NLP-Methoden in der Klassischen Philologie

Word Embeddings

Daidalos-Kickoff-Workshop, HU Berlin, 14.6.2024
Dr. Andrea Beyer & Konstantin Schulz (Humboldt-Universität zu Berlin)

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Folien

https://kurzlinks.de/klassphil-embeddings

Weitere Materialien in der Zenodo-Community Daidalos!

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

DH-Methoden:
Natural Language Processing (NLP)

01 | DH: AI, ML, NLP

02 | Digital Classics: Ausgewählte NLP-Methoden

03 | Word Embeddings: Vektoren als Repräsentation

04 | Embeddings in der Klassischen Philologie

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

01 | DH: AI, ML, NLP

Digital Humanities:
Artificial Intelligence,
Machine Learning,
Natural Language Processing

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Arbeitsfelder der Digital Humanities (DH)

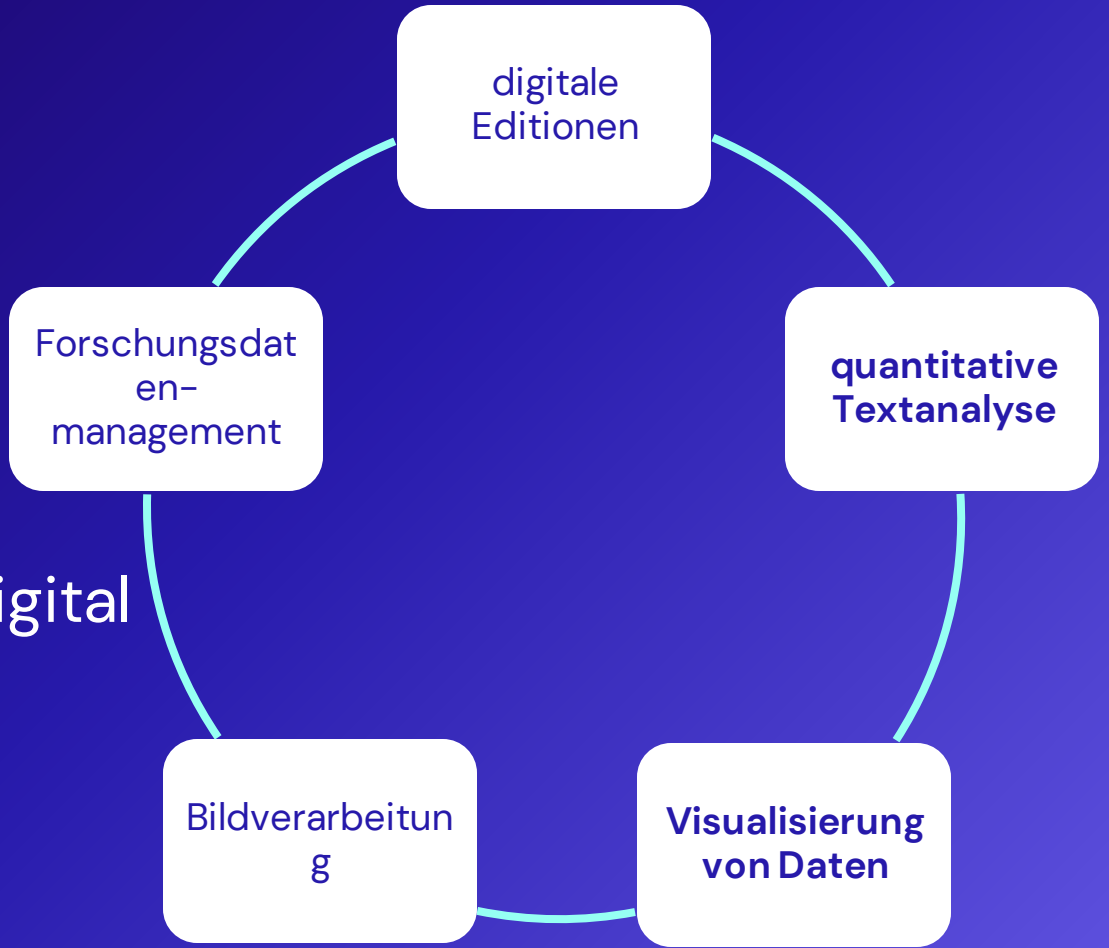

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Der Einsatz von digitalen Methoden umfasst …

… einen Text oder ein Artefakt digital zu erfassen,

… die gewonnenen Daten zu organisieren und zu speichern,

… die Daten zu verarbeiten,

… die Ergebnisse der Verarbeitung darzustellen und

… die Daten für eine Nachnutzung zur Verfügung zu stellen.

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

NLP im Verhältnis zu KI

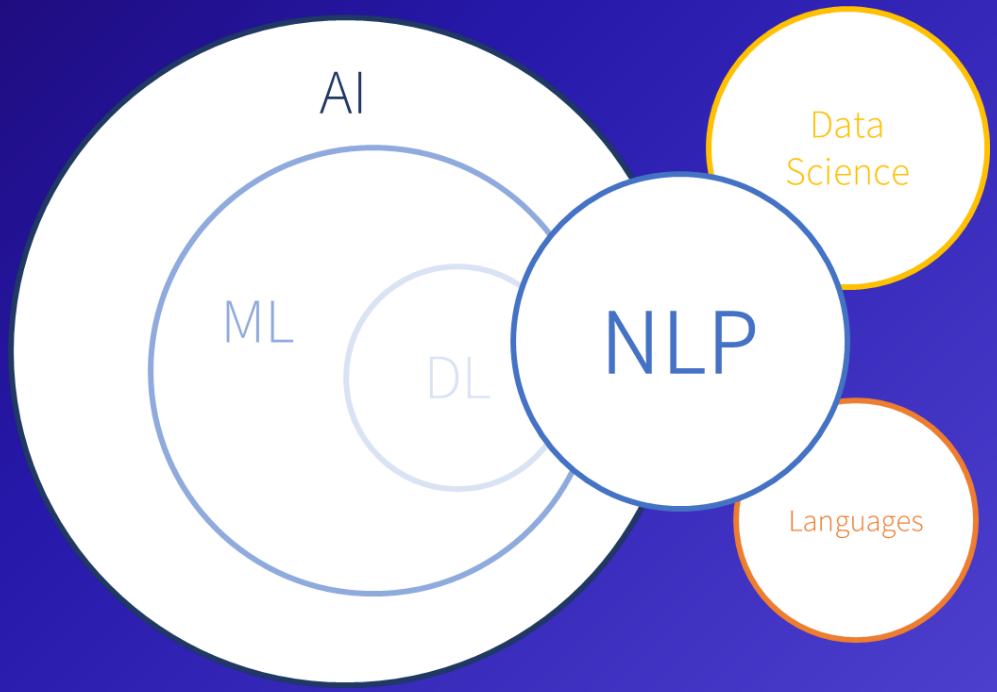

AI – Artificial Intelligence
ML – Machine Learning
DL – Deep Learning
NLP – Natural Language Processing

NLP = NLU + NLG

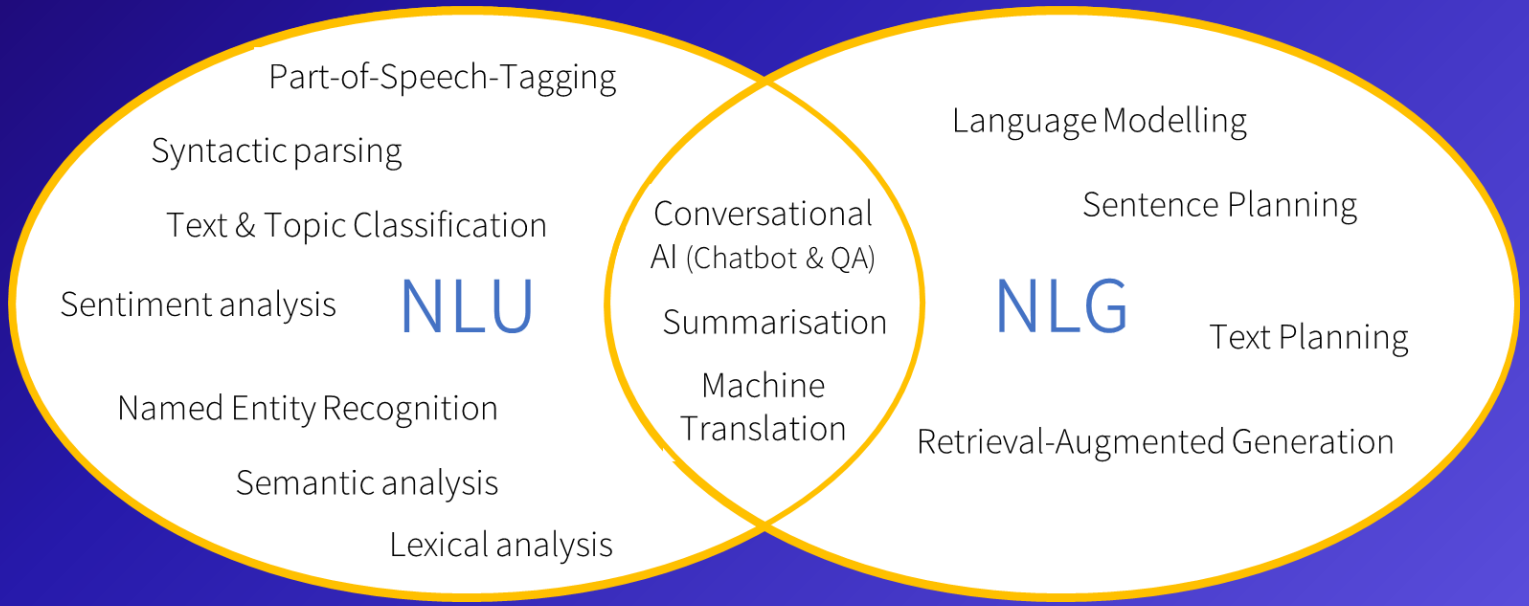

NLP – Natural Language Processing
NLU – Natural Language Understanding
NLG – Natural Language Generation
QA – Question Answering

Wie versteht eine Maschine Sprache?

- Sprachdaten sind unstrukturiert, d.h. nicht mit zusätzlichen Informationen erklärt (annotiert).
- Sie müssen also strukturiert werden, damit sie von Maschinen analysiert werden können (Sprachvorverarbeitung).
- Die Annotationen können sich z. B. auf Wortstellung, Wortkombinationen, Semantik und Morphologie beziehen.
- Maschinelle Sprachverarbeitung (NLP) analysiert mithilfe dieser Merkmale Sprache, berechnet Zusammenhänge, erkennt Muster und erstellt Modelle.

