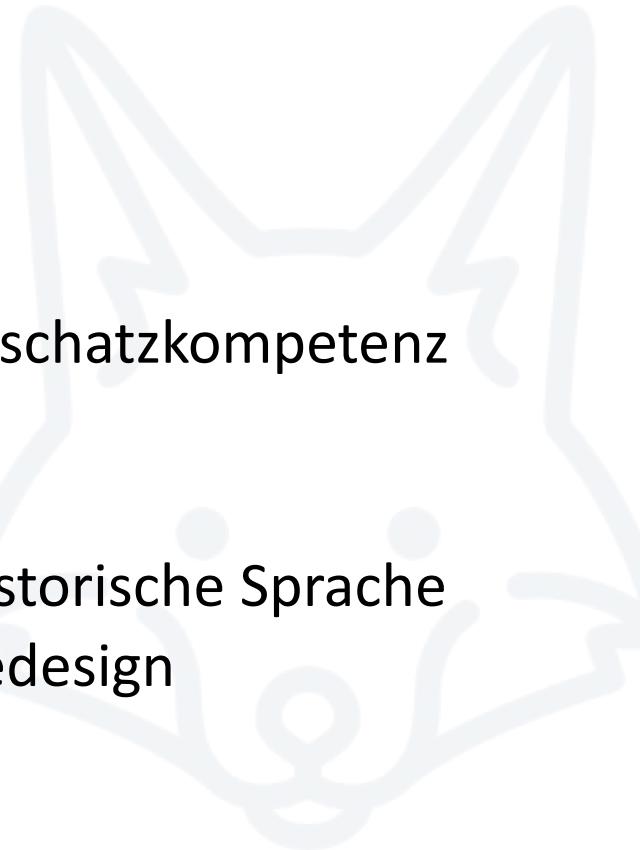




# CALLIDUS

Einsatz von Korpora im Erwerb historischer Sprachen

# Themen

- 
1. Motivation
  2. Fragliche Prämissen
  3. Ein Weg zu besserer Wortschatzkompetenz
  4. Korpora
  5. Forschungsfragen
  6. Probleme für Latein als historische Sprache
  7. Machina Callida: Softwaredesign
    - a) Korpora
    - b) Zitationsmodell
    - c) Suchfunktion
    - d) Vokabelfilter
  8. Übungsdesign

# 1. Motivation

- Gegenwärtige **Situation** des Lateinunterrichts
  - **Selten** spezifische Wortschatzarbeit
  - sprachübergreifende **Wortgleichungen**
    - Keine einheitlichen Gütekriterien, basieren oft nur auf **rohen Frequenzen**
    - **Übersetzung** = Wortschatzkompetenz
    - **Dekontextualisierte** Einzelwörter
- res = Ding
  - res publica = öffentliches Ding ?
  - res familiares = familienartiges Ding ?
  - res frumentaria = getreidehaftes Ding ?



## 2. Fragliche Prämissen (I)

1. Fremdspracherwerb dient der Fähigkeit zur Kommunikation.  
⚡ **Rezeption und Sprachreflexion** als Ziele des Lateinunterrichts
2. Im Fremdspracherwerb sollte der aktive, passive und **potentielle Wortschatz** gefördert werden, am meisten jedoch der aktive.  
⚡ aktiver eher unwichtig, potentieller bei Latein besonders wichtig (Derivation, Etymologien etc.)
3. Im Lateinunterricht wird hauptsächlich Latein gelernt.  
⚡ Ziele (Latein) vs. tatsächliche Effekte des LU (**Deutsch**)

## 2. Fragliche Prämissen (II)

4. Der Spracherwerb ist zu Beginn der Lektürephase im Wesentlichen abgeschlossen.

⚡ **Lektüre-“Schock”**, lebenslanger Spracherwerb

5. In der Lektürephase wird lateinische Literatur in umfangreicherem Maß gelesen und rezipiert.

⚡ mehr **Formenbestimmung** & Übersetzung als Leseverständnis

6. Die römische Kultur ist weit genug entfernt, um objektiv studiert zu werden.

⚡ kulturelle **Interferenzen** bei einzelnen Konzepten und bei der Textinterpretation

# 3. Ein Weg zu besserer Wortschatzkompetenz

- Entwicklung einer Umgebung für lateinische Wortschatzarbeit
  - **Regelmäßige** explizite Wortschatzarbeit im Unterricht (und außerhalb)
  - **Kontextualisierte** Übungen
  - Nachhaltig **vernetzt**
- Voraussetzungen
  - Systematische Analyse der **empirischen** Grundlagen
  - **Dynamische** Anpassung an die jeweiligen Gegebenheiten
    - **Verfügbarkeit:** mobil oder stationär, selbstständig oder in Gruppen
    - **Zielorientierung:** je nach zu rezipierendem Text
    - **Vorwissen:** je nach Stand des individuellen Wortschatzerwerbs

# 4. Korpora

- „any collection of written or spoken texts“
- **authentische Sprache**
- hohe Phänomenfrequenz
- **Kontext**
- **Variation & historische Linguistik**
- **Distribution von sprachlichen Phänomenen**
- sprachliche **Muster**, z.B. Kollostruktionen
- **Verfügbarkeit**

Definition: Lüdeling & Kytö 2008; Authentische Sprache & Phänomenfrequenz: Campoy et al. 2010, Gilquin & Granger 2010; Kontext: Gardner 2007; Variation: Ajmer 2009; historische Linguistik: Hundt et al. 2012; Distribution: Brysbaert & New 2009, Lijffijt et al. 2011, Gries 2013; sprachliche Muster allgemein: O’Keeffe et al. 2007; Kollostruktionen: Schmid & Küchenhoff 2013; Verfügbarkeit: Römer 2009

