

Annotation Guidelines for German Non-standard Varieties

Marc Reznicek

empirikom

4. Arbeitstagung

8.11.2012, Aachen

Overview

Motivation & Goals

- existing resources

Data & Annotation

- test corpus
- annotation

Chat

- DCC-Chat-Protocols (Conversion, Processing)

Next steps

Motivation: linguistic corpus annotation

last 20 years:

Large effort for linguistic annotations on corpora

- large annotation projects (TiGer, TüBa)
- shared tasks (CONLL, MUC, B-CUBED, ACE, ARE, CEAF)
- SFB: Information structure

resources

- tag sets
- annotation schemes
- guidelines
- training sets

→ designed for linguistic standard variety

tools

- taggers
- parsers

→ trained mostly on newspaper text

Motivation: domain adaption in NLP

In NLP domain adaption fastly growing

- POS:
 - e.g.. Miller et al.(2006), Kübler & Baucom (2011), Hinrichs & Zastrow (2012), Rehbein et al. 2012, Rush et. al. (2012)
- syntactic analysis
 - SANCL 2012 shared task
 - e.g. Dredze et al. (07), Yoshida et al.(2007)
- coreference resolution
 - e.g.Yang et al. (2012), Uryupina, Poesio (2012)

Motivation: beyond robustness

- In NLP domain adaption is mostly seen as a matter of ***robustness*** (e.g. Balsa & Lopes 2000, Carreras & Marquez 2005)
 - **assumption:**
 - there is a **right way** to annotate the data
- **task:**
- reach at the right annotation under the condition of noisy data

! This assumption only holds for prototypical data!

Motivation:

Weaknesses of existing resources

- categories of many phenomena in non-standard varieties are not defined
- e.g. part-of-speech in **learner language**

Studenten	sind	in	der	Uni	viel	praxisorientiert	.
NN	VAFIN	APPR	ART	NN	PIS	???	

Studenten	sind	in	der	Uni	sehr	praxisorientiert	.
NN	VAFIN	APPR	ART	NN	ADV	ADJD	

Students are very practically oriented in university.

Studenten	werden	in	der	Uni	stark	praxisorientiert	.
NN	VAFIN	APPR	ART	NN	ADJD	VVPP	

Students are quite often practically oriented in university [by someone].

Motivation:

Weaknesses of existing resources

- categories of many phenomena in non-standard varieties are not defined
 - e.g. part-of-speech in **historical data**

nu	pin	ich	großleich	erhöcht	vön	meīem	chind	vber	alles	himlisch	her	
nun	bin	ich	sehr	erhöht	von	meinem	kind	über	alles	himmlische	heer	
ADV	VAFIN	PPER	ADV	ADJD	APPR	PPOSAT	NN	APPR	PIS	ADJA	ADJA	
nun	bin	ich	sehr	erhöht	von	worden	meinem	kind	über	alles	himmlische	heer
ADV	VAFIN	PPER	ADV	VVPP	APPR	PPOSAT	NN	APPR	PIS	ADJA	ADJA	

Motivation: evaluation of annotation schemes

- domain adaption in a linguistic sense:
extention of descriptive inventory of non canonical structures
- **assumption:**
 - there is a **no right way** to annotate non-canonical data with grammars that describe only canonical data

→ **task:**

- evaluate and extend annotation schemes and guidelines

Motivation: gold standard data

- **extended descriptions** of structures from more domains allows:
 - building a **gold standard** annotated data resource
 - for **evaluation** of standard tools on non-standard varieties
 - for **training**

Motivation: gold standard data

request for IBC test set in NLP

Punctuation and capitalization are often inconsistent, making it difficult to rely on features that can be predictive for newswire [the training data]. There is often a lexical shift due to increased use of slang, technical jargon or other phenomena. There is an increase in ungrammatical sentences.

...

Unfortunately, there are currently few high quality test sets available for evaluating parsers on such noisy web texts, forcing researchers to keep evaluating on a now 20 year old test (WSJ Section 23).

(SANCL2012 shared task motivation)

Motivation: Clarin-D curation project



Clarin F-AG 7 - Curation project (KP2):
Linguistic annotation of nonstandard
varieties — guidelines and "best practices"

Motivation: Goals

data:

- test corpus of German non-standard varieties

annotations:

- gold standard
 - dependencies
 - coreference
 - named entities


guidelines:

- evaluation and extension of existing guidelines
- "best practices" for lay people


tools:

- evaluation of automatic tools for chosen annotations

- description of similarities and differences



Motivation: learner language




Motivation: learner language

tok	TH1a	TH1b
Meine	Meine	Meine
meinung	Meinung	Meinung
ist	ist	ist
,	,	,
dass	dass	das
		das
examen	Examen	Examen
soll		soll
kommen		
am	am	am
Ende	Ende	Ende
des	des	des
Semester	Semesters	Semesters
	kommen	kommen
	soll	

