetzungsfunktion. [Chrome herunterladen](#) [Schließen](#)". Below the banner, the word "Übersetzer" is displayed in red. The language selection dropdowns show "Von: Englisch" and "Nach: Deutsch". A blue "Übersetzen" button is prominent. On the left, under "Englisch", the text reads: "For instance, on the planet Earth, man had always assumed that he was more intelligent than dolphins because he had achieved so much — the wheel, New York, wars and so on — whilst all the dolphins had ever done was muck about in the water having a good time. But conversely, the dolphins had always believed that they were far more intelligent than man — for precisely the same reasons." On the right, under "Deutsch", the translated text is: "Zum Beispiel auf dem Planeten Erde, hatte man immer angenommen, dass er intelligenter als Delfine war, weil er so viel erreicht hatte - das Rad, New York, Kriege und so weiter - während alle Delfine jemals getan hatten war Dreck im Wasser eine gute Zeit. Aber umgekehrt waren die Delfine immer geglaubt, dass sie viel intelligenter als der Mensch - für genau den gleichen Gründen." Below the German text are three small icons: a speech bubble, a speaker, and a checkmark. At the bottom, a note says: "Neu! Klicken Sie auf die Wörter oben, um Alternativübersetzungen zu bearbeiten und anzusehen. [Schließen](#)".

Text Documents Websites

KOREAN - DETECTED ENGLISH SPANISH FRENCH ▾ ↔ ENGLISH KOREAN ITALIAN ▾

자연어 처리(自然語處理) 또는 자연 언어 처리(自然言語處理)는 인간의 언어 현상을 컴퓨터와 같은 기계를 이용해서 묘사할 수 있도록 연구하고 이를 구현하는 인공지능의 주요 분야 중 하나다. 자연 언어 처리는 연구 대상이 언어 이기 때문에 당연하게도 언어 자체를 연구하는 언어학과 언어 현상의 내적 기재를 탐구하는 언어 인지 과학과 연관이 깊다. 구현을 위해 수학적 통계적 도구를 많이 활용하며 특히 기계학습 도구를 많이 사용하는 대표적인 분야이다. 정보검색, QA 시스템, 문서 자동 분류, 신문기사 클러스터링, 대화형 Agent 등 다양한 응용이 이루어지고 있다.

jayeon-eo cheoli(jayeon-eocheoli) ttoneun jayeon eon-eo cheoli(jayeon-eon-eocheoli)neun ingan-ui eon-eo hyeonsang-eul keompyuteowa gat-eun gigyeleul iyonghaeseo myosahal su issdolog yeonguhago ileul guhyeonhaneun ingongjineung-ui


Show more

316 / 5,000 

Natural language processing or natural language processing is one of the main fields of artificial intelligence that studies and implements human language phenomena to be described using machines such as computers. Natural language processing is naturally closely related to linguistics, which studies language itself, and language cognitive science, which explores the internal mechanisms of language phenomena, since the subject of study is language. It is a representative field that uses a lot of mathematical and statistical tools for implementation, especially machine learning tools. Various applications such as information retrieval, QA system, automatic document classification, newspaper article clustering, and interactive agent are being made.

 Send feedback




The screenshot shows a user interface for machine translation. At the top, there are three tabs: 'Text' (selected), 'Documents', and 'Websites'. Below the tabs, there are two rows of language detection buttons: 'DETECT LANGUAGE', 'KOREAN', 'ENGLISH', 'SPANISH' on the left, and 'ENGLISH', 'KOREAN', 'ITALIAN' on the right. A search bar labeled 'Search languages' is present. The main area is a table of language pairs:

Detect language	Czech	Hindi	Latvian	Polish	Tamil
Afrikaans	Danish	Hmong	Lingala	Portuguese	Tatar
Albanian	Dhivehi	Hungarian	Lithuanian	Punjabi	Telugu
Amharic	Dogri	Icelandic	Luganda	Quechua	Thai
Arabic	Dutch	Igbo	Luxembourgish	Romanian	Tigrinya
Armenian	English	Ilocano	Macedonian	Russian	Tsonga
Assamese	Esperanto	Indonesian	Maithili	Samoan	Turkish
Aymara	Estonian	Irish	Malagasy	Sanskrit	Turkmen
Azerbaijani	Ewe	Italian	Malay	Scots Gaelic	Twi
Bambara	Filipino	Japanese	Malayalam	Sepedi	Ukrainian
Basque	Finnish	Javanese	Maltese	Serbian	Urdu
Belarusian	French	Kannada	Maori	Sesotho	Uyghur
Bengali	Frisian	Kazakh	Marathi	Shona	Uzbek
Bhojpuri	Galician	Khmer	Meiteilon (Manipuri)	Sindhi	Vietnamese
Bosnian	Georgian	Kinyarwanda	Mizo	Sinhala	Welsh
Bulgarian	German	Konkani	Mongolian	Slovak	Xhosa
Catalan	Greek	Korean	Myanmar (Burmese)	Slovenian	Yiddish
Cebuano	Guarani	Krio	Nepali	Somali	Yoruba
Chichewa	Gujarati	Kurdish (Kurmanji)	Norwegian	Spanish	Zulu
Chinese (Simplified)	Haitian Creole	Kurdish (Sorani)	Odia (Oriya)	Sundanese	
Chinese (Traditional)	Hausa	Kyrgyz	Oromo	Swahili	
Corsican	Hawaiian	Lao	Pashto	Swedish	
Croatian	Hebrew	Latin	Persian	Tajik	

Anwendungen der Computerlinguistik

= NLP, linguistische Datenverarbeitung, ...

- Maschinelle Übersetzung (Google, DeepL, ...)
- Rechtschreibkorrektur und Grammatikprüfung
- Virtuelle Keyboards
- Spamerkennung
- (Semantische) Websuche
- Diktieren & Sprachsteuerung
- Sprachausgabe (z.B. Navi)
- Sprachdialogsystem (z.B. im Auto, Fahrplanauskunft, ...)
- Virtuelle Assistenten (z.B. Siri, Alexa, Cortana, ...)
- KI (Watson, IBM Project Debater, ...)
- Meinungs- & Marktforschung
- Wörterbücher (zweisprachige, Lerner-WB, Kollokations-WB)
- Information Retrieval & Question Answering
- Text / Knowledge Mining (z.B. Biomedizin, Patentrecherche)
- Social Bots & Fake News
- Kontrollierte Terminologie
- Plagiaterkennung
- Automatische Bewertung von Klausuren und Hausarbeiten
- Spam verfassen
- Forensik & Aufklärung (z.B. linguistische Steganographie)



1. Grundlagen

- 1.1 Computerlinguistik
- 1.2 Korpora
- 1.3 Korpuslinguistik

2. Ausgewählte Anwendungen

- 2.1 Tracking the Infodemic
- 2.2 Financial Narrative Processing
- 2.3 Argumentation Mining

Corpus

OXFORD UNIVERSITY PRESS Views 1,883,913 Updated Jun 11 2018

cor·pus / 'kôrpəs/

- n. (pl. **-po·ra** / -pərə/ or **-pus·es**) **1.** a collection of written texts, esp. the entire works of a particular author or a body of writing on a particular subject: *the Darwinian corpus*.
 - a collection of written or spoken material in machine-readable form, assembled for the purpose of studying linguistic structures, frequencies, etc.
- 2.** Anat. the main body or mass of a structure.
 - the central part of the stomach, between the fundus and the antrum.

