

# Korpusbasierte Analyse internetbasierter Kommunikation: Herausforderungen und Perspektiven

**Neue Wege in der Nutzung von Korpora:  
Data-Mining für die textorientierten Geisteswissenschaften**

Fachtagung, 30. Oktober 2015



Michael Beißwenger  
Harald Lüngen  
Christian Pölitz

- [1] Werkzeuge für die automatische linguistische Annotation können mit der Schriftlichkeit in Genres internetbasierter Kommunikation nicht umgehen (“Nonstandard-Phänomene”: Abweichungen von den Normen der geschriebenen Standardsprache; fehlende Standards für die Verarbeitung netztypischer Stilelemente)
  - ⇒ Handannotation: kostet viel Zeit (und Geld)
  - ⇒ Volltextsuche: Hohe Zahl an unerwünschten Treffern; Trefferlisten müssen vor der Analyse intellektuell bereinigt werden (auch teuer)
- [2] Zwar können IBK-Daten prinzipiell in großen Mengen aus dem Web erhoben werden (s. „web as corpus“) – die Datensets, die man bei der Analyse tatsächlich bewältigen kann, sind aber i.d.R. eher klein.

## Fragestellung:

- Können Machine-Learning-Verfahren für eine Bereinigung von Trefferlisten zu Fragestellungen im Bereich IBK adaptiert werden?

- *Aktionswörter* basieren auf einem Wort – im Deutschen häufig einem Inflektiv –, das entweder alleine steht (*lach*, *schüttel*) oder um weitere Einheiten erweitert sein kann (*lautlach*, *kopfschüttel*).

Ich frage mich, ob's wohl nen Fachbegriff für genau diese Art von Klangerzeugern gibt? **\*grübel\***

**\*Augenroll\*** Das ist genau meine Argumentation.

Deinen Kommentar finde ich **\*räusper\*** problematisch.

- Sie dienen zur (häufig spielerischen) Beschreibung von Emotionen, mentalen oder körperlichen Zuständen oder Aktivitäten sowie als Illokutions- und Ironiemarker.
- Sie sind typischerweise nicht syntaktisch integriert.
- Sie werden häufig (nicht immer) durch Asterisken markiert (**\*lach\***, **\*freu\***).

## Daten:

z.B. (1): Trefferliste für die häufigsten Aktionswort-Formen (*lol, lach, freu, grins, wink, seufz*) (Storrer 2013)

z.B. (2): Trefferliste „Beliebige Ausdrücke zwischen Asterisken“

**Aufgabe:** Lerne, ausgehend von einem Sample mit manuell klassifizierten Daten, ein Modell, das es erlaubt, die Treffer automatisch in zwei Klassen zu teilen!

## Beispiele für unerwünschte Treffer:

- (1) Ich **freu** mich auf die Diskussion :)
- (1) hahahahaha ich **lach** mich tot xD
- (2) hehe, hast mich erwischt. Nein, das mit dem Zitat hatte ich im Eifer des Gefechts eingefügt und **\*natürlich\*** ist es von Watson.
- (2)  $Go(s) = (1,8s+1)*(0,9s+1)*(0,54s+1)$ . Die Überschwingung wird auf ca. 3 % reduziert.

# Interdisziplinäres Hauptseminar (Germanistik / Informatik):

# Korpusgestützte Analyse internetbasierter Kommunikation mit Hilfe von Data-Mining



**tu** technische universität  
dortmund

## Korpusgestützte Analyse internetbasierter Kommunikation mit Hilfe von Data-Mining

Interdisziplinäres Projektseminar im Sommersemester 2014

PD Dr. Michael Beißwenger (Germanistik) – Dipl.-Inform. Christian Pöltz (Informatik)

Termin	Sitzungsthema
Di. 08.04.	[PLENUM] Vorstellung des Seminarkonzepts und Organisatorisches
Di. 15.04.	[PLENUM] Überblick: Korpusgestützte Analyse internetbasierter Kommunikation: Fragestellungen und Perspektiven (M. Beißwenger) / Methoden der Künstlichen Intelligenzforschung und des Maschinellen Lernens/Data-Mining für die Analyse von Sprachdaten (C. Politz)
Di. 22.04.	[PLENUM] Einführung in Fokusbereich 1: <i>Geht die Nebensatzstellung im Netz verloren?</i> (Untersuchung zu Diskursmarkern in der internetbasierten Kommunikation)
Di. 29.04.	[PLENUM] Einführung in Fokusbereich 2: <i>Wie mündlich sind „getippte Gespräche“?</i> (Untersuchung zu Verschmelzungsformen in der internetbasierten Kommunikation)
Di. 06.05.	[GERMANISTIK] Ausgabe der Korpusdaten und Annotationsrichtlinien (L. Cedli)
Di. 13.05.	[GERMANISTIK] Fortsetzung der Ausgabe der Korpusdaten und Annotationsrichtlinien (L. Cedli)

