

**Emotionserkennung bei Nachrichtencommentaren mittels  
Convolutional Neural Networks und Label Propagationsverfahren**



Inauguraldissertation  
zur Erlangung des Doktorgrades der Philosophie  
an der Ludwig-Maximilians-Universität München

vorgelegt von  
Andreas Aschenbrenner  
aus Roding

2019

Erstgutachter: Prof. Dr. Marcus Spies, Psychologie

Zweitgutachter: Prof. Dr. Hinrich Schütze

Datum der mündlichen Prüfung: 25.04.2019



## Abstract

Das Ziel dieser Arbeit ist es, anhand der textuellen Emotionserkennung einen Schulter-schluss zwischen der Psychologie und der Computerlinguistik herzustellen. Gängige und in der Emotionserkennung verwendete Modelle werden bewertet. In dem dafür erstellten Bewertungsframework werden Validität, Anzahl der Dimensionen bzw. Anzahl der diskreten Emotionen, Vollständigkeit, Balance, Struktur und Realisierbarkeit gegenübergestellt. Nach Eingrenzung auf geeignete Emotionsmodelle wurde ein Datensatz anhand der Emotionstheorie von Merten & Krause (1993) annotiert. Anhand bisheriger Sentimentanalyseforschungen werden Fragestellungen zur Ebene der Granularität, zur methodischen Herangehensweise, zur Datenreduktion und -anreicherung herausgearbeitet. Ergebnisse der Anwendung eines Ansatzes mittels *Convolutional Neural Network* und des Labelpropagationsverfahrens wurden statistisch gegenübergestellt und zur Klärung der Hypothesen verwendet. Aus psychologischer Perspektive konnte die Struktur der Emotionen näher eingegrenzt und eine praktikable Methode zur Emotionsbestimmung herausgearbeitet werden. Aus computerlinguistischer Sicht stellten sich kürzere Eingabephrasen, der maschinelle Lernansatz, Datenbereinigung und -reduktionsverfahren sowie die Anwendung einer Negation als zielführend heraus.

Schlüsselwörter: Emotion, Emotionserkennung, feingranulare Sentimentanalyse, *Word Embeddings*, *Convolutional Neural Network*, Labelpropagationsverfahren

# Inhaltsverzeichnis

Abstract.....	IV
Inhaltsverzeichnis.....	V
Abbildungsverzeichnis.....	XII
Tabellenverzeichnis.....	XVI
Symbolverzeichnis.....	XVIII
1 Ziel dieser Studie.....	1
1.1 Relevanz.....	1
1.2 Zielsetzung.....	3
1.3 Vorgehensweise und Aufbau dieser Studie.....	4
2 Emotionstheoretische Grundlagen der Sentimentanalyse.....	6
2.1 Abgrenzung der Begriffe.....	6
2.1.1 Affekt.....	6
2.1.2 Stimmung.....	7
2.1.3 Gefühle.....	7
2.1.4 Emotion.....	8
2.2 Fokussierung dieser Arbeit.....	11
2.3 Bewertung der Emotionstheorien.....	12
2.3.1 Dimensionale Kategorisierung der Emotionen.....	12
2.3.1.1 Traxel und Heide.....	14
2.3.1.2 Watson und Tellegen.....	16
2.3.1.3 Russell.....	19
2.3.1.4 Osgood, Suci und Tannenbaum.....	20
2.3.1.5 Scherer.....	23
2.3.1.6 Roseman.....	28
2.3.1.7 Smith und Ellsworth.....	30
2.3.1.8 Manstead und Tetlock.....	33
2.3.2 Diskrete Abgrenzung der Emotionen.....	34
2.3.2.1 Gray.....	36
2.3.2.2 McDougall.....	38
2.3.2.3 Plutchik.....	39
2.3.2.4 Panksepp.....	43

2.3.2.5	Tomkins.....	45
2.3.2.6	Ekman.....	47
2.3.2.7	Izard.....	48
2.3.2.8	Merten und Krause.....	50
2.3.2.9	Frijda .....	52
2.3.2.10	Robinson.....	53
2.3.2.11	Levenson.....	56
2.3.2.12	Arnold.....	57
2.3.2.13	Lazarus .....	58
2.3.2.14	Shaver .....	60
2.3.2.15	Parrott .....	63
2.3.2.16	Schmidt-Atzert und Ströhme .....	66
2.3.2.17	Mayring .....	69
2.3.2.18	Ortony, Clore und Collins .....	71
2.3.2.19	Mees .....	74
2.4	Fragestellungen und offene Punkte in der Emotionsforschung .....	76
2.5	Auswahl eines geeigneten Emotionsmodells.....	78
2.5.1	Emotionstheorien im Überblick.....	78
2.5.2	Bewertung des Kategorisierungsschemas für die Sentimentanalyse .....	82
2.5.2.1	Vorteile des dimensionalen Kategorisierungsansatzes .....	82
2.5.2.2	Nachteile des dimensionalen Kategorisierungsansatzes .....	84
2.5.2.3	Vorteile des diskreten Kategorisierungsansatzes.....	90
2.5.2.4	Nachteile des diskreten Kategorisierungsansatzes.....	92
2.5.2.5	Auswahl eines geeigneten Kategorisierungsansatzes .....	94
2.5.3	Auswahl geeigneter theoretischer Modelle .....	94
3	Korpus.....	98
3.1	Nachrichtenkommentare als geeignete Textgrundlage .....	98
3.2	Datenakquise.....	99
3.2.1	Web-Crawler.....	99
3.2.2	Web-Scraper .....	101
3.3	Datensatz.....	101
3.3.1	Textmenge .....	101
3.3.2	Textlänge .....	102

3.3.3	Strukturierung der Nachrichtentexte .....	102
3.3.4	Strukturierung der Kommentare .....	103
3.3.5	Subjektive und nichtsubjektive Sprache.....	103
3.3.6	Datenqualität.....	104
4	Annotation .....	105
4.1	Klassifikationskategorien .....	106
4.1.1	Interesse .....	107
4.1.2	Freude .....	107
4.1.3	Überraschung .....	108
4.1.4	Trauer .....	109
4.1.5	Wut .....	109
4.1.6	Ekel.....	109
4.1.7	Verachtung.....	110
4.1.8	Angst.....	110
4.1.9	Scham .....	111
4.1.10	Schuld .....	111
4.2	Erstellung eines Goldstandards.....	112
4.2.1	Problemstellung .....	112
4.2.2	Vorgehensweise .....	112
4.2.2.1	Vorbereitung .....	113
4.2.2.2	Annotation .....	114
4.2.2.3	Bewertung.....	115
4.2.3	Annotationsergebnisse.....	117
5	Computerlinguistische Grundlagen der Sentimentanalyse.....	119
5.1	Differenziertheit der Ergebnisunterteilung.....	119
5.1.1	Subjektivitätserkennung .....	119
5.1.2	Polaritätserkennung.....	120
5.1.3	Emotionserkennung.....	121
5.1.4	Bewertung.....	124
5.2	Die Ebene der Granularität .....	125
5.2.1	Dokumentenebene.....	125
5.2.2	Satz- und Phrasenebene .....	126
5.2.3	Wortebene.....	128

5.2.4	Entität- oder Aspektebene.....	132
5.2.5	Bewertung.....	132
5.3	Herangehensweise existenter Sentimentanalysen.....	132
5.3.1	Erstellung eines Meinungslexikons.....	133
5.3.2	Maschinelle Lernansätze in der Sentimentanalyseforschung.....	137
5.3.3	Bewertung.....	139
6	Hypothesen.....	141
6.1	Hypothese zur Ebene der Granularität.....	141
6.2	Hypothesen zur methodischen Herangehensweise.....	142
6.3	Hypothesen zur Datenreduktion.....	143
6.4	Hypothesen zur Datenanreicherung.....	144
7	Methodisches Vorgehen.....	146
7.1	Datenvorverarbeitungsschritte.....	146
7.1.1	Datenexklusion.....	146
7.1.1.1	Entfernen der HTML-Formatierung.....	146
7.1.1.2	Exklusion von Fremdsprachen und unbekanntem Texten.....	147
7.1.1.3	Exklusion von Zahlen, E-Mail-Adressen und Links.....	148
7.1.2	Datentrennung und -struktur.....	148
7.1.2.1	Tokenisierung.....	148
7.1.2.2	Trennungen innerhalb eines Wortes.....	151
7.1.2.3	Satztrennung.....	156
7.1.3	Datenbereinigung.....	159
7.1.3.1	Entfernen von Zeichendopplungen.....	159
7.1.3.2	Großschreibung.....	160
7.1.3.3	Rechtschreibkorrektur.....	161
7.1.3.4	Alte Rechtschreibung.....	161
7.1.3.5	Rechtschreibfehler.....	161
7.1.3.6	Ergänzungsstriche.....	164
7.1.4	Datenharmonisierung.....	165
7.1.4.1	Abkürzungen.....	165
7.1.4.2	Netzjargon und internetspezifische Sprachmerkmale.....	166
7.1.4.3	Sonderzeichen und nichtdeutsche Alphabete.....	173
7.1.5	Merkmalsanreicherung.....	175

7.1.5.1	Wortarten.....	175
7.1.5.2	Negation.....	177
7.2	Externe und korpusbasierte Wissensbasis.....	188
7.2.1	Vektorieller Vergleich zur Nutzung von Wissensrepräsentationen.....	189
7.2.2	Korpusbasierte Wissensrepräsentation.....	190
7.2.2.1	Wissensrepräsentation mittels worthäufigkeitsbasierter Kookkurrenz.....	190
7.2.2.2	Wissensrepräsentation mittel prozessierter Dokument-Term-Matrix.....	191
7.2.2.3	Word-Embeddings.....	199
7.2.2.4	Auswahl des Modells und Parametrisierung.....	204
7.2.3	Wissensbasis für die Termerweiterung.....	205
7.3	Lexikonbasierte Ansätze.....	206
7.3.1	Voraussetzungen des lexikonbasierten Ansatzes.....	206
7.3.2	Emotionswortlistenerstellung mittels Labelpropagationsverfahren.....	207
7.3.2.1	Manuelle Erweiterung der gegebenen Emotionswörter.....	208
7.3.2.2	Erstellung der Emotionskategoriezugehörigkeit.....	211
7.3.3	Erstellung und Anwendung der Meinungslexika.....	214
7.3.3.1	Schwellenwerte zur Inklusion semantischer Beziehungen.....	215
7.3.3.2	Aggregation der Meinungswörter.....	215
7.3.3.3	Umgang mit der neutralen Klasse.....	216
7.3.3.4	Anwendung unterschiedlicher Gewichtungsmethoden.....	217
7.4	Modell des maschinellen Lernens.....	218
7.4.1	Voraussetzungen des maschinellen Lernansatzes.....	219
7.4.2	Convolutional Neural Networks.....	220
7.4.2.1	Anwendung eines Bilderkennungsverfahrens bei Texten.....	221
7.4.2.2	Faltungsschicht.....	224
7.4.2.3	Nichtlineare Aktivierungsfunktion.....	226
7.4.2.4	Pooling-Schicht.....	227
7.4.2.5	Klassifikationsschichten.....	229
7.4.3	Konfiguration des neuronalen Netzwerkes.....	231
7.4.3.1	Initialisierung.....	232
7.4.3.2	Verlustfunktion und Optimierungsvorgang.....	234
7.4.3.3	Regularisierung.....	237
7.4.3.4	Parametrisierung.....	238

8	Evaluation.....	239
8.1	Referenzdatensatz.....	239
8.1.1	Ansätze der Evaluierungsverfahren .....	239
8.1.2	Festlegung des Evaluierungsverfahrens .....	240
8.2	Beurteilungskriterien der Klassifikation.....	241
8.2.1	Bewertungsmetriken.....	241
8.2.2	Festlegung der Beurteilungskriterien und des Evaluationsframeworks .....	242
8.3	Statistische Überprüfung der Ergebnisse auf Signifikanz .....	243
9	Prozessuale Zusammenfassung der Datenverarbeitung .....	245
10	Ergebnisse .....	250
10.1	Einfluss des Kontexts auf das Analyseergebnis.....	252
10.2	Vergleich des manuellen und semi-überwachten lexikonbasierten Ansatzes ..	254
10.3	Lexikonbasierter und maschineller Lernansatzes im Vergleich .....	255
10.4	Harmonisierung, Reinigung und Wortstammreduktion .....	257
10.5	Anreicherung.....	259
10.6	Negation.....	261
10.7	Optimierte Ergebnisse .....	263
10.7.1	Manueller lexikonbasierter Ansatz.....	263
10.7.2	Lexikonbasierter Ansatz mit Labelpropagationsverfahren.....	266
10.7.3	Maschineller Lernansatz.....	271
10.7.4	Gegenüberstellung der optimierten Ergebnisse .....	277
11	Diskussion.....	284
11.1	Bewertung der Ergebnisse aus emotionstheoretischer Sicht .....	284
11.1.1	Struktur von Emotionen.....	284
11.1.2	Sekundäremotionen .....	287
11.1.3	Forschungsfeldübergreifender Ansatz der Emotionsbestimmung .....	288
11.2	Bewertung der Ergebnisse aus computerlinguistischer Sicht .....	289
11.2.1	Bewertung der Kontextrelevanz.....	290
11.2.2	Handverlesene und maschinell erstellte Emotionslisten im Vergleich .....	291
11.2.3	Der wortbasierte und der maschinelle Lernansatz im Vergleich .....	292
11.2.4	Bewertung der Vorverarbeitung.....	294
11.2.5	Praktische und theoretische Implikationen der Negation.....	295
11.2.6	Bewertung des Auswahlprozesses .....	297

11.3	Einschränkungen .....	299
11.3.1	Einschränkungen hinsichtlich der Emotionstheorie .....	299
11.3.1.1	Einschränkungen des gewählten Emotionsmodells .....	299
11.3.1.2	Ungleiche Aufteilung der Emotionen .....	301
11.3.2	Einschränkungen der methodischen Herangehensweise .....	302
11.3.2.1	Feineinteilung der Unteremotionen .....	302
11.3.2.2	Beschränkung auf einzelne Emotionen .....	302
11.3.2.3	Vorgelagerte Suche .....	303
11.3.2.4	Annotation mit Hindernissen .....	303
11.3.2.5	Angewendete Methodik .....	304
11.3.3	Einschränkungen, bezogen auf den Korpus .....	305
11.3.3.1	Datenqualität und Problematik der Echt Daten .....	305
11.3.3.2	Einschlägiger Datensatz .....	305
11.3.3.3	Sarkasmus und Ironie .....	306
11.4	Weitere wissenschaftliche Anknüpfungspunkte .....	307
11.4.1	Nutzung der speziellen Eigenschaften von Nachrichtenkommentaren .....	307
11.4.2	Nivellierung der Emotionen .....	309
11.4.3	Voraufteilung der Daten .....	310
12	Anhang .....	312
12.1	Suchbegriffe für die Vorselektion der Datensätze .....	312
12.2	Emotionslexikon nach Merten & Krause (1993) .....	320
12.3	Mögliches Gliederungsschema zur detaillierteren Emotionsbetrachtung .....	334
13	Literaturverzeichnis .....	341
	Eidesstattliche Erklärung .....	398

# Abbildungsverzeichnis

Abbildung 1: Unterschiedliche theoretische Sichtweisen auf Emotionen (angelehnt an Gross & Barrett, 2011).....	9
Abbildung 2: Differenzierbarkeit der Emotionstheorien (Reisenzein, 2000b, S. 210).....	11
Abbildung 3: Einordnung der Emotionen nach dem Schätzverfahren von Traxel & Heide (1961).....	14
Abbildung 4: Watsons & Tellegens (1985) Emotionsmodell (aus Pekrun, 2000, S. 338).....	17
Abbildung 5: Dimensionale Einteilung der abgeleiteten Emotionen (nach Russell, J., 1997, S. 299).....	19
Abbildung 6: Emotionsdimensionen aus semantischen Differentialen (nach Osgood et al., 1957).....	21
Abbildung 7: Geneva Emotion Wheel (Shuman et al., 2015).....	24
Abbildung 8: Semantischer Raum der Emotionen (Scherer, 2005, S. 720).....	25
Abbildung 9: Plutchiks Emotionsmodell (angelehnt an Plutchik, 1984).....	40
Abbildung 10: Clusteranalyse durch Sortieren der Emotionsterme (nach Shaver et al., 1987).....	61
Abbildung 11: Emotionsclusterung durch sprachliche Zuordnung (nach Schmidt-Atzert & Ströhm, 1983).....	67
Abbildung 12: Struktur der Emotionen einer positiven Bewertung (nach Ortony et al., 1988).....	71
Abbildung 13: Struktur der Emotionen einer negativen Bewertung (nach Ortony et al., 1988).....	72
Abbildung 14: Positive Bewertungsschema der Emotionen nach Mees (1991).....	74
Abbildung 15: Negatives Bewertungsschema der Emotionen nach Mees (1991).....	75
Abbildung 16: Mathematischer Flächenschluss der Emotionen nach (Traxel & Heide, 1961).....	87
Abbildung 17: Mögliche Verortung der Trauer (nach Barrett, 2011).....	88
Abbildung 18: Unterscheidungen der Sentimentanalyse (nach Medhat et al., 2014; Ravi & Ravi, 2015).....	133
Abbildung 19: Semantische Wissensrepräsentation (nach Harispe et al., 2013).....	188
Abbildung 20: Anwendung des CNN-Verfahrens bei Texten.....	224
Abbildung 21: Überlagerung der Kernel- und Eingabematrizen mit Padding.....	225
Abbildung 22: Anwendung des Kernelfilters (Wang, H. et al., 2017).....	225
Abbildung 23: Anwendung einer Max-Pooling-Operation.....	228
Abbildung 24: Anwendung einer Average-Pooling-Operation.....	228

Abbildung 25: Anwendung einer Sum-Pooling-Operation.....	229
Abbildung 26: Anwendung einer p-Norm-Pooling-Operation .....	229
Abbildung 27: Ein- bzw. zweistufiges Multi-Layer-Perceptron.....	230
Abbildung 28: Prozess der Linksammlung .....	245
Abbildung 29: Prozess des Herunterladens der Datenbasis.....	245
Abbildung 30: Prozess der Datenannotation .....	246
Abbildung 31: Prozess der Datenvorverarbeitung .....	246
Abbildung 32: Prozess der Erstellung der externen Wissensrepräsentation.....	247
Abbildung 33: Prozess der Wortlistenerstellung mittels Labelpropagationsverfahren ..	247
Abbildung 34: Prozess der Anwendung des lexikonbasierten Ansatzes .....	247
Abbildung 35: Prozess des Trainings und der Anwendung der CNN Methode .....	248
Abbildung 36: Übersicht aller errechneten F1 Werte mittels Labelpropagationsverfahren .....	250
Abbildung 37: Übersicht aller errechneten F1 Werte mittels CNN-Verfahren.....	250
Abbildung 38: Überprüfung der Hypothese H1 beim Labelpropagationsverfahren .....	253
Abbildung 39: Überprüfung der Hypothese H1 bei der CNN-Methode.....	253
Abbildung 40: Entwicklung der Ergebniswerte bei H1 pro Epoche .....	254
Abbildung 41: Überprüfung der Hypothese H2 beim Labelpropagationsverfahren .....	255
Abbildung 42: Überprüfung der Hypothese H3 .....	257
Abbildung 43: Überprüfung der Hypothesen H4a und H4b.....	258
Abbildung 44: Überprüfung der Hypothese H4a und H4c.....	259
Abbildung 45: Entwicklung der Ergebniswerte bei H4a und H4c pro Epoche .....	259
Abbildung 46: Fehlgeschlagene Überprüfung der Hypothesen H5a, H5b und H5c.....	260
Abbildung 47: Entwicklung der Ergebniswerte bei H5 pro Epoche .....	261
Abbildung 48: Überprüfung von H6 beim Labelpropagationsverfahren.....	262
Abbildung 49: Überprüfung der Hypothese H6 bei der CNN-Analyse.....	262
Abbildung 50: Entwicklung der Ergebniswerte bei H6 pro Epoche .....	263
Abbildung 51: Boxplot der Werte der Synonymgewichtungen bei der manuellen Lexikonerstellung .....	263
Abbildung 52: Boxplot der Werte der Schlüsselwortgewichtungen bei der manuellen Lexikonerstellung .....	264
Abbildung 53: Boxplot der Aggregationstypen bei der manuellen Lexikonerstellung ...	264
Abbildung 54: Boxplot der Wortgewichte bei der manuellen Lexikonerstellung .....	265
Abbildung 55: Boxplot des Umgangs mit der neutralen Klasse.....	265
Abbildung 56: Boxplot der Schwellenwerte im Umgang mit der neutralen Klasse .....	266

Abbildung 57: Boxplot der Werte der Synonymgewichtungen bei der manuellen Lexikonerstellung .....	267
Abbildung 58: Boxplot der Werte der Schlüsselwortgewichtungen bei der manuellen Lexikonerstellung .....	267
Abbildung 59: Boxplot der Aggregationstypen bei der manuellen Lexikonerstellung ...	268
Abbildung 60: Boxplot der Wortgewichte bei der manuellen Lexikonerstellung .....	268
Abbildung 61: Übersicht der Schwellwerte mit geringer Ergebnisvarianz .....	269
Abbildung 62: Übersicht der Schwellwerte mit größerer Varianz und besserer Werteinstufung .....	269
Abbildung 63: Boxplot im Umgang mit der Klasse Neutral.....	270
Abbildung 64: Schwellenwerte im Umgang mit der Klasse Neutral.....	270
Abbildung 65: Optimale Konfiguration bei der maschinellen Lexikonerstellung .....	270
Abbildung 66: Boxplot der Gewichtsinitialisierungen .....	271
Abbildung 67: Boxplot der Erweiterungen der Lernrate .....	271
Abbildung 68: Entwicklung der F1-Werte pro adaptiver Lernrate und Epoche .....	272
Abbildung 69: Boxplot der nichtlinearen Aktivierung.....	272
Abbildung 70: Entwicklung der F1-Werte pro Aktivierungsfunktion und Epoche .....	273
Abbildung 71: Boxplot der Pooling-Varianten .....	273
Abbildung 72: Entwicklung der F1-Werte pro Pooling-Konfiguration und Epoche.....	273
Abbildung 73: Boxplot der Anzahl der Filter pro Faltungsschicht.....	274
Abbildung 74: Entwicklung der F1-Werte pro Filteranzahl und Epoche .....	274
Abbildung 75: Boxplot der Verlustfunktion.....	275
Abbildung 76: Entwicklung der F1-Werte pro Verlustfunktion und Epoche .....	275
Abbildung 77: Boxplot der unterschiedlichen Werte der L2-Regularisierung.....	276
Abbildung 78: Entwicklung der F1-Werte pro Regularisierungswert und Epoche.....	276
Abbildung 79: Boxplot der Ergebniswerte mit und ohne Dropout.....	277
Abbildung 80: Entwicklung der F1-Werte pro Dropout-Konfiguration und Epoche .....	277
Abbildung 81: Entwicklung der F1 Werte für die Konfiguration WORD NEG .....	278
Abbildung 82: Entwicklung der F1 Werte für die restlichen CNN Konfigurationen.....	279
Abbildung 83: Entwicklung der Zielfunktionswerte der Konfiguration LC   UNCHANGED .....	279
Abbildung 84: Entwicklung der Zielfunktionswerte der Konfiguration LC   LEMMA.....	280
Abbildung 85: Entwicklung der Zielfunktionswerte der Konfiguration LC   LEMMA NEG .....	280
Abbildung 86: Entwicklung der Zielfunktionswerte der Konfiguration LC   WORD .....	281

Abbildung 87: Entwicklung der Zielfunktionswerte der Konfiguration LC   WORD NEG	
.....	281
Abbildung 88: Entwicklung der Zielfunktionswerte der Konfiguration C   WORD NEG	282
Abbildung 89: Entwicklung der Zielfunktionswerte der Konfiguration CR   WORD NEG	
.....	282
Abbildung 90: Entwicklung der Zielfunktionswerte der Konfiguration LCR   WORD NEG	
.....	283

## Tabellenverzeichnis

Tabelle 1:Dimensionsausprägungen nach Scherer (1982, S. 561).....	23
Tabelle 2: Stuktur der Emotionen (Roseman, 2001, S. 31).....	28
Tabelle 3: Emotionsdimensionen (nach Smith & Ellsworth, 1985;angelehnt an Omdahl, 2014).....	31
Tabelle 4: Emotionen und Ausprägungen des DAS nach Merten & Krause (1993, S. 2f.) .....	51
Tabelle 5: Verknüpfung der Handlungstendenzen und Emotionen nach Frijda (1986) ..	52
Tabelle 6: Taxonomie der Emotionen nach Robinson (2008, S. 155).....	54
Tabelle 7: Taxonomie der Emotionen nach (Parrott, 2001a, S. 33–35) .....	64
Tabelle 8: Emotionsgruppen nach (Mayring, 2003, S. 151).....	69
Tabelle 9: Bewertung der dimensionalen Emotionsklassifikationsansätze.....	80
Tabelle 10: Bewertung der diskreten Emotionsklassifikationsansätze .....	81
Tabelle 11: Beispielsätze für die Emotion Interesse .....	107
Tabelle 12: Beispielsätze für die Emotion Freude.....	107
Tabelle 13: Beispielsätze für die Emotion Schadenfreude.....	108
Tabelle 14: Beispielsätze für die positive Emotion Überraschung.....	108
Tabelle 15: Beispielsätze für die negative Emotion Überraschung .....	108
Tabelle 16: Beispielsätze für die Emotion Trauer .....	109
Tabelle 17: Beispielsätze für die Emotion Wut .....	109
Tabelle 18: Beispielsätze für die Emotion Ekel.....	110
Tabelle 19: Beispielsätze für die Emotion Verachtung.....	110
Tabelle 20: Beispielsätze für die Emotion Angst.....	111
Tabelle 21: Beispielsätze für die Emotion Scham.....	111
Tabelle 22: Beispielsätze für die Emotion Schuld.....	112
Tabelle 23: Detaillierte Aufschlüsselung der Annotatorenzuordnungen .....	118
Tabelle 24: Übersicht gängiger Lexika im Bereich der Sentimentanalyse.....	131
Tabelle 25: Abweichungsgrad bei ausgewählten Meinungslexika (Potts, 2011a) .....	131
Tabelle 26: Typen der Zeichen und Zeichenfolgen für den Tokenizer .....	150
Tabelle 27: Verkettete Zeichensequenzen .....	150
Tabelle 28: Gültige Token für die Tokenisierung .....	151
Tabelle 29: Nicht zerlegte Komposita.....	154
Tabelle 30: Korrekt zerlegte Komposita.....	155
Tabelle 31: Nicht korrekt zerlegte Komposita .....	155
Tabelle 32: Komposita mit richtiger Zerlegung .....	155
Tabelle 33: Exemplarische Korrektoren von Zeichendopplungen.....	160

