

# Delta und Merkmalsselektion

Welche Wörter unterscheiden arabisch-lateinische Übersetzer?

Andreas Büttner<sup>1</sup> Thomas Proisl<sup>2</sup>

<sup>1</sup>Institut für Philosophie  
Universität Würzburg

<sup>2</sup>Professur für Korpuslinguistik  
Universität Erlangen-Nürnberg

<philtag n="13"/>, 26.02.2016

# Gliederung

Einleitung

Problem

Merkmalsselektion

Ergebnisse

Literatur

# Gliederung

Einleitung

Problem

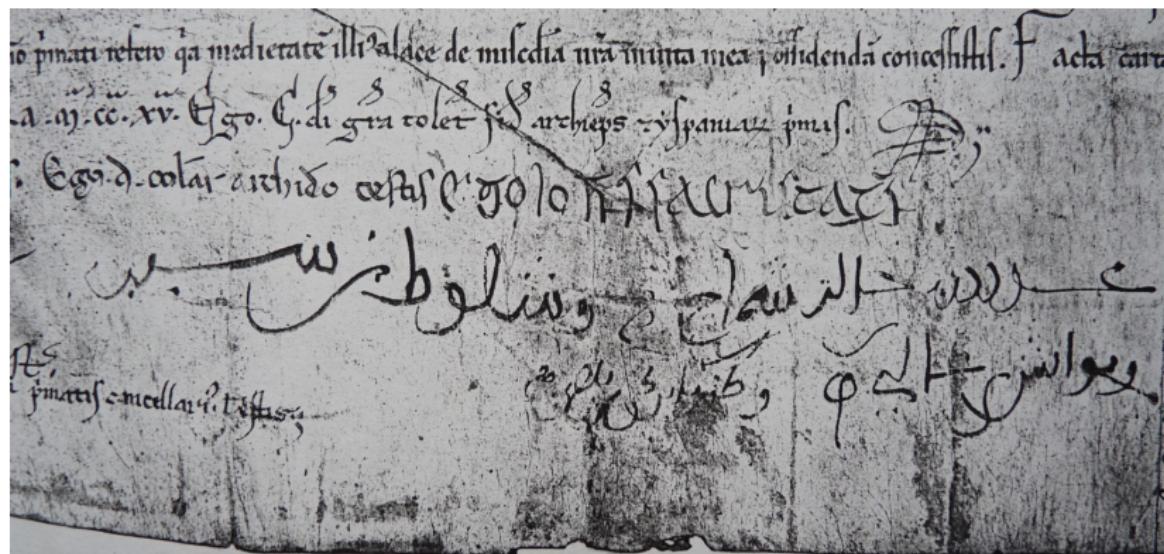
Merkmalsselektion

Ergebnisse

Literatur

# Einleitung

## Arabisch-lateinische Übersetzungen im 12. Jahrhundert



**Abbildung:** Urkunde Toledo, 20. Dezember 1177, ACT V.12.P.1.1  
(F. Hernández, Los cartularios de Toledo: catálogo documental, 1985).

# Einleitung

Zum Textcorpus

- ▶ inzwischen 98 Texte digitalisiert
- ▶ Texte von 11 verschiedenen Übersetzern, 41 anonym
- ▶ zum Teil Zusammenarbeit von Übersetzern
- ▶ Philosophie, Mathematik, Astronomie, Astrologie, Medizin, Geologie und Metereologie, aber auch religiöse, magische und alchemistische Traktate
- ▶ Ziel: Identifizierung der anonymen Übersetzer

# Gliederung

Einleitung

Problem

Merkmalsselektion

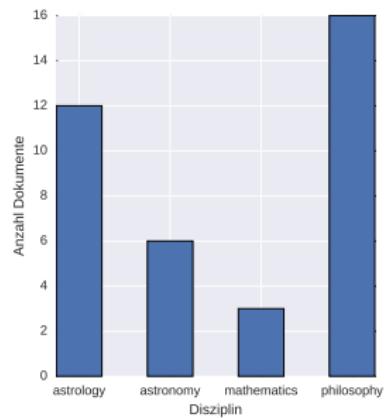
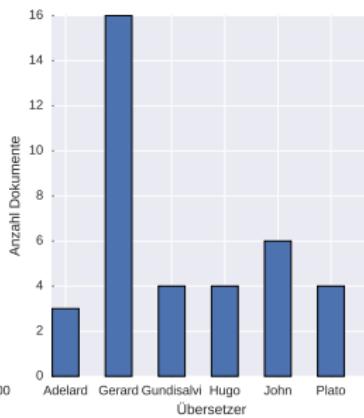
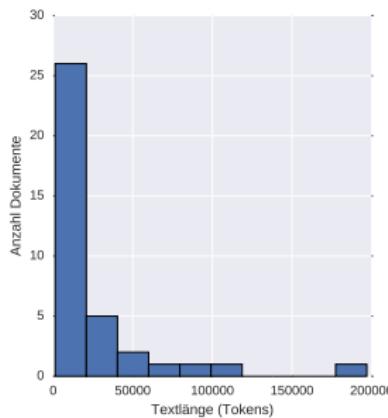
Ergebnisse

