

RÄUME - GRENZEN - ÜBERGÄNGE:

5. Kongress der Internationalen Gesellschaft für Dialektologie des Deutschen

10. - 12. September 2015

Universität Luxemburg



GRAMMATISCHE ANNOTATION HISTORISCHER TEXTE – EIN TAGSET FÜR DAS MITTELNIEDERDEUTSCHE

- ReN-Projekt
 - Rahmendaten
 - Korpusdesign und -erstellung
- Besonderheiten des Mittelniederdeutschen
- Historisches-Niederdeutsch-Tagset (HiNTS)
 - Basis
 - PoS-Tagging
 - Flexionsmorphologisches Tagging
- Resümee

Rahmendaten

Referenzkorpus Mittelniederdeutsch/ Niederrheinisch (1200-1650)

- Teil des ‚Korpus historischer Texte des Deutschen‘, gemeinsam mit den Referenzkorpora
 - *Altdeutsch*
 - *Mittelhochdeutsch*
 - *Frühneuhochdeutsch*
- Basis sind Handschriften, Drucke und Inschriften

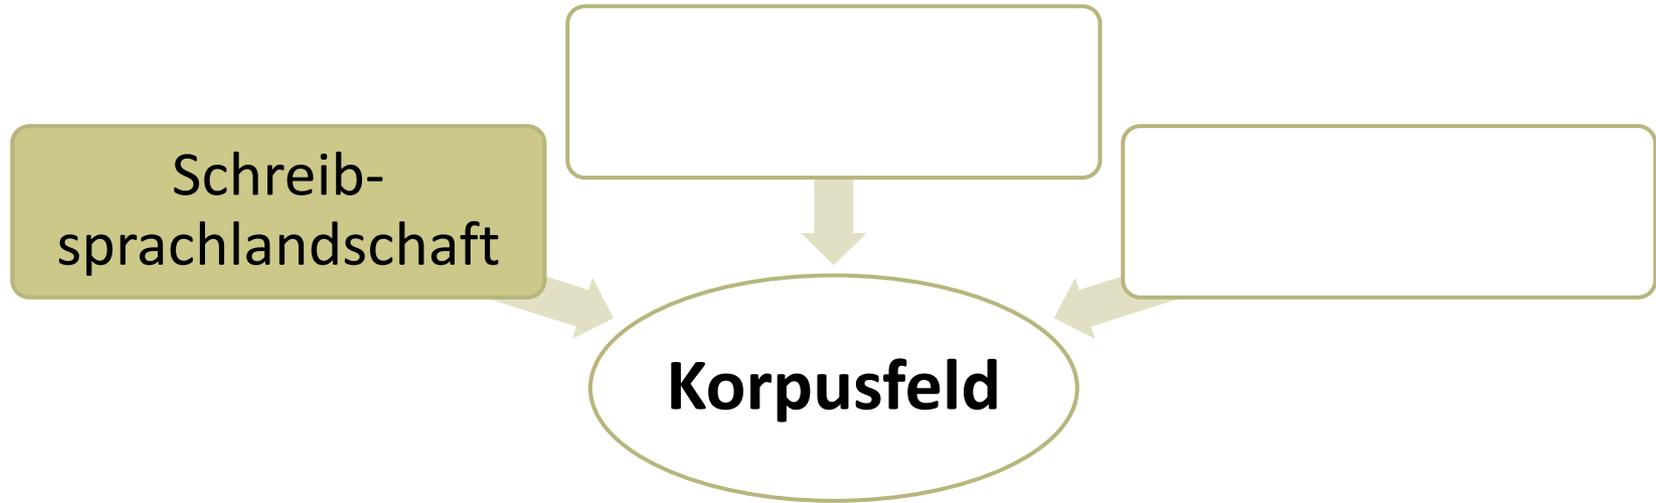
Ziel des Projekts

- digitale Veröffentlichung diplomatisch transkribierter, lemmatisierter und grammatisch annotierter Texte