	non-VL	kein finV	Pseudo	Beleg
1				zur Redundanz von ""Die T7zai-Linie nach Nishi-Funabashi beginnt derzeit hier"": Das Wort ""redundant"" ist ""Redundanz...: Das Vorhandensein von eigentlich überflüssigen, für die Information nicht notwendigen Ele unumgänglich sind und/oder sein sollen. Das 'eigentlich' trägt dem rechnung, denn es schränkt ein: Nach 'eigentlich' mütlich' und 'hilfreich', 'angebracht' und 'sinnvoll'. Wenn man einen Bahnhofsartikel liest, dann mö
2		X		
3	X			Wieder einmal bin ich auf einen Artikel gestoßen, der Potential hat, ich aber (aufgrund fehlenden Fachwisse allerdings vielleicht etwas kurz [Sozialverhältnissen könnte ergänzt werden, ansonsten fällt mir nichts ein]). Wobei ihm exzellent zu machen. //OT: Übrigens gibt es hier so etwas wie eine Standardgliederung für Tiere <>swie
4		X		Wie kommt du auf 1980? In den 1980er Jahren hat sich der Maskulismus in den USA entwickelt, wurde aber Backlash auf vergleichsweise fruchtbarer Boden, auch wenn da auch viel Kramele und Skandal dabei, <>swie erarbeitet...--
5	X			Wer meint das ich trolle kann googeln, wie gesagt Quelle ist offen aber nicht unbedingt öffentlich und niem Funktechnik als selbstständiger Kaufmann auf ungewöhnliche Antennen ausgerichtet bin, müßte ich mir der sollte mann/frau eigentlich nach Antennengewinn verschieben! <>Well</> dort fehlt das. Zur weiteren Meldung Euer unwissender suchender usw Reinhard-
				Wer kennt den Aufsatz von Gerhard Kern über "Theosophie und Anthroposophie - Eine philosophische Basis diesem befaßt. Der Text war bei Pierre Krebs angegeben. Ich hatte ihn gelöscht, <>Well</> er nicht mehr die Theos - Gegenstück einer Theorie nehmen mit den Theos Theosophen einen Platz. Werkschule, Melior, Beschau

akr?	Redup?	AKW?kpix?	AKW?inf?	AKW?inflbasis	match	start pos	end pos	text
		X	X	grinsen	"ganzzahngsins"	9.0	28.0	"Nowidat" "ganzzahngsins" da ergibt sich doch eine tolle Gelegenheit für ein AP, nicht wahr "diabolischgsins" - Altan Disc. 14-43, 6. Feb. 2010 (CET)
					"kann"	184.0	190.0	Nur, für sachlich falsch halte ich zunächst die Aussage, das d in Adlershgt würde wie gesprochen. Dass "Du" dspricht, obwohl die Lippen zu verändern, mag sein. Ich "kann" es notfalls so_ tun, doch dann abweichen. Doch es ist eine Umlautverschiebung, die sich aber bei "mir" jdehnen lässt. Die Laute d und in Lippenspannung dann -t, beim d wird "mein" Mund runden. Ebenso spräche dVollkanonntal oder iV0 uern überhashterntz nur im Komposita.
		X	X	zucken	"schulerzuck"	64.0	78.0	Ja, nun ja, da AMD ist aber am komparative selber von G1 spricht "schulerzuck"? Heiss berichtet auch nicht von Änderungen am Kern selbst. Ich wäre sagen, wir lassen es mal basierend auf den offiziellen Angaben von AMD

Sommersemester 2014

# Korpusgestützte Analyse internetbasierter Kommunikation mit Hilfe von Data-Mining

**Michael Beißwenger**  
(Germanistik)  
**Christian Pöltz**  
(Informatik)

<b>auptseminar</b>	2 SWS	Di 10-12 Uhr, R. U331	Beginn: 8.4.2014
ABG 2009: BLS1 / BaMaLa 2005: F6 / a./M.a. Angewandte Sprachwissenschaft: M2, M3, M7			

### **Kurzbeschreibung:**

Ziel des Seminars ist es, anhand ausgewählter sprachwissenschaftlicher Fragestellungen den Einsatz innovativer Informatikmethoden („Data-Mining“, maschinelles Lernen) für die empirische korpusgestützte Analyse internetbasierter Kommunikation zu erproben.

Um Besonderheiten der Sprachverwendung in der internetbasierten Kommunikation auf der Basis großer Datensammlungen (Korpora) quantitativ und qualitativ untersuchen zu können, bedarf es automatischer Verfahren, die die Daten vorsortieren, klassifizieren und nach potenziell interessanten Belegen durchforsten. Um solche Verfahren entwickeln zu können, bedarf es sprachwissenschaftlichen Know-Hows, das in Form sogenannter „Annotationen“ in kleine Datensets eingebracht wird.

Im Seminar werden wir in kleinen Analyseprojekten solche Annotations- und Entwicklungsprozesse durchspielen. Dabei arbeiten Studierende der Germanistik mit Studierenden der Informatik zusammen, wobei die Germanistik-Studierenden Daten auf der Grundlage sprachwissenschaftlicher Konzepte evaluieren und annotieren und die