The Oxford Pocket Dictionary of Current English

- Korpus^a als repräsentative Stichprobe der Sprache
- Korpus als maschinenlesbare Textsammlung

^aAchtung: das Korpus, die Korpora

Korpus im engeren Sinn = repräsentative **Stichprobe**

- repräsentativ für Sprachvarietät, Register, Spezialsprache, Gruppe von Sprechern, ...
- statistische Inferenz generalisiert Beobachtungen
- Brown Corpus: AmE Schriftsprache der 1960er Jahre
 - 500 Textausschnitte à 2000 Wörtern = 1M Wörter
 - 15 Genres (Zeitungen, Akad., Sachbücher, Belletristik)
- British National Corpus: BrE der 1990er Jahre
 - 90M Schriftsprache + 10M gesprochene Sprache
 - umfangreiche Metadaten zu Texten und Sprechern

Korpus im weiteren Sinn = elektronische **Textsammlung**

- Korpussuche, statistische Auswertung, Training von maschinellen Lernverfahren, Wissensextraktion
- Digital Humanities: Digitalisierung von Kulturgütern
- Computerlinguistik (NLP): bigger is better
- Webkorpora: opportunistische Sammlung v. Webseiten
 - WaCky (2007): je 2G Wörter Englisch, Deutsch, ...
 - COW (2014): > 10G Wörter Englisch, Deutsch, ...
- N-Gramm-Datenbanken: Häufige Wortsequenzen
 - Google Web1T5 aus ca. 1T (Billion) Wörter Webseiten
 - Google Books: bis zu 900G Wörter aus gescannten Büchern

- Objektdaten = Texte
 - primärer Untersuchungsgegenstand
- Metadaten = Informationen über die Texte
 - Titel, Autor/in, Veröffentlichungsdatum, Textsorte, ...
 - Alter, Geschlecht, Bildungsstand, ... der Autoren
- Typographie & Textstruktur
 - Abschnitte, Überschriften, Schriftarten, Listen, ...
- Annotation = linguistische Interpretation
 - einfach (Wortebene) vs. strukturiert (z.B. Syntax)
 - Voraussetzung für die Erschließung großer Korpora




Annotation auf Wortebene

- Jedem (laufenden) Wort wird eine Kategorie zugeordnet
 - sog. Tagging (= Etikettierung)
 - Voraussetzung: Text muss in Wörter zerlegt sein
- Tokenisierung
 - Token = Wort, Zahl, Symbol (!), Satzzeichen, ...
 - im Gegensatz zu Typen = verschiedene Wörter
 - kann schwieriger sein, als man vermuten würde ...

@Mia1234 #semibk [1] Das schließt direkt an die vorige Frage von @DieMaja22 an. In jedem Fall gibt es (wie auch in der Sitzung ...@Mia1234 #semibk [2]am BspChats gezeigt) starke Hinweise darauf, dass(wie auch imRealLife) diverseFaktoren die sprVariation beeinflussen: <http://tinyurl.com/3umxkuh>

- Wortartenannotierung = POS-Tagging
 - Substantiv (noun), Adjektiv, Verb, Adverb, Pronomen, Präposition, Konjunktion, Zahl, Satzzeichen, ...
 - engl. POS = part of speech
 - Tagset = Kategorienschema (fein vs. grob)



The image shows a sentence from Douglas Adams' "The Hitchhiker's Guide to the Galaxy": "Mr. Arthur Dent never liked the Sirius Cybernetics Corp.". Each word is followed by a colored bracket indicating its part of speech: Mr. (NNP), Arthur (NNP), Dent (NNP), never (RB), liked (VBD), the (DT), Sirius (NNP), Cybernetics (NNP), Corp. (NNP). The colors correspond to the tagset categories: blue for NNP, red for RB, green for VBD, purple for DT, and yellow for NN.

- zusätzlich:
 - Lemmatisierung
 - semantische Kategorien
 - emotionale Valenzen
 - Schwierigkeitsgrad


POS-Tagset: STTS (Deutsch)

ADJA	attributives Adjektiv
ADJD	adverbiales / prädikatives Adjektiv
ADV	Adverb <i>schon, bald, doch</i>
APPR	Präposition / Zirkumposition links
APPART	Präposition mit Artikel fusioniert zum
APPO	Postposition <i>zufolge, wegen</i>
APZR	Zirkumposition rechts <i>von ... an</i>
ART	bestimmter oder unbestimmter Artikel
CARD	Kardinalzahlen (Ordinalzahl = ADJA)
FM	Fremdsprachliches Material
ITJ	Interjektion <i>mhm, ach, tja</i>
KOUI	unterordnende Konj. mit zu + Inf
KOUS	unterordnende Konjunktion mit Satz
KON	nebenordnende Konjunktion <i>und, oder</i>
KOKOM	Vergleichskonjunktion <i>als, wie</i>
NN	normales Nomen
NE	Eigenname
PDS	substituierendes Demonstrativpron.
PDAT	attribuierendes Demonstrativpron.
PIS	substituierendes Indefinitpron.
PIAT	attrib. Indefinitpron. ohne Determiner
PIDAT	attrib. Indefinitpron. mit Determiner
PPER	Personalpronomen (nicht reflexiv)
PPOS	substituierendes Possessivpronomen
PPOSAT	attribuierendes Possessivpronomen
PRELS	substituierendes Relativpronomen
PRELAT	attribuierendes Relativpronomen


PRF	reflexives Personalpronomen
PWS	substituierendes Interrogativpron.
PWAT	attribuierendes Interrogativpronomen
PWAV	adverbiales Interrogativ-/Relativpron.
PAV	Pronominaladverb <i>dafür, deswegen</i>
PTKZU	zu vor Infinitiv
PTKNEG	Negationspartikel <i>nicht</i>
PTKVZ	abgetrennter Verbzusatz <i>kommt ... an</i>
PTKANT	Antwortpartikel <i>ja, nein, danke</i>
PTKA	Partikel bei Adjektiv/Adverb <i>am, zu</i>
TRUNC	Kompositions-Erstglied <i>Unter- und ...</i>
VVFIN	finites Verb, voll (= lexikalisch)
VVIMP	Imperativ, voll
VVINF	Infinitiv, voll
VVIZU	Infinitiv mit zu, voll
VVPP	Partizip Perfekt, voll
VAFIN	finites Hilfsverb
VAIMP	Imperativ, Hilfsverb
VAINF	Infinitiv, Hilfsverb
VAPP	Partizip Perfekt, Hilfsverb
VMFIN	Finites Modalverb
VMINF	Infinitiv, Modalverb
VMPP	Partizip Perfekt, Modalverb
XY	Nichtwort mit Sonderzeichen <i>3:7, H2O</i>
\$,	Komma ,
\$.	Satzbeendende Interpunktions . ? ! ; :
\$()	sonstige Satzzeichen (intern) - [] ()