Tabelle 34: Ersetzungstabelle der Abkürzungen .....	165
Tabelle 35: Liste der Harmonisierungen für Parenthesenkonstruktionen.....	169
Tabelle 36: Ersetzungen der Schimpfwortschreibweisen.....	171
Tabelle 37: Liste der häufigsten Emoticons .....	173
Tabelle 38: Harmonisierung der Emoticons in Schlüsselwörter .....	173
Tabelle 39: Ersetzung und Harmonisierung der verwendeten Zeichen.....	174
Tabelle 40: Zeichenpersistierung im Korpus.....	175
Tabelle 41: Regel für die Negation durch nie, nicht und außer .....	183
Tabelle 42: Regel für die Negation durch ohne und ohne ... zu.....	183
Tabelle 43: Regel für die Negation durch weder ... noch .....	183
Tabelle 44: Regel für die Negation durch kein.....	184
Tabelle 45: Regel für die Negation durch nicht.....	187
Tabelle 46: Ausprägung des Emotionsschemas nach Mayring (2003) .....	209
Tabelle 47: Ausprägungen der Emotionstypen nach Mees (1991) .....	210
Tabelle 48: Übersicht der erweiterten Seed-Words .....	211
Tabelle 49: Varianten der Vorverarbeitung der Word2Vec-Modelle.....	220
Tabelle 50: Konfusionsmatrix der Klassifikationsergebnisbewertung.....	241
Tabelle 51: Listung aller Konfigurationen beim Labelpropagationsverfahren.....	248
Tabelle 52: Listung aller Konfigurationen bei der CNN Methode .....	249
Tabelle 53: Ergebniswerte der Hypothese H1 beim Labelpropagationsverfahren.....	252
Tabelle 54: Eingangskonfigurationen der Schwellwerte bei Hypothese H2 .....	254
Tabelle 55: Mittlere Rangabweichung bei Hypothese H3 .....	256
Tabelle 56: Optimale Konfiguration bei manueller Lexikonerstellung.....	266
Tabelle 57: Optimale Konfiguration beim CNN-Verfahren .....	277
Tabelle 58: Ergebniswerte der Emotionserkennung bei Nachrichtenkommentaren .....	278
Tabelle 59: Suchwörter für die Auswahl emotionaler Phrasen.....	320
Tabelle 60: Theoriebasiertes Anreichern der Emotionsterme .....	333
Tabelle 61: Gruppierung der Emotionen aus den Datensätzen zu Unteremotionen.....	340

# Symbolverzeichnis

Zeichen	Beschreibung
$D$	Alle Dokumente bzw. gesamter Korpus
$E$	Anzahl der Dimensionen der Wortrepräsentationen
$L$	Korrekturwörter mit Levenshtein-Distanz $< 2$
$N$	Größe der gleichzeitig in das Modell eingegebenen Wörter
$T$	Themen bei der LDA; geordnete Sequenz von Wörtern bei <i>Word Embeddings</i>
$U$	Alle annotierten Bewertungspaare
$V$	Menge aller Terme aus dem Vokabular
$W_d$	Sequenz von Wörtern eines Dokuments
$X$	Kookkurrenzbasierte Wert bei Glove
$Y$	Emotionsklassen nach Mertens und Krause
$a$	Skalarer Eingabewert
$b$	Verzerrungswert
$c$	Wörter im Kontext / innerhalb eines Fensters
$d$	Dokument aus dem Korpus
$df$	Dokumenthäufigkeit
$fn$	Fälschlicherweise als nicht zugehörig klassifiziert
$fp$	Fälschlicherweise als zugehörig klassifiziert
$g$	Featureset
$h$	Wortfensterlänge
$idf$	Inverse Dokumenthäufigkeit
$k$	Anzahl $k$ nächste Nachbarn
$l$	Korrekturwort
$p$	Wahrscheinlichkeit
$s$	Ergebniswert der Berechnung in einem Neuron
$t$	Thema bei der LDA
$tn$	Richtigerweise als nicht zugehörig klassifiziert
$tp$	Richtigerweise als zugehörig klassifiziert
$u$	Bewertungspaar zweier Annotatoren
$v$	Wortvektor aus dem Vokabular
$w$	Wort bzw. Term aus dem Vokabular; Gewichtungsfaktor bei neuronalen Netzen
$x$	Termvektor
$y$	Emotionsklasse nach Merten & Krause (1993)
$\hat{y}$	Errechneten Emotionsklasse
$z$	Dokumentspezifische Themenverteilung bei LDA
$\mathbf{0}$	Nullmatrix
$\mathbf{C}$	Nachschlagematrix

$D^T$	Matrix mit Eigenvektoren
$I$	Identitätsmatrix
$P$	Übergangsmatrix
$\hat{P}$	Zielmatrix
$Q$	Übergangsteilmatrix
$R$	Übergangsteilmatrix
$\hat{R}$	Zuordnungsmatrix
$S$	Diagonalmatrix bei LSI
$T$	Matrix mit Eigenvektoren bei LSI
$X$	Term-Dokument-Matrix bei LSI
$w$	Kernelfiltermatrix
$x$	Zusammengefügte Sequenz aus Wortvektoren
$\phi$	Termverteilung für ein Thema
$\alpha$	Trainierbarer Dirichlet-Hyperparameter der Themenverteilung pro Dokument bei LDA
$\beta$	Trainierbarer Dirichlet-Parameter der Term- bzw. Wortverteilung pro Thema bei LDA
$\gamma$	Schwellenwerte im Umgang mit der neutralen Klasse
$\zeta$	Hyperparameter bei der nichtlinearen Aktivierungsfunktion
$\theta$	Themenverteilung für ein Dokument bei der LDA; Substituierte Modellparametern bei <i>Word Embeddings</i>
$\psi$	Schwellenwerte der Übergangswskalarahrscheinlichkeiten

# 1 Ziel dieser Studie

## 1.1 Relevanz

Medien und insbesondere Nachrichten fällt eine wichtige Funktion in der Gesellschaft zu. Sie informieren, tragen zum öffentlichen Diskurs und zur Meinungsbildung bei. Marcic (1957, S. 394) wies ihnen die Aufgabe der „vierte[n] Gewalt“ in der Gewaltentrennung zu. Nachrichten sind ein Ausschnitt dessen, was die Öffentlichkeit als wichtig oder bewegend empfindet. Sie ermöglichen es den Menschen, an Begebenheiten teilzuhaben, ohne selbst am Ort des Geschehens sein zu müssen. Lokale und globale Ereignisse werden für den Einzelnen greifbar. Über eine längere Zeitspanne hinweg betrachtet, helfen Meldungen dabei, Geschehnisse zu interpretieren und Tendenzen zu erkennen. Kurzfristig ermöglichen sie es, die neusten Geschehnisse einzufangen, die Tragweite neuer Ereignisse zu erfassen und am Puls der Zeit zu bleiben.

Längst stellt das Printmedium ein altersschwaches Relikt aus grauer Vorzeit dar, dem das Onlineangebot enteilt ist. An der Brisanz von Nachrichtenmeldungen hat dies nichts geändert, an dem Takt und der Reichweite schon (Schweiger, 2017). Durch die Kommentarfunktion in Online-Nachrichtenmeldungen hat sich der Journalismus grundlegend geändert. Ein Zitat, das mit Bayart, einem französischen Vordenker für die Grundfreiheiten der Informationsgesellschaft, als Urheber in Verbindung gebracht wird, unterstreicht dies: „Die Druckerpresse hat die Menschen lesen gelehrt; das Internet lehrt die Menschen, zu schreiben“ (Assange, Appelbaum, Müller-Maguhn & Zimmermann, 2013, S. 98). Der Leser ist somit nicht nur bloßer Konsument der Inhalte, er wird zum Akteur in der Meinungsbildung. Jeder kann an dem öffentlichen Meinungsaustausch partizipieren und so Einfluss auf die Welt nehmen. Meckel (2009) formuliert dies noch viel drastischer, wenn sie sagt, dass „Journalismus im Internet [...] nichts anderes als eine Dauerkonversation aller Beteiligten untereinander [ist]“. Unweigerlich geht damit eine enorme Menge an nutzergenerierten Daten einher, deren Informationsgehalt durch manuelle Sichtung der Verlage nicht mehr bewältigt werden kann.

Die Kommentarfunktionen stellt zweifelsohne einen Sieg für die Meinungsfreiheit dar und man kann dem öffentlichen Diskurs viel Gutes abgewinnen. Nichtsdestotrotz erwachsen daraus auch zwei Gefahren: einerseits für die Nutzer selbst und andererseits für die Betreiber von Nachrichtenportalen. Die Nutzer sehen sich zahlreichen sogenannten *Fake News* oder Halbwahrheiten ausgesetzt, was unter anderem die Tagesschau dazu veranlasste, den Faktenfinder ins Leben zu rufen (NDR/ARD-aktuell, o.J.). Müller von Blumencron (2015) bemängelt überdies die Möglichkeit der anonymisierten Meinungsäußerung, bei der sich „[d]as [...] Internet

[...] in den vergangenen Jahren zu einer gewaltigen Empörungsmaschine entwickelt [hat], einer Gerüchteschleuder, zu einem Propagandavehikel für jede noch so obskure Theorie“. Weiter führt er aus, dass „[d]ie eingebildete Wahrheit [...] die Fakten [verdrängt], eine scheinbare Welt die Realität. [...] Und selten zuvor fragten sich so viele Menschen verunsichert: Wo eigentlich geht’s hier zur Wahrheit?“ (Müller von Blumencron, 2015). Letzteres ist ein inhaltliches Problem, doch was noch schwerer wiegt, sind die rechtlichen Konsequenzen, die daraus entstehen. Denn die Betreiber von Nachrichtenportalen sowie andere Webseitenanbieter müssen für die Inhalte auf ihrer Seite haften. Zwar kann der Ersteller eines Kommentars zur Haftung gezogen werden, sofern er strafbare Äußerungen von sich gibt und ermittelt werden kann. Doch wie aus dem Telemediengesetz hervorgeht, wird auch der Betreiber in die Pflicht genommen, wenn es dort heißt (§ 10 Telemediengesetz):

Diensteanbieter sind für fremde Informationen, die sie für einen Nutzer speichern, nicht verantwortlich, sofern

1. sie keine Kenntnis von der rechtswidrigen Handlung oder der Information haben und ihnen im Falle von Schadensersatzansprüchen auch keine Tatsachen oder Umstände bekannt sind, aus denen die rechtswidrige Handlung oder die Information offensichtlich wird, oder
2. sie unverzüglich tätig geworden sind, um die Information zu entfernen oder den Zugang zu ihr zu sperren, sobald sie diese Kenntnis erlangt haben.

Wie das Hanseatisches Oberlandesgericht Hamburg (2006) urteilte, ergeben sich für den Betreiber eines solchen Dienstes Prüfungspflichten, denen er nachkommen muss. Passiert dies nicht, so kann „[e]in Unterlassungsanspruch wegen eines in ein Meinungsforum im Internet eingestellten ehrverletzenden Beitrags [...] auch dann gegen den Betreiber des Forums gegeben sein, wenn dem Verletzten die Identität des Autors bekannt ist“, entschied der Bundesgerichtshof (2007). Erst jüngst beschäftigte sich die Bundesregierung in Person des Bundesjustizministers Heiko Maas mit Hasskommentaren im Internet. Es löst Unsicherheit aus, sowohl beim Erkennen solcher Beiträge, im Umgang damit oder der zukünftigen technischen Umsetzung (Müller-Neuhof, 2017).

Dies ist ein Aspekt, der eine hohe Relevanz und Dringlichkeit besitzt. Es besteht der Bedarf, Inhalte in kürzester Zeit zu prüfen und einzuordnen. Dies ist jedoch angesichts der zeitlich uneingeschränkten Kommentierungsfunktionen und der schieren Menge an erzeugten Daten manuell kaum lösbar. Maschinelle Verfahren, die bei der Prüfung der Inhalte Hilfestellung leisten oder gänzlich automatisiert arbeiten, stellen einen möglichen Lösungsansatz dar. Dies ist insbesondere hinsichtlich des kürzlich verabschiedeten Netzwerkdurchsetzungsgesetz bei Hasskommentaren von großer Bedeutung (Deutscher Bundestag, 2017).

## 1.2 Zielsetzung

Den Kern dieser Untersuchung bildet die Erkennung von affektierten Zustände in geschriebener Sprache. Das Vorhaben wird als *Opinion-Mining* bzw. *Sentiment-Analysis* bezeichnet. Beide Begriffe werden oft synonym verwendet. Es gibt zahlreiche Herangehensweisen, doch allen ist ein gemeinsamer Nenner gleich: Die Ansätze versuchen, Meinungen oder Emotionen aus Texten maschinell zu extrahieren oder die subjektiven Texte bzw. Textfragmente zu annotieren (Liu, B., 2011). Einen Schritt weiter geht die feingranulare Sentimentanalyse bzw. die Methode der Emotionsdetektion (Kaur & Jatinderkumar, 2014): Dort werden Emotionen in Texten gefunden und klassifiziert (Liu, B., 2015a).

Die Sentimentanalyse ist ein interdisziplinäres Teilgebiet, das häufig in der natürlichen Sprachverarbeitung (Liu, B., 2015b; Medhat, Hassan & Korashy, 2014) und vereinzelt in der Linguistik (Jahr, 2000; Ortner, 2014) anzutreffen ist, wobei es bei Letzterer lange ein „Schattendasein“ führte (Rummer & Engelkamp, 2000, S. 325). Es gibt jedoch auch Computerwissenschaftler, die eine große Schnittmenge mit der Psychologie sehen (Cambria & Hussain, 2012; Cambria, Livingstone & Hussain, 2012b; Devitt & Ahmad, 2013). In der Psychologie selbst existiert seit 1995 (Picard) das Feld *Affective Computing*. Jedoch setzt man sich hier eher großflächig mit der emotionalen Ausdrucksweise in Form von Gesichtsausdrücken, gesprochener Sprache, Tonsequenzen, Bewegungsmustern, Körperreaktionen, Hormonspiegeln, Sensordaten oder sonstigen Signalen auseinander (Calvo, 2010). Zum einen ist die Anzahl der psychologischen Beiträge in diesem Feld im Vergleich zu anderen Wissenschaftszweigen wie der Computerlinguistik überschaubar (Ahmad, 2011; Ravi & Ravi, 2015), zum anderen stellen Forschungsarbeiten mit geschriebener Sprache in der Psychologie eher die Ausnahme dar und sind gewöhnlich nicht auf die Massendatenanalyse ausgerichtet (beispielsweise Hobbs & Gordon, 2011; Mark et al., 2016; Musacchio, 2011; Poirier, Bothorel & Neef, 2011). Auch das Feld der Psycholinguistik beschäftigt sich kaum mit der Verwendung von Emotionen in der Sprache, sondern eher mit Themen wie der menschlichen Befähigung und dem Erwerb der Sprache, der Sprachwahrnehmung sowie den dabei ablaufenden Prozessen und Repräsentationsstrukturen im Gehirn (Höhle, 2010).

Während die textuelle Betrachtung der Emotionen in der Hand der Computerlinguisten und Linguisten liegt, stellen in erster Linie Psychologen, aber auch Soziologen, Philosophen, Neuro- und Wirtschaftswissenschaftler die führenden Emotionsforscher dar (Frijda, 2007). Emotionen, Emotionstheorien und -modelle sind seit über hundert Jahren Gegenstand der Psychologie (James, 1884) und bis heute fest in diesem Feld verankert (Barrett, 2017).

An dieser Stelle deutet sich bereits eine Diskrepanz an. Denn Psychologen behandeln die textanalytische Betrachtung von Emotionen äußerst stiefmütterlich und Computerlinguisten operieren hierbei auf fremdem Terrain. Letzteres mündet darin, dass fundamentale Prinzipien ignoriert, handfeste Kritikpunkte umgangen, fehlerhafte bzw. kontroverse Modelle angewendet und/oder mehrere Emotionsströmungen fern jeder Theorie kombiniert werden (Cambria & Hussain, 2012). Es klafft somit eine deutliche Lücke zwischen den beiden Forschungsfeldern Psychologie und Computerlinguistik, die sich besonders in folgendem Zitat widerspiegelt (Liu, B., 2015a, S. 36):

*The preceding discussions are only about people's states of mind, which are the subjects of study of psychologists. However, for sentiment analysis, we need to know, how much feelings are expressed in natural language and how they can be recognized.*

Exakt diese Lücke soll mit der vorliegenden Arbeit geschlossen werden. Einerseits soll eine fundierte Übersicht der Emotionsmodelle aus der Anwendungsperspektive der computerlinguistischen Sentimentanalyse erarbeitet werden. Andererseits soll ein gültiges Emotionsmodell anhand aktueller Forschungsmethoden an einem Textkorpus erstellt, angewendet und bewertet werden.

### **1.3 Vorgehensweise und Aufbau dieser Studie**

Diese Arbeit bietet eine fächerübergreifende Studie, die auch als solche wahrgenommen werden sollte. Nichtsdestotrotz ist sie in der Fachrichtung Psychologie verankert und wird sich daher auch an den Maßstäben und Vorgehensweise dieses Faches orientieren. Bedingt durch den multidisziplinären Ansatz ergeben sich zahlreiche Schnittpunkte mit den Disziplinen Linguistik und Computerlinguistik. Grundsätzlich wird versucht, diesen Forschungsgebieten gerecht zu werden, indem man sich an deren Herangehensweisen anlehnt. Weicht das Vorgehen jedoch von den üblichen Praktiken der Psychologie ab, so wird sich an der federführenden Wissenschaftsmethodik orientiert. Ferner wird die in der Psychologie übliche Zitierweise und Hypothesenüberprüfung verwendet.

In Abgrenzung zu verwandten Forschungsgebieten wird im weiteren Verlauf kein neues Emotionsmodell kreiert, sondern die bestehenden werden evaluiert. Darüber hinaus wird auch keine vollständige Sentimentanalyseanwendung erstellt. Letzteres impliziert, dass neben der Meinungsklassifikation keine Intensitätsbestimmung, keine Erkennung des Meinungsgebers und des Zieles, an das eine Emotion geknüpft ist, sowie keine Ursachenanalyse umgesetzt wird (Liu, B., 2015a).

In Kapitel 2 wird der wissenschaftliche Hintergrund der Emotionsmodelle aufgearbeitet. Es findet an dieser Stelle jedoch keine Vertiefung oder kritische Aufarbeitung der Thematik statt, sondern es wird eine Brücke zwischen Psychologie und Computerlinguistik gebildet.

In Kapitel 3 werden auf das zugrunde liegende Korpus und die Akquise der Textdaten eingegangen. Die verwendete Datenbasis wurde explizit für diesen Analysezweck gesammelt. Darüber hinaus werden in diesem Teilabschnitt generelle Vorverarbeitungsschritte erläutert, die angewendet wurden, um die unstrukturierten Rohdaten nutzbar zu machen.

Kapitel 4 steht ganz unter dem Vorzeichen der Erstellung eines annotierten Datensatzes im Sinne einer praktikablen und psychologisch sinnvollen Emotionskategorisierung. Hierbei handelt es sich um ein wissenschaftliches Novum, da dieser Goldstandard explizit für diese Arbeit entwickelt und das zugrunde liegende Emotionsmodell noch nicht im Kontext einer Textklassifikation verwendet wurde. Viele computerlinguistische Ansätze finden Eingang in diese Studie. Die meisten dieser Konzepte sind in den Humanwissenschaften wenig bis gar nicht bekannt sind.

In Kapitel 5 wird der Bogen etwas weiter gespannt und die Sentimentanalyse sowie die Emotionsdetektion werden näher erläutert. Wang, Z. et al. (2016, S. 1361) kritisierte, dass *„most existing sentiment analysis techniques focus only on the aggregated level, classifying sentiments broadly into positive, neutral or negative, and lack the capabilities to perform fine-grained sentiment analysis“*. Um nicht ebenfalls unter diesen Kritikpunkt zu fallen, finden hier aktuelle Strömungen der Sentimentanalyseforschung Eingang. Diese werden vor dem Hintergrund wissenschaftlicher Fragestellungen näher beleuchtet.

In Kapitel 6 werden Hypothesen ausformuliert, wie dies in dem psychologischen Forschungsfeld üblich ist. Das vielschichtige methodische Vorgehen und die Art und Weise, wie die Hypothesenüberprüfung angegangen wird, finden sich in Kapitel 7. Die Beurteilungskriterien, anhand derer die Messlatte für diese Forschungsarbeit definiert wird, werden in Kapitel 8 vorgestellt. In Kapitel 9 wird der gesamte Vorgang prozessual zusammengefasst. Schließlich werden die Ergebnisse der Analyse in Kapitel 10 dezidiert dargestellt und in Kapitel 11 hinsichtlich ihrer praktischen und theoretischen Implikationen diskutiert.

## **2 Emotionstheoretische Grundlagen der Sentimentanalyse**

Die theoretischen Inhalte der Emotionsforschung liefern einerseits die Grundlage für die Eingangsdaten, andererseits werden die Ergebnisse an ihren Maßstäben und theoretischen Vorgaben gemessen. Um die Schnittpunkte der computerlinguistischen Herangehensweise mit der Emotionsforschung herauszuarbeiten, wird zunächst auf Begriffe und Definitionen eingegangen, um ein gemeinsames Verständnis der verwendeten Konzepte zu schaffen.

In diesem Kapitel wird eine große, aber nicht vollumfängliche Liste an Emotionstheorien angeführt und untersucht. Man mag hierbei einwenden, dass eine intensive Illustration des ausgewählten Emotionsmodells ausreichend wäre. Doch zum einen misst sich der Beitrag dieser Arbeit an der Gegenüberstellung und Überprüfung der Emotionstheorien in Hinblick auf die Sentimentanalyse, weswegen eine möglichst große Bandbreite abgedeckt werden soll. Zum anderen darf dieser Vorstoß als Kritik gewertet werden, deren Gegenstand die leichtfertige Auswahl, Handhabung und Kombination der Emotionsmodelle in zahlreichen Sentimentanalysepublikationen darstellt, die fernab der Emotionsforschung verfasst wurden.

### **2.1 Abgrenzung der Begriffe**

Um ein gemeinsames Verständnis des Kerngegenstands dieser Untersuchung zu schaffen, muss dieser zuerst definiert werden. Die Untersuchung von Emotionen ist in mehreren wissenschaftlichen Disziplinen wie z. B. der Linguistik vertreten. Jedoch folgt die Definition primär psychologischen Gesichtspunkten. Der Begriff Emotion ist von den themenverwandten Begriffen des Affekts, des Gefühls bzw. des Fühlens sowie der Stimmung abzugrenzen, die sich grob zu dem Begriff der Emotionalität zusammenfassen lassen (Wirtz, 2017).

#### **2.1.1 Affekt**

Die überwiegende Auslegung des Begriffes Affekt beschreibt eine kurz andauernde Gefühlsregung, beispielsweise Begeisterung oder Schreck, die in ihrer Intensität sehr deutlich ausfällt und deren Auftreten häufig mit einem mimischen, gestischen oder motorischen Ausdruck gepaart ist (Wirtz, 2017). Aus Sicht der psychologischen Emotionsforschung sind Affekte von geringer Bedeutung und beziehen sich auf „besonders intensive [...] Emotionen, die oft mit einem Verlust der Handlungskontrolle einhergehen“ (Otto, Euler & Mandl, 2000a, S. 13). Gemäß Lindquist, MacCormack & Shablack (2015) fällt der Wahrnehmung und dem Erleben von Affekten in der Bewertung ebenfalls eine große Bedeutung zu. Letzteres trifft auf Zustände zu, die sich einer genauen sprachlichen Einordnung entziehen, aber dennoch zwischen angenehm und unangenehm differenziert werden können. Diesem Aspekt soll insofern Rechnung

getragen werden, dass die Unterscheidung in positiv und negativ in der folgenden Gegenüberstellung der Modelle beibehalten wird. Davidson, Scherer & Goldsmith (2009) gehen noch weiter und inkludieren alle emotionsgeladenen Zustände. Umgangssprachlich wird Affekt mit einer plötzlichen Erregung oder einer besonderen psychischen Angespanntheit in Verbindung gebracht (Dudenredaktion, o. J. b.).

### **2.1.2 Stimmung**

Die Stimmung zeichnet einen positiven oder negativen, nicht gegen ein Objekt gerichteten Zustand aus. Sie stellt in der Psychologie eine über einen längeren Zeitraum unveränderte Befindlichkeit eines Individuums in geringer Intensität dar. Gefühle hingegen beschreiben kürzere und deutlicher affektierte Zustände.

Wahrgenommene Emotionen können einen nachhaltigen Einfluss auf die Stimmungslage eines Individuums haben (Wirtz, 2017). Die Stimmung oder das Gemüt einer Person ist an den Erfüllungsgrad seiner Bedürfnisse und die aktuelle Verfassung des Selbst geknüpft. Die Stimmung kann als eine im Hintergrund befindliche „Dauertönung des Erlebnisfeldes“ beschrieben werden (Otto et al., 2000a, S. 12).

### **2.1.3 Gefühle**

Gefühle und Emotionen werden nicht nur in der Alltagssprache synonym verwendet, auch in einem psychologischen Lexikon findet man eine inhaltliche Gleichstellung (Städtler, 2003). Doch bereits in den Anfängen der Emotionsforschung wurden diese beiden Begriffe einer inhaltlichen Trennung zu unterzogen (Cannon, 1927). Auch Stemmler, Schmidt-Atzert & Peper (2014, S. 19) sehen in Emotion und Gefühl zwei unterschiedliche Zustände, die in ihrer Reihenfolge abhängig von der Betrachtungsweise als „natürliche[s] Phänomen[...]“ oder „soziale Konstruktion[...]“ aufeinander aufbauen können.

An anderer lexikalischer Stelle wird ein Gefühl als „Erlebnisqualität [...] und somit [als] die subjektiven Komponenten von Emotion“ definiert (Dorsch, Wirtz & Strohmer, 2013, S. 609). Die begriffliche Abgrenzung umfasst Emotionen als psychologisches Konstrukt zur Ordnung von allen Gemütsbewegungen, unter die sich eine Teilmenge aller Gefühle und Gefühlslagen einreicht. Gefühle stellen somit nur ein Hyponym der Emotionen dar (Otto et al., 2000a). Galliker (2009), der Gefühle mit Bedürfnissen und Emotion mit Motivation verknüpft, spezifiziert dies dahingehend, dass sich Gefühl und Emotion durch die bewusste Wahrnehmung des subjektiven Phänomens unterscheiden. Eine ähnliche Argumentation verfolgen auch

Stemmler et al. (2014, S. 25), die als Arbeitsdefinition für Gefühl einen Zustand ausmachen, „der von der betroffenen Person selbst qualitativ beschreibbar oder benennbar ist“.

#### **2.1.4 Emotion**

Ähnlich wie bei den vorangegangenen Schlüsselbegriffen existiert auch hier kein Konsens über die allgemeingültige Auslegung des Emotionsbegriffs. Emotionen können mehrere innere Gemütszustände oder Gefühlsqualitäten umfassen, die sowohl subjektive Erfahrungen als auch verbale und non-verbale Ausdrucksformen sowie Körperreaktionen beinhalten und zu Verhaltensänderungen führen können, sofern diese nicht durch das Individuum reguliert werden (Wirtz, 2017). Zu einer ähnlichen Auffassung kommen auch Stemmler et al. (2014, S. 25), denen zufolge die Emotion „ein qualitativ näher beschreibbarer Zustand [ist], der mit Veränderung auf einer oder mehreren der folgenden Ebenen einhergeht: Gefühl, körperlicher Zustand und Ausdruck“. In der einschlägigen Forschung wird übergreifend nur ein weiteres Kriterium für psychologische Modelle akzeptiert, nämlich dass Emotionen eine wesentliche Komponente des menschlichen Geistes darstellen. Darüber hinaus, so formulieren es Gross & Barrett (2011) weiterführend, gibt es keinen weiteren gemeinsamen Nenner. Lindquist et al. (2015) weisen jedoch zusätzlich auf den zentralen sprachlichen Charakter von Emotionen hin, der es, im Gegensatz zu Affekten, erlaubt unterschiedliche Zustände genauer zu differenzieren. Letzteres ist laut den Autoren jedoch auch mit einer Ungenauigkeit behaftet, da tatsächliche Emotionszustände sprachlich nur bedingt in Worte gekleidet werden können. Darüber hinaus können Emotionen in unterschiedlichen Sprachräumen anders konnotiert sein, so dass „emotions might in fact get lost in translation between cultures whose languages encode different emotion terms“ (Lindquist, 2017, S. 138). Auch das Set an Emotionen kann abhängig vom Sprachraum variieren (Briggs, 1995; Hurtado-de-Mendoza, Molina & Fernández-Dols, 2012). Letzteres hat für diese Arbeit als Implikation, dass die gegenübergestellten Emotionsmodelle im sprachlichen Hintergrund der hier auszuwertenden Texte berücksichtigt werden müssen.

