




FRIEDRICH-SCHILLER-
UNIVERSITÄT
JENA



Quantifizierung von Emotionen in Historischer Sprache


Anwendungen und Methodische Grundlagen

Sven Büchel

Jena University Language & Information Engineering
(JULIE) Lab

<http://www.julielab.de>

Friedrich-Schiller-Universität Jena






- Studium der Physik, Germanistik und Soziologie in Jena
- B.A. erlangt 2016 mit „Automatische Analyse von Emotionen in Geschäfts- und Nachhaltigkeitsberichten“
- Ko-Betreut vom Lehrstuhl für ABWL / Organisation, Führung und HRM (Prof. Dr. Peter Walgenbach)
- Ab Sommer 2016 Direktpromotion am JULIE Lab (Prof. Dr. Udo Hahn)
- Forschungsschwerpunkt: Methodenentwicklung zur Automatischen Messung von Emotionen in Text

- Studium der Physik, Germanistik und Soziologie in Jena
- B.A. erlangt 2016 mit „Automatische Analyse von Emotionen in Geschäfts- und Nachhaltigkeitsberichten“
- Ko-Betreut vom Lehrstuhl für ABWL / Organisation, Führung und HRM (Prof. Dr. Peter Walgenbach)
- Ab Sommer 2016 Direktpromotion am JULIE Lab (Prof. Dr. Udo Hahn)
- Forschungsschwerpunkt: Methodenentwicklung zur Automatischen Messung von Emotionen in Text
- Zusammen mit Johannes Hellrich: Emotionen in historischer Sprache



Geisteswissenschaften und Emotionen



https://de.wikipedia.org/wiki/Walther_von_der_Vogelweide

<https://de.wikipedia.org/wiki/Laokoon-Gruppe>

https://de.wikipedia.org/wiki/Der_Schrei

<http://www.br.de/telekolleg/faecher/deutsch/literatur/goethe-weimarer-klassik-100.html>

Unterschiedliche Datendichten


Zeitgenössische Sprachdaten



Historische Sprachdaten




Methodisches Vorgehen



Methoden

Formale Darstellung von Emotionen: VAD



Emotionslexika


- Lexikalische Datensätze
- Kodiert Emotionen einzelner Wörter
- Kontextunabhängig
- Zahlreiche Datensätze in Psychologie aufgebaut

Lemma	Valence	Arousal	Dominance
Sonnenschein	8.1	5.3	5.4
Terrorismus	1.6	7.4	2.7
Ekstase	6.9	7.8	3.0

(9-Punkt-Skala)


Automatische Erweiterung von Emotionslexika

- Basierend auf sog. *seed*-Wörtern
- Turney-Littman-Algorithmus



Automatische Erweiterung von Emotionslexika

- Basierend auf sog. *seed*-Wörtern
- Turney-Littman-Algorithmus



- Aber: Wie bestimmen wir Wort-Ähnlichkeiten?
→ **Worteinbettungen**



Wortsemantik und Wortumfeld

„Die Bedeutung eines Wortes ist sein Gebrauch in der Sprache.“

Wittgenstein, Philosophische Untersuchungen, 1953

“You shall know a word by the company it keeps!”

Firth, A synopsis of Linguistic Theory, 1957



Wortsemantik und Wortumfeld

Er *liest* ein *Gedicht*.

Susanne *liest* einen *Roman*.

Der *Roman* hat 100 *Seiten*.

Ihr *Gedicht* hat 3 *Seiten*.

Susanne *hört* eine *Oper*.

Peter *hört* ein *Lied*.

Das *Lied* ist in *d-Moll*.

Die *Oper* ist in *d-Moll*.



Wortsemantik und Wortumfeld

Er *liest* ein *Gedicht*.

Susanne *liest* einen *Roman*.

Der *Roman* hat 100 *Seiten*.

Ihr *Gedicht* hat 3 *Seiten*.

Susanne *hört* eine *Oper*.

Peter *hört* ein *Lied*.

Das *Lied* ist in *d-Moll*.