Segmente und Strukturen

- Erkennung von speziellen Wortfolgen (**Segmenten**) und ihre Kategorisierung
 - z.B. Eigennamen (NER = named entity recognition)




- Erkennung der **Satzstruktur** = Parsing
 - z.B. Abhängigkeiten zwischen Wörtern (Dependenz-Graph)




- alternativ: Phrasenstruktur als baumförmige Hierarchie
- „minimale“ Phrasen können auch als Segmente interpretiert werden (Chunk-Parsing)

Linguistische Annotation von Korpora

Satzstruktur als Baum



- kleine Korpora werden oft **manuell** annotiert
 - z.B. digitale Editionen, Reden eines Präsidenten, ...
- Annotationsschema und -kategorien
- Richtlinien (Guidelines)
 - zusätzlich: Beispielsammlung für schwierige Einzelfälle
- Annotationswerkzeuge (meist Web-basiert)
 - z.B. brat (<https://brat.nlplab.org/>)
- Inter-Annotator Agreement (IAA)
 - überprüft Reliabilität und Validität der Annotation
 - Flüchtigkeitsfehler vs. systematische Differenzen
- für größere Korpora ist eine manuelle Annotation zu teuer und zeitaufwändig
 - Romane von Charles Dickens: ca. 4 Mio. Wörter
 - Deutsches Gutenberg-Archiv: > 100 Mio. Wörter
 - Early English Books (EEBO): > 500 Mio. Wörter
 - Times Online 1780–1900: ca. 4.000 Mio. Wörter
- **automatische** Verfahren zur Annotation von großen Datenmengen
- erfolgreichster Ansatz: maschinelle Lernverfahren
- Trainingskorpus (manuell annotiert)
 - wichtig: Konsistenz der Annotationen
 - Flüchtigkeitsfehler scheinen weniger problematisch
- Evaluation auf separatem Testkorpus
 - Gefahr der Überanpassung an das Trainingskorpus
- Beispiel: Tagging mit Hidden Markov Model (HMM)



```

<article year="2010" month="2010-01" date="2010-01-01" fname="litauenreaktor100" rubrik="ausland">
<p type="topline">
<s>
Forderung      NN
der          ART
EU            NE
erfüllt    VVPP
</s>
</p>
<p type="headline">
<s>
Litauen NE
schaltet    VVFIN
sein        PPOSAT
letztes     ADJA
Atomkraftwerk  NN
ab          PTKVZ
</s>
</p>
<p type="base">
<s>
Litauen NE
hat         VAFIN
sein        PPOSAT
einziges    ADJA
Atomkraftwerk  NN
endgültig   ADJD
abgeschaltet VVPP
.           $.
</s>

```

corpus position	word form	ID	part of speech	ID	lemma	ID
(0)	<text>	value	=	"id=42 lang="English"		
(0)	<text_id>	value	=	"42"		
(0)	<text_lang>	value	=	"English"		
(0)	<s>					
0	An	0	DET	0	a	0
1	easy	1	ADJ	1	easy	1
2	example	2	NN	2	example	2
3	.	3	PUN	3	.	3
(3)	</s>					
:	:					
(13)	</text_lang>					
(13)	</text_id>					
(13)	</text>					

1. Grundlagen

- 1.1 Computerlinguistik
- 1.2 Korpora
- 1.3 Korpuslinguistik

2. Ausgewählte Anwendungen

- 2.1 Tracking the Infodemic
- 2.2 Financial Narrative Processing
- 2.3 Argumentation Mining

- Abfrage von Korpora via Korpusabfragesprachen (CQL)
- Softwarelösungen nutzen unterschiedliche Abfragesprachen:
 - CQP (CQPweb, SketchEngine)
 - AQL (ANNIS)
 - COSMAS II QL (DeReKo)
- manche Ressourcen sind in der Praxis nur über Software verfügbar, die *eine spezielle CQL* verwendet
- Abfragesprachen sind unterschiedlich ausdrucksstark:
 - finde alle Wörter, die auf *ität* enden
 - finde alle Sätze, die sowohl *Covid* als auch *Bayern* enthalten
 - finde alle Nomina, die durch *gut* modifiziert werden
- CCL Erlangen: CQP als Abfragesprache
 - vereinfachte Version in CQPweb
 - Arbeit an einer Corpus Query Lingua Franca (CQLF)




Abbildung: Frequency Breakdown der Query (GermaParl).

```
[lemma="global"] [lemma="Erwärmung"] | [lemma="Klimawandel"] | [lemma="Klimalüge"] | ...
```

No.	Text	Solution 1 to 50	Page 1 / 38
1	p_19_111_56	dass es in Zukunft Kriege gibt , die etwas mit dem	Klimawandel zu tun haben , der muss heute den Klimawandel bekämpfen . Daher
2	p_19_231_49	Welche habe ich vorhin gesagt ?) – Sie ignorieren den menschengemachten	Klimawandel . Und Sie reden hier mit jemandem , der Biologie studiert hat
3	p_19_176_151	Flucht . Schon heute werden innerstaatlich mehr Menschen durch die Folgen der	Klimakrise vertrieben als durch Gewalt und Konflikte . Am härtesten trifft es den
4	p_19_48_35	Braun und Gelb dort , wo eigentlich Grün sein müsste . Die	Klimakrise selbst ist das größte Problem , die größte Zumutung , die wir
5	p_19_63_82	darauf eingegangen : Im Bundeshaushalt geschieht jetzt schon einiges , um den	Klimawandel zu stoppen bzw. wenigstens zu verlangsamen . Im vergangenen Jahr 2017 sagte
6	p_19_24_161	wenn er mich fragt : Warum habt ihr nichts gegen den menschengemachten	Klimawandel getan ? (Beifall bei der FDP , der SPD und dem
7	p_19_111_154	denn nun will auch das BMZ verstärkt in die weltweite Bekämpfung des	Klimawandels einsteigen . Herr Minister , Sie sagten vor wenigen Wochen in der
8	p_19_81_11	Ihnen , dass Sie auch etwas vorlegen ; denn in Zeiten der	Klimakrise können wir nicht über KI reden , ohne diese Themen ganz klar
9	p_19_175_406	Das Geld fehlt für Investitionen und befeuert vor allen Dingen massiv die	Klimakrise . Wenn wir also eine nachhaltige Finanzpolitik machen wollen , können wir
10	p_19_184_239	sich beliebig fortsetzen , von den immensen Herausforderungen der Coronapandemie und der	Klimakrise ganz zu schweigen . Und bei all diesen Problemen richtet sich der
11	p_19_238_96	Beifall bei der AfD) und : „ Die Behauptung , der	Klimawandel ist schuld , ist ... nicht haltbar . “ Das war ein
12	p_19_54_323	der gegen RWE klagt , weil sein Bergdorf in den Anden vom	Klimawandel bedroht ist . Wie es jetzt aussieht , hat seine Klage sogar
13	p_19_182_233	jetzt umso mehr ; denn wir haben erlebt , wie sich die	Klimakrise verschärft , wir haben doch erlebt , was in Australien los war
14	p_19_205_335	dass die Landwirtschaft einen Beitrag leisten muss im Kampf gegen den	Klimawandel . Weltweit steht immer weniger Fläche zur Verfügung . Und wir haben
15	p_19_44_121	einfacher Kaufmann auch nicht wie Sie hier ein pseudowissenschaftliches Seminar zum Thema	Klimawandel halten . Ich probiere es erst einmal versöhnlich . (Karsten Hilse
16	p_19_179_129	mit denen wir konfrontiert sind – Stichwort „ Klimawandel “ . Der	Klimawandel – wir haben das vorhin auch schon angesprochen – ist ein sicherheitsrelevanter
17	p_19_135_96	wie viel Geld wir , die Industrienationen und somit die Hauptverursacher des	Klimawandels , für von Naturkatastrophen betroffene Länder beisteuern , wenn wir unsere Hausaufgaben
18	p_19_99_138	Aber natürlich gehört zu den Herausforderungen auch der Kampf gegen den	Klimawandel . Wir wollen das Klimaschutzbkommen erfüllen , damit die Temperatur auf der
19	p_19_80_201	denn die Welt schaut , wie wir den Kampf gegen den	Klimawandel aufnehmen . Ich hatte das Vergnügen und die Ehre , an der
20	p_19_185_119	wenn man auf der einen Seite sagt : „ Die Bekämpfung des	Klimawandels und das Gelingen der Energiewende sind von essentieller Bedeutung für die Zukunft