Da der Begriff der Emotion für diese Arbeit von zentraler Bedeutung ist, wird auf die wohl umfassendste semantische Analyse aus 101 wissenschaftlichen Quellen von Kleinginna & Kleinginna (1981) verwiesen, die eine entsprechende Arbeitsdefinition erstellt haben. Dabei wird auf die deutsche Übersetzung von auf Otto et al. (2000a, S. 15) zurückgegriffen:

Emotion ist ein komplexes Interaktionsgefüge subjektiver und objektiver Faktoren, das von neuronal/hormonalen Systemen vermittelt wird, die (a) affektive Erfahrungen, wie Gefühle der Erregung oder Lust/Unlust, bewirken können; (b) kognitive Prozesse, wie emotional relevante Wahrnehmungseffekte, Bewertungen, Klassifikationsprozesse, hervorrufen können; (c) ausgedehnte physiologische Anpassungen an die erregungsauslösenden Bedingungen in Gang setzen können; (d) zu Verhalten führen können, welches oft expressiv, zielgerichtet und adaptiv ist.

Die unterschiedlichen theoretischen Verständnisse entstanden aus der historischen Entwicklung des Emotionsbegriffs und aus den jeweils vorherrschenden psychologischen Strömungen. Diese wurden ebenfalls von Gross & Barrett (2011) anhand eines Kontinuums nachgezeichnet, das in vier Kategorien untergliedert wurde, wie in Abbildung 1 veranschaulicht wird. Die hier für die Emotionserkennung untersuchten Emotionsmodelle reihen sich in die diskrete oder dimensionale Herangehensweise ein (Jacob-Dazarola, Ortíz Nicolás & Cárdenas Bayona, 2016). Es handelt sich um ein inhaltlich-psychologisches Differenzierungsmerkmal, das, wie später gezeigt wird, eine unterschiedliche computerlinguistischen Anwendungsgestaltung nach sich zieht.

	Basis-emotionen	Bewertungstheorien	Psychologische Konstruktion	Soziale Konstruktion
dimensional	Lövheim	Roseman	Scherer Ellsworth Manstead & Tetlock	Osgood, Suci & Tannenbaum Traxel & Heide Russell Wundt Watson & Telegen
diskret	Panksepp Watson McDougall Robinson Gray	Ekman Levenson Tomkins Damasio Izard	Arnold Lazarus Frijda Clore & Ortony	Schmidt-Atzert & Ströme Mees Mayring Mertens James
sonstige	Buck LeDoux Davis		Leventhal	Barrett Mandler Harlow Duffy Schlachter & Singer Solomon Averill Mesquita Harre

Abbildung 1: Unterschiedliche theoretische Sichtweisen auf Emotionen (angelehnt an Gross & Barrett, 2011)

Die Theorie der Basisemotionen geht auf äquivalente Gefühlszustände zurück, die kulturübergreifend meist anhand von Gesichtsausdrücken gemessen wurden. Diese Grundzustände sind weitestgehend angeboren oder entwickeln sich in frühester Kindheit. Begründet ist dieser theoretische Ansatz darauf, dass verschiedenartige Emotionen grundsätzlich separierbar und in ihrem mentalen Zustand einzigartig sind, weswegen diese auch als Basisemotionen bezeichnet werden (Gross & Barrett, 2011). Sie resultieren aus Evolutionsprozessen, weshalb die Ausdrucksweisen universell bei allen Menschen anzufinden sind (Wirtz, 2017).

Die Bewertungstheorien umfassen ein weites Spektrum an emotionalen Zuständen und den Prozessen der Emotionsbildung (Schirmer, 2015). Emotionen definieren sich nicht zwangsläufig durch klar voneinander abgrenzbare Geisteszustände in Verbindung mit psychischen Reaktionsmustern oder -verhaltensweisen (Gross & Barrett, 2011). Bei den behavioristischen Ansätzen liegt der Fokus auf der reinen Beobachtung und Auswertung einer Verhaltensweise einer Person. Eine Emotion ist demnach das reflexhafte Verhalten von Agenten, die auf einen Stimulus in einer bestimmten Art und Weise reagieren (Wirtz, 2017). In kognitiven Bewertungstheorien sind Emotionen nicht mehr losgelöst von Bewertungsvorgängen, sondern deren Bestandteil (Gross & Barrett, 2011). Analog zur behavioristischen Herangehensweise

existieren der Reiz und die Reaktion, jedoch wird dieses Schema durch die „Modifikation dieses Prozesses“ des Reiz-Reaktions-Schemas bzw. der „Emotionsregulation“ durchbrochen (Stemmler et al., S. 134). Für die Emotionserkennung ist die Bewertungstheorie von praktischer Relevanz, da die meisten computergestützten Emotionsmodelle darauf fußen (Marsella, Gratch & Petta, 2010).

Bei dem psychologisch konstruierten Ansatz sind Emotionen das Ergebnis eines kontinuierlichen Entwicklungsprozesses. Mehrere Faktoren spielen hierbei eine Rolle. Emotionen entstehen nicht ausschließlich durch Kognitionszustände oder Wahrnehmung. Es kann nicht zwangsläufig ein Kausalzusammenhang zwischen Ereignissen und mentalen Zuständen gezogen werden, sondern eine Reihe von Größen und Einflüssen sind für den Gemütszustand des Individuums verantwortlich (Gross & Barrett, 2011).

Der soziale Konstruktivismus bezieht auch die soziale Interaktion mehrerer Personen mit ein (Wirtz, 2017). Durch die Soziogenese entstehen Zustände wie Scham oder Schüchternheit, die ohne die Betrachtung miteinander agierender Agenten nicht erklärt werden können (Burkitt, 2014). Nach den Gesichtspunkten der sozial konstruierten Emotionstheorien sind mental wahrgenommene Zustände ein Produkt des sozialen Kontextes und kultureller Vorgaben. Emotionen sind im Hinblick auf die sozialen Erwartungen und gruppenspezifisch vorgegebene Rahmenbedingungen eher ein kulturell vorgegebenes und gelerntes Verständnis als ein natürlicher interner Geisteszustand (Gross & Barrett, 2011). Dies ist ein relevanter Aspekt, da die Partizipation an einer Diskussionsplattform nicht zum Selbstzweck, sondern als Mittel der sozialen Interaktion und des kollektiven Austausches genutzt wird.

Es bleibt festzuhalten, dass es unterschiedliche Forschungsansätze mit jeweils eigenem Emotionsverständnis gibt und diese von vorneherein kein Einschränkungsmerkmal für die Emotionserkennung darstellen. Für die weiterführende Analyse bedient sich die vorliegende Arbeit daher aller oben genannten Schulen. Darüber hinaus gibt es inhaltliche Unterschieden zwischen den Begriffen Emotion und Gefühl. Diese werden jedoch nicht als maßgeblich für die Auseinandersetzung mit diesem forschungsfeldübergreifenden Thema angesehen. In dieser Arbeit wird eine sprachliche Ungenauigkeit der beiden Begriffe demnach in Kauf genommen: Emotionen und Gefühle werden in den weiteren Ausführungen synonym verwendet, da die genaue Definition der jeweiligen Erlebnisqualitäten ohnehin mit dem jeweils betrachteten Emotionsmodell verknüpft ist.

Die vorliegende wissenschaftliche Arbeit orientiert sich an dem Ordnungsschema von Reisenzein (2000b), das in Abbildung 2 dargestellt ist. Es wird auf die dimensionale und die diskrete Abgrenzung der Emotionen besonderes Augenmerk gelegt. Man mag einwenden, dass

es insbesondere im psychologischen Konstruktivismus Ansätze gibt, mittels Einbeziehung der Affektdimension außersprachliche diskrete Emotionen zu beschreiben, um so den Brückenschlag zwischen beiden Ansätzen herzustellen (Lindquist et al., 2015). Es sei an dieser Stelle jedoch explizit erwähnt, dass in dieser Arbeit nicht der Weg der psychologischen Beantwortung der Richtigkeit oder Ausprägung aktueller Strömungen der Emotions- bzw. Affektforschung beschränkt wird. Vielmehr wird sich hier an der Einteilung zwischen dimensionalen und diskreten Ansätzen orientiert. Begründet wird dies damit, dass der Schritt der Auswahl eines geeigneten Emotionsmodells in der Vielzahl der bestehenden computerlinguistischen Arbeiten zu kurz kommt. Somit ist diese Forschungsarbeit nicht an den versierten Leser der Psychologie adressiert, da psychologische Konzepte nicht vertieft bzw. erweitert werden, sondern an Personen aus dem Gebiet der Computerlinguistik, die eine fundiertere Wahl eines Emotionsmodells treffen wollen. Es sei somit auch deutlich gemacht, dass Konzepte aus der Psychologie verwendet werden, die Bedeutung somit auch beigesteuert wird, jedoch die Breite der Abdeckung nicht vollumfänglich behandelt werden können.



Abbildung 2: Differenzierbarkeit der Emotionstheorien (Reisenzein, 2000b, S. 210)

## 2.2 Fokussierung dieser Arbeit

Wie Quigley, Lindquist & Barrett (2014) herausarbeiten, gibt es eine große Bandbreite an Möglichkeiten, Emotionen bzw. auch Veränderungen in Affekten zu messen. Dies reicht von Selbstberichten (Cowen & Keltner, 2017), Beobachterbewertungen (Quigley et al., 2014), Mimiken (Gervasi, Franzoni, Riganelli & Tasso, 2019; Khan, Siddiqi, Khan, Wahla & Samyan, 2019; Ko, 2018), akustischen Signalen (Abdel-Wahab & Busso, 2018; Ardakani & Arbabi, 2017; Bai et al., 2017; Deb & Dandapat, 2019; Goshvarpour, Abbasi & Goshvarpour, 2017;

Grekow, 2018; Kaya & Karpov, 2018; Lv, Li & Huang, 2018; Noroozi, Marjanovic, Njegus, Escalera & Anbarjafari, 2018b; Shepstone, Tan & Jensen, 2018; Spyrou, Vernikos, Nikopoulou & Mylonas, 2018; Yenigalla et al., 2018; Yoon, Son & Kwon, 2019; Zhang, K., Zhang, Li, Yang & Sun, 2018; Zhang, B., Provost & Essl, 2019), Text (Gaind, Syal & Padgalwar, 2019), Verhaltensänderung (Barros et al., 2018), Körperreaktionen (Feng, H., Golshan & Mahoor, 2018; Fourati & Pelachaud, 2018; Kumar & Shivakumar, 2018; Noroozi et al., 2018a; Santamaria-Granados, Organero, González, Abdulhay & N., 2019; Song et al., 2019; Zhao et al., 2019), Hormonspiegel (Lövheim, 2012) bis hin zu neuronalen Aktivitäten (Hamada, Zaidan & Zaidan, 2018; Katsigiannis & Ramzan, 2018; Liu, N. et al., 2018; Mert & Akan, 2018; Tiwari & Falk, 2019). Auch die Gründe, wodurch Emotionen ausgelöst wurden bzw. wodurch diese induziert werden, sind sehr vielfältig und umfassen beispielsweise Videosequenzen, Bilder, Gesichtsausdrücke, Tonaufnahmen, Musik, Vorstellung, Erinnerungen, emotionsgeladene Wörter, selbst durchgeführte oder vorgenommene Bewegungen, Medikamentenverabreichungen, virtuelle Realitäten oder Stimuli der realen Welt (Quigley et al., 2014). Um sich zu fokussieren, wird sich in dieser Arbeit ausschließlich auf die textuelle Bestimmung von Emotionen konzentriert, die durch Ereignisse der Nachrichtenwelt bzw. aus Interaktionen mit anderen Kommentatoren induziert wurden.

## **2.3 Bewertung der Emotionstheorien**

Die Eingliederung und Reihenfolge der hier vorgestellten Emotionstheorien und ihrer Beschreibungen sind an Otto, Euler & Mandl (2000b), Meyer, Reisenzein & Schützwohl (2001) und Ulich & Mayring (2003) angelehnt. Der theoretische Beitrag zur Wissenschaft liegt an dieser Stelle nicht in einer möglichst vollständigen Auflistung der Emotionsmodelle oder der Zusammenfassung der dazugehörenden Kritikpunkte. Dies fand an anderer literarischer Stelle bereits mehrfach statt. Der Mehrwert liegt in der Bezugssetzung der Modelle zur Forschung der Computerlinguistik und Sentimentanalyse bzw. Emotionsdetektion.

### **2.3.1 Dimensionale Kategorisierung der Emotionen**

Damit die Beurteilung nach einem nachvollziehbaren Muster abläuft, werden im Vorfeld Kriterien definiert, die als Grundlage für einen dezidierten Auswahlprozess dienen. Für die dimensionale Einteilung werden die Bewertungskriterien Validität, Anzahl der Dimensionsachsen und Realisierbarkeit der Dimension in einem textuellen Kontext verwendet, sowie die

empirische oder theoretische Abtragung von bestimmten Emotionsqualitäten. Die Kategorien werden in den nachfolgenden Absätzen näher erläutert.

Die Validität eines Modells stellt das zentrale Kriterium dar, um zu beurteilen, ob ein psychologischer Theorieansatz für die feingranulare Sentimentanalyse geeignet ist. Dies ist kein triviales Unterfangen, denn die Emotionsforschung blickt auf über hundert Jahre Entwicklung und wissenschaftlichen Diskurs zurück, weswegen sehr viele emotionstheoretische Kategorisierungsversuche existieren. Bis dato gibt es keine Einigkeit über ein allgemeingültiges Emotionskonzept. Auch über die Herangehensweisen zur Bestimmung oder Abgrenzung von Emotionen, deren zugrunde liegenden Eigenschaften, ihre Auslöser und Anzahl wurde keinen Konsens gefunden. Da kein Einvernehmen besteht, kann nicht abschließend und mit Bestimmtheit gesagt werden, welche Theorie korrekt bzw. ungültig ist. Daher wird als Kriterium für die Validität der wissenschaftliche Diskurs sowie die Kritik an den jeweiligen Modellen verwendet.

Die Anzahl der Dimensionen stellt ein deskriptives Kriterium dar. Die Menge der Dimensionen ist ein indirekter Hinweis auf die Differenziertheit des Modells. Generell kann davon ausgegangen werden, dass ein mehrdimensionales Modell die konkreten Emotionstypen besser trennen kann, wobei dies auch die Komplexität des Modells erhöht. Da die Modellgenauigkeit auch mit der Validität in Verbindung gebracht werden kann, sollen diese Punkte separiert voneinander betrachtet werden. Jedoch wird diesbezüglich herausgearbeiteten Kritiken besonderes Gehör geschenkt. Es wird grundsätzlich davon ausgegangen, dass alle Dimensionen in ihrer Wichtigkeit gleichwertig sind. Darüber hinaus wird hier standardmäßig davon ausgegangen, dass die Achsen zueinander orthogonal stehen, wenn nicht explizit anders angegeben.

Die Realisierbarkeit der Dimensionen in einem sentimentanalytischen Kontext zielt darauf ab, dass die vorgeschlagenen Emotionsausprägungen der jeweiligen Achsen maschinell aus einem Text ausgelesen werden können. Ein Beispiel für die computergestützte Erfassbarkeit ist das Aufspannen eines Kontinuums zwischen positiven und negativen Emotionen, wobei sich zwischen beiden Extrema neutrale Emotionen befinden. In Abgrenzung zu den diskreten Ansätzen geschieht dies unter der Prämisse, dass Emotionen anhand einer Skalierung der vom Modell vorgeschriebenen Dimensionen abgelesen werden können und nicht in umgekehrter Richtung, wobei anhand von gegebenen Emotionen eine Verortung auf den vorgeschlagenen Achsen stattfindet. Dies bedeutet für das Kriterium der Realisierbarkeit, dass vor allem untersucht wird, ob sich textuelle Hinweise finden lassen, die eine computerlinguistisch reproduzierbare Differenzierung und Einordnung auf einer Skala erlauben. Da es aktuell für weiterführende Emotionsdimensionen in Verbindung mit der maschinellen Auswertbarkeit innerhalb eines Textes kaum Literatur gibt, werden diese meist argumentativ erarbeitet und bewertet.

Das Kriterium der empirischen oder theoretischen Abtragung von bestimmten Emotionsqualitäten auf den vorgeschlagenen Achsen mag nicht zwingend erforderlich sein. Doch hat ein Modell mit repräsentativen Abtragungen einen deutlichen Vorteil bei der Evaluation einer Emotionserkennung gegenüber einem Modell, bei dem nur die Achsen angegeben sind. Letzteres lässt sich zwar mit unterschiedlichen empirischen Untersuchungen auf die gleiche Stufe heben, jedoch wird dem zusätzlich notwendigen Schritt mit diesem Kriterium in der Bewertung Rechnung getragen.

### 2.3.1.1 Traxel und Heide

#### 2.3.1.1.1 Dimensionen und Vollständigkeit

Traxel & Heide (1961) erstellten ein Modell mit den Achsen Angenehm–Unangenehm sowie Unterwerfung–Überhebung. Wie in Abbildung 3 zeigt, wurden 21 Zustände verortet.

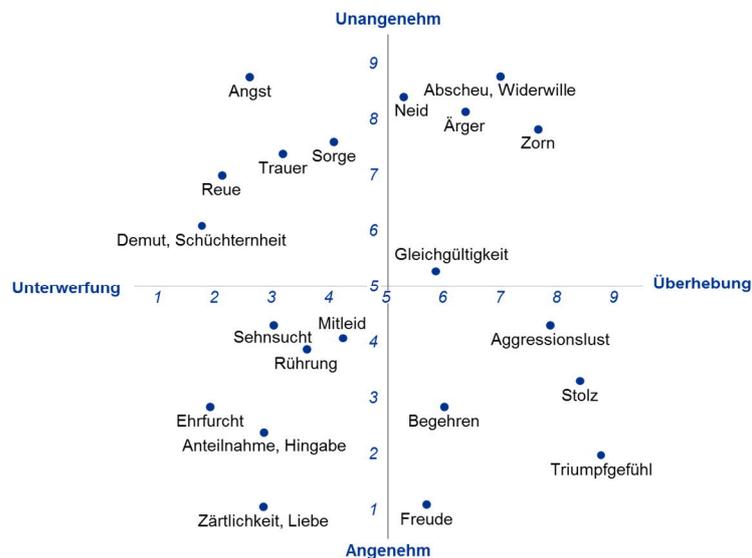


Abbildung 3: Einordnung der Emotionen nach dem Schätzverfahren von Traxel & Heide (1961)

#### 2.3.1.1.2 Modellkritik

Wie die Autoren selbst kritisch anmerken, ist in dem ersten Modell der Wahlmethode durch die Auswahl und Vorgabe der Emotionswörter bereits eine deterministische Verzerrung hinsichtlich des Ergebnisses gegeben. Ferner wenden sie ein, dass die Trennschärfe bei dem Term Liebe nicht gegeben ist. Als dritten Selbsteinwand bringen Traxel & Heide (1961) ein, dass es keine Gewissheit über die hier angesetzte zweidimensionale Einteilung gibt, oder darüber, ob gar mehrere Dimensionen zur Beschreibung des Modells nötig wären.

Als weiterer Kritikpunkt kann angeführt werden, dass sich die Dimension Unterwerfung–Überhebung von Traxel & Heide (1961) nicht mit den gesicherten Ergebnissen anderer Forscher decken, wie sie beispielsweise von Schmidt-Atzert (1980) herausgearbeitet wurden. Dies

kann als Indiz dafür genommen werden, dass das Modell nicht ausreichend differenziert oder unvollständig ist.

Dem emotionalen Ordnungsschema liegt zwar eine empirische Eingliederung zugrunde, jedoch basiert es nur auf der Einschätzung von 25 Versuchsteilnehmern. Die geringe Anzahl der Probanden kann in Verbindung mit ihrer Zusammenstellung zu Verzerrungen führen (Henrich, J., Heine & Norenzayan, 2010).

#### 2.3.1.1.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Die Realisierung von multidimensionalen Emotionsmodellen kann durch mehrere Klassifikatoren realisiert werden. Unter der Voraussetzung der statistischen Unabhängigkeit kann jede Achse einzeln bewertet werden (Cambria & Hussain, 2015). Dies erlaubt eine gewisse flexible Erweiterbarkeit des dimensional Ansatzes, da nachträglich Emotionsdimensionen ergänzt werden können. Die zwei orthogonalen Achsen können mittels einer kontinuierlichen oder diskret abgestuften Erfassung der beiden Dimensionen abgebildet werden.

Bezogen auf diesen exemplarischen Ansatz bedeutet dies, dass die Valenzdimension durch eine existente Polaritätserkennung realisiert werden kann (vgl Kapitel 5.1.2). Da die psychologische Valenz angenehme und unangenehme Gefühle abbildet, entspricht dies im Grunde dem computerlinguistischen Bestreben nach der Polaritätsbestimmung. Dies gilt analog auch für die nachfolgenden dimensional Emotionsmodelle.

Die zweite Dimension der Unterwerfung und Überhebung beschreibt die Relation einer Person zu einer anderen Person oder Sache. Letzteres bedingt eine genaue Bestimmung der sozialen Komponente bzw. des Verhältnisses zu einer anderen Person oder einem Sachverhalt. Die direkte Ermittlung der Ausprägung dieser Dimension ist nicht unkompliziert, da Mensch-zu-Mensch- und Mensch-zu-Objekt-Beziehungen bei diesem Ansatz berücksichtigt werden müssen. Für die Aufbereitung eines annotierten Datensatzes setzt dies eine detaillierte Erläuterung dieser Achsenausprägungen in möglichen Szenarien voraus. Im Gegensatz zu bewertenden Äußerungen werden Angaben dieser Art oft indirekt codiert oder als Situationsrahmen gegeben. Eine Textannotation ist notwendig, damit ein ausreichend großer Hintergrund gegeben ist. Es lässt sich somit festhalten, dass die zweite Dimension für die Sentimentanalyse nicht leicht zu realisieren ist.

Als problematisch bei einer Umsetzung dieses Ansatzes wird die abstandsbedingte Nähe der unterschiedlicher psychologischen Konzepte angesehen. Eine marginale Verschiebung auf der Achse könnte das Ergebnis der Textklassifikation beispielsweise von Abscheu zu Ärger

umschlagen lassen. Die Abgrenzung ist auch deswegen prekär, da sich die Dimensionsausprägungen Unterwerfung bzw. Überhebung sprachlich kaum greifen lassen.

Darüber hinaus ist der Ansatz der Emotionsverortung nicht unproblematisch. Dies ergibt sich beispielsweise durch große Lücken im Emotionsraster. Wie auch bei anderen dimensionalen Modellen ist hier nicht geklärt, ob die Nähe zu einem Emotionspunkt im Koordinatensystem entscheidend ist oder ob ein Punkt genau getroffen werden muss. Sofern Ersteres zutrifft, ist emotionstheoretisch unklar, ob ein mathematischer Flächenschluss oder eine Auswahl des nächsten Nachbarn angewendet werden dürfen.

#### 2.3.1.1.4 Abtragung der Dimensionen

Durch die Abtragung diskreter Emotionen im dimensionalen Raum ist auch der Umweg über die direkte Bestimmung der Emotionen möglich. Die entsprechende Dimensionsausprägung kann in den Quadranten nachgeschlagen werden. Wie in Abbildung 3 gezeigt, wurden 21 Emotionen empirisch abgetragen. Ein Hindernis, aber kein Ausschlusskriterium, stellen dabei die noch nicht klassifizierten Räume im Koordinatensystem dar. Diese lassen sich jedoch in den meisten Fällen durch weiterführende Klassifikation, sei es manuell oder automatisch, bzw. durch zusätzliche Theorie füllen.

### 2.3.1.2 Watson und Tellegen

#### 2.3.1.2.1 Dimensionen und Vollständigkeit

Das Modell von Watson & Tellegen (1985) soll der Abhängigkeit der Dimensionen Rechnung tragen. Ihrer Ansicht nach gibt es einen Zusammenhang zwischen negativ gearteten Emotionen und den Zuständen der Angst oder Depression (Watson, Clark & Tellegen, 1988). Beim Circumplexmodell der Emotionsausprägungen werden eine negative und eine positive Affektivität als dimensionale Abhängigkeit zwischen der Aktivierungs- und der Valenzdimension eingefügt (Watson & Tellegen, 1985). Dieses Modell kommt folglich ebenfalls mit nur zwei Dimensionen aus, wie Abbildung 4 darstellt.

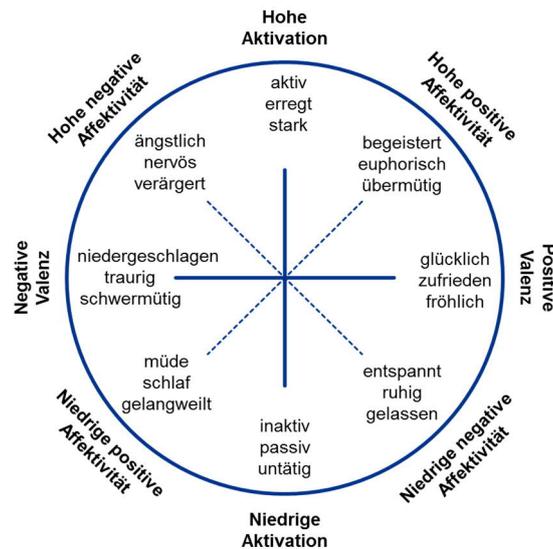


Abbildung 4: Watsons & Tellegens (1985) Emotionsmodell (aus Pekrun, 2000, S. 338)

### 2.3.1.2.2 Modellkritik

Beide Dimensionen lassen sich empirisch nachweisen. Basieren auf Blocks (1957) konnte mit diesen zwei Dimensionen ein Großteil der Varianz bei einer Faktorenanalyse erklärt werden. Die Dimensionsreduktion befindet sich im Einklang mit Bottenberg (1972), der in seiner Bewertung empirischer Dimensionssysteme diese beiden Kontinuen als valide und stabil einstuft. Dieser dimensionale Ansatz hat jedoch keine statistische Unabhängigkeit der beiden Merkmale Aktivierung und Valenz.

Zwei Dimensionen sind zu wenig, um das Phänomen der Emotionen ausreichend zu beschreiben. Wie Schmidt-Atzert (1980) anführt, lassen sich beispielsweise Ekelgefühle und Angst oder Liebe und Freude zweidimensional kaum abgrenzen. An der gleichen theoretischen Stelle werden die gesicherten Emotionsdimensionen in Frage gestellt, so dass sich die Einschränkung auf zwei Dimensionen als Trugschluss erweisen könnte (Mayring, 2003; Schmidt-Atzert, 1980). Kreibitz, Wilhelm, Roth & Gross (2007) weisen darauf hin, dass auf dieser zweidimensionalen Einordnung die Emotionen Furcht und Traurigkeit ähnliche Ausprägungen haben. In einem empirischen Test ermittelten sie jedoch deutliche Unterschiede auf den Ebenen des subjektiven Erlebens, des Gesichtsausdrucks, der körperlichen Reaktionen sowie der gemessenen Veränderung der Gehirnaktivität in Bezug auf die beiden Gefühlszustände. Durch die Vereinfachung fehlt es an Differenzierung; entscheidende Aspekte müssen außer Acht gelassen werden.