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Vorverarbeitung: Korpusaufbau

Zerlegen und Annotieren der Texte im Korpus

1. Zusammenstellen des Inhalts (Rohtext)
2. Zerlegen des Rohtexts in Paragraphen
3. Zerlegen der Paragraphen in einzelne Sätze (Segmentation)
4. Zerlegen der Sätze in einzelne Wörter (Tokenisation)
5. Zuordnung der Tokens zu den passenden Lemmata (Lemmatisation)
6. Bestimmen der Wortarten (POS-Tagging)
7. Erste (oberflächliche) Korpus-Analysen

und anschließend Transformation des Korpus mit weiteren NLP-Methoden

Bengfort et al. 2018

Segmentation (Zerlegen in Sätze)

```
1 <id n="02">
2 <sentence n="16">2. De duodecim signis</sentence>
3 <p n="1"> <sentence n="17">Signa sunt in caelo duodecim.
  </sentence><sentence n="18">Aries beneficio Liberi, quod is cum
  exercitum in Indiam per Libyam duceret per loca sicca et arenosa,
  qua aquae inopia esset et exercitus eius siti adfligeretur, aries
  eis aquam demonstravit; et ob id a Libero Iovis Ammon est
  appellatus, eique fanum magnificum fecit ad eum locum ubi aquam
  invenit;</sentence><sentence n="19">quod abest ab Aegypto et
  Alexandria milia passuum novem.</sentence><sentence n="20"> ob
  eam rem a Iove petiit ut in<ter> sidera reciperetur. alii putant
  eum esse qui Hellen et Phryxum vexerit.</sentence></p>
4 <p n="2"><sentence n="21">Taurus beneficio Iovis, quem Iuppiter a
  Neptuno fratre per gratiam abduxit; </sentence><sentence
  n="22">qui sensum humanum figura tauri continebat hisque Iovis
  iussu Europam Agenoris filiam Sidonia adludens decepit et eam
  Cretam deportavit. </sentence><sentence n="23">ob eam rem
  Iuppiter in sideribus eum dignatus est immortali
  memoria.</sentence></p>
5 <p n="3"><sentence n="24">Gemini, qui <dii> Samothraces
  nominantur [esse]; </sentence><sentence n="25">quorum argumentum
  nefas est pronuntiare praeter eos qui mi<ste>riis
  prae[sto]sunt.</sentence><sentence n="26"> alii Castorem et
```

Beispiel: *Liber memorialis* des Ampelius (ca. 2. Jh.)

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Zuweisung von Token zu Lemma und Wortart

```
<id n="02">
<sentence n="16">
<w n="1" form="2" lemma="num._arab." pos="NUM"</w>
<w n="2" form="." lemma="." pos="PUNCT"></w>
<w n="1" form="De" lemma="de" pos="ADP"></w>
<w n="2" form="duodecim" lemma="duodecim" pos="NUM"> </w>
<w n="3" form="signis" lemma="signum" pos="NOUN"> </w></sentence>
<p n="1"> <sentence n="17">
<w n="5" form="Signa" lemma="signum" pos="NOUN"> </w>
<w n="6" form="sunt" lemma="sum" pos="VERB"> </w>
<w n="7" form="in" lemma="in" pos="ADP"> </w>
<w n="8" form="caelo" lemma="caelum" pos="NOUN"> </w>
<w n="9" form="duodecim" lemma="duodecim" pos="NUM"> </w>
<w n="10" form="." lemma="." pos="PUNCT"> </w></sentence>
<sentence n="18">
<w n="1" form="Aries" lemma="Aries" pos="NOUN"> </w>
<w n="2" form="beneficio" lemma="beneficium" pos="NOUN"> </w>
<w n="3" form="Liberi" lemma="libeor" pos="VERB"> </w>
<w n="4" form="," lemma="," pos="PUNCT"> </w>
<w n="5" form="quod" lemma="quod" pos="SCONJ"> </w>
w n="6" form="is" lemma="is" pos="ADJ"> </w>
<w n="7" form="cum" lemma="cum" pos="SCONJ"> </w>
<w n="8" form="exercitum" lemma="exercitus" pos="VERB"> </w>
<w n="9" form="in" lemma="in" pos="ADP"> </w>
```

Beispiel: *Liber memorialis* des Ampelius (ca. 2. Jh.)

Erste (oberflächliche) Korpus-Analysen

- Erstelle eine Liste der 100 häufigsten Wörter und sortiere sie absteigend nach Frequenz. (Frequenzanalyse)
- Wie oft kommt bei Ampelius das Wort *magnificus* vor? (Frequenzanalyse)
- Wie viele Adjektive verwendet Ampelius? (Frequenzanalyse)
- Gib alle Vorkommen von *atque* mit je 2 Wörtern davor und danach. (Key Word in Context)
- Berechne die lexikalische Variation / die durchschnittliche Satzlänge / die Textlänge / die durchschnittliche Länge der Kapitel.

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

02 | Digital Classics: NLP-Methoden

Automatische Erkennung von Wortarten, Eigennamen, Gefühlen und Themen

dAIdalos — Digital Research for All —

Gefördert durch DFG Deutsche Forschungsgemeinschaft

Part-of-Speech-Tagging (POS-Tagging)

Ziel

Bestimmung der Wortarten

Einsatz

Datenannotation für komplexere Verfahren, z. B. Textklassifikation, Autorschaft

Methoden

regelbasiert, statistisch, ML, DL, auf der Basis eines festgelegten Tagsets

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

	Dominus	Erasmus	plurimam	salutem	tibi	adscribere	iussit	.
GS:	NOUN	PROPN	ADJ	NOUN	PRON	VERB	VERB	PUNCT
LC:	NOUN	PROPN	ADJ	NOUN	PRON	NOUN	VERB	PUNCT
RDR:	NOUN	VERB	ADJ	NOUN	PRON	VERB	VERB	VERB
GPT-4:	NOUN	PROPN	ADJ	NOUN	PRON	VERB	VERB	PUNCT

Tagger-Vergleich

getaggt mit Gold Standard (GS), LatinCy (LC), RDRPOSTagger (RDR) und GPT-4.
Vgl. Stüssi & Ströbel, 2024: Part-of-Speech Tagging of 16th-Century Latin with GPT, 197.

Named Entity Recognition (NER)

Ziel

Informationsextraktion Texten: automatische Identifikation und Klassifikation von Eigennamen (Person, Ort, Volk)

Einsatz

Datenannotation für Textklassifikation, Sentiment-Analyse, Social-Network-Analyse etc.

Methoden

regelbasiert, statistisch, ML, DL sowie deren Kombination

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Suet. Iul. 24

sed cum Lucius Domitius PERSON consulatus candidatus palam minaretur consulem se effecturum quod praetor nequisset adempturumque ei exercitus, Crassum PERSON Pompeiumque PERSON in urbem prouinciae suae Lucam LOC extractos conpulit, ut detrudendi Domitii PERSON causa consulatum alterum peterent, perfecitque utrumque, ut in quinquennium sibi imperium prorogaretur. qua fiducia ad legiones, quas a re publica acceperat, alias priuato sumptu addidit, unam etiam ex Transalpinis LOC conscriptam, uocabulo quoque Gallico LOC — Alauda LOC enim appellabatur—, quam disciplina cultuque Romano institutam et ornatam postea uniuersam ciuitate donauit. nec deinde ulla belli occasione, ne iniusti quidem ac periculosi abstinuit, tam foederatis quam infestis ac feris gentibus ultro lacessitis, adeo ut senatus quondam legatos ad explorandum statum Galliarum mittendos decreuerit ac nonnulli dedendum eum hostibus censuerint. sed prospere de cedentibus rebus et saepius et plurium quam quisquam umquam dierum supplicationes impetrauit.

Latein: LatinCy
Personen & Orte

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

ὁ δὲ Καῖσαρ PER ἔν τε Κελτοῖς LOC καὶ Βρεττανοῖς MISC πολλὰ καὶ λαμπρὰ εἰργασμένος, ὅσα μοι περὶ Κελτῶν MISC λέγοντι εἴρηται, πλούτου γέμων ἐς τὴν ὅμορον τῇ Ἰταλίᾳ LOC Γαλατίαν LOC, τὴν ἀμφὶ τὸν Ἠριδανὸν LOC ποταμόν, ἦκεν, ἐκ συνεχοῦς πολέμου τὸν στρατὸν ἀναπαύσων ἐπ' ὀλίγον. ὅθεν αὐτῷ περιπέμποντι ἐς Ῥώμην LOC πολλὰ πολλοῖς χρήματα αἵ τε ἐτήσιοι ἀρχαὶ παρὰ μέρος ἀπήντων καὶ οἱ ἄλλως ἐπιφανεῖς ὅσοι τε ἐς ἡγεμονίας ἐθνῶν ἢ στρατοπέδων ἐξήεσαν, ὡς ἑκατὸν μέν ποτε καὶ εἴκοσι ῥάβδους ἀμφ' αὐτὸν γενέσθαι, βουλευτὰς δὲ πλείους διακοσίων, τοὺς μὲν ἀμειβομένους ὑπὲρ τῶν ἤδη γεγονότων, τοὺς δὲ χρηματιουμένους, τοὺς δ' ἄλλο τι τοιουτότροπον αὐτοῖς ἐξεργασομένους. πάντα γὰρ ἤδη διὰ τούτου ἐπράσσετο στρατιᾶς τε πολλῆς οὕνεκα καὶ δυνάμεως χρημάτων καὶ σπουδῆς ἐς ἅπαντας φιλανθρώπου. ἀφίκοντο δ' αὐτῷ καὶ Πομπήιος PER καὶ Κράσσος PER, οἱ κοινωνοὶ τῆς δυναστείας. καὶ αὐτοῖς βουλευομένοις ἔδοξε Πομπήιον PER μὲν καὶ Κράσσον PER αὖθις ὑπατεῦσαι, Καίσαρι PER δ' ἐς τὴν ἡγεμονίαν ὧν εἶχεν ἐθνῶν, ἄλλην ἐπιψηφισθῆναι πενταετίαν. ὧδε μὲν ἀπ' ἀλλήλων διεκρίθησαν, Πομπηίῳ PER δ' ἐς τὴν ὑπατείαν ἀντιπαρήγγελλε Δομίτιος PER Αἰνόβαρβος· καὶ τῆς κυρίας ἡμέρας ἄμφω κατῆσαν ἔτι νυκτὸς ἐς τὸ πεδίον ἐς τὴν χειροτονίαν. τῶν δ' ἀμφ' αὐτοὺς ἔριδες ἦσαν καὶ συνεπλέκοντο, μέχρι τις τὸν Δομιτίου PER δᾳδοῦχον ἐπάταξε ξίφει. καὶ φυγὴ μετὰ τοῦτο ἦν, Δομίτιός PER τε αὐτὸς ἐς τὴν οἰκίαν διεσῴζετο μόλις, καὶ Πομπηίου PER τὴν ἐσθῆτά τινες ἡμαγμένην ἔφερον οἴκαδε. παρὰ τοσοῦτον ἑκάτερος ἦλθε κινδύνου.