- Kollokate eines Wortes (dem *Knoten*, oder engl. *node*) sind Wörter, die häufig in dessen Umgebung auftreten (Ko-Okkurrenz)
- Einblick in die Semantik des Wortes, vgl. Firth's (1957) *distributional hypothesis*:
You shall know a word by the company it keeps!
- Anwendung bspw. in der *Diskursanalyse*, *Lexikographie*, ...
- Kollokation als Phänomen, das in Korpora empirisch beobachtbar ist
 - Kollokate von „Klimawandel“ in GermaParl
 - Kollokate von „Impfung“ auf Twitter
- Kollokate \neq Mehrworteinheiten, Idiome, Phraseologismen, ...
- Parameter: Kollokationsart, Fenstergröße, Assoziationsmaß, ...

rank	lemma	LRC
1	menschengemacht	11.74
2	Artensterben	9.20
3	Ressourcenknappheit	7.76
4	Anpassungsstrategie	7.74
5	Menschheitsherausforderung	6.85
6	Erderwärmung	6.37
7	Dürre	6.19
8	drohend	5.98
9	Wetterextrem	5.89
10	Hauptverursacher	5.66
11	Wassermangel	5.62
12	Artenvielfalt	5.48
13	Bevölkerungswachstum	5.37
14	Anpassungsmaßnahme	5.34
15	Biodiversität	5.27
16	Herausforderung	5.24
17	Naturkatastrophe	5.23
18	Ernährungskrise	5.22
19	Treibhauseffekt	5.16
20	leugnen	5.08

Tabelle: 10L-10R-S-Kollokate zu *Klimawandel* (GermaParl).

rank	lemma	LLR
1	menschengemacht	2406.84
2	Herausforderung	1848.52
3	die	1425.40
4	Folge	1400.30
5	global	1099.30
6	Auswirkung	854.99
7	Anpassung	850.94
8	Bekämpfung	826.61
9	Kampf	790.89
10	drohend	703.85
11	gegen	652.04
12	Artensterben	616.13
13	bekämpfen	545.56
14	leugnen	526.50
15	,	492.06
16	dass	482.90
17	Digitalisierung	461.30
18	aufhalten	402.87
19	Klimaschutz	389.67
20	und	376.72

Tabelle: 10L-10R-S-Kollokate zu *Klimawandel* (GermaParl).

rank	lemma	MI
1	menschengemacht	3.38
2	Menschheitsherausforderung	3.08
3	Artensterben	3.04
4	Ressourcenknappheit	3.03
5	Extremwetterlage	3.00
6	Ernährungskrise	2.99
7	Biodiversitätsverlust	2.97
8	Anpassungsstrategie	2.89
9	Leugner	2.85
10	Wetterextrem	2.83
11	Nicholas	2.70
12	Wassermangel	2.68
13	Extremwetterereignis	2.65
14	Eisbär	2.64
15	Klimaflüchtling	2.62
16	Hungerkrise	2.58
17	Dürreperiode	2.56
18	Menschheitsfrage	2.56
19	Wüstenbildung	2.52
20	Erderwärmung	2.50

Tabelle: 10L-10R-S-Kollokate zu *Klimawandel* (GermaParl).

ID	... context	keyword	context ...
0	Dieses Beispiel zeigt einmal mehr , welche gravierenden Auswirkungen der	Klimawandel	gerade auf die Meere und die marinen Ökosysteme hat .
1	Angesichts von Überfischung , Vermüllung der Meere und	Klimawandel	ist dieses Argument mehr als fragwürdig .
2	Grund dafür ist der	Klimawandel	, der den Meeresspiegel ansteigen lässt .
3	Mit Einsatz im Indischen und Pazifischen Ozean soll die FS „Sonne“ dazu beitragen , relevante Forschungsfragen hinsichtlich des	Klimawandels	, der Versorgung mit Rohstoffen aus dem Meer und der Folgen des Eingreifens in die Ökosysteme zu beantworten .
4	Die Temperaturen steigen , der Meeresspiegel steigt , Wetterextreme häufen sich : Der	Klimawandel	ist da .
5	Der globale	Klimawandel	führt zu einer Erhöhung des Meeresspiegels , zur Häufung von Wetterextremen wie Stürmen oder Starkregen und in manchen Regionen z...
6	Dennoch kommen wir nicht an der Tatsache vorbei , dass der	Klimawandel	natürlich auch Auswirkungen auf die Meere und die Biodiversität dort hat .
7	...elber werden immer stärker durch die Begleiterscheinungen unserer modernen Welt gefährdet : Meeres - und Umweltverschmutzung ,	Klimawandel	, Beifänge in der Fischerei , Schiffsvorkehr , Unterwasserlärm und Offshoreaktivitäten .
8	Angesichts der drohenden	Klimakatastrophe	, der fortschreitenden Zerstörung der Wälder und Meere , angesichts des Aussterbens zahlreicher Tier- und Pflanzenarten muß die Erha...
9		Klimawandel	, Plastikmüll in den Meeren , Artensterben , das alles sind weltweite Probleme , die wir nur gemeinsam in der Staatengemeinschaft werden l...
10	Es gibt tatsächlich immer wieder welche , die nicht wahrhaben wollen , welche Bedrohung für die Bevölkerung mit dem	Klimawandel	einhergeht : millionenfach Klimaflüchtlinge , Anstieg der Meeresspiegel , Erderwärmung , die auch Ernteschäden nach sich zieht ; ic...
11	Die Meere sind wichtige Seismographen des	Klimawandels	und der Biodiversität .
12	...erung von Ökosystemen nennen , auf die Zerstörung der Regenwälder hinweisen , die Überfischung der Meere anprangern , die Folgen des	Klimawandels	analysieren sowie auf das größte Artensterben seit der Zeit der Dinosaurier eingehen .
13	Wir stehen vor riesigen Herausforderungen :	Klimakrise	, Artensterben , Vermüllung der Meere mit Plastik .
14	Hinzu kommen - als wäre das alles noch nicht bedrohlich genug - die Erwärmung und Versauerung der Meere durch den	Klimawandel	.
15	Aber wir haben große Gebiete auf der Welt , die noch nicht so zugänglich sind - das sind vor allen Dingen die Meere - , die wir aber über	Klimawandel	und vieles andere schon sehr verändern .
16	Absurd ist , dass wir das Weddellmeer und andere Teile der Meere deshalb schützen müssen , weil es den	Klimawandel	gibt , weil heute bestimmte Teile der Meere eben ganz anders zugänglich sind , als sie es in der Vergangenheit waren , und wir in der Lage ...
17	...innung von Bodenschätzen und Energie aus dem Meer . Verschmutzung und Vermüllung sowie die Erwärmung der Meere infolge des	Klimawandels	sind nur einige Stichworte .
18	Viel lesen können wir auch jeden Tag über die Auswirkungen des	Klimawandels	und die Erwärmung der Meere
19	Die Kommission geht davon aus , dass infolge des	Klimawandels	die Niederschlagsmengen und der Meeresspiegel steigen und wetterbedingte Naturkatastrophen häufiger werden .
20	...t es wichtig , dass wir dem Meeresschutz als Naturschutz mehr Raum geben , dass wir Programme starten , dass wir eben auch , je mehr der	Klimawandel	den Meeren zusetzt , umso mehr dafür sorgen , dass es Räume gibt , wo Meeresschutz sich entsprechend entfalten kann .
21	Wer sich mit dem Bericht des Weltklimarates auseinandersetzt hat , weiß , dass der	Klimawandel	zu einem Anstieg der Meeresspiegel führen wird .
22	Erzählen Sie doch mal einer Familie auf Langeoog , deren Haus im Meer versinkt , es gäbe keinen	Klimawandel	!
23	So können genau diese Bewohner der Küsten auch vor dem	Klimawandel	und den daraus resultierenden katastrophalen Folgen des Anstiegs des Meeresspiegels geschützt werden .
24	Betroffen ist das Wattenmeer in dramatischer Form - das ist gerade schon angesprochen worden - vom	Klimawandel	, insbesondere vom Anstieg des Meeresspiegels , der diesen Raum , der sich über einen Zeitraum von mehr als 7 000 Jahren dort gebil...

