

# Sentimentanalyse

Rachele Sprugnoli

 <https://orcid.org/00-0001-6861-5595>

**Abstract** Dieses Kapitel gibt einen Überblick über die Sentimentanalyse, wobei der Schwerpunkt darauf liegt, wie sie typischerweise im Bereich der Digital Humanities angewendet wird. Insbesondere werden sprachliche Probleme wie Ironie und die Verwendung von Emojis erörtert, die die Sentimentanalyse zu einer Herausforderung machen und es wird eine kurze Beschreibung verschiedener Aufgaben und Teilaufgaben gegeben, die alle mit subjektiven Texten zu tun haben, aber aus unterschiedlichen Blickwinkeln betrachtet werden: z. B. Klassifizierung der Subjektivität, Klassifizierung der Polarität auf Dokument- und Satzebene, aspektbasierte Sentimentanalyse, Erkennung von Haltungen, Erkennung von Ironie und Emotionen. Darüber hinaus stellen wir lexikonbasierte und maschinelle Lernansätze zur Sentimentanalyse vor. Offene Fragen und bewährte Verfahren für die Anwendung von Methoden der Sentimentanalyse in den Digital Humanities werden ebenfalls erörtert, und das Kapitel schließt mit einer Liste aufkommender Trends in diesem Bereich.\*

**Keywords** sentiment analysis, opinion mining, emotion analysis

## 1. Einleitung

Die Sentimentanalyse (SA) ist ein Forschungsgebiet im Bereich der natürlichen Sprachverarbeitung (orig. „Natural Language Processing“, NLP),<sup>1</sup> die darauf abzielt, Meinungen, Gefühle, persönliche Bewertungen von Entitäten (z. B. Personen, Orte, Produkte) oder Ereignisse und Themen, die in schriftlichen Texten zum Ausdruck kommen, zu identifizieren und zu klassifizieren (Liu 2022). In ihrer einfachsten Form unterscheidet die SA Texte nach ihrer Polarität (oder Stimmungsorientierung): „Ich liebe Krimis“ hat eine positive Polarität, „Ich mag keine Liebesromane“ hat eine nega-

\* Dieses Kapitel wurde inkl. fremdsprachiger Zitate von der Redaktion aus dem Englischen übersetzt.

1 Traditionell wird zwischen der Computerlinguistik, die als Teilgebiet der Linguistik betrachtet wird, und der natürlichen Sprachverarbeitung, die als Teilgebiet der Ingenieurwissenschaften oder der Informatik betrachtet wird, unterschieden (Bender, 2016). In diesem Kapitel werden wir jedoch eine integrierte Sichtweise dieser beiden Bereiche einnehmen, da beide das Ziel haben, eine linguistische Analyse durchzuführen und linguistische Daten als Input zu verwenden.

tive Polarität und „Agatha Christie war eine englische Schriftstellerin“ hat eine neutrale Polarität.<sup>2</sup>

In der Literatur gibt es viele alternative Ausdrücke für dieses vielschichtige Problem: Wir finden u. a. *Opinion Mining*, *Opinion Extraction*, *Sentiment Mining*, Affektanalyse und Polaritätserkennung. In diesem Zusammenhang werden die Begriffe *Stimmung* (Engl.: *sentiment*) und *Meinung* (Engl.: *opinion*) oft als Synonyme betrachtet; obwohl sie das nicht sind, ist die Unterscheidung sehr subtil, und sie sind eng miteinander verbunden. Der Satz „Ich langweile mich beim Lesen von romantischen Büchern“ drückt eine negative Stimmung aus, die durch das Gefühl der Langeweile ausgelöst wird, während „Ich finde, dass romantische Bücher alle die gleiche Handlung haben“ eine negative Meinung ausdrückt; dieses Beispiel zeigt, dass eine negative Stimmung eine negative Meinung impliziert und eine negative Meinung auf eine negative Stimmung zurückzuführen ist. Die SA umfasst auch andere Forschungs- und Anwendungsbereiche, die detailliertere Unterscheidungen erfordern und auf die in einem gesonderten Abschnitt eingegangen wird; beispielsweise ermittelt die aspektbasierte SA die Stimmung bestimmter Attribute oder Komponenten einer Entität.

Das wachsende Interesse an SA geht Hand in Hand mit der zunehmenden Verbreitung von Online-Rezensionen, Foren, Microblogs und sozialen Netzwerken, die eine enorme Menge an subjektiven Texten produzieren, in denen User\*innen ihre Meinungen und Bewertungen zum Ausdruck bringen. Die SA wird auch in den Bereichen der Unternehmens-, Kommunikations- und Sozialwissenschaften als nützliches Instrument betrachtet: Es gibt zahlreiche Anwendungen, die die Meinung der Kunden zu einer Dienstleistung oder einem Produkt beobachten oder die Einstellung der Akteure in sozialen Netzwerken untersuchen. Es gibt auch Arbeiten, die Methoden und Techniken der SA an die Geisteswissenschaften anpassen, mit Anwendungen auf historische, literarische oder klassisch sprachliche Texte.

In diesem Kapitel werden die grundlegenden Definitionen und Konzepte im Zusammenhang mit der SA-Forschung vorgestellt, um die Leser\*innen für die Herausforderungen im Zusammenhang mit der SA zu sensibilisieren, v. a. auf dem Gebiet der Digital Humanities (DH).

2 Sofern in einer Fußnote nicht anders angegeben, wurden die Beispiele in diesem Kapitel von der Autorin selbst erstellt.

## 2. Warum die Sentimentanalyse eine Herausforderung ist – Einige sprachliche Eigenheiten

Die im vorigen Abschnitt genannten Beispiele sind aus sprachlicher Sicht äußerst einfach, aber die Sprache, die wir verwenden, um unsere subjektiven Bewertungen auszudrücken, ist komplex und besteht aus vielen Komponenten, die SA zu einer interessanten Herausforderung sowohl für Menschen als auch für Computer machen.

Zunächst einmal kann ein und dasselbe Wort in verschiedenen Kontexten unterschiedliche Bedeutungen haben, die unterschiedliche Gefühle kodieren. Das Adjektiv *scharf* kann beispielsweise mit einem negativen Gefühl assoziiert werden, wenn es „scharf und schmerzhaft empfunden“ bedeutet, aber es hat eine positive Bedeutung, wenn es „die Fähigkeit haben oder demonstrieren, feine Unterschiede zu erkennen oder zu ziehen“ bedeutet.<sup>3</sup>

Außerdem werden Meinungen nicht immer explizit und direkt geäußert, sondern haben oft eine implizite oder vergleichende Form. Implizite Meinungen sind solche, die sich auf Tatsachen oder Wirkungen beziehen, die mit dem Gegenstand der Meinung zusammenhängen: Der Satz „Dieses Buch bringt mich nur zum Gähnen“ beschreibt z. B. eine Nebenwirkung des Lesens eines langweiligen Buches. Komparative Meinungen hingegen stellen verschiedene Elemente auf der Grundlage desselben Aspekts nebeneinander, wie z. B. „Ich finde, die Romane von Agatha Christie haben eine linearere Handlung als die von Arthur Conan Doyle“: Es ist interessant festzustellen, dass es schwierig ist, die Stimmung dieses letzten Beispiels zu verstehen, da sie vom persönlichen Geschmack des Lesenden abhängt.