- word order
- argument selection

und	und
bereiten	
die	die
Studenten	Studenten
vor	auf
die	die
wirkliche	wirkliche
Welt	Welt
vorbereiten	

Motivation: historical language




Motivation: historical language

- sentence segmentation

*AIn höcher lerer hiesz anshelm **der pat vnser frawn lang wainnd vnd vastuñd daz se im czu erchennen geb wie vnser her gemartert wer vnd do er also nach seiner gewonhait vmb dy selbñ sache eines males vnser frawn pat mit gancžm ernſt do erschain im vnser fraw vnd sprach also***

der	pat	vnsr	frawn	lang	wainnnd	vnd	vastunnd	daz
der	bat	unsere	Frau	lang	weinend	und	fastend	dass
REL	VVFIN	PPOSAT	NN	ADV	ADJD	KON	ADJD	KOUS
PIS	VVFIN	PPOSAT	NN	ADV	ADJD	KON	ADJD	KOUS

Motivation: literary prose



Motivation: literary prose

- **complex insertions**
- **direct speech**


*"Ja", sagte der Mann, "aber ich bin nicht mehr verpflichtet,
Sie jetzt zu verhören" - wieder das Murren, diesmal aber
**mißverständlich, denn der Mann fuhr, indem er den
Leuten mit der Hand abwinkte, fort, - "ich will es jedoch
ausnahmsweise heute noch tun. Eine solche Verspätung
darf sich aber nicht mehr wiederholen. Und nun treten Sie
vor!"***

Motivation: literary prose

- complex insertions
- direct speech

"Ja", sagte **der Mann**, "aber ich bin nicht mehr verpflichtet, Sie jetzt zu verhören" - **wieder das Murren, diesmal aber mißverständlich, denn der Mann fuhr, indem er den Leuten mit der Hand abwinkte, fort**, - "ich will es jedoch ausnahmsweise heute noch tun. Eine solche Verspätung darf sich aber nicht mehr wiederholen. Und nun treten Sie vor!"

Motivation: spoken dialogues



Motivation :: spoken dialogues

- filled pauses
- interruptions
- corrections
- repetitions


genau **du gehst jetzt/** du gehst jetzt genau **am/** am
Motorrad da unten **äh oben** lang und vorbei geradeaus
du machst **n** du machst **so/** wieder so **nen** Knick

Motivation :: spoken dialogues

- collaborative contructions


		instructor	instructee
da	ADV		
gehst	VVFIN		
du	PPER		
rechts	ADV		
ab	PTKVZ		
		unter APPR	
		oder KON	
		über APPR	
		dem ART PIS	
		unter APPR	
		dem ART PIS	
		unter APPR	
		dem ART	
		Bild NN	

Motivation : chat protocols



Motivation : chat protocols

- chat data especially challenging
 - hybrid variety (oral – written / close –distant)
(e.g. Lenke & Schmitz 1995, Beißwenger 2001, Storrer 2001)
- shares deviations from standard with most other chosen varieties
- chat-specific phenomena



Motivation :

chat protocols

■ tokenization

Hübsche1017_(w): Ja ich sage dir das mein Mann **zu hause** wartet.
Du ich gehe jetzt. War nett mit dir. Wie **wärs** mit nächsten
Dienstag so um **halb11** oder 11 Uhr?

Single9384_(w): ich verstehe mich mit jeden mann

Speedy24: Bist du Arbeiten?

Single9384_(w): das meinte ich

AufderSuche2481_(m): ja ich **probiers**

Süsser1201_(m): ja, wirklich?

AufderSuche2481_(m): fidne dich auch nett

Motivation : chat protocols

▪ capitalization

Hübsche1017_(w): Ja ich sage dir das mein Mann zu **hause** wartet.
Du ich gehe jetzt. War nett mit dir. Wie wärs mit nächsten
Dienstag so um halb11 oder 11 Uhr?

Single9384_(w): **ich** verstehe mich mit jeden **mann**

Speedy24: Bist du **Arbeiten**?

Single9384_(w): **das** meinte ich

AufderSuche2481_(m): **ja** ich probiers

Süsser1201_(m): **ja**, wirklich?

AufderSuche2481_(m): **fidne** dich auch nett

Motivation : chat protocols

▪ punctuation

Hübsche1017_(w): Ja [,] ich sage dir[,] das mein Mann zu hause wartet. Du [,] ich gehe jetzt. War nett mit dir. Wie wärs mit nächsten Dienstag so um halb11 oder 11 Uhr?