- *Keywords* sind Wörter, die in einem gegebenen Korpus überdurchschnittlich oft vorkommen – im Vgl. zur Häufigkeit in einem *Referenzkorpus*
- *Keyness* ist ein textuelles, kein sprachliches Feature
 - gesprochene Sprache vs. geschriebene Sprache
 - soziale Medien vs. Zeitungen
 - Hochliteratur vs. Groschenromane
 - links-liberale Zeitungen vs. rechts-konservative Zeitungen
 - Grüne vs. AfD
 - ...
- Anwendung bspw. in der *Diskursanalyse*, *Indexerstellung*, ...

rank	lemma	LRC
1	Klimahysterie	6.96
2	Altpartei	6.95
3	Masseneinwanderung	6.44
4	0,000653	6.06
5	Lockdown	5.78
6	Klimareligion	5.62
7	Timon	5.61
8	Windindustrieanlage	5.58
9	Gremmels	5.53
10	Nullzinspolitik	5.45
11	AfD	5.44
12	Altfraktion	5.34
13	Coronamaßnahmen	5.33
14	Antifa	5.32
15	Shutdown	5.27
16	Massenmigration	5.25
17	Coronapolitik	5.24
18	globalistisch	5.17
19	Lockdowns	5.16
20	Greta	5.15

Tabelle: Keywords der AfD (GermaParl).

GermaParl (1949–2021) vs. SZ




Abbildung: Keywords bei Referenz SZ 2011–2014





Abbildung: Keywords bei Referenz SZ 2019–2021



Korpuslinguistik als Methodenwissenschaft (corpus-based research)

- Erstellung von Korpora als Stichproben
(Grundgesamtheit, Stichprobenplanung, ...)
- Automatische linguistische Annotation
(schwierig z.B. für literarische oder historische Texte)
- Werkzeuge für Query & Visualisierung
- Quantitative Auswertung mit statistischen Tests
→ methodologische Schwierigkeiten
- Statistische Modellierung & explorative Verfahren

Korpuslinguistik als Teildisziplin der Sprachwissenschaft (corpus-driven research)

- Britische Forschungstradition seit 1950er Jahren
(Firth, Sinclair, Halliday, Leech, McEnery, ...)
- Keywords, Kollokationen, semantische Prosodie, ...
- Auch qualitative Analyse von Konkordanzen
(John Sinclair: *trust the text!*)
- Vorwiegend deskriptiv, Fokus auf Anwendungen
- Themen: Sprachvarietäten, soziologische und politische Aspekte, Spracherwerb und -unterricht, ...

- Dialektologie, kontrastive Linguistik, Kulturwissenschaft
- Fremdsprachenunterricht & Spracherwerb (→ CALL)
- Grammatik & Syntax (→ Quirk/Greenbaum CGEL)
- Historische Sprachwissenschaft & Sprachwandel
- Lexikalische Semantik (→ semantische Prosodien)
- Lexikographie & Lexikologie (→ COBUILD, Kollokations-WB)
- Morphologie (→ Produktivitätsbegriff)
- Phonologie (→ Sprachatlas)
- Pragmatik & Diskursanalyse (→ Rhetorik, Soziologie, Politik)
- Soziolinguistik (→ Gender Studies, Sprachideologie)
- Sprachdokumentation (→ bedrohte Sprachen)
- Sprachvariation (→ z.B. Registeranalyse nach Biber)
- Stilometrie & Literaturwissenschaft (→ Autorenerkennung)
- Übersetzungswissenschaft (→ „Translationese“)

1. Grundlagen

- 1.1 Computerlinguistik
- 1.2 Korpora
- 1.3 Korpuslinguistik

2. Ausgewählte Anwendungen

- 2.1 Tracking the Infodemic
- 2.2 Financial Narrative Processing
- 2.3 Argumentation Mining

1. Grundlagen

- 1.1 Computerlinguistik
- 1.2 Korpora
- 1.3 Korpuslinguistik

2. Ausgewählte Anwendungen

- 2.1 Tracking the Infodemic
- 2.2 Financial Narrative Processing
- 2.3 Argumentation Mining

- Tracking the Infodemic: Automatische Identifikation von **Verschwörungstheorien** in sozialen Medien
- WHO warnt 2020: „Infodemie“ neben der Pandemie
 - Verschwörungstheorien
 - Misrepräsentation von medizinischen Fakten
 - Desinformation
- vorhersehbar:
 - Debatten finden unmoderiert online statt
 - Glaube an Verschwörungstheorien ist stärker in Zeiten von Unsicherheit („Wissensvakuum“)
- in Deutschland glaubt 1 von 5, dass die
 - Gefahren von SARS-CoV-2 absichtlich übertrieben wurden und (Infratest dimap)
 - Zahlen und Statistiken gefälscht sind (Institut für Demoskopie Allensbach)

Tracking the Infodemic


Eine Infodemie während einer Pandemie

Zustimmung zu ausgewählten Verschwörungstheorien nach Parteianhängerschaft

Quelle: Allensbacher Archiv, IfD-Umfrage 12049 (2022)

- █ Viele Zahlen und Statistiken zu Corona sind gefälscht, um Angst zu verbreiten.
- █ Die Corona-Impfung ist gefährlicher als die Krankheit selbst. Die Impfung verursacht schwere Schäden.
- █ Ich fürchte, dass man allen Menschen Mikrochips einpflanzen will, um sie besser kontrollieren zu können.