Griechisch: flair_grc_bert_ner
Personen, Orte & Völker

Text Classification

Ziel

Zuweisung von Kategorien an Text(e), z. B. zur Unterscheidung von Genres

Einsatz

Merkmalszuweisung für Autorschaft, Sentiment-Analyse, Topic Modelling, Bewerten grammatischer Korrektheit

Methoden

regelbasiert, statistisch, ML, DL sowie deren Kombination

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Autorencluster

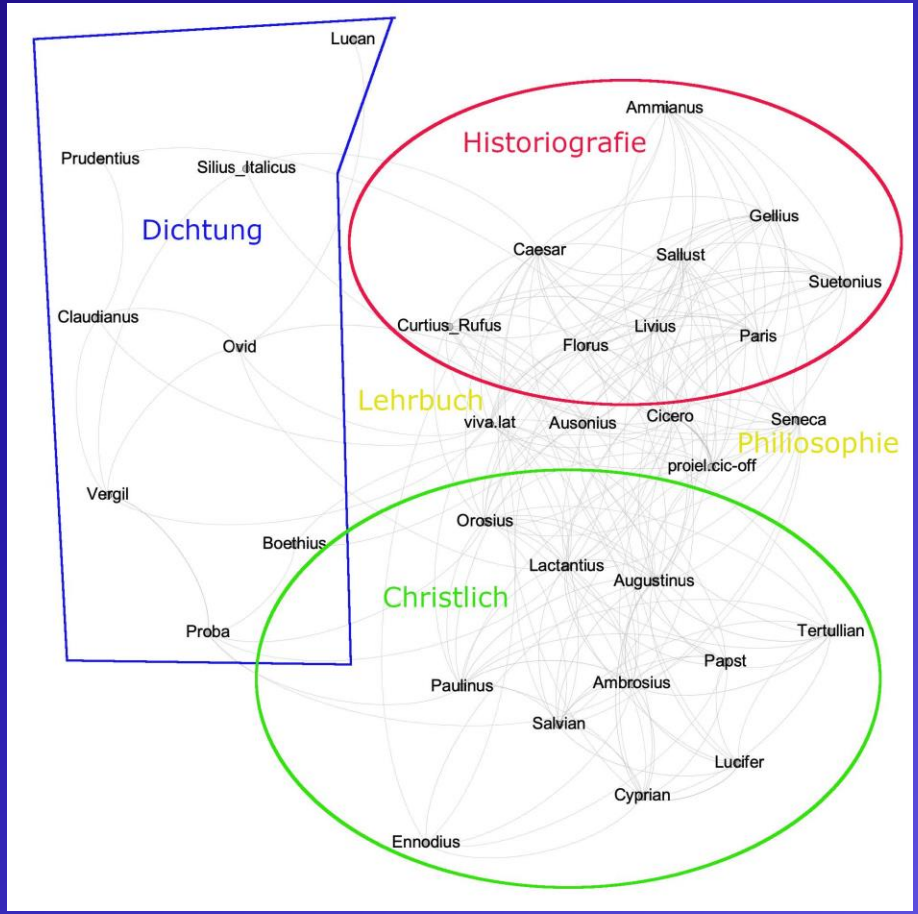

Topic Modelling

Ziel

Exploration versteckter semantischer Strukturen in großen Textkorpora

Einsatz

Vergleich von Texten, Merkmalszuweisung für Autorschaft, Textklassifikation, Motive bzw. Topik

Methoden

regelbasiert, statistisch

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Gewichtung von Themen in den Werken Vergils

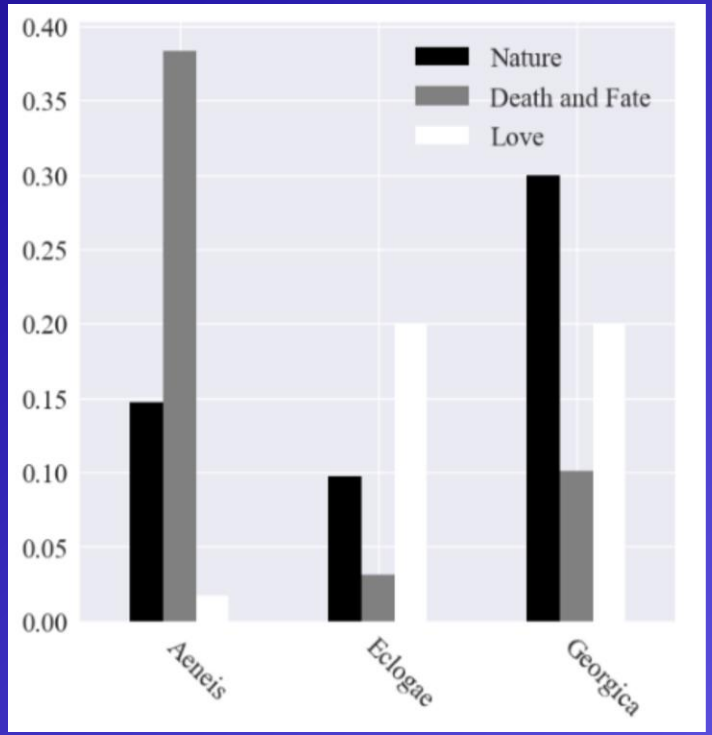

Martinelli et al. 2024, 6932.

Sentiment Analysis

Ziel

Analyse von dargestellten menschlichen Gefühlen, Empfindungen, Meinungen

Einsatz

Bewertung von Meinungen oder Stimmungen im Verhältnis zum Handlungsverlauf, Figurencharakterisierung, Genreklassifikation

Methoden

lexikonbasiert, manuell, statistisch, ML

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

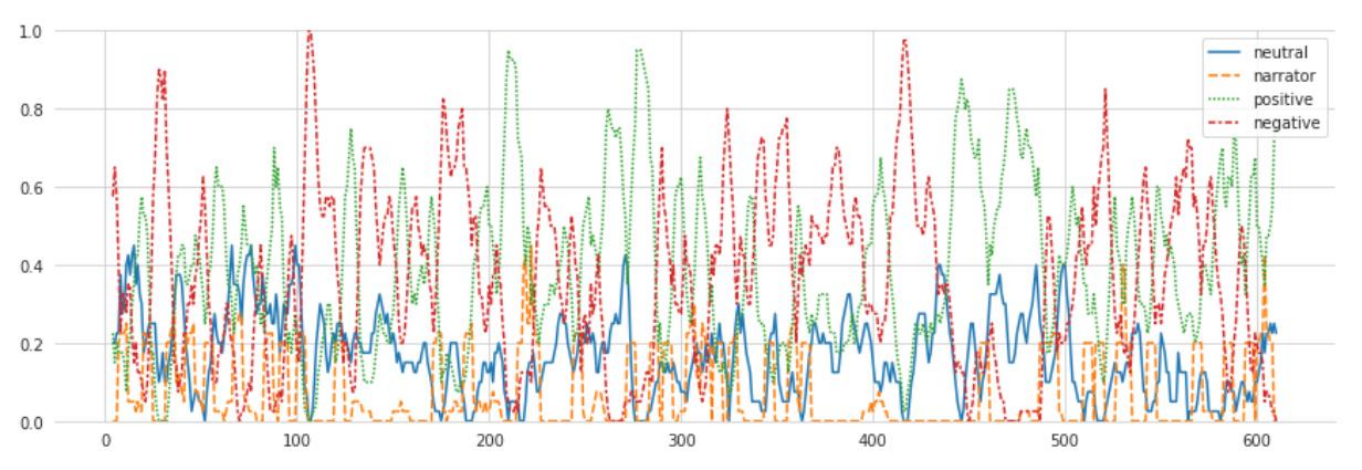

1. Buch der Ilias: Einschätzung der Annotierenden pro Vers

(positiv, negativ, neutral, Erzähler)

Pavlopoulos et al. 2022, 7073.

03 | Word Embeddings: Vektoren als Repräsentation

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Word Embedding

Ziel

Repräsentation eines Wortes (Satzes, Paragraphen, Dokuments) als Vektor

Einsatz

Textanalysen

Methoden

Wörter oder Phrasen aus dem Vokabular werden auf Vektoren mit reellen Zahlen abgebildet

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Beispielsatz	In	*principio*	*erat*	*verbum*	*et*	*verbum*	*erat*
	apud	*deum*	*et*	*deus*	*erat*	*verbum*	

Auftrag	Definiere die Bedeutung eines jeden Worts durch seinen linken und rechten **Nachbarn**.

Schritt 1	Weise jeder einzigartigen Wortform einen Identifikator zu.

In	*principio*	*erat*	*verbum*	*et*	*verbum*	*erat*	*apud*	*deum*	*et*	*deus*	*erat*	*verbum*
1	2	3	4	5	4	3	6	7	5	7	3	4

Wort → Vektor
Schritt 1

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Schritt 2 | Repräsentiere jedes Wort als eine Sequenz von Identifikatoren.

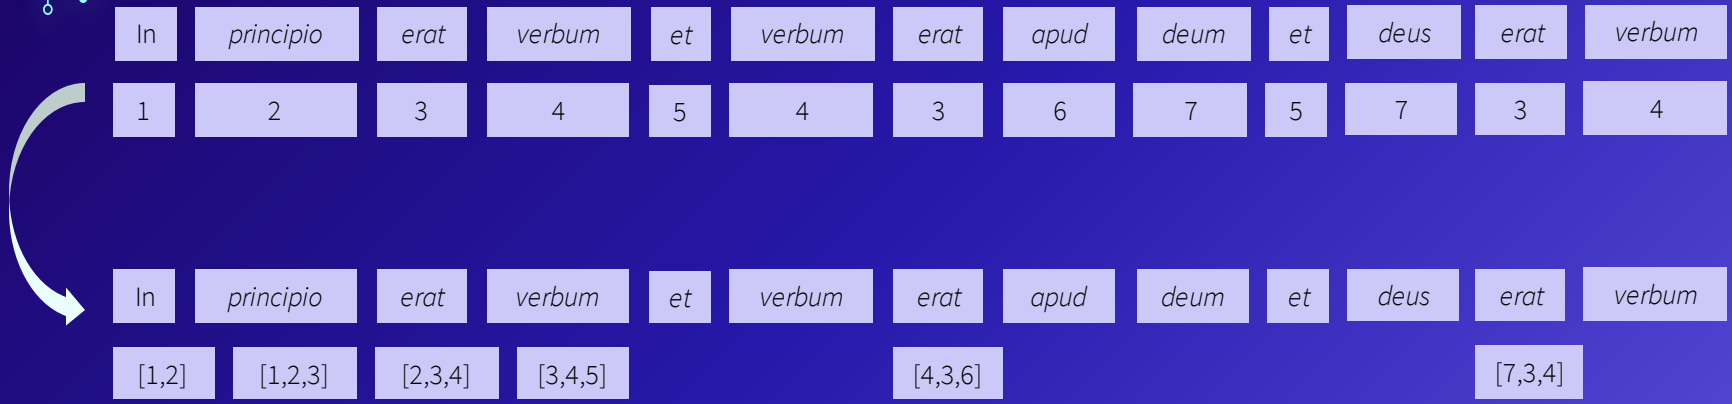

Wort → Vektor
Schritt 2

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Schritt 3	Kombiniere mehrfache Kodierungen derselben Wortform.