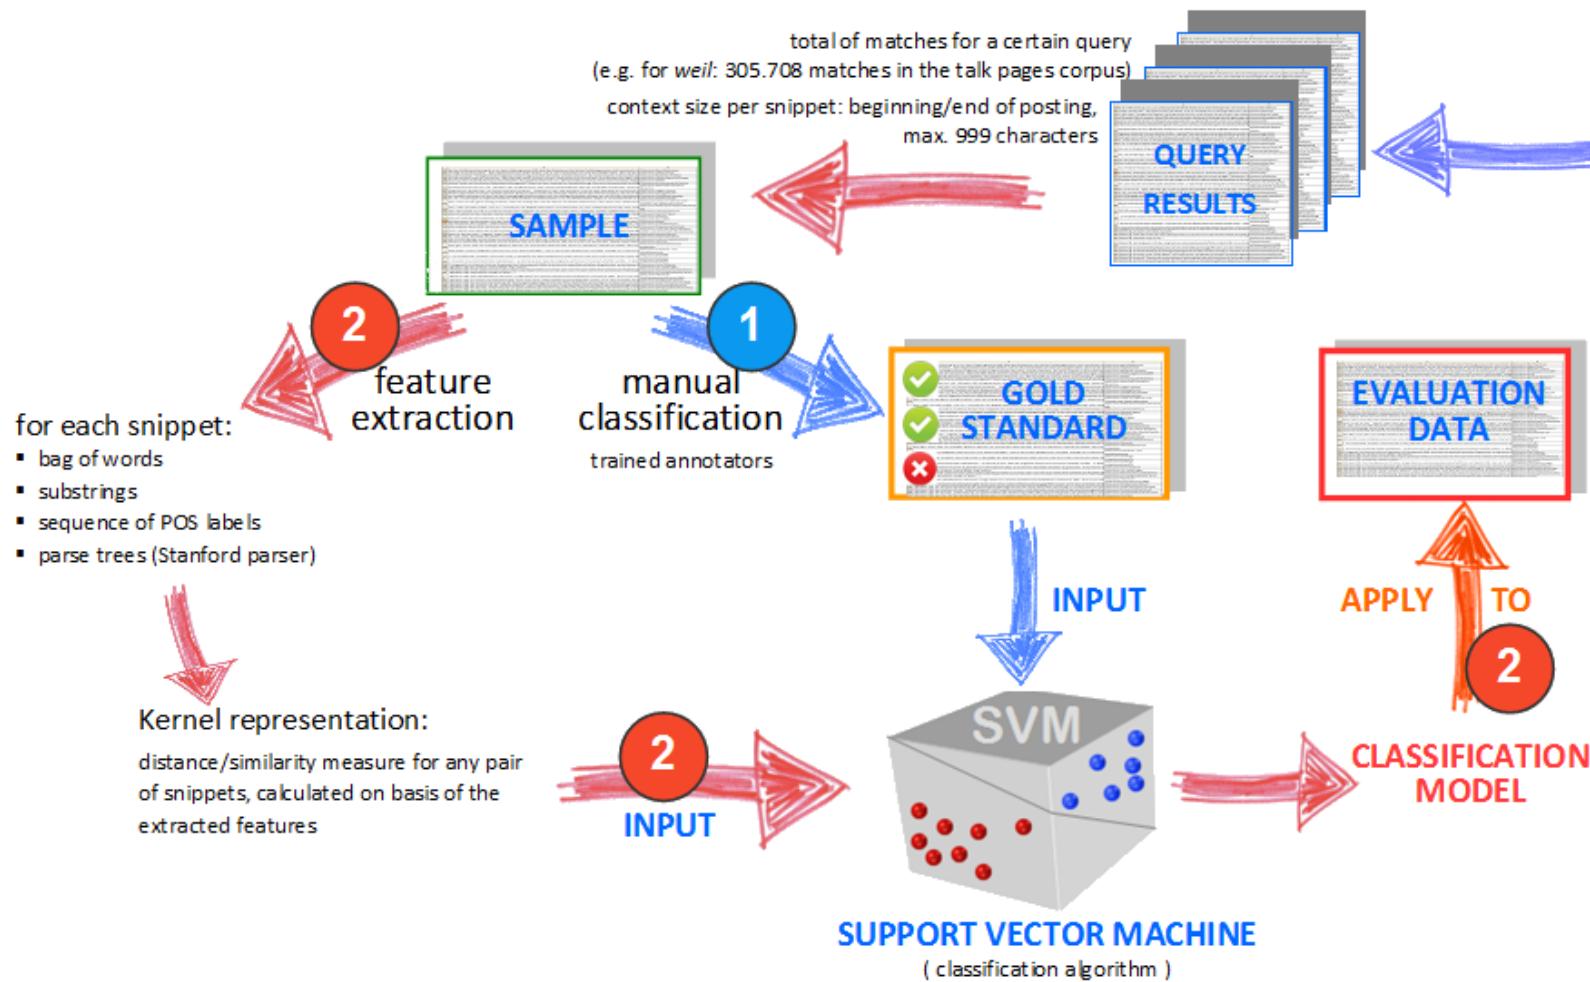
**Seminarprojekt:** Automatische Eliminierung von Pseudotreffern und Finden von „Nadeln im Heuhaufen“ für große Trefferlisten zu ausgewählten sprachlichen Phänomenen internetbasierter Kommunikation – zum Beispiel:



**tu** technische universität  
dortmund

- **Aktionswörter:**  
*freu, lach, schmunzel, ganzfiesgrins, ...*
- **nicht-kanonische Verwendungen von *weil* und *obwohl* (V2 anstelle von V-L):**  
*ja toll aber so richtig steht es nicht drin weil  
damals sollten wir nämlich eine arbeit in  
informatik machen über das dualsystem*