- █ Die Regierung nutzt die Krise als Vorwand, um dauerhaft die Grundrechte der Bürger einzuschränken.
- █ Bill Gates ist der eigentlich Schuldige an der Corona-Krise. Er nutzt die Krise, um eine neue Weltordnung zu errichten.



Daten

Datensammlung

- Identifikation bekannter Verschwörungstheoretiker (KenFM, Eva Herman, Attila Hildmann, Bodo Schiffmann, Oliver Janich usw.)
- Scraping ausgewählter, öffentlicher Kanäle und verknüpfter Chat-Gruppen
- Ergänzung des Korpus um häufig genannte/zitierte Kanäle (mehrmals)

Korpus: Infodemic-Telegram-v1

- über 130 Kanäle, 20 öffentliche Gruppenchats
- ca. 4,5 Mio. Beiträge
- ca. 150 Mio. Token

1	Demokratie & Systemmedien	130
2	Pseudopandemie	78
3	Rechtsaußen	77
4	QAnon	75
5	Corona-Verschwörungsnarrative	73
6	Maßnahmenkritik	43
7	Impfängste	40
8	Esoterik & Medizingeschwurbel	39
9	allgemeine Verschwörungsnarrative	31
10	Schlafschafe	19
11	Millenarismus / Tag der Abrechnung	14
12	Alternative Gegenmittel	10

Tabelle: Häufigkeiten von Narrativgruppen in 500 zufälligen Texten

Zero-Shot-Klassifikation: Satzähnlichkeiten



- Idee: Vergleiche Sätze der Posts mit Narrativ-Beschreibungen

Satz	Narrativ	Ähnlichkeit
Glaubt mir es gibt kein Coronavirus, das ist kompletter Schwachsinn.	Corona gibt es nicht.	0.82
Die Impfungen sind keine Viren Schutzimpfungen sondern tödlich!	Impfung ist gefährlich.	0.76
Impfstoffbedingte Schäden an unseren Blutgefäßen sind häufig.	Impfung ist gefährlich.	0.74
Die neue Weltordnung - Great Reset wartet.	Pandemie ist geplant.	0.53
...

- Satzähnlichkeiten via Kosinusähnlichkeit von Satz-Embeddings
 - Embedding = hochdimensionaler Vektor, der die Semantik des Satzes anhand von Ko-Okkurrenz-Mustern einfängt

Tracking the Infodemic

Zero-Shot-Klassifikation: Evaluation



classifier

- trained ML
- zero shot

Show Case: Analyse von Bundestagsdebatten


1. Grundlagen

- 1.1 Computerlinguistik
- 1.2 Korpora
- 1.3 Korpuslinguistik

2. Ausgewählte Anwendungen

- 2.1 Tracking the Infodemic
- 2.2 Financial Narrative Processing
- 2.3 Argumentation Mining

- Untersuchungsgegenstand: AdHoc-Mitteilungen
 - Unternehmensberichte bei Ereignissen, die den Aktienkurs beeinflussen können
- Daten
 - gut 30,000 Mitteilungen von deutschen Unternehmen
 - kumulative abnormale Rendite bei Veröffentlichung
- Vorhersage des Aktienkurses
 1. Ontologie-basierte Identifikation von Themen
 2. Integration der Merkmale in klassische MLV



Financial Narrative Processing

Analyse von Jahresberichten

- Untersuchungsgegenstand: Jahresberichte in den USA
 - eingereicht via SEC's EDGAR filing system ("form 10-k")
 - Format: XBRL + Fließtext (ohne semantisches Mark-Up)
- Daten
 - knapp 80,000 Berichte (2006 – 2015)
 - Informationen über Unternehmen (bspw. Industrie-Kategorisierung)
- Identifikation von *red flags*
 - „zwischen den Zeilen lesen“
 - stilometrische Merkmale der einzelnen Abschnitte

**UNITED STATES
SECURITIES AND EXCHANGE COMMISSION
Washington, D.C. 20549**

FORM 10-K

(Mark One)
 ANNUAL REPORT PURSUANT TO SECTION 13 OR 15(d) OF THE SECURITIES EXCHANGE ACT OF 1934
For the fiscal year ended October 31, 2018
Or
 TRANSITION REPORT PURSUANT TO SECTION 13 OR 15(d) OF THE SECURITIES EXCHANGE ACT OF 1934
For the transition period from _____ to _____
Commission file number 001-37483

HEWLETT PACKARD ENTERPRISE COMPANY
(Exact name of registrant as specified in its charter)

Delaware 47-3298624
(State or other jurisdiction of incorporation or organization) (I.R.S. employer identification no.)
3000 Hanover Street, Palo Alto, California 94304
(Address of principal executive offices) (Zip code)
Registrant's telephone number, including area code: (650) 687-5817
Securities registered pursuant to Section 12(b) of the Act:
Title of each class Name of each exchange on which registered
Common stock, par value \$0.01 per share New York Stock Exchange
Securities registered pursuant to Section 12(g) of the Act:
None

Act. Indicate by check mark if the registrant is a well-known seasoned issuer as defined in Rule 405 of the Securities Act. Yes No
Indicate by check mark if the registrant is not required to file reports pursuant to Section 13 or Section 15(d) of the Securities Exchange Act of 1934 during the preceding 12 months (or for such shorter period that the registrant was required to file such reports), and (2) has been subject to such filing requirements for the past 90 days. Yes No
Indicate by check mark whether the registrant (1) has filed all reports required to be filed by Section 13 or 15(d) of the Securities Exchange Act of 1934 during the preceding 12 months (or for such shorter period that the registrant was required to file such reports), and (2) has been subject to such filing requirements for the past 90 days. Yes No
Indicate by check mark whether the registrant has submitted electronically and posted on its corporate Web site, if any, every Interactive Data File required to be submitted and posted pursuant to Rule 405 of Regulation S-T during the preceding 12 months (or for such shorter period that the registrant was required to submit and post such files). Yes No
Indicate by check mark if disclosure of delinquent filers pursuant to Item 405 of Regulation S-K is not contained herein, and will not be contained, to the best of registrant's knowledge, in definitive proxy or information statements incorporated by reference in Part III of this Form 10-K or any amendment to this Form 10-K.
Indicate by check mark whether the registrant is a large accelerated filer, an accelerated filer, a non-accelerated filer, a smaller reporting company, or an emerging growth company. See the definitions of "large accelerated filer," "accelerated filer," "smaller reporting company" and "emerging growth company" in Rule 12b-2 of the Exchange Act. (Check one):
Large accelerated filer Accelerated filer
Non-accelerated filer (Do not check if a smaller reporting company) Smaller reporting company
Emerging growth company
If an emerging growth company, indicate by check mark if the registrant has elected not to use the extended transition period for complying with any new or revised financial accounting standards provided pursuant to Section 13(a) of the Exchange Act.
Indicate by check mark whether the registrant is a shell company (as defined in Rule 12b-2 of the Act). Yes No
The aggregate market value of the registrant's common stock held by non-affiliates was \$25,624,852,116 based on the last sale price of common stock on April 30, 2018.
The number of shares of Hewlett Packard Enterprise Company common stock outstanding as of November 30, 2018 was 1,398,678,425 shares.

