

Die Normalisierung von Komposita in frühneuhochdeutschen Texten am Beispiel des RIDGES-Korpus

Laura Perlit, Gohar Schnelle, Anke Lüdeling, Carolin Odebrecht, Humboldt-Universität zu Berlin

39. Jahrestagung der DGfS, Saarbrücken, 08.03.-10.03.2017



1. Wie lassen sich Komposita im Fnhd. variationistisch untersuchen?

- Motivation: Komposition ist ein produktives Wortbildungsmittel mit einer Vielzahl an Bildungsmöglichkeiten
- man möchte deshalb systematisch suchen und analysieren
- Herausforderung: eine Variable mit vielen unvorhersagbaren historischen Varianten (graphische, morphologische, phonologische Realisierung)

Variable	Kompositum		
Variante	phonologisch	graphematisch	morphologisch
Beispiel	Repräsentationen durchgeführter und nicht durchgeführter Lautwandel	Getrennt- und Zusammenschreibung	Existenz von Fugenelementen
Historische Belege	wieh=rauch Weyhrauch	Kräuter Saltz Kräutersaltz	Kolfewer kolfeuwer

2. Kompositum vs. Syntagma im Fnhd.

- zweifelsfreie Disambiguierung aufgrund fehlender graphematischer Kennzeichnung nicht immer möglich, v.a. für NLP-Methoden besteht darin eine Herausforderung⁸, z.B.:
 - NPn mit Adjektivattributen:
auff das Stro das leinen tuchlein vs. Leinentuchlein
 - NPn mit vorangestellten Genitivattributen:
Teuffels Bissz vs. Teufelsbissz
- Definition im Gegenwartsdeutschen eher graphematisch (Zusammenschreibung¹⁰)

3. RIDGES-Korpus



- **Version 5.0⁴:**
- 36 Kräuterdetexte vom 15.-20. Jh.
- 183.724 Token auf der diplomatischen Primärtextebene
- Version 6.0 in Arbeit
- entstanden im Rahmen von Bachelor- und Masterseminaren an der Humboldt-Universität zu Berlin
- variationistischer Forschungsansatz: konstanter Faktor: Register; variabler Faktor: Zeit
- multiple Segmentierung auf verschiedenen linguistischen Ebenen
- ausführliche Annotationsrichtlinien¹

4. Normalisierung im RIDGES-Korpus


• Primärtextebenen:

- **dipl:** diplomatische Transskription
- **clean:** Normalisierung auf Zeichenebene
- **norm:** Normalisierung auf verschiedenen linguistischen Ebenen

dipl	den	zūor	berēuchen	mit	wie=	rauch
clean	solt	zuor	berēuchen	mit	wierauch	
norm	sollst	zuvor	beräuchern	mit	Weihrauch	

- Normalisierung erfolgt manuell (bisher noch keine verlässlichen automatischen Verfahren zur Normalisierung frühneuhochdeutscher Texte entwickelt^{2,8})
- nur auf den Ebenen Phonologie, Morphologie, Graphematik
- **nicht** lexikalisch und syntaktisch, da dies eine tiefere Interpretation erfordert

Diese Prinzipien werden bei der Normalisierung eingehalten:



5. Normalisierung fnhd. Komposita

	Phonologie	Graphematik	Morphologie
dipl	wieh=rauch	Kräuter Saltz	Kolfewer
norm	Weihrauch	Kräutersaltz	Kohlenfeuer

- phonologische und morphologische Normalisierung ermöglicht die automatische Verarbeitbarkeit, z.B. Lemmatisierung, POS-Tagging
- Zusammenschreibung für eindeutige Komposita
- Zweifelsfälle bleiben gemäß dem Konservativitätsprinzip getrennt geschrieben
- unbedingtes Miteinbeziehen der diplomatischen Transkription für eine Analyse des historischen Standes, da Normalisierungen immer Interpretationen der Annotatoren beinhalten