Literatur

# Stilometrie (MFW)

## Testkorpus

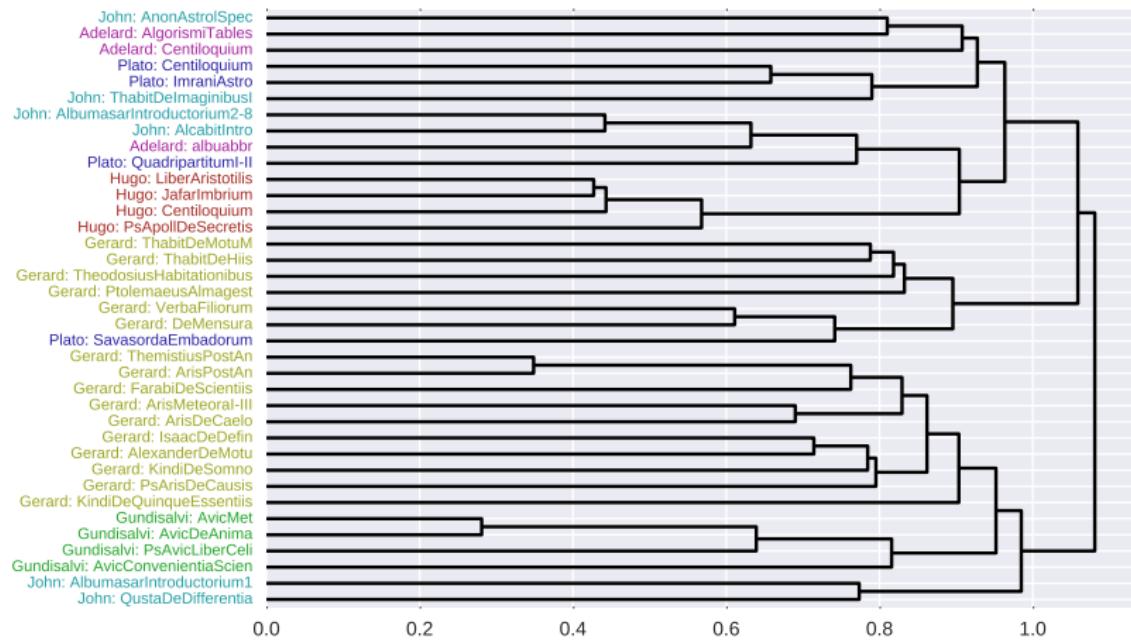
- ▶ Auswahl von 37 Texten
- ▶ keine Überarbeitungen (soweit bekannt)
- ▶ Textlänge mindestens 750 Wörter
- ▶ mindestens drei Texte pro Übersetzer/Disziplin



# Stilometrie (MFW)

das Problem: Übersetzer

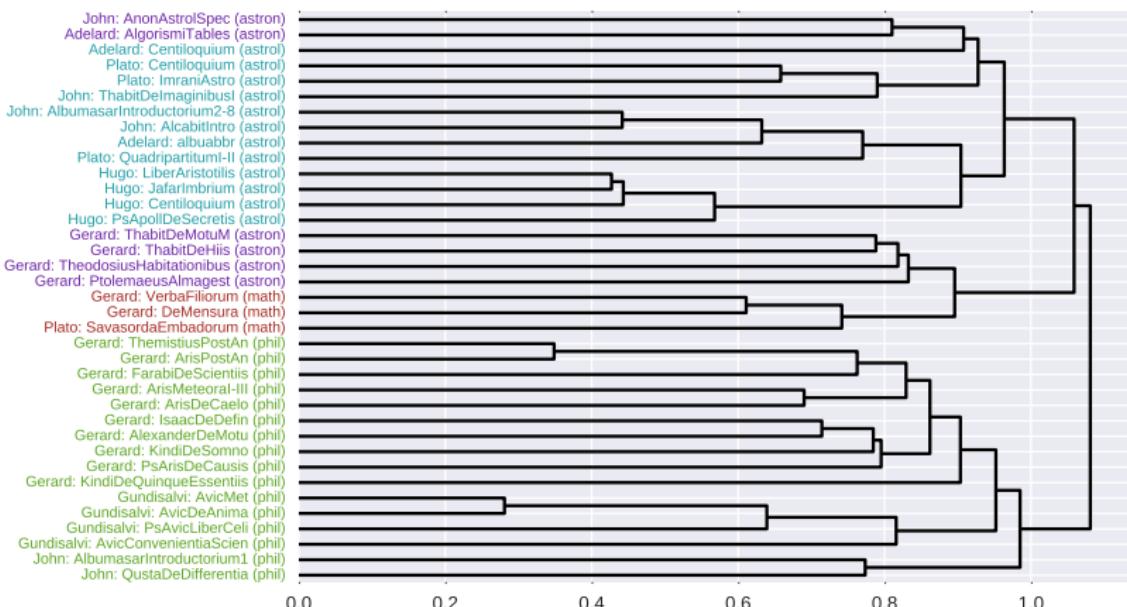
Cosinus/Weighted-Clustering auf Z-scores der 500 häufigsten Wörter, Farben nach Übersetzer.