Implizite Meinungen erfordern oft (außersprachliches) Weltwissen, um richtig interpretiert zu werden. Der Satz „Sie sieht aus wie eine Madonna von Botticelli!“ drückt ein positives Gefühl aus, indem er sich auf die Harmonie und Schönheit der von dem Renaissancekünstler gemalten Gesichter bezieht; im Gegensatz dazu verweist „Er sieht aus wie ein Picasso-Gemälde!“ auf die unstrukturierten Gesichter des Kubismus und damit auf ein Gesicht mit unproportionierten Zügen.

Weltwissen ist auch erforderlich, um wörtliche von ironischen Inhalten zu unterscheiden. Ironie ist eine Art der figurativen Sprache, die absichtlich verwendet wird, um einem Satz eine der wörtlichen Bedeutung entgegengesetzte Bedeutung zu geben. Nach der Definition von Utsumi (2000) in seiner *Implicit Display Theory* ist verbale Ironie eine Äußerung oder eine Aussage, die implizit ein ironisches Umfeld zeigt, in dem der Sprechende eine negative emotionale Einstellung gegenüber der Inkongruenz zwischen dem, was er/sie erwartet und dem, was tatsächlich ist, hat. Der Begriff Ironie wird häufig als Oberbegriff für Sarkasmus verwendet (Grice 1975), der in der Tat eine besondere Form der Ironie ist, die dazu dient, sich auf verächtliche

3 Definitionen entnommen aus WordNet 3.1. URL: <http://wordnetweb.princeton.edu/perl/webwn>, zuletzt aufgerufen am 23.06.2024.

oder ätzende Weise über jemanden lustig zu machen oder ihn zu beleidigen. Sowohl Ironie als auch Sarkasmus sind in der SA besonders interessant, weil sie Stimmungsumwandler sind, d. h. sie ändern die Polarität: ein Satz wie „die Wifi-Verbindung ist toll – sie ist schnell wie ein Faultier“ bedeutet genau das Gegenteil von dem, was er zu sein scheint (die Wifi-Verbindung ist langsam), aber seine offensichtliche sprachliche Form würde dazu führen, ihm eine positive Polarität zuzuweisen.

Ein weiterer Aspekt, den es zu berücksichtigen gilt, ist das Vorhandensein von Emoticons und Emojis, die bei informellen Texten wie Posts in sozialen Netzwerken und Foren eine wichtige Rolle spielen. Vergleicht man „Rom :)“ mit „Rom :(“, so wird deutlich, dass die Meinung über die Stadt vollständig durch das Emoticon ausgedrückt wird; ohne dieses hätte der Name Rom allein keine Polarität. Mit anderen Worten, diese Elemente verstärken die Ausdruckskraft eines Textes und vermitteln ihre eigene spezifische Stimmung, auch wenn diese nicht immer leicht zu erkennen ist. Das Feuer-Emoji zum Beispiel wird meist mit der Bedeutung „ausgezeichnet“ oder „attraktiv“ verwendet (also mit einer positiven Stimmung), kann aber auch Ärger signalisieren (also eine negative Stimmung) oder eine Tatsache wie das Vorhandensein von Feuer oder übermäßiger Hitze (in diesem Fall mit einer neutralen Stimmung).

### 3. Ein Name, viele Aufgaben

Wie Liu bereits 2010 feststellte, ist die SA ein vielschichtiges Problem: Es handelt sich nicht um eine einzelne monolithische linguistische Aufgabe; für sie gibt es keine einheitliche Lösung, sondern sie kann durch Berücksichtigung verschiedener Analyseebenen angegangen werden.

Auf der ersten Ebene geht es um die sogenannte Subjektivitätsklassifizierung, die darauf abzielt, objektive Texte, die Sachinformationen enthalten, von subjektiven, meinungsbetonten Texten zu unterscheiden, die Gefühle, Standpunkte oder persönliche Überzeugungen ausdrücken. Dies ist der erste Schritt zu einer tiefergehenden Analyse: Bei objektiven Texten ist es nämlich nicht möglich, eine Polarität zu erkennen (sie sind neutral), während subjektive Texte nach ihrer Gefühlsausrichtung klassifiziert werden können.

Die Klassifizierung der Polarität ist der nächste Schritt und besteht darin, einer Informationseinheit einen Wert zuzuweisen, der angibt, ob sie eine positive, negative oder neutrale Stimmung zum Ausdruck bringt. Dieser Wert kann kategorisch oder numerisch sein, und die Bandbreite der möglichen Werte kann je nach gewünschtem Detaillierungsgrad erheblich variieren. So gibt es bspw. binäre Klassifizierungen (mit nur zwei Werten wie *positiv* und *negativ*), 3-wertige Klassifizierungen (z. B. *positiv*, *neutral*, *negativ* oder  $+1$ ,  $0$ ,  $-1$ ), 5-wertige Klassifizierungen (z. B. *sehr positiv*, *etwas positiv*, *neutral*, *etwas negativ*, *sehr negativ* oder  $+1$ ,  $+0,5$ ,  $0$ ,  $-0,5$ ,  $-1$ ), aber auch dezimale Bewertungen in einem kontinuierlichen Bereich (typischerweise zwischen  $+1$  und  $-1$ ).

Die Klassifizierung der Polarität kann auf unterschiedlicher Granularität erfolgen, d. h. unter Berücksichtigung verschiedener Arten von Informationseinheiten: das gesamte Dokument, jeweils ein einzelner Satz oder ein bestimmter Aspekt. Bei der Klassifizierung auf Dokumentenebene wird einem gesamten Dokument (z. B. einer Buchrezension) ein Polaritätswert zugewiesen, indem ein solches Dokument als einzelne Informationseinheit betrachtet wird, die die Meinung einer einzelnen Person (des\*der Autor\*in der Rezension) zu einer einzelnen Entität (einem Buch) zum Ausdruck bringt. Die gleiche Art der Klassifizierung kann auch auf Satzebene angewendet werden. Die SA auf Satzebene ist nützlich, weil ein und dasselbe Dokument in verschiedenen Sätzen unterschiedliche oder sogar entgegengesetzte Meinungen enthalten kann. Eine Buchrezension kann z. B. aus neutralen Sätzen bestehen, die die Handlung beschreiben, ohne persönliche Urteile abzugeben, und aus anderen Sätzen, die Wertschätzung oder Ablehnung ausdrücken.