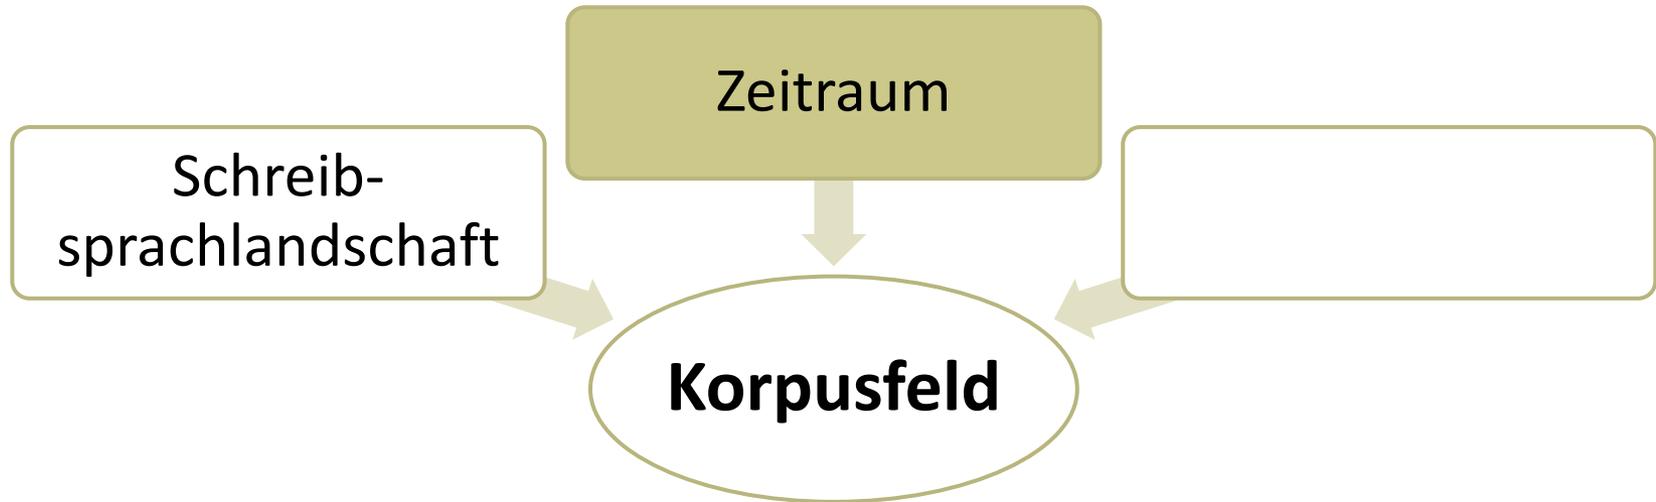
Nutzen des Referenzkorpus

- verschafft Einblicke in die Sprach- und Textkultur des niederdeutschen und niederrheinischen Raums
- ermöglicht sprachwissenschaftliche Analysen