Die *Oper* ist in *d-Moll*.



Wortsemantik und Wortumfeld

Er *liest* ein *Gedicht*.

Susanne *liest* einen *Roman*.

Der *Roman* hat 100 *Seiten*.

Ihr *Gedicht* hat 3 *Seiten*.

Susanne *hört* eine *Oper*.

Peter *hört* ein *Lied*.

Das *Lied* ist in *d-Moll*.

Die *Oper* ist in *d-Moll*.



Kookkurrenz-Tabelle

	lesen	Seiten	kaufen	essen	hören	...
Roman	98	60	3	0	2	
Gedicht	67	10	1	0	8	
Oper	4	8	0	0	38	
Lied	12	1	2	0	47	
⋮						




Wortvektoren

	lesen	Seiten	kaufen	essen	hören	...
Roman	98	60	3	0	2	
Gedicht	67	10	1	0	8	
Oper	4	8	0	0	38	
Lied	12	1	2	0	47	
⋮						




Wörter im Vektorraum





Wörter im Vektorraum





Dimensionsreduktion

	lesen	Seiten	kaufen	essen	hören	...
Roman	98	60	3	0	2	
Gedicht	67	10	1	0	8	
Oper	4	8	0	0	38	
Lied	12	1	2	0	47	
⋮						

- In der Praxis 100.000 x 100.000 = 10 Milliarden Zellen
- Viele Spalten wenig informativ (z.B. Synonymie)




Dimensionsreduktion

	Dim 1	Dim 2	Dim 3	Dim 4	Dim 5	...
Roman	2.37	-0.334	0.385	-2.84	0.015	
Gedicht	1.576	2.002	-1.23	-1.19	0.385	
Oper	-0.778	0.624	-2.846	3.125	-2.967	
Lied	1.113	-4.12	0.112	-1.235	-1.285	
⋮						

- Reduktion auf die 300 relevantesten Dimensionen
- Nicht mehr direkt interpretierbar
- Verschiedene mathematische Verfahren (z.B. Neuronale Netze) → **Worteinbettungen**




Worteinbettungen



$$\cos(\text{Hund}, \text{Katze}) > \cos(\text{Hund}, \text{Schildkröte}) > \cos(\text{Hund}, \text{Apfelkuchen})$$