- 1 Germanistik-Studierende
- 2 Informatik-Studierende



Das Korpus		
WIKIPEDIA DEREKO	Aufbau	Inhalte
	Wikipedia-Korpus 2013 in DeReKo	(Kupietz & Lüngen 2014) <a href="http://www.ids-mannheim.de/kl/projekte/korpora/verfuegbarkeit.html">http://www.ids-mannheim.de/kl/projekte/korpora/verfuegbarkeit.html</a>
	Articles	Talk pages
# files	~16G	~4.8G
# pages	~1.6M	~550K
# postings	—	~5.5M
# tokens	~678M	~264M

Das Korpus ist repäsentiert in I5 (Sperber-McQueen & Lüngen 2012), der Customization des P5-Encoding-Formats der [Text Encoding Initiative](http://tei.org/) (TEI, <http://tei.org/>) für DEREKO. I5 integriert Modelle für die Strukturbeschreibung von Genres internetbasierter Kommunikation aus dem adaptierten TEI-Schema von Beßwenger et al. (2012).

```
<div name="WU0000000000" type="thread">
  <head type="cross">
    <s>Totensonntag in der DDR?</s>
  </head>
  <posting indentLevel="0" who="WU0000000000">
    <p>
      <s>Hallo, weiß jemand ob es auch einen  
Totensonntag in der DDR Gab?? Danke</s>
    </p>
  </posting>
  <posting indentLevel="1" synch="t00121163"  
who="WU00006525">
    <p>
      <s>broken="yes">Warum sollte es den dort  
nicht gegeben haben?</s>
      <s>Auch in der DDR hörte das Kirchenjahr  
mit dem Ewigkeitssonntag/Totensonntag auf  
und das neue fing mit dem 1. Advent wieder  
an.</s>
      <s><autoSignature/> 29:23, 5. Dez. 2006  
(CET)</s>
    </p>
  </posting>
<_>
```

Die Grundlage für das Seminar bildet das Diskussionsseiten-Teilkorpus. Die Konvertierung nach I5 ist beschrieben in Margaretha & Lüngen (2014).

# WIKIPEDIA IN DEREKO (2013)

	Artikel	Diskussionen
# WP-Seiten (Texte)	1.585.823	554.617
# Postings	--	5.469.899
# Tokens	678.444.643	272.654.185
I5-Dateigröße	16G	4,8G

- Encoding in I5 + CMC (Sperberg-McQueen/Lüngen 2012, Beißwenger et al. 2015)
- Threads, Heuristiken für Posting-Segmentierung in Diskussionen
- POS-Annotationen mit TreeTagger/ STTS 1.0 (standoff)
- COSMAS II oder Download v. <http://corpora.ids-mannheim.de/pub/wikipedia-2013/>

Referenz: Eliza Margaretha / Harald Lüngen (2014): Building Linguistic Corpora from Wikipedia Articles and Discussions. In: *Journal of Language Technology and Computational Linguistics (JLCL)* 29 (2), S. 59-82, <http://www.jlcl.org/>

# CMC DOKUMENTSTRUKTUR IN I5

IBK-ELEMENTE ADAPTIERT VON BEIßWENGER ET AL. 2012

```
<div n="2" type="thread">
  <head type="cross">
    <s>Totensonntag in der DDR</s>
  </head>
  <posting indentLevel="0" who="WU00000000">
    <p>
      <s>Hallo, weiß jemand ob es auch einen Totensonntag in der DDR
          Gab?? Danke</s>
    </p>
  </posting>
  <posting indentLevel="1" synch="t00121163" who="WU00006525">
    <p>
      <s broken="yes">Warum sollte es den dort nicht gegeben haben?</s>
      <s>Auch in der DDR hörte das Kirchenjahr mit dem Ewigkeitssonntag/
          Totensonntag auf und das neue fing mit dem 1. Advent wieder
          an.</s>
      <s>--<autoSignature/> 23:23, 5. Dez. 2006 (CET) </s>
    </p>
  </posting>
  [...]
```

# WIKIPEDIA-KORPORA AM IDS (2015)

## KONVERTIERUNG: ELIZA MARGARETHA

Neue Features 2015:

- Nutzerdiskussionen (*User Talk Pages*)
- Verbesserung der Posting-Segmentierung
- Language-Links in Metadaten

	Artikel #tok	Diskussionen #tok	Nutzerdiskussionen #tok
Deutsch (de)	796.638.747	309.897.027	271.441.322
Englisch (en)	2.403.943.177	1.270.217.981	2.698.338.998
Französisch (fr)	764.459.026	137.107.729	372.639.260
Ungarisch (hu)	117.987.947	8.293.799	26.215.158
Norwegisch (no)	99.014.144	5.314.362	32.481.331
Spanisch (es)	578.882.431	54.907.258	276.034.367
Kroatisch (hr)	46.641.724	2.480.966	18.731.167
Italienisch (it)	463.022.806	49.825.036	125.573.567
Polnisch (pl)	298.207.197	16.558.557	64-126.136

## Lernaufgaben zu Aktionswörtern:

- |     |                |             |
|-----|----------------|-------------|
| (1) | Precision: 87% | Recall: 92% |
| (2) | Precision: 74% | Recall: 71% |

## Identifizierung nicht-kanonischer Verwendungen von *weil*:

Precision: 13%      Recall: 55%

Wenn man zum reinen Bag-of-words-Ansatz Part-of-speech- und Parse-Tree-Kernels zuschaltet, werden die Ergebnisse sogar schlechter.