In einer Metastudie verglichen Smith & Ellsworth (1985) mehrere Dimensionsmodelle. Lediglich 4 der 23 verwendeten Studien wiesen ebenfalls nur zwei Dimensionen auf. Neben Abelson, Robert & Sernat (1962) und Shepard (1962a, 1962b) wurden auch zwei

Forschungsarbeiten von Russell (1980, 1983) betrachtet, der in Kapitel 2.3.1.3 noch ausführlicher behandelt wird. Wie Smith & Ellsworth (1985) herausstellen, haben all diese Modelle die gleiche Ausprägung, wenngleich sich die Nomenklatur unterscheidet. Jedoch, und dass soll als Kritikpunkt angebracht werden, deutet Smith & Ellsworth (1985) Metastudie darauf hin, dass zwei Dimensionen nicht ausreichend sind. Zwar räumen sie ein, dass „*attentional activity emerged as a consistent third dimension in the research on facial expression, none of the studies of subjective experience has found any evidence for it*“ (Smith & Ellsworth, 1985, S. 815), dennoch verwenden auch sie diese Dimension für ihr eigenes Modell.

#### 2.3.1.2.3 Realisierbarkeit

Durch die statistische Abhängigkeit kann bei diesem Ansatz nicht analog zum vorhergegangenen Kapitel vorgegangen werden. Ein nachträgliches Erweitern einer Polaritätserkennung um eine oder mehrere Achsen ist nur möglich, wenn die Achsen zueinander orthogonal sind und sich folglich nicht gegenseitig beeinflussen. In diesem speziellen Fall müssen beide Ausprägungen gleichzeitig betrachtet werden. Folglich müssen bei einer Annotation sowohl die positive und negative Meinung als auch der Grad der Aktivierung in Kombination sowie mögliche Abhängigkeitskonstellationen in Betracht gezogen werden.

Es gibt zahlreiche Ansatzmöglichkeiten für die Aktivierungsdimension, beispielsweise anhand von Satzmerkmalen wie dem Verbalstil oder der Verwendung von Aktiv- statt Passivkonstruktionen. Ebenfalls ist empirisch zu prüfen, ob ein überdurchschnittlicher Gebrauch von rhetorischen Stilmitteln auf einen höheren Aktivierungsgrad hindeutet. Auch Schlüsselwörter könnten als Rückschluss auf energetische Emotionszustände verwendet werden. Es sei jedoch zu bedenken gegeben, dass ein niedriger Grad der Erregung bzw. Aktivierung, im extremen Fall womöglich auch zu einer lethargischen oder kaum wahrnehmbaren Reaktionsbereitschaft führen kann. Spiegelt sich der Zustand der Passivität in der fehlenden Bereitschaft der Textgenerierung wider, so wäre zumindest in Frage zu stellen, ob jeglicher Korpus für die Erstellung einer feingranularen Sentimentanalyse geeignet ist.

#### 2.3.1.2.4 Abtragung der Dimensionen

Die abgetragenen Emotionen können zur indirekten dimensionalen Emotionsverortung genutzt werden. Da jeweils drei Emotionen gelistet wurden, sind theoretisch insgesamt 24 Emotionstypen im Modell verortet. Diese sind im dimensionalen Emotionsraum jedoch nur als Richtung und nicht als punktuelle Ausprägung vorhanden, weswegen keine kontinuierliche Dimensionsbestimmung der Emotionen vorgenommen werden kann.

### 2.3.1.3 Russell

#### 2.3.1.3.1 Dimensionen und Vollständigkeit

Russell (1980, 1983, 1997) wird repräsentativ für weitere zweidimensionale Emotionsmodelle der gleichen Bauart (beispielsweise Abelson & Sermat (1962) und Shepard (1962) vorgestellt. Zunächst entwickelte Russell, J. (1980) ein Circumplexmodell, welches später durch Ergänzungen angepasst wurde (Russell, J., 1997). Sein aktualisiertes Modell beruht auf den dimensionalen Ausprägungen Missbehagen („*displeasure*“) und Vergnügen („*pleasure*“) sowie Schlaf („*sleep*“) und Erregung („*arousal*“) (Russell, J., 1997, S. 298f.), wie aus Abbildung 5 hervorgeht. Im Vergleich zu den zuvor vorgestellten Dimensionsmodellen gibt es Parallelen zwischen der Erregungsdimension von Russell, J. (1997) und der Aktivierungsdimension von beispielsweise (Osgood, Suci & Tannenbaum, 1957) oder Watson et al. (1988). Die Dimension hört nicht bei dem Zustand einer Nicht-Erregung auf, sondern fügt dem Kontinuum noch eine Komponente der Erschöpfung hinzu.

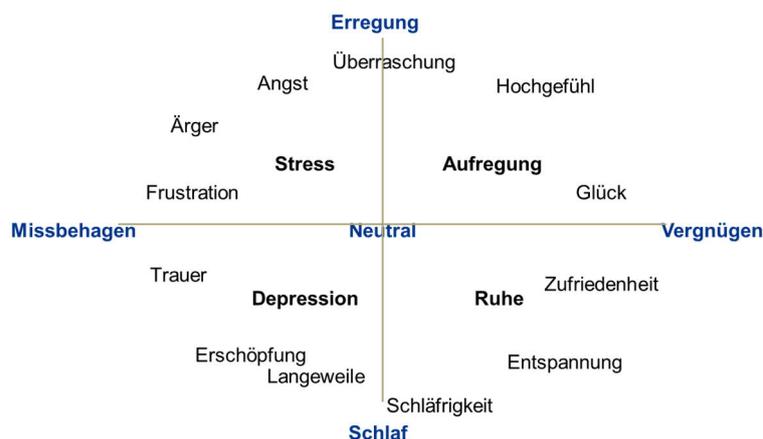


Abbildung 5: Dimensionale Einteilung der abgeleiteten Emotionen (nach Russell, J., 1997, S. 299)

#### 2.3.1.3.2 Modellkritik

Russells (1997) Ansatz ist eine empirische Untersuchung. Die Kritik konzentriert sich auf zwei Aspekte: zum einen das zugrunde liegende theoretische Konstrukt und zum anderen eine Studie, die die Ergebnisse reproduzieren sollte. Wie in der Argumentationslinie des vorangegangenen Kapitels bildet dieses Modell Emotionen ebenfalls nur auf zwei Dimensionen ab und unterliegt folglich vergleichbaren Ungenauigkeiten und Einschränkungen. Der zweite Aspekt wurde von Reisenzein (1994) überprüft. Er bestätigte in empirischen Studien die Existenz der Valenz- und Erregungsdimension, wenngleich er die Ausprägungen „*arousal-sleep or activation-deactivation*“ als vergleichbare Achsenbeschriftung auslegte und nicht explizit auf den Zustand des Schlafens einging (Reisenzein, 1994, S. 525). Während der Autor keine

Übereinstimmung bei Zufriedenheit („*contentment*“) und Überraschung („*surprise*“) feststellen konnte, wurde die restliche Verortung bestätigt (Reisenzein, 1994, S. 536).

#### 2.3.1.3.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Für eine Gliederung der Emotionen in einer Sentimentanalyse stellt die Erweiterung der Aktivierungsdimension dieses Modells ein schwieriges Unterfangen dar. Die Dimension wird textuell als unscharf abzugrenzen angesehen, da sie Zustände zwischen Erregung und Schlaf abbildet und somit zusätzlich die körperliche Erschöpfung berücksichtigt werden muss. Diese ist aus einem Fließtext schwierig bis gar nicht zu ermitteln, es sei denn, ein Verfasser erwähnt beispielsweise explizit, dass er müde sei. Dieser Punkt müsste jedoch als Hintergrundinformation für den restlichen Text berücksichtigt werden und in alle Emotionsklassifikationsentscheidungen einfließen.

Bezogen auf den Aktivierungsgrad einer Person, kann nicht immer zweifelsfrei gesagt werden, wann eine Abgrenzung zwischen Schlaf und Erregung vorgenommen werden sollte. So könnte beispielsweise der Fall eintreten, dass eine Person nach getaner körperlicher Arbeit Glück darüber empfindet, dass etwas vollendet ist. Diese Person weist gleichzeitig sowohl einen Zustand der Erschöpfung als auch eine innere Freude auf. Nach diesem Modell würde sich bei der Aggregation im Sinne einer gemeinsamen Betrachtung ein Zustand im Quadranten Ruhe einstellen. Jedoch dürfte hier keine unerwünschte Überlagerung stattfinden, sondern nur eine Separierung würde den beiden Emotionszuständen nach Russell, J. (1997) gerecht werden. Auch Langeweile und Erschöpfung sind Beispiele dieser Art. Eine gelangweilte Person hat eine niedrige geistige Erregung, kann sich jedoch in vollkommen erholtter körperlicher Verfassung befinden. Die geringe Trennschärfe der emotionalen Zustände kann zu umsetzungsbedingten Problemen in der Emotionserkennung führen.

#### 2.3.1.3.4 Abtragung der Dimensionen

Einige diskrete Emotionen sind bereits empirisch abgetragen und hinterlegt, wodurch der Umweg der Dimensionsausprägungsbestimmung über ein Nachschlageverfahren möglich ist. In Summe wurden jedoch nur zwölf Emotionsqualitäten auf den zwei Achsen verankert. Diese sind zusätzlich mit einer gewissen Unschärfe behaftet, da die seriell gelisteten Emotionszustände nur ungefähr im Vektorraum verortet sind.

### **2.3.1.4 Osgood, Suci und Tannenbaum**

#### 2.3.1.4.1 Dimensionen und Vollständigkeit

Osgood et al. (1957) reduzierten 20 semantischen Differentiale mittels einer Faktorenanalyse auf 3 wesentliche Dimensionen. Diese sind die Valenz- („*evaluation*“), die Potenz- („*potency*“) und die Aktivierungsdimension („*activity*“). D. h. die Dimension differenziert zwischen einem aktivierten, anregenden, dynamischen Zustand und einem passiven, ruhigen Zustand (Rummer & Engelkamp, 2000).

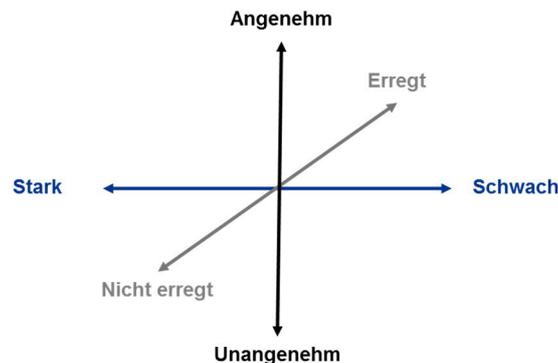


Abbildung 6: Emotionsdimensionen aus semantischen Differentialen (nach Osgood et al., 1957)

#### 2.3.1.4.2 Modellkritik

Ein Kritikpunkt an der Herangehensweise besteht in der „Isolierung des Einflusses denotativer Bedeutungsrelationen“, bezogen auf die Konnotation des Wortes (Dorsch et al., 2013, S. 1412). Dies bedeutet, dass die vorgegebenen Konzepte nicht ausschließlich und ohne Einfluss in Verbindung stehender Konzepte anhand einer Skala bewertet werden. Ortner (2014) ergänzt einen weiteren Kritikpunkt, nämlich dass die Wertigkeiten der Konzepte bei jeder Person kognitiv unterschiedlich verankert sind, beispielsweise durch den subjektiven Erfahrungsschatz, wodurch erhebliche Varianzen bei der Bewertung einzelner Konzepte auf der Skala möglich sind.

Für dieses Modell spricht, dass sich die drei Achsen, wenngleich unter anderem Label, bei anderen Autoren wiederfinden. Schmidt-Atzert (1980) spricht diesen Emotionsdimensionen auch eine gewisse gesicherte Stellung zu.

Sousa (2007) kritisiert, dass Emotionsdimensionen statistisch unabhängig sein müssen. Dies ist jedoch bei Aktivierung und Valenz nicht gegeben. So gibt er zu bedenken, dass *„[e]xtremely high arousal can presumably become ‚unbearable‘ and thus incompatible with positive valence. Conversely a zero degree of arousal seems incompatible with any valence, positive or negative“* (Sousa, 2007, S. 385).

#### 2.3.1.4.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Die Erstellung des Modells weist Parallelen zu der Annotation von Datensätzen in der Sentimentanalyse auf. Osgood et al. (1957) entwickelten ein Erhebungsverfahren, um eine

Gefühlsreaktion auf schlagwortbasierte Stimuli zu messen. Mittels des *Semantic Differential* wird gemessen, inwieweit die Einschätzung bei einem Probanden in die eine oder andere Richtung ausschlägt (Heise, 1977).

Die zweite Dimension der Potenz zeigt Parallelen zur Dimension der Unterwerfung und Überhebung von Traxel & Heide (1961), wobei hier der Fokus weniger auf der relationalen Diskrepanz zwischen einer Person und einem über- oder untergeordneten Dritten liegt, sondern auf der Emotionsqualität als solches. Für die Sentimentanalyse bedeutet dies daher, dass emotional abgestufte Ausprägungen nicht indirekt über die Relation, sondern beispielsweise direkt über Wortrepräsentationen und die Anwendung der semantischen Differentiale ermittelt werden können. Anders als beim diskreten Ansatz zielt das dimensionale Schema nicht direkt auf die Nennung von konkreten Gefühlsqualitäten ab, sondern es können Lexeme gesucht werden, die exemplarisch mit Triumphgefühl, Macht und Dominanz auf der einen Seite und Abhängigkeit, Unterwerfung und Unterjochung auf der anderen Seite koexistieren. Letzteres wäre entweder in einer empirischen Ermittlung wie bei Traxel & Heide (1961) oder in einem textanalytischen Ansatz wie bei Shaver, Schwartz, Kirson & O'Connor (1987) denkbar.

Ein analoges Vorgehen wäre bei der Aktivierungsdimension vorstellbar. Mittels Schlüsselwörtern könnten ähnliche Verfahren wie bei einer Polaritätserkennung verwendet werden. Beispielhafte Adjektive wären einerseits „aktiv“, „fleißig“, „energetisch“ oder „geschäftig“ und andererseits „passiv“, „träge“, „bequem“ oder „schlapp“. Wie bereits bei der Realisierung des Ansatzes von Watson & Tellegen (1985) angeführt, wäre zu prüfen, inwieweit rhetorische Mittel und Schreibstile für die Aktivierung herangezogen werden können.

Alternativ lassen sich für alle im Ansatz existenten Dimensionen semantische Differentiale als Bewertungsskalen nutzen. Textpassagen oder einzelne Wörter könnten von Annotatoren anhand ihrer Ausprägungen auf den drei Achsen klassifiziert werden. Durch eine Vielzahl solcher Annotationen und einer empirischen Abwägung gleicher Zuordnung ließe sich ein Trainingsdatensatz erstellen, der für eine Emotionserkennung verwendet werden kann.

Ein Vorteil dieser Bemessungsgrundlage besteht darin, dass die Einteilung nach Valenz, Potenz und Aktivierung auch heute noch in unterschiedlichen Forschungsdisziplinen breite Akzeptanz findet. In der Linguistik werden die erwähnten semantischen Differentiale genutzt, um die Konnotation bzw. die Wertigkeit eines Terms zu bestimmen (Imhasly, Marfurt & Portmann, 1982; Roth, 2003, 267f.; Rummer & Engelkamp, 2000). Ferner erwies sich der empirische Ansatz der Dimensionsreduktion von Emotionen kultur- und sprachübergreifend bis auf zwei Ausnahmen als sehr robust (Heise, 1977; Jakobovits, 1966; Osgood, 1964).

### 2.3.1.4.4 Abtragung der Dimensionen

Osgood et al. (1957) haben keine konkreten Emotionen auf den Achsen verortet, sondern sie schlagen semantische Differentiale vor. Um ein Nachschlagen zu ermöglichen, müssen jedoch alle Emotionsqualitäten im semantischen Raum verortet sein. Es gibt von Shaver et al. (1987) einen Bestimmungsversuch, bei dem 135 unterschiedliche Emotionszustände auf den von Osgood et al. (1957) definierten Dimensionen bestimmt werden. Durch diese Fülle an diskreten Vertretern ist eine dezidiertere Bestimmung der Achsenausprägungen möglich. Es wird daher behauptet, dass dieses Modell aufgrund der empirischen Untermauerung besonders gut zur indirekten Bestimmung geeignet ist.

### 2.3.1.5 Scherer

#### 2.3.1.5.1 Dimensionen und Vollständigkeit

Ausgehend von der postnatalen Entwicklung, arbeitete Scherer (1982, S. 558) *Stimulus-Evaluation-Checks* (SEC) heraus, die einer fünfdimensionalen Vektorraumrepräsentation entsprechen. Diese setzen sich aus der Bewertung einer Neuigkeit („*novelty*“), der intrinsisch wahrgenommenen Valenz („*intrinsic pleasure*“), der Zielrelevanz („*goal/plan relevance*“), dem Grad der Beherrschbarkeit („*coping potential*“) und der Übereinstimmung mit Selbst- und Fremdkonzept („*norm/self-concept compatibility*“) zusammen.

Die acht frühkindlichen Emotionen Aufschrecken („*startle*“), Missfallen („*displeasure*“), Überraschung („*surprise*“), Freude („*joy*“), Wut („*anger*“), Angst („*fear*“), Scham bzw. Schuld („*shame/guilt*“) und Verachtung („*contempt*“) sind diskrete Ausprägungen dieses dimensionalen Emotionsmodells (Scherer, 1982, S. 561). In Tabelle 1 werden die Zusammenhänge der Voraussetzung und der möglichen Emotionsbildung dargestellt.

	Entwicklungsmonat	Neuigkeit	Valenz	Zielrelevanz	Beherrschbarkeit	Normkompatibilität
Aufschrecken	0	<b>notwendig</b>				
Missfallen	0	vorhanden	<b>notwendig</b>			
Überraschung	1–3	vorhanden	vorhanden	<b>notwendig</b>		
Freude	3–5	vorhanden	vorhanden	<b>notwendig</b>		
Wut	4–6	vorhanden	vorhanden	<b>notwendig</b>	<b>notwendig</b>	
Angst	5–9	vorhanden	vorhanden	<b>notwendig</b>	<b>notwendig</b>	
Scham/Schuld	12–15	vorhanden	vorhanden	vorhanden	vorhanden	<b>notwendig</b>
Verachtung	15–18	vorhanden	vorhanden	vorhanden	vorhanden	<b>notwendig</b>

Tabelle 1: Dimensionsausprägungen nach Scherer (1982, S. 561)

In einer späteren Arbeit zur Emotionsforschung spricht sich Scherer (2005) für den weniger komplizierten Ansatz des *Geneva Emotion Wheel* aus. Dieses existiert nunmehr in der zweiten Version und ist ebenfalls ein dimensionaler Ansatz (Shuman, Schlegel & Scherer,

2015). Dem zugrunde liegt unter anderem ein Fragebogen, durch den beispielsweise eine Einordnung anhand der Dimensionen Kontrolle und Valenz vorgenommen werden kann. Die Emotionsverortung ist in Abbildung 7 dargestellt.

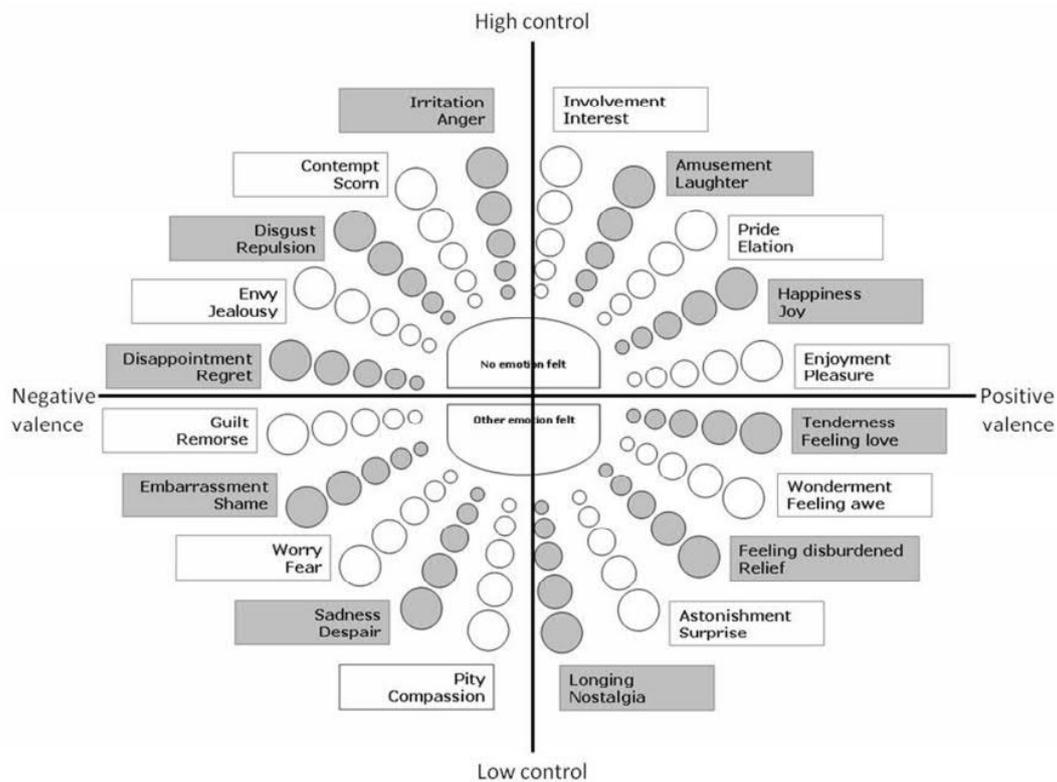


Abbildung 7: Geneva Emotion Wheel (Shuman et al., 2015)

Die dimensionale Anbringung der beiden Achsen soll jedoch nicht irreführend sein, denn die eigentliche Einordnung ist multidimensionaler oder kategorischer Natur und könnte auch im diskreten Kapitel eingegliedert werden. Denn die nunmehr 20 Emotionskategorien können koexistieren und in unterschiedlicher Stärke ausgeprägt sein.

Scherer (2005) stellte das *Geneva Emotion Wheel* in der ersten Version dem zuvor ange-deutete Modell von Russell, J. (1983) gegenüber. Er befand, „*this simple superposition yields a remarkably good fit*“ (Scherer, 2005, S. 722), was in dem semantischen Raum der Emotionen in Abbildung 8 gezeigt wird.

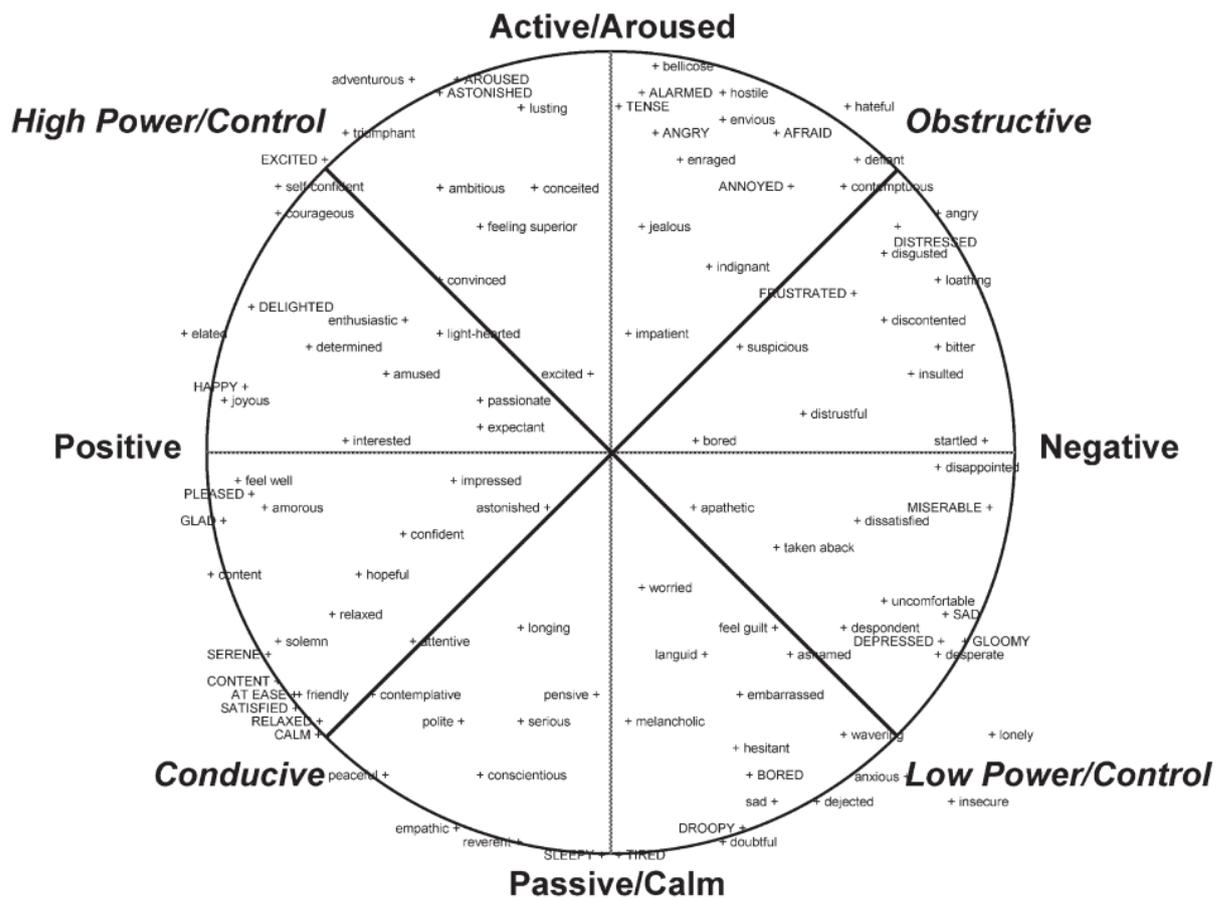


Abbildung 8: Semantischer Raum der Emotionen (Scherer, 2005, S. 720)

### 2.3.1.5.2 Modellkritik

Scherers (1982) Beitrag ist ein hypothetischer Versuch, die Ontogenese der Emotionen auf einer Reihe fundamentaler Achsen abzubilden. Er räumt den theoretischen Charakter des Modells selbst mit folgenden Worten ein (Scherer, 1982, S. 560):

*„The assumption underlying this sequence of stimulus evaluation checks is that each consecutive SEC further differentiates the emotional state of the organism. I assume that our verbal emotion labels characterize the outcome of particular checks.“*

Auch die Diskussion von Zajonc (1980) über die Reihenfolge des Emotionsprozesses, ob Emotionen oder kognitive Bewertungsvorgänge vorausgehen, kann hier angebracht werden. Dabei wird auf Kapitel 2.3.2.13.2 verwiesen, da dies dort kontextspezifisch abgehandelt wird.

Das zuerstgenannte Modell ist nur eingeschränkt zur Bestimmung der Emotionen geeignet. Es wurde nicht vollständig ausdifferenziert, da, wie Scherer (1982, S. 561) selbst schreibt, *„the respective SEC is a necessary prerequisite for the occurrence of a particular emotion (albeit not necessarily sufficient)“*. Letzteres bezieht sich auf die Dimensionsausprägungen, die in Tabelle 1 als vorhanden eingestuft sind. Zwei marginale Kritikpunkte hinsichtlich der Vollständigkeit der Dimensionen sollen hier angebracht werden, nämlich dass möglicherweise

nicht alle frühkindlichen Emotionsqualitäten berücksichtigt wurden (vgl. Vaas, 2000) und dass nicht geklärt sei, warum bei dem Emotionsdifferenzierungsprozess nur 18 Monate betrachtet wurden.