# 5. Forschungsfragen

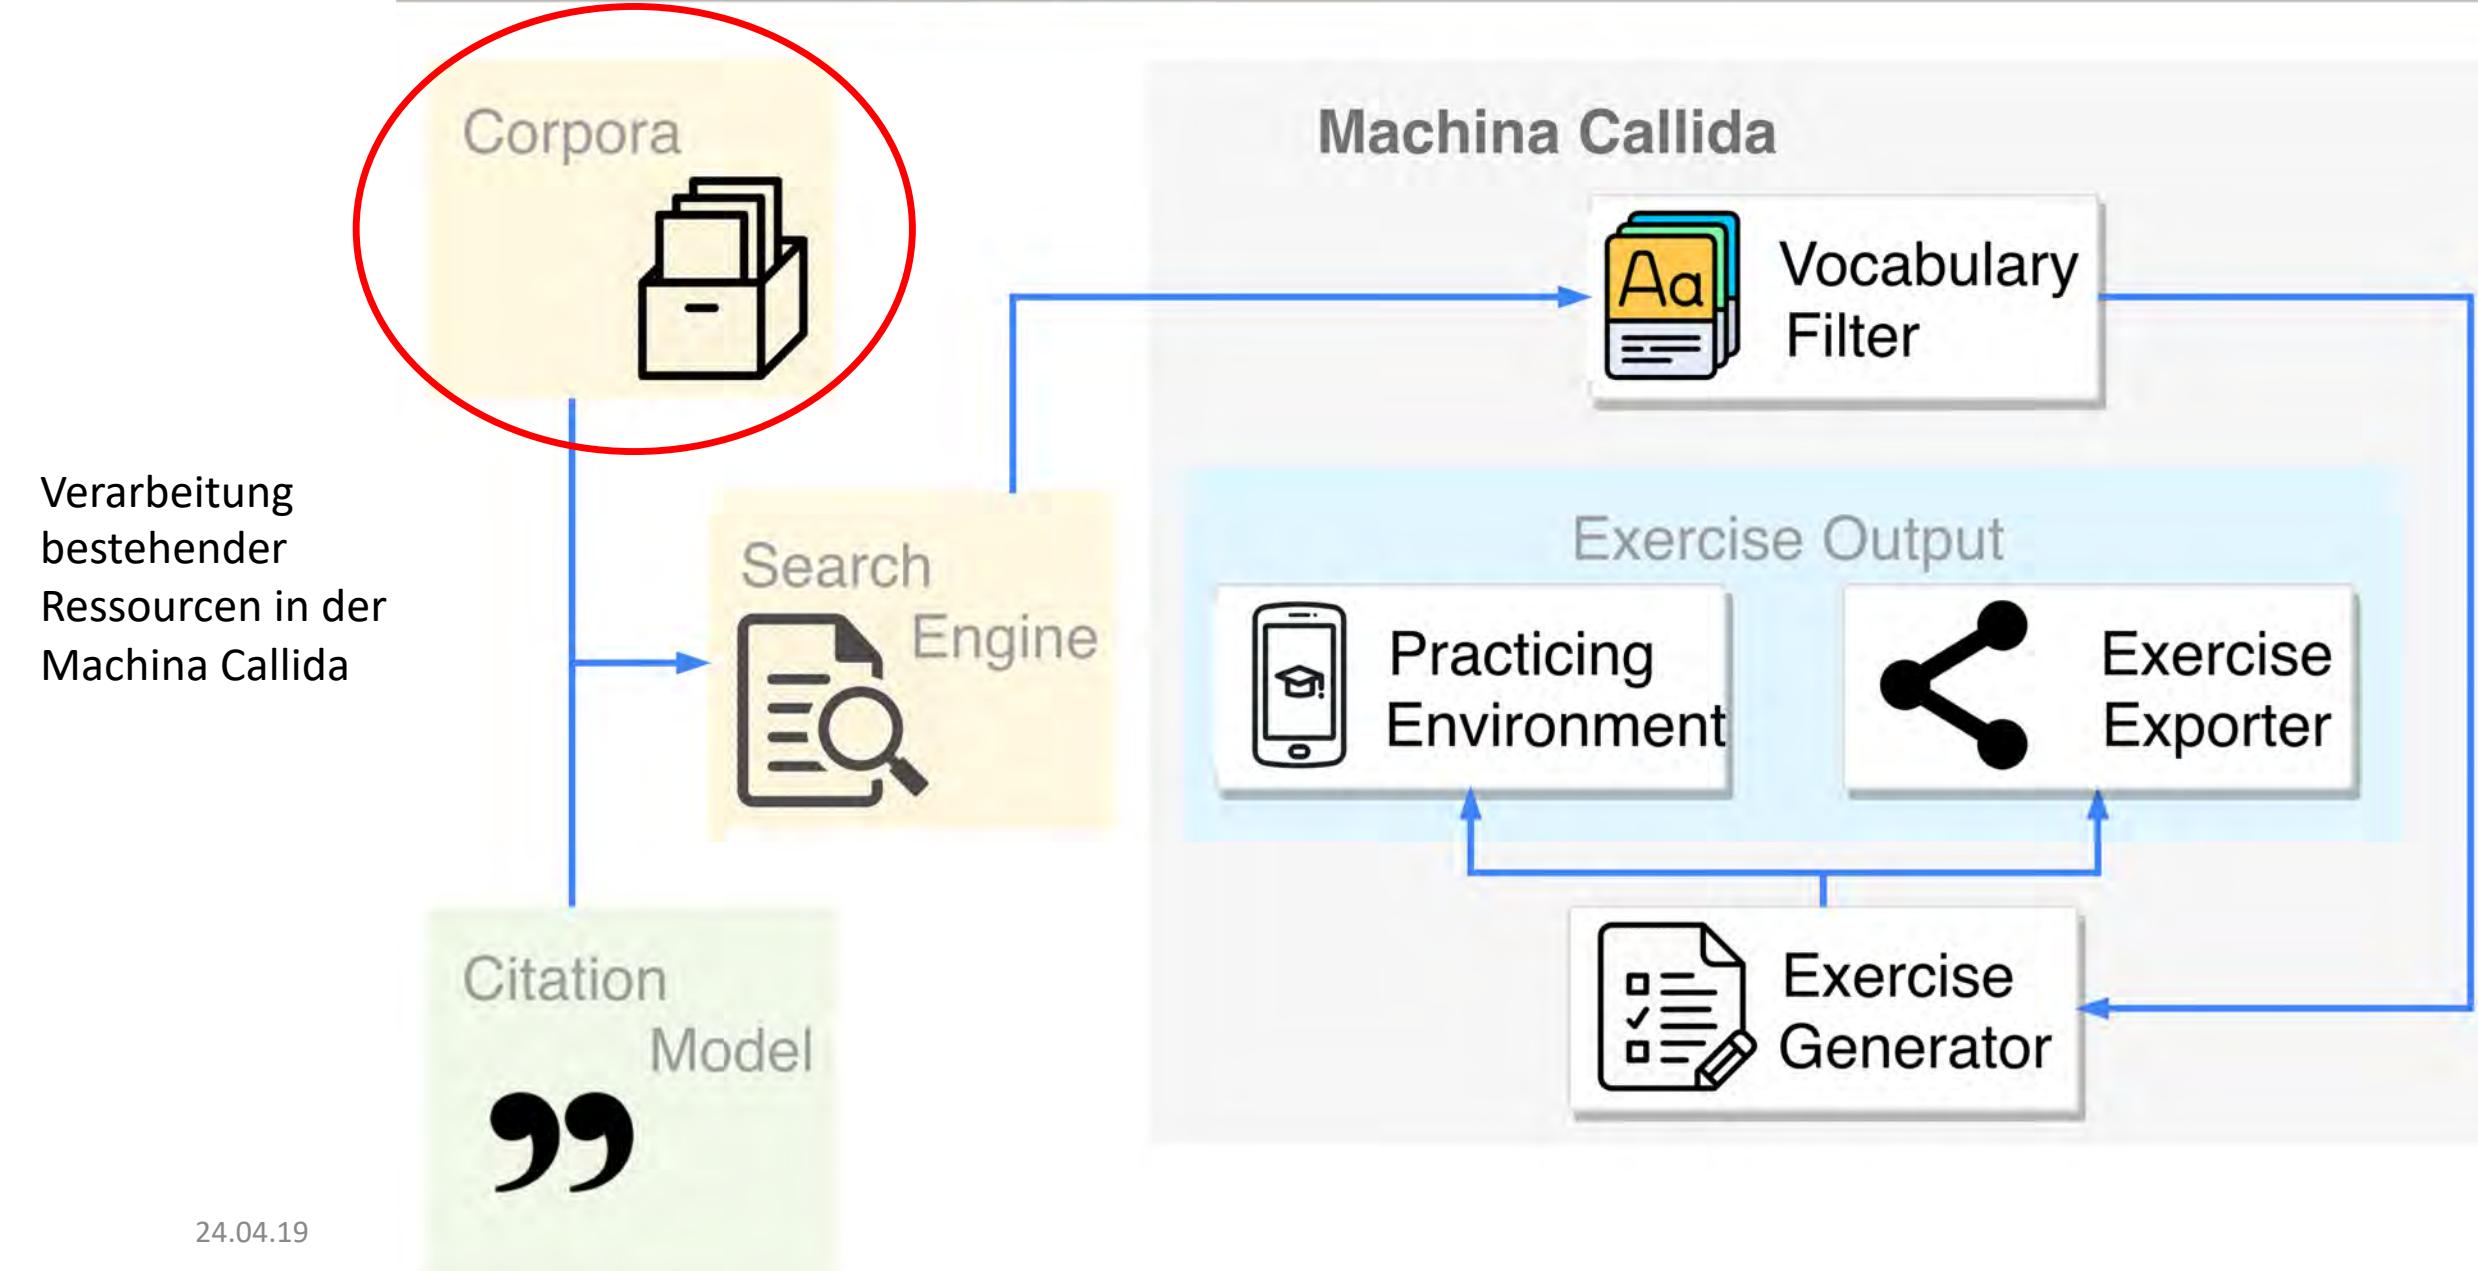
- Wie können bereits **vorhandene Ressourcen** (z.B. Korpora) für den lateinischen **Wortschatzerwerb** in Schulen eingesetzt werden?
- Lexikalische **Informationen**:
  - Wie können sie aus problematischen Texten **gewonnen** werden?
  - Wie können sie zur Unterstützung des lateinischen Wortschatzerwerbs eingesetzt werden?
- ... und einige andere mehr:
  - Softwaredesign
  - Übungsdesign
  - kognitive Progression
  - etc.

# 6. Probleme für Latein als historische Sprache

| Probleme   | Lösungsansätze  |
|--|---|
| Keine L1-Lernenden → fehlende Goldstandards für Korpora  | Annotation durch Forschende und Studierende; Crowdsourcing / Cyberscience |
| Geringe Datenbasis<br>→ statistisch generalisierende Modelle schwer anwendbar                    | Vereinheitlichung der Annotationsformate                                  |
| Starke Diachronie<br>→ höhere Variation<br>→ schwerer verarbeitbar für maschinelle Sprachmodelle | Normalisierung, Klassizismus  |

