

Universität Stuttgart



Nils Reiter  
Sarah Schulz

# Reflected Text Analysis: Computational Linguistics Meets Digital Humanities

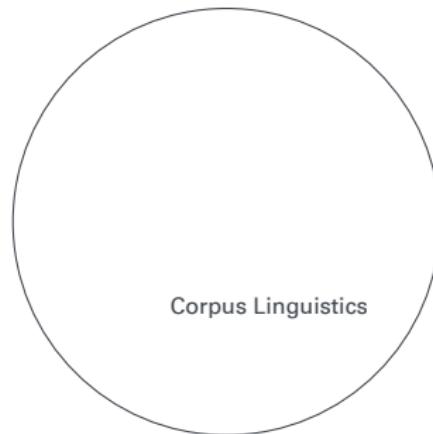
## About this Talk

- Computational Linguistics and Digital Humanities
- DH in Stuttgart
- Coreference Resolution

If you should have questions, feel free to ask...

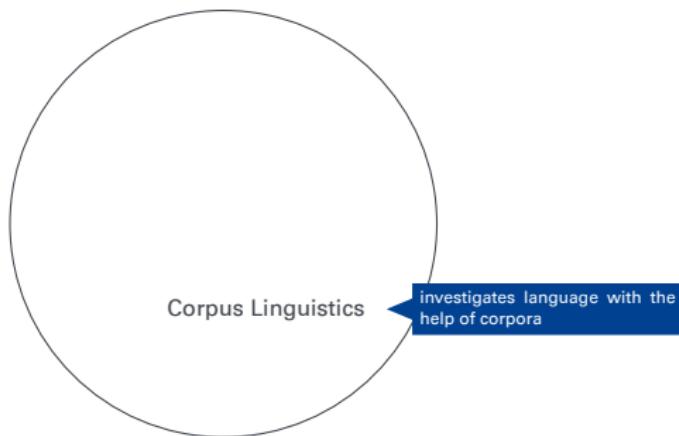
# **Computational Linguistics and Digital Humanities**