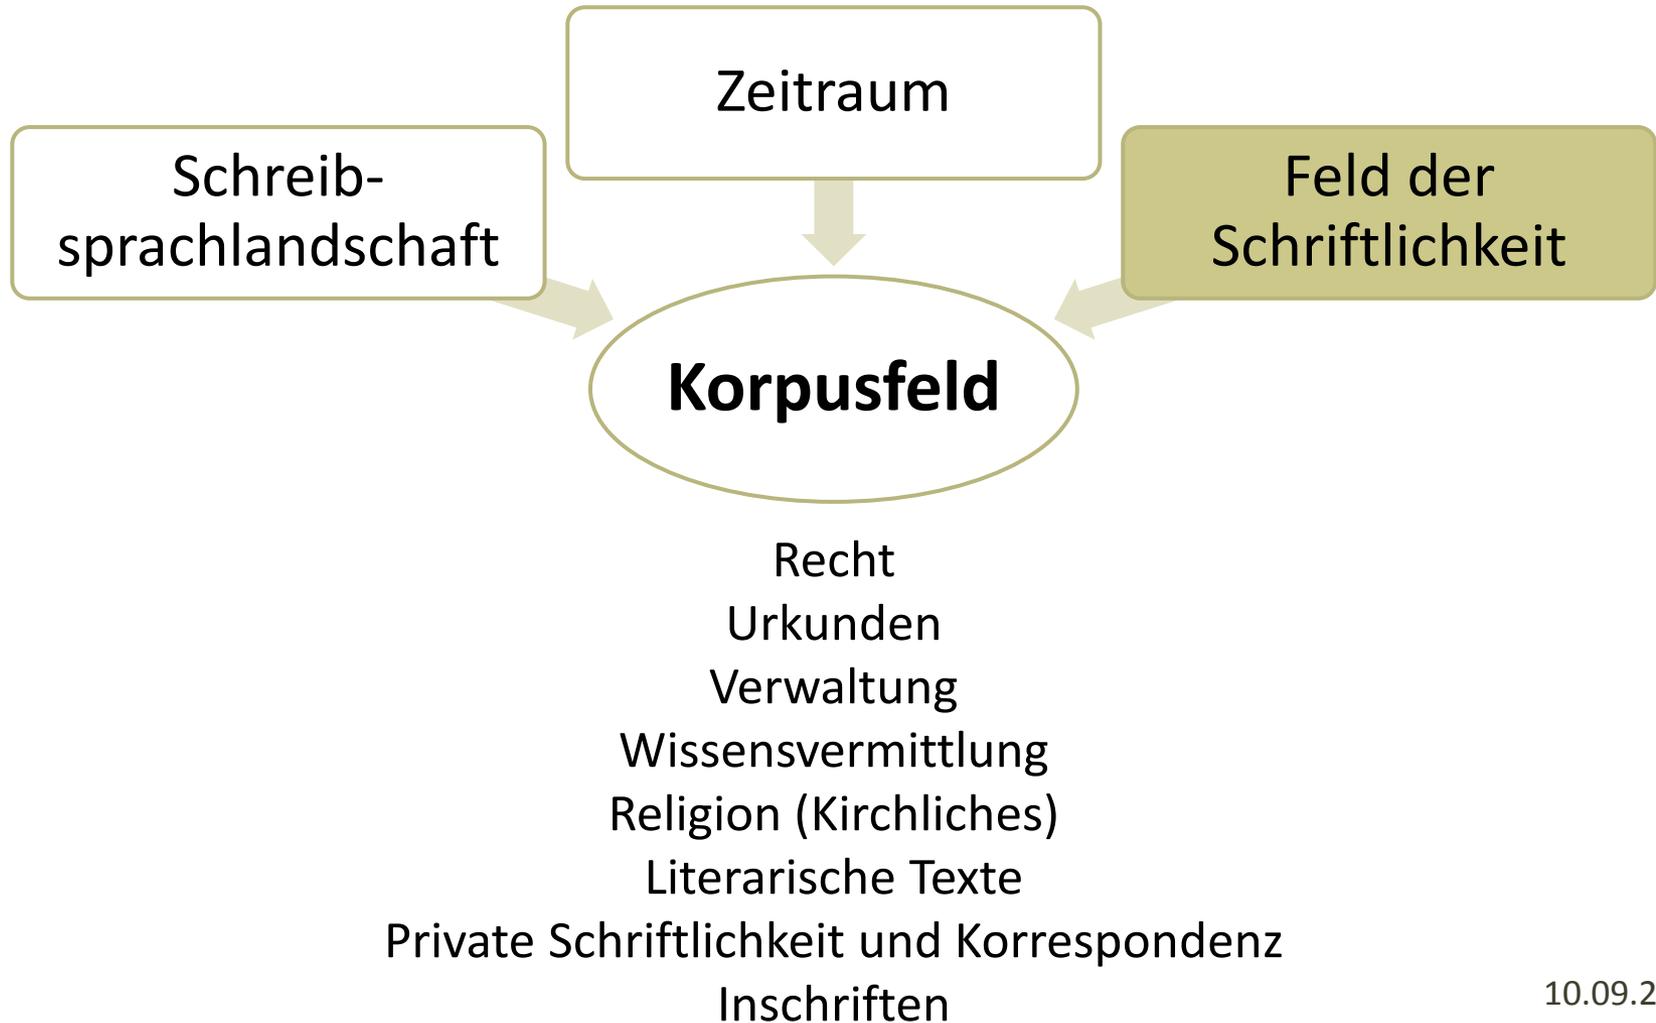
Korpusdesign



- | Standort Hamburg | Standort Münster |
|-------------------------|-------------------------|
| Nordniedersächsisch | Lübeckisch |
| Ostelbisch | Westfälisch |
| Baltisch | Ostfälisch |
| Südmärkisch | Elbostfälisch |
| | Niederrheinisch |