Eine noch granularere Ebene der Analyse bietet die entitäts- oder aspektbasierte SA,<sup>4</sup> die darauf abzielt, die Meinungen über einzelne Entitäten oder Merkmale von Entitäten zu extrahieren. Im Fall der oben erwähnten Rezension ist das Buch die Entität, die bewertet wird, während zwei relevante Merkmale die Handlung und der Preis sein können; die Stimmung kann für jedes dieser Elemente unterschiedlich sein, z. B. kann sie für das Buch selbst und für die Handlung positiv sein, aber für den Preis negativ wie in „Ich habe das Buch gerne gelesen, weil die Handlung fesselnd ist, aber der Preis ist zu hoch: nicht jeder kann 25 Euro für ein Buch ausgeben!“. Die Aufgabe besteht also aus zwei Hauptphasen: zunächst die Extraktion von Entitäten und/oder Merkmalen und dann die Klassifizierung der Stimmung für jedes dieser Merkmale. Es ist wichtig zu beachten, dass die relevanten Merkmale entitätstypspezifisch sind: Wenn der Preis für jedes kommerzielle Produkt oder jede Dienstleistung wichtig ist, ist die Handlung spezifisch für Bücher und Filme. Bei einem Mobiltelefon können dagegen die Akkulaufzeit und die einfache Konfiguration als Merkmale identifiziert werden, während für Hotels der Standort besonders wichtig ist.

#### 4. Andere verwandte Aufgaben

In diesem Abschnitt geben wir einen Überblick über andere Aufgaben, welche als Teilprobleme der SA angesehen werden und die alle mit subjektiven Texten zu tun haben, aber aus unterschiedlichen Blickwinkeln betrachtet werden.

**Stance Detection:** Bei der Erkennung von Haltungen geht es darum, festzustellen, ob der\*die Autor\*in eines Textes für oder gegen eine Entität, ein Ereignis oder ein Thema ist (AlDayel & Magdy 2021). Aus linguistischer Sicht ist die Haltung ein offe-

4 Die aspektbasierte SA ist auch als merkmalsbasierte SA bekannt.

ner Ausdruck, der verwendet wird, um ein bestimmtes Zielelement zu bewerten und sich in Bezug auf die anderen zu positionieren, indem man eine Ausrichtung oder Opposition zeigt (Du Bois 2007). Aus diesem Grund erfordert die Erkennung der Haltung ein bestimmtes Ziel, um den Standpunkt des\*der Autors\*in gegenüber diesem Ziel zu messen, und das Ergebnis der Klassifizierung ist eine der drei Kennzeichnungen *Dafür*, *Dagegen* oder *Weder noch*, anstatt *Positiv*, *Negativ* oder *Neutral* wie im einfachsten Fall der Polaritätsklassifizierung. Haltung und Polarität sind unabhängig voneinander: Eine positive Stimmung führt nicht zwangsläufig zu einer unterstützenden Haltung, ebenso wie eine negative Stimmung nicht zwangsläufig mit einer ablehnenden Haltung verbunden ist. Nimmt man z. B. die Aussage „Der Klimawandel ist ein echtes Problem“ als Ziel, so drückt der Satz „Es ist so traurig, dass zu viele Menschen nichts tun wollen, während unser Planet verbrennt“ eine negative Stimmung, aber eine unterstützende Haltung gegenüber der Aussage aus. Diese Aufgabe wird meist bei politischen und sozialen Themen angewandt, um die Haltung der Nutzer\*innen sozialer Netzwerke zu einer politischen Figur oder zu Vorschlägen abzufangen, die als kontrovers angesehen werden, wie z. B. die Liberalisierung von Drogen und die gleichgeschlechtliche Ehe.

**Irony Detection & Sarcasm Detection:** Aufgaben zur Erkennung von Ironie und Sarkasmus zielen darauf ab, zwischen ironischen oder sarkastischen und nicht-ironischen oder nicht-sarkastischen Texten zu unterscheiden (Maynard und Greenwood 2014). Während Ironie in der Regel unkritisch ist, ist Sarkasmus eher aggressiv; allerdings führen beide figurativen Mittel zu einer Diskrepanz zwischen der wörtlichen und der beabsichtigten Bedeutung eines Textes. Manchmal wird eine binäre Klassifizierung vorgenommen, ohne zwischen Ironie und Sarkasmus zu unterscheiden, während in anderen Fällen eine detailliertere Klassifizierung versucht wird, indem verschiedene Arten von Ironie erkannt werden, z. B. durch die Unterscheidung von Sarkasmus, Satire oder Parodie (Abu Farha et al. 2022).

**Emotion Analysis:** Bei der Emotionsanalyse geht es darum, festzustellen, welche Emotionen in einem Text vermittelt werden. Die wissenschaftliche Untersuchung von Emotionen hat Psycholog\*innen und Anthropolog\*innen seit der Veröffentlichung von Darwins bahnbrechendem Werk *The Expression of the Emotions in Man and Animals* im Jahr 1872 interessiert. Obwohl die Theorien zahlreich sind, gibt es zwei Hauptansätze, auf denen die Berechnungstechniken basieren. Der erste Ansatz geht davon aus, dass Emotionen angeboren, kulturübergreifend und zahlenmäßig begrenzt sind, sodass sie mit kategorialen Bezeichnungen klassifiziert werden können. Im NLP werden diese Bezeichnungen oft von den Theorien von Ekman (1993) oder Plutchik (1980) übernommen. Ekman unterscheidet sechs Emotionen (Wut, Abscheu, Traurigkeit, Freude, Angst, Überraschung), während Plutchik vier Paare von Basisemotionen definiert (Freude versus Traurigkeit, Wut versus Angst, Vertrauen versus Abscheu, Überraschung versus Erwartung), die miteinander kombiniert werden, um

Dyaden, d. h. komplexe Emotionen zu bilden (z. B. ist Liebe eine Kombination aus Freude und Vertrauen). Beim zweiten Ansatz hingegen können Emotionen nicht etikettiert werden, sondern werden anhand verschiedener Dimensionen mit kontinuierlichen Werten dargestellt. Im Zirkumplex-Modell (Russell 1980) gibt es zwei grundlegende Dimensionen des emotionalen Erlebens: die Valenz, d. h. den Grad der Annehmlichkeit, und die Erregung, d. h. die Intensität der Emotion. Eine dritte Dimension, die Dominanz, wird häufig zu den beiden anderen hinzugefügt, um den Grad der Kontrolle zu kodieren, den die Emotion über die Person ausübt, die sie erlebt. Nach diesem Ansatz, der unter dem Akronym VAD (*Valence-Arousal-Dominance*) bekannt ist, hat Wut zum Beispiel eine niedrige Valenz, hohe Erregung und hohe Dominanz.

## 5. Methoden

Im Hinblick auf die Entwicklung von SA-Systemen können zwei Hauptansätze unterschieden werden: solche, die auf Lexika basieren, und solche, die Algorithmen des maschinellen Lernens verwenden, sowohl überwachte als auch unüberwachte.