# **CL is DH**

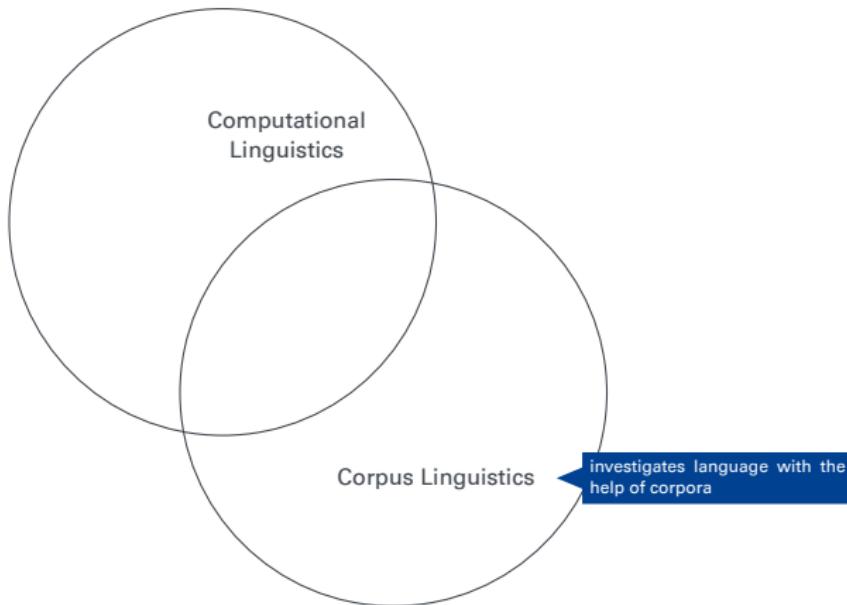


Corpus Linguistics

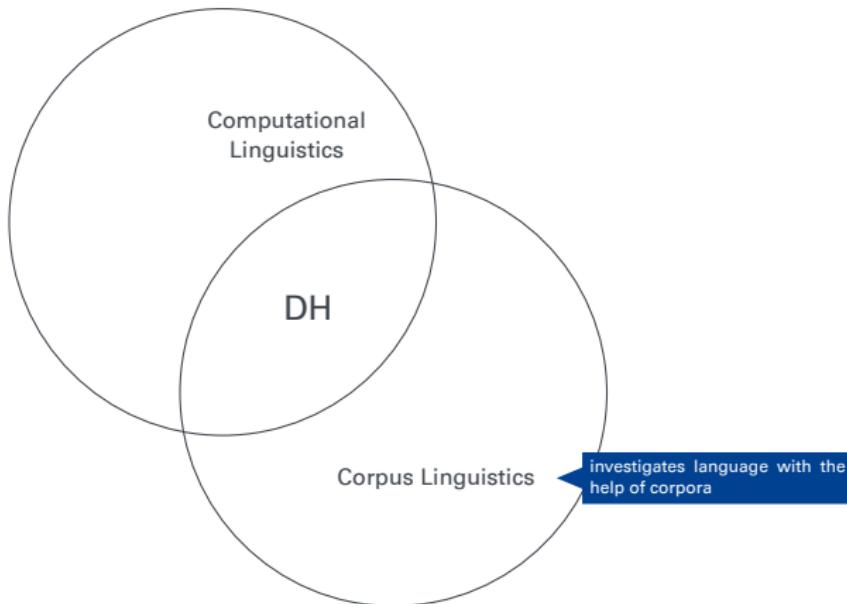
# CL is DH



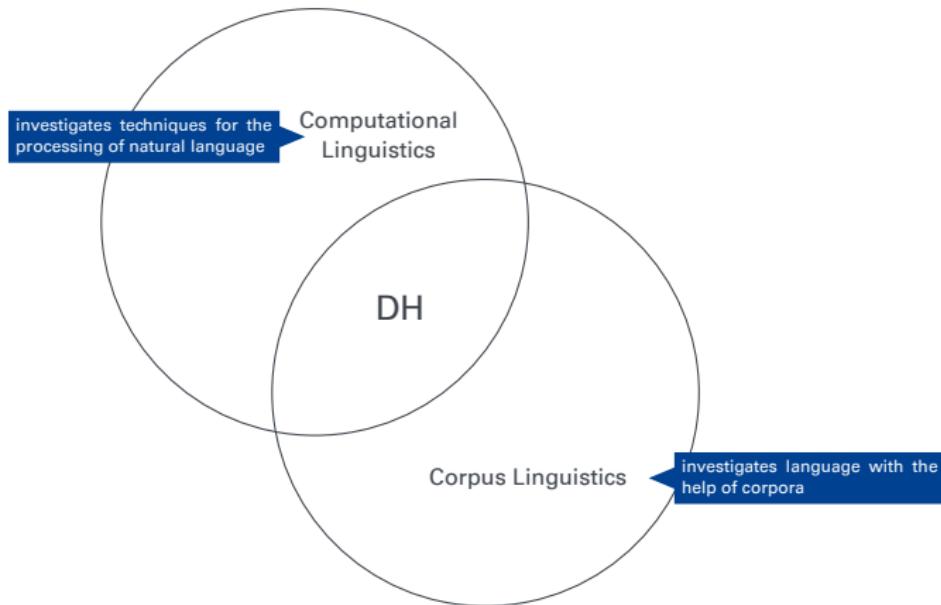
# CL is DH



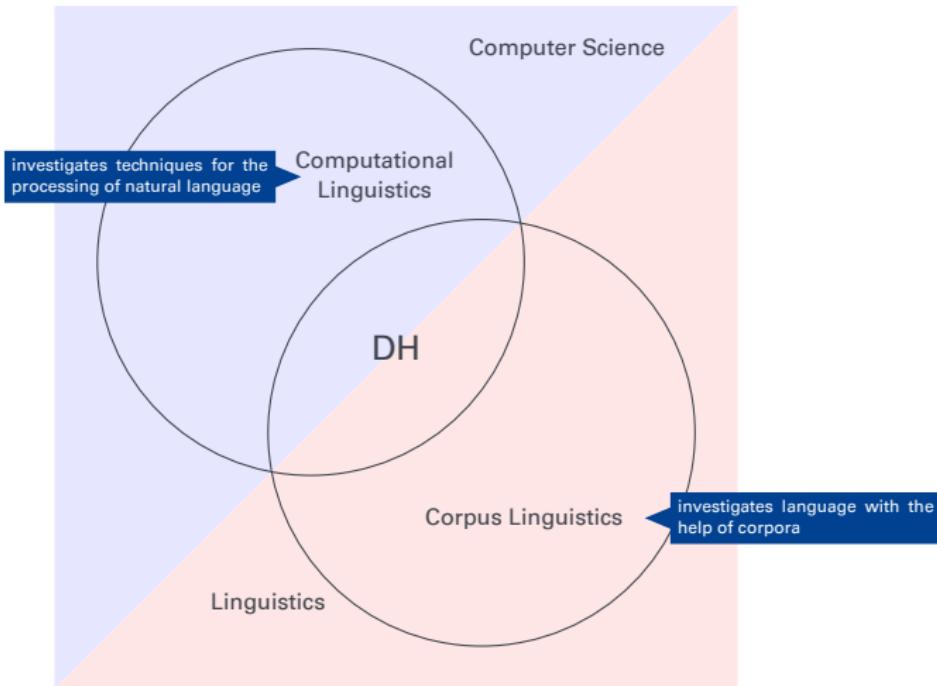
# CL is DH



# CL is DH



# CL is DH



## Computational Linguistics and Digital Humanities

- Why do the humanities want to work with CL?
  - many humanities projects are text-based
    - → tools and workflows from CL can be adapted to DH projects
  - larger corpora can be analysed

## Computational Linguistics and Digital Humanities

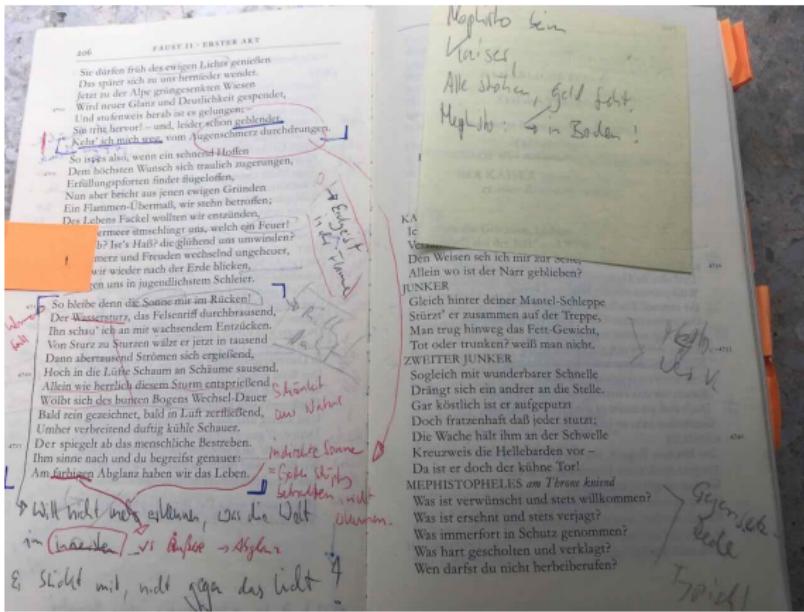
- Why do the humanities want to work with CL?
  - many humanities projects are text-based
    - → tools and workflows from CL can be adapted to DH projects
  - larger corpora can be analysed
- Why does CL want to work with the humanities?
  - non-standard language, text structure, applications and research questions from DH are new for CL
  - humanities scholars provide expert knowledge
  - research question can limit the scope of what a tool has to provide

## Computational Linguistics and Digital Humanities

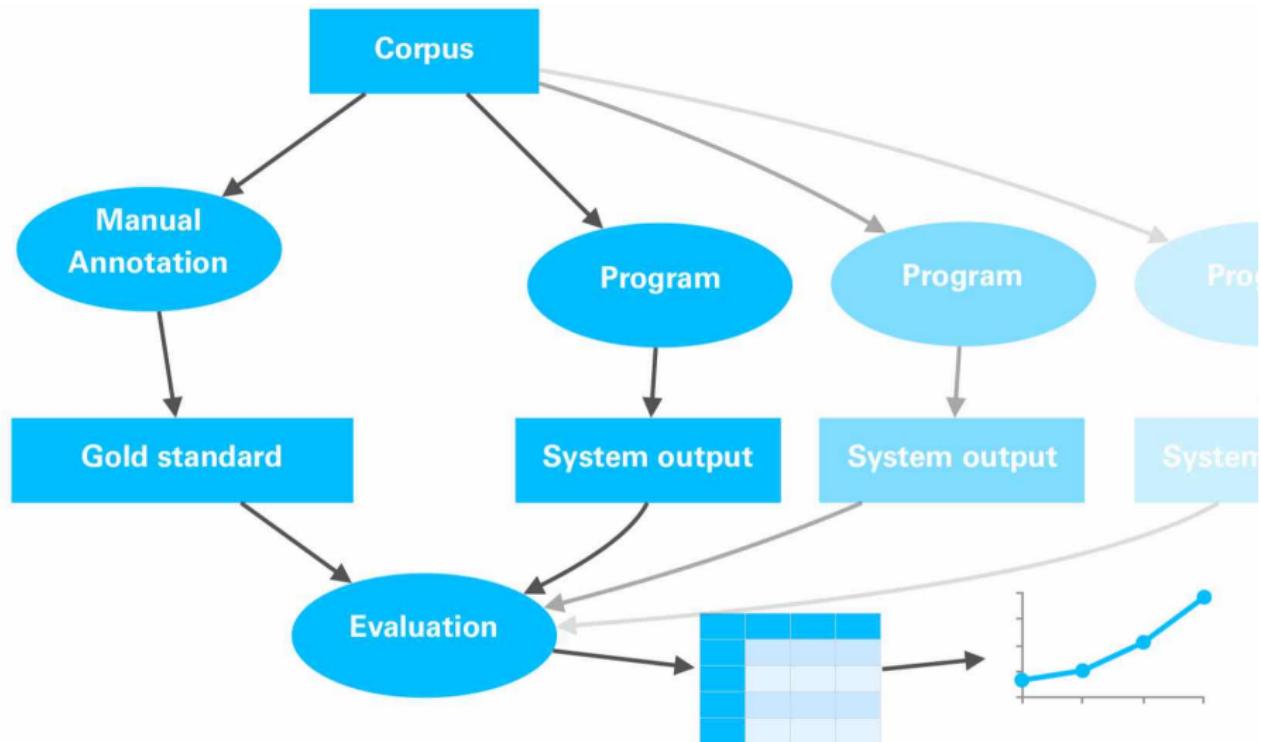
- Why do the humanities want to work with CL?
  - many humanities projects are text-based
    - → tools and workflows from CL can be adapted to DH projects
  - larger corpora can be analysed
- Why does CL want to work with the humanities?
  - non-standard language, text structure, applications and research questions from DH are new for CL
  - humanities scholars provide expert knowledge
  - research question can limit the scope of what a tool has to provide
- both: collaboration is a chance and challenge

# Annotation as Basis for... Everything

- explicit assignment of categories to text spans
  - text spans are explicitly bounded (begin, end)
- annotation by humans vs. annotation by computers



# The Day-to-Day Work of a Computational Linguist



## Why do we annotate?

- empirical validation of theories
  - discovering phenomena not covered by a theory
  - strengthening definitions in a theory
    - often confused categories might be overlapping or at least unclear
  - uncovering implicit assumptions
- data creation
  - manually annotated data can be analysed
    - which categories are how frequent in what context?
  - automatic tools can be evaluated
    - How well do machines do this task?
  - supervised tools can be trained