# Stilometrie (MFW)

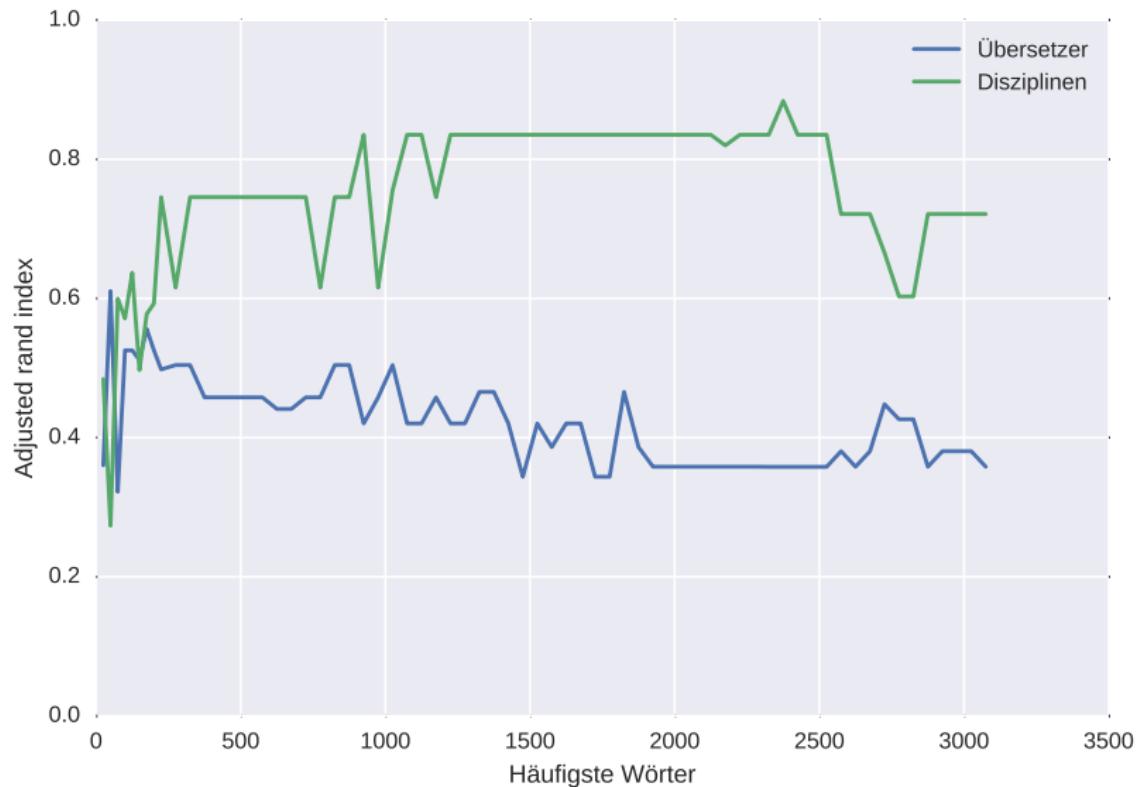
das Problem: Disziplinen

Cosinus/Weighted-Clustering auf Z-scores der 500 häufigsten Wörter, Farben nach Disziplin.



# Stilometrie (MFW)

das Problem: Übersetzer vs. Disziplinen



# Stilometrie (MFW)

## das Problem: Zusammenfassung

- ▶ Clustering nach Disziplinen funktioniert relativ gut
- ▶ inhaltliche Information überlagert Übersetzer
- ▶ Wie lassen sich Übersetzer- von Disziplineninformationen trennen?

# Gliederung

Einleitung

Problem

Merkmalsselektion

Ergebnisse

Literatur

# Rekursive Merkmalseliminierung

## Methode

- ▶ von Guyon et al. (2002) vorgeschlagene Methode
  - ▶ möglichst kleine Teilmenge von Merkmalen
  - ▶ trotzdem möglichst gute Ergebnisse
- ▶ basiert auf überwachtem Lernverfahren (üblicherweise *Support Vector Classifier*)
  - ▶ d.h. wahre Autoren bzw. Übersetzer müssen bekannt sein (zumindest für Teilkorpus)
- ▶ mögliche Alternative zu *most frequent words* zur Autorschaftszuschreibung (Evert et al. 2015)

# Rekursive Merkmalseliminierung

## Details

### Algorithmus

1. trainiere Klassifikator auf Merkmalsmenge (= Zuweisung von Gewichten)
  2. entferne  $k$  Merkmale mit niedrigsten absoluten Gewichten (*pruning*)
  3. gewünschte Anzahl von Merkmalen erreicht?
    - ja: fertig
    - nein: gehe zu 1.
- alternativ: Kreuzvalidierung nach jedem *pruning* Schritt zur Bestimmung der optimalen Merkmalsmenge

# Rekursive Merkmalseliminierung

## Anwendung

### Unser Vorgehen

- ▶ schrittweise Verkleinerung der Merkmalsmenge auf 500 Merkmale
  - ▶ auf 10.000 Merkmale in 1.000er Schritten
  - ▶ auf 1.000 Merkmale in 200er Schritten
  - ▶ auf 500 Merkmale in 25er Schritten
- ▶ anschließend Bestimmung der optimalen Merkmalsmenge
  - ▶ reduzieren der Merkmalsmenge in 1er Schritten
  - ▶ 3-fache Kreuzvalidierung