# 7. Machina Callida

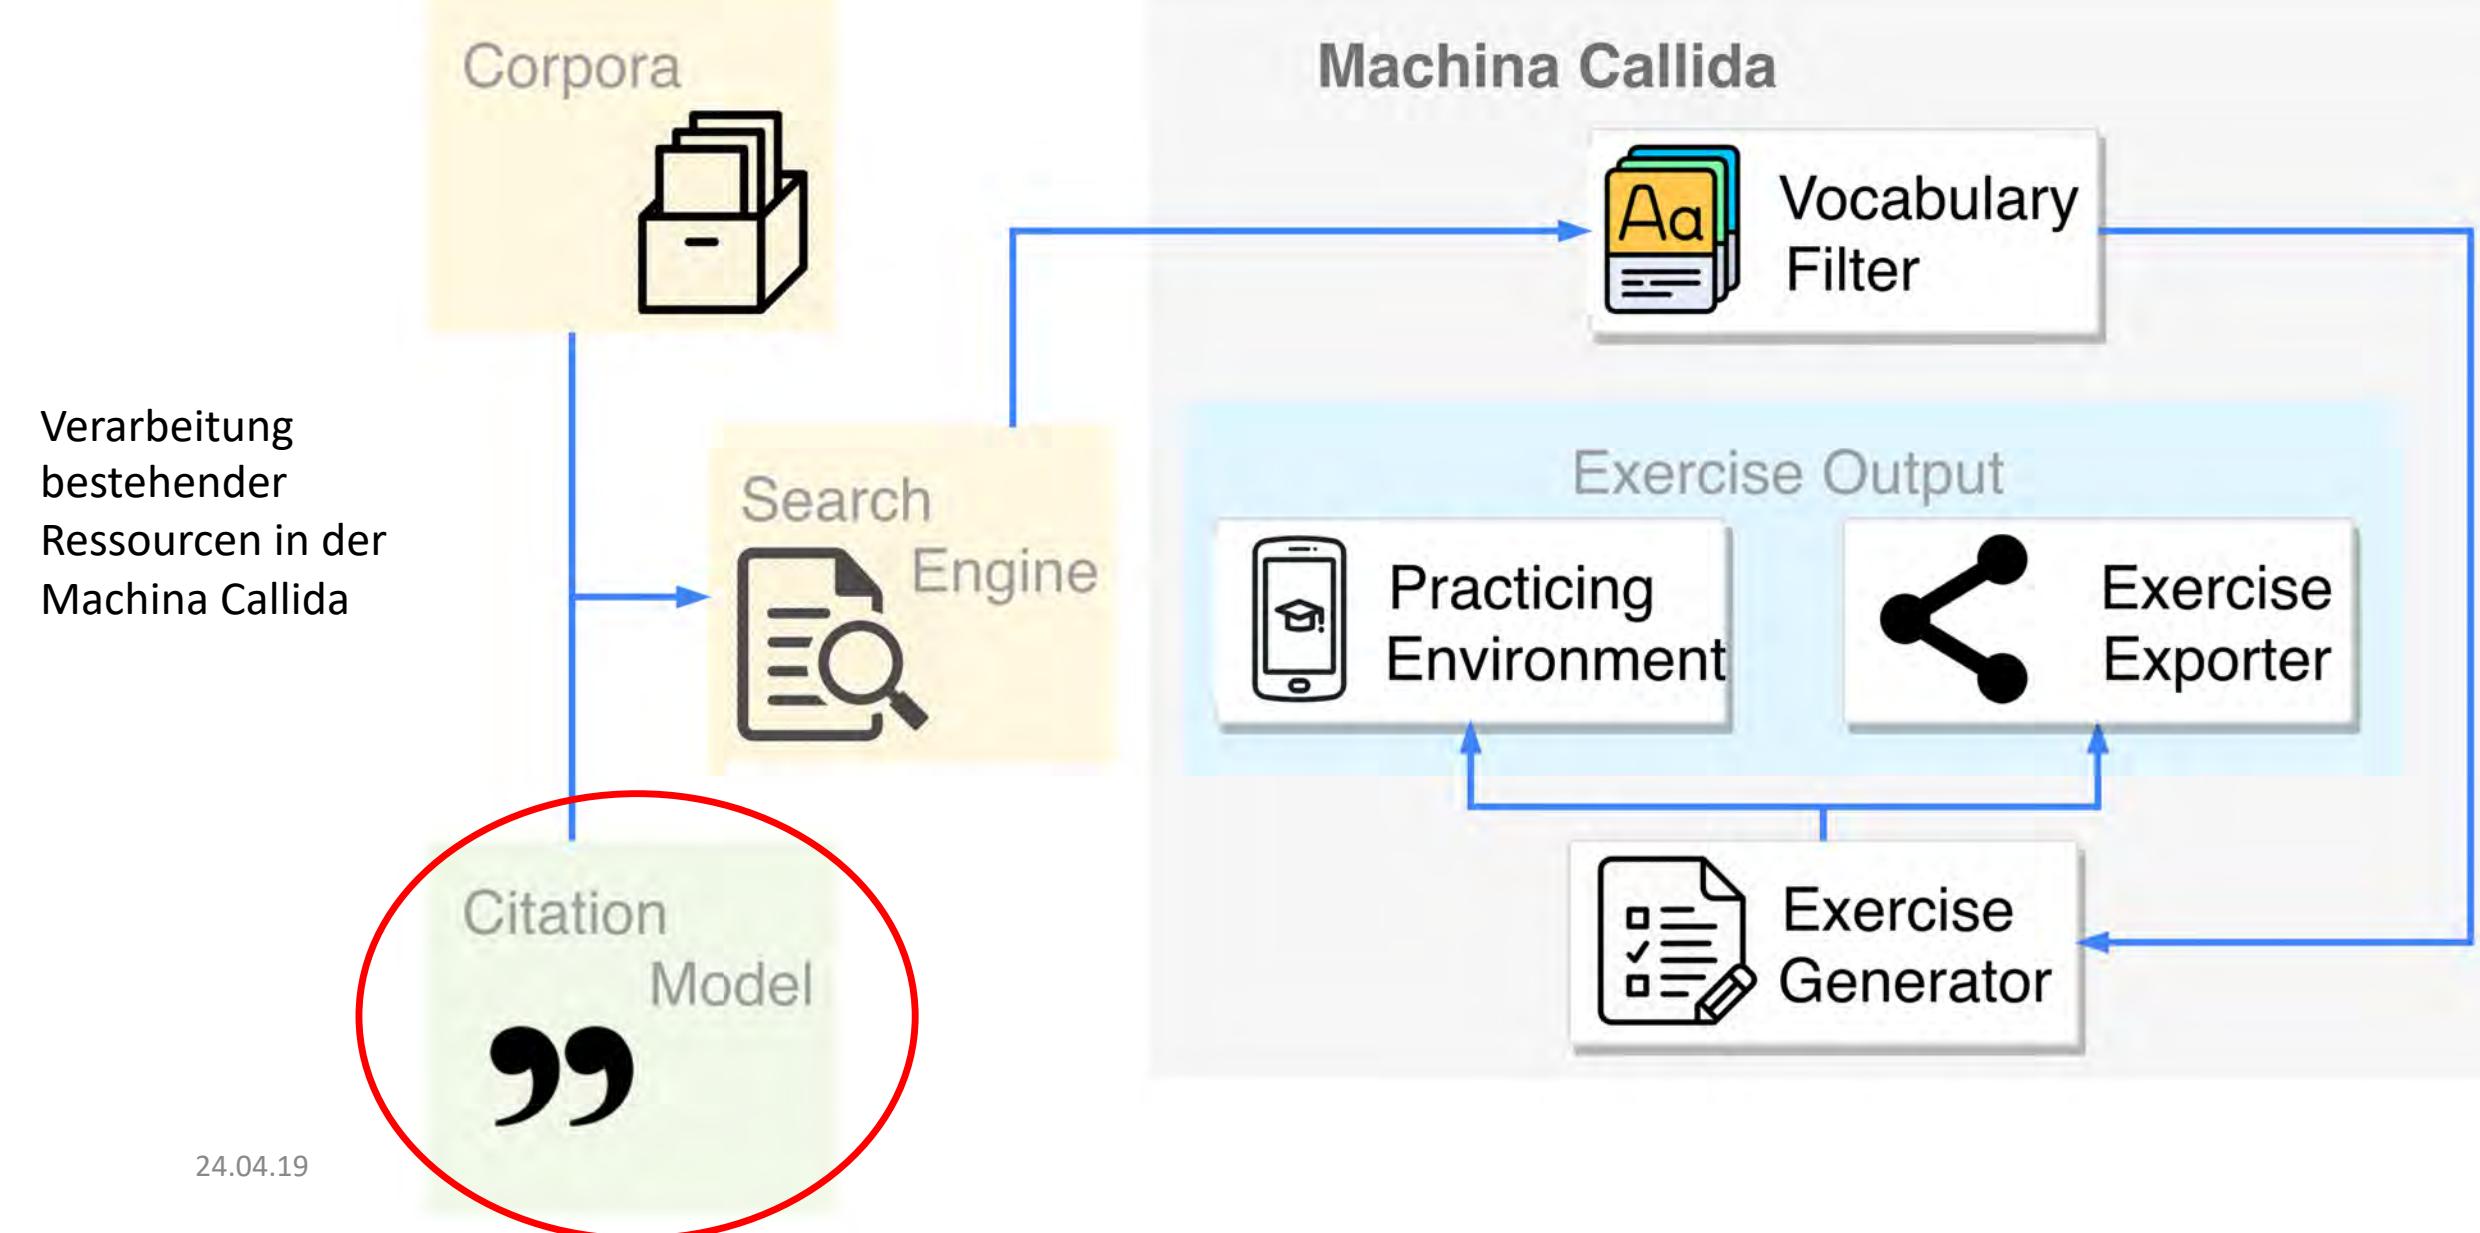
# Resource Workflow



# 7.1. Softwaredesign: Korpora

- a) Treebanks (ca. 0,5 Mio. *tokens*)
  - Annotationen & Vokabular: PROIEL
  - Trainingsdaten für automatische Annotationen: ITTB
  - Vokabular: AGLDT
- b) Rohtexte (> 15 Mio. *tokens*)
  - Perseids CTS
  - Lehrbuch VIVA
- c) experimentell: maschinelle Generierung autorenspezifischer pseudo-literarischer Texte