# Annotationworkflow

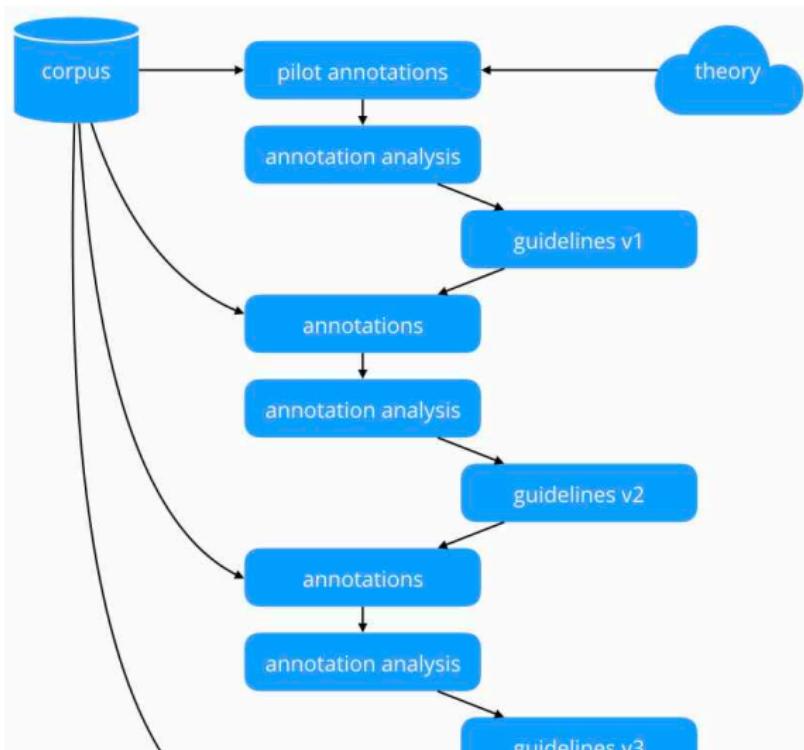


Figure: Annotation workflow schema. Arrows indicate (rough) temporal sequence.

## Inter-subjective Annotations in DH?

- Linguistic annotations: Inter-subjective annotations
  - E.g., part of speech
  - Different annotators create the same annotations
  - Inter-Annotator Agreement (IAA)
- Annotation guidelines
  - Mediator between theory and annotation
  - Guidebook for annotators (who may not be experts)
    - What is to be annotated?
    - Which categories are used in which cases?
    - How to deal with borderline cases?
    - How have we dealt with difficult cases in the past?
    - Tons of examples

# **CL and DH in Stuttgart**

**2**

# Masterstudiengang Digital Humanities, Universität Stuttgart

	1. Semester	2. Semester	3. Semester	4. Semester
Vertiefung geisteswissenschaftliches Fach		Wahlbereich Geisteswissenschaften - Vertiefung Geisteswissenschaften* 12-18		
	DH in den Geisteswissenschaften I 6 (Ringvorlesung)	DH in den Geisteswissenschaften II 6 ***		
Spezialisierung Digital Humanities	Theoretische und informatische Grundlagen für die Digital Humanities (VL+Ü) 9	Methoden der Digital Humanities (Sem) 6  Projektarbeit (P) 9	Reflexion digitaler Methoden (Sem) 6  Forschungskolloquium (Sem) 6	Masterarbeit 30
Spezialisierung Informatik	Methoden maschinelner Sprachverarbeitung (VL+Ü) 9  Programmierkurs (Ü)** 3		Wahlbereich Informatik** 12-18	
	Semester 1 30 LP	Semester 2 30 LP	Semester 3 30 LP	Semester 4 30 LP

\* Importmodule aus den Geisteswissenschaften

\*\* Importmodule Informatik

\*\*\* DH-Veranstaltung in den Geisteswissenschaften - Veranstaltung wird vom geisteswissenschaftlichen Fach angeboten

14.04.2016

# Masterstudiengang Digital Humanities, Universität Stuttgart

	1. Semester	2. Semester	3. Semester	4. Semester
<b>Vertiefung geisteswissenschaftliches Fach</b>		Wahlbereich Geisteswissenschaften - Vertiefung Geisteswissenschaften* 12-18		
	DH in den Geisteswissenschaften I (Ringvorlesung) 6	DH in den Geisteswissenschaften II *** 6		
<b>Spezialisierung Digital Humanities</b>	Theoretische und informative Grundlagen für die Digital Humanities (VL+Ü) 9	Methoden der Digital Humanities (Sem) 6 Projektarbeit (P) 9	Reflexion digitaler Methoden (Sem) 6 Forschungskolloquium (Sem) 6	Masterarbeit 30
<b>Spezialisierung Informatik</b>	Methoden maschinelner Sprachverarbeitung (VL+Ü) 9 Programmierkurs (Ü)** 3		Wahlbereich Informatik** 12-18	
	Semester 1 30 LP	Semester 2 30 LP	Semester 3 30 LP	Semester 4 30 LP

\* Importmodule aus den Geisteswissenschaften

\*\* Importmodule Informatik

\*\*\* DH-Veranstaltung in den Geisteswissenschaften - Veranstaltung wird vom geisteswissenschaftlichen Fach angeboten

14.04.2016

# NLP Methods for DH

Two main ideas

- cover some basic NLP tasks
- cover conceptual workflow

	PoS tagging	Named Entity Recognition	Coreference Resolution
Annotation	STTS, IAA, Kappa	NoSta-D, BIO	TueBa + NoSta-D
Modelling	Decision Trees	HMM, CRF	Clustering
Evaluation	Accuracy	Precision/Recall	Specific metrics (CEAF, B3, BLANC)

Test hypotheses about dramatic characters on large data sets using NLP methods

Dimensions:

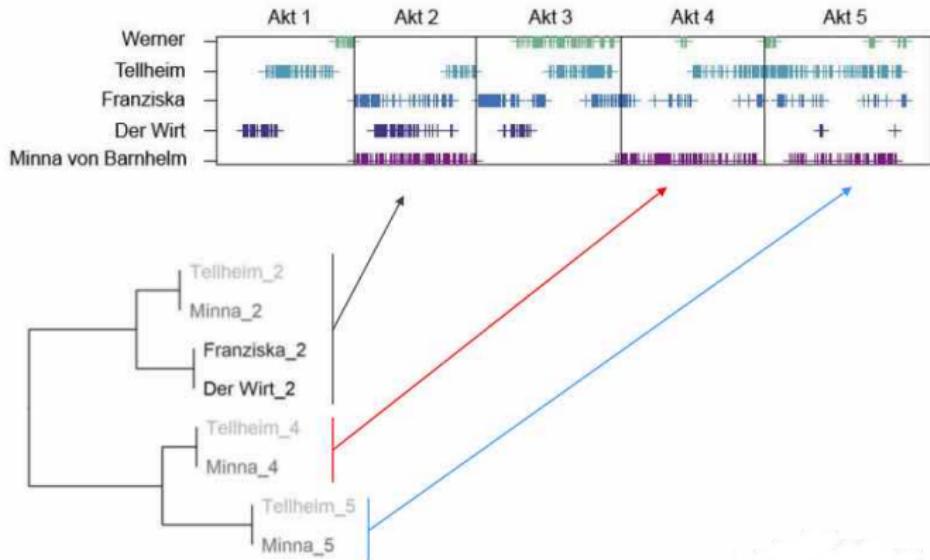
- Character classes by gender, action, social class, stock character
  - How are fathers marked as being 'tender'?
- Relations between characters
  - What are shared topics/emotions?
- Character (type) development
  - When are characters types appearing/disappearing?