⇒ Eine Verbesserung der Lernverfahren setzt eine Anpassung der genutzten Sprachverarbeitungswerkzeuge voraus.

## Die Probleme betreffen verschiedene Ebenen des Verarbeitungsprozesses:

- **Tokenisierungsprobleme:** Der Tokenisierungsprozess erzeugt Tokens, die keine sinnvollen linguistischen Einheiten darstellen (z.B. aufgrund von *speedwriting phenomena*)
- **Kategorisierungsprobleme:** Es gibt eine passende Kategorie im verwendeten Tagset, der Tagger kann das entsprechende Tag aber nicht zuweisen (z.B. aufgrund von umgangssprachlichen Schreibungen)
- **Kategorienprobleme:** Der Tagger kann kein sinnvolles Tag zuweisen, da für die betreffende Kategorie im Tagset kein Tag existiert (z.B. im Falle von Emoticons, Emojis, Hashtags, Aktionswörtern, konzeptionell mündlichen Verschmelzungsformen)

Cf. Bartz et al. (2014)

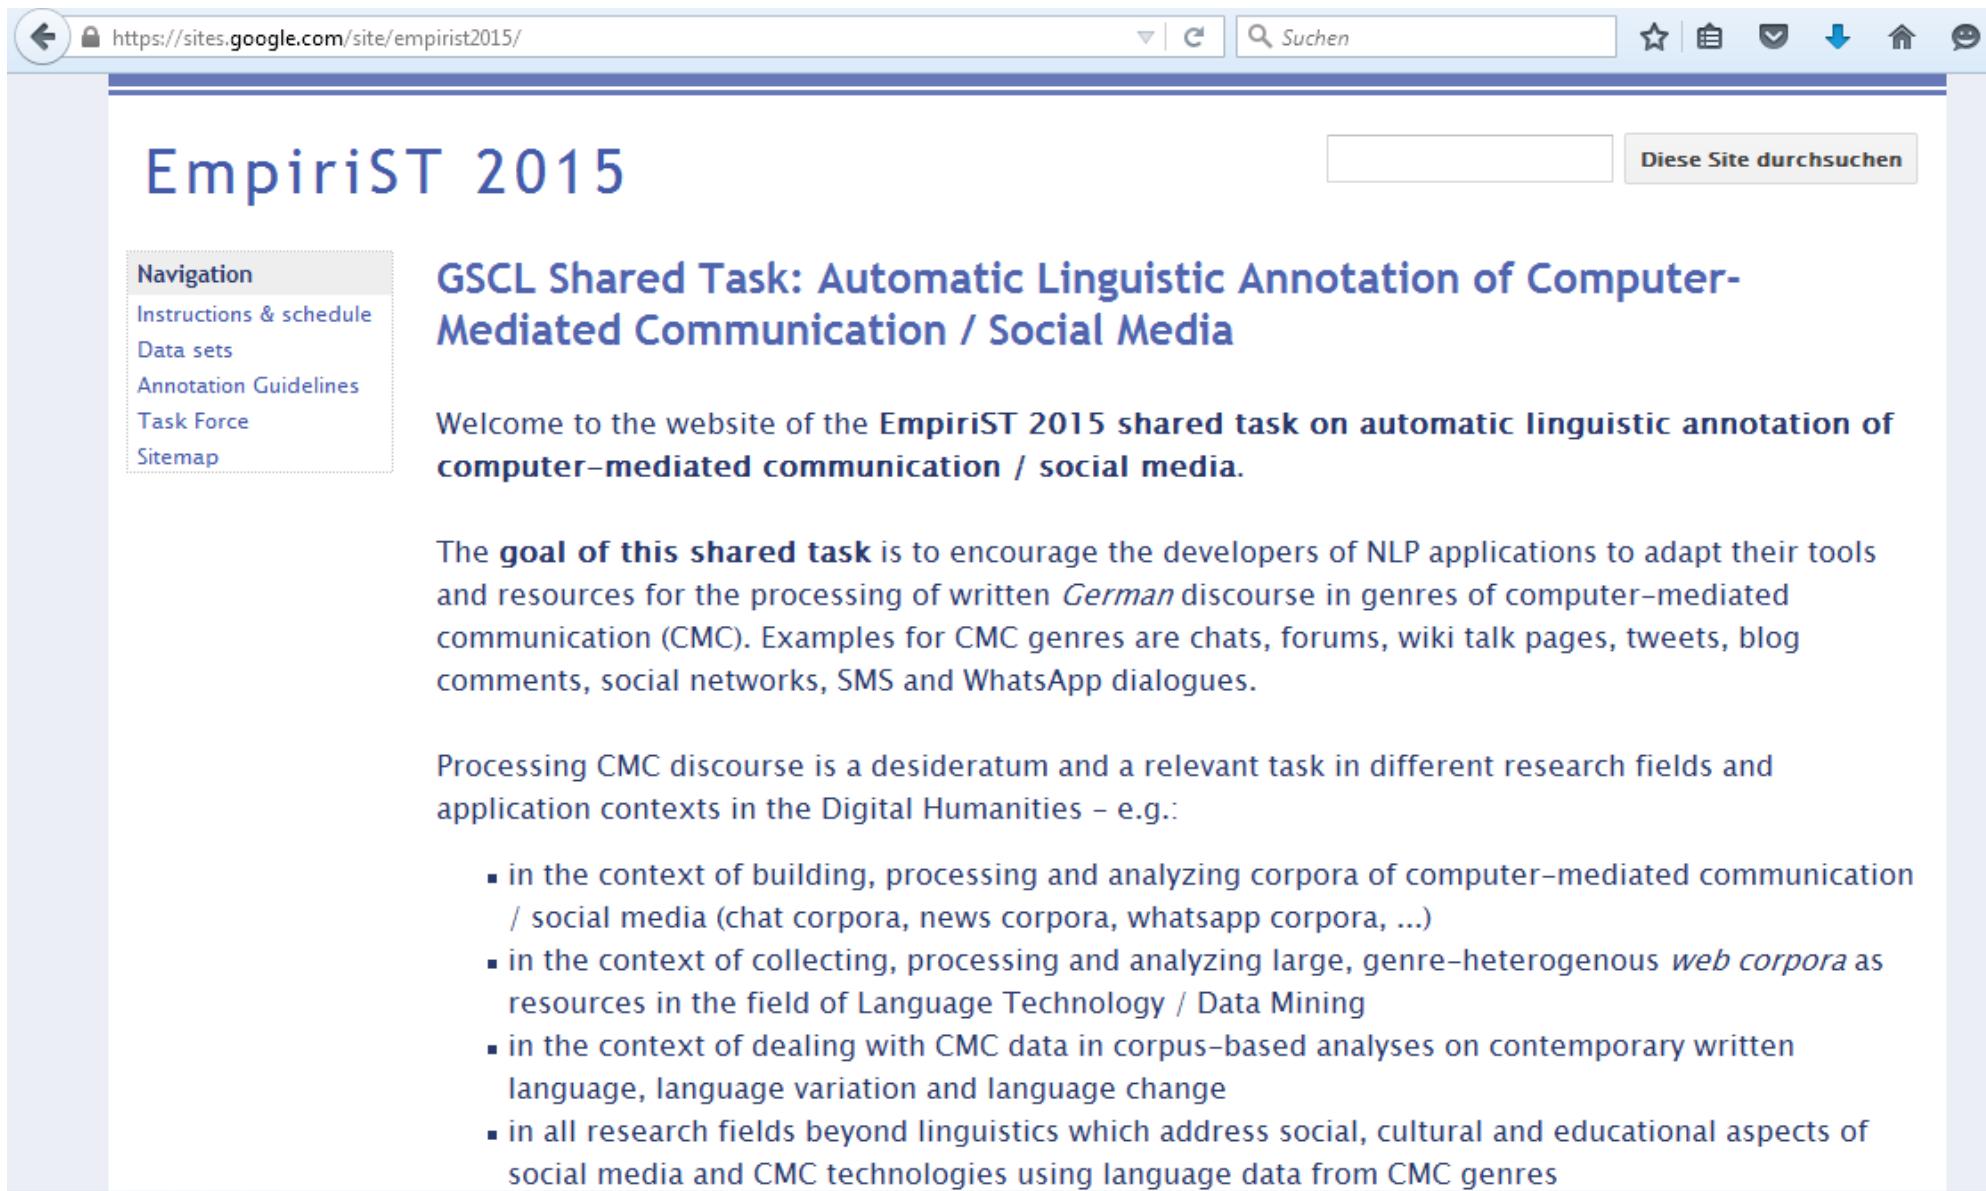
# “STTS 2.0”: Erweitertes Part-of-speech-Tagset für IBK