- | | |
|----------------|-----------------|
| I: 1200-1300 | V: 1451-1500 |
| II: 1301-1350 | VI: 1501-1550 |
| III: 1351-1400 | VII: 1551-1600 |
| IV: 1401-1450 | VIII: 1601-1650 |



Korpuserstellung

Phase 1: Textaufbereitung/ Transkription

Phase 2: Annotation

(PoS- und flexionsmorph. Tagging, Lemmatisierung)

Phase 3: Publikation

(Annis, TEI)

Nutzung

Sprachspezifische Besonderheiten

Wortartwechsel

to *donde*_{VVINF} *hebben*

oder

to *donde*_{NA} *hebben*

Syntaktische Ambiguität

*dochter*_{NA.Fem.Gen.Sg} *name*_{NA.Masc.Nom.Sg}

oder

*dochtername*_{NA.Masc.Nom.Sg}

Historisches-Niederdeutsch-Tagset (HiNTS)

Basis

- low-resourced language
 - keine Tools zur automatischen Annotation vorhanden
 - keine Trainingsdaten für statistische Tools vorhanden
 - kaum elektronische Ressourcen vorhanden (z.B. Wörterbuch)
- keine Standards für die Annotation mnd. Daten
 - **POS-Tagset (inkl. Morphologie)**, Lemmainventar

STTS
(PoS + Morphologie)

Stuttgart-Tübingen-Tagset
(Schiller et al. 1999)

→ HiTS
(PoS)

Historisches Tagset
(Dipper et al. 2013)

Nomen – N

Verb – V

Determinierer – **D** (Artikel – **ART**)

Adjektiv – ADJ

Pronomina – P (Pronominaladverb – **PAV**)

Kardinalzahlen – CARD

Adverbien – **ADV**, **AV**

Junktionen – KO

Appositionen – AP

Interjektion – ITJ

Partikel – PTK

- Die Hauptwortarten sind nach funktionalen und distributionellen Kriterien subklassifiziert

Beispiel (HiTS):

DDART

Determinativ, definit, artikelartig

- Angabe einer Basiswortart

Beispiel: *to **donde**_{NA} < VVIN_F hebben*

Anforderungen (I)

1. Möglichst nah an existierenden Tagsets bleiben
(POS: HiTS, Morphologie: STTS)

→ Aber:

2. Tags müssen anhand des konkreten Kontextes auswählbar sein
(keine muttersprachliche Intuition)

- Beispiel (STTS):

- PIAT (attribuierendes Indefinitpron., ohne Determinierer vorkommend)
 - *[etwas] Schokolade*

vs.

- PIDAT (attribuierendes Indefinitpron., mit Determinierer vorkommend)
 - *[solch] eine Frage*

→ dies ist erst als Ergebnis der Korpusauswertung entscheidbar

Anforderungen (II)

3. Ambiguitäten kennzeichnen

- Beispiel:

- KON vs. KOU nicht immer entscheidbar > HiTS hat KO*

4. Aber: so spezifisch wie möglich sein

- STTS kennt in der Morphologie nur eine eindeutige Zuweisung oder ambig (*)

- daher weder STTS noch HiTS ohne Modifikation geeignet
- Eigene angepasste Version von HiTS:
Hi**N**TS (PoS + Morphologie)

Historisches-Niederdeutsch-Tagset (HiNTS)

Part of Speech (PoS)

Flexionsmorphologie

Historisches-Niederdeutsch-Tagset (HiNTS)

Part of Speech (PoS)

Flexionsmorphologie

HiTS (Dipper et al. 2013: 36f.) unterscheidet zwischen:

- Tags mit **D...** (Determinativa) → 2 Unterkategorien: **Typ** + **Position**, z.B.:
 - *[dise]_{DDA} rede*
(Determinativ, **definit/demonstrativ**, **attributiv**)
 - *[dizze]_{DDS} ist ein anphanlich zit*
(Determinativ, **definit/demonstrativ**, **substituierend**)
- Tags mit **P...** (Pronomen): stets substituierend → nur eine Unterkategorie: **Typ**, z.B.:
 - *man_{P1}* (Pronomen, **indefinit**)

