

Combining heterogeneous text-technological resources for anaphora resolution

Daniela Goecke
Universität Bielefeld

CoGETI Workshop
Heidelberg, 24.11.2006



1. Projekt and Research Group
2. Application Domain: Anaphora Resolution
3. Corpus Annotation
4. Sample Annotation
5. Corpus Study
6. Use of logical document structure
7. Combining heterogeneous XML resources
8. Conclusion and Outlook

- DFG Research Group 437 „Text-technological Modelling of Information“ (2002–2008)
- Projekt A2 „Sekimo“ – Secondary Information Modelling and Combination of text-technological Resources

- DFG Research Group 437 „Text-technological Modelling of Information“ (2002–2008)
- Projekt A2 „Sekimo“ – Secondary Information Modelling and Combination of text-technological Resources
 - Abstract representation to model multi-layered XML annotations
 - Architecture for the combination of heterogeneous linguistic resources
 - Markup-Unification
 - Generation of new – richer annotated – XML documents
 - Creation of a corpus of anaphoric relations
 - Application domain: resolution of definite description anaphora

The application domain

- Development of a system for the automatic resolution of anaphoric relations (decision tree based)
- Subgoals
 - Annotation of a training and evaluation corpus
 - Integration of necessary knowledge (morpho-syntactic and semantic information, anaphora-antecedent distance etc.)
 - Creation of anaphora-antecedent-candidate pairs
 - Detection of the correct antecedent



The Corpus

- 47 German linguistic articles (collected in the C1 project, Giessen)
- 6 German newspaper articles
- Evaluation based on a subset of 2 linguistic articles, 1 newspaper article and 1 hypertext article:
 - 4196 discourse entities
 - 1971 anaphoric relations
- XML annotated corpus
- Corpus annotation is done semi-automatically

- The annotation schema
 - Is an extension of the annotation Schema developed for the B1 project of the DFG research group (Anke Holler)
 - Defines three primary semantic relation types
 - cospecLink *The man – he , city – hanseatic city*
 - bridgingLink *The room – the window*
 - corefLink as a text-world relation
 - cospecLinks and bridgingLinks hold between discourse entities (in A2 DE of type *nominal* and *namedEntity*)
 - In the XML annotation, semantic relations are modelled using ID/IDREF

Annotation Schema

- The Annotation is done in two steps:
 1. Annotation/Detection of Discourse Entities
 2. Annotation of semantic relations
- In A2 only intra-textual relations are annotated

Annotation Schema

- For each primary relation type several secondary relation types exist
- cospecLink
 - ident, synonym, hyperonym, hyponym, paraphrase, addInfo, isA
 - a man – the man*
 - Peter – he*
 - the horse – the animal*
 - Mary Baggins – the 17 year old girl*
- bridgingLink
 - possession, meronym, holonym, setMember, hasMember, association
 - Peter – his mother*
 - a room – the window*
 - two men – the younger one*

Sample Annotation

- „Lurup is a social ghetto of the hanseatic city (Hansestadt), an outskirt with single unit houses but also many apartment blocks in the west of the city (Stadt)“

```
<cnx-pi_sentence id="w826" auto="no">  
    Lurup ist ein sozialer Brennpunkt  
    <de deID="de226" headRef="w833">  
        <cnx-pi_token ref="w832">der</cnx-pi_token>  
        <cnx-pi_token ref="w833">Hansestadt</cnx-pi_token>  
    </de>  
    , ein Vorort mit Einzelhäusern, aber auch vielen Wohnblocks im Westen  
    <de deID="de231" headRef="w848">  
        <cnx-pi_token ref="w847">der</cnx-pi_token>  
        <cnx-pi_token ref="w848">Stadt</cnx-pi_token>  
    </de>.  
</cnx-pi_sentence>
```

Sample Annotation

- „Lurup is a social ghetto of the hanseatic city (Hansestadt), an outskirt with single unit houses but also many apartment blocks in the west of the city (Stadt)“

```
<cnx-pi_sentence id="w826" auto="no">  
  
    Lurup ist ein sozialer Brennpunkt  
    <de deID="de226" headRef="w833">  
        <cnx-pi_token ref="w832">der</cnx-pi_token>  
        <cnx-pi_token ref="w833">Hansestadt</cnx-pi_token>  
    </de>  
    , ein Vorort mit Einzelhäusern, aber auch vielen Wohnblocks im Westen  
    <de deID="de231" headRef="w848">  
        <cnx-pi_token ref="w847">der</cnx-pi_token>  
        <cnx-pi_token ref="w848">Stadt</cnx-pi_token>  
    </de>.  
  
</cnx-pi_sentence>
```

Sample Annotation

- „Lurup is a social ghetto of the hanseatic city (Hansestadt), an outskirt with single unit houses but also many appartment blocks in the west of the city (Stadt)“

```
<cnx-pi_sentence id="w826" auto="no">  
  
    Lurup ist ein sozialer Brennpunkt  
    <de deID="de226" headRef="w833">  
        <cnx-pi_token ref="w832">der</cnx-pi_token>  
        <cnx-pi_token ref="w833">Hansestadt</cnx-pi_token>  
    </de>  
    , ein Vord  
    <de deID="de227" headRef="w831">  
        <cnx-pi_token_ref text="Hansestadt" dependHead="w831" pos="N" syntax="@NH" heur="no" />  
        <cnx-pi_token_ref lemma="hanse#stadt" dependValue="mod" morpho="FEM SG GEN" id="w833" skip="no" cnx-output="correct"/>  
    </de>.  
  
</cnx-pi_sentence>
```



Sample Annotation

- „Lurup is a social ghetto of the hanseatic city (Hansestadt), an outskirt with single unit houses but also many apartment blocks in the west of the city (Stadt)“

```
<cnx-pi_sentence id="w826" auto="no">
```

Lurup ist ein sozialer Brennpunkt

```
<de deID="de226" headRef="w833">
    <cnx-pi_token ref="w832">der</cnx-pi_token>
    <cnx-pi_token ref="w833">Hansestadt</cnx-pi_token>
</de>
```

, ein Vorort mit Einzelhäusern, aber auch vielen Wohnblocks im Westen

```
<de deID="de231" headRef="w848">
    <cnx-pi_token ref="w847">der</cnx-pi_token>
    <cnx-pi_token ref="w848">Stadt</cnx-pi_token>
</de>.
```

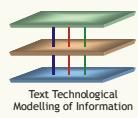
```
</cnx-pi_sentence>
```

```
<cospecLink relType="hyperonym" phorIDRef="de231"
    antecedentIDRefs="de226" />
```