Tag	Beschreibung	Beispiele
ADJA	attributives Adjektiv	[das] große [Haus]
ADJO	advitiales oder prädikatives Adjektiv	[er ist] schnell [er ist] schnell
ADV	Adverb	schnell, bald, heute, jetzt
APPR	Präposition, Zirkumposition links	In [der Stadt], ohne [mich]
APPART	Präposition mit Artikel	Im [Haus], zur [Seite], vom, übern, über
APPO	Postposition	[hier] zufolge, [der Seite] wegen
APZR	Zirkumposition rechts	[von, jetzt] an
ART	bestimmter oder unbestimmter Artikel	der, die, das, ein, eine
CARD	Kardinalzahl	zwei []/drei, [im Jahre] 1994
FM	Fremdsprechliches Material	[Er hat des mit] A big fish [Übersetzung]
ITJ	Interjektion	mhm, ach, ja
ONO	Onomatopoeik	boing, miau, zisch
OM	Diskursmerker	prototypisch: weil, obwohl, nur also als Einheiten mit projektivem Potential im Vorvorfeld von V2-Sätzen
KOU1	unterordinende Konjunktion mit „zu“ und Infinitiv	um [zu leben] anstatt [zu fragen]
KOU8	unterordinende Konjunktion mit Satz (VL-Stellung)	wenn, dass, damit wenn, ob
KON	nebenordinende Konjunktion	und, oder, aber
KOKOM	Vergleichspartikel ohne Satz	als, wie
NN	Appellativa	Tisch, Hem, [das] Reisen
NE	Eigennamen	Hans, Hamburg, HSV
PD8	substituierendes Demonstrativpronomen	dieser, jener
PDAT	attributierendes Demonstrativpronomen	jener []/jensch
PI8	substituierendes Indefinitpronomen	keiner, viele, man, niemand
PIAT	attributierendes Indefinitpronomen ohne Determiner	kein [Mensch] Irgendein [Glas]
PIDAT	attributierendes Indefinitpronomen mit Determiner	[ein] wenig [Wasser] [die] beiden [Brüder]
PPER	Imreflexives Personalpronomen	Ich, er, ihm, mich, dir
PPOS8	substituierendes Possessivpronomen	meins, deiner
PPOSAT	attributierendes Possessivpronomen	mein [Buch], deine [Mutze]
PREL8	substituierendes Relativpronomen	[der Hund], der
PRELAT	attributierendes Relativpronomen	[der J.]ann, [dessen] Hund
PRF	reflexives Personalpronomen	sich, einander, dich, mir
PW8	substituierendes Interrogativpronomen	wer, was
PWAT	attributierendes Interrogativpronomen	welche (Farbe)
PWAV	advitiales Interrogativ- oder Relativpronomen	warum, wo, wann woher, wobel
PAV	Pronominalizedverb	dafür, dabei, deswegen, trotzdem
PTKZU	„zu“ vor Infinitiv	zu [gehen]
PTKNEG	Negationspartikel	nicht