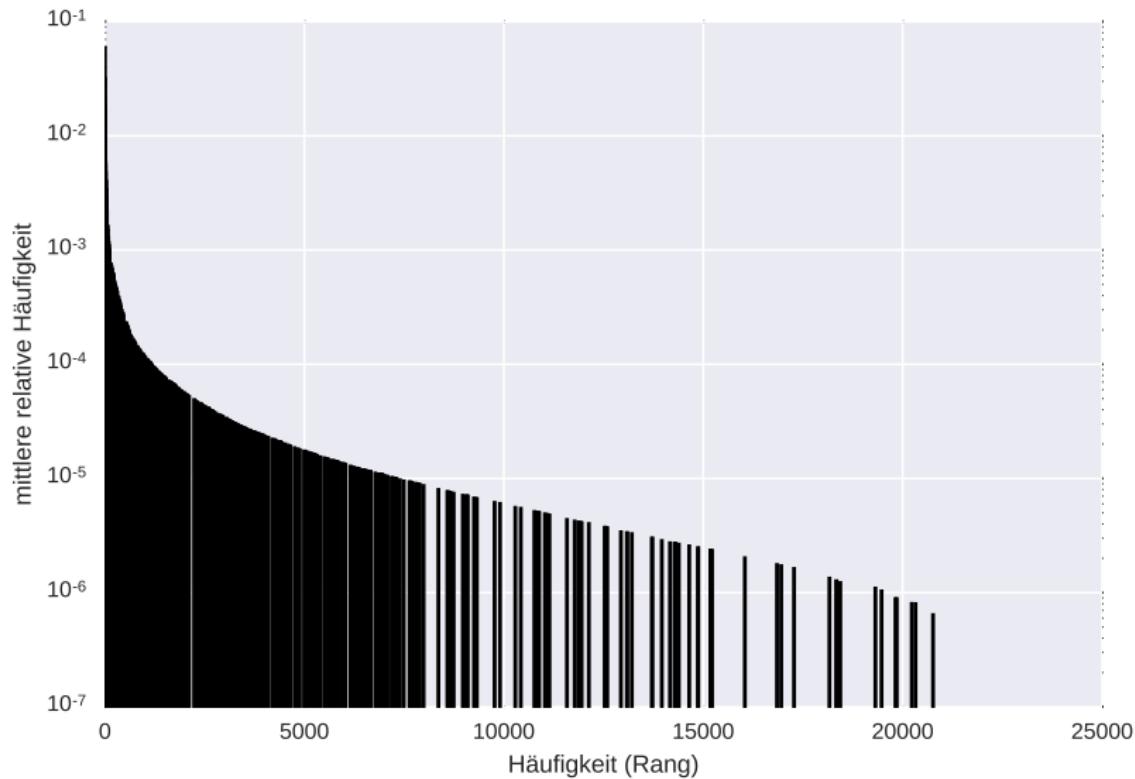
# Rekursive Merkmalseliminierung

## Merkmalsmengen

- ▶ Trainingssets für Übersetzer/Disziplinen
- ▶ Optimale Merkmalsmenge Übersetzer: 495 Wörter
- ▶ Optimale Merkmalsmenge Disziplinen: 485 Wörter
- ▶ auf dem Testset korrekte Aufteilung nach Übersetzern/Disziplinen ( $ARI = 1$ )