Worteinbettungen



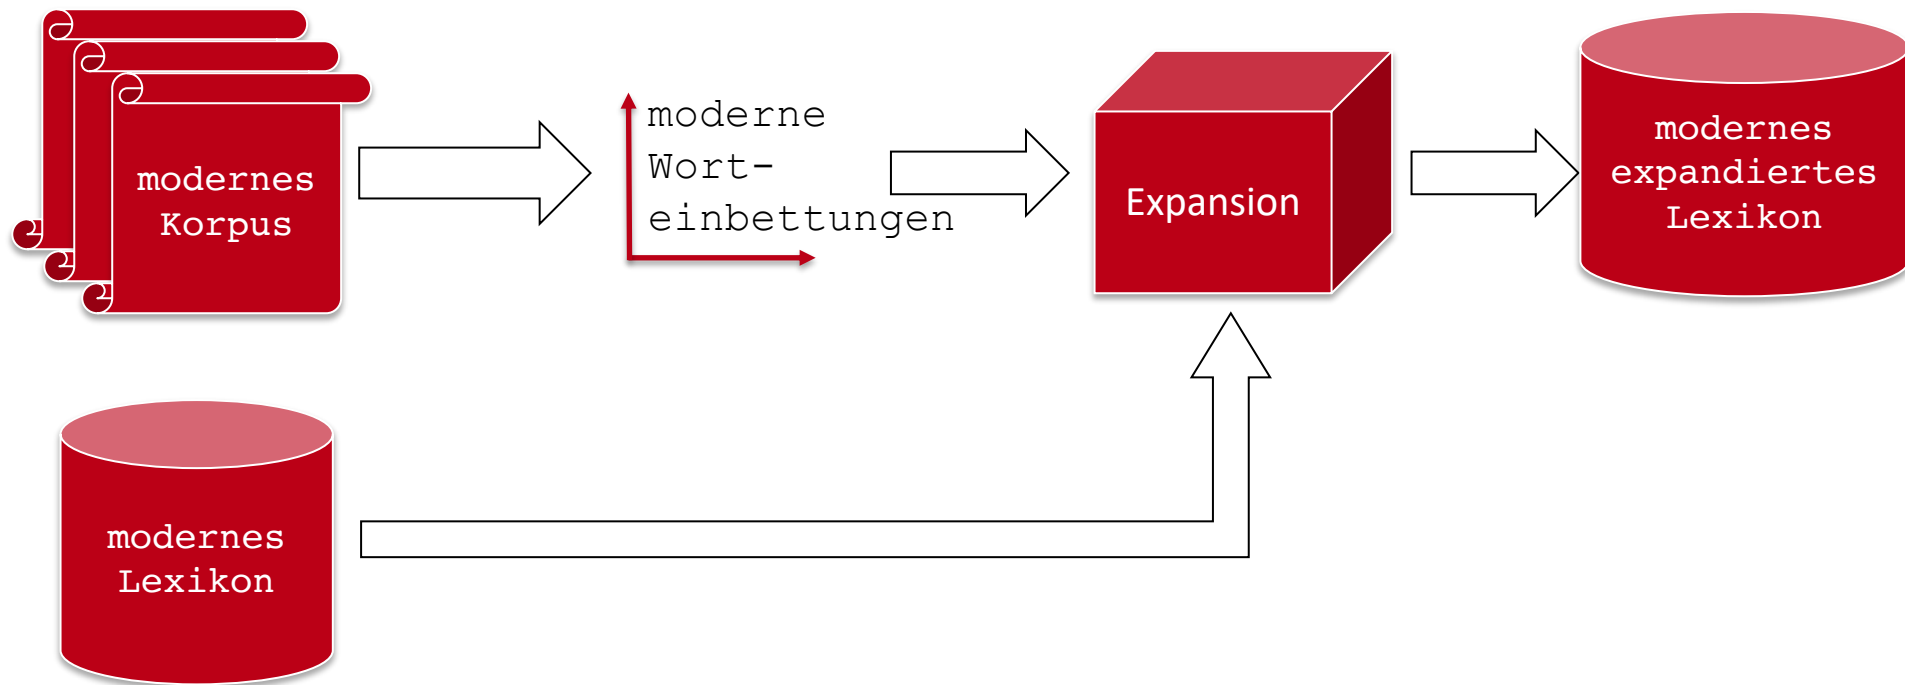
Automatische Erweiterung von Emotionslexika

- Basierend auf sog. *seed*-Wörtern
- Turney-Littman-Algorithmus



- Wortähnlichkeit durch Worteinbettungen!