DOCUMENTS INCORPORATED BY REFERENCE

DOCUMENT DESCRIPTION 10-K PART

Portions of the Registrant's proxy statement related to its 2019 Annual Meeting of Stockholders to be filed pursuant to Regulation 14A within 120 days after Registrant's fiscal year end of October 31, 2018 are incorporated by reference into Part III of this Report.

III

Part I

Item 1 Business

Item 1A Risk Factors

Item 1B Unresolved Staff Comments

Item 2 Properties

Item 3 Legal Proceedings

Item 4 Mine Safety Disclosures

Part II

Item 5 Market for Registrant's Common Equity, Related Stockholder Matters and Issuer Purchases

Item 6 Selected Financial Data

Item 7 Management's Discussion and Analysis of Financial Condition and Results of Operations

Item 7A Quantitative and Qualitative Disclosures About Market Risk

Item 8 Financial Statements and Supplementary Data

Item 9 Changes in and Disagreements With Accountants on Accounting and Financial Disclosure

Item 9A Controls and Procedures

Item 9B Other Information

Part III

Item 10 Directors, Executive Officers and Corporate Governance

Item 11 Executive Compensation

Item 12 Security Ownership of Certain Beneficial Owners and Management and Related Stockholder Matters

Item 13 Certain Relationships and Related Transactions, and Director Independence

Item 14 Principal Accounting Fees and Services

Part IV

Item 15 Exhibits, Financial Statement Schedules

Item 16 Form 10-K Summary

Sentiment & Subjectivity

- meist Wörterbuch-basiert
- zusätzlich: WSD, Negationserkennung
- viele frei verfügbare Module

Readability





- verschiedene Maße, basierend auf
 - Anzahl Wörter pro Satz
 - Anzahl Silben pro Wort
- bspw. Flesh-Kincaid grade-level (Kincaid 1975):

$$\ell_{fk} = 0.39 \left(\frac{n_w}{n_s} \right) + 11.8 \left(\frac{n_y}{n_w} \right) - 15.59$$

Stilistische Merkmale

- Biber (1998): *Variation across Speech and Writing: The Multi-dimensional Approach to Linguistic Analyses*
- Dimensionen:
 - the opposition between **involved** and **informational** discourse
 - the opposition between **narrative** and **non-narrative** concerns
 - the opposition between **context-independent** and **context-dependent** discourse
 - overt expression of **persuasion**
 - opposition between **abstract** and **non-abstract** information
 - on-line informational elaboration**
- Implementierungen frei verfügbar (z.B. Andrea Nini)
- basierend auf Stanford Tagger (Merkmale = Sequenzen)

Deskriptive Statistiken: Sentiment & Readability



1. Grundlagen

- 1.1 Computerlinguistik
- 1.2 Korpora
- 1.3 Korpuslinguistik

2. Ausgewählte Anwendungen

- 2.1 Tracking the Infodemic
- 2.2 Financial Narrative Processing
- 2.3 Argumentation Mining

- Argumentation Mining
 - automatische Extraktion von Argumentationsstrukturen aus natürlichsprachlichem Text
 - Strukturen: Prämissen, Folgerungen, ... : logische Schemata
- hier: Identifikation von Argumentfragmenten auf Twitter
 - Fallstudie: Brexit-Tweets (bis zur Abstimmung am 23.06.2016)
 - Ziel: Erkundung und Formalisierung der argumentativen Landschaft auf Twitter
 - linguistische Oberflächenrealisierung → logische Muster
 - Precision wichtig für automatische Extraktion (Fehlerpropagation)
- höchst informelle Argumentation in sozialen Medien (*defeasible logic*):
 - keine klassischen Schemata (Modus Ponens, Modus Tollens)
 - „objektive Wahrheit“ scheint irrelevant (*anything goes*)
 - stattdessen: alltägliche Kommunikation (argumentation by authority, ad hominem, etc.)
 - Twitter: zu kurz für volle Argumente (d. h. Prämissen und Konklusionen)
 - hier: *implizite Konklusion*, dass die UK die EU verlassen soll (oder nicht)

- we European knows it and see our culture disappearing
- the #UN says that most of them are NOT 'refugees' at all
- Today cast a vote that you can make a "that's what she said" joke about. Don't pull out #BetterIn #Brexit
- Brexit is still better than being in the EU
- pensionists stand to lose from Brexit
- this lie that young people can't travel, it's another stay lie
- more bullshit from the in camp, next they'll be claiming that Brexit 'could' cause Mars to crash in to Venus lol
- argumentation by *authority*
 - quotes
 - ascribing knowledge or expertise to authorities
 - etc.
- statements of *evaluation*
 - as good or bad
 - either for some or for all
 - with or without hedging and / or comparison to other statements
- *ad-hominem*, i. e. discrediting others by alleging
 - incompetence
 - conspiracy
 - scaremongering or plain lying

- *desire*: truth of some formula 1 is desirable for some entity 0 $D_{?0:entity}(?1 : formula)$
- *bad for concept*: formula 1 is/would be bad for concept 0 $badFor(?0 : concept, ?1 : formula)$
- *warning*: entity 0 warns of formula 1 being bad $Q_{?0:entity}bad(?1 : formula)$
- *membership*: entity 0 is part of entity 1 $?0 : entity \implies ?1 : entity$
- *lying*: entity 0 lies about formula 1 $Q_{?0:entity}(?1 : formula) \wedge \neg B_{?0}(?1)$
- *ad-hominem*: entity 0 is morally bad and hence discredited $\neg moral(?0 : entity)$
- ...

- Erarbeitung *detaillierter Guidelines* für alle Muster
- Annotation von Tweets bzw. Sätzen bzgl. des Vorkommens der Muster (und der realisierten *Slots*)
- Recall: *zuällige Auswahl* von Sätzen aus dem Gesamtkorpus
- Precision: Annotation von Treffern des Verfahrens (*Matches*)

		desire			lying			warning		
		gold	PH	MG	gold	PH	MG	gold	PH	MG
random	ND	0.673	0.456	0.521	0.722	0.511	0.588	0.902	0.667	0.682
	MG	0.661	0.523		0.659	0.713		0.713	0.747	
	PH	0.487			0.701			0.761		
matches	ND	0.564	0.463	0.229	0.611	0.648	0.415	0.430	0.449	0.337
	MG	0.439	0.311		0.777	0.713		0.961	0.430	
	PH	0.527			0.765			0.500		

Tabelle: Pairwise kappa scores for inter-annotator agreement and agreement with the adjudicated gold data.