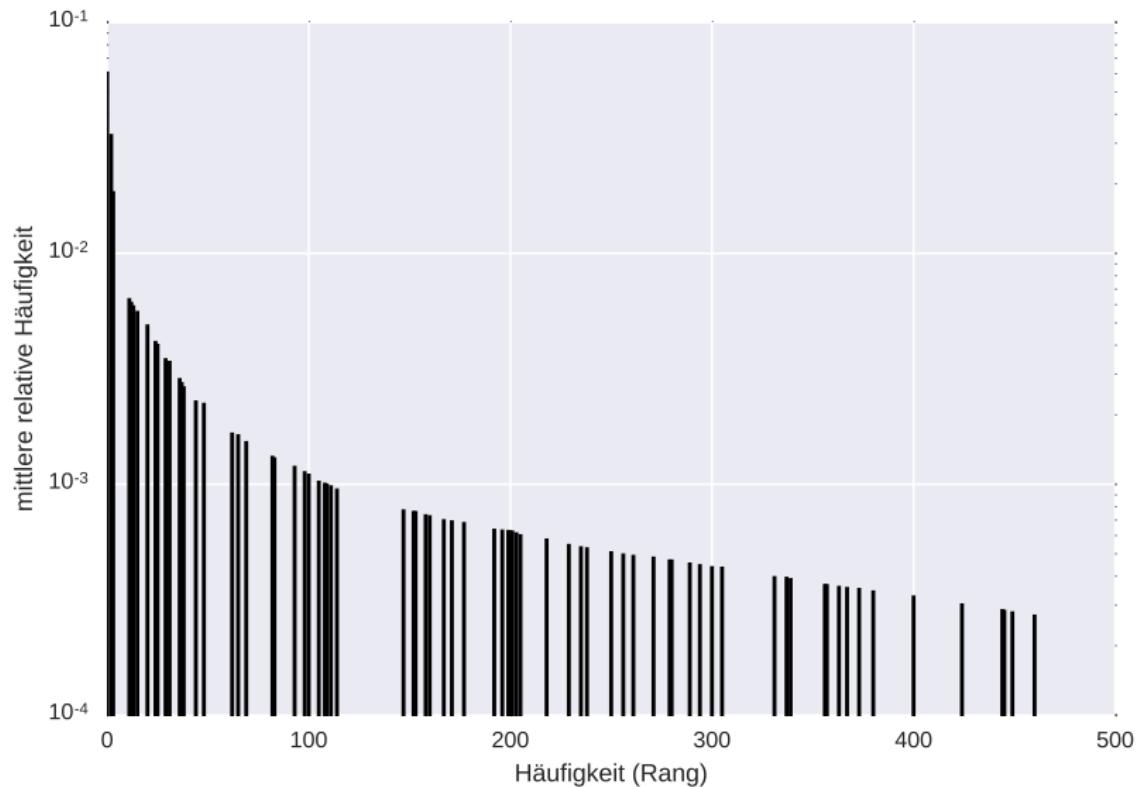
# Rekursive Merkmalseliminierung

## Merkmalsmenge – Übersetzer



# Rekursive Merkmalseliminierung

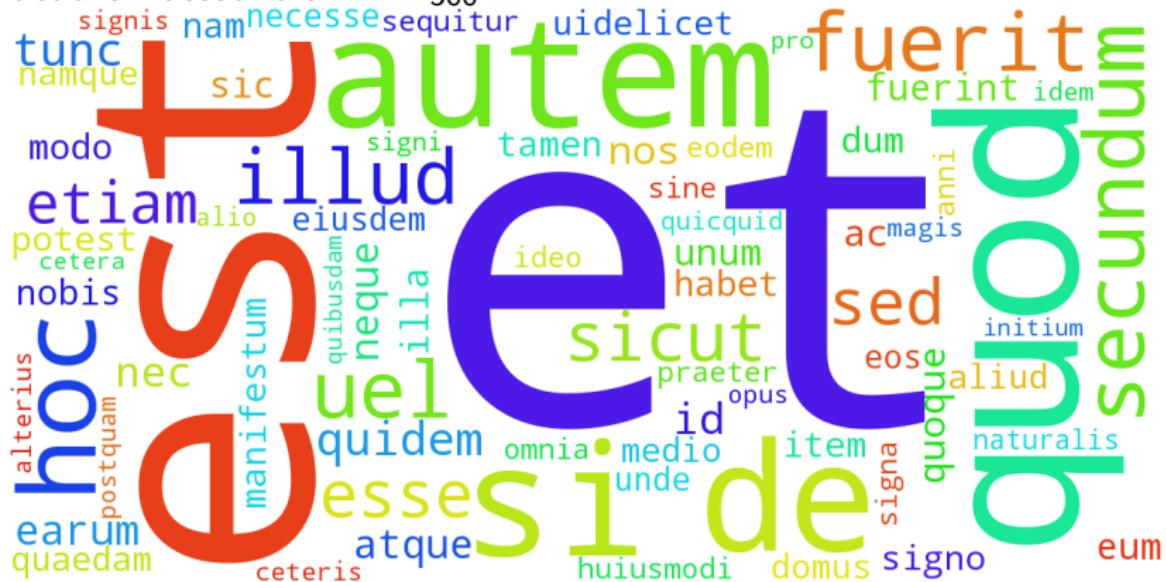
## Merkmalsmenge – Übersetzer (Detail)



## Rekursive Merkmalseliminierung

## Übersetzerwörter

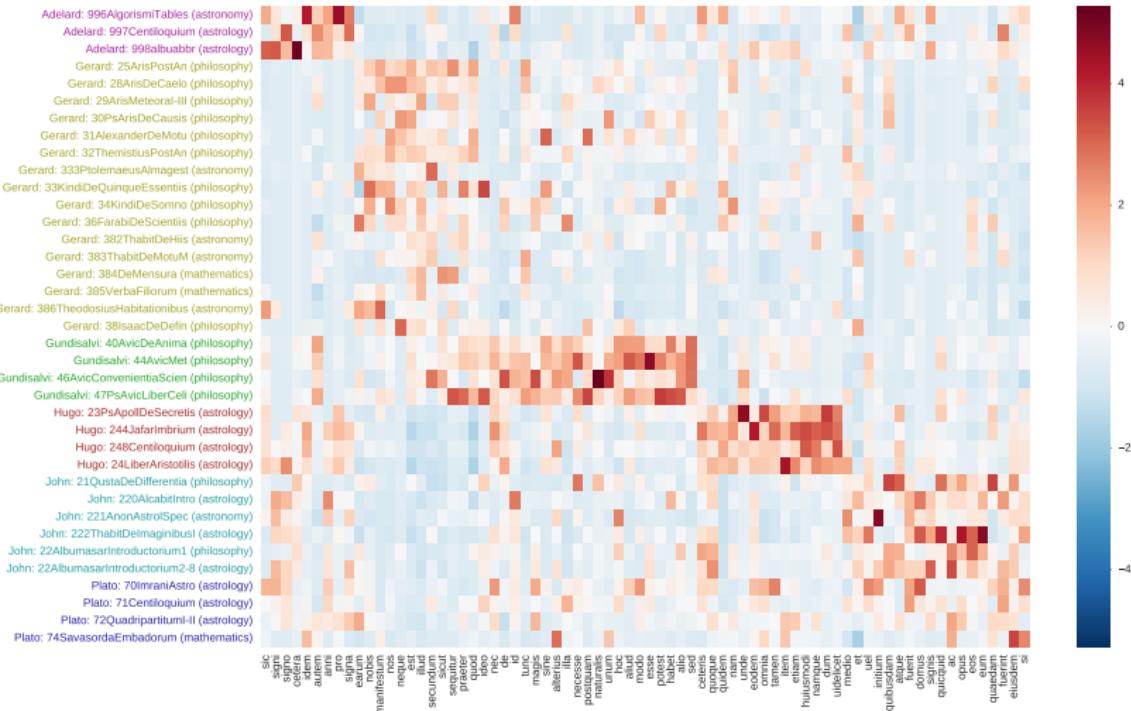
Schnittmenge (74 Wörter) zwischen Übersetzerwörtern (RFE<sub>Ü</sub>) und Menge der 500 häufigsten Wörter (MFW<sub>500</sub>):  $ARI = 0,824$  – deutlich besser als MFW<sub>500</sub>.