Lexikonbasierte Methoden beruhen auf der Intuition, dass die Polarität eines Textes auf der Grundlage der Polarität der Wörter, aus denen er besteht, ermittelt werden kann (Taboada 2011). Diese Polarität wird aus Lexika gewonnen, die aus Listen von Token, Lemmata oder Phrasen bestehen, in denen jeder lexikalische Eintrag mit einem kategorischen oder numerischen Wert (z. B. *Positiv* oder +1) verknüpft ist, der seine Stimmungsausrichtung quantifiziert. Polaritätslexika sind für zahlreiche Sprachen verfügbar (Mohammed & Balakrishnan 2020): Einige wurden manuell von Expert\*innen (z. B. aus der Linguistik oder Psychologie) oder mit Hilfe von *Crowdsourcing*-Techniken erstellt (Mohammad & Turney 2013),<sup>5</sup> aber die Entwicklung dieser Ressourcen ist sehr zeitaufwendig, sodass auch automatische Ansätze erprobt wurden, z. B. durch Nutzung der maschinellen Übersetzung oder verfügbarer lexikografischer Ressourcen und Korpora. Lexika erfassen in der Regel die vorrangige Polarität von Wörtern, d. h. die Stimmung, die sie über ihren Verwendungskontext hinaus hervorrufen. So werden Wörter wie *Freundschaft* und *Liebe* mit einer positiven Polarität assoziiert, während *Mord* und *Hass* mit einer negativen verbunden sind. Seltener sind Lexika, die sinnbasierte Polaritäten enthalten. Das bekannteste ist *SentiWordNet* (Baccianella et al. 2010), in dem jedes *WordNet*-Synset (Miller 1995) einen positiven, einen negativen und einen objektiven Wert hat. Auf der Grundlage dieser Lexika werden Skripte erstellt, die das Verhältnis zwischen positiven und negativen Wörtern innerhalb des zu analysierenden Textes berechnen: Wenn der Text mehr

5 Die Arbeit wird von nicht fachkundigen Mitarbeiter\*innen durchgeführt, die auf speziellen Webplattformen eingestellt werden.

positive Wörter enthält, wird er als positiv eingestuft, andernfalls als negativ. Dieser Ansatz ist sehr einfach anzuwenden, ist aber tendenziell weniger genau als die Methoden des maschinellen Lernens, weil die Abdeckung des Lexikons nicht unbegrenzt ist und weil der spezifische Kontext die Polarität eines Wortes verändern kann. Es ist wichtig zu erwähnen, dass der lexikonbasierte Ansatz auch bei der Emotionsanalyse angewendet werden kann: In diesem Fall werden Emotionslexika verwendet, die Wort-Emotionen-Assoziationen enthalten. Abb. 1 zeigt, wie sehr sich fünf englische Lexika in der Art und Weise unterscheiden, wie sie demselben Wort, nämlich dem Substantiv *Einladung*, Polarität oder emotionale Werte zuordnen. Die für diesen Vergleich herangezogenen Lexika sind: *SenticNet* (Cambria et al. 2022), *NRC-VAD-Lexicon* (Mohammad 2018), *SentiWordNet 3.0*, *DepecheMood++* (Araque et al. 2019) und *NRC-Emotion-Lexicon* (Mohammad & Turney 2013).

**SenticNet**

POLARITY
positive

**NRC-VAD-Lexicon**

VALENCE	AROUSAL	DOMINANCE
0.802	0.549	0.647

**SentiWordNet 3.0**

PoS	Synset ID	PosScore	NegScore	Gloss
n	07186148	0	0	a request (spoken or written) to participate...
n	04689048	0.5	0	a tempting allurement

**DepecheMood++**

AFFRAID	AMUSED	ANGRY	ANNOYED	DONT_CARE	HAPPY	INSPIRED	SAD
0.045481	0.155150	0.130596	0.154374	0.179065	0.135442	0.148765	0.051123

**NRC-Emotion-Lexicon**

ANGER	ANTICIPATION	DISGUST	FEAR	JOY	SADNESS	SURPRISED	TRUST	POSITIVE	NEGATIVE
0	1	0	0	0	0	0	0	1	0

**Abb. 1** Einträge für das Substantiv *Einladung* in verschiedenen Polaritäts- und Emotionslexika.

Unter maschinellem Lernen versteht man im Zusammenhang mit NLP den Prozess des Trainings eines Computersystems zur Durchführung einer bestimmten linguistischen Aufgabe. Beim überwachten Ansatz wird der Algorithmus anhand eines Satzes annotierter Daten trainiert, d. h. einer Auswahl von Texten, bei denen die erwartete Klassifizierung vorgegeben ist (z. B. eine Sammlung von Sätzen, denen jeweils ein Polaritätswert zugeordnet ist). Im Gegensatz dazu werden bei der unüberwachten Methode keine Trainingsdaten zur Verfügung gestellt, sondern versucht, dass das System selbstständig Verallgemeinerungen aus den Eingabetexten extrahiert. Im Allgemeinen ist das unüberwachte Lernen weniger kostspielig als das überwachte Lernen,



da es keine Trainingsdaten benötigt, aber die Ergebnisse sind weniger genau. Aus diesem Grund gibt es zahlreiche Initiativen, die darauf abzielen, annotierte Daten für alle in den vorangegangenen Abschnitten erwähnten Aufgaben zu erstellen, die viele Sprachen und verschiedene Textgattungen abdecken. Im Laufe der Zeit haben sich die verwendeten Algorithmen des maschinellen Lernens weiterentwickelt, und *Deep-Learning*-Techniken werden nun in größerem Umfang eingesetzt, was zu erheblichen Verbesserungen der Systemleistung führt (Yadav & Vishwakarma 2020).

Unabhängig von der verwendeten Methode variiert die Systemleistung je nach Aufgabe, Textart und Granularität der Analyse stark. Im Allgemeinen gilt: Je größer die Anzahl der für die Klassifizierung verwendeten Labels ist, desto komplexer ist die Aufgabe und desto geringer ist die Leistung (Wankhade 2022).

## 6. Sentiment-Analyse in der Digital-Humanities-Forschung

Obwohl die gebräuchlichsten Ressourcen und Werkzeuge für die SA in Kategorien wie die Analyse sozialer Netzwerke und die Beobachtung von Kundenmeinungen fallen, hat die Forschung im Bereich der DH in den letzten Jahren zugenommen. Generell steigt das Interesse an der Verwendung von NLP-Methoden für die Verarbeitung geisteswissenschaftlicher Daten, wie die große Beteiligung an speziellen wissenschaftlichen Veranstaltungen zeigt.<sup>6</sup> In diesem zunehmend reichhaltigen Panorama von Projekten und Aktivitäten an der Schnittstelle zwischen DH und NLP wird die SA als eine fruchtbare Technik zur Anreicherung von Textdaten angesehen, insbesondere in den Bereichen Geschichte und Literaturwissenschaft.

Die meisten Arbeiten im historischen Bereich verwenden in erster Linie digitalisierte Zeitungsartikel als Daten, um zu verstehen, wie wichtige Ereignisse oder berühmte Persönlichkeiten von ihren Zeitgenossen wahrgenommen wurden. So wird beispielsweise die entitätenbasierte SA im Projekt *Oceanic Exchanges* verwendet, um die in deutschen Zeitungen des 19. Jahrhunderts geäußerte Meinung gegenüber einer Gruppe von Schriftstellern derselben Zeit zu ermitteln (Keck et al., 2020), während Viola (2023) dieselbe Methode zur Analyse der Stimmung gegenüber einer Auswahl von Entitäten in von italienischen Einwanderern herausgegebenen US-Zeitungen einsetzt. Andererseits untersuchen Mayer et al. (2022) die transnationale Rezeption der Hinrichtung von Maximilian I., Kaiser von Mexiko, im Jahr 1867 anhand von

6 S. z. B. die jährlichen Workshops der ACL *Special Interest Group on Language Technologies for the Socio-Economic Sciences and Humanities* (LaTeCH, <https://sighum.wordpress.com/events>), die *Computational Humanities Research Conference* (CHR, <https://2023.computational-humanities-research.org>), den *Workshop on Ancient Language Processing* (ALP, <https://www.ancientnlp.com/alp2023/>) und den *Workshop on Language Technologies for Historical and Ancient Languages* (LT4HALA, <https://circse.github.io/LT4HALA/>). Alle Adressen wurden zuletzt am 23.06.2024 aufgerufen.