Synchrone Lexikon-Expansion



Diachrone Lexikon-Expansion

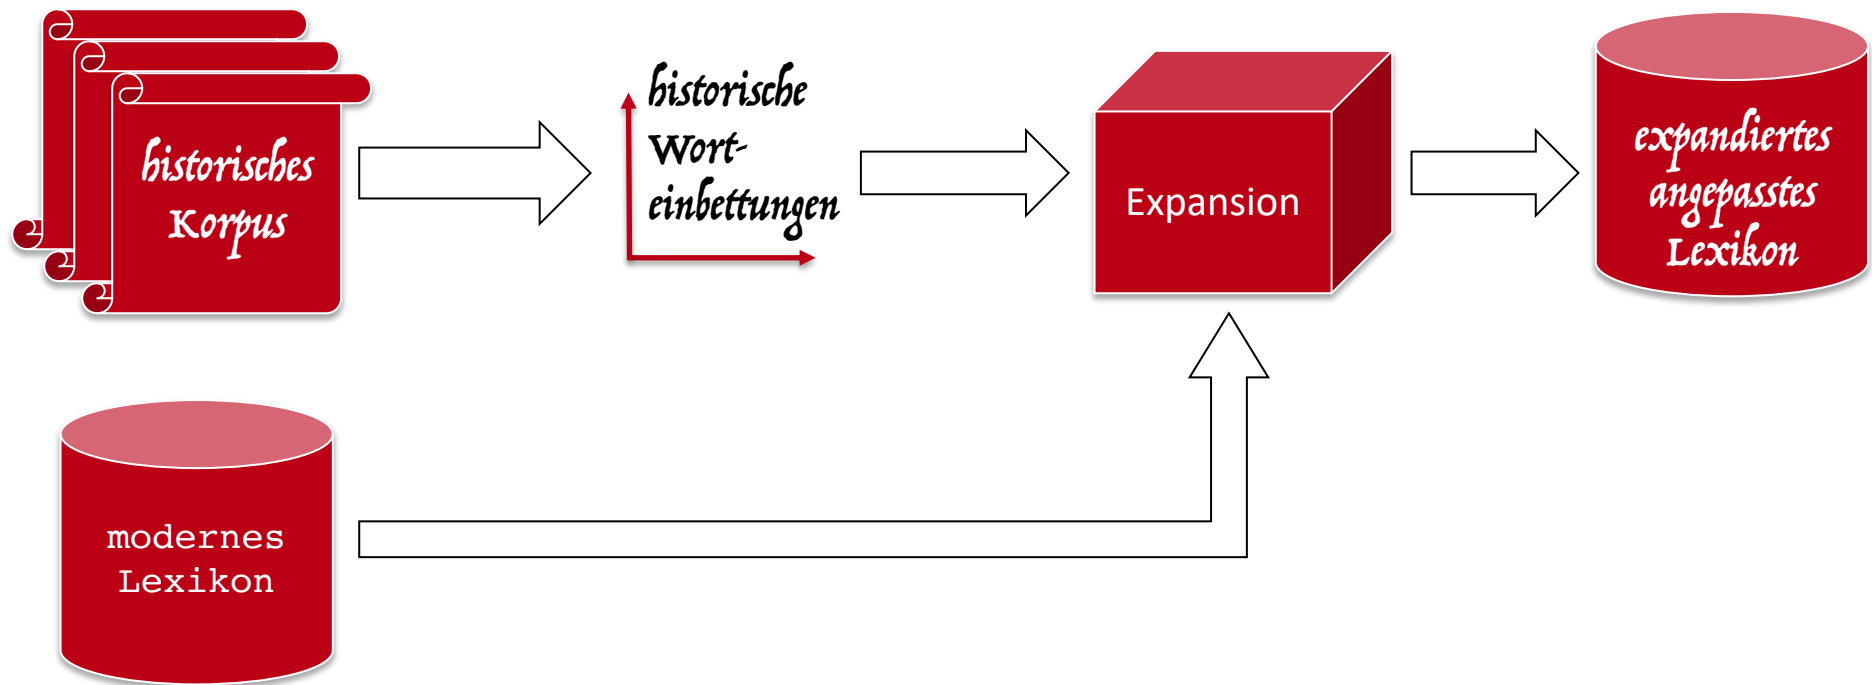


Illustration des Anpassungsschritts (vorher)






Illustration des Anpassungsschritts (nachher)



Experiment I

(Quantifizierung historischer Wortemotionen)

Methodisches Vorgehen




Ressourcen

- Computerlingustik ist stark datengetrieben:
- *Seed-Lexikon*:
 - ANGST (Schmidtke et al. (2014))
 - 1.000 deutsche Wort-Emotionspaare
- Zielkorpus:
 - Deutsches Textarchiv (DTA)
 - viele Meta-Daten verfügbar (z.B. Klassen und Unterklassen)

Lemma	Valence	Arousal	Dominance
Sonnenschein	8.1	5.3	5.4
Terrorismus	1.6	7.4	2.7
Ekstase	6.9	7.8	3.0


Zielkorpus: DTA



<http://www.deutsches-textarchiv.de/doku/textauswahl>


- Aggregation von jeweils 30-Jahres-Abschnitten
- Auswahlzeitraum 1690-1899 (~ 1000 Dokumente, 7 Abschnitte)