<sup>1</sup> Project members: Nils Reiter, Marcus Willand, Benjamin Krauter, Janis Pagel

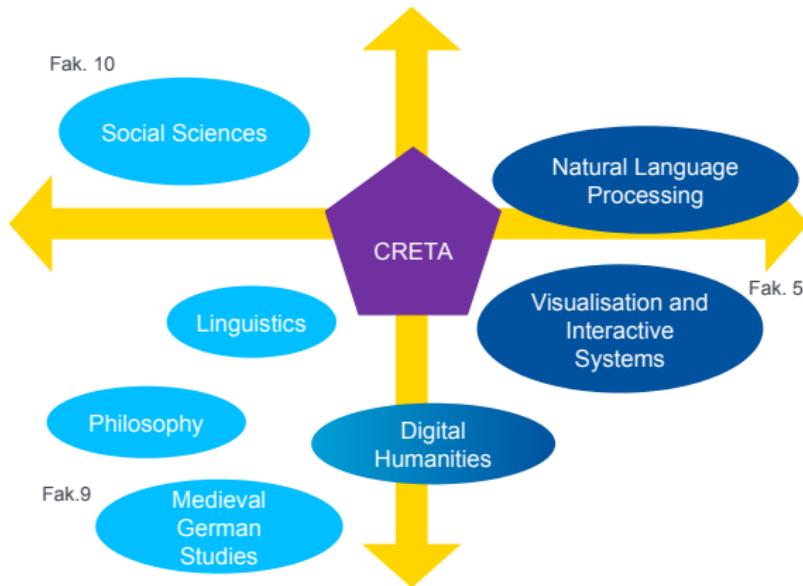
# Co-presence of Characters

## Figuren im Drama: Lessings *Minna von Barnhelm*

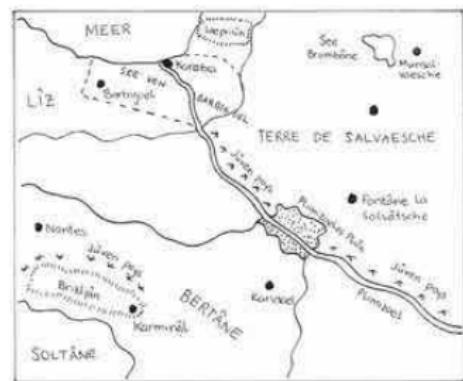
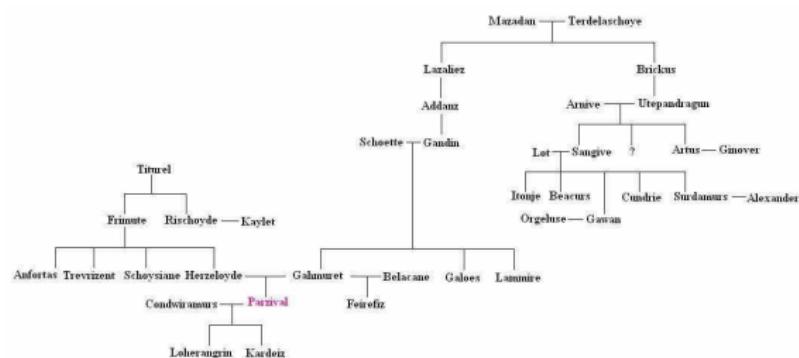
Kopräsenz (II)



# Center for Reflected Text Analytics (CRETA)



## Narrative Structure of Arthurian Romance (Example Parzival)<sup>1</sup>



<sup>1</sup>Project members: Nora Ketschik, André Blessing, Manuel Braun

## Wertheradaptionen<sup>1</sup>

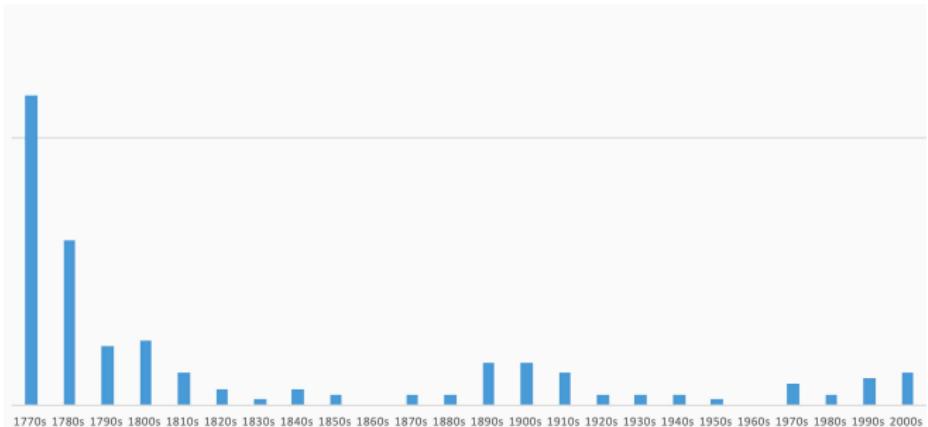
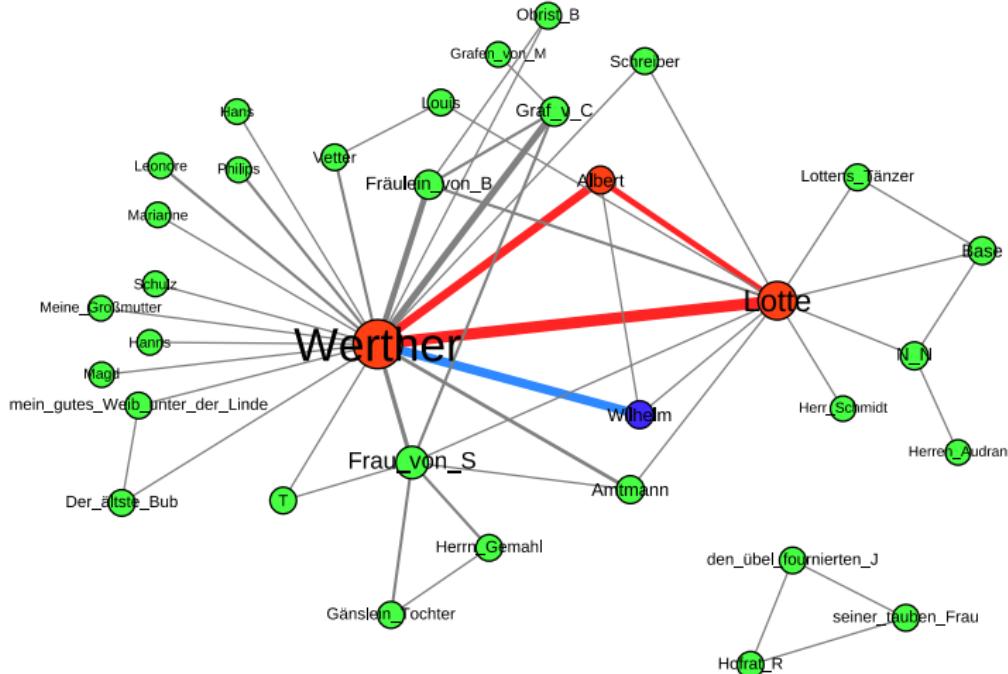


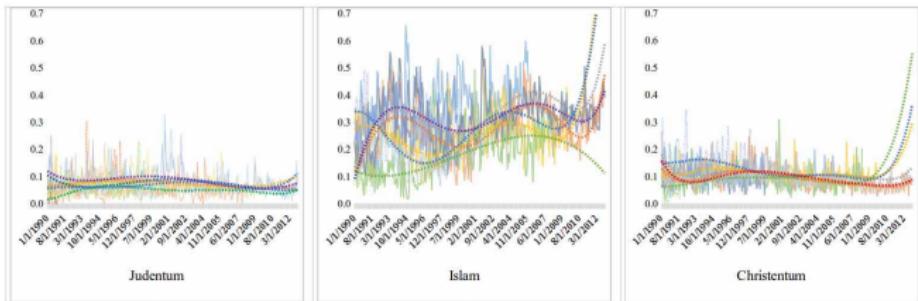
Figure: Anzahl publizierter Wertheriadaden seit der Publikation des Originals in 1774.