# Resource Workflow



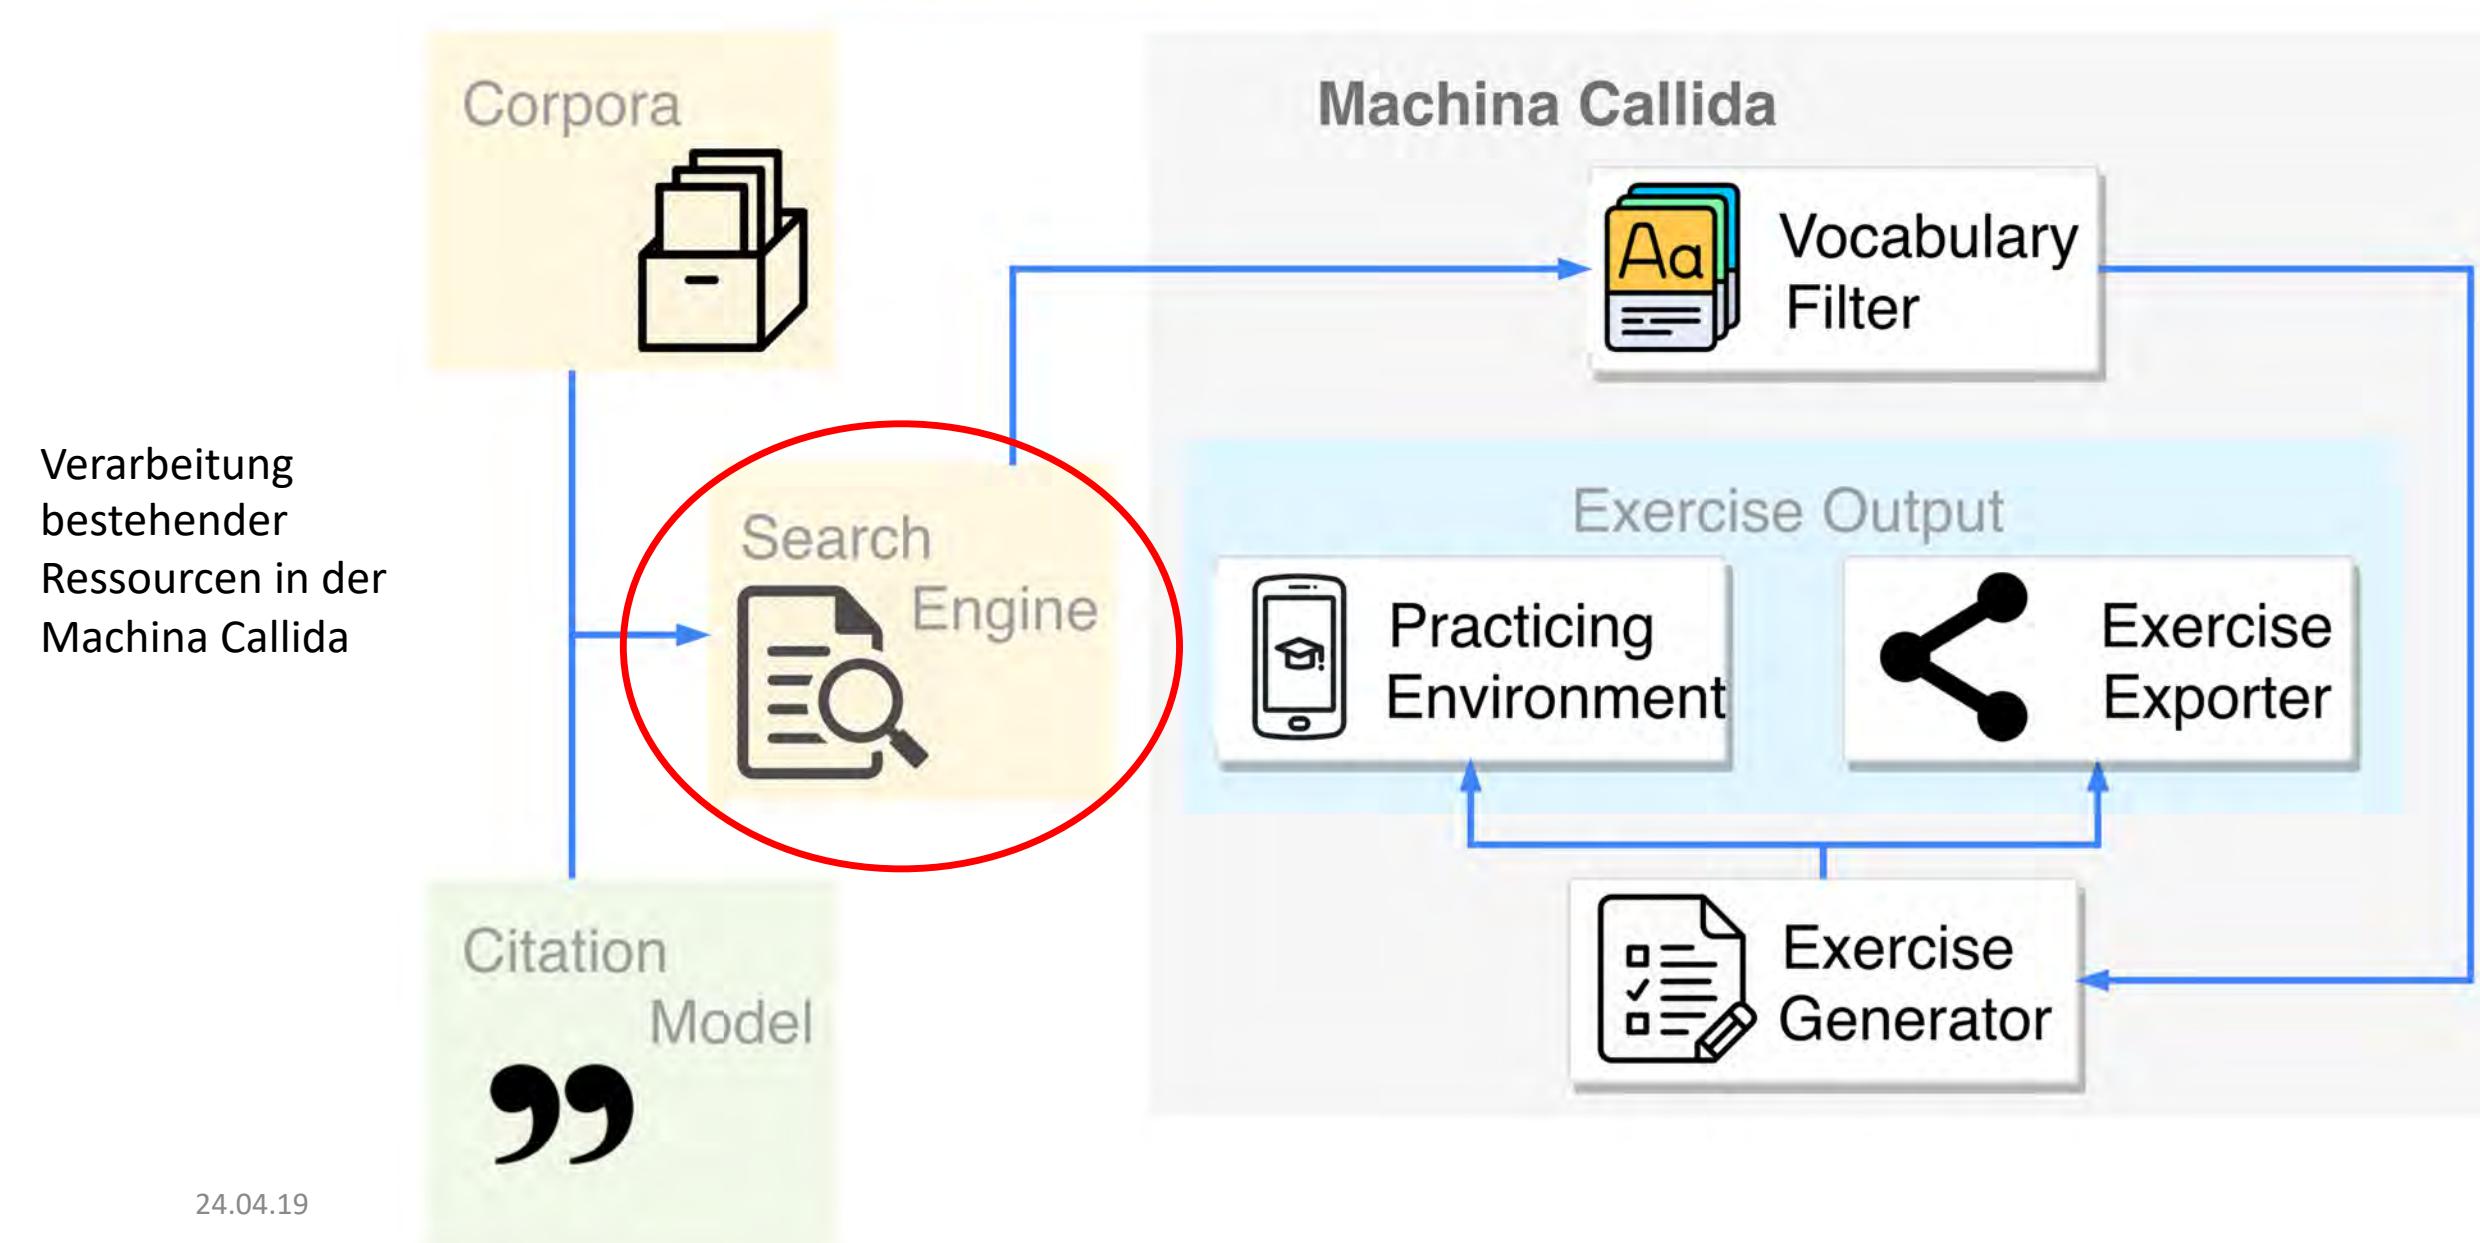
## 7.2. Softwaredesign: Zitationsmodell (I)

- CITE
  - urn:cts:CTSNAMESPACE:WORK:PASSAGE
    - WORK = TEXTGROUP.WORK.VERSION.EXEMPLAR
    - PASSAGE = CITABLENODE@SUBSECTION
      - Problem: keine Subsections beim Perseids CTS-Repository möglich
      - Lösung: Segmentierung nach Satzzeichen und dann Verweis auf Satz-IDs
        - Neues Problem: kein genauerer Kontext als Satzebene möglich
        - Lösungsansatz: Verweis auf Token-IDs (über graphANNIS)
  - Beispiel urn:cts:**latinLit:phi0448.phi001.perseus-lat2:1.1.1-1.2.3**
    - Sprache Autor Werk Textedition Textpassage
    - = Latein, Caesar, Bellum Gallicum, Oxford 1901, Buch 1, Kapitel 1, Abschnitt 1 ...

## 7.2. Softwaredesign: Zitationsmodell (II)

- Übertragung des CITE URN-Modells auf nicht-CTS-Texte:
  - urn:cts:latinLit:phi0448.phi001.perseus-lat2:1.1.1-1.2.3
  - urn:custom:latinLit:proiel.caes-gal.lat:1.1.1-1.2.3
    - Problem: schwammige Definition von Autor, Werk und Edition
  - urn:custom:latinLit:viva.lat:1.3-1.5 (= Lehrbuch VIVA, Buch 1, Lektion 3-4Z)
    - Problem: Analogie „Lehrbuchlektion=Kapitel“ funktioniert schlecht, wegen Zusatztexten
    - Lösungsansatz: weitere Zitationsebene definieren (Level 3), für Zusatztexte