- Automatic discourse entity detection based on the tagger output
- Annotation of semantic relations using the tool Serengeti
 - web based client-server-application
 - enables distributed work on same corpus by user accounts
 - low system requirements on client-side
 - annotation and corpus organisation in one system
 - interface for corpus analysis (inter-annotator reliability, etc.)
 - developed in the project A2 „Sekimo“

Annotation Tool



Serengeti Annotator :: Start - Mozilla Firefox

Datei Bearbeiten Ansicht Gehe Lesezeichen Extras Hilfe

http://localhost/cgi-bin/annotator.pl?action=main

 serengeti

Semantic Relations Annotation Tool

Serengeti Annotator V0.6.0
Last Update: 2006-11-20 by Nils Diewald

developed in the SEKIMO (A2) project, part of the distributed research group "Text Technological Modelling of Information", founded by the DFG

Please log in

Handle: annotator1

Password:

Login

Relation

cospecLink bridgingLink

RelType: ident

Comment:

Save Load Commit Print Logout

Edit Delete

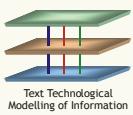
Hide NewRel showDE

serengeti V0.6.0 - 2006-11-20

Fertig



Annotation Tool



Text Technological
Modelling of Information

Select the corpus file

Serengeti
Semantic Relations Annotation Tool

Serengeti Annotator V0.6.0
Last Update: 2006-11-20 by Nils Diewald
developed in the SEKIMO (A2) project, part of the distributed research group "Text Technological Modelling of Information", founded by the DFG

zeit-15-2005	md nd	vor 0 Tagen
Luckhardt-1995a	md ag nd	vor 2 Tagen
ling-deu-003	ag nd	vor 10 Tagen
ling-deu-029		vor 38 Tagen
ling-deu-030		vor 38 Tagen
ling-deu-033		vor 41 Tagen
ling-deu-044		vor 41 Tagen
ling-deu-028		vor 54 Tagen
ling-deu-001	md ag	vor 65 Tagen

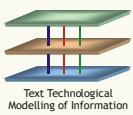
Relation: cospecLink bridgingLink
RelType: ident
Comment:

 Hide NewRel showDE
serengeti V0.6.0 - 2006-11-20

Fertig



Annotation Tool



Serengeti Annotator :: zeit-15-2005 - Mozilla Firefox

Datei Bearbeiten Ansicht Gehe Lesezeichen Extras Hilfe

http://localhost/cgi-bin/annotator.pl?action=load&sid=7x6vLPwBQUm55uXC&file=zeit-15-2005

Kinder^[193] können in armen Familien^[194] leben, aber es^[195] ist schwer, dort den vier großen Gefahren^[196] zu entgehen: einer eingeschränkten materiellen Grundversorgung^[197], verminderter Bildungschancen^[198], schlechterer Gesundheit^[199] und geringerer sozialer Teilhabe^[200].

Arme Kinder^[201] erleben eine dieser vier Lebenslagen^[203] deutlich häufiger als andere^[204], sagt die Wissenschaftlerin Gerda Holz^[207]^[206] vom Frankfurter Institut für Sozialarbeit und Sozialpädagogik^[208]. Vor einigen Jahren^[212] wurden 40 Prozent der armen Sechsjährigen^[214]^[213], aber nur 15 Prozent der nichtarmen^[215] mangelhaft ernährt, waren schlecht gekleidet oder lebten in einer kleinen Wohnung^[216]. Bis heute hat sich^[217] die Spaltung^[218] verschärft: Unterversorgung^[219] bei der Hälfte der armen^[220], aber nur jedem elften nichtarmen Kind^[221].

Die Armut^[222] wohnt in Hamburg-Lurup^[223]. Lurup^[224] ist ein sozialer Brennpunkt^[225] der Hansestadt^[226], ein Vorort^[227] mit Einzelhäusern^[228], aber auch vielen Wohnblocks^[229] im Westen^[230] der Stadt^[231]. Hier lebt Maik Celik^[232]. Er^[234] hat Schwierigkeiten^[235], sich^[236] zu konzentrieren, und geht daher auf eine Förderschule^[237]. Aufgewachsen ist er^[238] mit seinen zwei Brüdern^[239] und den Eltern^[240] in einer Zweizimmerwohnung^[241]. Seine Mutter^[242] lebt seit 19 Jahren^[243] von Sozialhilfe^[244], seit sie^[245] erstmals schwanger wurde und den Hauptschulabschluss^[246] nicht gemacht hat. Armut^[247] heißt hier - geringe Bildungschancen^[248].

Einmal im Monat^[249] geht Monika Celik^[250] einkaufen und füllt die Tiefkühltruhe^[252] auf. Durch die Unterstützung^[253] eines Kinder - und Familienzentrums^[254] wird sie^[256] mit Obst^[257] oder getragenen Hosen^[258] versorgt - an Vitaminen^[259] und Markenklamotten^[260] fehlt es^[261]. Maik^[262] also nicht. Ein Segen^[263] sind für seine Mutter^[264] auch Markenimitate^[265] aus Polen^[266]. "Neulich haben wir^[267] einen Eastpak-Rucksack^[268] für acht Euro^[269] bekommen. Den Unterschied^[270] sieht man^[271] gar nicht ", sagt sie^[272]. Trotzdem " sagen meine Mitschüler^[273] > arm < zumir^[274], weil ich^[275] keine Playstation habe ", sagt Maik^[277]. Und zu seinen Geburtstagen^[278] kommen nur noch Verwandte^[279], seit den eigenen Spielgefährten^[280] von deren Eltern^[281] verboten wurde zu kommen. Wegbrechende soziale Netze^[282] beschleunigen den sozialen Abstieg^[283].