<sup>1</sup> Projektbeteiligte: Sandra Murr, Sandra Richter

# Love Triangle



# Religion in International Newspaper Discourse<sup>1</sup>



Deutsche Presse			US-Amerikanische Presse			Französische Presse			Britische Presse		
No.	Search result	Freq.	No.	Search result	Freq.	No.	Search result	Freq.	No.	Search result	Freq.
1	Muslime	9094	1	Islamie	45276	1	Muslimans	10251	1	Muslim	15300
2	islamischen	7641	2	Muslim	43293	2	islamistes	10144	2	Islamic	12368
3	Islam	6953	3	Muslims	28619	3	islamique	8540	3	Muslims	10973
4	Islamisten	6109	4	Shiite	28498	4	islamiste	5873	4	Shia	5743
5	muslimischen	4593	5	Islam	12208	5	chiites	5489	5	Islam	4193
6	islamische	4168	6	mosque	9625	6	chuite	5319	6	Islamist	4169
7	Schiiten	3271	7	Shiites	8860	7	islam	4852	7	jihad	3294
8	Muslimen	3247	8	Jihad	7669	8	sunnites	3702	8	mosque	2821
9	islamistischen	2886	9	Sunnis	6512	9	djihad	3412	9	Islamists	1552
10	Dschihad	2617	10	Islamist	5675	10	Musliman	3402	10	Sunnis	1307
11	muslimische	2510	11	mosques	3599	11	sunnite	2850	11	mosques	1054
12	Moschee	2015	12	Islamists	2689	12	musulmane	2704	12	Shias	995
13	schittischen	1995	13	Imam	1989	13	mosquée	2144	13	Imam	640
14	islamistische	1871	14	Muslim-led	1902	14	islamiques	1649	14	Allah	493
15	Sunniten	1708	15	jihadists	1249	15	djihadistes	1579	15	Muslim-Croat	416
16	islamischer	1302	16	jihadist	1197	16	mosquées	1284	16	jihadists	390
17	sunnitischen	1299	17	Muslim-Croat	1066	17	imam	1234	17	jihadis	342
18	schittische	1283	18	of Ramadan	983	18	musulmanes	1186	18	Jihadi	337
19	Moscheen	1103	19	Allah	931	19	islamisme	1179	19	Mecca	336
20	Islams	977	20	Mecca	862	20	Allah	761	20	jihadist	332

<sup>1</sup>Project members: Maximilian Overbeck, Cathleen Kantner

## Concepts and their Connections in Adorno<sup>1</sup>

“Interessant ist, daß sich mir bei der Arbeit aus dem Inhalt der Gedanken gewisse Konsequenzen für die Form aufdrängen, die ich längst erwartete, aber die mich nun doch überraschen. Es handelt sich ganz einfach darum, daß aus meinem Theorem, daß es philosophisch nichts ‘Erstes’ gibt, nun auch folgt, daß man nicht einen argumentativen Zusammenhang in der üblichen Stufenfolge aufbauen kann, sondern daß man das Ganze aus **einer Reihe von Teilkomplexen montieren muß, die gleichsam gleichgewichtig sind und konzentrisch angeordnet,** auf gleicher Stufe; deren Konstellation, nicht die Folge, muß die Idee ergeben.”

<sup>1</sup> Project member: Axel Pichler

# Concepts and their Connections in Adorno<sup>1</sup>

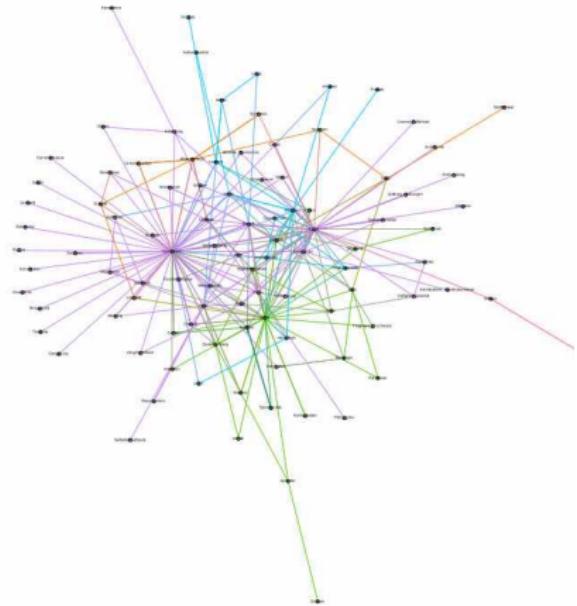
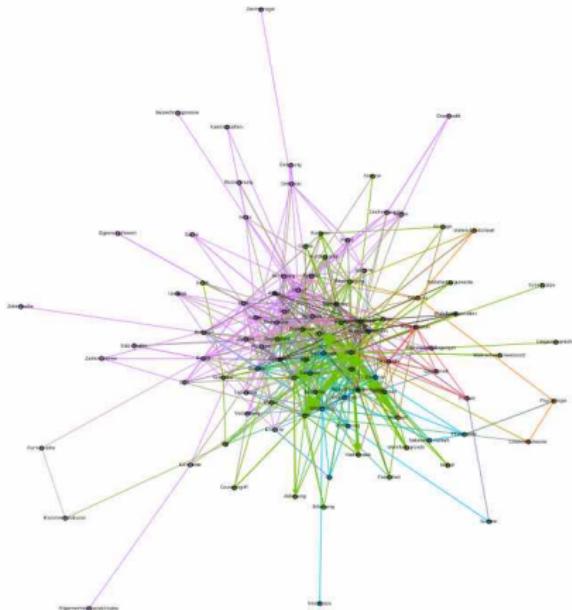


Figure: Term networks in Wittgenstein's Tractatus (left) and Adorno's "Ästhetische Theorie" (right)

<sup>1</sup> Project member: Axel Pichler

## Common interest

- Individually distinguishable objects in the real or a fictional world
  - “Individually distinguishable” = by naming
  - “objects” does not imply physical objects
- References to such entities in texts
  - Proper names (“Angela Merkel”)
  - Descriptive noun phrases (“the chancellor”)
  - Pronouns (“she”)

## Entities

- Parzival
  - Characters und groups of characters ("three knights")
  - Locations
- Werther
  - Characters: Werther, Lotte, Albert
- Parliamentary debates
  - Political parties, international organisations ("EU commission", "United Nations general assembly")
- Aesthetic Theory
  - Philosophers, works, abstract concepts
- Dramatic Texts
  - Characters: Hamlet, Sara Sampson, the priest

# Annotating Coreference

# Coreference

## Definition and Examples

- If two linguistic units co-refer, they refer to the same non-textual entity
  - [A woman] bought a house. [The woman] lived happily ever after. (prototypical)
  - [A woman] bought a house. [She] lived happily ever after. (anaphoric)
  - [Mary] bought a house. [The woman] enjoyed the garden. (coreferential)
  - [Mary likes to sing in the shower.] Her boyfriend hates [that]. (non-nominal antecedent)

# Coreference

## Definition and Examples

- If two linguistic units co-refer, they refer to the same non-textual entity
  - [A woman] bought a house. [The woman] lived happily ever after. (prototypical)
  - [A woman] bought a house. [She] lived happily ever after. (anaphoric)
  - [Mary] bought a house. [The woman] enjoyed the garden. (coreferential)
  - [Mary likes to sing in the shower.] Her boyfriend hates [that]. (non-nominal antecedent)
- Complications
  - Embedded mentions: [ [Donald Trumps] Gouvernement]
  - Plural mentions: [John] was cooking for [Mary]. [They] enjoyed it.
  - Discontinuity/relative clauses: Ich habe [die Sendungen] zur Post gebracht, [ [die] hier schon lange rumliegen].