# Resource Workflow

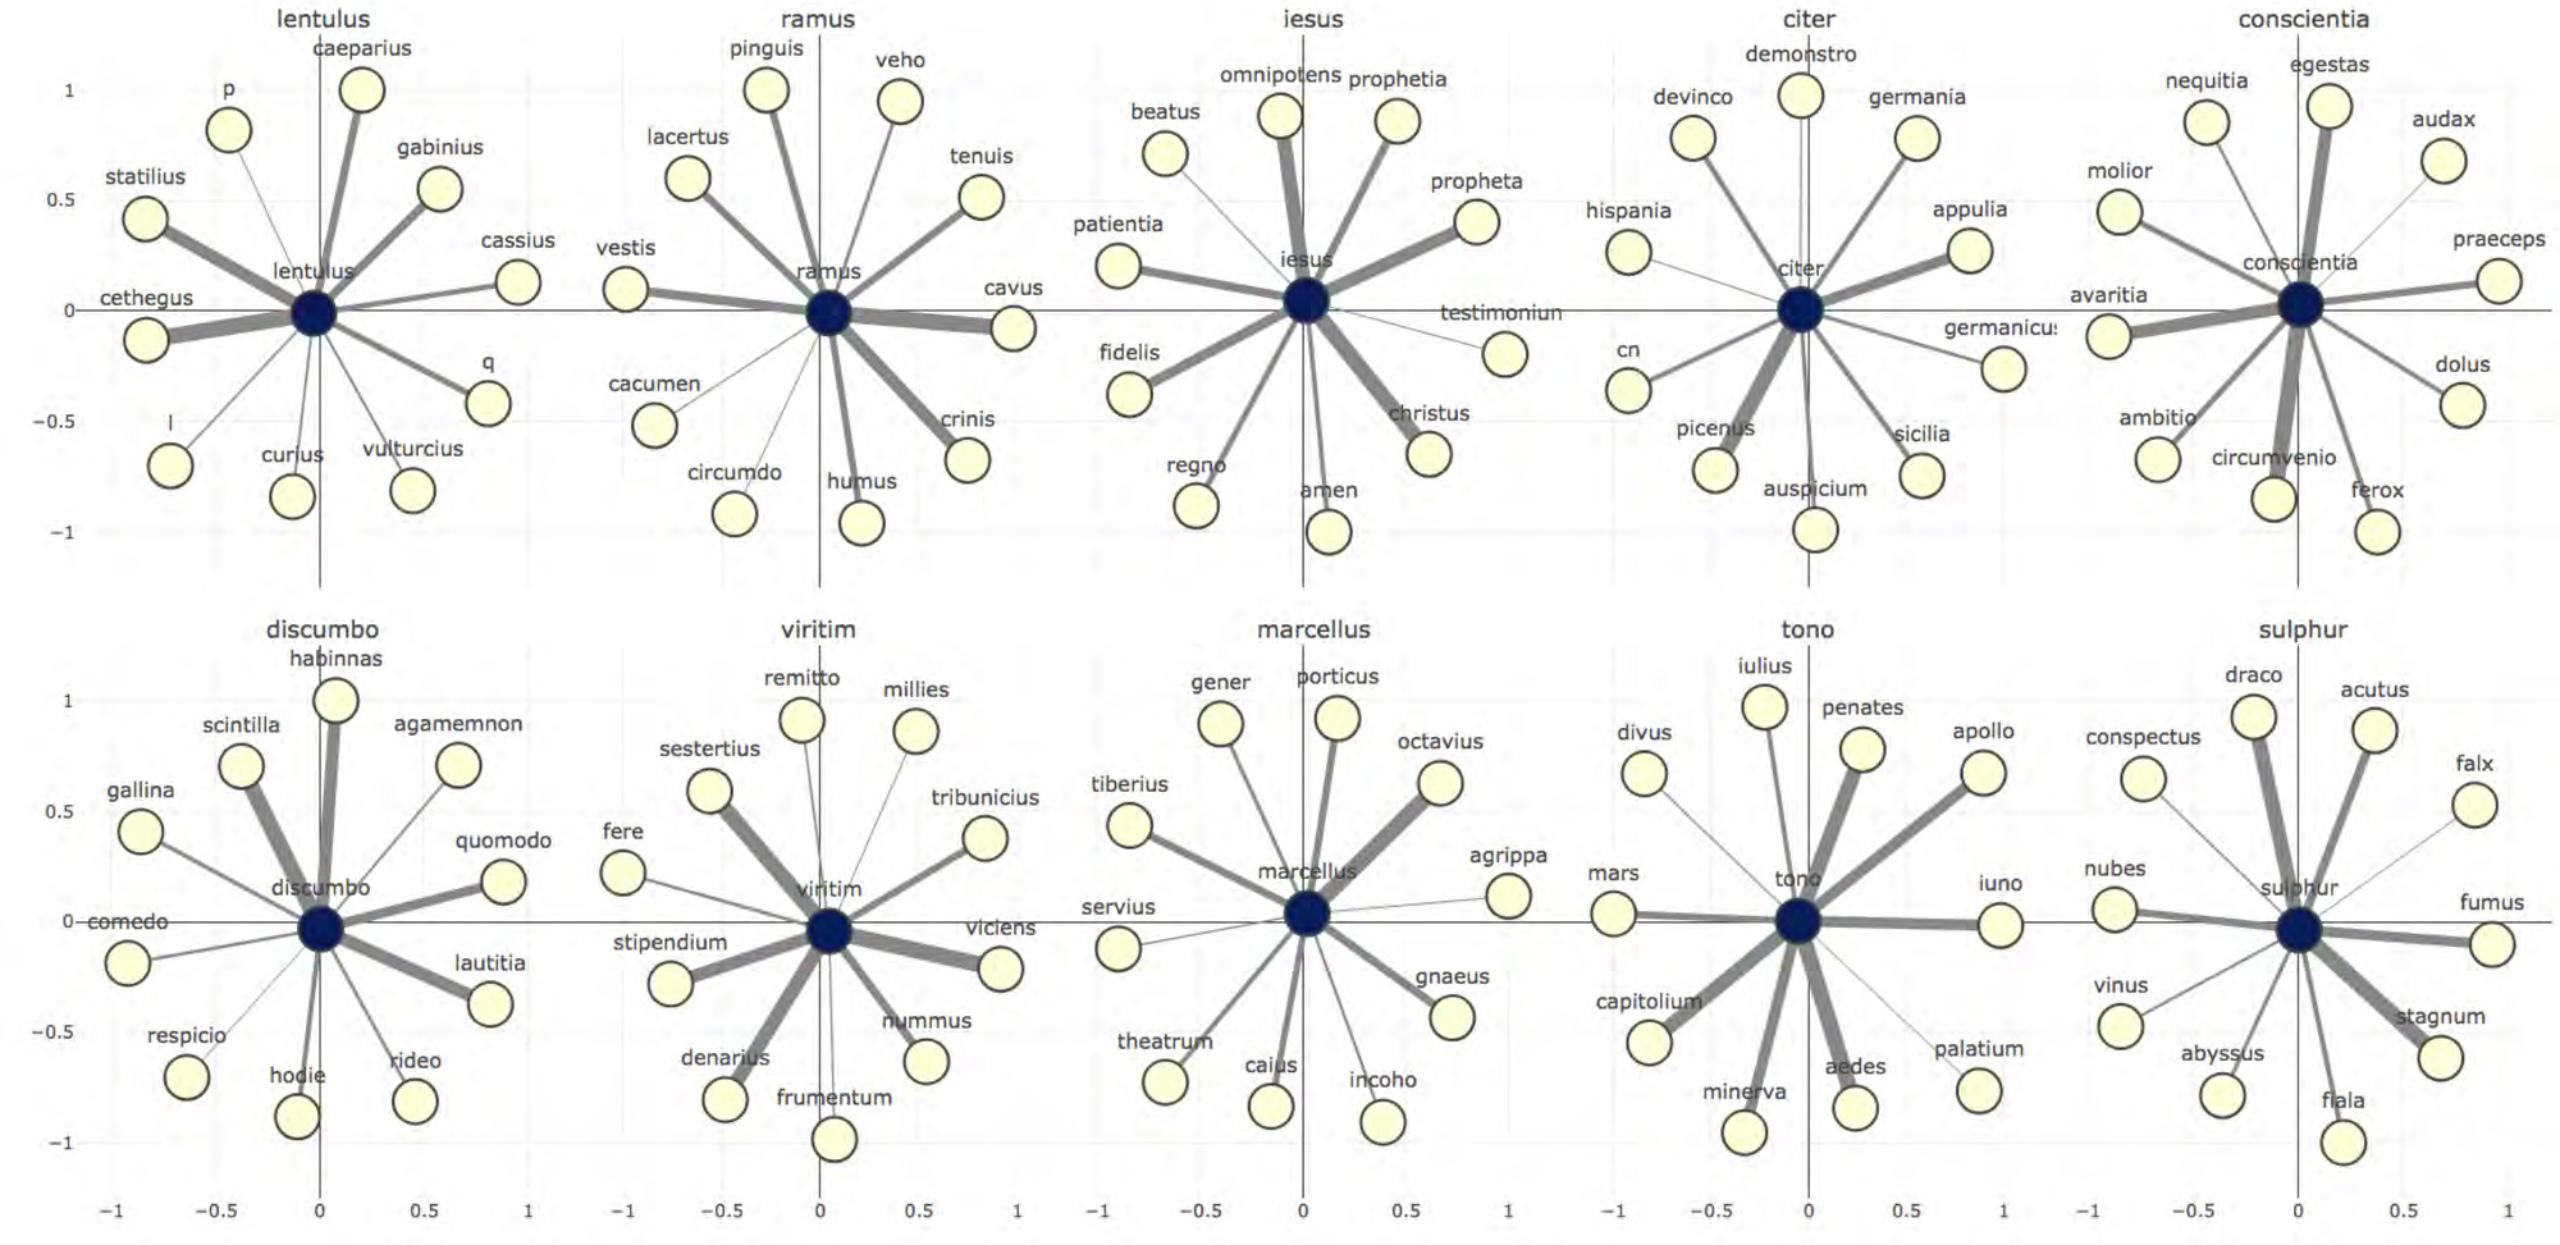




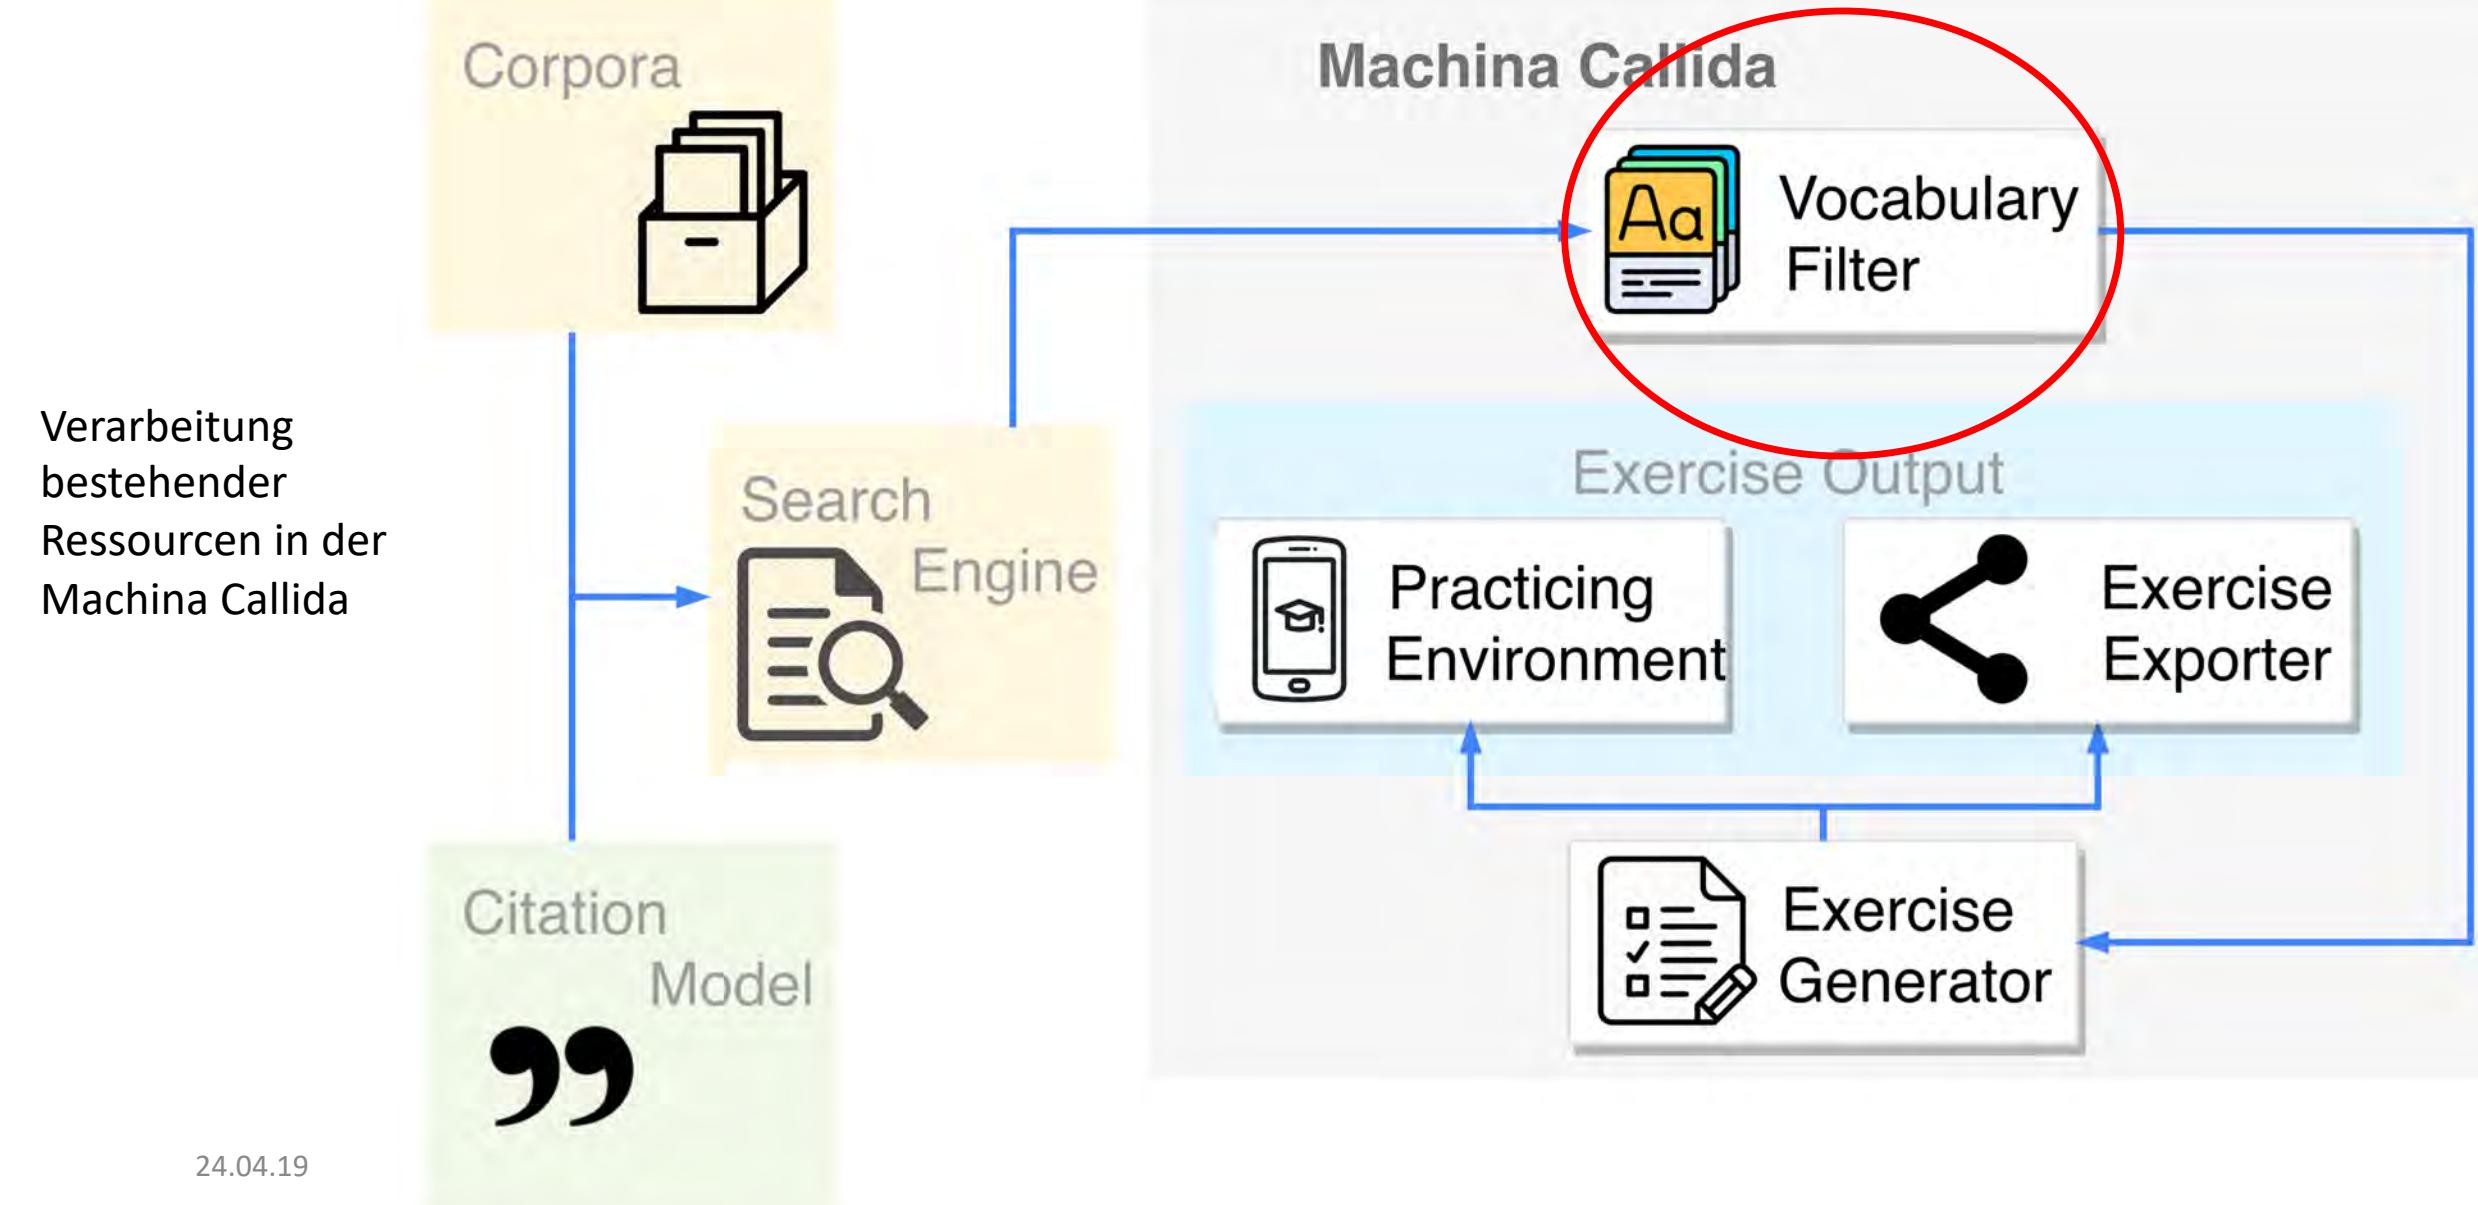
## 7.3. Softwaredesign: Suchfunktion ...fueled by

- Verschiedene linguistische Phänomene: Flexion (→ Morphologie), Lemmata (→ Lexik), Dependenzgrammatik (→ Syntax)
- Multi-Layer-Annotationen
- Verschiedene Modelle: Bäume, Graphen...
- Domänenspezifische Sprache zur Anwendung der ANNIS Query Language
- Unicode für entlegene Zeichen
- Unterstützung für Von-rechts-nach-links gelesene Texte & Annotationen
- Experimentell: maschinell generierte Wortfelder (→ Semantik)

# Top 10 Kookkurrenzfelder (nach Ähnlichkeit)



# Resource Workflow



## 7.4. Softwaredesign: Vokabelfilter (I)

- Status quo: Bamberger Wortschatz
    - Lemmaliste, als Basis für die meisten Lehrbücher
    - Erstellungsprozedur fragwürdig: Korpus nicht zugänglich, rohe Frequenzen, willkürliche Schwellwerte
    - Einteilung in Top 500 und vollständig (1.248)
  - Ergänzungen / Alternativen:
    - Treebanks:
      - AGLDT: 7.182 Lemmata
      - PROIEL: 16.402 Lemmata
    - Lehrbuch: VIVA → 1.164 Lemmata (bisher ohne Frequenzen)
- ➔ Granulare Hierarchie (nach Frequenz sortiert), größerer Umfang, korpuspezifisch

## 7.4. Softwaredesign: Vokabelfilter (II)

1. Korpus auswählen (z.B. Caesar, Bellum Gallicum, Buch 1)
2. Referenzvokabular auswählen (z.B. BWS Top 500 oder VIVA oder PROIEL Top 287)
3. Lemmatisierung
  - a) Treebank: Annotationen abfragen mittels ANNIS
  - b) Rohtext: automatisch annotieren mittels UDPipe, dann Übertragung in ANNIS
4. Lemma-Abgleich für jedes Token (Korpus vs. Referenzvokabular)
5. Ranking nach prozentualer Abdeckung
6. Auswahl eines Subkorpus