Zielkorpus: DTA



- Aggregation von jeweils 30-Jahres-Abschnitten
- Auswahlzeitraum 1690-1899 (~ 1000 Dokumente, 7 Abschnitte)

Emotionsverlauf von *Sünde*



- Starker Anstieg der Valenz seit Beginn der Aufklärung
- Vergleich mit korpuslinguistischen Methoden

Die 10 häufigsten Kollokationen von *Sünde*

Rang	Lemma	
	1690er	1890er
1	todt-	Lamm
2	Erzürnung	hinwegnehmen
3	läßlich	Verzeihung
4	beichten	Ausschweifung
5	Nachlaß	Gotte
6	Grobheit	Schande
7	verschweigen	Reue
8	beweinen	Ärgernis
9	pichen	Laster
10	beichten	aufrichtig

Die 10 häufigsten Kollokationen von *Sünde*

Rang	Lemma	
	1690er	1890er
1	todt-	Lamm
2	Erzürnung	hinwegnehmen
3	läßlich	Verzeihung
4	beichten	Ausschweifung
5	Nachlaß	Gotte
6	Grobheit	Schande
7	verschweigen	Reue
8	beweinen	Ärgernis
9	pichen	Laster
10	beichten	aufrichtig


Die 10 häufigsten Kollokationen von *Sünde*

Rang	Lemma	
	1690er	1890er
1	todt-	Lamm
2	Erzürnung	hinwegnehmen
3	läßlich	Verzeihung
4	beichten	Ausschweifung
5	Nachlaß	Gotte
6	Grobheit	Schande
7	verschweigen	Reue
8	beweinen	Ärgernis
9	pichen	Laster
10	beichten	aufrichtig

Experiment II


(Quantifizierung historischer Textemotionen)

Methodisches Vorgehen



Textbasierte Emotionsanalyse: JEmAS


(Buechel & Hahn, ECAI 2016)



Verfügbar:

<https://github.com/JULIELab/JEmAS>

Pipeline-Modell der Computerlinguistik



- Reihung voneinander unabhängiger Komponenten
- Schrittweise Analyse unter Rückgriff früherer Ergebnisse

Lexikonbasierter Ansatz

Kennst du das Land, wo die Zitronen blühen?

- Tokenisieren

Kennst | du | das | Land | , | wo | die | Zitronen | blühen | ?

- Lemmatisieren

Kennen | du | der | Land | , | wo | der | Zitrone | blühen | ?

- Stoppwörter und Interpunktion entfernen

Kennen | _ | _ | Land | _ | _ | _ | Zitrone | blühen | _

- Lexikonabgleich

(6,5,5) | (6,5,5) | (6,6,4) | (8,7,7)

- VAD-Berechnung

$[(6,5,5) + (6,5,5) + (6,6,4) + (8,7,7)] / 4 = (6.5, 5.75, 5.25)$

Lexikonbasierter Ansatz

Kennst du das Land, wo die Zitronen blühen?

- Tokenisieren

Kennst | du | das | Land | , | wo | der | Zitrone | blühen | ?



Temporale
Information?

- Lemmatisieren

Kennen | du | der | Land | , | wo | der | Zitrone | blühen | ?

- Stoppwörter und Interpunktion entfernen

Kennen | _ | _ | Land | _ | _ | _ | Zitrone | blühen | _

- Lexikonabgleich

(6,5,5) | (6,5,5) | (6,6,4) | (8,7,7)

- VAD-Berechnung

$[(6,5,5) + (6,5,5) + (6,6,4) + (8,7,7)] / 4 = (6.5, 5.75, 5.25)$

Lexikonbasierter Ansatz

Kennst du das Land, wo die Zitronen blühen?

- Tokenisieren

Kennst | du | das | Land | , | wo | der | Zitronen | blühen | ?

Temporale
Information?

- Lemmatisieren

Kennen | du | der | Land | , | wo | der | Zitronen | blühen | ?

Negation??