Single9384_(w): **ich** verstehe mich mit jeden **mann**

Speedy24: Bist du **Arbeiten**?

Single9384_(w): **das** meinte ich

AufderSuche2481_(m): **ja** [,] ich probiers

Süsser1201_(m): **ja**, wirklich?

AufderSuche2481_(m): **fidne** dich auch nett

Motivation : chat protocols

▪ orthography

Hübsche1017_(w): Ja ich sage dir **das** mein Mann zu hause wartet.
Du ich gehe jetzt. War nett mit dir. Wie wärs mit nächsten
Dienstag so um halb11 oder 11 Uhr?

Single9384_(w): ich verstehe mich mit jeden mann

Speedy24: Bist du Arbeiten?

Single9384_(w): das meinte ich

AufderSuche2481_(m): ja ich probiers

Süsser1201_(m): ja, wirklich?

AufderSuche2481_(m): **fidne** dich auch nett

Motivation : chat protocols

▪ morpho-syntax

Hübsche1017_(w): Ja ich sage dir das mein Mann zu hause wartet.
Du ich gehe jetzt. War nett mit dir. Wie wärs **mit nächsten
Dienstag** so um halb11 oder 11 Uhr?

Single9384_(w): ich verstehe mich **mit jeden mann**

Speedy24: Bist du Arbeiten?

Single9384_(w): das meinte ich

AufderSuche2481_(m): ja ich probiers

Süsser1201_(m): ja, wirklich?

AufderSuche2481_(m): fidne dich auch nett

Motivation : chat protocols

- **oral argument drop, vocatives**

Hübsche1017_(w): Ja ich sage dir das mein Mann zu hause wartet.

Du ich gehe jetzt. **War nett mit dir**. Wie wärs mit nächsten Dienstag so um halb11 oder 11 Uhr?

Single9384_(w): ich verstehe mich mit jeden mann

Speedy24: **Bist du Arbeiten?**

Single9384_(w): das meinte ich

AufderSuche2481_(m): ja ich probiers

Süsser1201_(m): **ja, wirklich?**

AufderSuche2481_(m): **fidne dich auch nett**

Motivation : chat protocols

- **threading** (difficult for coreference)

Hübsche1017_(w): Ja ich sage dir das mein Mann zu hause wartet.
Du ich gehe jetzt. War nett mit dir. Wie wärs mit nächsten
Dienstag so um halb11 oder 11 Uhr?

Single9384_(w): ich verstehe mich mit jeden mann

Speedy24: Bist **du** Arbeiten?

Single9384_(w): **das** meinte ich

AufderSuche2481_(m): ja ich probiers

Süsser1201_(m): ja, wirklich?

AufderSuche2481_(m): fidne **dich** auch nett

Motivation: chat protocols

- verbless sentences
- inflectives
- asterisk expressions
- emoticons

alles so wie immer :-)

Ich habe kürzlich gegen Riff, 6 halbe Liter Flens verloren, Thor, UND eine Überraschung.

:((


Roten Faden wieder in die Hand nehm

ONKELZ !!!

Ruffputtbles betritt den Raum.

tach ruff


Process: path to corpus and guidelines



correction of Malt (Nivre 2006) parses (on normalization)

- 4) description of deviation between norm. and orig. data
- 5) proposal for changes in annotation schemes
- 6) evaluation of tools

Annotations tool chain



Annotations chat xml

```
<message id="22" type="utterance" creator="süpi" color="#D29552">
  <messageHead>
    <nickname>süpi</nickname>
  </messageHead>
  <messageBody>Hi Jungs und Mädels</messageBody>
</message>
```

```
<message id="23" type="utterance" creator="Thor..." color="#D62929">
  <messageHead>
    <nickname>Thor...</nickname>
  </messageHead>
  <messageBody>
    <address addressee="Emon">Emon</address> wir sehen uns wenn du mich bei den
    new classics anfeuerst <asteriskExpression>*<acronym>gg</acronym>*
    </asteriskExpression>
  </messageBody>
</message>
```

```
<message id="24" type="utterance" creator="quaki" color="#D62994">
  <messageHead>
    <nickname>quaki</nickname>
  </messageHead>
  <messageBody>und enten??</messageBody>
</message>
```