# Coreference

## Two tasks

- Mention detection
  - Find all linguistic units that refer (to something)
  - Named entity detection + X
    - Noun phrases (the gardener)
      - Almost all NPs can be used both non-referring and referring
    - Pronouns (she)
      - Trivial, since it's a fixed list
- Coreference resolution
  - Group mentions that co-refer
  - Most simple approach: Classification of mention pairs

# Coreference

## Two tasks

- Mention detection
  - Find all linguistic units that refer (to something)
  - Named entity detection + X
    - Noun phrases (the gardener)
      - Almost all NPs can be used both non-referring and referring
    - Pronouns (she)
      - Trivial, since it's a fixed list

# Annotating Coreference

## Goals

- Create a **gold standard** for a couple of relevant texts
- Allows for experimentation of simple hacks (dramas) as well as more complex systems
- Be *compatible* to standard coreference as much as possible
  - Reuse of annotation guidelines (Naumann, 2007)
  - Potential integration of tools
  - Potential combination of annotated data (→ domain adaptation)
- Apply the same/similar scheme to prose, drama, and non-literary texts

# Annotating Coreference

## Guidelines

- Singletons are not annotated
- Non-nominals are included (as antecedents)
- Deviations from standard coreference
  - Chains: Elements of a chain form an equivalence set
  - No annotation of link type (e.g., anaphoric vs. coreferential vs. cataphoric)
    - Can be detected automatically

# Annotating Coreference

## Corpus

- Prose
  - Goethe: *Die Leiden des Jungen Werther* (1787)
  - Perutz: *Zwischen neun und neun* (1918), *Nur ein Druck auf den Knopf* (1930), *Der Mond lacht* (1930)
  - Rowlandson: *Narrative of the Captivity and Restoration of Mrs. Mary Rowlandson* (1682, English)
  - Fairy tales
- Drama
  - Lessing: *Miß Sara Sampson* (Bürgerliches Trauerspiel)
  - Schiller: *Die Räuber* (Sturm und Drang)
  - Hofmannsthal: *Der Rosenkavalier* (?)
- Drama-like
  - Bundestag: Parliamentary debates (1996-2015)

Annotating Coreference

# Annotation Issues

# Annotation Issues

## Use of generic noun phrases (1/2)

**Der Wirt.** [...] Was liegt mir daran, ob ich es weiß, oder nicht, was Sie für eine Ursache hierher führt, und warum Sie bei mir im Verborgnen sein wollen? Ein Wirt nimmt sein Geld, und lässt seine Gäste machen, was ihnen gut dünkt. Waitwell hat mir zwar gesagt, [...]

(Lessing, Miß Sara Sampson)

# Annotation Issues

## Use of generic noun phrases (1/2)

**Der Wirt.** [...] Was liegt mir daran, ob ich es weiß, oder nicht, was Sie für eine Ursache hierher führt, und warum Sie bei mir im Verborgnen sein wollen? Ein Wirt nimmt sein Geld, und lässt seine Gäste machen, was ihnen gut dünkt. Waitwell hat mir zwar gesagt, [...]

(Lessing, *Miß Sara Sampson*)

[Sie]<sub>1</sub> ließ [[ihren]<sub>2</sub> Regenschirm]<sub>3</sub> fallen. [Jeder junge Mann]<sub>4</sub> wird in einem solchen Fall blitzschnell nach [dem Schirm]<sub>5</sub> greifen und [ihn]<sub>6</sub> [der Dame]<sub>7</sub> überreichen. Und [die Dame]<sub>8</sub> bedankt sich vielmals. Aber diesmal geschah etwas Unerhörtes. [Stanislaus Demba]<sub>9</sub> ließ [den Schirm]<sub>10</sub> liegen.

(Perutz, *Zwischen Neun und Neun*)

# Annotation Issues

## Use of generic noun phrases (2/2)

- Generic expressions are relatively frequent
  - “[Ihr Mannspersonen] müßt doch selbst nicht wissen, was ihr wollt.”
  - “Mellefont besitzt alles, was uns [eine Mannsperson] gefährlich machen kann.”
- Should generic expressions be co-referent (e.g., multiple references to the class man)?
  - Standard guidelines: No coreference between generic mentions
- Generic noun phrases not specific to literary texts
- Switching between generic and non-generic use is more frequent than in newspaper texts

# Annotation Issues

## Entity development and character perception



- Characters change over the course of the text (frog prince)
- Characters in disguise (red riding hood: wolf poses as grandmother)

- Annotating reader knowledge possible in both cases
- What do we lose?
- What knowledge do we define?
  - Important for reaching inter-subjective annotations

# Annotation Issues

## World knowledge

**Hermann.** [...] Da Karl auf der Welt nichts mehr zu hoffen hatte, zog ihn der Hall von Friederichs siegreicher Trommel nach Böhmen. Erlaubt mir, sagte er [zum großen Schwerin], daß ich den Tod sterbe auf dem Bette der Helden [...].

(Schiller, *Die Räuber*)

- Friederich == großer Schwerin?

# Annotation Issues

## World knowledge

**Hermann.** [...] Da Karl auf der Welt nichts mehr zu hoffen hatte, zog ihn der Hall von Friederichs siegreicher Trommel nach Böhmen. Erlaubt mir, sagte er [zum großen Schwerin], daß ich den Tod sterbe auf dem Bette der Helden [...].

(Schiller, *Die Räuber*)

- Friederich == großer Schwerin?
  - No. Großer Schwerin = Kurt Christoph Graf von Schwerin
  - [https://de.wikipedia.org/wiki/Kurt\\_Christoph\\_von\\_Schwerin](https://de.wikipedia.org/wiki/Kurt_Christoph_von_Schwerin)

## Annotation Issues

### Lexical variation / coreference vs. bridging

**Mellefont.** Mit Unrecht tadeln Sie die Verzögerung [einer Zeremonie] [...].

**Sara.** Neue Freunde sollen die Zeugen [unserer Verbindung] sein? [...]

**Mellefont.** Aber überlegen Sie denn nicht, Miss, dass [unserer Verbindung] hier diejenige Feier fehlen würde, die wir ihr zu geben schuldig sind?

(*Lessing, Miß Sara Sampson*)

# Annotation Issues

## Lexical variation / coreference vs. bridging

**Mellefont.** Mit Unrecht tadeln Sie die Verzögerung [einer Zeremonie] [...].

**Sara.** Neue Freunde sollen die Zeugen [unserer Verbindung] sein? [...]

**Mellefont.** Aber überlegen Sie denn nicht, Miss, dass [unserer Verbindung] hier diejenige Feier fehlen würde, die wir ihr zu geben schuldig sind?

(Lessing, *Miß Sara Sampson*)

- “Verbindung” refers to both the wedding and the marriage
- Related to bridging: Reference to entities that are related to previously mentioned entities
  - Mary bought [a car]. [The engine] is strong.
    - (bridging relation between car and engine)

# Annotation Issues

## Colorful language

**Mellefont.** [...] ich hatte noch keine verwahrloste Tugend auf meiner Seele. Ich hatte noch keine Unschuld in ein unabsehbliches Unglück gestürzt. Ich hatte noch keine Sara aus dem Hause eines geliebten Vaters entwendet, und sie gezwungen, einem Nichtswürdigen zu folgen, der auf keine Weise mehr sein eigen war.