Zeitungen aus verschiedenen Ländern. Die Fallstudie von Sprugnoli et al. (2016) ist anders, da sie sowohl vorgängige als auch kontextuelle Polaritäten in italienischen politischen Texten der ersten Hälfte des 20. Jahrhunderts aufspürt und zeigt, dass eine Stimmungsorientierung oft implizit ausgedrückt wird, was die Zuweisung eines Polaritätswerts selbst für Menschen besonders schwierig macht.

Das Spektrum der Forschung auf dem Gebiet der computergestützten Literaturwissenschaft ist breiter. Ausgehend von der Pionierarbeit von Anderson & McMaster (1982) über die Messung affektiver Töne in den Kapiteln eines Romans und in einer Reihe von Kindergeschichten betreffen die Anwendungen verschiedene Textgattungen (Schauerromane, Romanzen, Märchen, Theaterstücke, Fan-Fiction) und verschiedene Zwecke (zu verstehen, was eine Handlung fesselnder macht als eine andere, welche Rolle Emotionen in den Interaktionen zwischen Figuren spielen, wie Emotionen dabei helfen können, zwischen verschiedenen literarischen Gattungen zu unterscheiden, was die emotionalen Bögen von Geschichten sind), wie in den Übersichtsarbeiten von Kim & Klinger (2019) und Reborra (2023) beschrieben, auf die wir für weitere Einzelheiten verweisen.

## 7. Offene Fragen und bewährte Praktiken

Die bisher zitierten Arbeiten (sowie all jene, die wir aus Platzgründen nicht zitieren konnten) haben sich auf die eine oder andere Weise mit verschiedenen Fragen der geisteswissenschaftlichen Forschungspraxis und mit den Merkmalen geisteswissenschaftlicher Texte in nicht zeitgenössischen Sprachen befasst. Erstens sind literarische und historische Texte oft spärlich, uneinheitlich, unvollständig und weisen aufgrund von diachronen und diatopischen Phänomenen zahlreiche orthographische Variationen auf. Außerdem müssen die Texte in einem maschinenlesbaren Format vorliegen, damit sie von NLP-Systemen verarbeitet werden können: Die Verwendung von OCR-Systemen (*Optical Character Recognition*) bei Digitalisierungsprozessen, insbesondere bei Manuskripten oder alten Drucken, ist nicht frei von Fehlern, und es ist oft notwendig, einzugreifen, um das Rauschen (orig. „noise“) zu reduzieren und qualitativ hochwertige Daten zu erhalten. Darüber hinaus arbeiten Geisteswissenschaftler\*innen mit Textgattungen (z. B. Gedichte, Theaterstücke, philosophische und historische Abhandlungen), die sich stark von denen unterscheiden, die normalerweise von NLP-Systemen analysiert werden: Dies erfordert, dass solche Systeme entsprechend angepasst oder von Grund auf neu entwickelt werden. Nicht zuletzt sind die Endnutzer\*innen von Digital-Humanities-Anwendungen Geisteswissenschaftler\*innen, die oft nicht technisch versiert sind, sodass es wichtig ist, einfache, intuitive und transparente Systeme zu entwickeln.

Der Mangel an großen Datenmengen, auf denen maschinelle Lernsysteme trainiert werden können, in Verbindung mit der Nachfrage nach Systemen, deren Ergeb-

nisse leicht zu interpretieren sind, hat zur weit verbreiteten Annahme des lexikonbasierten Ansatzes in den DH geführt (Ohman 2021). Tatsächlich werden Algorithmen des maschinellen Lernens oft kritisiert, weil sie schwer zu interpretieren sind; sie sind wie *Black Boxes* und nicht einmal die Entwickler\*innen sind in der Lage, hinreichend zu erklären, warum bestimmte Entscheidungen und folglich bestimmte Vorhersagen getroffen werden. Im Gegensatz dazu erleichtern lexikonbasierte Systeme das Verständnis der Ergebnisse, indem sie Trends und Passagen hervorheben, die dann durch genauere Lektüre erneut analysiert werden können. Darüber hinaus hat der Bedarf an intuitiven Systemen zur Entwicklung anwendungsfreundlicher grafischer Oberflächen geführt, die sich besser für die Nutzung durch Laien eignen als Programmierskripte; einige Beispiele sind *SEANCE* (Crossley et al. 2017), *Lingmotif* (Moreno-Ortiz 2017) und *SentText* (Schmidt et al. 2021). Es ist wichtig anzumerken, dass *Syuzhet*, das erste SA-System, das in der DH-Community auf große Resonanz, aber auch auf zahlreiche Kritik stieß, lexikonbasiert und aus rechnerischer Sicht extrem einfach ist, da es auf einer einfachen Wortzählung basiert;<sup>7</sup> seither wurden lexikonbasierte Ansätze jedoch verfeinert und die oben genannten Tools enthalten Vorverarbeitungsfunktionen (z. B. Entfernung von Stoppwörtern, Lemmatisierung) und Regeln zur Behandlung von Negationen.

Unabhängig davon, welche Methode verwendet wird und ob eine Polaritäts- oder eine Emotionsanalyse durchgeführt werden soll, müssen verschiedene Aspekte berücksichtigt werden (Mohammad 2023). Es ist in der Tat notwendig, ein Lexikon, Daten und ein zu verwendendes System auszuwählen oder zu entscheiden, neue Ad-hoc-Ressourcen zu entwickeln, die für den interessierenden Bereich geeignet sind, weil die vorhandenen nicht mit den Zielen der Forschung übereinstimmen. Dazu gehört die Wahl der Art der Konzeptualisierung, d. h. ob man sich für den kategorialen oder den dimensionalen Ansatz entscheidet, aber auch, ob man kontinuierliche Werte oder diskrete Bezeichnungen verwendet, sowie der beste Granularitätsgrad (mit anderen Worten, wie viele Klassen oder wie viele Dimensionen man erfassen will). Wenn ein neues Lexikon oder ein neuer annotierter Datensatz von Grund auf neu entwickelt werden soll, ist es außerdem von entscheidender Bedeutung, ob Expert\*innen oder Laien als Annotator\*innen rekrutiert werden sollen, indem man Crowdsourcing-Techniken einsetzt. Diese zweite Option, die bei Texten aus sozialen Netzwerken und zeitgenössischen Sprachen weit verbreitet ist, ist bei historischen und alten Sprachen schwieriger anzuwenden. Darüber hinaus muss speziell bei alten Sprachen auch das Problem des Mangels an Muttersprachler\*innen angegangen werden, da es unmöglich ist, sich auf die Intuition oder die persönliche Sensibilität der Annotator\*innen zu verlassen. Hier ist es daher unerlässlich, Sprach- und Kultur-expert\*innen einzubeziehen (Sprugnoli et al. 2020).