Bezüglich des neueren Vorstoßes von Scherer (2005) stimmt Frijda (2007, S. 382) insofern mit ihm überein, dass „[w]ithout consensual conceptualization and operationalization of exactly what phenomenon is to be studied, progress in theory and research is difficult to achieve, and fruitless debates are likely to proliferate“. Auch Sousa (2007, S. 384) merkte an, dass „[h]is short article packs a great deal of useful wisdom, both in what he includes in his characterization of emotions and in what he sets aside“. Jedoch gab sie zu Bedenken, dass der Ergebnishorizont der abgebildeten Emotionen im *Geneva Emotion Wheel* als Resultat des dimensionalen Ansatzes zu kurz gegriffen sein könnten. Parrott (2007, S. 423) sieht bei dem Emotionsgerüst des *Geneva Emotion Wheel* besonders vorteilhaft, dass es „fuzzy in nature“ ist.

#### 2.3.1.5.3 Realisierbarkeit

Die Bestimmbarkeit der dimensionalen Ausprägungen der Neuigkeit im ersten Modell lässt sich nur bedingt realisieren. Hinzu kommen personenabhängige Faktoren. Diese können nicht mittels einer Verteilung abgebildet werden, da sie bei jeder Person unterschiedlich ausgeprägt sind. Daher lässt sich diese Information kaum für eine Textanalyse nutzen, es sei denn, es wird explizit erwähnt, dass dies für den Autor neuartig ist. Um darüber hinaus in Einklang mit Scherers (1982) Theorie zu sein, muss ferner unterstellt werden, dass die Nachricht eine gewisse Brisanz und subjektive Relevanz aufweist, um eine emotionale Reaktion hervorzurufen. Deren Bestimmung steht analytisch unter einem ähnlich schlechten Stern, weswegen mit Sicherheit gesagt werden kann, dass eine computerlinguistische Determination dieser Dimensionsausprägung kaum möglich sein dürfte, sofern die individuellen Beweggründe einer Person nicht bekannt sind.

Die subjektive Zielrelevanz im ersten Model kann textuell nur eingeschränkt beurteilt werden, da hierzu ebenfalls die inneren Zielvorstellungen sowie die gegebenen Grenzen, innerhalb derer sich die Person bewegt, bekannt sein müssten. Sofern das Ziel des Verfassers eines emotionalen Textes nicht vorgegeben, anderweitig bekannt oder explizit erwähnt wird, ist eine sentimentanalytische Ermittlung kaum vorstellbar, es sei denn, es wird wieder darauf zurückgegriffen, den Autor eines Textes direkt zu befragen und eine Vielzahl solcher Ergebnisse mit typischen Formulierungen abzugleichen. Doch selbst dann wird argumentiert, dass dies mit einer großen Unschärfe verbunden ist, da speziell bei dieser Dimension die beiden Faktoren Neuigkeit und Relevanz beteiligt sind.

Auch die Dimensionen Beherrschbarkeit und Normkompatibilität sind zum aktuellen Stand der Technik nur unter sehr großem Aufwand umsetzbar, da neben der intrapersonellen Komponente nun auch interpersonelle Konstellationen als Unbekannte in das Modell einfließen. An dieser Stelle wird argumentiert, dass Dimensionsausprägungen, die einen relationalen Zusammenhang zwischen einer fühlenden Person und einer anderen Person, einem Objekt oder einem Sachverhalt aufbauen, in den meisten Fällen maschinell zu komplex geartet sind, als dass diese zweifelsfrei und großflächig reproduzierbar einer textuellen Repräsentation zu entnehmen sind. Als mögliche Voraussetzung dafür wird angenommen, dass eine konkrete Erfassung der textuell repräsentierten Ausgangslage notwendig ist, um aus einem Fließtext die gewünschte Information extrahieren zu können.

Das *Geneva Emotion Wheel* ist in der Realisierung vergleichbar mit diskreten Emotionsmodellen und daher deutlich einfacher zu realisieren. Verwiesen wird an dieser Stelle auf Kapitel 2.3.2, in dem diese Ansätze detaillierter beschrieben werden und alle vorkommenden diskreten Emotionen erläutert werden.

Somit bleibt für das neuere Modell aus dimensionaler Betrachtung die Berücksichtigung der Intensität in fünfstufiger Einteilung. Aus Sicht einer Annotation mag es strittige Zuordnungen geben, doch die Eingliederung kann bereits anhand kurzer Textpassagen vorgenommen werden. Beispiele wie ich bin jetzt schon erbost im Vergleich zu ich bin richtig stinksauer zeigen deutlich eine Intensitätssteigerung im zweiten Textfragment. Um diese Kategorie richtig umzusetzen, sollte jedoch darauf geachtet werden, dass eine Justierung der Annotatoren, im Sinne einer Erläuterung der Stufen und der normalen Intensität, vorgenommen wird.

#### 2.3.1.5.4 Abtragung der Dimensionen

Was das Abtragen der Emotionen auf den Achsen des ersten Modells betrifft, so muss hier bereits modellbedingt eine gewisse Ungenauigkeit eingeräumt werden. Dies betrifft insbesondere die in Tabelle 1 als vorhanden eingestufteten Ausprägungen und deren undefinierten Zustand. Da zudem keine intervall- oder ordinalskalierten Ausprägungen gegeben sind, werden die acht Emotionszustände als unzureichend abgetragen gekennzeichnet. Eine Bestimmung der Dimensionen über den Umweg der diskreten Emotionen ist unter diesen Umständen nicht möglich.

Im späteren Modell sind die Abtragungen bereits im Emotionsmodell enthalten. Daher ist dieser Punkt vollumfänglich erfüllt, wenngleich es anders als bei anderen Autoren dimensionaler Modelle keine positionale Verortung der Emotionen gibt.

## 2.3.1.6 Roseman

### 2.3.1.6.1 Dimensionen und Vollständigkeit

Das Emotionsmodell von Roseman (2001) leitet sich aus mehreren Bewertungsdimensionen ab (Reisenzein, 2000a), die zu diskreten Emotionsqualitäten führen. Die Dimensionsausprägungen betreffen das Unerwartete („*unexpectedness*“), die Zielvereinbarkeit („*situational state*“), den motivationalen Zustand („*motivational state*“), die Eintreffwahrscheinlichkeit („*Probability*“), den Ursachenbezugspunkt („*agency*“), die Beeinflussbarkeit („*control potential*“) und die Art des Problems („*problem type*“) (Roseman, 2001, S. 30f.). Das hypothetische Emotionsmodell mit den unterschiedlichen Einflussfaktoren ist in Tabelle 2 zur Verdeutlichung dargestellt.

			Positive Emotionen		Negative Emotionen	
			Zielkonsistent		Zielinkonsistent	
			Appetitiv	Aversiv	Appetitiv	Aversiv
<b>Umstandsbedingt</b>	-	Unerwartet	<b>Überraschung</b>			
	Geringe Beeinflussbarkeit	Unsicher	<b>Hoffnung</b>		<b>Angst</b>	
		Sicher	<b>Freude</b>	<b>Erleichterung</b>	<b>Trauer</b>	<b>Leid</b>
	Hohe Beeinflussbarkeit	Unsicher	<b>Hoffnung</b>		<b>Frustration</b>	<b>Ekel</b>
		Sicher	<b>Freude</b>	<b>Erleichterung</b>		
	<b>Bedingt durch andere</b>	Geringe Beeinflussbarkeit	Unsicher	<b>Zuneigung</b>		<b>Abneigung</b>
Sicher						
Hohe Beeinflussbarkeit		Unsicher		<b>Wut</b>	<b>Verachtung</b>	
		Sicher				
<b>Selbstbedingt</b>	Geringe Beeinflussbarkeit	Unsicher	<b>Stolz</b>		<b>Bedauern</b>	
		Sicher				
	Hohe Beeinflussbarkeit	Unsicher		<b>Schuld</b>	<b>Scham</b>	
		Sicher				
					Instrumentaler Problemtyp	Intrinsischer Problemtyp

Tabelle 2: Struktur der Emotionen (Roseman, 2001, S. 31)

Das Modell ist im Praxiseinsatz erprobt. Dies ist insbesondere positiv hervorzuheben, da das Modell dazu gedacht war, als Entscheidungsbaum zu fungieren (Bartsch & Hübner). Damit wäre es für Modelle der computerbasierten Entscheidung besonders gut geeignet.

### 2.3.1.6.2 Modellkritik

Pecchinenda (2001) übt Kritik an der Vorgehensweise der retropektiven Betrachtung der Emotionen durch Selbstberichte der Probanden. Sie führt an, dass „*this evidence reflects more stereotypical and idiosyncratic ideas of emotions rather than the various dimensions involved in the appraisal process*“ (ebenda S. 302). Tong et al. (2005) monieren, dass mit dieser

Methodik Emotionen nicht in situativen Kontexten gemessen werden und es aufgrund dessen zu Verzerrungen kommen kann.

Campos & Barrett (1990) sehen Rosemans Ansatz in der Herleitung der Emotionen problematisch, da er entwicklungspsychologische Aspekte zur Erklärung seiner Theorie heranzieht, diese aber nicht vollumfänglich berücksichtigt. Sie führen aus, dass Rossman „*ignores important complexities in the development of certain emotions*“ (Campos & Barrett, 1990, S. 248), weswegen die beiden Kritiker das von Hoffman (1982) untersuchte Schuldgefühl anführen, bei dem ein umfangreicheres Wahrnehmungsverständnis erst entwickelt werden muss und das nicht wie andere Emotionen von Geburt an vorhanden ist bzw. in den ersten Monaten entsteht.

Roseman & Evdokas (2004) räumen Zweifel an der Kausalkette ein, nach dem Bewertungsprozesse Emotionen hervorrufen. In einer empirischen Studie untersuchten sie die positiven Emotionen Freude, Erleichterung und Hoffnung. Während sie für den Zustand Erleichterung die Theorie von Roseman (2001) bestätigen konnten, ergaben sich für Freude nur schwache Signifikanzen ( $p < 0,10$ ) und für Hoffnung keine signifikante Beziehung entsprechend dem postulierten Zusammenhang.

Der affektierte Zustand Überraschung nimmt in dem Modell von Roseman (2001) einen Sonderstatus ein. Dies spricht entweder dafür, dass sich diese Emotion tatsächlich schwer klassifizieren lässt, weswegen auch keine Wertung zwischen positiv oder negativ vorgenommen werden kann. Scherer (1999) verweist auf eine generelle Kritik an der empirischen Bestimmung der Emotionen mittels Selbstberichte.

#### 2.3.1.6.3 Realisierbarkeit

Die dimensionale Ausprägung der Zielvereinbarkeit kann am ehesten mit der psychologischen Valenzdimension vorangegangener Emotionsmodelle verglichen werden. Diese deckt bei Roseman (2001) die Frage ab, ob etwas mit den subjektiven Zielen kongruent ist, also als zielkonsistent bezeichnet werden kann, oder nicht. Daraus resultieren die positiven und negativen Emotionen. In Abgrenzung zur umsetzbaren Polaritätserkennung wird dieser Dimension eine referenzielle Bedeutung hinsichtlich der subjektiven Ziele zugemessen, deren Deckung mit den bisherigen Valenzdimensionen erst noch geklärt werden muss.

Weiterführende Dimensionen nach Roseman (2001) weisen in Teilen Parallelen zu den Achsen von Scherer (2005) auf. Dies betrifft insbesondere die Ausprägungen des Unerwarteten bzw. der Neuigkeit, des Motivationszustands bzw. der Zielrelevanz und der Beeinflussbarkeit respektive Beherrschbarkeit. Analog zum vorangegangenen Kapitel wird davon ausgegangen,

dass die indirekte Ergründung der Dimensionen über die kontextuellen Informationen ohne eine direkte Befragung des Autors oder eine vollständige Erfassung der textuellen Sachverhalte und eine weiterführenden Analyse, z. B. durch das Einspielen zusätzlichen Wissens, sowie eine Lösung zur computerbasierten Schlussfolgerung kaum zu realisieren sind.

Ganz anders werden die beiden letzten Dimensionen Eintreffwahrscheinlichkeit und Ursachenbezug beurteilt. Die Bewertung, ob ein bestimmtes Ereignis als sicher oder unsicher gilt, ist zwar ebenfalls subjektiv, doch dies kann linguistisch abgegriffen werden – einerseits durch Hinweiswörter wie sicherlich, zweifellos, möglicherweise oder vielleicht sowie Phrasen wie kann sein, unter Umständen usw., andererseits durch Möglichkeitsformen im Modus der Grammatik wie dem Konjunktiv wie könnte sein oder dem Subjunktiv, der jedoch nur in bestimmten Sprachen vorhanden ist. Sprachanalytisch wird die Überprüfung der Umsetzung an dieser Stelle jedoch nicht weiter verfolgt, sondern nur argumentativ begründet.

Die Erfassung des Ursachenbezugspunkts, sei es umstandsbedingt, selbstbedingt oder durch andere, deutet eine breite analytische Verwendbarkeit an. Bisher losgelöste Emotionen werden gerichtet, also etwas oder jemand referenzierend. Damit ist eine noch differenziertere Eingliederung der Emotionen möglich (Mees, 1991; Ortony, Clore & Collins, 1988).

#### 2.3.1.6.4 Abtragung der Dimensionen

Die Abtragung der diskreten Emotionen ermöglicht ein indirektes Nachschlagen der Dimensionsausprägungen. Die 17 Emotionen können aufgrund ihrer Positionierung im Modell als theoretisch abgetragen angesehen werden. Die Achsenausprägungen sind jedoch, anders als bei den bisherigen Modellen, nominalskaliert und es gibt mit wenigen Ausnahmen eine 1:1-Beziehung. Unter den zweigeteilten Achsendifferenzierungen ist der Ursachenbezug die einzige Dimension mit drei Kategorien. Dieser Ansatz lässt sich ebenso wie die meisten vorangegangenen direkt und indirekt ermitteln.

### 2.3.1.7 Smith und Ellsworth

#### 2.3.1.7.1 Dimensionen und Vollständigkeit

Als Synthese von Roseman (1979) und Scherer (1982) schlagen Smith & Ellsworth (1985, S. 817f., 835) die Dimensionen psychologische Valenz („*pleasantness*“), Aufmerksamkeit („*attentional activity / novelty*“), Grad der Einflussnahme („*control Agency / coping potential*“), Eintreffwahrscheinlichkeit („*certainty*“), Schwierigkeit der Zielerreichung bzw. Zielrelevanz („*goal-path obstacle / goal relevance*“), Legitimität („*legitimacy*“) und Verantwortung („*responsibility*“) vor.

In einer nachgelagerten empirische Untersuchung reduzierten Smith & Ellsworth (1985) ihr Model auf sechs relevante Dimensionen. Neben den zuvor genannten Dimensionen psychologische Valenz („*pleasantness*“), Unsicherheit („*uncertainty*“), Aufmerksamkeit („*attention*“) und erwartete Anstrengung („*effort*“) tauchen die reduzierten Dimensionen Verantwortung / Kontrolle („*responsibility / control*“) sowie Situationskontrolle („*situational control*“) auf (Smith & Ellsworth, 1985). In Tabelle 3 wird die Verortung von 15 Emotionen auf den resultierenden Dimensionsachsen dargestellt.

Emotionen	Dimensionen					
	Psychologische Valenz	Verantwortung / Kontrolle	Unsicherheit	Aufmerksamkeit	Erwartete Anstrengung	Situationskontrolle
<b>Freude</b>	++	0	-	0	-	0
<b>Trauer</b>	-	-	0	0	0	++
<b>Wut</b>	-	--	0	0	+	--
<b>Langeweile</b>	-	0	-	--	--	0
<b>Herausforderung</b>	+	+	0	+	++	0
<b>Hoffnung</b>	+	0	+	+	0	+
<b>Angst</b>	-	0	+	0	+	+
<b>Interesse</b>	++	0	0	+	0	-
<b>Verachtung</b>	-	-	0	+	0	-
<b>Ekel</b>	-	-	-	--	0	0
<b>Frustration</b>	-	-	0	+	+	0
<b>Überraschung</b>	++	--	+	+	-	0
<b>Stolz</b>	++	+	-	0	-	-
<b>Scham</b>	-	++	0	0	0	0
<b>Schuld</b>	-	++	0	-	0	0

Tabelle 3: Emotionsdimensionen (nach Smith & Ellsworth, 1985; angelehnt an Omdahl, 2014)

### 2.3.1.7.2 Modellkritik

Manstead & Tetlock (1989) monieren an dem Modell von Smith & Ellsworth (1985), dass sich Scham und Schuld in deren Ausprägung nur sehr geringfügig unterscheiden, weswegen zusätzliche Ausprägungen nötig wären. Diese Kritik an der unzureichenden Abgrenzung wiederholen auch Tangney, Miller, Flicker & Barlow (1996, S. 1256), die empirisch nachweisen, dass es sich bei Scham („*shame*“), Schuldgefühlen („*guilt*“) und Verlegenheit („*embarrassment*“) um unterschiedliche Gefühlsqualitäten handelt. Sie weisen auch auf die soziale Komponente dieser drei Emotionen hin, womit sich der nächste Kritikpunkt anschließt. Smith & Ellsworth (1985) lassen in ihrer Betrachtung die sozialkonstruierenden Komponenten außer Acht, wie Manstead & Tetlock (1989, S. 227) hervorheben, da sie „*[c]oordinated social action*“ nicht in ihrem Modell berücksichtigen.

Mauro, Sato & Tucker (1992) weisen auf eine weitere soziale Komponente hin, die in der Anwendung in unterschiedlichen Kulturkreisen zu Tage kommt. Dabei wurden signifikante

Varianzen bei einzelnen Emotionen auf den Dimensionen erwartete Anstrengung, Verantwortung / Kontrolle sowie Situationskontrolle von Smith & Ellsworth (1985) festgestellt.

Auch hier kann die Kritik von Pecchinenda (2001) hinsichtlich der empirischen Methode des nachgelagerten Selbstberichts angebracht werden. Dieser ziehe den Prozess einer Emotion nur partiell in Betracht, so dass die resultierenden Dimensionen in Frage gestellt werden können. Die wissenschaftliche Kritik von Tong et al. (2005), dass die theoretischen Konstrukte fernab der Realität überprüft wurden, kommt auch hier zum Tragen. Tangney et al. (1996) führen eine weitere methodische Bemängelung der Studie von Smith & Ellsworth (1985) ins Feld. Diese bezieht sich darauf, dass mit Hinblick auf die schwach ausgeprägten Emotionen Scham und Schuld nur 16 Versuchspersonenbefragungen eruiert wurden.

#### 2.3.1.7.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Die psychologische Valenz wurde nun mehrfach erläutert. Deswegen wird sie an dieser Stelle übersprungen und auf die oben genannten Ausführungen verwiesen. Darüber hinaus wurden auch die Dimension Aufmerksamkeit als Neuigkeit, die Situationskontrolle als Beherrschbarkeit sowie die erwartete Anstrengung anstelle der Zielrelevanz in Kapitel 2.3.1.5.3 und die Sicherheit bzw. Unsicherheit als Eintreffwahrscheinlichkeit in Kapitel 2.3.1.6.3 für die Sentimentanalyse abgehandelt.

Somit bleibt nur die theoretische Auseinandersetzung mit einer einzigen Dimension der Verantwortung bzw. Kontrolle offen. Wie bereits angedeutet, bezieht sich das auf den Grad der Zuordenbarkeit beim Herbeiführen eines Sachverhalts bzw. auf die Möglichkeit der Einflussnahme der Person. Die indirekte Ermittlung über die Analyse der Ursache einer Emotion und deren Bezug zur fühlenden Person mutet ebenfalls schwierig an. In erster Instanz müsste ein Objektbezug hergestellt werden, wie im vorangegangenen Modell bei der Suche des Ursachenbezugspunkts angedeutet. In zweiter Instanz müsste dann in Abhängigkeit davon, ob ein Selbst-, Personen- oder Objektbezug vorliegt, bewertet werden, wie groß die mögliche Einflussnahme ist. Dabei wäre ein Mischmodell zwischen sprachlichen Indizien und psychologischen Modellen mit unterlegten Wahrscheinlichkeiten der Kontrollierbarkeit denkbar.

In der Umsetzung des Modells kann es in der direkten Emotionsbestimmung zu konträren Einschätzungen, bezogen auf Scham, kommen. Die diskrete Form dieser Emotion geht mit einer hohen modellgegebenen Ausprägung der Verantwortungsdimension einher. Aufgrund der Umsetzungskomplexität, der womöglich ungenauen Ergebnisse der übersetzten Theorien in Wahrscheinlichkeiten und der Voraussetzungen an den Text erscheint die indirekte Ermittlung der Emotionen über diese spezielle Achse der Verantwortung und Kontrolle deutlich

schwieriger, als wenn die Emotionen direkt ermittelt werden. Dies wird hier jedoch sentimentanalytisch als Weg der diskreten Kategorisierung der Emotionen bezeichnet.

#### 2.3.1.7.4 Abtragung der Dimensionen

Alle 15 genannten Emotionen sind auf den Achsen abgetragen. Diese sind nicht nur, wie in Tabelle 3 dargestellt, als Ordinalskala zu finden, sondern liegen intervallskaliert für die jeweiligen Achsen vor. Analog wie bei den bisherigen dimensional Verfahren können somit die Achsenausprägungen der Dimensionen indirekt über die Positionen der diskreten Emotionen abgelesen werden.

### 2.3.1.8 Manstead und Tetlock

#### 2.3.1.8.1 Dimensionen und Vollständigkeit

Das Dimensionsmodell beinhaltet die vier Achsen psychologische Valenz („*unpleasantness*“), Fremd- oder Selbstverantwortung („*agency*“), Grad der Erwartbarkeit („*unexpectedness*“) und situativer Grad der Einflussnahme („*situational control*“) (Manstead & Tetlock (1989, S. 234). Die Emotionen Freude („*joy*“), Stolz („*pride*“), Hoffnung („*hope*“), Angst („*anxiety*“), Wut („*anger*“), Scham („*shame*“), Schuld („*guilt*“) und Verlegenheit („*embarrassment*“) werden dabei empirisch verortet (Manstead & Tetlock, 1989, S. 229).

#### 2.3.1.8.2 Modellkritik

Das Modell von Manstead & Tetlock (1989) war als Kritik an die Dimensionsgliederung von Smith & Ellsworth (1985) gedacht, da deren Einteilung eine Unschärfe hinsichtlich der Emotionen Scham und Schuld aufweist. Jedoch ist hervorzuheben, dass eine Vergleichbarkeit nicht gegeben ist, wie die Autoren selbst feststellen (Manstead & Tetlock, 1989). Dies ist insbesondere deswegen der Fall, da nur 8 anstelle von 15 Emotionen als Eingangsgröße vorhanden sind, von denen 2 nicht in der Liste von Smith & Ellsworth (1985) auftauchen. Darüber hinaus wurden 6 Dimensionen nicht in die Auswertung aufgenommen (Manstead & Tetlock, 1989). Es wird an dieser Stelle in Frage gestellt, ob es sich hierbei um eine kritische Auseinandersetzung mit Smith & Ellsworth (1985) handelt oder ob ein eigenständiger, losgelöster Ansatz entwickelt wurde.

Reisenzein & Hofmann (1993) zweifeln die Unterscheidung von Emotionen anhand bewertungsrelevanter Informationen in Situationskontexten an. Sie bekräftigen ihren Kritikpunkt mit den beiden ungeklärten Fragen, ob „*[i]t is more difficult to say [...] how strong this support can be considered to be in an absolute sense [...] and] what the discrimination data tell about the relative merits of the different theory*“ (Reisenzein & Hofmann, 1993, S. 272).

Aufgrund der Herleitung der Emotionsdimensionen anhand eines Fragebogens zur Selbstbeurteilung kann die methodische Herangehensweise angefochten werden, da diese nur zu stereotypisierten Ergebnissen führe (Pecchinenda, 2001). Darüber hinaus ist die Anzahl der Probanden in dieser empirischen Untersuchung mit 20 Teilnehmern gering und kann bei falscher Zusammenstellung der Versuchspersonen zu Verzerrungen führen (Henrich, J. et al., 2010). Tong et al. (2005, S. 508) bemängeln in diesem Zusammenhang, dass ein Selbstbeurteilungsbogen nicht einer realistischen Situation entspreche und dass es einem solchen Model an einer „*ecological validity*“ mangle.

#### 2.3.1.8.3 Realisierbarkeit

Im Gegensatz zu den zuletzt genannten Dimensionsansätzen ist bei diesem Emotionsmodell ein Rückgang der Dimensionen zu verzeichnen. Mit Ausnahme der psychologischen Valenz sind die drei übrigen Dimensionen nur schwer aus einem Text extrahierbar. Dies wurde argumentativ für die Dimensionen Fremd- oder Selbstverantwortung in Kapitel 2.3.1.7.3, Grad der Erwartbarkeit in Kapitel 2.3.1.6.3 und Grad der situativen Einflussnahme in Kapitel erarbeitet. Dort wurde gezeigt, dass diese Ausprägungen nur unter aufwendigem Einbezug persönlicher Präferenzen und des jeweiligen Kontextes in Verbindung mit einer direkten dimensionalen Bestimmung realisiert werden können.

#### 2.3.1.8.4 Abtragung der Dimensionen

Alle acht genannten Emotionen sind auf den vorgeschlagenen Achsen durch empirische Mittelwerte dargestellt. Die Anzahl der diskreten Emotionen weist im Vergleich zur Anzahl der Achsen nur ein Verhältnis von 2:1 auf. Um eine größere Genauigkeit beim indirekten Ansatz zu erzielen, müssen weitere Emotionstypen auf den Achsen theoretisch verortet bzw. empirisch verankert werden.

### 2.3.2 Diskrete Abgrenzung der Emotionen

Wie bereits bei der Einstufung der Anwendbarkeit eines Ansatzes in der Sentimentanalyse bei den dimensionsbasierten Modellen gezeigt, werden die Emotionstheorien hier ebenfalls anhand von Kriterien bemessen. Aufgrund der unterschiedlichen Natur der dimensional und diskreten Forschungsansätze kann hier nicht der gleiche Maßstab angesetzt werden. Die Kriterien wurden daher übernommen oder der Abgrenzung entsprechend adaptiert. Im Wesentlichen werden für Zielkategorien einer Emotionserkennung die Punkte Validität, Anzahl, Vollständigkeit, Balance, existentes Gliederungsschema, Anwendbarkeit auf textuelle Emotionsrepräsentationen und Realisierbarkeit herangezogen.

Die Validität stellt ein zentrales Kriterium dar. Da es jedoch keine allgemeingültige Skala gibt, um zu ermitteln, ob oder zu welchem Grad ein Ansatz valide ist, werden hier, ähnlich wie schon bei der dimensionalen Kategorisierung in Kapitel 2.3.1 näher ausgeführt wurde, der wissenschaftliche Diskurs und die Modellkritik herangezogen.

Die Anzahl sowie die damit verbundene Vollständigkeit der Emotionstypen sind deskriptive Merkmale. Die Anzahl der Emotionsqualitäten ist selbstsprechend. Einzig bei Emotionsmodellen mit mehreren Hierarchiestufen wird auf die letzte kategorische Ebene vor der Ausführung dezidierter Exemplare verwiesen.

Bei neutraler Betrachtung kann hinsichtlich der Vollständigkeit kein Ansatz dem anderen vorgezogen werden. Dieses Kriterium wird somit lediglich relativ definiert. Die Frage, wie viele Emotionen existieren, kann nicht abschließend beantwortet werden, da auch Emotionsforscher zu einer unterschiedlichen Auswahl der Emotionen kommen (vgl. Ortony & Turner, 1990). Die Vollständigkeit wird hier daher so ausgelegt, dass valide nachvollziehbare Kriterien, die in einer oder mehreren Theorien für die Existenz einer solchen Emotion sprechen, aber in einer anderen nicht vorhanden sind, in letzterer als Zeichen der Unvollständigkeit gewertet werden. Es wird hingegen deutlich davon abgerückt, hier ein eigenes Konsensmodell zu bilden, da die Erstellung eines Emotionsmodells nicht Gegenstand dieser Arbeit sein soll.