In	*principio*	*erat*	*verbum*	*et*	*verbum*	*erat*	*apud*	*deum*	*et*	*deus*	*erat*	*verbum*
		[2,3,4]				[4,3,6]					[7,3,4]	

erat	=	([2,3,4]	+	[4,3,6]	+	[7,3,4])	/ 3	=	7,266
verbum	=	([3,4,5]	+	[5,4,3]	+	[3,4])	/ 3	=	6,381
deus	=	([6,7,5]	+	[5,7,3])			/ 2	=	9,799

Anfrage	Was ist ein typischer Kontext von „*erat*"?
Antwort	*verbum*

Wort → Vektor
Schritt 3

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Worte im Vektorraum

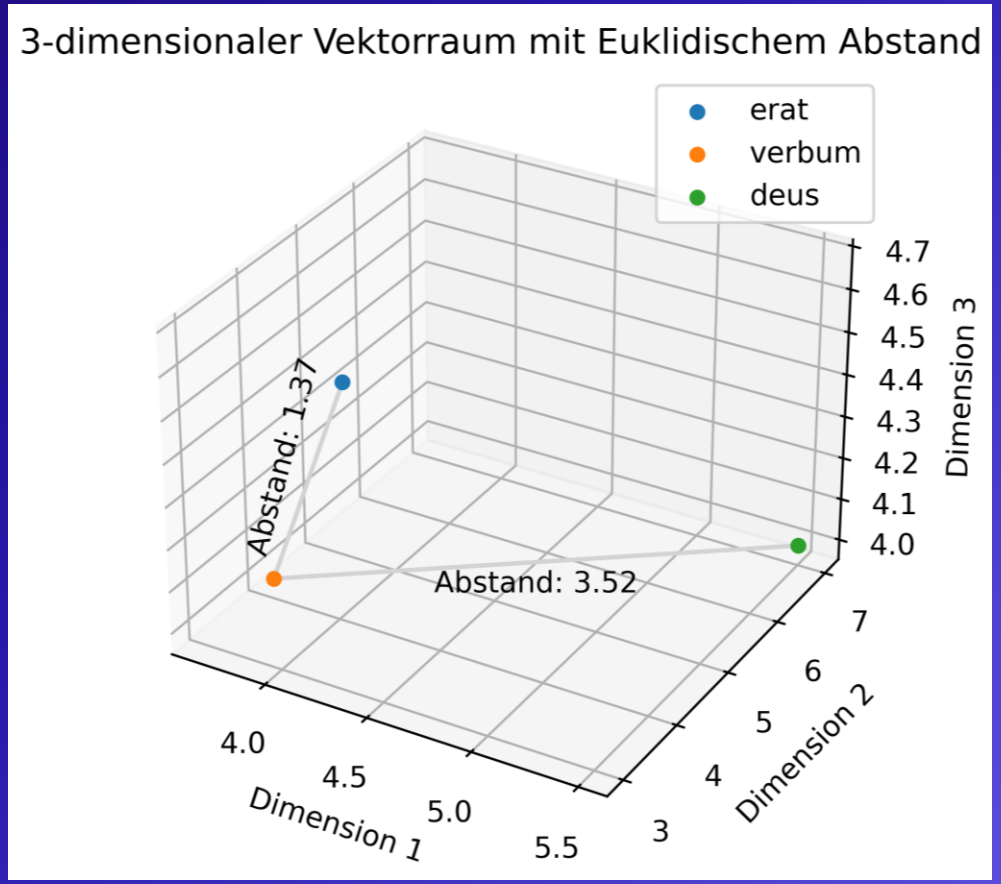

Vektoren und Semantik

- Distanz als Indiz für semantische Relationen
  - Stärke der Verbundenheit
  - Art der Relation (Synonym, Antonym …)
- Nicht alle Wortarten gleichermaßen gut durch Vektoren abbildbar
- Rückschluss von Verteilung auf Funktion
- Mengentheoretische Zuordnungen: "Alle X sind Y"
- Globale vs. kontextualisierte Vektoren
- Qualität des Modells stark abhängig von der Konfiguration

Gries & Divjak 2009, Grefenstette & Sadrzadeh 2011, Baroni & Lenci 2011, Karan et al. 2012, Herbelot & Vecchi 2015, Rodda et al. 2019

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Forschungsfrage

Wie unterscheidet sich das Verständnis der griechischen Polis in der Grabrede aus Platons Menexenos von dem Verständnis in seinen Nomoi?

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

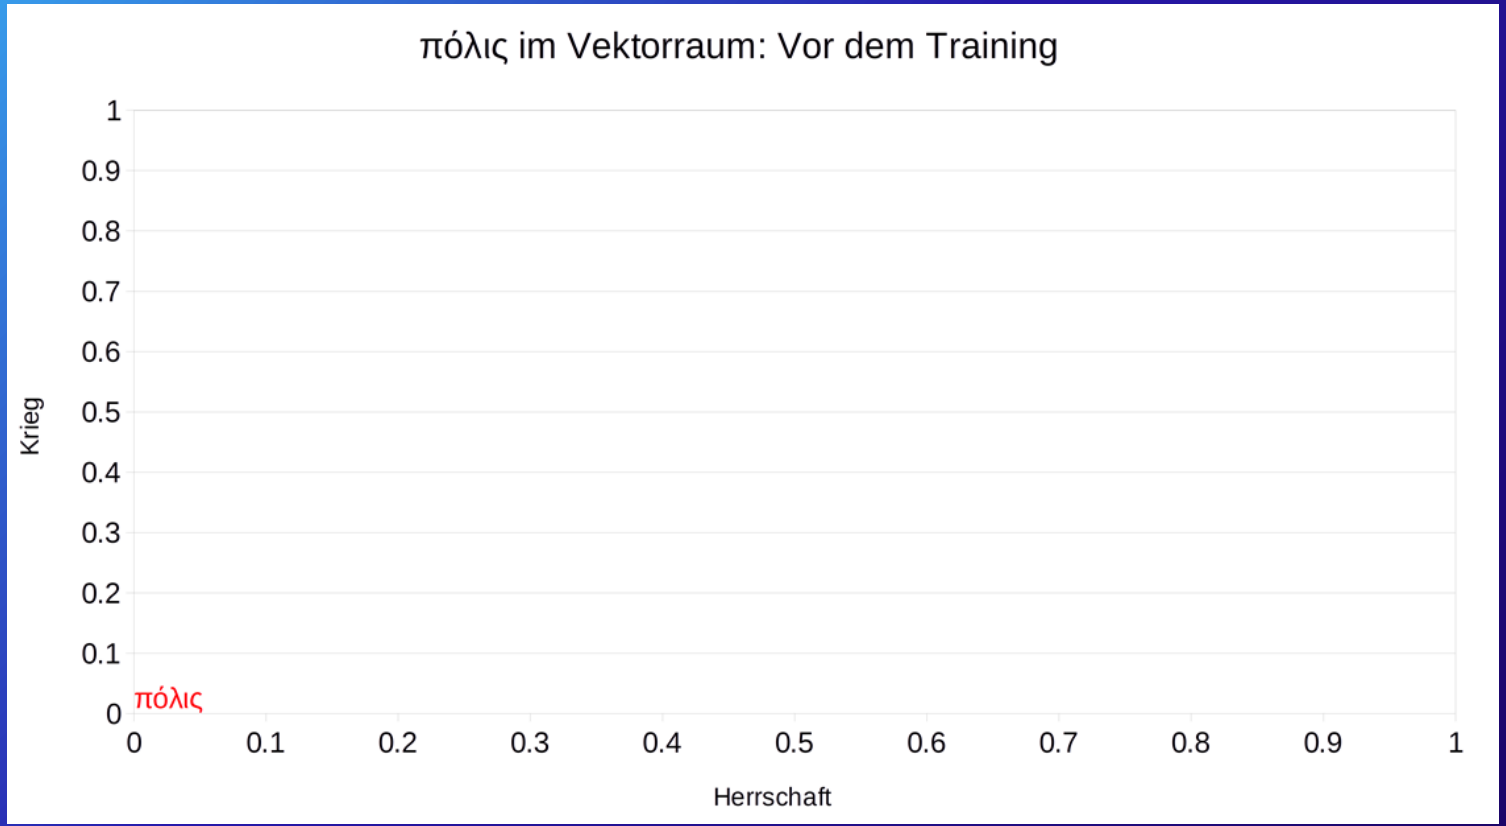
πόλις im Vektorraum: Vor dem Training
Krieg
Herrschaft
πόλις
0
0.1
0.2
0.3
0.4
0.5
0.6
0.7
0.8
0.9
1