<bridingLink id="sr76" relType="setMember" phorIDRef="de199" antecedentIDRefs="de196" />
<bridingLink id="sr77" relType="setMember" phorIDRef="de200" antecedentIDRefs="de196" />
<bridingLink id="sr78" relType="setMember" phorIDRef="de201" antecedentIDRefs="de193" />
<bridingLink id="sr79" relType="setMember" phorIDRef="de213" antecedentIDRefs="de201" />
<bridingLink id="sr80" relType="setMember" phorIDRef="de220" antecedentIDRefs="de201" />
<cospecLink id="sr81" relType="ident" phorIDRef="de222" antecedentIDRefs="de151" />
<cospecLink id="sr82" relType="ident" phorIDRef="de224" antecedentIDRefs="de223" />
<bridingLink id="sr83" relType="holonym" phorIDRef="de226" antecedentIDRefs="de224" />
<newRelation id="sr84" phorIDRef="de231" antecedentIDRefs="de226" />

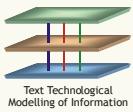
Relation
 cospecLink bridgingLink
RelType: hyperonym
Comment:

 Hide NewRel showDE

Fertig



Annotation Tool



Text Technological
Modelling of Information

Serengeti Annotator :: zeit-15-2005 - Mozilla Firefox

Datei Bearbeiten Ansicht Gehe Lesezeichen Extras Hilfe

http://localhost/cgi-bin/annotator.pl?action=load&sid=7x6vLPwBQUm55uXC&file=zeit-15-2005

Select the anaphoric element Select the antecedent

Arme Kinder erneut eine dieser vier Lebenslagen deutlich häufiger als andere, sagt die Wissenschaftlerin Gerda Hutzl vom Frankfurter Institut für Sozialarbeit und Sozialpädagogik. Vor einigen Jahren wurden 40 Prozent der armen Sechsjährigen, aber nur 15 Prozent der nichtarmen mangelhaft ernährt, waren schlecht gekleidet oder lebten in einer kleinen Wohnung. Bis heute hat sich die Spaltung verschärft: Unterversorgung bei der Hälfte der armen, aber nur jedem elften nichtarmen Kind.

Die Armut wohnet in Hamburg-Lurup ist ein sozialer Brennpunkt der Hansestadt, ein Vorort mit Einzelhäusern, aber auch vielen Wohnblocks im Westen der Stadt. Hier lebt Maik Celik. Er hat Schwierigkeiten, sich zu konzentrieren, und geht daher auf eine Förderschule. Aufgewachsen ist er mit seinen zwei Brüdern und den Eltern in einer Zweizimmerwohnung. Seine Mutter lebt seit 19 Jahren von Sozialhilfe, seit sie erstmals schwanger wurde und den Hauptschulabschluss nicht gemacht hat. Armut heißt hier - geringe Bildungschancen.

Einmal im Monat geht Monika Celik einkaufen und füllt die Tiefkühltruhe auf. Durch die Unterstützung eines Kinder- und Familienzentrums wird sie mit Obst oder getragenen Hosen versorgt - an Vitaminen und Markenklamotten fehlt es also nicht. Ein Segen sind für seine Mutter auch Markenimitate aus Polen. "Neulich haben wir einen Eastpak-Rucksack für acht Euro bekommen. Den Unterschied sieht man gar nicht", sagt sie. Trotzdem "sagen meine Mitschüler > arm < zumir", weil ich ²⁷⁵ keine Playstation habe", sagt Maik. Und zu seinen Geburtstagen kommen nur noch Verwandte, seit den eigenen Spielgefährten von deren Eltern verboten wurde zu kommen. Wegbrechende soziale Netze beschleunigen den sozialen Abstieg.

<bridingLink id="sr76" relType="setMember" phorIDRef="de199" antecedentIDRefs="de196" />
<bridingLink id="sr77" relType="setMember" phorIDRef="de200" antecedentIDRefs="de196" />
<bridingLink id="sr78" relType="setMember" phorIDRef="de201" antecedentIDRefs="de193" />
<bridingLink id="sr79" relType="setMember" phorIDRef="de213" antecedentIDRefs="de201" />
<bridingLink id="sr80" relType="setMember" phorIDRef="de220" antecedentIDRefs="de201" />
<cospecLink id="sr81" relType="ident" phorIDRef="de22" antecedentIDRefs="de151" />
<cospecLink id="sr82" relType="ident" phorIDRef="de224" antecedentIDRefs="de223" />
<bridingLink id="sr83" relType="setMember" phorIDRef="de224" antecedentIDRefs="de221" />
<newRelation id="sr84" phorIDRef="de231" antecedentIDRefs="de226" />

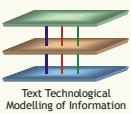
Relation
 cospecLink bridgingLink
RelType: hyperonym
Comment:

 Hide NewRel showDE
serengeti V0.6.0 - 2006-11-17

Fertig



Annotation Tool



Text Technological
Modelling of Information

Serengeti Annotator :: zeit-15-2005 - Mozilla Firefox

Datei Bearbeiten Ansicht Gehe Lesezeichen Extras Hilfe

http://localhost/cgi-bin/annotator.pl?action=load&sid=7x6vLPwBQUm55uXC&file=zeit-15-2005

Select the anaphoric element

es^[195] ist schwer, dort den vier großen Gefahren^[196] zu entgehen: Arme Kinder^[197] und soziale Ungleichheit^[198] und geringerer sozialer Teilhabe^[200].

Arme Kinder^[201] erleben eine dieser vier Lebenslagen^[203] deutlich häufiger als andere^[204], sagt die Wissenschaftlerin Gerda Huuz^[205] vom Frankfurter Institut für Sozialarbeit^[206] und Sozialpädagogik^[208]. Vor einigen Jahren^[212] wurden 40 Prozent der armen Sechsjährigen^{[214][213]}, aber nur 15 Prozent der nichtarmen^[215] mangelhaft ernährt, waren schlecht gekleidet oder lebten in einer kleinen Wohnung^[216]. Bis heute hat sich^[217] die Spaltung^[218] verschärft: Unterversorgung^[219] bei der Hälfte der armen^[220], aber nur jedem elften nichtarmen Kind^[221].

Die Armut^[222] wurmt in Hamburg-Lurup^[223]. Lurup^[224] ist ein sozialer Brennpunkt^[225] der Hansestadt^[226], ein Vorort^[227] mit Einzelhäusern^[228], aber auch vielen Wohnblocks^[229] im Westen^[230] der Stadt^[231]. Hier lebt Maik Celik^[232]. Er^[234] hat Schwierigkeiten^[235], sich^[236] zu konzentrieren, und geht daher auf eine Förderschule^[237]. Aufgewachsen ist er^[238] mit seinen zwei Brüdern^[239] und den Eltern^[240] in einer Zweizimmerwohnung^[241]. Seine Mutter^[242] lebt seit 19 Jahren^[243] von Sozialhilfe^[244], seit sie^[245] erstmals schwanger wurde und den Hauptschulabschluss^[246] nicht gemacht hat. Armut^[247] heißt hier - geringe Bildungschancen^[248].