- At utterance time, Mellefont has abducted Sara.
- “kein X”: Typically considered to be generic and therefore non-referring
- But clearly related to (and understood as) a non-generic entity (Sara)

# Annotation Issues

## Colorful language

**Mellefont.** [...] ich hatte noch keine verwahrloste Tugend auf meiner Seele. Ich hatte noch keine Unschuld in ein unabsehbliches Unglück gestürzt. Ich hatte noch keine Sara aus dem Hause eines geliebten Vaters entwendet, und sie gezwungen, einem Nichtswürdigen zu folgen, der auf keine Weise mehr sein eigen war.

- At utterance time, Mellefont has abducted Sara.
- “kein X”: Typically considered to be generic and therefore non-referring
- But clearly related to (and understood as) a non-generic entity (Sara)

**Sara.** [...] Wenn zum Exempel, [ein Mellefont] [eine Marwood] liebt, und sie endlich verläßt

- Proper nouns with indefinite article

# Annotation Issues

## Non-nominal antecedents

**Mellefont.** Eine schlechte Vorbereitung, eine [trost]suchende Betrühte zu empfangen. Warum sucht [ihn] auch bei mir? – Doch wo soll sie [ihn] sonst suchen?

- Only possible antecedent for „ihn“: trost
- Sub-token annotation!

**Waitwell.** Sara liebt ihren Vater noch. Wenn Sie nur [davon] überzeugt sein wollen

- „davon“ refers to the entire sentence

# Annotation Issues

## True ambiguities

“Vierzehn Personen, darunter zwei Professoren der Universität, [...]”

Der Universitätsprofessor versuchte es [...]”

[...] und einer von den Professoren versuchte [...]”

Einer von den Universitätsprofessoren trat hin [...]”

(Perutz, *Nur ein Druck auf den Knopf*)

- Two references must be co-referential but we don't know which ones

# Annotation Issues

## True ambiguities

“Vierzehn Personen, darunter zwei Professoren der Universität, [...]”

Der Universitätsprofessor versuchte es [...]

[...] und einer von den Professoren versuchte [...]”

Einer von den Universitätsprofessoren trat hin [...]”

(Perutz, *Nur ein Druck auf den Knopf*)

- Two references must be co-referential but we don't know which ones
- Other examples:
  - Rhetorical “we” in parliamentary debates (we the opposition, we the CDU, we the Europeans, we the audience, we politicians, ...)
  - Groupings in Schiller's *Räuber*: Who exactly belongs to the group at which point is impossible to determine

Annotating Coreference

# Annotation Tool

# Annotation Tool

## Requirements

- Basics: Group mentions that refer to the same entity
- Handling of groups, discontinuous clauses
- Long texts
- A lot of entities
- Flexible Im- and Export
  - E.g., TEI/XML
- Handling of text structure (acts, scenes, who speaks, stage directions)

# Annotation Tool

## Failed but tried

- Annotators edit TEI/XML files directly

```
<sp who="#sir_william">
  <speaker>SIR WILLIAM.</speaker>
  <l> Hier <rs ref="#sara">meine Tochter</rs>? Hier in <rs xml:id="wirtshaus">
    diesem elenden Wirtshause</rs>?</l>
</sp>
```

- Readily available
- Well-formedness/validity can be ensured automatically
- Slow, cumbersome, somewhat error-prone

# Annotation Tool

## Failed but tried

- Annotators edit TEI/XML files directly

```
<sp who="#sir_william">
  <speaker>SIR WILLIAM.</speaker>
  <l> Hier <rs ref="#sara">meine Tochter</rs>? Hier in <rs xml:id="wirtshaus">
    diesem elenden Wirtshause</rs>?</l>
</sp>
```

- Readily available
- Well-formedness/validity can be ensured automatically
- Slow, cumbersome, somewhat error-prone
- WebAnno <https://webanno.github.io>
  - Conversion from/to TEI/XML
  - Web-based (distribution of documents, update of software)
  - Impossible to handle many long chains
  - UI unresponsive for long documents

# Annotation Tool

## Failed but tried

- Annotators edit TEI/XML files directly

```
<sp who="#sir_william">
  <speaker>SIR WILLIAM.</speaker>
  <1> Hier <rs ref="#sara">meine Tochter</rs>? Hier
      diesem elenden Wirtshause</rs>?</1>
</sp>
```

- Readily available
- Well-formedness/validity can be ensured automatically
- Slow, cumbersome, somewhat error-prone
- WebAnno <https://webanno.github.io>
  - Conversion from/to TEI/XML
  - Web-based (distribution of documents, update)
  - Impossible to handle many long chains
  - UI unresponsive for long documents

The screenshot shows a web browser window titled "QuaDramA". The URL in the address bar is "quadrama.github.io". The main content area displays a blog post by Nils Reiter, dated 20<sup>th</sup> December 2017, titled "Annotating Coreference Chains (Part 2)". The post discusses the recent start of annotating coreference chains in dramatic texts and revisits the annotation tool question. It includes links to "Part 1" and "Part 2". Below the post, there is a "Table of contents" section with links to various parts of the series:

- XML-Editor and TEI
- Requirements
- Converting TEI/XML to UIMA XMI
- Converting UIMA XMI to TEI/XML
- WebAnno

Text below the table of contents states: "Before going into details about interesting findings, we'll have to revisit the annotation tool question, because there has been a development."

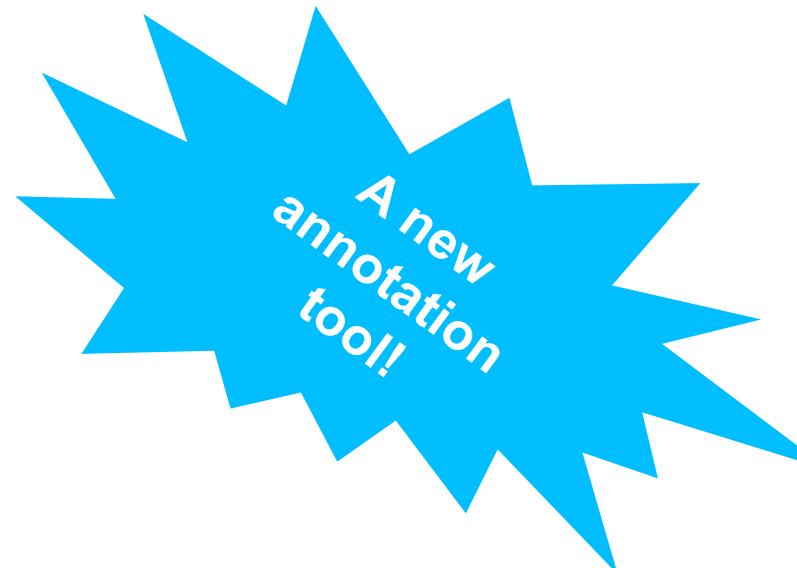
**XML-Editor and TEI**

Our initial setup was to ask the annotators to annotate coreferences directly in TEI/XML, using the plain text editor Atom. Atom is extendable relatively easy, so that we could have

# Annotation Tool

## CorefAnnotator

- Developed for long texts with many entities
- Entities represented as sets of mentions,  
no binary relations between mentions
- Useable with a keyboard for fast annotation
- Automatic generation of candidate entities  
based on context and previous annotations (semi-automatic annotation)
- Annotations stored in stand-off format using UIMA as a platform
  - Compatible to WebAnno
  - Import/Export in various formats (CoNLL, TEI/XML\*)
  - Open Source: Apache License 2.0
  - <https://github.com/nilsreiter/CorefAnnotator>



\* Given some preconditions

A || + - C | D E F G H I J K L Q

Die Räuber (Räuber\_AS.xmi)

Engel grollen nicht – er verzeiht Euch. Faßt seine Hand mit Wehmut. Vater meines Karls! ich verzeih Euch.

• **DER ALTE MOOR.**

Nein, meine Tochter! diese Totenfarbe deines Angesichts verdammet den Vater. Armes Mädchen! Ich brachte dich um die Freuden deiner Jugend – o fluche mir nicht!

• **AMALIA**

küßt seine Hand mit Zärtlichkeit.