- maßgeschneiderte Queries versuchen je eine spezielle Gruppe von Oberflächenrealisierungen eines logischen Musters abzudecken
 - Korpora in CWB indexiert (CQP-Syntax)
 - Modularität: wiederverwendbare Wortlisten und Macros mit domänenspezifischen Wörtern
 - grammatische Muster via POS-Sequenzen
- Grundgedanke:
 - Nutzung linguistischen Wissens hilft bei der Analyse von *Noisy Text*
 - Queries können explizit so konzipiert werden, dass sie Phänomene der internetbasierten Kommunikation abdecken
 - keine Nutzung bspw. von Depenzenparsing nötig (funktioniert nicht auf Tweets!)
- Queries werden iterativ entwickelt (Fallbeispieldiskussion)
 - *high precision, low recall*
- Recall
 - random-1000
 - nur auf Ebene der logischen Muster möglich
- Precision
 - query-matches
 - qualitativ via Konkordanzen
- sehr arbeitsaufwändig
 - insb. bei veränderlichem Muster-Repertoire

```
<np>
  @0: [::]
  /actor_np_all[]
  @1: [::]
</np>
<vp>
  [lemma=$verbs_prefer]
  ("to" "have|get")?
</vp>
<np>
  @2: [::]
  []+
</np>
@3:"back"
within tweet;
```

Beschreibung:

- /actor_np_all[]: macro mit optionalen *determiners* und *modifiers*, gefolgt von einer *Entität*, bspw. Eigennamen oder spez. Wortliste(n)
- \$verbs_prefer: Liste von Verben, die *desire* (*want*, *wish*, *prefer*, *hope*...) ausdrücken
- Tokenspannen @0...@1 und @2...@3: *Slots* des Musters (*entity*, *formula*)

Beispieldreffer:

- Yes we do want our fish back. They take our money and our fish and then tells us what to do! #brexit
- We want our borders back, we want our democracy back, we want our country back ! #BrexitBusTour
- don't think most #Brexiteers want an empire back just their freedom and democracy #brexit

	TP	FP	precision	n_{matches}	$n_{\text{estimated}}$
pattern #3			0.95	19709	18723
– entity supports x	47	3	0.94	14386	13522
– entity favours 1 implicit 2	72	0	1.00	9570	9570
–
pattern #16			0.73	116	84
– 2 is better than 0 implicit entity	40	1	0.98	41	40
– entity favours policy over 2	14	18	0.44	32	14
–
pattern #20			0.91	2908	2646
– entity's lie about	162	17	0.91	2802	2549
– another entity lie	35	16	0.69	87	60
–
pattern #38			0.99	6133	6071
– entity warns that 1	50	0	1.00	4800	4800
– entity says X harms y	47	3	0.94	671	630
–

Tabelle: Precision of queries and patterns estimated on random selections of matches for each query. n_{matches} is the number of matches in the whole corpus, $n_{\text{estimated}}$ corresponds to this number corrected by precision.

	TP	FP	TN	FN	recall
pattern #3	11	3	922	64	0.147
– adj.	4	1	471	24	0.143
– maj.	7	2	451	40	0.149
pattern #16	2	0	975	23	0.080
– man.	2	0	481	17	0.105
– aut.	0	0	494	6	0.000
pattern #20	2	0	971	27	0.069
– adj.	1	0	492	7	0.125
– maj.	1	0	479	20	0.048
pattern #38	9	0	935	56	0.138
– adj.	4	0	478	18	0.182
– maj.	5	0	457	38	0.116

Tabelle: Estimation of recall of logical patterns on random-1000.

- *off-the-shelf* keine passenden Werkzeuge verfügbar
→ spheroscope: a web app for argumentation mining via corpus queries
- Features
 - Definition und Management der *Queries*, *Wordlisten* und *Macros*
 - Query-Kategorisierung logischen Mustern
 - erweiterte *Konkordanzen*
 - halb-automatische Erweiterung von *Wortlisten*
- *Query Refinement*
 - welche Tweets werden durch Update entfernt / kommen hinzu?
 - detaillierter Vergleich auf Tokenebene
 - quantitative Query-Evaluation

ID	Name	#Q	Formula
0	quotation	7	$Q_{?0:entity} (?1 : formula)$
1	explanation	2	$(?0 : formula) \square \rightarrow (?1 : formula)$
2	causal implication	0	$(?0 : formula) \xrightarrow{c} (?1 : formula)$
3	desire	18	$D_{?0:entity} (?1 : formula)$
4	ought	0	$O(?0 : formula)$
5	possibility	1	$\diamond(?0 : formula)$

Abbildung: Pattern Overview

Item	Frequency	Similarity ▲
useful	958	0.684856
important	7143	0.658682
difficult	1977	0.650458
challenging	42	0.636462
consistent	272	0.629459
sensible	1763	0.625485
valuable	199	0.620347
satisfactory	18	0.615404
interesting	9016	0.612765
profitable	106	0.612587

Abbildung: Similarity View

Index ▼	whole	0	1	tweet	TP
('pattern3_entity_wants_their_concept_back', 30776292, 30776297)	From brexit to @realDonaldTrump everyone wants their country back	@realDonaldTrump	their country back	t746036667706916864	?
('pattern3_entity_wants_their_concept_back', 4216663, 4216667)	I want my country back . So I'm voting remain . #VoteRemain https://t.co /q6vKo77x6T	I	my country back	t743734737106141184	True
('pattern3_entity_wants_their_concept_back', 14983065, 14983073)	I just wish #ukip would stop taking everything back to #brexit the NHS is another subject this isn't an EU Debate ! #bbcqt #EUreferendum	I	#ukip would stop taking everything back	t733426508254023680	True
('pattern3_entity_wants_their_concept_back', 1600174, 1600178)	@Col_Irrelevant resolve with the EU ? Don't make me laugh . Do you even know those in charge ? We want our sovereignty back	We	our sovereignty back	t745527503217795076	True
('pattern3_entity_wants_their_concept_back', 912895, 912902)	@Iron_Spike as I understand it , Brexit is mainly supported by 60-somethings longing back to an era of imperial britain	Brexit	by 60-somethings longing back	t744846007075209216	False

Abbildung: Concordance View

```
<np>
  @0: [: :]
  /actor_np_all []
  @1: [: :]
</np>
<vp>
  [lemma=$verbs_prefer]
</vp>
<np>
  @2: [: :]
  []+
</np>
<vp>
  "wieder.*|zurück.*"
  []*
  @3: [: :]
</vp>
within s;
```

Beispiele aus der SZ:

- *Er will sein altes Leben zurück*
- *Der Staat will die Konsummaschine wieder anwerfen*
- deshalb wollen *wir nächste Saison wieder Erstligaspiele haben*
- Als unabhängiger *Küstenstaat will das Vereinigte Königreich wieder voll und ganz die Kontrolle über seine Gewässer haben*

Schwierigkeiten bei der Übertragung:

- einige Queries sind sehr stark an das Zielkorpus angepasst
- Macros und Wortlisten müssen komplett neu geschrieben werden
- Wortstellung im Deutschen viel freier
- Zeitungstexte komplizierter als Tweets
- weniger NLP-Werkzeuge für Deutsch verfügbar

Vielen Dank für Ihre Aufmerksamkeit!

... Zeit für Diskussion ...