Die Festlegung des meist geeigneten Verfahrens kann ein langer interaktiver Prozess sein, der aus mehreren Experimentierphasen besteht. So beschreiben

7 S. <http://www.matthewjockers.net/2015/02/02/syuzhet>, zuletzt aufgerufen am 23.06.2024.

Schmidt et al. (2021) detailliert die Entscheidungen, die getroffen wurden, um ein neues Schema für die Annotation von Emotionen in deutschen Theaterstücken, die um 1800 geschrieben wurden, zu definieren. Obwohl sie zunächst in Erwägung zogen, den kategorialen Ansatz mit den von Ekman oder Plutchik definierten Basisemotionen zu übernehmen, stellten sie bald fest, dass die psychologischen Theorien, auf denen diese Kategorien beruhten, die Emotions- und Affektkonzepte der Literaturtheorien nicht widerspiegeln. Dank einer Pilotkommentierung stellten sie fest, dass einige Emotionen besonders relevant waren, auch wenn sie zu keiner psychologischen Theorie gehörten (z. B. Freundschaft), während andere in dramatischen Texten keine große Bedeutung hatten (z. B. Ekel). Am Ende erarbeiteten sie ein neues hierarchisches Schema, das aus 13 Emotionskonzepten besteht. Ein weiteres interessantes Beispiel ist die Analyse von Emotionen in Gedichten, die zeigt, wie ein und dieselbe Textgattung unter Berücksichtigung verschiedener Aspekte behandelt werden kann (Sprugnoli et al. 2023), z. B. das Kompetenzniveau der Annotator\*innen (Expert\*innen oder Crowdworker), die zu annotierende Texteinheit (Zeile, Satz, Strophe, ganzes Gedicht), die Anzahl der berücksichtigten Emotionen (zwei oder mehr) und die allgemeine Perspektive (Emotionen werden so annotiert, wie sie von den Autor\*innen beabsichtigt sind oder wie sie vom Lesepublikum wahrgenommen werden). So wird z. B. jedes Gedicht von PO-EMO sowohl auf Zeilen- als auch auf Strophenebene mit neun Emotionen annotiert, die bei den Leser\*innen ausgelöst werden, wobei sowohl geschulte Expert\*innen als auch Crowdworker eingesetzt werden (Haider et al. 2020). Andererseits werden im Kabithaa-Korpus, das aus Odia-Gedichten besteht, jedem Gedicht nur zwei Klassen von Expert\*innen zugewiesen (Mohanty et al. 2018).

Zusammenfassend lässt sich sagen, dass es keinen einzig richtigen Weg gibt: Alle Entscheidungen müssen auf der Grundlage des Forschungsziels, der Merkmale der zu analysierenden Texte und des theoretischen Referenzkontexts gewichtet werden.

## 8. Fazit

In diesem Kapitel wurde die Komplexität der SA als ein vielschichtiges Problem beschrieben: Verschiedene Aufgaben, Methoden und Anwendungen wurden vorgestellt, wobei der Schwerpunkt auf der Forschung im Bereich der DH liegt. Abschließend werden fünf vielversprechende Forschungsrichtungen genannt, die in den letzten Jahren zunehmend an Bedeutung gewonnen haben.

**Large Language Models (LLMs).** LLMs sind mehrschichtige (Engl.: *deep*) neuronale Netze (sogenannte Transformer), die auf riesigen Mengen unkommentierter Daten trainiert werden, um vorherzusagen, wie ein Satz weitergeht oder was in einem Satz fehlt. Menschen interagieren mit einem LLM über Prompts, d. h. Anweisungen in

natürlicher Sprache, die die auszuführende Aufgabe beschreiben.<sup>8</sup> LLMs zeigen bei vielen Aufgaben von NLP beeindruckende Fähigkeiten, aber die Frage, wie Prompts optimiert werden können, um immer bessere Ergebnisse zu erzielen, ist auch im Fall von SA ein offenes Thema (Mao et al. 2023).

**Multimodalität.** Multimodale SA ermöglicht es, über die textbasierte SA hinauszugehen und linguistische Informationen mit audiovisuellen Informationen aus Bildern, Tonaufnahmen und Videos zu kombinieren. Die ersten Experimente im DH-Bereich betrafen die Analyse von Theaterstücken (Schmidt & Wolff 2021) und mündliche Interviews zu Geschichte (Gref et al. 2022).

**Linguistische Linked Data.** Linguistische Ressourcen (Lexika und annotierte Daten) für die SA sind inzwischen sehr zahlreich, interagieren aber nicht miteinander: Die Verwendung von *Linked-Data*-Techniken (Iglesias et al. 2017) würde sie interoperabel, sichtbarer und wiederverwendbar machen. Datenmodelle, Ontologien und verknüpfte Ressourcen werden jedes Jahr im Rahmen der Workshop-Reihe *Sentiment Analysis & Linguistic Linked Data* vorgestellt, darunter auch Beiträge zu klassischen Sprachen (Sprugnoli et al. 2021).

**Perspektivismus.** Um Systeme für maschinelles Lernen zu trainieren, sind qualitativ hochwertige Daten erforderlich, bei denen die Bezeichnungen einheitlich vergeben werden. Allerdings ist die Kommentierung von Gefühlen und Emotionen sehr subjektiv, und es ist oft schwierig, einen Konsens über die zu vergebende Bezeichnung zu erzielen, da mehrere Interpretationen möglich sind, v. a. bei literarischen Texten. Im Zweifelsfall oder bei Uneinigkeit werden Zuordnungen zu einem einzigen Label erzwungen, damit der Algorithmus lernen und Vorhersagen treffen kann. Um dieses Paradigma zu ändern, wurde der sogenannte Perspektivismus vorgeschlagen, ein umfassenderer Rahmen, der darauf abzielt, die verschiedenen Standpunkte der Annotator\*innen zu erhalten (Cabitza et al. 2023).

**Reader-Response-Studien.** Auch wenn die Anwendung der SA auf die Analyse literarischer Texte immer noch kritisiert wird, weil es nicht einfach ist, das richtige Gleichgewicht zwischen computergestützten Ansätzen und narratologischen Theorien zu finden, sind Studien zur Leser\*innenreaktion auch in Bezug auf die Systemleistung erfolgreicher und zeigen, dass die SA effizienter zu sein scheint, wenn sie auf Kommentare zu einem literarischen Text als auf den Text selbst angewendet wird (Pianzola et al. 2020).