# Rekursive Merkmalseliminierung

## Übersetzerwörter

Terme lassen sich dem Übersetzer zuordnen, in dessen Texten der Mittelwert ihrer z-Werte am höchsten ist.



$RFE_0 \cap MPW_{500}$ , sortiert nach Übersetzern

# Rekursive Merkmalseliminierung

## Differenzmengen

- ▶ Wenn die 74 Wörter in  $MFW_{500} \cap RFE_{Ü}$  so gut für Übersetzer funktionieren ( $ARI=0,824$ ), was ist mit den 426 restlichen Wörtern in  $MFW_{500}$ ?

Differenzmenge mit  $MFW_{500}$  ( $MFW_{500} \setminus RFE_{Ü}$ )

- ▶ 426 Wörter
- ▶ ( $ARI$  für Übersetzer: 0,284)
- ▶  $ARI$  für Disziplinen: 0,795
  - ▶ besser als mit allen  $MFW_{500}$  (0,746)!

# Rekursive Merkmalseliminierung

## Differenzmengen

- ▶ Wenn die 123 Wörter in  $MFW_{500} \cap RFE_D$  so gut für Disziplinen funktionieren ( $ARI=0,836$ ), was ist mit den 377 restlichen Wörtern in  $MFW_{500}$ ?

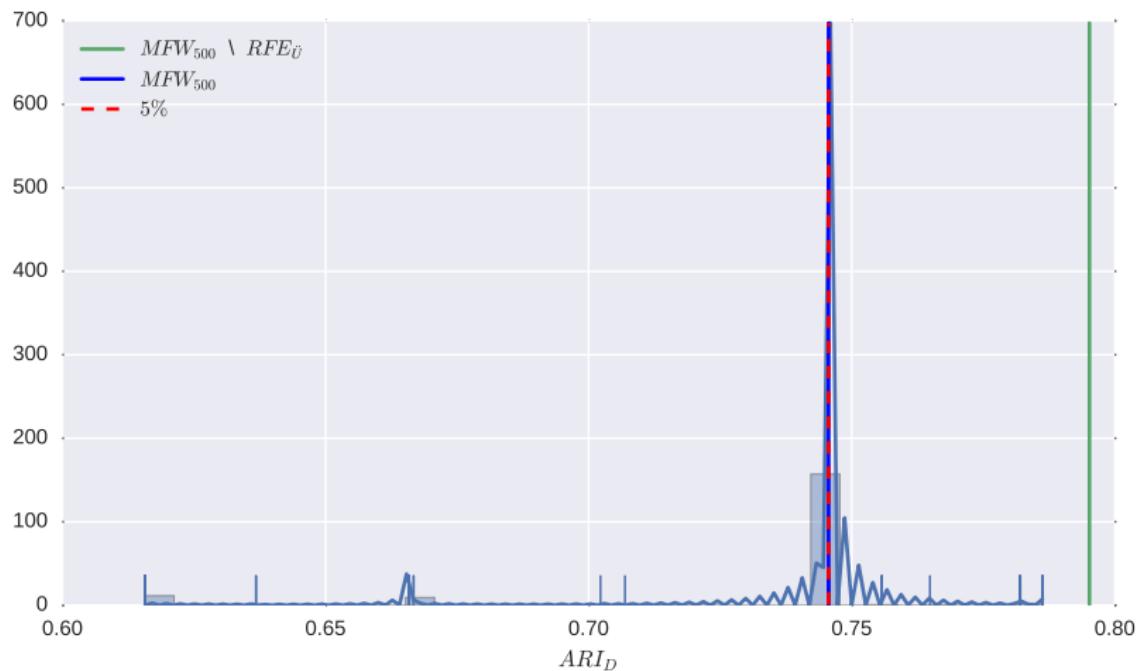
Differenzmenge mit  $MFW_{500}$  ( $MFW_{500} \setminus RFE_D$ )

- ▶ 377 Wörter
- ▶ ( $ARI$  für Disziplinen: 0,593)
- ▶  $ARI$  für Übersetzer: 0,526
  - ▶ besser als mit allen  $MFW_{500}$  (0,458)!