Fallbeispiel

dipl	wer	der	beyfufz	wurczeln	über	die	thor	des	haufes	legt	oder	hencket
clean	wer	der	beyfusz	wurczeln	über	die	thor	des	hauses	legt	oder	hencket
norm	wer	der	Beifuß	Wurzeln	über	die	Tor	des	Hauses	legt	oder	hängt
lemma	wer	die	Beifuß	Wurzel	über	die	Tor	die	Haus	legen	oder	hängen
pos	PWS	ART	NN	NN	APPR	ART	NN	ART	NN	VVFIN	KON	VVFIN

Trefferreferenzlink: <https://korpling.org/annis3/?id=e62923a0-96ff-46a2-aaa2-59c434ab09c7>

Dieser Beleg ist auch im Kontext nicht disambiguiert, daher greift das Prinzip der Konservativität.

6. Bisherige Forschung:

Perlit, L. (2014): Konkurrenz zwischen Wortbildung und Syntax – historische Entwicklung von Benennung⁷

• Forschungsfrage:

- "Haben Syntax und Wortbildung bei der Entwicklung von Fachtermini in der deutschen Wissenschaftssprache miteinander konkurriert?" (Fokus auf Komposita und NPn mit Genitivattribut)
- basierend auf RIDGES 4.1
- Erstellung zusätzlicher Annotationen
 - graphematische Annotationen (Zusammen-, Getrennt- und Bindestrichschreibung)
 - Annotation des Status potentieller Komposita auf der Skala "eindeutig – wahrscheinlich – zweifelhaft"




Abbildung: Anteil der Getrennt- ('gtr'), Zusammen- ('zs') und Bindestrichschreibung ('bs') an allen Komposita pro Erscheinungsjahr in % (abzüglich Komposita mit Zeilenumbruch).

In dieser Abbildung wird deutlich, dass in einem bestimmten Zeitraum aufgrund fehlender graphematischer Kennzeichnung Komposita und konkurrierende Syntagmen nicht eindeutig disambiguiert sind. Dies geht einher mit dem Vorkommen vorangestellter Genitivattribute im selben Zeitraum.

Referenzen:

- [1] Belz, M.; Odebrecht, C.; Perlit, L.; Schnelle, G. & Voigt, V. (2016): Annotationsrichtlinien zu Ridges Herbology Version 5.0, Humboldt-Universität zu Berlin. https://hu.berlin/ridges_annotationsrichtlinien_v5. • [2] Bollmann, M. (2012): Automatic normalization for linguistic annotation of historical language data. Masterarbeit, Ruhr-Universität Bochum. <http://publikationen.ub.uni-frankfurt.de/frontdoor/index/index/docId/31076>. • [3] Labov, William (2006): The social stratification of English in New York City. 2. Auflage. Cambridge; New York: Cambridge University Press. [4] Lüdeling, A.; Odebrecht, C.; Zeldes, A.: RIDGES-Herbology (Version 5.0), Humboldt-Universität zu Berlin. <https://korpling.org/ridges>. • [5] Odebrecht, C., Belz, M., Zeldes, A., Lüdeling, A., Krause, T. (erscheint): RIDGES Herbology - Designing a Diachronic Multi-Layer Corpus. In: Language Resources and Evaluation. Malden, Oxford: Blackwell. • [6] Pavlov, V. M. (1983): Zur Ausbildung der Norm der deutschen Literatursprache (1470-1730). Berlin: Akademie-Verlag. • [7] Perlit, L. (2014): Konkurrenz zwischen Wortbildung und Syntax - historische Entwicklung von Benennung. Bachelorarbeit, Humboldt-Universität zu Berlin. <http://edoc.hu-berlin.de/master/perlit-laura-2014-08-08/PDF/perlit.pdf>. • [8] Piotrowski, Michael (2012): Synthesis Lectures on Human Language Technologies: Natural Language Processing for Historical Texts. Morgan & Claypool. • [9] Wegera, K.-P.; Prell, H.-P. (2000): Wortbildung des Frühneuhochdeutschen. In: Sprachgeschichte 2.2. Berlin, New York: de Gruyter, 1594-1605. • [10] Wöllstein A., Eisenberg P. (2016): Duden - Die Grammatik: unentbehrlich für richtiges Deutsch. Berlin: Dudenverlag:722-723.