Euch?

• **DER ALTE MOOR.**

Kennst du dieses Bild, meine Tochter?

• **AMALIA.**

Karls! –

+ Add new entity

- ▶ KARL VON MOOR
- ▶ FRANZ VON MOOR
- ▶ AMALIA (239)
- ▶ DER ALTE MOOR (182)
- ▶ DIE RÄUBER (182)
- ▶ HERMANN (159)
- ▶ SCHWEIZER (120)
- ▶ SPIEGELBERG (115)
- ▶ RAZMANN (110)
- ▶ KOSINSKY (103)
- ▶ ROLLER (92)
- ▶ DANIEL (70)
- ▶ PATER (59)
- ▶ GRIMM (51)
- ▶ SCHWARZ (48)
- ▶ SCHUFTERLE (42)
- ▶ du (40)
- ▶ TOD (32)
- ▶ Menschen Kirche
- ▶ Gott (29)
- ▶ GEN. MAN (23)
- ▶ JAKOB (21)
- ▶ Ganze Haufen bölk
- ▶ Der Teufel (21)
- ▶ HIMMEL (21)
- ▶ MANN, HERMANN
- ▶ Mädchen Kosinsk

Style: QuaDramA CoreFAnnotator 1.3.0

Die Räuber (Räuber\_AS.xmi)

A C

Engel grollen nicht – er verzeiht Euch. Faßt seine Hand mit Wehmut. Vater meines Karls! ich verzeih Euch.

**DER ALTE MOOR.**

Nein, meine Tochter! diese Totenfarbe deines Angesichts verdammet den Vater. Armes Mädchen! Ich brachte dich um die Freuden deiner Jugend – o fluche mir nicht!

**AMALIA**

küßt seine Hand mit Zärtlichkeit Euch?

**DER ALTE MOOR.**

Kennst du dieses Bild, meine Tochter?

**AMALIA.**

Karls! –

+ Add new entity

- ▶ KARL VON MOOR
- ▶ FRANZ VON MOOR
- ▶ AMALIA (239)
- ▶ DER ALTE MOOR (
- ▶ DIE RÄUBER (182)
- ▶ HERMANN (159)
- ▶ SCHWEIZER (120)
- ▶ SPIEGELBERG (115)
- ▶ RAZMANN (110)
- ▶ KOSINSKY (103)
- ▶ ROLLER (92)
- ▶ DANIEL (70)

Search

Amalia\w+\b

erstaunt. Mir? **Amalias** Porträt? Mir, Karl, Amalia? Mir?  
 ete, der Gefürchtete, erklärt sich freiwillig für **Amalias** Sklaven –  
 cher, gepriesener Mann – hier dein Knabenleben in **Amalias** blühenden Kindern zum zweiten Mal leben –  
 Er segelt auf ungestümen Meeren – **Amalias** Liebe segelt mit ihm – er wandelt durch ungeba –  
 – er wandelt durch ungebaunte, sandige Wüsten – **Amalias** Liebe macht den brennenden Sand unter ihm  
 n, stürmischer Hagel regnet um seine Schläfe, und **Amalias** Liebe wiegt ihn in Stürmen ein – Meere und

6 Search results

- ▶ MANN, HERMANN
- ▶ Mädchen Kosinsk

Style: QuaDramA CoreFAnnotator 1.3.0

Sir William Sampson und Waitwell treten in Reisekleidern herein.

SIR WILLIAM.  
Hier meine Tochter? Hier in diesem elenden Wirtshause?

WAITWELL.  
Ohne Zweifel hat Mellefont mit Fleiß das allerelendeste im ganzen Städtchen zu seinem Aufenthalte gewählt. Böse Leute suchen immer das Dunkle, weil sie böse Leute sind. Aber was hilft es ihnen, wenn sie sich auch vor der ganzen Welt verbergen könnten? Das Gewissen ist doch mehr, als eine ganze uns verklagende Welt. – Ach, Sie weinen schon wieder, schon wieder, Sir! – Sir!

**Sara\_AH.xmi**

Color:	<span style="background-color: blue; width: 20px; height: 10px;"></span>
Mentions:	3203
Entities:	370
Position:	224.126 (99,8%)
Open:	<a href="#">Sara_AH.xmi</a>

**Sara\_AS.xmi**

Color:	<span style="background-color: lime; width: 20px; height: 10px;"></span>
Mentions:	3161
Entities:	305
Position:	224.126 (99,8%)
Open:	<a href="#">Sara_AS.xmi</a>

**Agreement Analysis**

Annotations:	4330
Agreement (absolute):	2.034
Agreement (document):	47,0%
Agreement (parallel):	47,0%

CorefAnnotator 1.3.0

Style: QuaDramA

CorefAnnotator 1.3.0

(Sara\_AS.xmi)

Sir William Sampson. Sara. Waitwell.

SIR WILLIAM.  
Du bleibst mir viel zu lange, Waitwell. Ich muß sie sehen.

SARA.  
Wessen Stimme --

SIR WILLIAM.  
Ach, meine Tochter!

**Annotate ▶**

- +• New
- HN
- sara
- arabella
- norton
- sir\_william
- marwood
- waitwell
- mellefont

SARA.  
Ach, mein Vater! – Hilf mir auf, daß ich mich zu seinen Füßen werfen kann. Sie Schwachheit in den Lehnsstuhl zurück. Eine erquickende Erscheinung, vom Himmel den Starken zu stärken kam? – Segne mich, wer du auch seist, ein Bote des Höchsten, in der Gestalt meines Vaters, oder selbst mein Vater!

SIR WILLIAM.  
Gott segne dich, meine Tochter! – Bleib ruhig. Indem sie es nochmals versuchen will, vor ihm niederzufallen. Ein andermal, bei mehrern Kräften, will ich dich nicht ungern mein zitterndes Knie umfassen sehen.

+• Add new entity

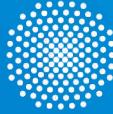
- • mellefont (898)
- • marwood (538)
- • sara (513)
- • norton (115)
- • arabella (104)
- • sir\_william (96)
- • lady\_solmes (84)
- • waitwell (55)
- • hannah (45)
- • betty (32)
- • herz\_mellefont (22)
- • der\_himmel (19)
- • menschen (15)
- • herz\_sara (14)
- • man\_gen (13)
- • eine\_marwood (12)
- • kollektiv\_frau (12)
- • der\_wirt (11)
- • dieser\_brief (11)
- • unser (11)
- • eheschließung (11)
- • welt (11)
- • dolch (10)
- • uns (9)
- • uns (8)
- • unser (8)
- • deine\_Tyrannen (7)
- • liebe\_mellefont (7)
- • einen\_vogel (7)
- • qualen (6)
- • eine\_anverwandtin (6)
- • gasthof (6)
- • mein\_Eigentum (6)
- • einbildung (6)
- • eine\_anverwandte (6)
- • eine\_iammernde\_tochter (6)

Style: Default      CorefAnnotator 1.3.0

# Summary

# Summary

- Lessons learned
  - Clarify concepts through annotation and discussion
  - Annotation useful in DH, because close reading
  - Common sub tasks can be addressed across disciplines/research questions
  - Expert knowledge helpful for method development
  - Coreference fascinating task when applied to literary texts because it highlights the blind spots of linguistic theory / CL assumptions
- Collaboration
  - Two-way street
    - CL: New challenges for established workflows
    - DH: Quantification and inter-subjectivity



# Vielen Dank!



**Sarah Schulz, Nils Reiter**

E-Mail [firstname.lastname@ims.uni-stuttgart.de](mailto:firstname.lastname@ims.uni-stuttgart.de)

Telefon +49 (0) 711 685-81354

Fax +49 (0) 711 685-81366

Universität Stuttgart  
Institut für Maschinelle Sprachverarbeitung  
Pfaffenwaldring 5b  
70569 Stuttgart