# Rekursive Merkmalseliminierung

Differenzmengen – besser als Zufall?

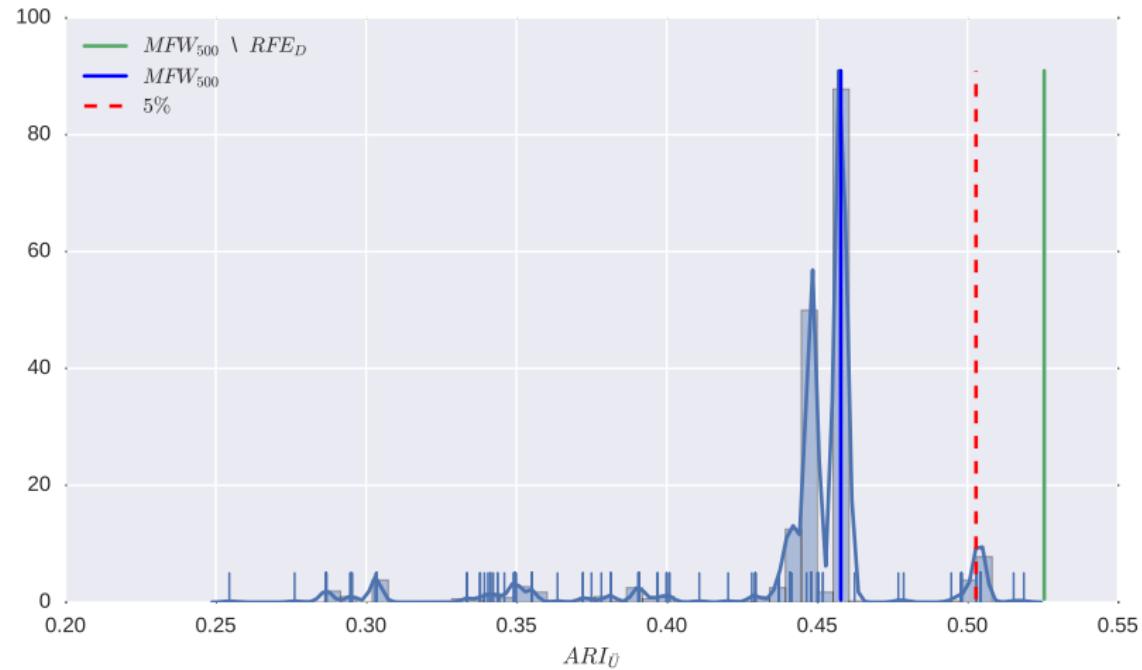
Ohne Übersetzerwörter: Vergleich von  $(MFW_{500} \setminus RFE_{Ü})$  mit 1000 zufällig ausgewählten Teilmengen der gleichen Größe.



# Rekursive Merkmalseliminierung

Differenzmengen – besser als Zufall?

Ohne Disziplinenwörter: Vergleich von  $(MFW_{500} \setminus RFE_D)$  mit 1000 zufällig ausgewählten Teilmengen der gleichen Größe.



# Gliederung

Einleitung

Problem

Merkmalsselektion

Ergebnisse

Literatur

# Ergebnisse

## Überblick

Merkmale	ARI <sub>Ü</sub>	ARI <sub>D</sub>
MFW <sub>500</sub>	0,458	0,746
RFE <sub>Ü</sub>	1,000	0,310
RFE <sub>D</sub>	0,223	1,000
MFW <sub>500</sub> ∩ RFE <sub>Ü</sub>	0,824	0,228
MFW <sub>500</sub> ∩ RFE <sub>D</sub>	0,189	0,836
MFW <sub>500</sub> \ RFE <sub>Ü</sub>	0,284	0,795
MFW <sub>500</sub> \ RFE <sub>D</sub>	0,526	0,593

Bei anderen Qualitätsmaßen als dem ARI, nämlich dem V-measure-score (Homogenität und Vollständigkeit) sowie dem mittleren Silhouettenkoeffizienten, ist der gleiche Trend zu bemerken.

# Ergebnisse

## Fazit

### Hauptergebnis

- ▶ Partitionierung der MFW in zwei Teilmengen möglich:
  - Teilmenge 1: bessere Identifikation der Übersetzer als Gesamtmenge
  - Teilmenge 2: bessere Identifikation der Disziplinen als Gesamtmenge
- ▶ MFW tragen teils Übersetzer-, teils Disziplinsignal!