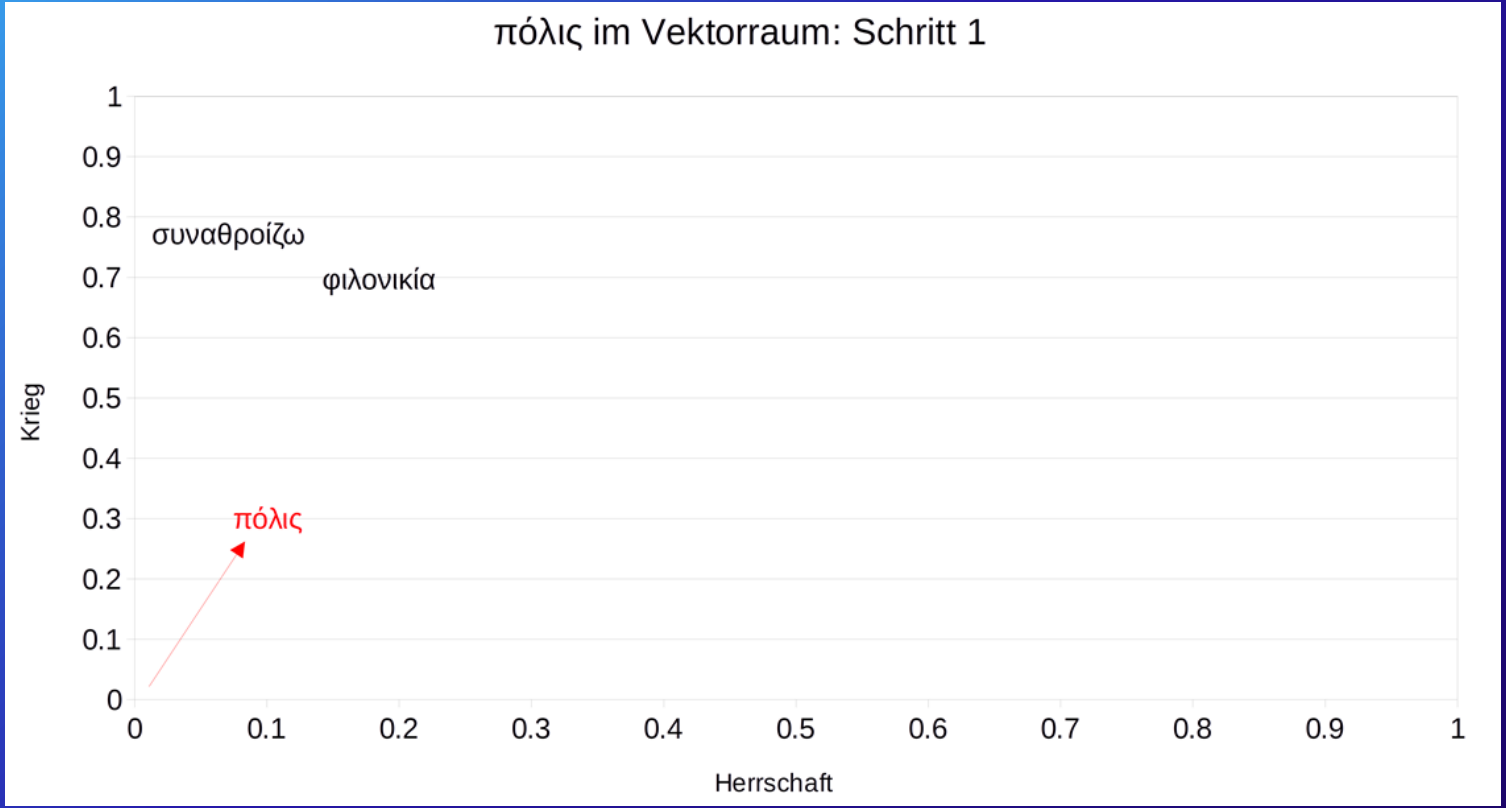

Plat. Mx. 243b: τόδε λέγω τὸ εἰς τοσοῦτον **φιλονικίας** ἐλθεῖν πρὸς τὴν πόλιν τοὺς ἄλλους Ἕλληνας, ὥστε **συναθροῖσαι** ἐπὶ τὴν πόλιν πάντας Ἕλληνάς τε καὶ βαρβάρους.

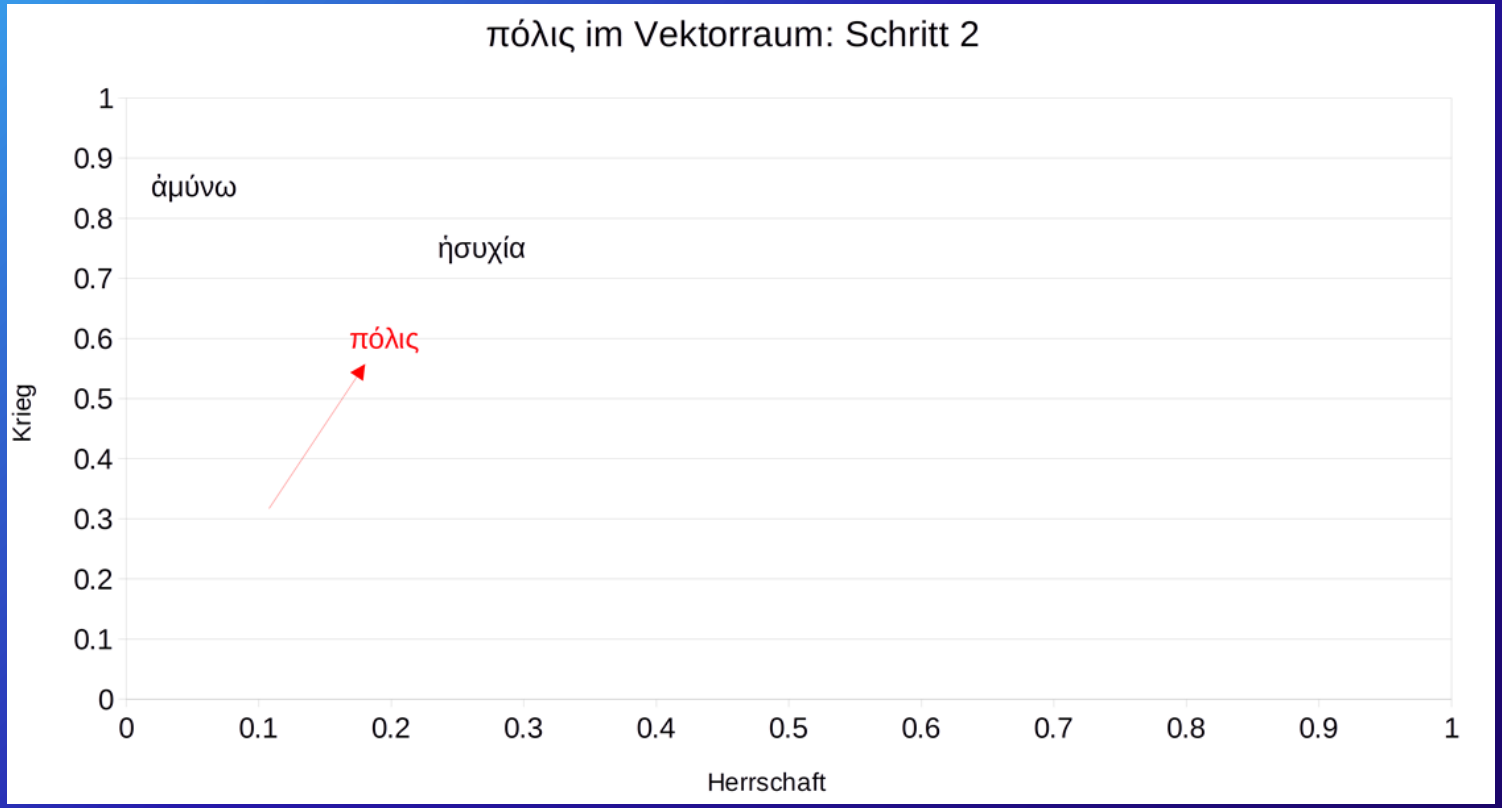

Plat. Mx. 244b–c: μετὰ δὲ τοῦτο **ἡσυχίαν** ἦγεν ἡ πόλις, τοῖς μὲν βαρβάροις συγγιγνώσκουσα, ὅτι παθόντες ὑπ᾽ αὐτῆς κακῶς ἱκανῶς οὐκ ἐνδεῶς **ἠμύναντο**.

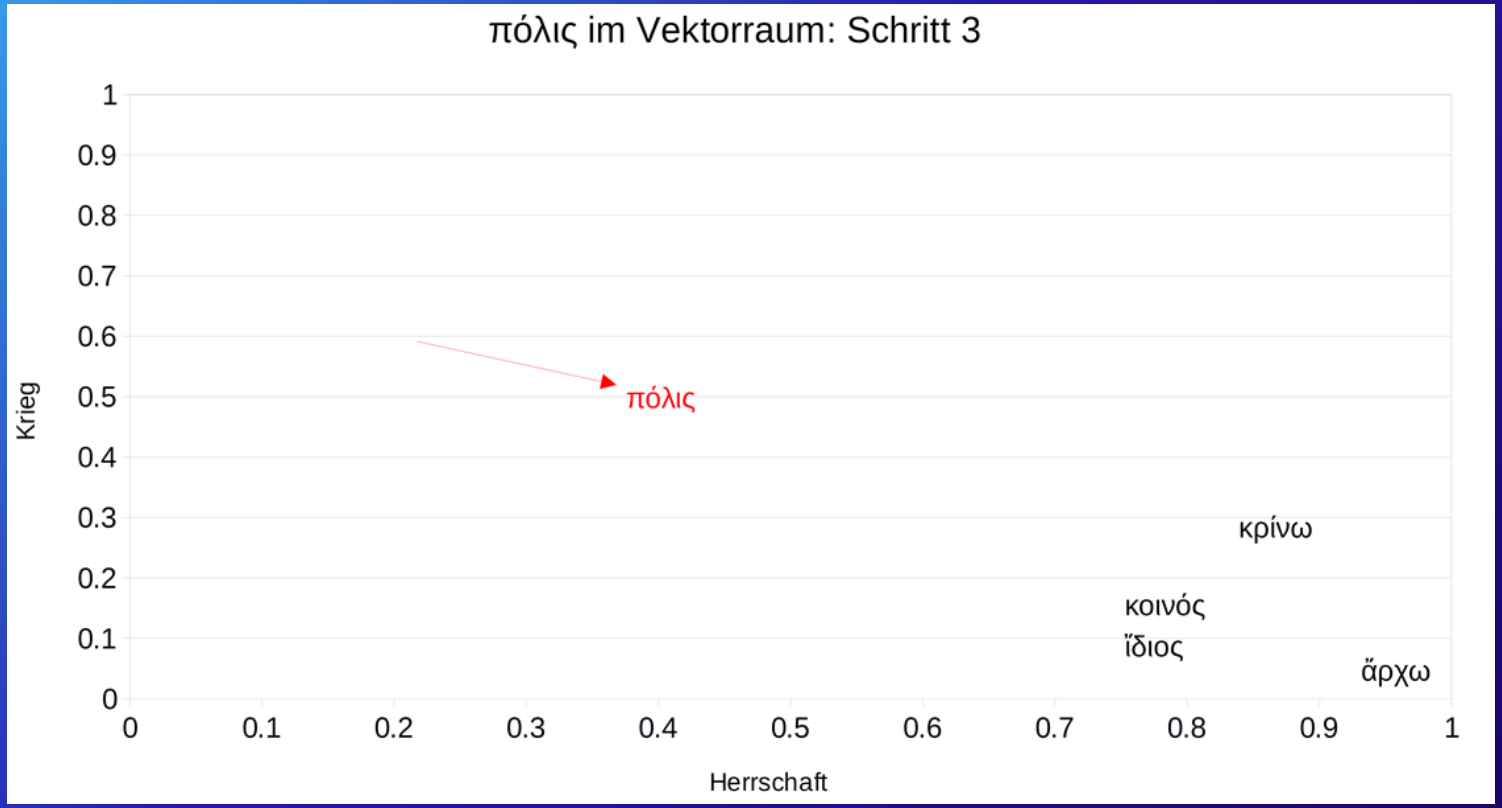

Plat. leg. 946d: καὶ τὰ μὲν **ἰδίᾳ** ἕκαστος, τὰ δὲ καὶ **κοινῇ** μετ᾽ ἀλλήλων **κρίναντες** τοὺς **ἄρξαντας** τῇ πόλει, ἀποφηνάντων ὅτι χρὴ παθεῖν ἢ ἀποτίνειν.