Annotations stand-off

	A	B	C	D	AL	AM	AN	AO	AP	AQ	AR	AS	HH	HI
	tok	pos	lemma	S	Thor...:tok	Thor...:acronym	Thor...:asteriskExpression	Thor...:address	Thor...:NickName	Thor...:Color	Thor...:Type	Thor...:ID	tok:dep[tok:func]	
1	tok	pos	lemma	S	Thor...:tok	Thor...:acronym	Thor...:asteriskExpression	Thor...:address	Thor...:NickName	Thor...:Color	Thor...:Type	Thor...:ID	tok:dep[tok:func]	
97	Hi	ADJA	[unknown]	utterance									97	ATTR
98	Jungs	NN	Jungs										98	
99	und	KON	und										99	KON
100	Mädchen	NN	Mädchen										100	CJ
101	Emon	NE	[unknown]		Emon								101	GMOD
102	wir	PPER	wir		wir								102	SUBJ
103	sehen	VVFIN	sehen		sehen								103	
104	uns	PPER	wir		uns								104	OBJA
105	wenn	KOUS	wenn		wenn								105	KONJ
106	du	PPER	du		du								106	SUBJ
107	mich	PRF	ich		mich								107	OBJA
108	bei	APPR	bei		bei								108	PP
109	den	ART	d		den								109	DET
110	hew	NE	[unknown]		hew								110	ATTR
111	classics	NE	Classics		classics								111	
112	anfeuerst	ADJA	[unknown]		anfeuerst								112	NEB
113	*	XY	*		utterance	*gg*	gg	*gg*	addressee:Emon	#D62929	Thor...	utterance	23	CJ
114	gg	VVIMP	[unknown]											
115	*	XY	*											
116	und	KON	und											
117	enten	VVFIN	[unknown]											
118	?	\$..	?											
119	?	\$..	?											

Annotation dependencies: Arborator (soon brat)

■ Malt parses

□ 23: *Emon wir sehen uns wenn du mich bei den hew classics anfeuerst * gg **




Annotation

dependencies: Arborator (soon brat)

■ corrected parses

□ 23: Emon wir sehen uns wenn du mich bei den hew classics anfeuerst * gg *




Annotation

extension of POS

- proposal for enlargement of STTS für chat data

Michael Beißwenger (STTS-Workshop 2012)



Data


Path: chat > 2221007_unicum_21-02-2003_2

Emon wir sehen uns wenn du mich bei den hew classics anfeuerst * gg *

NE PPER WFIN PPER KOUS PPER PRF APPR ART NE NE ADJA XY WIMP XY

[unknown] wir sehen wir wenn du ich bei d [unknown] Classics [unknown] * [unknown] *

- chat (grid)
- chat (dependencies)

 Thor (grid)

Select Displayed Annotation Levels ▾

Color	#D62929
ID	23,000000
NickName	Thor...
Type	utterance
acronym	
address	Emon
asteriskExpression	*gg*
tok	Emon wir sehen uns wenn du mich bei den hew classics anfeuerst * gg *
tok	Emon wir sehen uns wenn du mich bei den hew classics anfeuerst * gg *

Malt parses

Search Form

AnnisQL: S="utterance"

Show Result Query Builder History


Result: 413

Visualization: ANNIS2 (soon ANNIS3)



Path: chat > 2221007_unicum_21-02-2003_2

Emon wir sehen uns wenn du mich bei den hew classics anfeuerst * gg *
NE PPER VVFIN PPER KOUS PPER APPR ART NE NE VVFIN XY ITJ XY
[unknown] wir sehen wir wenn du ich bei d [unknown] Classics [unknown] * [unknown] *
 chat (grid)
 chat (dependencies)



corrected parses

Thor (grid)

Select Displayed Annotation Levels ▾

Color	#D62929
ID	23,000000
NickName	Thor...
Type	utterance
acronym	
address	Emon
asteriskExpression	*gg*
tok	Emon wir sehen uns wenn du mich bei den hew classics anfeuerst * gg *
tok	Emon wir sehen uns wenn du mich bei den hew classics anfeuerst * gg *

empirikom

Next steps

- Coreference
- Named entities

Thanks to
Stefanie Dipper
Anke Lüdeling
Michael Beißwenger

Data:

Test corpus

Korpus	Textsorte	Norm	POS	NE	Syntax		Koref
					DepRel	GramFkt	
TüBa-D/Z Link	Zeitungstexte	n.a.	STTS	<i>organisation person location, geo-political entity</i>	TüBa	TüBa	Anaph.& Koref. nom. & pron. Antezendenz
DDB – Deutsche Diachrone Baumbank Link	Historische Texte Fnhd.	ja	STTS	nein	TIGER	DDB-Liste	nein
Anselm							
Bematac	Gesprochene Maptasks	nein	STTS	nein	nein	nein	nein
Dortmund Chat-Korpus Link	Chat-Protokolle	nein	nein	nein	nein	nein	nein
Falko Link	Lerner-aufsätze	mehrere Ziel-hypothesen	STTS	nein	ja	ja	nein
Franz Kafka: Der Prozeß	literarische Prosa	nein	nein	nein	nein	nein	nein