Einmal im Monat^[249] geht Monika Celik^[250] einkaufen und füllt die Tiefkühltruhe^[252] auf. Durch die Unterstützung^[253] einer Freiwilligen^[254] wird sie^[255] Obst^[257] oder getragenen Hosen^[258] versorgt - an Vitaminen^[259] und Markenklamotten^[260] fehlt es^[261]. Maik^[262] also nicht. Ein Semester^[263] und seine Mutter^[264] zu Hause^[265] Markenimitate^[265] aus Polen^[266]. "Neulich haben wir^[267] einen Eastpak-Rucksack^[268] für acht Euro^[269] bekommen. Den

Select the antecedent

Trotzdem " sagen meine Mitschüler^[273] > arm < zumir^[274], weil ich^[275] keine Playstation habe ", sagt Maik^[277]. Und zu seinen Geburtstagen^[278] kommen nur noch Verwandte^[279], seit den eigenen Spielgefährten^[280] von deren Eltern^[281] verboten wurde zu kommen. Wegbrechende soziale Netze^[282] beschleunigen den sozialen Abstieg^[283].

Relation

cospecLink bridgingLink

RelType: hyperonym

Comment:

Hide NewRel showDE

serengeti V0.6.0 - 2006-11-17

Fertig

`<bridingLink id="sr76" relType="setMember" phorIDRef="de199" antecedentIDRefs="de196" />`
`<bridingLink id="sr77" relType="setMember" phorIDRef="de200" antecedentIDRefs="de196" />`
`<bridingLink id="sr78" relType="setMember" phorIDRef="de201" antecedentIDRefs="de193" />`
`<bridingLink id="sr79" relType="setMember" phorIDRef="de213" antecedentIDRefs="de201" />`
`<bridingLink id="sr80" relType="setMember" phorIDRef="de220" antecedentIDRefs="de201" />`
`<cospecLink id="sr81" relType="ident" phorIDRef="de22" antecedentIDRefs="de151" />`
`<cospecLink id="sr82" relType="ident" phorIDRef="de224" antecedentIDRefs="de223" />`
`<bridingLink id="sr83" relType="setMember" phorIDRef="de231" antecedentIDRefs="de201" />`
`<newRelation id="sr84" phorIDRef="de231" antecedentIDRefs="de226" />`



Training and Evaluation Set

anaphoric element

```
<?xml version="1.0" encoding="iso-8859-1"?>
<hypo filename="zeit-15-2005-chs.xml" max_de_distance="15">
  <semRel_candidate type="cospecLink" relType="hyperonym">
    <anaphora>
      <de deID="de231" antecedentID="de226"
          GN_lookup="1" GN_IlexUnitID="nOrt.1750.Stadt" GN_propernoun="nein" GN_artificial="nein" GN_wordClass="nomen" GN_sense="1"
          text="Stadt" pos="N" syntax="@NH" lemma="stadt" dependValue="mod" morpho="FEM SG GEN"
          id="w848" sentence_pos="8" position="201">der Stadt</de>
    </anaphora>
    <antecedent de_distance="15" GN_rel="" pattern="" LSA="" score="">
      <de deID="de216"
          GN_lookup="1" GN_IlexUnitID="nArtefakt.3281.Wohnung" GN_propernoun="nein" GN_artificial="nein" GN_wordClass="nomen" GN_sense="1"
          text="Wohnung" dependHead="w789" pos="N" syntax="@NH" lemma="wohnung" dependValue="advl" morpho="FEM SG DAT"
          id="w793" sentence_pos="4" position="186">einer kleinen Wohnung</de>
    </antecedent>
    [...]
    <antecedent de_distance="5" GN_rel="hyperonymy" pattern="" LSA="" score="">
      <de deID="de226" anaphora="yes"
          GN_lookup="1" GN_IlexUnitID="nOrt.1768.Hansestadt" GN_propernoun="nein" GN_artificial="nein" GN_wordClass="nomen" GN_sense="1"
          text="Hansestadt" dependHead="w831" pos="N" syntax="@NH" lemma="hanse#stadt" dependValue="mod" morpho="FEM SG GEN"
          id="w833" sentence_pos="3" position="196">der Hansestadt</de>
    </antecedent>
    [...]
  </semRel_candidate>
</hypo>
```

antecedent candidate



How to define the set of antecedent candidates?

How to select the correct antecedent?

Resolving definite description anaphora

- How to define the set of antecedent candidates?
- Definition of a *flexible* search window

	#Occurrences	MIN-distance	MAX-distance
Identity	998	1	2262
NPform=pron	688	1	19
Paraphrase	166	1	2211
Proper Name	41	1	122
Synonymy	90	2	1699
Hyperonymy	10	2	1969
Hyponymy	4	12	99
Meronymy	17	1	50
Association	102	1	1849

Definition of a flexible search window

- Anaphora-antecedent distance varies according to the NP type of the anaphoric element (e.g. Mitkov 2002 for an overview)
- Accessibility of antecedent candidates is dependent on the hierarchical structure of the text (e.g. Vieira & Poesio 2001)

Definition of a flexible search window

- Anaphora-antecedent distance varies according to the NP type of the anaphoric element (e.g. Mitkov 2002 for an overview)
- Accessibility of antecedent candidates is dependent on the hierarchical structure of the text (e.g. Vieira & Poesio 2001)
- Problem: Annotation of hierarchical discourse structure is needed
- Possible solution: Use knowledge of logical document structure, e.g. DocBook, LaTeX, HTML
- Logical document structure describes the organization of a text in terms of chapters, sections, paragraphs and the like

- Influence of the logical document structure on the choice of an antecedent
- Two hypotheses
 1. Influence on the discourse entity (*antecedent life span*)
DEs in <title>-elements are more accessible than DEs in <footnote>-elements
 2. Influence on the search window for a given anaphoric element (comparable to different window sizes according to the NP form)

- Influence of the logical document structure on the choice of an antecedent
- Two hypotheses
 1. Influence on the discourse entity (*antecedent life span*) : DEs in <title>-elements are more accessible than DEs in <footnote>-elements
 2. Influence on the search window for a given anaphoric element (comparable to different window sizes according to the NP form)
- Corpus analysis to check hypothesis
 - 3490 discourse entities (anaphora:antecedent 1,36:1)
 - 1675 anaphoric expressions
 - 1234 antecedents

Distribution of Discourse Entities

	ling-deu-003	ling-deu-010	zeit-15-2005
<article>	1,35 : 1	1,3 : 1	1,6 : 1
<sect1>	1,3 : 1	1,31 : 1	1,6 : 1
<sect2>	1,3 : 1	no elements	no elements
<para>	1,35 : 1	1,35 : 1	1,6 : 1
<title>	0,84 : 1	0,25 : 1	(0)
<subtitle>	(0:2)	no elements	1,3 : 1
<listitem>	1,5 : 1	2,72 : 1	no elements
<footnote>	2,4 : 1	no elements	no elements
<glossentry>	1,4 : 1	1,15 : 1	no elements
<glossterm>	0,66 : 1	0,6 : 1	no elements
<glossdef>	1,55 : 1	1,2 : 1	no elements