8 Als Beispiel für eine solche Interaktion kann etwa die Nutzungsoberfläche von ChatGPT genannt werden.

## Literaturverzeichnis

- Abu Farha, I., Oprea, S. V., Wilson, S., & Magdy, W. (2022). SemEval-2022 Task 6. iSarcasmEval. Intended Sarcasm Detection in English and Arabic. In *Proceedings of the 16<sup>th</sup> International Workshop on Semantic Evaluation (SemEval-2022)* (S. 802–814). Seattle: Association for Computational Linguistics. <https://doi.org/10.18653/v1/2022.semeval-1.111> [zuletzt aufgerufen am 23.06.2024].
- AlDayel, A., & Magdy, W. (2021). Stance detection on social media. State of the art and trends, *Information Processing & Management*, 58(4), 1–22.
- Anderson, Clifford W., & McMaster, G. E. (1982). Computer assisted modeling of affective tone in written documents. *Computers and the Humanities* 16(1), 1–9.
- Araque, O., Gatti, L., Staiano, J., & Guerini, M. (2019). Depechemood++. A bilingual emotion lexicon built through simple yet powerful techniques, *IEEE transactions on affective computing*, 13(1), 496–507. <https://doi.org/10.1109/TAFCC.2019.2934444> [zuletzt aufgerufen am 23.06.2024].
- Bender, E. M. (2016). Linguistic typology in natural language processing, *Linguistic Typology*, 20(3), 645–660.
- Cabitzza, F., Campagner, A., & Basile, V. (2023). Toward a perspectivist turn in ground truthing for predictive computing, *Proceedings of the AAAI Conference on Artificial Intelligence*, 37(6), 6860–6868. <https://doi.org/10.1609/aaai.v37i6.25840> [zuletzt aufgerufen am 23.06.2024].
- Cambria, E., Liu, Q., Decherchi, S., Xing, F., & Kwok, K. (2022). SenticNet 7. A common-sense-based neurosymbolic AI framework for explainable sentiment analysis, *Proceedings of the Thirteenth Language Resources and Evaluation Conference*, 3829–3839. URL: <https://aclanthology.org/2022.lrec-1.408> [zuletzt aufgerufen am 23.06.2024].
- Crossley, S. A., Kyle, K., & McNamara, D. S. (2017). Sentiment Analysis and Social Cognition Engine (SEANCE). An automatic tool for sentiment, social cognition, and social-order analysis, *Behavior research methods*, 49, 803–821.
- Darwin, Ch. (1872). *The Expression of the Emotions in Man and Animals*. London: John Murray.
- Du Bois, J. W. (2007). The stance triangle. In R. Engebretson (Hrsg.). *Stancetaking in Discourse. Subjectivity, evaluation, interaction* (S. 139–182). Amsterdam: John Benjamins.
- Ekman, P. (1993). Facial expression and emotion, *American psychologist* 48(4), 384–392.
- Gref, M., Matthiesen, N., Venugopala, S. H., Satheesh, Sh., Vijayananth, A., Ha, D. B., Behnke, S., & Köhler, J. (2022). A Study on the Ambiguity in Human Annotation of German Oral History Interviews for Perceived Emotion Recognition and Sentiment Analysis, *Proceedings of the Thirteenth Language Resources and Evaluation Conference, 2022–2031*. URL: <https://aclanthology.org/2022.lrec-1.217> [zuletzt aufgerufen am 23.06.2024].

- Grice, H. P. (1975). *Logic and conversation*. In P. Cole & J. L. Morgan (Hrsg.), *Syntax and semantics*, 3. Speech acts (S. 41–58). New York/San Francisco/London: Academic Press.
- Haider, Th., Eger, S., Kim, E., Klinger, R., & Menninghaus, W. (2020). PO-EMO. Conceptualization, Annotation, and Modeling of Aesthetic Emotions in German and English Poetry, *Proceedings of the Twelfth Language Resources and Evaluation Conference*, 1652–1663. URL: <https://aclanthology.org/2020.lrec-1.205> [zuletzt aufgerufen am 23.06.2024].
- Hernández Farias, D. I., & Rosso, P. (2017). Irony, sarcasm, and sentiment analysis. In F. A. Pozzi, E. Fersini, E. Messina & B. Liu (Hrsg.), *Sentiment Analysis in Social Networks* (S. 113–128). Amsterdam et al.: Morgan Kaufmann.
- Hutto, C., & Gilbert, E. (2024). VADER. A parsimonious rule-based model for sentiment analysis of social media text, *Proceedings of the international AAAI conference on web and social media*, 8(1), 216–225. <https://doi.org/10.1609/icwsm.v8i1.14550> [zuletzt aufgerufen am 23.06.2024].
- Iglesias, C. A., Sanchez-Rada, F. J., Vulcu, G., & Buitelaar, P. (2017). *Linked data models for sentiment and emotion analysis in social networks*. In F. A. Pozzi, E. Fersini, E. Messina & B. Liu (Hrsg.), *Sentiment Analysis in Social Networks* (S. 49–69). Amsterdam et al.: Morgan Kaufmann.
- Keck, J., Knabben, M., & Pado, S. (2020). Who's in the News? Methodological Challenges and Opportunities in Studying 19th-century Writers in Historical Newspapers. *Europeana PRO*, 16. Newspapers, o. S. URL: <https://pro.europeana.eu/page/issue-16-newspapers#who-s-in-the-news> [zuletzt aufgerufen am 23.06.2024].
- Kim, E., & Klinger, R. (2019). A Survey on Sentiment and Emotion Analysis for Computational Literary Studies, *Zeitschrift für digitale Geisteswissenschaften*, o. S. [https://doi.org/10.17175/2019\\_008\\_v2](https://doi.org/10.17175/2019_008_v2) [zuletzt aufgerufen am 23.06.2024].
- Liu, B. (2010). Sentiment analysis. A multi-faceted problem. *IEEE intelligent systems*, 25(3), 76–80.
- Ders. (2022). *Sentiment analysis and opinion mining*. Cham: Springer. <https://doi.org/10.1007/978-3-031-02145-9> [zuletzt aufgerufen am 23.06.2024].
- Mayer, A. I. L., Gutierrez-Vasques, X., Saiso, E. P., & Salmi, H. (2022). Underlying Sentiments in 1867. A Study of News Flows on the Execution of Emperor Maximilian I of Mexico in Digitized Newspaper Corpora, *Digital Humanities Quarterly*, 16(4), 1–98. URL: <http://www.digitalhumanities.org/dhq/vol/16/4/000649/000649.html> [zuletzt aufgerufen am 23.06.2024].
- Maynard, D., & Greenwood, M. (2014). Who cares about Sarcastic Tweets? Investigating the Impact of Sarcasm on Sentiment Analysis, *Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14)*, 4238–4243. URL: [http://www.lrec-conf.org/proceedings/lrec2014/pdf/67\\_Paper.pdf](http://www.lrec-conf.org/proceedings/lrec2014/pdf/67_Paper.pdf) [zuletzt aufgerufen am 23.06.2024].