7. Weitere Operationen
  - a) Unbekannte Vokabeln markieren (z.B. um sie dann zu erklären)
  - b) Übungen nur zu bekannten Vokabeln erstellen

# 7.4. Softwaredesign: Vokabelfilter (III)

| Probleme   | Lösungsansätze   |
|--|--|
| Lemmaliste als Repräsentation der Wortschatzkompetenz<br>→ alles gleich gewichtet, nur Gesamtpunktzahl zählt<br>→ fehlende adäquate Diagnosemittel | <ul style="list-style-type: none"><li>Übertragung des Toolbox Picture Vocabulary Test auf den Schriftbereich</li><li>Anwendung der Item Response Theory<ul style="list-style-type: none"><li>→ Individuelle Anpassung der Item-Schwierigkeit</li><li>→ Unterschiedliche Gewichtungen</li></ul></li></ul> |
| Fehlende Alternative zu Einzelwortlisten<br>→ überprüft nur dekontextualisiert Form/Bedeutung  | <ul style="list-style-type: none"><li>strategisches Leseverständnis prüfen<ul style="list-style-type: none"><li>Focus on Form</li><li>Form/Bedeutung, Derivation, Polysemie, Kollokationen</li><li>Textbasiert (?)</li></ul></li></ul>   |
| Produktion/Kommunikation als Antrieb für Spracherwerb fehlt  | <ul style="list-style-type: none"><li>Intensivere Auseinandersetzung mit den jeweiligen Vokabeln<ul style="list-style-type: none"><li>Spreading Activation nutzen</li><li>Stemming, Word Sense Induction, Kollokationsanalysen</li></ul></li></ul>   |

Toolbox Picture Vocabulary Test & Item Response Theory: Gershon et al. 2013; Leseverständnis statt Form-Bedeutung: Schmitt 2014; Focus-on-form: Ellis 2009; Dimensionen der Wortschatzkompetenz: González-Fernández & Schmitt 2019; Kommunikation im Spracherwerb: Kersten 2010; Spreading Activation : Bruza et al. 2009