Distribution of Discourse Entities

	ling-deu-003	ling-deu-010	zeit-15-2005
<article>	1,35 : 1	1,3 : 1	1,6 : 1
<sect1>	1,3 : 1	1,31 : 1	1,6 : 1
<sect2>	1,3 : 1	no elements	no elements
<para>	1,35 : 1	1,35 : 1	1,6 : 1
<title>	0,84 : 1	0,25 : 1	(0)
<subtitle>	(0:2)	no elements	1,3 : 1
<listitem>	1,5 : 1	2,72 : 1	no elements
<footnote>	2,4 : 1	no elements	no elements
<glossentry>	1,4 : 1	1,15 : 1	no elements
<glossterm>	0,66 : 1	0,6 : 1	no elements
<glossdef>	1,55 : 1	1,2 : 1	no elements

Interpretation of results

- The relationship of anaphoric and antecedent DEs is quite stable throughout a document (sect1, sect2, para)
- There are elements that tend to contain more likely antecedent elements (title, subtitle, glossterm introduce the text's topics)
- There are elements that tend to contain more likely anaphoric elements (footnote, listitem)

Interpretation of results

- A closer look at footnotes and listitems
 - For 60% of the antecedents within a listitem element, the anaphoric element is within the same element. For 66% the distance between antecedent and anaphora is smaller than 10 DEs.
 - All antecedents within a footnote element have their anaphora within the same element, for 56% of the antecedents, the anaphoric element is only one or two DEs away (often pronouns), less than 1% are more than 10 DEs away
- The parent element of a DE serves as a clue for the antecedent life span.

How to integrate the document structure? → Markup Unification

Combination of resources

Logical document structure vs. Semantic relations

```
layer doc:<para>... im Westen der Stad ...</para>
```

```
layer de :<analysis>... im Westen <de>der Stadt</de>...<analysis>
```

#char	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
	i	m	W	e	s	t	e	n	d	e	r		S	t	a	d	t		
<para>	i	m	W	e	s	t	e	n	d	e	r		S	t	a	d	t	</para>	
<analysis>	...											<de>d	e	r		S	t	a	t

```
node( doc, 0, 18, [1], element(para) ).  

node( analysis, 0, 18, [1], element(analysis) ).  

node( analysis, 10, 18, [1,1], element(de) ).
```

Markup Unification:

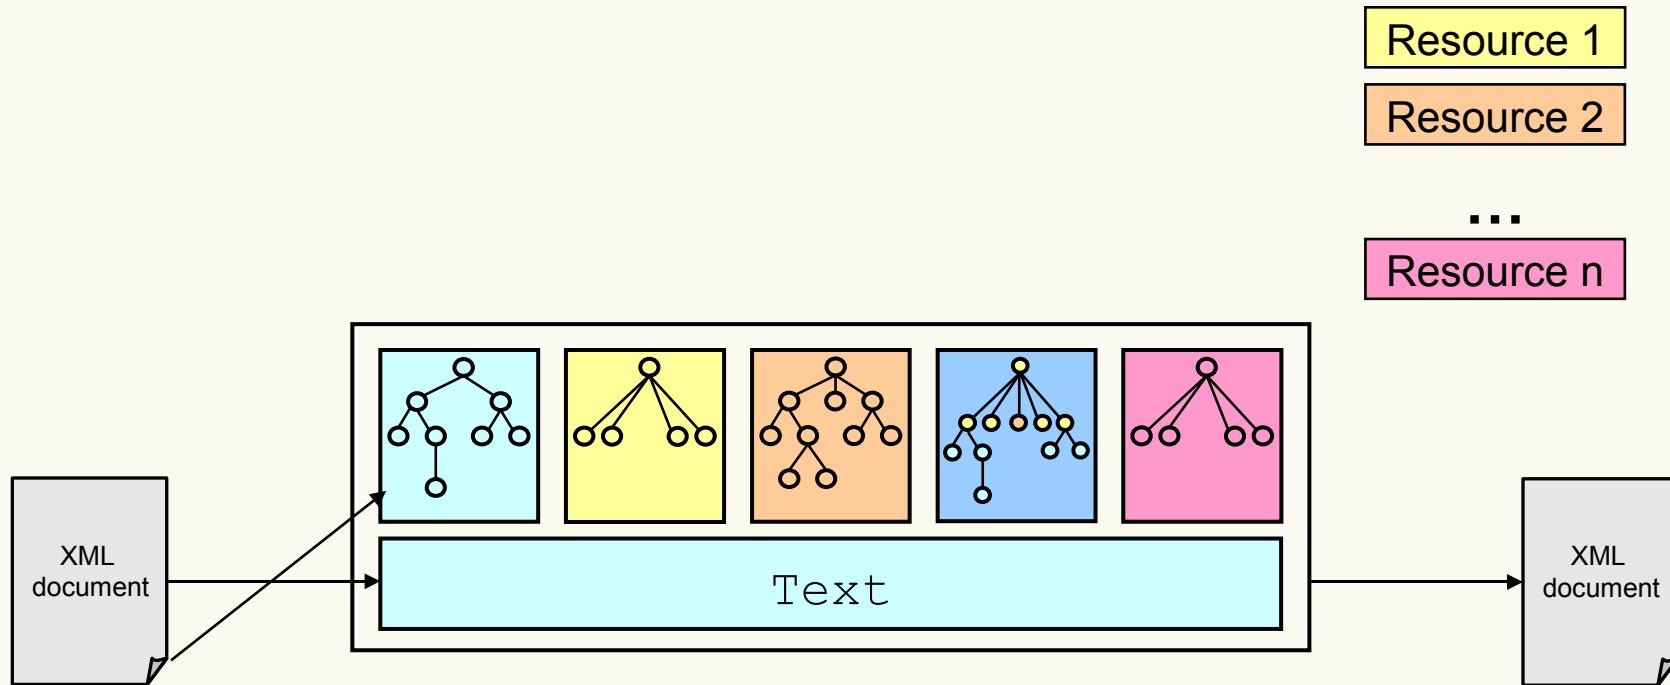
```
<analysis><para>... im Westen </de>der Stadt</de>...</para></an...>
```



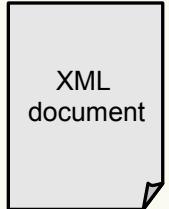
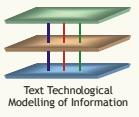
Benefit of Markup Unification