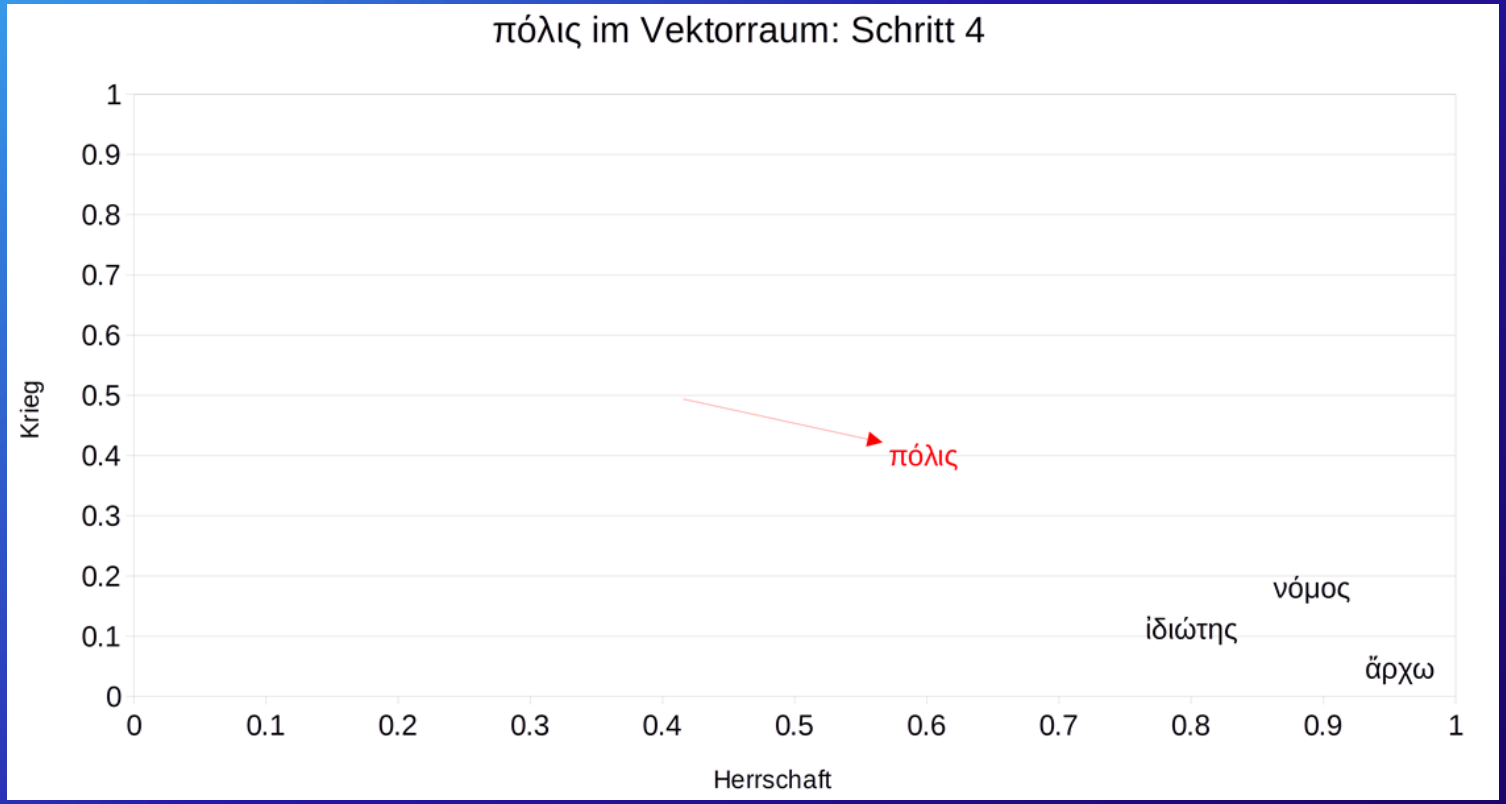

Plat. leg. 714a: εἰ δ’ ἄνθρωπος εἷς **ἄρξει** δὴ πόλεως ἢ τινος **ἰδιώτου** καταπατήσας ὁ τοιοῦτος τοὺς **νόμους**, ὃ νυνδὴ ἐλέγομεν, οὐκ ἔστι σωτηρίας μηχανή.

πόλις im Vektorraum

Zwischenergebnis

Spannungsfeld aus Krieg und Herrschaft

Beobachtung

Wörter im Kontext beeinflussen die Position von πόλις

Erkenntnis

Jeder weitere Satz führt zu einer weiteren Bewegung im Vektorraum.

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Methodendiskussion

Beispiel Wortanalogien:
vir = fortis und mulier = ???

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Erwartung: *vir* = *fortis* und *mulier* = ???

Mann + positive Eigenschaft
sowie
Frau + positive Eigenschaft

→ erwartetes Ergebnis z.B. *pudicus*

→ Ergebnis: *imprudens*

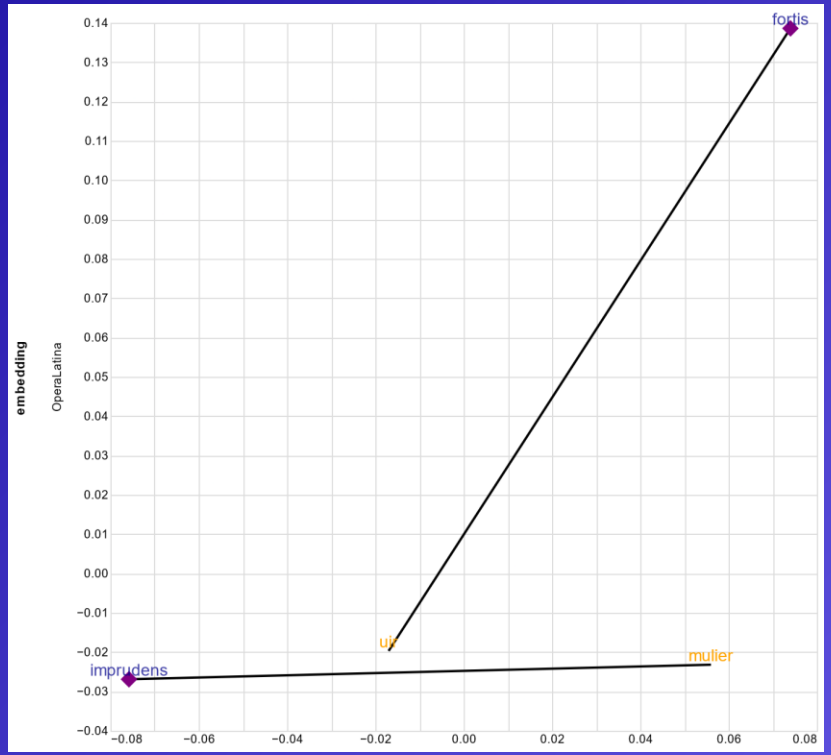

OperaLatina-Korpus auf Basis des LASLA-Korpus, Texte klassischer Zeit, rund 1.700.000 Wörter. Verwendetes Tool: https://embeddings.lila-erc.eu

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Zusammenfassung

- Erwartetes vs. vektorbasiertes Ergebnis
  a. Unterschiedliche Erschließungsmethoden
  b. Historisches Wissen vs. Berechnung der Distanzen/Vektoren
- Datenbias und User-Bias
- deterministisch reproduzierbar: Visualisierung vs. Embeddings
- Einfluss von Morphologie auf vektorbasierte Analogien: *fortis* vs. *imprudens* >> Adjektiv, oft attributiv
- Analogien fallspezifisch, nur zwischen kohärenten Wortklassen
- nicht alle Typen von linguistischen Analogien gleichermaßen abgebildet

→ Wert und Mehrwert
  - neue Perspektiven auf Bekanntes
  - Bearbeitung umfangreicher Korpora mit gleichbleibender Genauigkeit

Gladkova et al. 2016, Rogers et al. 2017

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

04 | Embeddings in der Klassischen Philologie

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Beispiel 1: Autorschaft

Wer ist der Autor des *Commentariolum petitionis*, das Q. Cicero zugeschrieben wird?