# Kollokationsanalyse: rohe Frequenzen

- AGLDT, dependenzbasiert, Substantiv + Adjektiv

127: **res publicus**

42: *populus Romanus*

18: **vox magnus**

16: *nomen meus*

14: *pars tertius*

13: **res novus**

13: **eques Romanus**

11: *res omnis*

10: *deus immortalis*

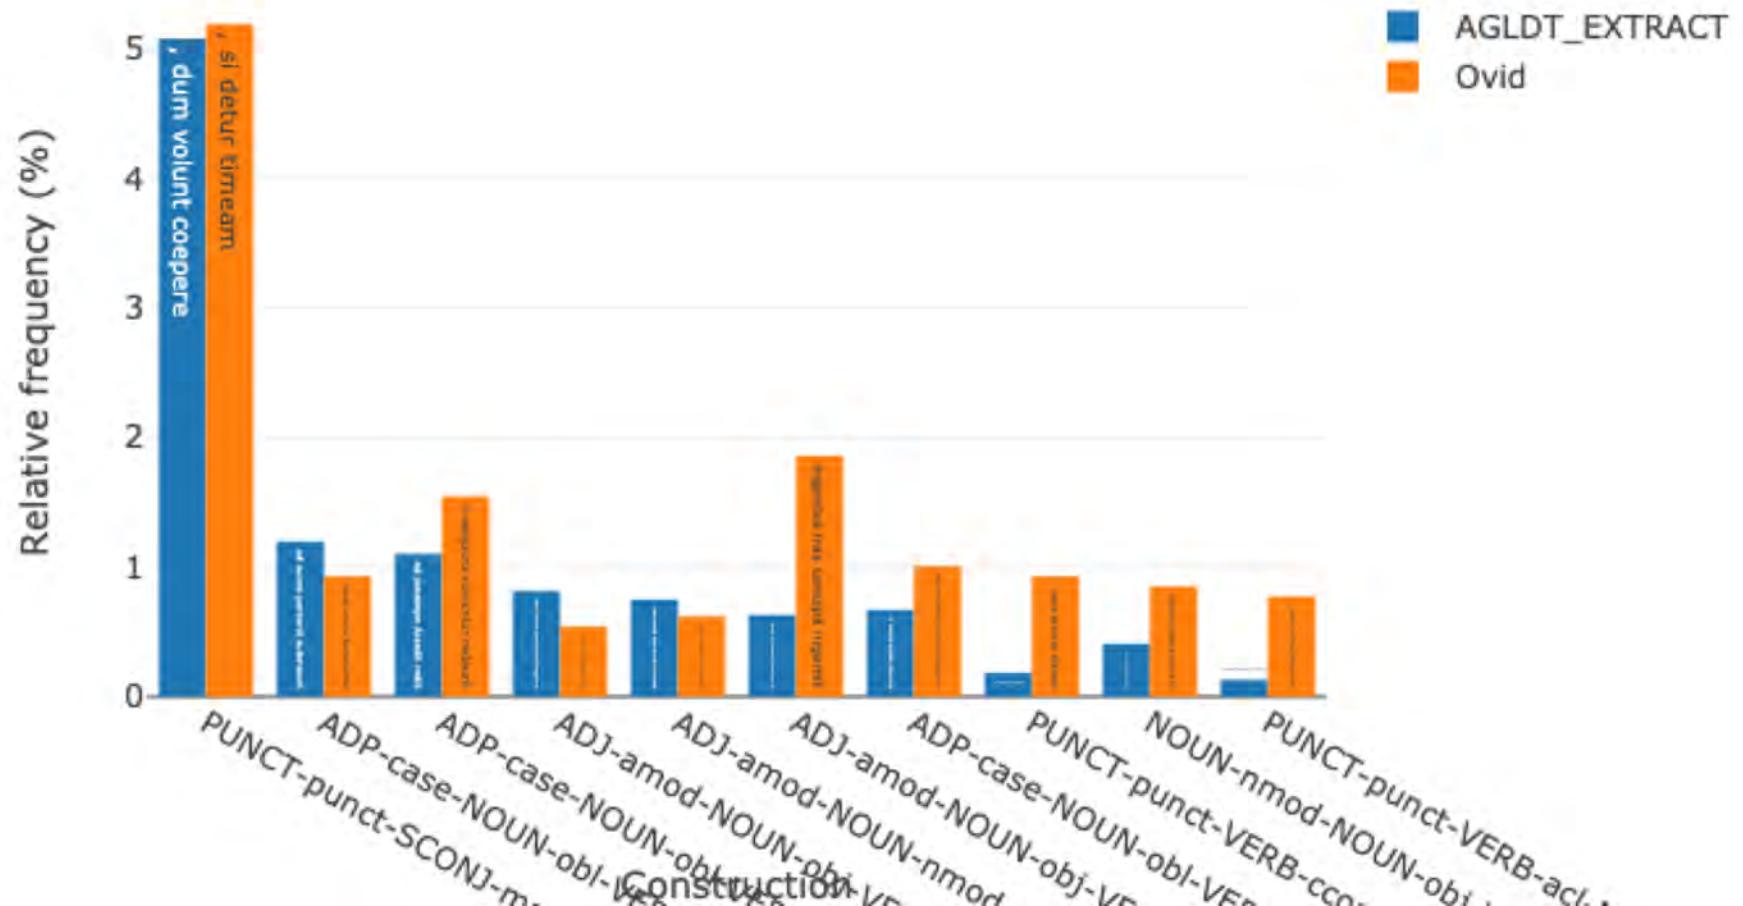
10: **aes alienus**

→ ca. 50% Kollokationen nach der lexikografischen Definition: „word combination whose semantic and/or syntactic properties cannot be fully predicted from those of its components“

→ Genauigkeit könnte möglicherweise durch Pointwise Mutual Information noch weiter erhöht werden

# Konstruktionsorientierter Ansatz

## Construction frequencies Ovid vs. AGLDT



# Vokabular: Subkorpus vs. Referenzkorpus

# Top500 Caesar vs. Top500 PROIEL

Caesar atque  
hostis ex  
res ab  
omnis ad  
ut si  
qui  
in  
sum  
et

# 8. Übungsdesign

- Zuordnungsübungen: Potenzial zur Förderung der sprachübergreifenden lexikalischen Vernetzung
  - Ressourcen dazu noch nicht ausgeschöpft, z.B. Wikipedia / Wiktionary
- Variation der Interaktion: Lückentexte, Zuordnung, Keyword In Context, ... (demnächst: Erkennung)
- Input vs. Intake (vs. Retention)

# Zusammenfassung

- ❤️ **Korpora** ❤️
  - Lernt Vokabeln, aber bitte im **Kontext!**
  - Übersetzung ist **nicht** Wortschatzerwerb.
- Wir brauchen bessere **Evaluationen** und **Übungen** für lateinischen Wortschatz.

# Bibliografie (I)

- Aijmer, K. (2009). *Corpora and language teaching* (Vol. 33). Retrieved from <https://books.google.de/books?hl=de&lr=&id=ll-hYaUJLu0C>.
- Almas, B. (2017). Perseids: Experimenting with Infrastructure for Creating and Sharing Research Data in the Digital Humanities. *Data Science Journal*, 16(19), 1–17. Retrieved from <https://datascience.codata.org/articles/10.5334/dsj-2017-019/galley/663/download/>.
- Bamman, D., & Crane, G. (2011). The Ancient Greek and Latin Dependency Treebanks [AGLDT]. In *Language Technology for Cultural Heritage* (pp. 79–98). Retrieved from [https://perseusdl.github.io/treebank\\_data/](https://perseusdl.github.io/treebank_data/).
- Bartoszek, V., Datené, V., Lösch, S., Mosebach-Kaufmann, I., Nagengast, G., Schöffel, C., ... Schröttel, W. (2013). *VIVA 1 Lehrerband* (Vol. 1). Retrieved from [https://books.google.de/books?hl=de&lr=&id=b\\_M4oV8VINGC](https://books.google.de/books?hl=de&lr=&id=b_M4oV8VINGC).
- Blackwell, C., & Smith, N. (Eds.). (2015). *The Canonical Text Services URN Specification, Version 2.0.rc.1 [CITE / URN]*. Retrieved from [http://cite-architecture.github.io/ctsurn\\_spec/](http://cite-architecture.github.io/ctsurn_spec/).
- Bruza, P., Kitto, K., Nelson, D., & McEvoy, C. (2009). Is there something quantum-like about the human mental lexicon? *Journal of Mathematical Psychology*, 53(5), 362–377. Retrieved from <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2834425/pdf/nihms160244.pdf>.
- Brysbaert, M., & New, B. (2009). Moving beyond Kučera and Francis: A critical evaluation of current word frequency norms and the introduction of a new and improved word frequency measure for American English. *Behavior Research Methods*, 41(4), 977–990. Retrieved from <https://link.springer.com/content/pdf/10.3758/BRM.41.4.977.pdf>.
- Campoy, M. C., Cubillo, M. C. C., Belles-Fortuno, B., & Gea-Valor, M. L. (2010). *Corpus-Based Approaches to English Language Teaching*. Retrieved from <https://books.google.de/books?hl=en&lr=&id=L6zzqz8JPUgC>.
- Cecchini, F. M., Passarotti, M., Marongiu, P., & Zeman, D. (2018). Challenges in Converting the Index Thomisticus Treebank into Universal Dependencies [ITTB]. *Proceedings of the Second Workshop on Universal Dependencies (UDW 2018)*, 27–36. Retrieved from <https://www.aclweb.org/anthology/W18-6004>.
- Daum, M. (2016). *Wortschatz und Lehrbuch: Ein Kriterienkatalog für die Wortschatzkonzeption in Lateinlehrwerken*. Retrieved from <https://books.google.de/books?id=CSv8CwAAQBAJ>.
- East, M. (2019). Sustaining innovation in school modern foreign language programmes: teachers' reflections on task-based language teaching three years after initial teacher education. *The Language Learning Journal*, 47(1), 105–115. <https://doi.org/10.1080/09571736.2016.1221440>.
- Ellis, N. C. (1997). Vocabulary acquisition: Word structure, collocation, word-class, and meaning. In N. Schmitt & M. McCarthy (Eds.), *Vocabulary: Description, acquisition and pedagogy* (pp. 122–139). Retrieved from <https://pdfs.semanticscholar.org/38b5/7a07241bbb22d1d0bf404f7d5e346f41e078.pdf>.
- Ellis, R. (2009). Task-based language teaching: Sorting out the misunderstandings. *International Journal of Applied Linguistics*, 19(3), 221–246. Retrieved from <https://pdfs.semanticscholar.org/2866/fad24dcd59848acb08a5468bacbecc02bf8a.pdf>.
- Evert, S. (2005). *The statistics of word cooccurrences: word pairs and collocations* (Dissertation, Universität Stuttgart). Retrieved from <https://elib.uni-stuttgart.de/bitstream/11682/2573/1/Evert2005phd.pdf>.
- Foley, J., & Thompson, L. (2017). *Language learning: A lifelong process*. Retrieved from <https://content.taylorfrancis.com/books/download?dac=C2012-0-11240-8&isbn=9781317835912&format=googlePreviewPdf>.