- Add new informationen from heterogeneous resources
- Resources can be developed independently
- Flexible use of resources: No conversion necessary
- Extraction of relevant parts: Application of resources only for relevant text parts
- Reuse of existing resources

Integration of linguistic resources



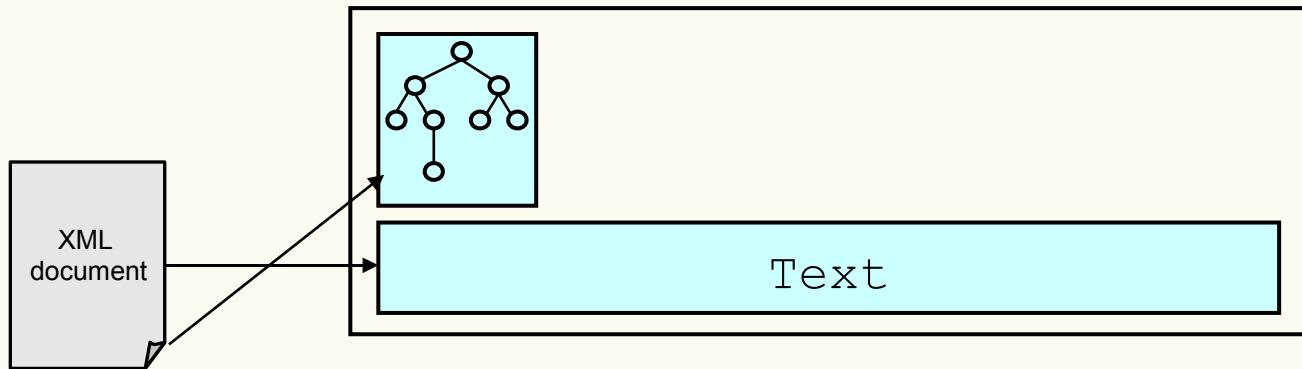
Integration of linguistic resources



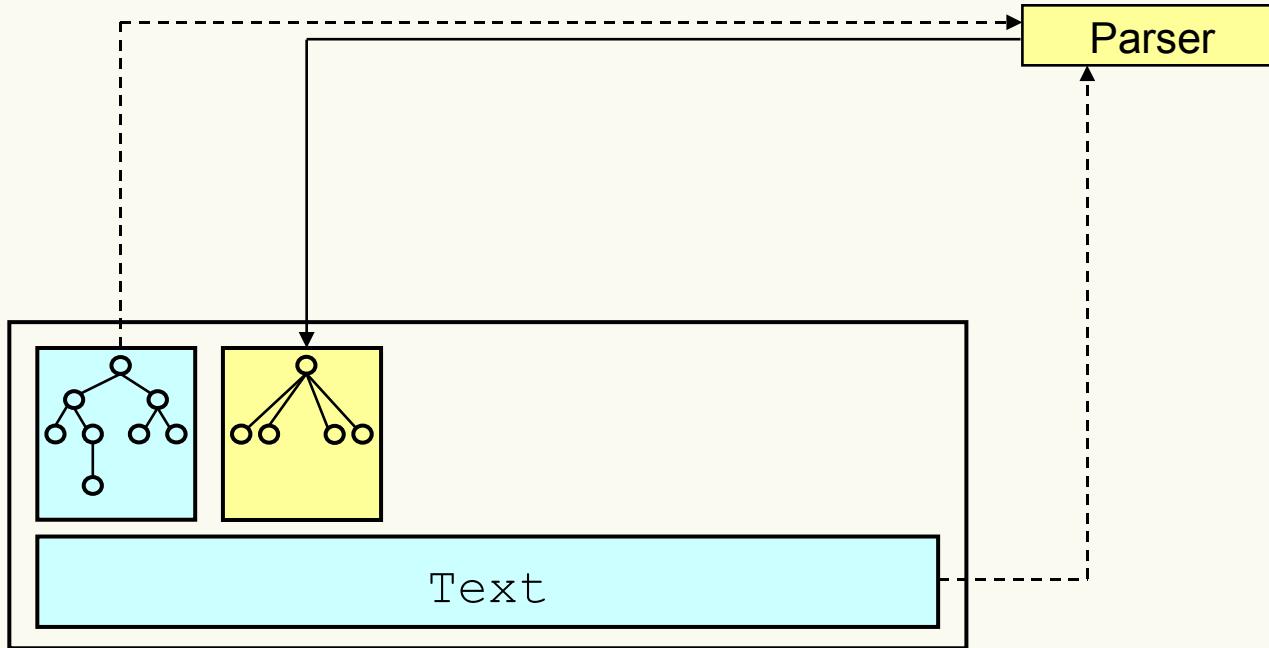
XML
document



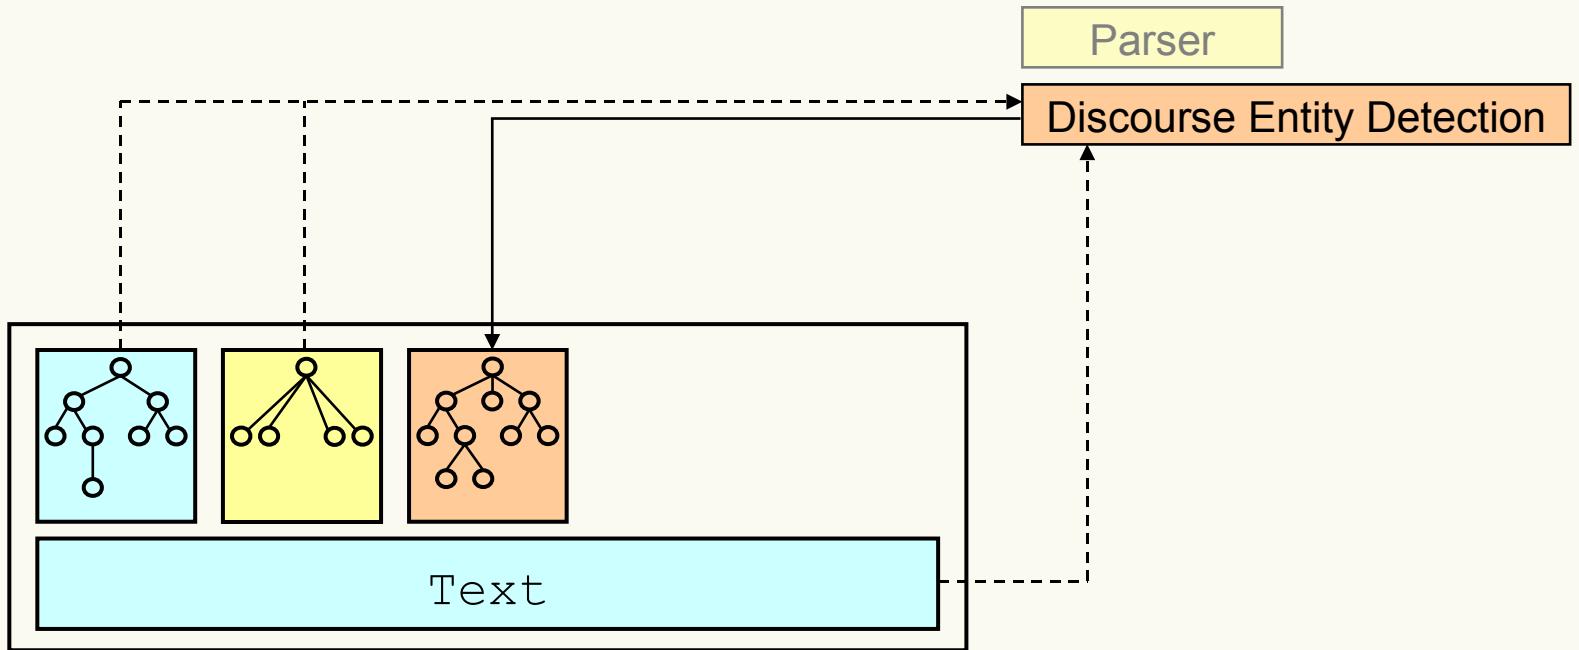