- Stoppwörter und Interpunktion entfernen

Kennen | _ | _ | Land | _ | _ | _ | Zitrone | blühen | _

- Lexikonabgleich

(6,5,5) | (6,5,5) | (6,6,4) | (8,7,7)

- VAD-Berechnung

$[(6,5,5) + (6,5,5) + (6,6,4) + (8,7,7)] / 4 = (6.5, 5.75, 5.25)$

Lexikonbasierter Ansatz

Kennst du das Land, wo die Zitronen blühen?

- Tokenisieren

Kennst | du | das | Land

Temporale
Information?

- Lemmatisieren

Kennen | du | der | Land | , | wo | der | Zit

Negation??

- Stoppwörter und Interpunktion entfernen

Kennen | _ | _ | Land | _ | _ | _ | Zitrone | blühen | _

- Lexikonabgleich


(6,5,5) | (6,5,5) | (6,6,4) | (8,7,7)

Sequenzielle
Ordnung???


- VAD-Berechnung

$[(6,5,5) + (6,5,5) + (6,6,4) + (8,7,7)] / 4 = (6.5, 5.75, 5.25)$


Maschinenlernen




Maschinenlernen




Maschinenlernen



Maschinenlernen




Maschinenlernen



Textbasierte Emotionsanalyse: JEmAS


(Buechel & Hahn, ECAI 2016)





Verfügbar:

<https://github.com/JULIELab/JEmAS>




Unterscheidung der DTA-Textsorten






■ Belletristik
■ Fachtexte




Unterscheidung literarischer Gattungen



Unterscheidung akademischer Disziplinen




Entwicklung literarischer Gattungen (1690-1719)




■ Lyrik ● Erzähltexte ▲ Dramen

Entwicklung literarischer Gattungen (1720-1749)




■ Lyrik ● Erzähltexte ▲ Dramen

Entwicklung literarischer Gattungen (1750-1779)




■ Lyrik ● Erzähltexte ▲ Dramen

Entwicklung literarischer Gattungen (1780-1809)




■ Lyrik ● Erzähltexte ▲ Dramen

Entwicklung literarischer Gattungen (1810-1839)




■ Lyrik ● Erzähltexte ▲ Dramen

Entwicklung literarischer Gattungen (1840-1869)



■ Lyrik ● Erzähltexte ▲ Dramen

Entwicklung literarischer Gattungen (1870-1899)



■ Lyrik ● Erzähltexte ▲ Dramen

Zusammenfassung


Zusammenfassung

- Methode für die Quantifizierung von Emotionen in historischer Sprache
- Kombination aus Sprachstufenanpassung für Emotionslexika und lexikonbasierter Textanalyse
- Fallstudie zur Anwendung auf das DTA-Korpus
- Qualitative Validierung auf Wort- und Textebene
- Gattungen zeigen distinktive, zeitlich veränderliche Emotionsprofile
- Ressourcen verfügbar: <https://github.com/JULIELab/HistEmo>
- Webportal zum Abfragen der Emotionswerte: <http://jeseme.org>

JeSemE 2.0 - The Jena Semantic Explorer

Results for "war" in Corpus of Historical American English
 Note: lowercased
 Search in [Corpus of Historical American English](#)

Similar Words




This chart shows the words detected as most similar to "war" and how their similarity changed over time (higher is more similar). These values are based on SVD_{PPMI} — see [Help](#) for details.

Add word to graph:

add


Word Emotion



This chart shows how the emotions connected to "war" changed over time. We describe emotions via valence (positive – negative), arousal (calm – excited) and dominance (controlled – in control) — see [Help](#) for details. Scores are given in standard deviations around an (for each time span) emotionally neutral 0.



FRIEDRICH-SCHILLER-
UNIVERSITÄT
JENA



Quantifizierung von Emotionen in Historischer Sprache

Anwendungen und Methodische Grundlagen

Sven Büchel

Jena University Language & Information Engineering
(JULIE) Lab

<http://www.julielab.de>

Friedrich-Schiller-Universität Jena