Mit dem Bewertungskriterium der Balance sei dem theoretischen Kritikpunkt der Unterrepräsentation Rechnung getragen (Fredrickson & Levenson, 1998). Dies ist nicht zwangsläufig falsch, aber ungenau und somit ein möglicher Anhaltspunkt für Unvollständigkeit. Desmet (2012) zeigt, dass viele Emotionstheoretiker nur eine oder zwei differenzierbare positive Emotionen besitzen, wohingegen er bis zu 25 unterschiedliche ausmacht. Unabhängig davon, ob diese Vertreter sprachlich tatsächlich zu differenzieren sind, ist unstrittig, dass eine einzige Emotionskategorie, die all diese positiven Ausprägungen umfassen soll, zu ungenau ist. Eine konkrete Benennung dieser Kategorie kann nicht aussagekräftig sein. Doch obwohl dieses Kriterium die Genauigkeit impliziert, ist es nur ein untergeordnetes Merkmal. Es dient daher als Anhaltspunkt dafür, in welchem Umfang die positiven und negativen Emotionstypen differenziert sind und wie sehr sich das Modell hinsichtlich der Anzahl die Waage hält.

Das Bewertungskriterium der Emotionsstruktur beschreibt, ob ein existentes Gliederungsschema vorhanden ist oder nicht. Die Bandbreite reicht von losgelösten Emotionstypen bis hin zu komplexen Emotionsgerüsten mit gegenseitiger Abhängigkeit. Für die Emotionserkennung sind zwei Punkte relevant. Erstens besteht zwischen den Emotionen eine gegenseitige Abhängigkeit, die beachtet werden muss. Beispielsweise kann eine Emotion nur dann auftreten, wenn ein anderer Emotionszustand als Vorbedingung vorhanden ist. Andererseits kann z. B. das

Eintreten einer Emotion die Existenz einer anderen ausschließen, sei es, dass sich dieses Vermengen oder dass diese nicht gleichzeitig auftreten können. Für die Emotionserkennung bedeutet dies, dass bestimmte Regeln, Bedingungen oder Einschränkungen betrachtet werden müssen. Zweitens existieren zwischen Emotionen Abhängigkeiten, die zusätzlich genutzt werden können. Kann eine Schlussfolgerung über zwei spezielle Emotionen getroffen werden, so dass das Vorhandensein einer dritten Emotion naheliegt? Lässt sich von einer Emotion auf den Kontext oder andersherum schließen und sollte dieser als Merkmal genutzt werden?

Die Realisierbarkeit sagt aus, ob das jeweilige Emotionsmodell mittels der Emotionserkennung umgesetzt werden kann. Auf argumentative Weise soll für die Emotionstheorien jeweils erarbeitet werden, ob die gegebenen Emotionen im Text bestimmbar sind. Dabei soll das generelle Vorkommen eines Emotionszustands im Text genauso erwogen werden wie der Komplexitätsgrad der zu bestimmenden Emotion. Dieses Kriterium berücksichtigt, wie schon beim dimensionalen Ansatz, Abhängigkeitsverhältnisse und Rahmenparameter. Darüber hinaus sollen Diskrepanzen einer möglichen Umsetzung hervorgehoben werden.

Textuelle Emotionsrepräsentationen als Bewertungskriterium stellen einen Nebenaspekt der Sentimentanalyse dar. Dies bezieht sich darauf, ob Beispielterme für Emotionsqualitäten gegeben sind, oder ob lediglich ein Oberbegriff für die Emotion besteht. Aus praktischen Gesichtspunkten ist es für lexikonbasierte Ansätze der Emotionserkennung von Vorteil, wenn Schlüsselwörter vorhanden sind. Falls keine exemplarischen Schlüsselwortausführungen existieren, müssen diese für die Emotionserkennung erarbeitet werden. Das kann abhängig vom Ersteller zu nicht eindeutigen bzw. reproduzierbaren Ergebnissen führen, je nachdem, welches subjektive Verständnis oder welche emotionstheoretischen Komponenten einfließen. Wenn gleich dieser Aspekt für die Sentimentanalyse als optional angesehen werden kann, ergibt sich, wie bereits ausgeführt, ein gewisser Vorteil aus der Existenz exemplarischer Emotionsterme.

### **2.3.2.1 Gray**

#### **2.3.2.1.1 Diskrete Emotionen, Vollständigkeit und Balance**

Gray (1990), der in die evolutionspsychologische Forschungsrichtung einzureihen ist, führt Emotionen auf drei grundlegende kognitive Systeme zurück: das *Behavioural-Approach-System (BAS)*, das *Fight-Flight-Freezing-System (FFFS)* und das *Behavioural-Inhibition-System (BIS)* (Gray & MacNaughton, 2003, S. 86). Ortony & Turner (1990) stellten bei Gray (1982) im Speziellen die vier Gefühlszustände Wut („*rage*“), Schrecken („*terror*“), Angst („*anxiety*“) und Freude („*joy*“) als neurologisch fest verankerte Emotionen in den Vordergrund.

Bei aktuellen neurobiologischen Ansätzen ist es schwierig, viele Emotionszustände zu differenzieren. Für die Verwendung in der Sentimentanalyse bietet dies noch zu wenig Tiefgang. Somit entstehen eine geringe Bandbreite und eine deutliche Ungleichverteilung der positiven und negativen Emotionen. Die vier genannten Emotionen werden weder weiter aufgefächert, noch bilden sie ein vollständiges Spektrum der Emotionen in der Kommunikation ab.

#### 2.3.2.1.2 Modellkritik

Pickering & Corr (2008, S. 239) heben die wissenschaftliche Persistenz dieser Theorie hervor und zeigen auf, dass sie aufgrund gewonnener Erkenntnisse im Bereich der Neurobiologie „*significant modifications of, and additions to, its superstructure*“ durchlaufen hat. Hauptsächlich wurde die nun neu getaufte *Reinforcement-Sensitivity-Theory (RST)* hinsichtlich der gegenseitigen Abhängigkeiten angepasst. Der gültige Charakter dieses Ansatzes wird hervorgehoben. Die Theorie, dass Emotionen mit bestimmten Gehirnarealen verknüpft sind, findet auch unter Emotionsforschern und Psychologen breiten Zuspruch (Davidson, Ekman, Saron, Senulis & Friesen, 1990).

Jedoch ist kritisch anzumerken, dass laut Pickering & Corr (2008) in der überarbeiteten Theorie neben den oben genannten neuronalen Systemen grundsätzlich Muster von Persönlichkeitsstrukturen im Fokus stehen. Emotionale Reaktionen basieren zwar auf den typischen Charakterzügen einer Person, aber „*[t]here remains some considerable uncertainty as the best way to relate fundamental systems of emotion and motivation to personality factors*“ (Pickering & Corr, 2008, S. 253). Letzteres findet sich literarisch auch an anderer Stelle, wenngleich anders formuliert (beispielsweise Corr & McNaughton, 2015; Gray & MacNaughton, 2003).

#### 2.3.2.1.3 Realisierbarkeit

Da die Realisierbarkeit durch direktes Ablesen der Emotion bzw. durch das Erkennen einer entsprechenden Phrase für alle diskreten Modelle vergleichbar ist, werden einmal erläuterte Aspekte der Realisierbarkeit nicht jedes Mal wiederholt. Stattdessen wird jeweils nur punktuell auf bisher nicht vorgestellte Zustände mit schwierigen Abgrenzungsfällen eingegangen.

Die in diesem Modell vorliegenden Emotionen Wut, Schrecken, Angst und Freude sind in ihrer sprachlichen Bedeutung deckungsgleich zur wissenschaftlichen Definition. Realisierungsschwierigkeiten werden in der schriftlichen Unterscheidung zwischen Schrecken und Angst erwartet, da ersterem eine gewisse affektive Reaktion anhaftet. Dies wird insofern bei einer Emotionserkennung als problematisch angesehen, da die textuelle Verarbeitung eines Schreckens nicht mit einer Reflexion und einem langsamen Schreibvorgang einhergeht.

## 2.3.2.2 McDougall

### 2.3.2.2.1 Diskrete Emotionen und Vollständigkeit

Die sieben Primäremotionen nach McDougall (1926) entsprechen den emotionalen Tendenzen und Impulsen, die den urtypischen Instinkten des Menschen entspringen. Die Emotionen sind Angst („*fear*“, S. 52), Ekel („*disgust*“, S. 58), Erstaunen („*Wonder*“, S. 59), Wut („*anger*“, S. 62), Zärtlichkeit („*tender*“, S. 68) Unterwerfung („*subjection*“, S. 64) und freudige Erregung („*elation*“, S. 64). Dem gegenüber stehen die komplexen Emotionen, deren Komponenten aus mindestens zwei Primäremotionen bestehen. Vertreter der komplexen Emotionen sind z. B. Ehrfurcht („*awe*“, S. 57), Verehrung („*reverence*“, S. 57) oder Neid („*jealousy*“, S. 86). Emotionale Zustände werden von der Gefühlsqualifikation „*joyful*“ für positiv gerichtete oder „*sorrowful*“ für negativ gerichtete Emotionen begleitet (McDougall, 1926, S. 50).

Dieses Modell besitzt mit sieben Basisemotionen und zusätzlichen Sekundäremotionen eine große Bandbreite an Emotionszuständen. Jedoch tauchen Emotionsqualitäten auf, die aus neueren Ansätzen verschwunden sind bzw. nicht mehr berücksichtigt werden. Das Modell weist einen deutlichen Überhang an negativen Emotionen auf. Darüber hinaus kann positiv hervorgehoben werden, dass dieser Kategorisierungsansatz mit *joyful* und *sorrowful* eine übergeordnete Stufe der Gefühlsqualitäten einführt, obgleich es dieser aufgrund der Vermengung an Trennschärfe fehlt.

### 2.3.2.2.2 Modellkritik

Meyer, Schützwohl & Reisenzein (2003) fassen zwei wesentliche Kritikpunkte hinsichtlich der Instinktlehre zusammen. Ersten wird angezweifelt, dass instinktgesteuerte Handlungsimpulse auf verborgenen kognitiven Prozesse fußen, die sich einer Beobachtung entziehen. Zweitens ist umstritten, ob Instinkte nicht nur im Tierreich, sondern auch beim menschlichen Verhalten in einer so gewichtigen Art und Weise wie bei Tieren Anwendung finden. Letzteres begründen sie damit, dass „Verhaltensklärungen durch Instinkte – so die Kritiker – [...] häufig (epistemisch) zirkulär“ sind (ebenda S. 140).

Eine neuere, allgemeine Kritik richtet sich insbesondere an die Basisemotionen. Die Existenz von Primäremotionen und daraus ableitbaren Sekundäremotionen, die durch Vermengung oder Kombination ersterer entstehen, wird generell in Frage gestellt (Barrett, 2006; Ortony & Turner, 1990). Auch die Auflösung von Basisemotionen in sekundäre oder weiterführende Emotionen ist umstritten (Wirtz, 2017). Als Kritikpunkt wird ebenfalls ins Feld gebracht, dass es nach über einem Jahrhundert noch keine Einigung über die Anzahl bzw. korrekte Auswahl der Basisemotionen gibt (Schirmer, 2015).

### 2.3.2.2.3 Realisierbarkeit

Die zugrunde liegende Einteilung *joyful* und *sorrowful* könnte hinsichtlich der Realisierung als Textfilterkriterium verwendet werden. Mögliche Texte ließen sich demnach im Vorfeld anhand einer Polaritätserkennung trennen und nachgelagert separat klassifizieren. Die gleiche Prozedur kann auch bei der Vorauswahl der zu annotierenden Texten angewendet werden, um beispielsweise neutrale Textpassagen von vornherein auszuschließen.

Es wird hier jedoch in Frage gestellt, ob sich die instinktbasierten Reaktionen wie Unterwerfung oder Zärtlichkeit auf alle textuelle Repräsentationen anwenden lassen. Besonders die zuerst genannte Gefühlsqualität wird vermutlich nur in wenigen und einschlägige Texten vorkommen. Auch für die elternbezogene Zärtlichkeit müsste auf eine dezidierte Literatur oder spezielle Internetforen zurückgegriffen werden. Diese Emotionen stellen daher Hürden bei einer vollumfänglichen Abbildung dieses Emotionsmodells dar.

### 2.3.2.3 Plutchik

#### 2.3.2.3.1 Diskrete Emotionen und Vollständigkeit

Eine vielschichtige Emotionstheorie, die auf die evolutionäre Entwicklung der Emotionen zurückgeht, stammt von Plutchik (1984, 2001). Eine dimensionale Emotionsdifferenzierung kann in Betracht gezogen werden, da sich die Elementaremotionen auf vier gegensätzlichen Emotionspaaren abbilden lassen (Plutchik, 1984). Alle Zustände erhalten durch die Intensitätsabstufung einen dimensional Charakter. Damit lassen sich die Emotionen weiter aufgliedern und es entstehen zwischen den Hauptachsen weitere diskrete Ausprägungen. Emotionen nach Plutchik entstehen kaum in ihrem idealisierten Grundzustand, sondern konstruieren sich aus einer Mischung oder Ableitung der Emotionszustände (Plutchik, 2001; Weitz, 2013).

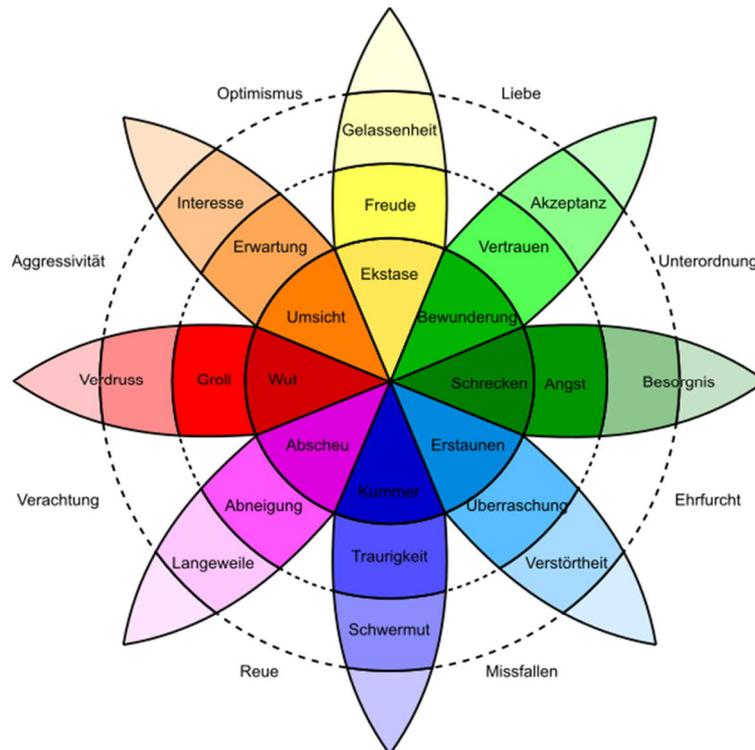


Abbildung 9: Plutchiks Emotionsmodell (angelehnt an Plutchik, 1984)

Hinsichtlich der Vollständigkeit deckt dieses Emotionsmodell eine weite Bandbreite an Emotionszuständen ab. Durch die Vermengung der Emotionen entsteht eine große Vielfalt. Von Vorteil ist, dass die Ausprägungen relativ gleichmäßig positiv und negativ verteilt sind.

### 2.3.2.3.2 Modellkritik

Dieses Modell erntete aus verschiedenen Gründen ein erhebliches Maß an Kritik. Neben dem allgemeinen Vorwurf des fehlenden empirischen Unterbaus (Meyer et al., 2003) wird vor allem seine kategorische Einordnung der Emotionen bemängelt. Seine Vorschläge zur Kombination der Emotionen, sofern diese Gefühlszustände im Kreis der Emotionen aus Abbildung 9 nebeneinander verortet sind, sind nicht unproblematisch, wie beispielsweise Ortony & Turner (1990) herausstellten. Dies machen sie an der Diskrepanz zwischen dem Modell und der Wirklichkeit aus. Denn für manche abgeleiteten Emotionspaare lassen sich nur schwerfällig oder gar keine Entsprechungen in der Wirklichkeit finden.

Der selbstaufgelegte Anspruch, sich in die Evolutionspsychologie einzuordnen, wird in der Literatur angezweifelt. Euler (2000) bringt dies sehr drastisch auf den Punkt, indem er klarstellt, dass „[Plutchiks] Modell einen Rückfall auf scholastische Vorstellungen dar[stellt], bei denen die Konstruktionsästhetik im Vordergrund steht, was dem historischen Prinzip der Evolution zuwiderläuft“ oder indem er Plutchik eine „unzureichende Berücksichtigung der neodarwinischen Weiterentwicklungen der Evolutionstheorie seit den 60er-Jahren“ vorwirft. Ulich (1982)

fechtet nicht nur Plutchiks (1962, 1980) ursprüngliche Idee der evolutionären Kontinuität an, nach der Menschen und Tiere einen gemeinsamen Fundus an Emotionen haben, sondern zerpfückt seinen Kategorisierungsversuch mit folgendem Zitat: „Wohl nirgendwo sonst in der Emotionspsychologie zeigt sich soviel Hilflosigkeit wie in diesem verkrampften Versuch von Plutchik, die ‚Natur‘ von Emotionen zu bestimmen und daraus deren ‚Funktion‘ in konkreten Handlungsabläufen abzuleiten.“ (Ulich, 1982, S. 128)

Der Ansatz erfreut sich großer Beliebtheit. Er scheint viele psychologischer Grundgedanken unterschiedlicher Strömungen in Einklang zu bringen. Dennoch bleibt festzuhalten, dass sein theoretisches Modell und die strukturelle Zusammenstellung nicht unumstritten sind.

#### 2.3.2.3.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Wie schon in den vorangegangenen Kapiteln können alle Konzepte der hier verwendeten diskreten Emotionen anhand der im Sprachgebrauch üblichen Definitionen nachvollzogen werden. Durch die Vielzahl der verwendeten Emotionsbegriffe entstehen jedoch Schwierigkeiten der korrekten Differenzierung. Dies trifft insbesondere auf die unterschiedlich starken Emotionspaare Wut-Groll, Abscheu-Abneigung, Kummer-Traurigkeit, Erstaunen-Überraschung und Schrecken-Angst zu. Eine feinere Einteilung ist generell positiv zu bewerten, jedoch erhöht dies aufgrund der fehlenden Trennschärfe den Schwierigkeitsgrad bei Annotationen. Begründet wird dies damit, dass bei einer manuellen Textklassifikation durch den Menschen nicht zwischen zwei gänzlich andersartigen Gefühlsqualitäten unterschieden werden muss, sondern zwischen feinen Nuancen innerhalb einer Klasse.

Durch das theoretische Modell bedingt, ist für die Sentimentanalyse auch die Berücksichtigung von Textintensivierungen wichtig. Letzteres ist kein triviales Unterfangen. In der Umsetzung ist dies schwierig, da sich die Intensität nicht nur in unterschiedlichen Termen, adverbialen Konstruktionen oder Steigerungsformen verbirgt (Kennedy & Inkpen, 2006; Polanyi & Zaenen, 2006; Tromp, 2012). In der Realisierung wird die Intensität daher als das größte Hindernis für eine valide und robuste Textklassifikation gesehen.

Durch die theoretische Modellgestaltung ist die Verneinung von Emotionen geregelt. Dies bedeutet, dass mit den vorliegenden Gegenpaaren unter Berücksichtigung der Negation gearbeitet werden kann. Wird ein Emotionswort negiert, so kann man sich bei der Emotion der gegenüberliegenden Seite bedienen. Dies setzt jedoch ebenfalls eine Berücksichtigung einer Intensivierung bzw. Abschwächung in Verbindung mit einer Emotion voraus, wie in dem Beispielsatz „sie ist nicht wirklich an ihm interessiert“ deutlich wird.

Der Gebrauch von kontrastierenden Emotionspaaren ist nicht unproblematisch, denn auf die gegenüberliegenden Kategorien ist die Negation nicht bedingungslos anwendbar. Beispielsweise ist die Nachvollziehbarkeit der Negation von Wut als Gegenteil von Schrecken nicht selbsterklärend. Das Gleiche gilt für das Kontinuum zwischen Umsicht und Erstaunen, bei denen die Gegenteile der beiden Emotionsterme naheliegend auf keines der gegebenen Ausprägungen der gegenüberliegenden Emotion mit dimensionaler Ausprägung anzuwenden sind. Einerseits kehrt sich die Polarität um, wie bei dem Kontinuum Ekstase und Kummer oder bei Bewunderung und Abscheu, andererseits bleibt die Polarität der Emotionen negativ, wie bei dem genannten Beispiel des Kontinuums zwischen Wut und Schrecken. Dieser vermeintliche Aspekt ist widersprüchlich zu gängigen Sentimentanalysemodellen der Polaritätserkennung. Um eine Aussage über eine negierte Emotion treffen zu können, bedarf es einer empirischen Untersuchung. Unter der Annahme, dass das Modell beispielsweise in einem Punkt der negierten Emotionen falsch liegt, entstehen bereits Verzerrungen, die die Güte des Modells trotz theoriekonformer Anwendung negativ beeinflussen. Ein theoretisches Konstrukt mit korrekten Negationspaaren würde einen deutlichen Mehrwert liefern, aber mit falscher Auslegung der Gegenpole ebensoviel Schaden anrichten.

Das Modell wirft hinsichtlich der Anwendung einige inhaltliche Fragen auf, was die Zusammenstellung der einzelnen Emotionsausprägungen bezüglich der Intensität angeht. Beispielsweise ist unklar, wie sich eine gesteigerte Zerstreutheit bzw. Verstörtheit zu Überraschung entwickeln soll. Eine sehr deutliche Ausprägung einer Emotion führt demnach nicht zwangsläufig dazu, dass die intensivere Version nach Plutchik gewählt werden kann.

Betrachtet man, entgegen der ursprünglichen Idee von Plutchik, die vier gegenüberliegenden Emotionen als Kategorien, so könnten die über die Intensitätsdimension abgebildeten Emotionen als exemplarische Ausprägungen gesehen werden. Damit wären zusätzlich zu den Bezeichnungen weitere Beispieltoken für die repräsentativen Kategorien vorhanden. Die Abstufung durch die Intensitätsdimension gibt mehrere Nuancen der Ergebnisskalierung vor. Diese müssten somit nicht mehr definiert, ermittelt und in Stufen eingeteilt werden. Darüber hinaus wäre es gegebenenfalls möglich, die Nivellierung der Elementaremotionen zur Aggregation der Emotionen einzelner Wörter, bezogen auf den ganzen Text, zu nutzen.

Wie bereits in der Kritik angeklungen, ist die Vermischung der Grundemotionen nicht unproblematisch. Es ist nicht zweifelsfrei ersichtlich, wie sich beispielsweise der Zustand der Aggressivität aus Umsicht und Wut bzw. einer der Ausprägungen der zwei Kategorien bilden soll, geschweige denn, wie sich dies sprachanalytisch abbilden ließe. Es stellt sich die Frage, ob beispielsweise zwei gleichzeitig auftretende Emotionen wie Verdruss und Gelassenheit zu

Interesse vermengt werden dürfen, da diese Emotion zwischen den beiden liegt. Es wird hier konstatiert, dass bei diesem Modell der Umgang mit mehreren Emotionen in einem Text mehr Fragen aufwirft, als beantwortet werden.

#### 2.3.2.3.4 Anwendbarkeit auf dimensionales Modelle

Der theoretische Ansatz ist eine geschickte Gratwanderung zwischen diskreter und dimensionaler Abgrenzung der Emotionen. Durch diese synthetische Gestaltung kann das Modell auch einfach als dimensionales Emotionsmodell überführt werden. Poria, Cambria, Winterstein & Huang (2014) machen sich die Differenziale des Modells zu eigen und nutzen diese als vier inhaltliche Dimensionen. Die diskreten Dimensionen sind entsprechend der Intensität auf den Achsen verortet. Die Bestimmung der Ausprägung der Dimensionen erfolgt mit einem Klassifikator je Emotionsachse.

#### 2.3.2.3.5 In Verwendung

Das Modell von Plutchik ist die Grundlage für SenticNet (Cambria, Poria, Bajpai & Schuller, 2016). Dies ist jedoch, wie bereits angesprochen, als dimensionales Modell realisiert (Poria et al., 2014). Dieses Modell erfreut sich in der Praxis bei Firmen, die auf dem Sentiment Analysis Symposium vertreten sind, großer Beliebtheit.

### 2.3.2.4 Panksepp

#### 2.3.2.4.1 Diskrete Emotionen, Vollständigkeit und Balance

Im Modell von Panksepp (1998) wurden sieben Emotionen und die zugehörigen neuronalen Areale identifiziert. Die Zustände sind „Generelle Motivation / Erwartung“, „Wut“, „Angst“, „Lust / Sexualität“, „Fürsorge / Pflege“, „Panik durch Isolation“ und „Spiel / Freude“ (Panksepp & Panksepp, 2013; Pritzel, Brand & Markowitsch, 2003, S. 394).

Bedingt durch die Herangehensweise, deckt das Modell nur einen Bruchteil der relevanten Emotionen für eine textuelle Analyse ab. Andererseits finden sich hier Emotionen, die andere Forscher und Modelle außen vorlassen. Es ist ebenfalls positiv anzumerken, dass die hier genannten Basisemotionen bei neutraler Auslegung der Emotion des Suchens bzw. des Gefühlszustands der Erwartung ebenso viele positive wie negative Kategorien aufweisen.

#### 2.3.2.4.2 Modellkritik

Barrett (2006) gibt zu bedenken, dass es kein singuläres Zentrum für die jeweiligen Emotionsqualitäten gibt. Sie wendet außerdem ein, dass sich Gefühlszustände von Mensch zu Mensch unterscheiden, weswegen keine eindeutige neuronale Signatur existiert. Zumal es

Überlappungen zwischen den einzelnen postulierten Emotionsregionen gibt, wie Shi (2012) anmerkt, weswegen eine Überprüfung seiner Theorie der neurochemischen Prozesse kaum möglich ist. Eine Emotionskategorisierung aus dieser Basis auszubauen ist folglich wenig zielführend.

Barrett et al. (2007, S. 4) behaupten außerdem, dass *„evidence for coherently organized neural circuits for emotional behaviors in the mammalian brain is more suggestive than convincing“*. Als Argument führen sie ins Feld, dass sich Panksepp (2007) in seiner Beweisführung der Existenz der primären Emotionen auf Denton (2006) stützt, obschon der Beitrag dieses Autors lediglich konzeptioneller Natur sei und es somit an empirischem Fundament fehle. Darüber hinaus argumentieren sie, dass es haltlos sei, wenn man Behauptungen über Emotionskonstrukte aufstellt, *„that have been already disconfirmed by published scientific evidence“* (Barrett et al., 2007, S. 305).

Panksepps (2007) empirische Versuche stützen sich auf Tests mit Labortieren. Allerdings ist in der einschlägigen Forschung umstritten, ob sich die Emotionen von Menschen von denen anderer Säugetiere unterscheiden (Barrett et al., 2007; Blanchard & Blanchard, 2003). Andere Forscher geben zu bedenken, dass generell angezweifelt wird, ob Tiere, einschließlich Säugern, überhaupt Emotionen haben können. Analogien mit dem menschlichen Empfinden stehen somit auf einem wackligen Fundament (Shi, 2012).