Tag	Beschreibung	Beispiele
PTKVZ	abgetrennter Verbzusatz	[er kommt] an, [er (h)at] Rad
PTKANT	Antwortpartikel	ja, nein, danke, bitte
PTKA	Partikel bei Adjektiv oder Adverb	am [schönsten], zu [schnell]
PTKIFG	Intensitäts-, Fokus- oder Gradpartikel	sehr[schön], höchst [eigenartig] nur [sic], voll [gel]
PTKMIA	Modell- oder Akkönigspartikel	[Das ist] ja / vielleicht [doch] [ist das] denn [richtig so?] [Das weiß] halt [echt nicht einfach]
PTKMWL	Partikel als Teil eines Mehrwort-Lexems	keine mehr, noch mal, schon wieder
TRUNC	Komposition-Estglied	An- [und Abreise]
VVRIN	finites Verb, voll	[du] gehst [wir] kommen [an]
VVIMP	Imperativ, voll	komm [!]
VVINF	Infinity, voll	gehen, ankommen
VVIZU	Infinity mit „zu“, voll	anzukommen, loszulassen
VVPP	Partizip Perfekt, voll	gegangen, angekommen
VARIN	finites Verb, aux	[du] bist, [wir] werden
VAIMP	Imperativ, aux	sei [fertig!]
VAINF	Infinity, aux	werden, sein
VAPP	Partizip Perfekt, aux	gewesen
VMPIN	finites Verb, modal	dürfen
VMINF	Infinity, modal	wollen
VMPP	Partizip Perfekt, modal	[er hat] gekommen
VVPPER	Kontraktion: Vollverb + Imreflexives Personalpronomen	schreibste, machste
VMPPER	Kontraktion: Modalverb + Imreflexives Personalpronomen	willste, darfst, musste
VAPPER	Kontraktion: Auxiliarverb + Imreflexives Personalpronomen	hast, bist, isses
KOU8PPER	Kontraktion: unterordinende Konjunktion mit Satz (VL-Stellung) + Imreflexives Personalpronomen	wenns, weis, obse
PPERRPER	Kontraktion: Imreflexives Personalpronomen + Imreflexives Personalpronomen	Ichs, du, ers
ADVART	Kontraktion: Adverb + Artikel	son, sone
EMOABC	Emoticon, als Zeichenfolge dargestellt (Typ „ABC“)	:> -> ^^ O_O
EMOIMG	Emoticon, als Grafikikon dargestellt (Typ „Image“)	kodiert (Beispiel aus WhatsApp): emojiiSmilingFaceWithSmilingEyes emojiiKissingCfFaceWithClosedEyes
AKW	Aktionswort	„Yeah“ freu, großel tol“
H&T	Hashtag	#oete war super! #sulaub
ADR	Adressierung	@Mother [!]: Wie isst so?
URL	Uniform Resource Locator	<a href="http://www.tu-dortmund.de">http://www.tu-dortmund.de</a>
EMIL	E-Mail-Adresse	peter.klein@web.de
XY	Nichtwort, Sonderzeichen enthaltend	D2xW3
;	Komma	,
.;	Satzzeigende Interpunktions	. ? ! ; :
	sonstige Satzzeichen; satzintern	- [ ] ( )

# “STTS 2.0”: Erweitertes Part-of-speech-Tagset für IBK

PoS tag	Category	Examples
<b>I. Tags for phenomena which are specific for CMC / social media discourse:</b>		
EMO ASC	ASCII emoticon	:-( :-( ^^ O.O
EMO IMG	Graphic emoticon	
AKW	Interaction word	*lach*, freu, grübel, *lol*
HST	Hash tag	Kreta war super! #urlaub
ADR	Addressing term	@lothar: Wie isset so?
URL	Uniform resource locator	http://www.tu-dortmund.de
EML	E-mail address	peterklein@web.de
<b>II. Tags for phenomena which are typical for spontaneous spoken language in colloquial registers:</b>		
VV PPER	Tags for types of colloquial contractions which are frequent in CMC  (APPRART is already existing in STTS 1999)	schreibste, machste
APPR ART		vorm, überm, fürn
VM PPER		willste, darfste, musste
VA PPER		haste, biste, isses
KOUS PPER		wenns, weils, obse
PPER PPER		ichs, dus, ers
ADV ART		son, sone
PTK IFG	‘Intensitätspartikeln’, ‘Fokuspartikeln’, ‘Gradpartikeln’	Abgestimmt auf die STTS-Erweiterungen für das Tagging gesprochener Sprache (FOLK-Korpus, IDS)
PTK MA	Modal particles	
PTK MWL	Particle as part of a multi-word lexeme	
DM	Discourse markers	
ONO	Onomatopoeia	