- Mao, R., Liu, Q., He, K., Li, W., & Cambria, E. (2023). The biases of pre-trained language models. An empirical study on prompt-based sentiment analysis and emotion detection. *IEEE Transactions on Affective Computing*, 14(3), 1743–1753. <https://doi.org/10.1109/TAFFC.2022.3204972> [zuletzt aufgerufen am 23.06.2024].
- Mohammad, S. (2018). Obtaining reliable human ratings of valence, arousal, and dominance for 20,000 English words, *Proceedings of the 56<sup>th</sup> annual meeting of the association for computational linguistics*, 1. Long papers, 174–184. <https://doi.org/10.18653/v1/P18-1017> [zuletzt aufgerufen am 23.06.2024].
- Ders. (2023). Best Practices in the Creation and Use of Emotion Lexicons, *Findings of the Association for Computational Linguistics*. EACL 2023, 1825–1836. <https://doi.org/10.18653/v1/2023.findings-eacl.136> [zuletzt aufgerufen am 23.06.2024].
- Ders., & Turney, P. D. (2013). Crowdsourcing a word–emotion association lexicon, *Computational intelligence*, 29(3), 436–465. <https://doi.org/10.1111/j.1467-8640.2012.00460.x> [zuletzt aufgerufen am 23.06.2024].
- Mohanty, G., Mishra, P., & Mamidi, R. (2018). Kabithaa. An annotated corpus of Odia poems with sentiment polarity information, *Proceedings of the Eleventh International Conference on Language Resources and Evaluation (LREC 2018)*, 52–57. URL: [http://lrec-conf.org/workshops/lrec2018/W11/pdf/15\\_W11.pdf](http://lrec-conf.org/workshops/lrec2018/W11/pdf/15_W11.pdf) [zuletzt aufgerufen am 23.06.2024].
- Moreno-Ortiz, A. (2017). Lingmotif. Sentiment analysis for the digital humanities, *Proceedings of the Software Demonstrations of the 15<sup>th</sup> Conference of the European Chapter of the Association for Computational Linguistics*, 73–76. URL: <https://aclanthology.org/E17-3019> [zuletzt aufgerufen am 23.06.2024].
- Ohman, E. (2021). The validity of lexicon-based emotion analysis in interdisciplinary research, *Proceedings of the Workshop on Natural Language Processing for Digital Humanities (NLP4DH)*, 7–12. URL: <https://aclanthology.org/2021.nlp4dh-1.2> [zuletzt aufgerufen am 23.06.2024].
- Pianzola, F., Rebora, S., & Lauer, G. (2020). Wattpad as a resource for literary studies. Quantitative and qualitative examples of the importance of digital social reading and readers' comments in the margins, *PLoS one*, 15(1), 1–46. URL: [10.1371/journal.pone.0226708](https://doi.org/10.1371/journal.pone.0226708) [zuletzt aufgerufen am 23.06.2024].
- Plutchik, R. (1980). A general psychoevolutionary theory of emotion. In Ders. & H. Kellermann (Hrsg.), *Theories of emotion* (S. 3–33). Cambridge, Mass.: Academic press [= *Emotion. Theory, Research, and Experience*, 1]. <https://doi.org/10.1016/B978-0-12-558701-3.50007-7> [zuletzt aufgerufen am 23.06.2024].
- Rebora, S. (2023). Sentiment Analysis in Literary Studies. A Critical Survey, *Digital Humanities Quarterly*, 17(2), 1–50. URL: <http://www.digitalhumanities.org/dhq/vol/17/2/000691/000691.html> [zuletzt aufgerufen am 23.06.2024].
- Russell, J. A. (1980). A circumplex model of affect, *Journal of Personality and Social Psychology*, 39, 1161–1178.
- Schmidt, Th., & Wolff, Ch. (2021). Exploring multimodal sentiment analysis in plays. A case study for a theater recording of Emilia Galotti, *Proceedings of CHR 2021*.



- Computational Humanities Research Conference*, 392–404. URL: [https://ceur-ws.org/Vol-2989/short\\_paper45.pdf](https://ceur-ws.org/Vol-2989/short_paper45.pdf) [zuletzt aufgerufen am 23.06.2024].
- Schmidt, Th., Dangel, J., & Wolff, Ch. (2021). A Tool for Lexicon-based Sentiment Analysis in Digital Humanities, *Proceedings of the 16<sup>th</sup> International Symposium of Information Science (ISI 2021)*, 156–172. URL: [https://epub.uni-regensburg.de/44943/1/isi\\_schmidt\\_dangel\\_wolff.pdf](https://epub.uni-regensburg.de/44943/1/isi_schmidt_dangel_wolff.pdf) [zuletzt aufgerufen am 23.06.2024].
- Schmidt, Th., Dennerlein, K., & Wolff, Ch. (2021). Towards a corpus of historical german plays with emotion annotations, *Proceedings of 3<sup>rd</sup> Conference on Language. Data and Knowledge (LDK 2021). Schloss Dagstuhl. Leibniz-Zentrum für Informatik*, 1–11 [= *Open Access Series in Informatics*, 93]. <https://doi.org/10.4230/OASICS.LDK.2021.9> [zuletzt aufgerufen am 23.06.2024].
- Sprugnoli, R., Passarotti, M., Corbetta, D., & Peverelli, A. (2020). Odi et Amo. Creating, Evaluating and Extending Sentiment Lexicons for Latin, *Proceedings of the Twelfth Language Resources and Evaluation Conference*, 3078–3086. URL: <https://aclanthology.org/2020.lrec-1.376> [zuletzt aufgerufen am 23.06.2024].
- Sprugnoli, R., Passarotti, M., Testori, M., & Moretti, G. (2022). Extending and Using a Sentiment Lexicon for Latin in a Linked Data Framework, *Proceedings of the Workshops and Tutorials. Language Data and Knowledge 2021 (LDK 2021)*, 1–14. <https://doi.org/10.5281/zenodo.6303164> [zuletzt aufgerufen am 23.06.2024].
- Taboada, M., Brooke, J., Tofiloski, M., Voll, K., & Stede, M. (2011). Lexicon-based methods for sentiment analysis, *Computational linguistics*, 37(2), 267–307. [https://doi.org/10.1162/COLI\\_a\\_00049](https://doi.org/10.1162/COLI_a_00049) [zuletzt aufgerufen am 23.06.2024].
- Utsumiu, A. (2000). Verbal irony as implicit display of ironic environment. Distinguishing ironic utterances from nonirony, *Journal of pragmatics*, 32(12), 1777–1806. URL: <http://www.utm.se.uec.ac.jp/~utsumi/paper/jop2000-utsumi.pdf> [zuletzt aufgerufen am 23.06.2024].
- Viola, L. (2023). Networks of migrants' narratives. A post-authentic approach to heritage visualisation, *ACM Journal on Computing and Cultural Heritage*, 16(1), 1–21. <https://doi.org/10.1145/3575863> [zuletzt aufgerufen am 23.06.2024].
- Wankhade, M., Rao, A. Ch. S., & Kulkarni, Ch. (2022). A survey on sentiment analysis methods, applications, and challenges, *Artificial Intelligence Review*, 55(7), 5731–5780. <https://doi.org/10.1007/s10462-022-10144-1> [zuletzt aufgerufen am 23.06.2024].
- Yadav, A., & Vishwakarma, D. K. (2020). Sentiment analysis using deep learning architectures. a review, *Artificial Intelligence Review*, 53(6), 4335–4385. <https://doi.org/10.1007/s10462-019-09794-5> [zuletzt aufgerufen am 23.06.2024].

## Bildnachweise

Abb. 1 wurde von der Autorin selbst erstellt und hier erstveröffentlicht.