Integration of linguistic resources



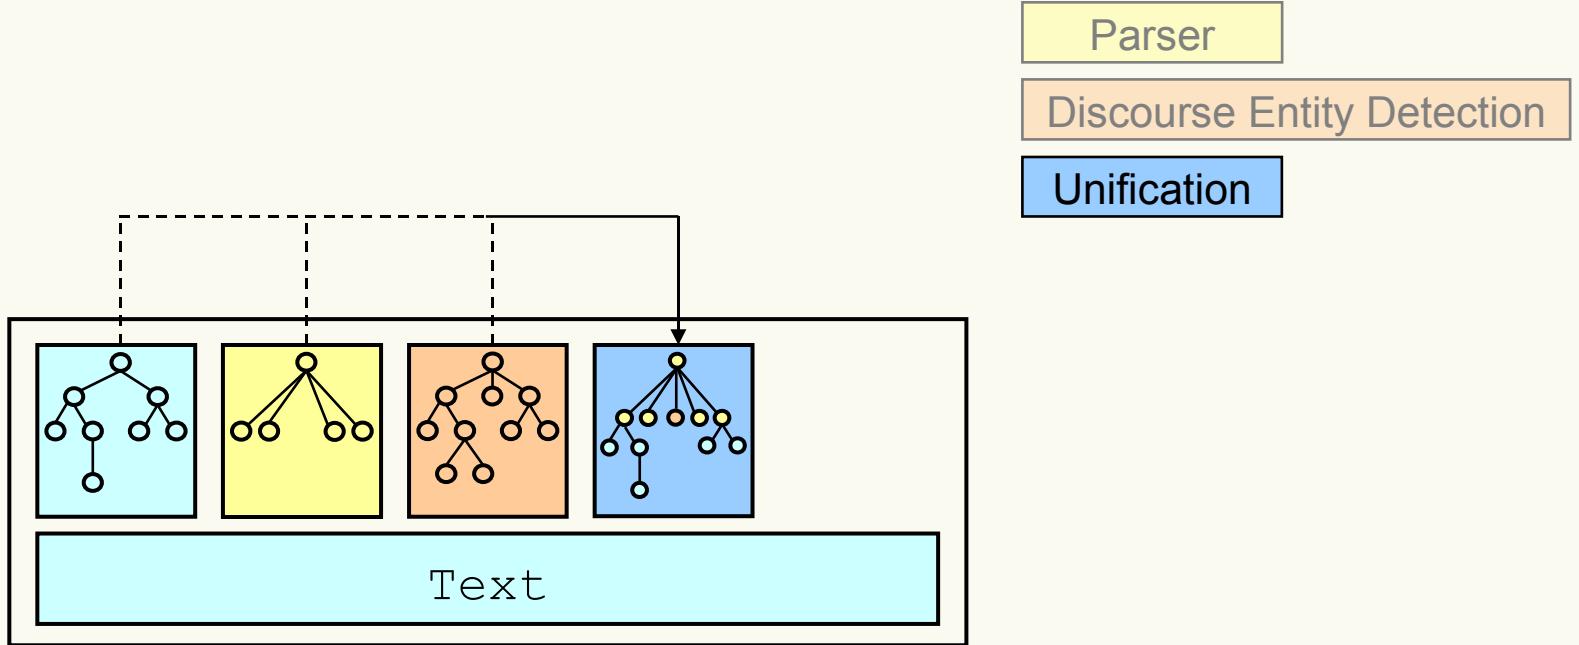
Integration of linguistic resources



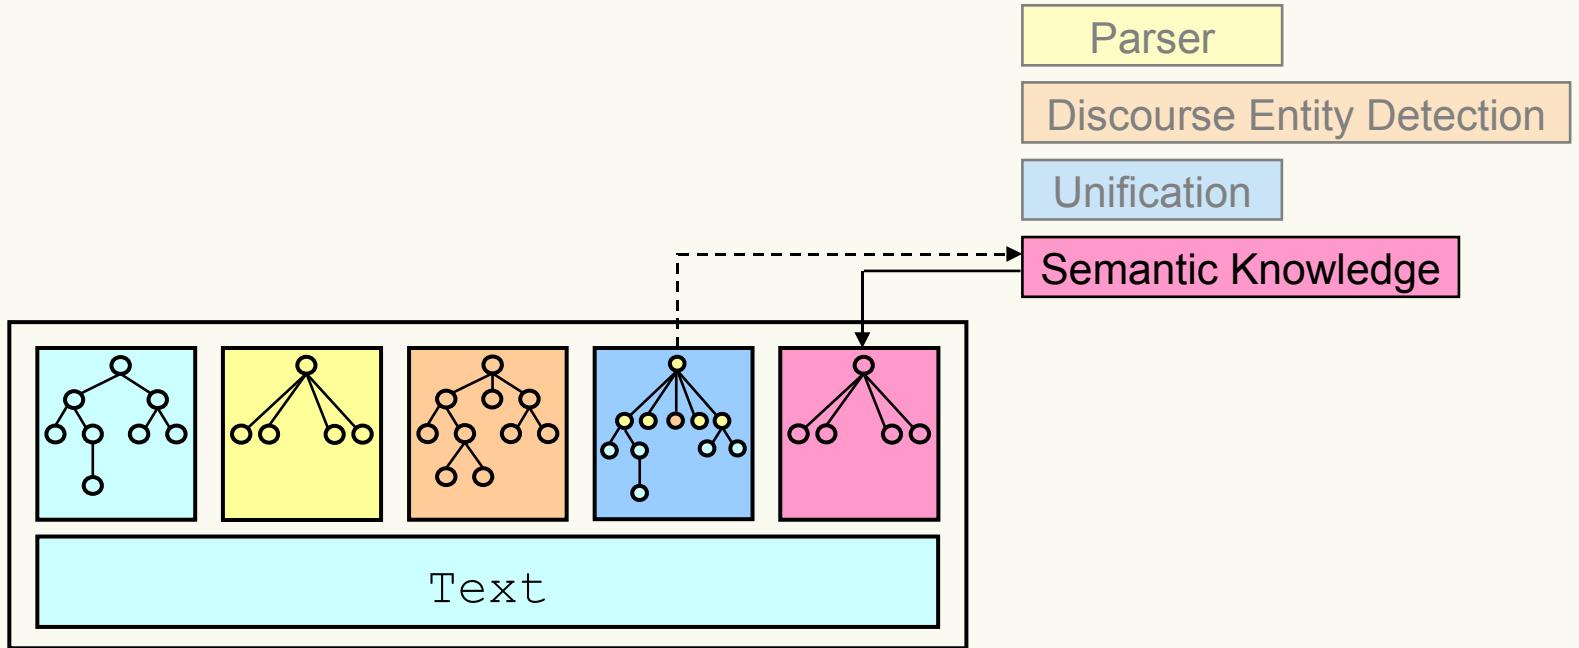
Integration of linguistic resources



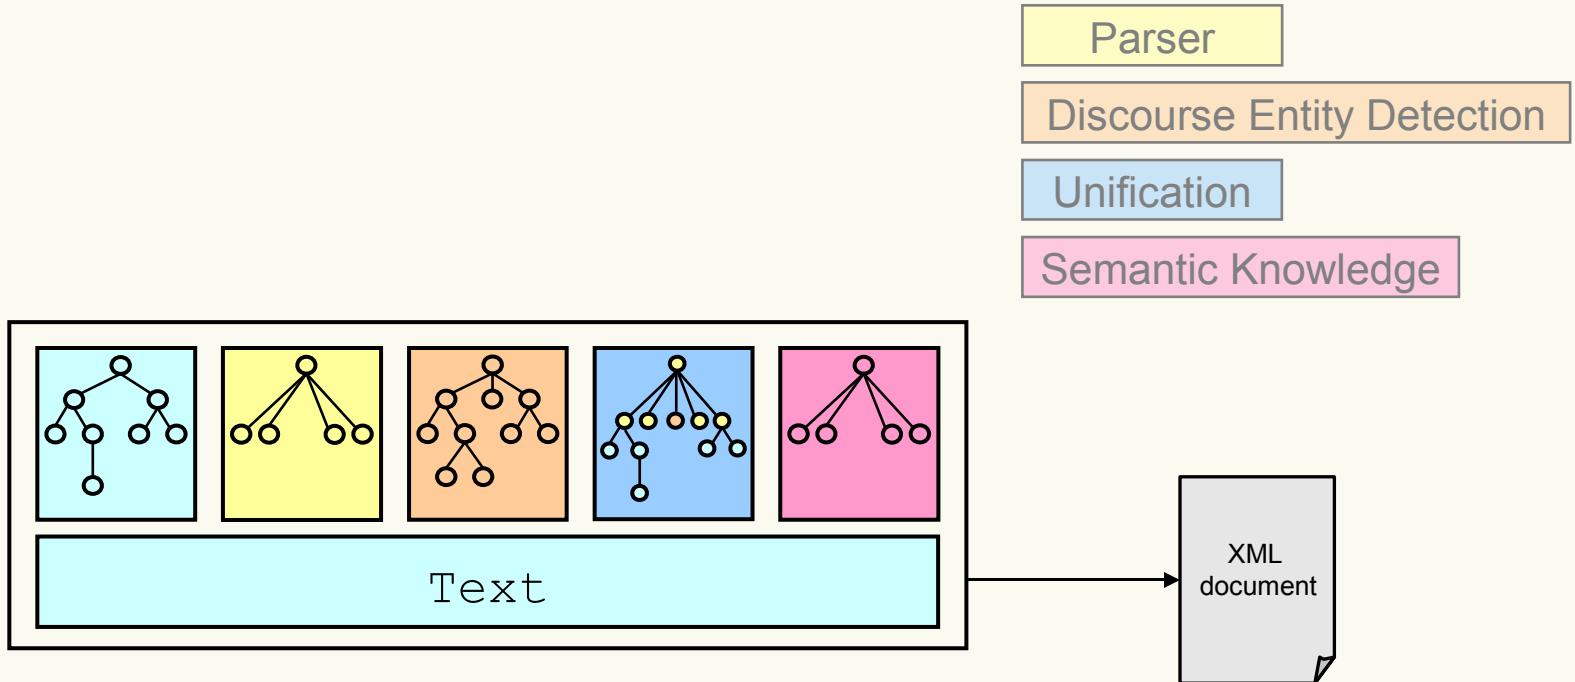
Integration of linguistic resources



Integration of linguistic resources



Integration of linguistic resources

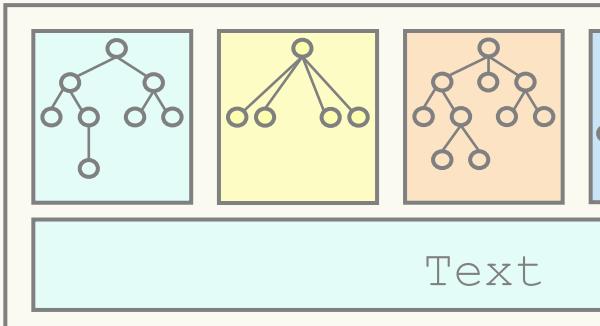


Integration of linguistic resources

Parser

Discourse Entity Detection

Unification



Semantic Knowledge

*Combination of GermaNet,
LSA, Hearst Pattern*

(in cooperation with the C2 project,
Tübingen/Osnabrück)



Conclusion and outlook

- Extend the corpus analysis
- Translate corpus findings into suitable features and XML attributes
- Translate XML annotations into feature vectors
- Train decision trees to resolve definite description anaphora automatically

Thank you!

Daniela Goecke : daniela.goecke@uni-bielefeld.de