# Bibliografie (II)

- Gardner, D. (2007). Validating the Construct of Word in Applied Corpus-based Vocabulary Research: A Critical Survey. *Applied Linguistics*, 28(2), 241–265. <https://doi.org/10.1093/applin/amm010>.
- Gershon, R. C., Slotkin, J., Manly, J. J., Blitz, D. L., Beaumont, J. L., Schnipke, D., ... Weintraub, S. (2013). NIH TOOLBOX COGNITION BATTERY (CB): MEASURING LANGUAGE (VOCABULARY COMPREHENSION AND READING DECODING). *Monographs of the Society for Research in Child Development*, 78(4), 49–69. Retrieved from <https://www.jstor.org/stable/43772790>.
- Gilquin, G., & Granger, S. (2010). How can data-driven learning be used in language teaching. In A. O'Keeffe & M. McCarthy (Eds.), *The Routledge handbook of corpus linguistics* (Vol. 359370, pp. 359–370). Retrieved from [https://sites.ucclouvain.be/cecl/archives/Gilquin\\_Granger\\_2010\\_How\\_can\\_DDL\\_be\\_used\\_in\\_language\\_teaching.pdf](https://sites.ucclouvain.be/cecl/archives/Gilquin_Granger_2010_How_can_DDL_be_used_in_language_teaching.pdf).
- González-Fernández, B., & Schmitt, N. (2019). Word Knowledge: Exploring the Relationships and Order of Acquisition of Vocabulary Knowledge Components. *Applied Linguistics*. <https://doi.org/10.1093/applin/amy057>.
- Gries, S. Th. (2013). 50-something years of work on collocations. *International Journal of Corpus Linguistics*, 18(1), 137–166. Retrieved from <https://pdfs.semanticscholar.org/b0a1/c74fb94d8da6c2f0f0a219755665936fdcb4.pdf>.
- Gries, S. T., & Durrant, P. (2019). *Analyzing co-occurrence data*. Retrieved from [http://stgries.faculty.linguistics.ucsb.edu/research/ToApp\\_STG\\_PD\\_CooccData\\_PHCL.pdf](http://stgries.faculty.linguistics.ucsb.edu/research/ToApp_STG_PD_CooccData_PHCL.pdf).
- Große, M. (2015). Pons Latinus: Latein als reflexionsbasierte Brückensprache im Rahmen eines sprachsensiblen Lateinunterrichts. In E. M. F. Ammann, A. Kropp, & J. Müller-Lancé (Eds.), *Herkunftsbedingte Mehrsprachigkeit im Unterricht der romanischen Sprachen* (Vol. 17, pp. 185–206). Retrieved from <https://books.google.de/books?hl=de&lr=&id=0EHWBgAAQBAJ>.
- Haug, D. T., & Jøhndal, M. (2008). Creating a parallel treebank of the old Indo-European Bible translations [PROIEL]. *Proceedings of the Second Workshop on Language Technology for Cultural Heritage Data (LaTeCH 2008)*, 27–34. Retrieved from <http://www.hf.uio.no/ifikk/english/research/projects/proiel/Activities/proiel/publications/marrakech.pdf>.
- Hosseini, S. M. H. (2019). Cognitive Socio-political Language Learning Theory, Multiple Input-output Hypothesis and Competitive Team-based Learning. *Theory and Practice in Language Studies*, 9(4), 411–423. Retrieved from <https://www.academypublication.com/ojs/index.php/tpls/article/download/tpls0904411423/1875>.
- Hundt, M., & Leech, G. (2012). "Small is beautiful": On the value of standard reference corpora for observing recent grammatical change. In T. Nevalainen & E. C. Traugott (Eds.), *The Oxford handbook of the history of English* (pp. 175–188). Retrieved from <http://www.oxfordhandbooks.com/view/10.1093/oxfordhb/9780199922765.001.0001/oxfordhb-9780199922765-e-17>.
- Kersten, S. (2010). *The mental lexicon and vocabulary learning: Implications for the foreign language classroom*. Retrieved from <https://books.google.de/books?hl=de&lr=&id=NEOx13zHKVoC>.
- Kipf, S. (2015). ... und wo bleibt die Literatur? Gedanken zum Kompetenzerwerb im altsprachlichen Unterricht. *Forum Classicum. Zeitschrift Für Die Fächer Latein Und Griechisch an Schulen Und Universitäten*, (2), 70–82. Retrieved from <https://www.altphilologenverband.de/forumclassicum/pdf/FC2015-2.pdf>.
- Krause, T. (2019). ANNIS: A graph-based query system for deeply annotated text corpora. <https://doi.org/10.5281/zenodo.2598164>.
- Lijffijt, J., Papapetrou, P., Puolamäki, K., & Mannila, H. (2011). Analyzing word frequencies in large text corpora using inter-arrival times and bootstrapping. *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, 341–357. Retrieved from <https://link.springer.com/content/pdf/10.1007%2F978-3-642-23783-6.pdf>.
- Lüdeling, A., & Kytö, M. (2008). *Corpus linguistics: An international handbook*. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.455.9749&rep=rep1&type=pdf>.
- McGillivray, B. (2013). *Methods in Latin computational linguistics*. Retrieved from <https://books.google.de/books?hl=de&lr=&id=33dfAgAAQBAJ>.
- Nation, I. S. P. (2013). *Learning Vocabulary in Another Language* (2nd ed.). Retrieved from <https://books.google.de/books?id=KjYuDwAAQBAJ>.
- Newman, G. (2014). Citizen CyberScience—New directions and opportunities for human computation. *Human Computation*, 1(2), 103–109. Retrieved from [https://www.researchgate.net/profile/Newman\\_Greg/publication/287704099\\_Citizen\\_CyberScience\\_New\\_Directions\\_and\\_Opportunities\\_for\\_Human\\_Computation/links/57c74ebf08aec24de042aa9c.pdf](https://www.researchgate.net/profile/Newman_Greg/publication/287704099_Citizen_CyberScience_New_Directions_and_Opportunities_for_Human_Computation/links/57c74ebf08aec24de042aa9c.pdf).
- O'Keeffe, A., McCarthy, M., & Carter, R. (2007). *From Corpus to Classroom: Language Use and Language Teaching*. Retrieved from <https://books.google.de/books?hl=en&lr=&id=O3k0tWLp5LYC>.

# Bibliografie (III)

[RLP 2006] Senatsverwaltung für Bildung, Jugend und Sport Berlin. (2006). *Rahmenlehrplan für die gymnasiale Oberstufe. Gymnasien, Gesamtschulen mit gymnasialer Oberstufe, Berufliche Gymnasien, Kollegs, Abendgymnasien. Latein*(RLP 2006). Retrieved from [https://www.berlin.de/sen/bildung/unterricht/faecher-rahmenlehrplaene/rahmenlehrplaene/mdb-sen-bildung-unterricht-lehrplaene-sek2\\_latein.pdf](https://www.berlin.de/sen/bildung/unterricht/faecher-rahmenlehrplaene/rahmenlehrplaene/mdb-sen-bildung-unterricht-lehrplaene-sek2_latein.pdf).

Römer, U. (2009). Corpus research and practice. *Corpora and Language Teaching*, Amsterdam: John Benjamins, 83–98. Retrieved from <https://books.google.de/books?hl=en&lr=&id=3yfOJSMTRhOC>.

Sass, A. (2015). *Sprachenübergreifendes Vokabellernen: eine qualitativ-interpretative Studie zur Vernetzung der Fächer Englisch und Latein* (Dissertation, Staats-und Universitätsbibliothek Bremen). Retrieved from <https://elib.suub.uni-bremen.de/edocs/00105616-1.pdf>.

Schirok, E. (2010). „Wortschatzarbeit“. In T. Doeppner & M. Keip (Eds.), *Interaktive Fachdidaktik Latein* (pp. 13–34). Retrieved from <https://static.onleihe.de/content/vandenhoeck/20141125/978-3-647-26411-0/v978-3-647-26411-0.pdf>.

Schmid, H.-J., & Küchenhoff, H. (2013). Collostructional analysis and other ways of measuring lexicogrammatical attraction: Theoretical premises, practical problems and cognitive underpinnings. *Cognitive Linguistics*, 24(3), 531–577. Retrieved from [http://www.anglistik.uni-muenchen.de/personen/professoren/schmid/schmid\\_publ/collostructional-analysis.pdf](http://www.anglistik.uni-muenchen.de/personen/professoren/schmid/schmid_publ/collostructional-analysis.pdf).

Schmitt, N. (2014). Size and depth of vocabulary knowledge: What the research shows. *Language Learning*, 64(4), 913–951. Retrieved from [http://eprints.nottingham.ac.uk/32299/1/Schmitt\\_final\\_version\\_LL.pdf](http://eprints.nottingham.ac.uk/32299/1/Schmitt_final_version_LL.pdf).

Siebel, K. (2011). Lateinischer Wortschatz als Brücke zur Mehrsprachigkeit? Eine Durchsicht des Aufgabenspektrums aktueller Lateinlehrwerke. *Pegasus-Onlinezeitschrift*, XI(1), 102–132. Retrieved from [www.pegasus-onlinezeitschrift.de/2011\\_1/pegasus\\_2011-1\\_siebel.pdf](http://www.pegasus-onlinezeitschrift.de/2011_1/pegasus_2011-1_siebel.pdf).

Siebel, K. (2017). *Mehrsprachigkeit und Lateinunterricht: Überlegungen zum lateinischen Lernwortschatz* (Vol. 4). Retrieved from <https://books.google.de/books?hl=de&lr=&id=YOMsDwAAQBAJ>.

Straková, J., Straka, M., & Hajič, J. (2014). Open-source tools for morphology, lemmatization, POS tagging and named entity recognition. *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics: System Demonstrations*, 13–18. Retrieved from <http://www.aclweb.org/anthology/P14-5003>.

Tiepmar, J., Teichmann, C., Heyer, G., Berti, M., & Crane, G. (2014). A new implementation for canonical text services [CTS]. *Proceedings of the 8th Workshop on Language Technology for Cultural Heritage, Social Sciences, and Humanities (LaTeCH)*, 1–8. Retrieved from [https://www.aclweb.org/anthology/W14-0601](http://www.aclweb.org/anthology/W14-0601).

Utz, C. (2000). Mutter Latein und unsere Schüler — Überlegungen zu Umfang und Aufbau des Wortschatzes [BWS]. *Antike Literatur–Mensch, Sprache, Welt. Dialog Schule Und Wissenschaft*, 34, 146–172. Retrieved from [https://www.ccbuchner.de/\\_files\\_media/mediathek/downloads/267.pdf](https://www.ccbuchner.de/_files_media/mediathek/downloads/267.pdf).

Van de Loo, T. (2016). Wortschatzarbeit – neuere Perspektiven und schulische Praxis. *Pegasus-Onlinezeitschrift*, 16, 131–151. Retrieved from <https://journals.ub.uni-heidelberg.de/index.php/pegasus/article/viewFile/35254/28912>.

Vincze, V., Szauter, D., Almási, A., Móra, G., Alexin, Z., & Csirik, J. (2010). *Hungarian dependency treebank. 1855–1862*. Retrieved from [http://publicatio.bibl.u-szeged.hu/8749/1/465\\_Paper.pdf](http://publicatio.bibl.u-szeged.hu/8749/1/465_Paper.pdf).

Webb, S. (2008). The effects of context on incidental vocabulary learning. *Reading in a Foreign Language*, 20(2), 232–245. Retrieved from <https://files.eric.ed.gov/fulltext/EJ815123.pdf>.

Xie, Z. (2017). *Neural Text Generation: A Practical Guide*. 1–21. Retrieved from <https://arxiv.org/abs/1711.09534v1>.