NLP-Methoden: Text Classification, Part-of-Speech Tagging, **Word Embeddings**

Vainio et al. 2019: *Reconsidering Authorship in the Ciceronian Corpus through Computational Authorship Attribution.*

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Commentariolum typisch für Stil von M. Cicero

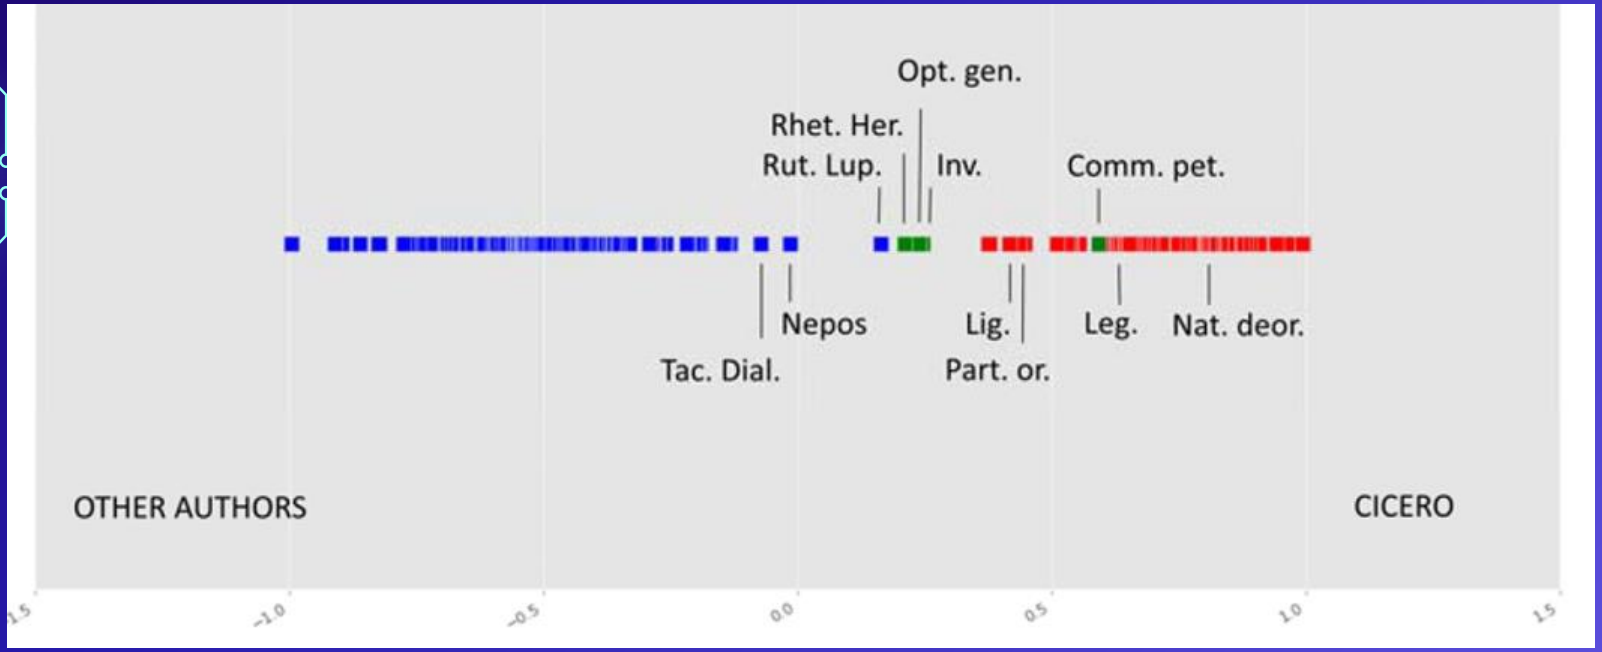

Texte werden auf einer Skala nach ihrem Klassifizierungswert dargestellt: Positive Werte weisen auf eine ciceronische und negative auf eine nicht-ciceronische Autorschaft hin (Null markiert die Schwelle).
Arbeit mit zwei Korpora (Cicero-Korpus + Referenzkorpus)

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Ergebnis

„Commentariolum petitionis **was written**, at least largely, by **Marcus Cicero**. It is possible that his brother Quintus participated in writing it, but we do not consider any major input by him probable, since **it would be unlikely that the brothers had such a uniform style as that in the text**, and since our analyses very strongly indicate a Ciceronian authorship.” (Vainio et al. 2019, 37)

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Beispiel 2: Analyse eines Konzepts

Was kann man über das Konzept Schmerz in der klassischen griech. Antike mittels maschineller Wortfeldanalysen erfahren?

NLP-Methoden: Lemmatisierung (Lexikon-basiert), **Word Embeddings**, Methodenmix mit manueller Wortklassifikation

Linka, V. & V. Kaše, 2023: Pain in Classical Greek Texts.

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Wortfamilien für „Schmerz“ entdecken

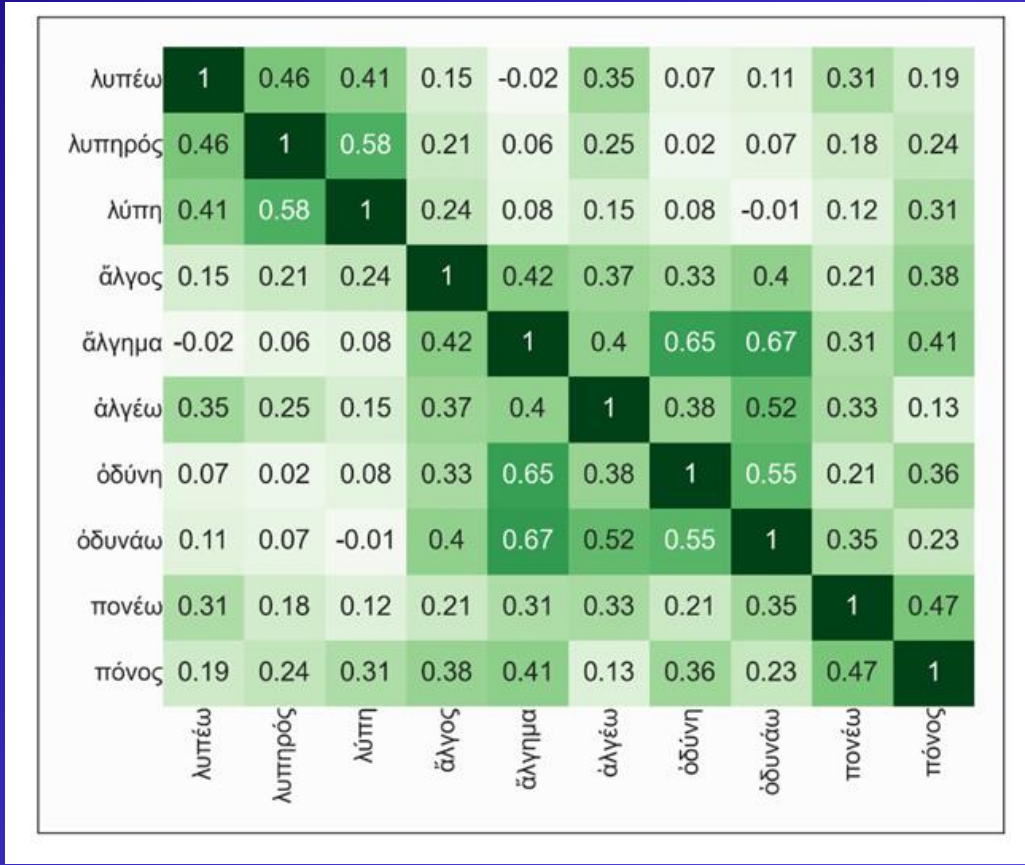

Wert 1 = identisch
Positive Werte = ähnlich
Negative Werte = unähnlich

Heatmap: Je dunkler das Grün, desto ähnlicher sind sich zwei Wörter.

„Schmerz“ nach Kategorien

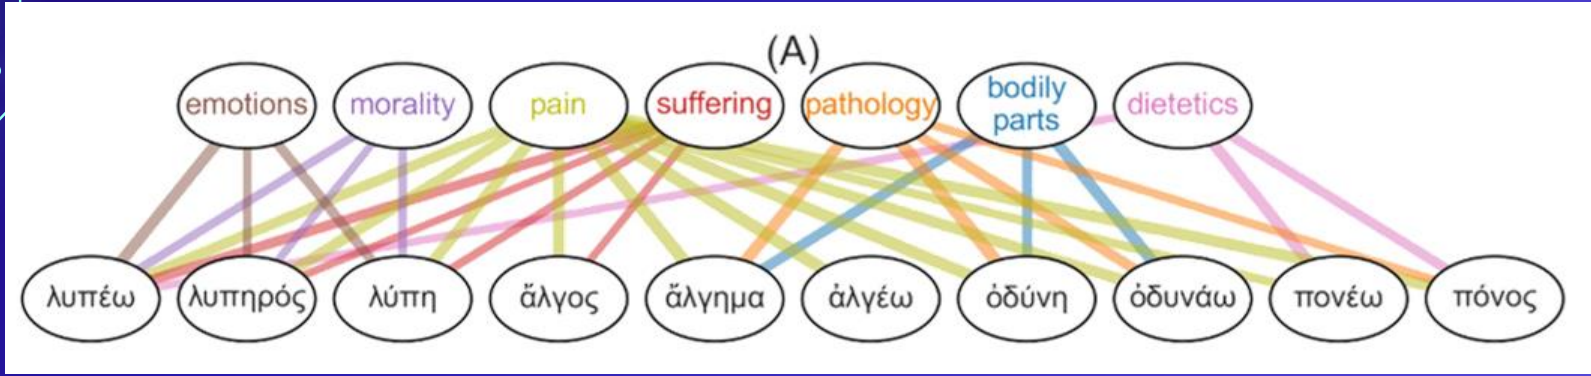

Assoziation zwischen Schmerzwörtern und ausgewählten semantischen Kategorien, berechnet mittels Kosinus-Ähnlichkeit, die ein Maß für die Ähnlichkeit zweier Vektoren ist. Stärkere Linien bedeuten ein höheres Ausmaß an Ähnlichkeit.

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Ergebnis

„Although all four pain word families were used for denoting pain, we have shown that their **meanings differ significantly according to the features of pain** that they associate with. […] Then we saw how particular pain word families **differ in their associations to semantic categories**: λυπ* is close to emotions and morality, ἀλγ* and ὀδυν* to bodily parts and pathologies, πον* to dietetics.” (Linka & Kaše, 2023, 12)

Beispiel 3: Intertextualität

Wie kann man in lateinischen Texten Anspielungen auf altgriechische Literatur maschinell finden?

NLP-Methoden: Multilingual **Sentence Embeddings**, Machine Translation

Riemenschneider, F. & A. Frank, 2023: *Graecia capta ferum victorem cepit. Detecting Latin Allusions to Ancient Greek Literature*.

dAIdalos — Digital Research for All —
Gefördert durch DFG Deutsche Forschungsgemeinschaft

Fallstudie: *Aeneis* und *Odyssee*

Entsprechende sprachübergreifende Begriffspaare wurden mit individuellen Farben markiert.