### Weitere Ergebnisse

- ▶ rekursive Merkmalseliminierung wirksame Methode zur Bestimmung von übersetzer- und disziplintypischen Merkmalen
- ▶ Kondensierung der Wortliste als philologische Chance

# Ergebnisse

## Ausblick

### Zukünftige Forschung

- ▶ Anwendung auf Mehrwortgruppen
- ▶ Anwendung auf andere Textkorpora
- ▶ unüberwachte Partitionierung der Merkmale

# Gliederung

Einleitung

Problem

Merkmalsselektion

Ergebnisse

Literatur

## Literatur (1)

- ▶ Argamon, Shlomo (2008): „Interpreting Burrows's Delta: Geometric and Probabilistic Foundations.“ *Literary and Linguistic Computing* 23/2: 131–147.  
doi:10.1093/linc/fqn003
- ▶ Burrows, John (2002): „Delta: a Measure of Stylistic Difference and a Guide to Likely Authorship.“ *Literary and Linguistic Computing* 17/3: 267–287. doi:10.1093/linc/17.3.267
- ▶ Eder, Maciej (2015): „Does size matter? Authorship attribution, small samples, big problem.“ *Digital Scholarship Humanities* 30/2: 167–182. doi:10.1093/linc/fqt066
- ▶ Eder, Maciej, Mike Kestemont, Jan Rybicki (2013): „Stylometry with R: a suite of tools.“ In: *Digital Humanities 2013: Conference Abstracts*. Lincoln: University of Nebraska, 487–489.

<http://dh2013.unl.edu/abstracts/ab-136.html>

## Literatur (2)

- ▶ Evert, Stefan, Thomas Proisl, Fotis Jannidis, Steffen Pielström, Christof Schöch, Thorsten Vitt (2015): „Towards a better understanding of Burrows's Delta in literary authorship attribution.“ In: Proceedings of the Fourth Workshop on Computational Linguistics for Literature. Association for Computational Linguistics, 79–88.  
<http://www.aclweb.org/anthology/W/W15/W15-0709.pdf>
- ▶ Guyon, Isabelle, Jason Weston, Stephen Barnhill, Vladimir Vapnik (2002): „Gene Selection for Cancer Classification using Support Vector Machines.“ Machine Learning 46/1: 389–422.  
doi:10.1023/A:1012487302797
- ▶ Hasse, Dag Nikolaus, Andreas Büttner (in Vorbereitung): „Notes on the Identity of the Latin Translator of Avicenna's Physics and on Further Anonymous Translations in Twelfth-Century Spain.“ Vorabversion:  
<https://go.uniwue.de/hassevigoni>

## Literatur (3)

- ▶ Hoover, David L. (2004a): „Testing Burrows's Delta.“ *Literary and Linguistic Computing* 19/4: 453–475.  
doi:10.1093/linc/19.4.453
- ▶ Hoover, David L. (2004b): „Delta Prime?“ *Literary and Linguistic Computing* 19/4: 477–495.  
doi:10.1093/linc/19.4.477
- ▶ Jannidis, Fotis, Steffen Pielström, Christof Schöch, Thorsten Vitt (2015): „Improving Burrows' Delta - An empirical evaluation of text distance measures.“ In: Digital Humanities Conference 2015, Sydney.  
[http://dh2015.org/abstracts/xml/JANNIDIS\\_Fotis\\_Improving\\_Burrows\\_\\_Delta\\_\\_\\_An\\_empi/JANNIDIS\\_Fotis\\_Improving\\_Burrows\\_\\_Delta\\_\\_\\_An\\_empirical\\_.html](http://dh2015.org/abstracts/xml/JANNIDIS_Fotis_Improving_Burrows__Delta___An_empi/JANNIDIS_Fotis_Improving_Burrows__Delta___An_empirical_.html)
- ▶ Kestemont, Mike, Kim Luyckx, Walter Daelemans, Thomas Crombez (2012): „Cross-Genre Authorship Verification Using Unmasking.“ *English Studies* 93/3: 340–356.  
doi:10.1080/0013838X.2012.668793

## Literatur (4)

- ▶ Rybicki, Jan (2012): „The great mystery of the (almost) invisible translator: stylometry in translation.“ In: M. Oakley and M. Ji (Hrsg.): Quantitative Methods in Corpus-Based Translation Studies. Amsterdam: John Benjamins, 231–248.  
<https://sites.google.com/site/computationalstylistics/preprints/Rybicki%20Great%20Mystery.pdf>
- ▶ Rybicki, Jan, Maciej Eder (2011): „Deeper Delta across genres and languages: do we really need the most frequent words?“ Literary and Linguistic Computing 26/3: 315–321.  
doi:10.1093/linc/fqr031
- ▶ Schöch, Christof (2013): „Fine-Tuning our Stylometric Tools: Investigating Authorship and Genre in French Classical Drama.“ In: Digital Humanities 2013: Conference Abstracts. Lincoln: University of Nebraska, 383–386.  
<http://dh2013.unl.edu/abstracts/ab-270.html>

## Literatur (5)

- ▶ Smith, Peter W. H., Aldridge, W. (2011): „Improving Authorship Attribution: Optimizing Burrows' Delta Method.“ *Journal of Quantitative Linguistics* 18/1: 63–88.  
doi:10.1080/09296174.2011.533591
- ▶ Stamatatos, Efstathios, Nikos Fakotakis, George Kokkinakis (2000): „Automatic Text Categorization in Terms of Genre and Author.“ *Computational Linguistics* 26/4: 471–497.  
doi:10.1162/089120100750105920