→ Problem:

vorab als Pronomen klassifiziertes Lexem in anderer Distribution (nicht substituierend), z.B. *man* vor einem Substantiv i.S.v. ‚irgendein‘_(Bsp. konstruiert)

→ lexembezogene Vorannahmen in HiNTS vermeiden → 2 Gruppen:

- Tags mit **D...** → attributiv, z.B.:

- *[dyt]_{DDA} ghut kanstu allene nyth ghe wynnen*

(Determinativ, definit/demonstrativ, attributiv, vorangestellt)

- Tags mit **DP...** → substituierend, z.B.:

- *dat my [nemant]_{DPNEGS} kunne lyken*

(Determinativ/Pronomen, negativ, substituierend)

↓

Nutzen: Ermittlung von Lemmata, die nur substituierend vorkommen und daher tatsächlich Pronomen sind

- Anwendung des MAMA-Zyklus (vgl. Pustejovsky/ Stubbs 2012)
- 2 Inter-Annotator-Agreements mit je 2 Annotatoren
 - IAA I:
 - PoS-Taggings und flexionsmorphologisches Tagging
 - keine Lemmatisierung
 - ausschließlich manuelles Tagging
 - IAA II:
 - PoS-Taggings und flexionsmorphologisches Tagging
 - Lemmatisierung mittels Lemmaliste
 - halbautomatisches Tagging

ART DER ABWEICHUNG	IAA I	IAA II	IAA III
Abweichungen aufgrund fehlender Regeln	8,9%	3,7%	↘
Abweichungen trotz bestehender Regeln	3,1%	5,7%	↘
unterschiedliches Textverständnis	1,0%	1,9%	→
gesamt	13,0%	11,3%	↘

Abweichungen trotz bestehender Regeln:

- Regelverstoß
- Folgefehler
- Annotation vergessen/ Aufmerksamkeit

Historisches-Niederdeutsch-Tagset (HiNTS)

Part of Speech (PoS)

Flexionsmorphologie

- Die Art und der Umfang der Tags sind abhängig von PoS

Beispiele:

*Her marcus meyger myn leue **frunth** klagent **mack** my **nycht** baten [...]* (Brief v. A. Willeken, 1535)

frunth_{NA.Masc.Nom.Sg} **mack**_{VMFIN.3.Sg.Pres.Ind} **nycht**_{PTKNEG}

- STTS nutzt das Sternchen (*) für Ambiguitäten

→ Nachteile:

- keine Angabe der konkreten möglichen Werte (z.B. Dat. und Akk., aber nicht Gen.)
- Tendenz, eine Entscheidung herbeizuführen, vgl. TIGER : „[...] Nur wenn es nicht gelingt, im gegebenen Kontext dem Attribut einen eindeutigen Wert zuzuweisen, soll der Wert * zugewiesen werden.“ (TIGER-Morphologie-Annotationsschema 2015: 5)

→ für Nhd. möglich, für historische Sprachstufen problematisch, da zu interpretatorisch

Genusambiguität

Beispiel:

Dit is der sassen speyghel (Oldb. Ssp., Überschrift)

TOKEN	PoS	MORPHOLOGIE
Dit	DPDS	
is	VVFIN	
der	DDARTA	
sassen	NA	
speyghel	NA	Masc-Neut.Nom.Sg

ART DER ABWEICHUNG	IAA I	IAA II	IAA III
Abweichungen aufgrund fehlender Regeln	8,2%	1,7%	↘
Abweichungen trotz bestehender Regeln	11,6%	12,6%	↘
unterschiedliches Textverständnis	0%	0,5%	→
gesamt	19,8%	14,8%	↘

Abweichungen trotz bestehender Regeln:

- Regelverstoß
- Folgefehler
- Annotation vergessen/ Aufmerksamkeit

Resümee

- Entwicklung des **HiNTS** aufgrund sprachspezifischer Besonderheiten des Mittelniederdeutschen
- **Qualitätssicherungsverfahren** sind von hoher Wichtigkeit
- Inter-Annotator-Agreements zeigten:
 - HiNTS ist erfolgreich anwendbar
 - mit HiNTS sinkt der Grad der Interpretation
 - Abweichungen zwischen den Annotatoren haben unterschiedliche Ursachen
 - systematische Abweichungen lassen sich reduzieren
 - Routinierte Anwendung wird aufmerksamkeitsbedingte Fehler und Regelverstöße herabsetzen

Herzlichen Dank für Ihre Aufmerksamkeit!