#### 2.3.2.4.3 Realisierbarkeit

Nicht alle Emotionen dieser Theorie sind für die Textanalyse verwendbar. Die Gliederungsaspekte des Modells kommen nur in einschlägigen Texten oder Fachliteratur vor. In der geschriebenen Sprache sind sie nur bedingt anwendbar, weswegen viele Kategorien, die mit anderen Emotionsmodellen klassifiziert werden könnten, hier ins Leere laufen. Letzteres wird damit begründet, dass der vorgeschlagene Zustand Panik mit dem Ziel der Überlebenssicherung textuell so selten anzutreffen ist, dass er aufgrund des Fehlens möglicher Trainingsdaten für eine computerlinguistische Analyse gänzlich ungeeignet ist. Ebenso wird angenommen, dass mütterliche Fürsorge oder Fürsorge allgemein nur zu einem geringen Teil in allgemeinen Texten zu finden sind. Auch die Sekundäremotion der sexuellen Lust ist in der Gesellschaft tabuisiert und daher nur in einschlägigen Textsorten zu finden. Ausführungen darüber unterliegen einer persönlichen Hemmschwelle und sind in üblichen Datenquellen der Sentimentanalyse in den meisten Fällen unerwünscht. Dahingegen muss die von den bisher vorgestellten Autoren postulierte Freude über die Emotionsqualität der Verspieltheit abgebildet werden, was einer dezidierten Ausprägung entspräche. Anders sieht die Realisierbarkeit hingegen mit der

Emotion der Erwartung bzw. des Suchens aus. Sowohl die eine als auch die andere Version dieser Emotion existieren in der schriftlichen Kommunikation.

#### 2.3.2.4.4 In Verwendung

Der Vorteil des Modells von Panksepp ist, dass die Theorie im Bereich Marketing in der Praxis verwendet wird. Damit sind zahlreiche Interpretationsversuche und Anwendungsfelder verknüpft (beispielsweise Bruhn, 2011).

### 2.3.2.5 Tomkins

#### 2.3.2.5.1 Diskrete Emotionen und Vollständigkeit

Tomkins (1962, 1963) vertritt neben den Grundemotionen auch die Annahme, dass sich Nicht-Basisemotionen daraus bilden lassen (Tomkins, 1970). Tomkins (1984) Grundemotionen setzen sich zusammen aus Wut („*anger*“, S. 176), Interesse („*interest*“, S. 171 f.), Verachtung („*contempt*“, S. 180), Ekel („*disgust*“, S. 180), Bedrängnis bzw. Elend („*distress*“, S. 174), Angst („*fear*“, S. 174), Freude („*enjoyment*“, S. 187), Scham („*shame*“, S. 180) und Überraschung („*surprise*“, S. 171).

Um den Punkt der Vollständigkeit aufzugreifen, bietet dieses Modell im Vergleich zu den zuvor genannten Ansätzen ein noch differenzierteres Bild. Jedoch sei anzumerken, dass die nun schon mehrfach erwähnte Trauer in diesem Ansatz nicht vorhanden ist. Die Emotion, die hier mit Bedrängnis oder Elend übersetzt wurde, ist der Gefühlszustand, der dieser am nächsten kommt. Auch bei diesem Modell findet sich ein deutlicher Überhang der negativen Emotionen, da nur zwei positive Zustände vorhanden sind.

#### 2.3.2.5.2 Modellkritik

Für die Herangehensweise spricht, dass es viele Übereinstimmungen mit mimischen Entsprechungen der Grundemotionen gibt, wie beispielsweise Angst, Ärger, Ekel, Freude, Überraschung, Trauer oder Verzweiflung. Diese sind sowohl in einem empirischen interkulturellen Vergleich wiederzufinden, als auch bei frühkindlichen Entwicklungsphasen des Menschen (z.B. Demos, 1982; Izard, 1991).

Als Kritik ergeben sich die Einwände, die allen Emotionstheorien entgegengebracht werden, die die Lehren der Primäremotionen aus der menschlichen Mimik extrahieren. Kraut & Johnston (1979) kritisierten, dass mimisches Verhalten nicht notwendigerweise mit Emotionen einhergehe. So ist Lächeln ihren Erkenntnissen nach nicht zwangsläufig ein Zeichen des Wohlbefindens oder der inneren Freude, sondern auch ein Kommunikationsmittel und wird häufig als soziales Signal verwendet. Nicht nur das Ausbleiben eines Gefühls bei einer mimischen

Ausdrucksweise, sondern auch das subjektive Wahrnehmen einer Emotion ohne Veränderung der Gesichtsmuskeln kann stattfinden. Dies kann als zweiter Kritikpunkt an der grundsätzlichen gedanklichen Verknüpfung von Emotionen und Mimik herangezogen werden. Gegen eine triviale Vermengung der Basisemotionen im hier genannten Sinne spricht auch, dass es für viele Emotionen keinen eindeutig entsprechenden Gesichtsausdruck und keine textuellen Emotionsmarker gibt, wie beispielsweise Neid (Jahr, 2000).

Emotionen äußern sich nicht ausschließlich über Gesichtsausdrücke. Darüber hinaus wird bei dieser Methodik ein Großteil der natürlichen Veränderungsvariationen in der Gesichtsmuskulatur als nicht emotional eingestuft und folglich nicht berücksichtigt. Häusel (2010, S. 43) drückt dies noch drastischer aus, indem er konstatiert: „Aus dem Vorhandensein von Gesichtsausdrücken ein vollständiges Emotionsprogramm abzuleiten und nur Emotionen (genauer Gefühle) aufzunehmen, die mit einem Gesichtsausdruck verbunden sind, ist theoretisch nicht zu rechtfertigen.“ Ferner kritisieren Russell, J. & Fernández-Dols (1997), dass gesellschaftsübergreifende Manifestationen der Gesichtsausdrücke in Studien unterrepräsentiert sind oder fehlen. Eine Ausnahme diesbezüglich stellen beispielsweise die Untersuchungen von Ekman & Friesen (1971) oder Izard (1982, 1994) dar.

Neben dem Für und Wider der Diskussion, ob die Mimik als Grundlage für die Bestimmung der Emotionen herangezogen werden kann oder nicht, muss eingeräumt werden, dass angesichts der empirischen Beweise beispielsweise der noch folgenden Autoren Izard (1991) und Ekman (2005) vieles dafür spricht. Jedoch bleibt der Zweifel, ob dadurch alle emotionalen Zustände abbildbar sind und ob sich daraus Sekundäremotionen ableiten lassen.

#### 2.3.2.5.3 Realisierbarkeit

Die in diesem Modell verwendeten Emotionen sind selbsterklärend und werden darüber hinaus mit Gesichtsausdrücken untermalt. Daher ist der Ansatz ebenfalls für die menschliche Annotation geeignet. Differenzierungsschwierigkeiten werden hingegen bei den Emotionen Ekel und Verachtung bzw. Bedrängnis und Angst erwartet. Die beiden zuerst genannten Emotionen deuten eine Abneigung an, jedoch bezieht sich die Abneigung einerseits gegen Objekte wie Nahrung und andererseits gegen andere Personen. Die minimalen Unterschiede zwischen den Aussagen „er findet es eklig“ und „er findet sie eklig“ verdeutlichen die Tragweite der inhaltlichen Gratwanderung. Durch diesen emotionstheoretischen Genauigkeitsgewinn werden in der Sentimentklassifikation und der Annotation neue Fallstricke aufgestellt. Gleiches gilt für die inhaltlich nahegelegenen Emotionen Angst und Bedrängnis. Auch wenn Überraschung

emotionstheoretisch kritisch beäugt wird (Ortony & Turner, 1990), werden für die Sentimentanalyse keine größeren Komplikationen erwartet.

Neben den textuellen Markern der Emotionserkennung liegt bei Modellen, die auf Gesichtsabdrücken basieren, die Verwendung von Emoticons nahe. Dem Argument, dass die Gesichtsausdrücke nur einen Bruchteil der sprachlichen Emotionen abdecken, kann entgegnet werden, dass Gesichtsausdrücke bereits im informellen Schriftsystem existieren. Bei Emoticons, einer gezielten Aneinanderreihung von Sonderzeichen und Buchstaben, werden die gemischten Ausdrücke in Zeichenform abgebildet (Rojas, Kirschenmann & Wolpers, 2012). Die Entsprechungen des menschlichen Gesichts sind insbesondere im geschriebenen Zeichensatz der Onlinekommunikation vorhanden. Gesichtsausdrücke und die damit verbundenen Emotionen finden in der schriftlichen Sprache Anwendung und ihnen wohnt eine semantische Bedeutung inne (Hogenboom et al., 2013; Liu, K.-L., Li & Guo, 2012; Rojas et al., 2012).

#### 2.3.2.5.4 Anwendbarkeit auf dimensionale Modelle

Lövheim (2012) erstellte ein auf dieser Theorie fußendes dreidimensionales Emotionsmodell. Dieses postulierte er auf dem Zusammenhang zwischen Emotionen und dem Hormonspiegel der drei Hormone Serotonin, Dopamin sowie Noradrenalin. Jeder dieser Zustände wird mit diskreten Emotion von Tomkins (1984) verbunden, wobei die Intensität insofern vernachlässigt wird, als sich bis zu zwei der drei Ausprägungen nach Tomkins (1984) in dem Eckpunkt des dreidimensionalen Modells überlagern. Jedoch fehlt auch dem Ansatz von Lövheim (2012) bisher eine empirische Bestätigung, da er selbst einräumt, dass Feldstudien benötigt werden, um die Validität dieses Modells zu untermauern.

### 2.3.2.6 Ekman

#### 2.3.2.6.1 Diskrete Emotionen und Vollständigkeit

Tomkins Schüler Ekman (2005) leitete seine Theorie der Emotionen ebenfalls aus Gesichtsausdrücken ab. Sein Ansatz ist auch in der Basisemotionstheorie zu verorten (Ekman, 1992). Ekman & Friesen (1971, S. 127) beschreiben sechs unterschiedlichen Primäremotionen – Freude („*happiness*“), Überraschung („*surprise*“), Wut („*anger*“), Trauer („*sadness*“), Ekel („*disgust / contempt*“) und Angst („*fear*“) –, die sie kulturübergreifend bestätigt fanden. Diese Primäremotionen können auch in Kombination auftreten, was zu komplexeren Sekundäremotionen führt, die jedoch nicht näher ausgeführt werden.

Sowohl die Vollständigkeit als auch die Balance sind durch die Undifferenziertheit der Freude und die geringe Anzahl an Emotionen zu kurz gefasst (Häusel, 2010). Mit Ausnahme

der Überraschung, deren Polarität nicht klar bestimmbar ist (Ortony & Turner, 1990), ist Freude die einzig positive Emotion im Modell, weswegen Häusel (2010) dies als unzureichend differenziert sieht. Dies deutet nach den hier aufgestellten Bewertungskriterien auf eine fehlende Balance hin. Mit nur sechs Emotionen reiht sich dieser Ansatz im Vergleich mit den anderen hier angeführten diskreten Emotionsmodellen im hinteren Drittel ein.

#### 2.3.2.6.2 Modellkritik

Sauter, Eisner, Ekman & Scott (2010) räumen ein, dass Emotionen überspielt oder durch Lautäußerung zum Ausdruck gebracht werden können, wodurch ein neutraler oder ein anderer Gesichtsausdruck verwendet wird. Dies kann auch genutzt werden, um den subjektiven Gefühlszustand nicht nach außen dringen zu lassen bzw. eine vorgetäuschte Freude oder ein Maskieren eines negativen Gefühlszustands zu erreichen. Wie bereit im vorangegangenen Kapitel gibt es hier einen wissenschaftlichen Diskurs gegen die reine Fokussierung auf Gesichtsausdrücke basierende Emotionen (Barrett, 2006; Ortony & Turner, 1990).

Gesichtsausdrücke und die damit verbundenen Emotionen sind sprachunabhängig. Dies lässt sich z. B. durch kulturübergreifende Studien (Schirmer, 2015), frühkindliche Entwicklungen (Izard, 1982) oder durch äquivalente Züge bei blinden Personen belegen (Matsumoto & Willingham, 2009). Andererseits gibt es nicht für alle gesichtsspezifischen Emotionen lexikalische Repräsentationen in allen Sprachen, wie beispielsweise das Fehlen des Emotionskonzepts Ärger bei den Inuit (Briggs, 1975). Dessen ungeachtet gibt es zumindest im deutschen Sprachgebrauch für alle mimischen Ausdrücke lexikalische Begrifflichkeiten.

#### 2.3.2.6.3 Realisierbarkeit

Alle von Ekman im Modell inkludierten Emotionen wurden bereits im vorangegangenen Kapiteln der diskreten Emotionen abgehandelt. Alle Emotionen sind, mit Hinblick auf die geringe Anzahl, klar differenzierbar und können folglich ohne größere Schwierigkeiten annotiert werden. Da dieser Ansatz ebenso wie der vorangehende von Tomkins auf Gesichtsausdrücken basiert, liegt ebenfalls die Anwendung von Emoticons nahe. Auch in dieser Hinsicht wird auf das obige Kapitel verwiesen.

### **2.3.2.7 Izard**

#### 2.3.2.7.1 Diskrete Emotionen, Vollständigkeit, Balance und Gliederungsschema

Laut Izard (1991) ist eine Palette an Basisemotionen bereits von Geburt an vorhanden oder entwickelt sich in den ersten Monaten. Die Gefühlstogenese, also die biologische Verankerung einer Grundmenge an Gefühlszuständen, wird als Argument dafür genommen, dass es

sogenannte fundamentale Emotionen gibt, die auf einige wenige beschränkt werden können (Izard, 1990). Während Ortony & Turner (1990, S. 316) die zehn Emotionen Ärger („*anger*“), Verachtung („*contempt*“), Ekel („*disgust*“), Kummer („*distress*“), Angst („*fear*“), Schuld („*guilt*“), Interesse („*interest*“), Freude („*joy*“), Scham („*shame*“) und Überraschung („*surprise*“) herausarbeiten, listet Izard (1991) in einem zeitlich nachgelagerten Werk nur eine kleinere Auswahl von acht Emotionen als fundamental. Wiederrum später wird wieder auf die von Ortony & Turner (1990) herausgestellte Liste von zehn Emotionen verwiesen (Izard, 1994).

Das Emotionsmodell nach Izard ist nicht nur breiter aufgestellt als das vorangegangene Modell, sondern sie erläutert auch weitere Differenzierungen der einzelnen Primäremotionen (Izard, 1991, 1994). Sie liefert damit eine valide Grundlage, um ein inhaltlich zusammengehöriges Grundschema von Emotionen für die Sentimentanalyse aufzubauen. Damit stehen bei ihrem Emotionsmodell mit den eben genannten Gefühlszuständen drei positive Emotionen den sieben negativen Emotionen gegenüber, wobei sich die negativen Emotionen in nach innen bezogene Gefühlszustände wie Scham, Leiden, Schuld und nach außen referenzierende Gefühle wie Ekel, Verachtung, Ärger oder Angst unterscheiden lassen. Mit der Referenzierung nach innen und außen ist neben der Einteilung in Positiv und Negativ eine hierarchische Gliederung zumindest angedeutet.

#### 2.3.2.7.2 Modellkritik

Auch hier lassen sich die zuvor gehörten Punkte der Ableitung der Emotionen aus Gesichtszügen anbringen. Die Herleitung der Emotionen ist im Wesentlichen vergleichbar. Daher wird an dieser Stelle auf Kapitel 2.3.2.5.2 verwiesen. Ortony & Turner (1990) kritisieren ebenfalls Izards unveränderten Emotionscharakter bei der Vermengung der Gefühlsqualitäten.

Eine Kritik, die sich insbesondere an den hier vorgestellten Ansatz richtet, wurde von Barrett et al. (2007, S. 298), bezogen auf festverdrahtete Emotionen, die von Geburt an existent sind, wie folgt geäußert „*Statements to this effect, no matter how often or forcefully made, are not yet facts; they are hypotheses.*“ Gleichzeitig räumt sie ein, dass „*there is some evidence to support the idea that emotions are natural kinds*“ (Barrett et al., 2007, S. 298), die durch die empirischen Untersuchungen von Izard bekräftigt werden.

Empirische Untersuchungen stützen das Modell. So überprüften beispielsweise Forman & Scholz (2010) die Validität des Modells und Boyle (1984) untersuchte die Reliabilität und Validität. Auch Ouss, Carton, Jouvent & Widlöcher (1990) und Merten & Krause (1993) übersetzten und validierten das Modell für die französische bzw. deutsche Sprache.

#### 2.3.2.7.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Im Unterschied zu Ekman (2005) oder Tomkins (1984) hebt Izard (1994) den positiven Charakter der Überraschungsemotion hervor, der häufig in Kombination mit Freude und Interesse auftritt. Es ist ungleich schwieriger eine positive Überraschung von einer beliebig gerichteten Überraschung zu differenzieren, denn dies beinhaltet eine Berücksichtigung des Kontexts. Letzterer kann sich auf Vorgegangenes beziehen oder gefolgt von einer Bewertung einer Situation sein. In beiden Fällen muss ein größerer Bezugsrahmen aufgespannt werden, was die Annotation erschwert. Ebenso wie bei Tomkins wird zwischen Ekel, dem Abscheu vor Objekten, und Verachtung, der Abneigung gegenüber Personen unterschieden. Dies hat insbesondere für die Sentimentanalyse eine gesteigerte Relevanz, da in Texten zwischen einer sachbezogenen Abscheubekundung und der sozialen Kommunikationskomponenten bzw. der personenbezogenen Geringschätzung unterschieden werden muss. Ebenso wie bei Tomkins (1984) werden jedoch auch Schwierigkeiten bei der Differenzierung der beiden Emotionen erwartet, im Vergleich zu nur einer Abneigungsemotion.

Die angedeutete hierarchische Dreiteilung in positiv sowie negativ, nach innen gerichtet bzw. nach außen gerichtet, bietet nur einen marginalen Nutzen für die Sentimentanalyse. Auf der Verarbeitungs- und Annotationsseite bringt die damit verknüpfte Information keinen Mehrwert in der Differenzierung der soeben genannten kniffligen Fälle, denn alle schwer zu unterscheidenden Emotionen befinden sich jeweils innerhalb derselben Gruppe, so dass die Information einer vorgelagerten Analyse für die maschinelle Emotionserkennung vermutlich keinen Vorteil bietet. Betrachtet man die feinere Einteilung aus der Ergebnisperspektive, dann ist die Gruppierung vorteilhaft, aber zu grobmaschig, um wirklich nutzstiftend zu sein. Sie ist kein Gliederungsmerkmal, auf das bei ungenauer Bestimmung zurückgegriffen werden kann, und es wird dadurch auch kein Erkenntnisgewinn erzeugt.

Da Izards (1993) DES auf Englisch verfasst wurde, kann auch hier die Kritik der Sprachenabhängigkeit der Ausprägungen der semantischen Repräsentation angebracht werden. Merten & Krause (1993) zeigen auf, dass mindestens ein Element in der Übersetzung ausgetauscht werden musste, da dies im Deutschen nicht äquivalent anwendbar ist.

### **2.3.2.8 Merten und Krause**

#### **2.3.2.8.1 Diskrete Emotionen**

Wie soeben erwähnt, haben Merten & Krause (1993) die *Differential Emotion-Scale* von Izard (1993) übersetzt. Bei ihrer „differentielle[n] Affektskala“ (DAS) ergeben sich die Zuordnungen (Merten & Krause, 1993, S. 1), die in Tabelle 4 zusammengehörig gelistet werden.

Interesse	aufmerksam	Wut	wütend	Angst	erschreckt
	konzentriert		ärgerlich		ängstlich
	wach		zornig		furchtsam
Freude	vergnügt	Ekel	angewidert	Scham	gehemmt
	erfreut		angeekelt		verschämt
	fröhlich		abgestoßen		verlegen
Überra- schung	überrascht	Verachtung	verach- tungsvoll	Schuld	reumütig
	erstaunt		spöttisch		schuldig
	verblüfft		geringschät- zend		tadelnswert
Trauer	niederge- schlagen				
	traurig				
	entmutigt				

Tabelle 4: Emotionen und Ausprägungen des DAS nach Merten & Krause (1993, S. 2f.)

Dieses Modell ist in auf der positiven Seite differenzierter aufgestellt als einige vorangegangene. Abgesehen von der Differenzierung zwischen Ekel vor Objekten und Verachtung von Menschen besitzt das Modell keine großen Abhängigkeiten oder Rahmenbezüge (im Gegensatz zu Ortony et al., 1988; Roseman, 2001; Scherer, 1982).

#### 2.3.2.8.2 Modellkritik

Dieser Ansatz stellt keinen fundamental neuen theoretischen Beitrag zur Emotionsforschung dar, sondern eine Übersetzung und Anwendung der *Differential Emotion-Scale* von Izard (1993). Merten & Krause (1993) haben eine Reihe empirischer Untersuchungen vorgenommen. Gegenstand war das subjektive, affektierte Erleben anhand politischer Diskussionen in Zweiergruppen, im Nachgang zu therapeutische Sitzungen oder in alltäglichen Situationen, die per Tagebuchmethode durchgeführt bzw. veranlasst wurden. In ihren Ergebnissen kamen sie zu nur geringfügig unterschiedlichen Ergebnissen zwischen den vorgenommenen empirischen Tests.

#### 2.3.2.8.3 Realisierbarkeit

Da dieses Modell eine Übersetzung darstellt, sind alle realisierungsrelevanten Punkte der Ursprungstheorie von Izard auch hier anwendbar. Einzig die sprachliche Barriere fällt bei diesem Ansatz in Verbindung mit einer deutschen Sentimentanalyse nicht ins Gewicht. Für die Übersetzung spricht ebenfalls, dass das ins Deutsche übertragene Modell empirisch getestet und für geeignet befunden wurde.

Die Verfügbarkeit von zusätzlichen Termen zu den jeweiligen Emotionen bieten diverse Vorteile. Ersten lässt sich die Liste an Emotionstermen mit Hinblick auf die Sentimentanalyse

direkt für einen lexikalischen Ansatz nutzen. Zweitens bieten die Schlüsselworte eine Filtermöglichkeit bei der Vorauswahl eines annotierten Datensatzes. So kann beispielsweise gezielt nach diesen Emotionswörtern gesucht und diese vorselektierten Textpassagen durch geschulte Annotatoren klassifiziert werden. Schließlich wird das Konzept einer Emotion für Annotatoren noch greifbarer, wenn es durch mehrere Wörter beschrieben ist.

### 2.3.2.9 Frijda

#### 2.3.2.9.1 Diskrete Emotionen und Vollständigkeit

Emotionen sind Frijda (1986, 1994) zufolge ein Phänomen, das sich im Verhalten, also der physiologischen Reaktion, äußert und von der subjektiven Erfahrung abhängt. Ortony & Turner (1990, S. 316) geben an, in einem persönlichen Gespräch nur 6 Emotionen genannt bekommen zu haben. Anders als in der Kommunikation stellt Frijda (1986, S. 88) 16 Emotionen heraus, die in der nachfolgenden Tabelle 5 dargestellt sind.

Handlungstendenz	Resultierende Emotion
Annähernd („ <i>approach</i> “)	Verlangen („ <i>desire</i> “)
Vermeidend („ <i>avoidance</i> “)	Angst („ <i>fear</i> “)
Mit ... sein („ <i>being-with</i> “)	Vergnügen, Vertrauen („ <i>enjoyment, confidence</i> “)
Teilnehmend („ <i>attending (opening)</i> “)	Interesse („ <i>interest</i> “)
Abweisend („ <i>rejecting (closing)</i> “)	Ekel („ <i>disgust</i> “)
Nicht teilnehmend („ <i>nonattending</i> “)	Gleichgültigkeit („ <i>indifference</i> “)
Nicht wahrnehmend („ <i>agnostic</i> “)	Wut („ <i>anger</i> “)
Unterbrechend („ <i>interrupting</i> “)	Schockiert, Überraschung („ <i>shock, surprise</i> “)
Dominierend („ <i>dominating</i> “)	Arroganz („ <i>arrogance</i> “)
Anpassend („ <i>submitting</i> “)	Bescheidenheit, Resignation („ <i>humility, resignation</i> “)
Deaktivierend („ <i>deactivation</i> “)	Trauer („ <i>sorrow</i> “)
Verpflichtende Aktivierung („ <i>bound activation</i> “)	Anstrengung („ <i>effort</i> “)
Erregend („ <i>excitement</i> “)	Erregung („ <i>excitement</i> “)
Freiheit zur Aktivierung („ <i>free activation</i> “)	Lust („ <i>joy</i> “)
Inaktivität („ <i>inactivity</i> “)	Zufriedenheit („ <i>contentment</i> “)
Hemmend („ <i>inhibition</i> “)	Angst („ <i>anxiety</i> “)
Aufgebend („ <i>surrender</i> “)	Lachend, weinend („ <i>laughter, weeping</i> “)

Tabelle 5: Verknüpfung der Handlungstendenzen und Emotionen nach Frijda (1986)

Das Emotionsmodell weist eine große Bandbreite an Emotionszuständen auf. Dies kann als Argument für eine breite Abdeckung hinsichtlich der Vollständigkeit gewertet werden. Viele Emotionen wie Arroganz, Gleichgültigkeit oder Bescheidenheit sind bei den meisten anderen Forschern und in den noch folgenden Emotionsmodellen nicht vorhanden. Das Modell ist zusätzlich hinsichtlich positiver und negativer Vertreter austariert.

#### 2.3.2.9.2 Modellkritik

Aufgrund der Vielfalt der integrierten Emotionen gibt es Kritik an der Auswahl. Ortony & Turner (1990) stellen Überraschung und Interesse wegen der fehlenden Valenz in Frage, da es

sich um kognitive Zustände handle. Die beiden Kritiker beziehen sich auf die verkürzte Liste der Emotionen aus der persönlichen Korrespondenz. In der ursprünglichen Liste besitzt Überraschung / Schock eine negative Valenz.

Die Verankerung von Frijdas (1986) Handlungstendenzen, denen „individuelle Relevanzkriterien und Reaktionsschwellen als persönlichkeitspezifische Bedingungen emotionaler Reaktionen“ zugrunde liegen (Ulich, 2003, S. 86), wird ebenfalls kritisiert. Der Kritiker führt weiterhin aus, dass diese nicht nur auf emotionale Motive zurückgeführt werden können, sondern auch auf individuell entwickelte Gewohnheitsmuster. Außerdem müssten sich Ulich (2003) Ansicht nach bei unterschiedlichen Personen durch die Soziogenese auch „interindividuell unterschiedliche[...] emotionale[...] Reaktionstendenzen“ (S. 87) herausbilden.

### 2.3.2.9.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Bezogen auf das Modell mit 16 Gefühlsqualitäten, offenbaren einige Emotionen einen komplexeren Charakter. Die negativ konnotierte Überraschung dürfte in der Umsetzung vergleichbar schwierig sein wie die positive Überraschung bei Izard. Daher lassen sich die gleichen Argumente anbringen, die oben schon erwähnt wurden. Die Emotion Bescheidenheit ist nur äußerst schwierig in einer schriftlichen Form auszumachen. Dies setzt eine spezielle Situation voraus, in der man diese Gefühlsqualität zum Ausdruck bringen kann. Sie benötigt eine soziale Zuschreibungskomponente. Es wird ebenso davon ausgegangen, dass Zufriedenheit selten anzutreffen ist, sofern dies aus der Handlungstendenz der Inaktivität herrührt.

### 2.3.2.9.4 In Verwendung

Das Emotionsmodell wird in der Praxis verwendet (Rübenstrunk, 1998). So wurden die theoretischen Emotionsgrundlagen in die zwei computergestützten Modelle ACRES (Frijda & Swagerman, 2008) und ACRES/WILL (Moffat, Frijda & Phaf, 1993) integriert.