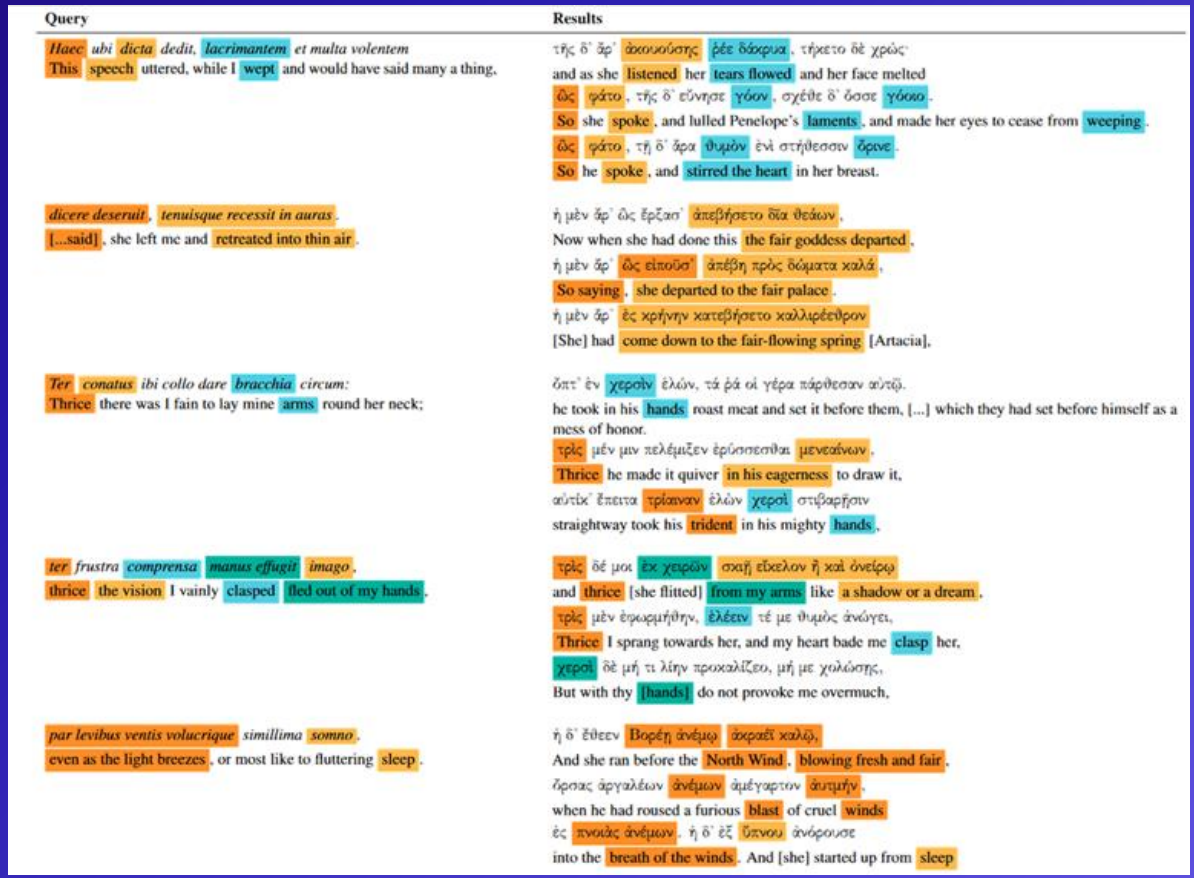

Query	Results
Haec ubi dicta dedit, lacrimantem et multa volentem This speech uttered, while I wept and would have said many a thing,	τῆς δ᾽ ἄρ᾽ ἀκουούσης ῥέε δάκρυα, τήκετο δὲ χρώς· and as she listened her tears flowed and her face melted ὣς φάτο, τῆς δ᾽ εὖνησε γόον, σχέθε δ᾽ ὄσσε γόοιο. So she spoke, and lulled Penelope's laments, and made her eyes to cease from weeping. ὣς φάτο, τῇ δ᾽ ἄρα θυμὸν ἐνὶ στήθεσσιν ὄρινε. So he spoke, and stirred the heart in her breast.
dicere deseruit, tenuisque recessit in auras. [...said], she left me and retreated into thin air.	ἡ μὲν ἄρ᾽ ὣς ἔρξασ᾽ ἀπεβήσετο δῖα θεάων. Now when she had done this the fair goddess departed. ἡ μὲν ἄρ᾽ ὣς εἰποῦσ᾽ ἀπέβη πρὸς δώματα καλά. So saying, she departed to the fair palace. ἡ μὲν ἄρ᾽ ἐς κρήνην κατεβήσετο καλλιρέεθρον [She] had come down to the fair-flowing spring [Artacia].
Ter conatus ibi collo dare bracchia circum: Thrice there was I fain to lay mine arms round her neck;	ὀπτ᾽ ἐν χερσὶν ἑλών, τά ῥά οἱ γέρα πάρθεσαν αὐτῷ. he took in his hands roast meat and set it before them, [...] which they had set before himself as a mess of honor. τρὶς μέν μιν πελέμιξεν ἐρύσσασθαι μενεαίνων. Thrice he made it quiver in his eagerness to draw it, αὐτίκ᾽ ἔπειτα τρίαιναν ἑλὼν χερσὶ στιβαρῇσιν straightway took his trident in his mighty hands,
ter frustra comprensa manus effugit imago, thrice the vision I vainly clasped fled out of my hands.	τρὶς δέ μοι ἐκ χειρῶν σκιὴ εἴκελον ἢ καὶ ὀνείρῳ and thrice [she flitted] from my arms like a shadow or a dream. τρὶς μὲν ἐφορμήθην, ἐλέειν τέ με θυμὸς ἀνώγει, Thrice I sprang towards her, and my heart bade me clasp her, χερσὶ δὲ μή τι λίην προκαλίζεο, μή με χολώσῃς, But with thy [hands] do not provoke me overmuch,
par levibus ventis volucrique simillima somno, even as the light breezes, or most like to fluttering sleep.	ἡ δ᾽ ἔθεεν Βορέῃ ἀνέμῳ ἀκραέϊ καλῷ, And she ran before the North Wind, blowing fresh and fair, ὄρσας ἀργαλέων ἀνέμων ἀμέγαρτον ἀυτμήν, when he had roused a furious blast of cruel winds ἐς πνοιὰς ἀνέμων. ἡ δ᾽ ἐξ ὕπνου ἀνόρουσε into the breath of the winds. And [she] started up from sleep

Ergebnis

„[…], our case study demonstrates the proficiency of our models in **recognizing sentence structures** and **translating them to a different language** […], and in **identifying common topics or concepts across languages**, even locating verses where multiple relevant concepts exist within the same verse […], our SPHILBERTA model can serve as a useful **tool for automatic first-pass exploration of potential cross-lingual intertextual allusions**, […].” (Riemenschneider & Frank 2023, 8)

Bibliographie

- Baroni, Marco, and Alessandro Lenci. 2011. "How We BLESSed Distributional Semantic Evaluation." In Proceedings of the GEMS 2011 Workshop on GEometrical Models of Natural Language Semantics, 1–10. Association for Computational Linguistics. https://www.aclweb.org/anthology/W11-2501
- Bengfort, B., T. Ojeda, & R. Bilbro, 2018: Applied Text Analysis with Python: Enabling Language-Aware Data Products with Machine Learning. Boston: O'Reilly.
- Dale, R., 2010: Classical Approaches to Natural Language Processing. Handbook of Natural Language Processing. Hrsg. von N.Indurkhya & F. J. Damerau. CRC Press, Taylor & Francis Group, 3–7.
- Forstall, C. & Scheirer, W. (2019): Quantitative Intertextuality. Cham.
- Gladkova, Anna, Aleksandr Drozd, and Satoshi Matsuoka. 2016. "Analogy-Based Detection of Morphological and Semantic Relations with Word Embeddings: What Works and What Doesn't." In Proceedings of the NAACL Student Research Workshop, 8–15. https://www.aclweb.org/anthology/N16-2002
- Grefenstette, Edward, and Mehrnoosh Sadrzadeh. 2011. "Experimental Support for a Categorical Compositional Distributional Model of Meaning." arXiv Preprint arXiv:1106.4058. https://arxiv.org/pdf/1106.4058.pdf
- Gries, Stefan Th, and Dagmar Divjak. 2009. "Behavioral Profiles: A Corpus-Based Approach to Cognitive Semantic Analysis." New Directions in Cognitive Linguistics, 57–75. https://pdfs.semanticscholar.org/bedf/34474970f22b87605659f939732cbf1b2b4b.pdf
- Herbelot, Aurélie, and Eva Maria Vecchi. 2015. "Building a Shared World: Mapping Distributional to Model-Theoretic Semantic Spaces." In Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing, 22–32. https://www.aclweb.org/anthology/D15-1003
- Karan, Mladen, Jan Šnajder, and Bojana Dalbelo Bašic. 2012. "Distributional Semantics Approach to Detecting Synonyms in Croatian Language." Information Society, 111–16. https://pdfs.semanticscholar.org/acc4/70ec10cdcc2aa720fd2c02407332ddcf2fbf.pdf
- Köntges, Th., 2020: Measuring Philosophy in the First Thousand Years of Greek Literature. Digital Classics Online 1–23. https://doi.org/10.11588/dco.2020.2.73197
- Linka, V. & V. Kaše, 2023: Pain in Classical Greek Texts. Digital Classics Online 1–14. https://journals.ub.uni-heidelberg.de/index.php/dco/article/view/93792/90156
- Martinelli, Ginevra, Paola Impicciché, Elisabetta Fersini, Francesco Mambrini, and Marco Passarotti. 2024. "Exploring Neural Topic Modeling on a Classical Latin Corpus." In , 6929–34
- Pavlopoulos, J., Xenos, A., & Picca, D. (2022). Sentiment Analysis of Homeric Text: The 1st Book of Iliad. 7071–7077. https://aclanthology.org/2022.lrec-1.765.pdf
- Riemenschneider, Frederick & Anette Frank. 2023: Graecia capta ferum victorem cepit. Detecting Latin Allusions to Ancient Greek Literature. https://arxiv.org/pdf/2308.12008.pdf
- Rodda, M, Philomen Probert, and Barbara McGillivray. 2019. "Vector Space Models of Ancient Greek Word Meaning, and a Case Study on Homer." Traitement Automatique Des Langues 60 (3)
- Rogers, Anna, Aleksandr Drozd, and Bofang Li. 2017. "The (Too Many) Problems of Analogical Reasoning with Word Vectors." In Proceedings of the 6th Joint Conference on Lexical and Computational Semantics (* SEM 2017), 135–48. https://www.aclweb.org/anthology/S17-1017
- Stüssi, E., & Ströbel, P. B. (2024). Part-of-Speech Tagging of 16th-Century Latin with GPT. Proceedings of LaTeCH-CLfL 2024, 196–206. https://aclanthology.org/2024.latechclfl-1.18.pdf
- Vainio, Raija, Reima Välimäki, Aleksi Vesanto, Anni Hella, Marjo Kaartinen, & Teemu Immonen. 2019: Reconsidering Authorship in the Ciceronian Corpus through Computational Authorship Attribution. Ciceroniana online 3:1.15–48. https://ojs.unito.it/index.php/COL/article/view/3518/3182

dAIdalos — Digital Research for All —

Gefördert durch DFG Deutsche Forschungsgemeinschaft