- Barteld, Fabian/ Ihden, Sarah/ Schröder, Ingrid/ Zinsmeister, Heike (2014): „Annotating descriptively incomplete language phenomena“. In: *Proceedings of LAW VIII - The 8th Linguistic Annotation Workshop*, August 2014, Dublin, S. 99-104. Online verfügbar unter: <http://www.aclweb.org/anthology/W14-4915>.
- Dipper, Stefanie/ Donhauser, Karin/ Klein, Thomas/ Linde, Sonja/ Müller, Stefan/ Wegera, Klaus-Peter (2013): „HiTS: ein Tagset für historische Sprachstufen des Deutschen“. In: *Journal for Language Technology and Computational Linguistics*, Special Issue, 28(1), 85-137.
- Pustejovsky, James/ Stubbs, Amber (2012): *Natural Language Annotation for Machine Learning. A Guide to Corpus-Building for Applications*. Beijing [u.a.].
- Rehbein, Ines/ Hirschmann, Hagen/ Lüdeling, Anke/ Reznicek, Marc (2012): “Better tags give better trees – or do they?“. In: *Linguistic Issues in Language Technology (LILT)*. Volume 7, S. 1-18.
- Rehbein, Ines/ Schalowski, Sören (2013): „STTS goes Kiez – Experiments on Annotating and Tagging Urban Youth Language“. In: *Journal for Language Technology and Computational Linguistics (JLCL)*, Special Issue, 28(1), S. 199-227.
- Schiller, Anne/ Teufel, Simone/ Stöckert, Christine: *Guidelines für das Tagging deutscher Textcorpora mit STTS (Kleines und großes Tagset)*. Stuttgart, Tübingen 1999: Univ. Stuttgart, Univ. Tübingen
- TIGER Morphologie-Annotationsschema (2015). Auf: http://www.ims.uni-stuttgart.de/forschung/ressourcen/korpora/TIGERCorpus/annotation/tiger_scheme-morph.pdf. [Zuletzt gesehen am 02.09.15]

Anhang

ART DER ABWEICHUNG	IAA I	IAA II	IAA III
Abweichungen aufgrund fehlender Regeln	8,9%	3,7%	
Abweichungen trotz bestehender Regeln	3,1%	5,7%	
unterschiedliches Textverständnis	1,0%		
gesamt	13,0%		

Abweichungen trotz bestehender Regeln

ART DER ABWEICHUNG	IAA I	IAA II
Regelverstoß	78,6%	62,5%
Folgefehler	21,4%	23,2%
Annotation vergessen, Aufmerksamkeit	0%	14,3%
gesamt	100%	100%

Qualitätssicherungsverfahren

Inter-Annotator-Agreement Morph.

ART DER ABWEICHUNG	IAA I	IAA II	IAA III
Abweichungen aufgrund fehlender Regeln	8,2%	1,7%	
Abweichungen trotz bestehender Regeln	11,6%	12,6%	
unterschiedliches Textverständnis	0%		
gesamt	19,8%		

ART DER ABWEICHUNG	IAA I	IAA II
Regelverstoß	35,6%	47,3%
Folgefehler	57,8%	25,5%
Annotation vergessen, Aufmerksamkeit	5,6%	17,3%
tagger-reproduzierte Fehler	-	10,0%
verschiedene	1,1%	0%
gesamt	100%	100%

- Rehbein et al. (2012, 8):
 - Annotation von Lernaltersprache mit dem STTS
 - Annotatorenübereinstimmung von 97,9 %
- Rehbein/ Schalowski (2013: 208)
 - Annotation des Kiezdeutsch-Korpus mit dem dafür erweiterten Tagset
 - Annotatorenübereinstimmung von 96,5 %