The screenshot shows a web browser window with the URL <https://sites.google.com/site/empirist2015/>. The page title is "EmpiriST 2015". On the left, there is a navigation sidebar with links: "Navigation", "Instructions & schedule", "Data sets", "Annotation Guidelines", "Task Force", and "Sitemap". The main content area features a large blue header "GSCL Shared Task: Automatic Linguistic Annotation of Computer-Mediated Communication / Social Media". Below it, a welcome message reads: "Welcome to the website of the EmpiriST 2015 shared task on automatic linguistic annotation of computer-mediated communication / social media." A descriptive paragraph follows: "The goal of this shared task is to encourage the developers of NLP applications to adapt their tools and resources for the processing of written *German* discourse in genres of computer-mediated communication (CMC). Examples for CMC genres are chats, forums, wiki talk pages, tweets, blog comments, social networks, SMS and WhatsApp dialogues." Another paragraph states: "Processing CMC discourse is a desideratum and a relevant task in different research fields and application contexts in the Digital Humanities – e.g.:". A bulleted list provides five examples of research fields:

- in the context of building, processing and analyzing corpora of computer-mediated communication / social media (chat corpora, news corpora, whatsapp corpora, ...)
- in the context of collecting, processing and analyzing large, genre-heterogenous *web corpora* as resources in the field of Language Technology / Data Mining
- in the context of dealing with CMC data in corpus-based analyses on contemporary written language, language variation and language change
- in all research fields beyond linguistics which address social, cultural and educational aspects of social media and CMC technologies using language data from CMC genres

<https://sites.google.com/site/empirist2015/home/>

Es müssen Annotationsstandards entwickelt werden, die es erlauben,

- 1) die Ergebnisse von Sprachverarbeitungsverfahren sinnvoll und abfragbar in Korpora zu annotieren;
- 2) diese Annotationen in Formaten zu repräsentieren, die interoperabel sind mit Standards, die für die Annotation von Text- und Gesprächskorpora eingesetzt werden  
(⇒ vergleichende korpusbasierte Analyse von IBK mit Text- und Gesprächsdaten);
- 3) die linguistische Annotation mit einer sinnvollen Annotation der strukturellen Besonderheiten von IBK-Genres (z.B. Threadstrukturen) und zugehörigen Metadaten zu verbinden;
- 4) Ergebnisse von Korpusanalysen, die diese Annotationen nutzen, wiederum als neue Annotationen (in standardisierten Formaten) den Korpora hinzuzufügen.



< Text Encoding Initiative >

<http://www.tei-c.org/Activities/SIG/CMC/>

Home Guidelines Activities Tools Membership Support About News

[Home](#) -> [Activities](#) -> [Special Interest Groups \(SIGs\)](#) -> [Computer-Mediated Communication](#)

Entire site ▾

Search

Computer-Mediated  
Communication

Correspondence

Education

Libraries

Manuscripts

Music

Ontologies

Scholarly Publishing

TEI for Linguists

Text & Graphics

Tools

## Computer-Mediated Communication SIG

### Contents

- Context
- Scope and Tasks
- Convener
- Wiki space and mailing lists
- Activities

### Context

In the past three decades, computer networks and especially the internet have brought forth new and emerging genres of interpersonal communication (*computer-mediated communication*, henceforth "CMC"). Even though there's been a lot of research on CMC genres and on language use on the internet in linguistics and social sciences as well as in the field of natural language processing, there are still no common standards for the representation and annotation of these new forms of communication and their structural and linguistic peculiarities. Being able to represent CMC data on the basis of an encoding framework such as the TEI which is broadly acknowledged within the field of digital humanities will allow for an interchange of data between research groups and for building interoperable CMC corpora for different languages

### Scope and Tasks

This special interest group is elaborating on suggestions for adapting the TEI guidelines to the representation of genres of computer-mediated communication (CMC). The focus of the group's work is on (but not limited to) tasks such as:

Dokumentation des aktuellen TEI-Schemaentwurfs für IBK  
(Stand Oktober 2015):

[http://wiki.tei-c.org/index.php/SIG:Computer-Mediated\\_Communication](http://wiki.tei-c.org/index.php/SIG:Computer-Mediated_Communication)

- CLARIN-D-Kurationsprojekt ChatCorpus2CLARIN  
<http://www.clarin-d.de/de/kurationsprojekt-1-3-germanistik>
- WhatsApp-Datensammlung  
(Projekt „What's up, Deutschland?“)
- Wikipedia-Korpus in DEReKo
- DWDS Blog-Korpus
- News-Korpus in DEReKo
- Projekt „Deutsches Referenzkorpus zur internetbasierten Kommunikation“ (DeRiK)