## 2.3.2.10 Robinson

### 2.3.2.10.1 Diskrete Emotionen und Vollständigkeit

Basierend auf einer Gegenüberstellung von Emotionsmodellen entwickelte Robinson (2008) einen theoretischen Ansatz, bei dem er die am häufigsten genannten Basisemotionen aus der Studie von Ortony & Turner (1990) als Positiv-negativ-Paare herausarbeitete. Das Ergebnis sind elf sich kontrastierende Emotionspaare, wie in Tabelle 6 dargestellt.

Art der Emotion	Positive Emotionen	Negative Emotionen
Emotionen, die auf Objekteigenschaften beruhen („emotions related to object properties“)	Interesse („ <i>interest</i> “), Neugier („ <i>curiosity</i> “) Anziehung („ <i>attraction</i> “), Verlangen („ <i>desire</i> “), Bewunderung („ <i>admiration</i> “)	Alarmiertheit („ <i>alarm</i> “), Panik („ <i>panic</i> “) Abneigung („ <i>aversion</i> “), Ekel („ <i>disgust</i> “), Abscheu („ <i>revulsion</i> “)

	Überraschung („ <i>surprise</i> “), Amüsement („ <i>amusement</i> “)	Gleichgültigkeit („ <i>indifference</i> “), Geborgenheit („ <i>familiarity</i> “), Gewöhnung („ <i>habituation</i> “) Furcht („ <i>fear</i> “)
Emotionen zukünftiger Beurteilung („ <i>future appraisal emotions</i> “)	Hoffnung („ <i>hope</i> “)	
Emotionen, bezogen auf eine unmittelbare Begebenheit („ <i>event related emotions</i> “)	Dankbarkeit („ <i>gratitude</i> “), Dankbarkeit („ <i>thankfulness</i> “) Freude („ <i>joy</i> “), Hochstimmung („ <i>elation</i> “), Triumphgefühl („ <i>triumph</i> “), Jubel („ <i>jubilation</i> “) Erleichterung („ <i>relief</i> “)	Wut („ <i>anger</i> “), Zorn („ <i>rage</i> “) Kummer („ <i>sorrow</i> “), Trauer („ <i>grief</i> “) Frustration („ <i>frustration</i> “), Enttäuschung („ <i>disappointment</i> “)
Emotionen der Selbstbeurteilung („ <i>self appraisal emotions</i> “)	Stolz in Bezug auf erfüllte Ziele („ <i>pride in achievement</i> “), Selbstvertrauen („ <i>self-confidence</i> “), Geselligkeit („ <i>sociability</i> “) Großzügigkeit („ <i>generosity</i> “)	Verlegenheit („ <i>embarrassment</i> “), Scham („ <i>shame</i> “), Schuld („ <i>guilt</i> “), Reue („ <i>remorse</i> “) Habsucht („ <i>avarice</i> “), Gier („ <i>greed</i> “), Geiz („ <i>miserliness</i> “), Neid („ <i>envy</i> “), Eifersucht („ <i>jealousy</i> “) Grausamkeit („ <i>cruelty</i> “)
Soziale Emotionen („ <i>social emotions</i> “)	Sympathie („ <i>sympathy</i> “)	Grausamkeit („ <i>cruelty</i> “)
Beziehungsemotionen („ <i>cathected emotions</i> “)	Liebe („ <i>love</i> “)	Hass („ <i>hate</i> “)

Tabelle 6: Taxonomie der Emotionen nach Robinson (2008, S. 155)

Das Modell ist als Synergieansatz von Ortony & Turner (1990) angelegt, wobei Robinson (2008) die Emotionen der 13 Theorien inkorporiert und durch weitere Emotionen ergänzt. Dem Autor dieses Metamodells der Basisemotionen kreierte hinsichtlich der Vollständigkeit ein ausführliches Modell. Die zweistufige Emotionsgliederung hat eine zugrunde liegende Struktur von sechs Oberkategorien mit jeweils positiven und negativen Ausprägungen. Durch die Eingliederung in positive und negative Emotionen weist das Modell eine relative Balance auf.

### 2.3.2.10.2 Modellkritik

Was eine kritische Beleuchtung des Modells angeht, so ist der Beitrag von Robinson (2008) ein wenig zitierter Ansatz. Zum Zeitpunkt der Erstellung dieser Forschungsarbeit gab es noch keine dem Autor bekannte kritische Auseinandersetzung mit diesem Modell.

Robinson (2009) leitet sein Emotionsmodell aus der Gegenüberstellung mehrerer Basisemotionsmodelle von Ortony & Turner (1990) ab. Deren theoretische Gegenüberstellung ist eine Momentaufnahme des Stands der damaligen Emotionsforschung. Ortony & Turner (1990) erheben keinen Anspruch auf Vollständigkeit, sondern erklären, dass sie sich auf eine Auswahl von Forschungsarbeiten einschränken, in denen Basisemotionen postuliert wurden.

Der rein theoretische Ansatz von Robinson (2009) stellt somit nur ein Metamodell der damals existenten Primäremotionsmodelle dar. Der Hauptgedanke von Ortony & Turner (1990) bestand darin, eine Gegenposition zur Existenz der Primäremotionen einzunehmen. Der Umstand, dass der Beitrag nicht als Listung, sondern als Kritik an den Basisemotionen zu verstehen ist, wird von Robinson (2008) ausgeblendet. Es entsteht ein Dilemma, denn einerseits leitet er ein Set aus Basisemotionen ab, möchte andererseits aber dem Einwand von Ortony & Turner

(1990) Rechnung tragen. Deswegen geht Robinson (2008) den Umweg über sogenannte Persönlichkeitsmerkmale.

Es stellt sich die Frage, ob der Autor nicht zu viele Emotionszustände integriert hat, da das Kriterium zur Aufnahme einer Emotion lediglich in der Nennung in der Studie von Ortony & Turner (1990) bestand. Dies geschieht nahezu ungeachtet der individuellen Häufigkeit, weswegen sich Hoffnung mit nur einem einzigen Auftreten und Furcht mit den häufigsten Nennungen von neun Vorkommnissen direkt gegenüberstehen. Auch der zugrunde liegende theoretische Unterbau der jeweiligen Modelle wird vernachlässigt, so dass neurochemische Ansätze mit behavioristischen und bewertungstheoretischen in einen Topf geworfen werden.

Da es sich um ein rein theoretisches Modell handelt, die Validität bisher weder verifiziert noch falsifiziert wurde und die hier herausgearbeitete Kritik gegen eine ausdrückliche Richtigkeit spricht, wird hier trotz der vielen einträglichen Aspekte von der Verwendung in der feingranularen Sentimentanalyse abgesehen.

#### 2.3.2.10.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Die übergeordnete Emotionsstruktur ermöglicht die Inklusion von Kontextinformationen zur genaueren Differenzierung. Zum einen sind durch die sechs übergeordneten Emotionskategorien ausreichend Unterscheidungsmerkmale vorhanden. Zum anderen lassen sich die meisten davon durch Zukunfts- oder Möglichkeitsformen, die Perspektive des Sprechers, den Kontextbezug oder den Bezug auf eine Entität bestimmen.

Durch die Vielzahl der diskreten Emotionen wird eine Annotation erschwert. Für jede Emotion müssen ausreichend Datensätze annotiert werden. Darüber hinaus muss für jeden Satz eine Anzahl an unterschiedlichen Emotionen abgewogen werden. Dies ist weit mehr, als von einem Menschen im Arbeitsgedächtnis gehalten werden kann (Miller, 1956).

Viele der genannten Emotionen sind schwierig zu differenzieren oder in der Schriftsprache kaum auszumachen. Als Beispiel für die komplexe Trennbarkeit werden die Emotionen Habsucht und Gier, Wut und Zorn oder Verlegenheit und Scham angeführt. Dazu kommen Emotionen wie Selbstvertrauen, Sympathie, Geselligkeit, Geborgenheit oder Gewöhnung, die in Texten selten bis gar nicht anzutreffen sind.

#### 2.3.2.10.4 Anwendbarkeit auf dimensionale Modelle

Dadurch, dass es zu jeder negativen Emotionsausprägung auch eine positive Emotionskategorie gibt, lässt sich analog zu Plutchik eine Negation anwenden. Die Emotionskategorien sind als Differentiale aufgebaut, so dass das Gegenteil des einen Kontinuums als Indiz dafür

dienen kann, dass die gegenüberliegende Kategorie zutrifft. Dies kann beispielsweise auf das Wortpaar Anziehung und Abneigung angewendet werden.

### 2.3.2.11 Levenson

#### 2.3.2.11.1 Diskrete Emotionen und Vollständigkeit

Seinem Verständnis nach sind Freude („*enjoyment (playing)*“), Wut („*anger (fighting)*“), Ekel („*disgust (rejecting)*“), Angst („*fear (avoiding)*“), Überraschung („*surprise (orienting)*“) und Trauer („*sadness (help seeking)*“) das Set der Basisemotionen (Levenson, 2011, S. 379). Levenson (2011, S. 379) räumt ein, dass er dazu tendiere, die Emotionen Erleichterung bzw. Zufriedenheit („*relief/contentment (soothing)*“), Interesse („*interest (exploration)*“) und Zuneigung („*love (attachment)*“) ebenfalls als elementar anzusehen. Generell kritisiert er, dass es in anderen Studien zu Grundemotionen wenig positiven Emotionen gibt, weswegen er Amüsiertheit, Aufregung, Ehrfurcht, Freude, Liebe, Ruhe, Stolz und Zufriedenheit als zusätzliche Vertreter vorschlägt (Fredrickson & Levenson, 1998).

Bezüglich der Bewertung für die Sentimentanalyse wird hier auf die erweiterte Liste Bezug genommen, da die Version mit nur sechs Basisemotionen exakt der von Ekman & Friesen (1971) entspricht. Durch das Hinzufügen der positiven Gefühlszustände Zufriedenheit, Interesse und Zuneigung sind nun vier positive und vier negative Emotionen sowie mit Überraschung eine in den überwiegenden Fällen positive Emotion vorhanden. Dies entspricht dem einzigen hier vorgestellten Modell, das eine größere positive als negative Gefühlspalette aufweist. Zudem ist damit die Balance zwischen beiden Emotionskategorien hergestellt.

#### 2.3.2.11.2 Modellkritik

Laut Fredrickson, Mancuso, Branigan & Tugade (2000) ist die Inklusion der zusätzlichen positiven Emotionen in den Primäremotionen selbst unter den Autoren, die mehrere positive Gefühlsaspekte herausarbeiteten, nicht unumstritten (beispielsweise Fredrickson & Levenson, 1998; Lazarus, 1994). Handlungstendenzen bezüglich positiver Emotionen sind nicht spezifisch genug und positive Emotionen sind oft durch einen Mangel an autonomer Reaktivität gekennzeichnet, weswegen kaum eine Aktivierung des autonomen Nervensystems festzustellen ist (Fredrickson et al., 2000). Dem widersprechen beispielsweise Schneiderman, Zilberstein-Kra, Leckman & Feldman (2011) in Bezug auf die Emotion des Verliebt-Seins.

#### 2.3.2.11.3 Realisierbarkeit

Dieses Modell weist auch mit der erweiterten Betrachtung der Zustände keine Emotionen auf, die nicht direkt in einem Text gefunden werden können oder eines besonderen Kontexts

bedürfen. Es ist jedoch in Frage zu stellen, ob die Gefühlszustände der Zufriedenheit und Zu-  
neigung textuell in gleicher Häufigkeit repräsentiert werden. Wie in Kapitel 2.3.2.9.3 erläutert  
wurde, ist Zufriedenheit ein Zustand der Inaktivität, was durch eine geringe Handlungsmotiva-  
tion gekennzeichnet ist. Auch die Emotion Zärtlichkeit ist, wie bei den Emotionen Fürsorge  
und Lust bei Pranksepp argumentiert wurde, sicherlich nicht in jedem Textkorpus zu finden.

### **2.3.2.12 Arnold**

#### **2.3.2.12.1 Diskrete Emotionen und Vollständigkeit**

Arnold (1960a, 1960b) ist eine Forscherin im Sinne der kognitiven Einschätzungstheorien.  
Sie wird zu den Theoretikern der Basisemotionen gezählt (Ortony & Turner, 1990). Arnold  
(1960a, S. 196) arbeitete die abgrenzbaren Emotionen Lieben / Mögen („*love / liking*“), Verab-  
scheuung („*hate / dislike*“), Verlangen („*wanting / desire*“), Abneigung („*aversion / recoil*“),  
Freude („*delight / joy*“), Trauer („*sorrow / sadness*“), Hoffnung („*hope*“), Hoffnungslosigkeit /  
Verzweiflung („*hopelessness / despair*“), Wagemut / Mut („*daring / courage*“), Angst („*fear*“),  
Wut („*anger*“) und Niedergeschlagenheit („*dejection*“) heraus.

Es gibt hier eine große Schnittmenge mit bisherigen Modellen. Allerdings sind auch sel-  
tene Emotionen wie Verlangen, Mut oder Hoffnung enthalten. Wenngleich mit leichtem Un-  
gleichgewicht, sind dabei sowohl positive als auch negative Vertreter ausreichend differenziert.

#### **2.3.2.12.2 Modellkritik**

Arnold gilt als die Begründerin der *Appraisal-Theory* (McEachrane, 2009, S. 34). Sie  
wurde wegen ihrer phänomenologischen Herangehensweise, die sich auf ihre subjektiven Emo-  
tionserfahrungen bezogen, kritisiert (Reisenzein, 2006). Ihr Ansatz gilt als überholt, wie fol-  
gendes Zitat belegt: „Im Laufe der Jahre wurde die ursprüngliche Bewertungstheorie von  
Arnold [...] jedoch in verschiedenen Hinsichten als mangelhaft befunden und dementspre-  
chend wurden verbesserte Einschätzungstheorien vorgeschlagen“ (Dorsch et al., 2013, S. 447).  
Zu den Kritikern zählen unter anderem Ortony & Turner (1990), die neben einer generellen Kri-  
tik an Basisemotionen bei Arnold insbesondere die Emotionen Verlangen und Mut beanstan-  
den, da es sich ihrer Ansicht nach in beiden Fällen nicht um eine Emotion handle.

#### **2.3.2.12.3 Realisierbarkeit**

Das theoretische Emotionskonstrukt setzt in Teilen auf unterschiedlich intensiven Emotio-  
nen auf. So muss in diesem Modell eine feine Differenzierung zwischen der extremen Form  
der Trauer von Hoffnungslosigkeit / Verzweiflung und einer weniger stark ausgeprägten

Niedergeschlagenheit getroffen werden. Gleiches gilt für die Verabscheuung und die Abneigung. Wie in Kapitel 2.3.2.3.3 bereits ausführlich dargelegt, ist dies keine triviale Aufgabe.

Im Vergleich zu Forschern, die ein nichthierarchisches Emotionsmodell vorschlagen, finden sich bei Arnold (1960a) diskrete Emotionen, die in dieser Form noch nicht anzutreffen waren. Unter diesen stellt Wagemut bzw. Mut, aber auch Hoffnungslosigkeit eine Herausforderung für die Emotionserkennung dar. Zum einen wird das Gefühl nur bedingt direkt durch eine Äußerung ausgedrückt, zum anderen bedarf es einer komplexen Bewertung der Situation. Die übrigen Emotionen stellen textuell keine komplizierteren Konstrukte dar. So existieren keine zusätzlichen Anforderungen wie Bezugssystemerkennung oder Personenabhängigkeiten beim Erkennen dieser Emotionen. Hoffnung kann sich durch Phrasen wie „ich hoffe“ oder „ich habe die Hoffnung“ manifestieren. Auch die Möglichkeitsform kann diesbezüglich bemüht werden. Generell kommt dieses Modell ohne komplexe Abhängigkeiten aus.

### **2.3.2.13 Lazarus**

#### 2.3.2.13.1 Diskrete Emotionen und Vollständigkeit

Lazarus (2001) differenziert zwischen primären und sekundären Bewertungsvorgängen, wobei beide als gleich bedeutsam einzustufen sind. Bei einer Zielinkongruenz finden sich die negativen Emotionen Wut („*anger*“), Angst („*fright-anxiety*“), Schuld und Scham („*guilt-shame*“), Trauer („*sadness*“), Neid („*envy-jealousy*“) sowie Ekel („*disgust*“) wieder (Lazarus, 1994, S. 217). Die positiven Emotionen Freude („*happiness/joy*“), Stolz („*pride*“), Zuneigung („*love/affection*“) und Erleichterung („*relief*“) entstehen bei einer Zielkongruenz (ebenda, S. 264). Darüber hinaus ergänzt Lazarus (1994) die ungesicherten Emotionen Hoffnung („*hope*“, S. 282), Mitgefühl („*compassion*“, S. 287) und den Sinn für das Schöne („*aesthetic emotions*“, S. 292), welche er selbst als problematisch einstuft. Der zweite Bewertungsschritt bezieht sich auf eine Schuld („*blame*“) oder einen Verdienst („*credit*“), die Möglichkeit, mit einer Situation umzugehen („ *coping potential*“) und die tendenzielle Erwartung der zukünftigen Entwicklung („*future expectancy*“) (Lazarus, 1994, S. 150).

Dieser Ansatz reiht sich bezüglich der Anzahl an Emotionen in das Mittelfeld der hier vorgestellten Modelle ein. Dabei konzentriert er sich hinsichtlich der Vollständigkeit auf eine konsensbasierte und akzeptierte Grundgesamtheit. Jedoch finden sich auch hier einige Emotionen, die in keinem der anderen Emotionsmodelle zu finden sind, wie der Sinn für das Schöne. Bei Inklusion der ungesicherten Emotionen liegt eine relative Balance vor.

#### 2.3.2.13.2 Modellkritik

Reisenzein (2006) bemängelt an „Lazarus’ proposal that emotions [...] essentially include [...] the awareness of ‘instinctive’ action impulse [...]“, dass es noch wenig aussagekräftige, empirische Untermauerungen gibt und dass das theoretische Konstrukt „still await[s] a close examination“.

Repräsentativ für viele andere Forscher der kognitiven Bewertungstheorie wurde Lazarus insbesondere von Zajonc (1980) bezüglich des fundamentalen Punkts der Bewertungstheorie kritisiert, dass Emotionen ein Produkt eines Einschätzungsvorgangs sind. In empirischen Untersuchungen zeigte er auf, dass Gefühlsurteile keineswegs uneingeschränkt der kognitiven Bewertung eines Sachverhalts folgen. Er räumte jedoch ein, dass der kognitive Einschätzungsprozess der Entstehung von Emotionen nachgelagert sein kann. Mandl & Reiserer (2000, S. 103) begründen den wissenschaftlichen Diskurs zwischen Lazarus (1984) und Zajonc (1984) der sogenannten „Kognitions-Emotions-Debatte“ sowie der Reihenfolge der Bewertungsprozesse damit, dass die beiden Wissenschaftler „unterschiedliche terminologische Konzeptualisierungen“ haben. Eine vergleichbare Ansicht haben Davidson & Ekman (1994).

Wie Mandl & Reiserer (2000, S. 103) ausführen, steht auch Izard (1994) der Interpretation von Lazarus (1994) zur Emotionsentstehung kritisch gegenüber, da diese Betrachtungsweise beispielsweise „genetisch bedingte, zelluläre[...] und] biologisch-physiologische [...] Informationsverarbeitungsebene[n]“ außer Acht lasse.

#### 2.3.2.13.3 Realisierbarkeit

Bei diesem Modell kommen viele zusätzliche Abhängigkeiten und innere Wertmaßstäbe hinzu. Diese sind textuell meist nicht direkt erfassbar, da diesbezüglich weitreichende Informationen über den Autor benötigt werden. Diese Zusatzinformation, die dem dimensional Modell Rechnung tragen soll, stellt jedoch kein Ausschlusskriterium für die direkte, diskrete Emotionsbestimmung dar. Vielmehr kann das Wissen über die dimensional Ausprägungen, sofern es bestimmbar ist, unterstützend in eine Klassifikation eingegeben werden.

Unter den Emotionen befinden sich auch einige, die Hürden für eine Umsetzung darstellen. Neben den bei anderen Autoren abgehandelten Emotionen ist hier unter anderem Stolz zu nennen. Diese Emotion ist klar abgegrenzt von anderen Emotionszuständen und somit besteht keine inhaltliche Grenzverwischung. Nichtsdestotrotz ist Stolz schwierig auszumachen, da dieses Gefühl nicht immer direkt zur Schau gestellt wird, weil dies in der sozialen Bewertung als Arroganz ausgelegt werden kann. Auch die Aussage, dass jemand stolz sei, steht in einem negativen Licht, im Gegensatz zu dem im Modell positiv verankerten Gefühl.

#### 2.3.2.13.4 Anwendbarkeit auf dimensionale Modelle

Bezüglich der Frage, ob Emotionskategorien diskret oder dimensional abgegrenzt werden, versucht Lazarus einen Mittelweg zu gehen, indem er einerseits klar abgrenzbare Emotionen vorschlägt, aber einräumt, dass jede Emotion für sich als Dimension verstanden werden kann. Jede Dimension kann aufgrund der Intensität unterschiedliche Ausprägungen haben, „*without necessarily implying any changes in its quality*“ (Lazarus, 1994, S. 59). Durch diesen Ansatz kann dieses Modell, wie bereits das synergetische Modell von Plutchik (1984), als dimensionales Modell ausgelegt und angewendet werden.

#### **2.3.2.14 Shaver**

##### **2.3.2.14.1 Diskrete Emotionen und Vollständigkeit**

Shaver et al. (1987) wählen einen linguistisch-empirischen Ansatz zur Bestimmung der Emotionskategorien. Die Autoren leiten ein abstrahiertes Emotionsverständnis durch eine menschliche Sortierung von Emotionswörtern ab, so dass übergeordnete Kategorien entstehen und Gruppen von Gefühlszuständen zusammengefasst werden können. Sie begründen ihre Vorgehensweise damit, dass „*[o]rdinary people know a great deal about emotion*“ (Shaver et al., 1987, S. 1061). Aus der Kookkurrenz der Emotionsterme entstand ein hierarchisches Emotionscluster. Shaver et al. (1987) bevorzugten eine Einteilung nach sechs abgrenzbaren Konzepten, die sich aus Angst, Ärger, Freude, Liebe, Trauer, und Überraschung zusammensetzen, wie in Abbildung 10 dargestellt.

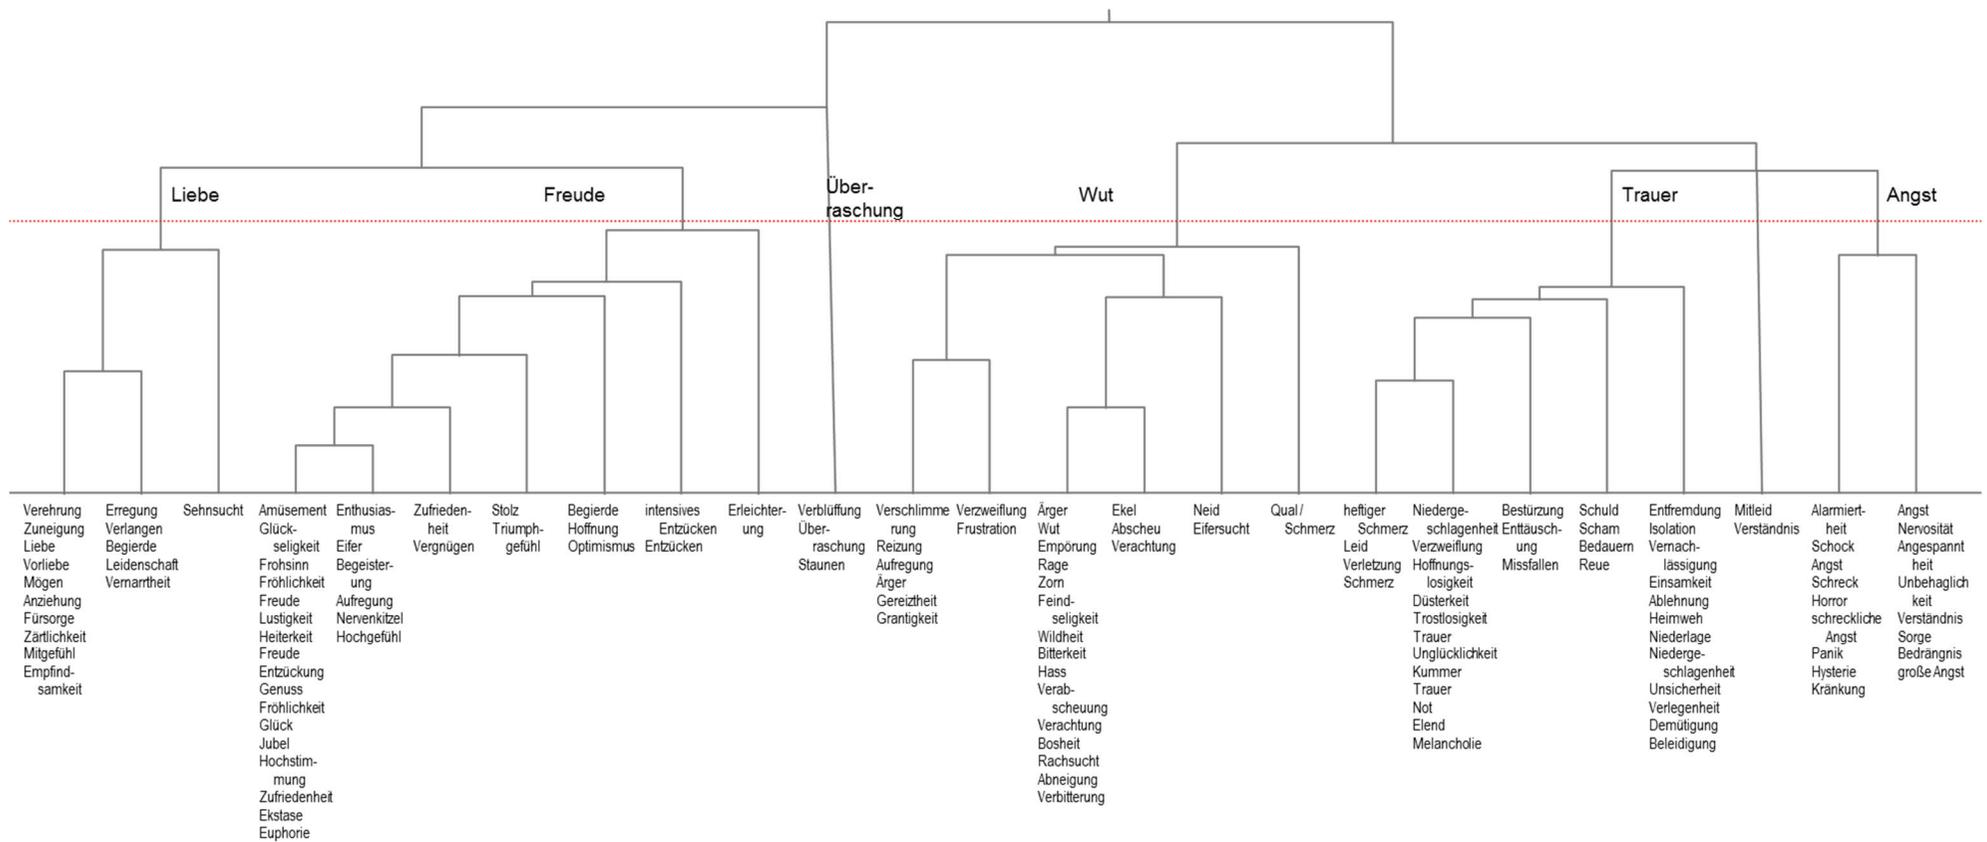


Abbildung 10: Clusteranalyse durch Sortieren der Emotionsterme (nach Shaver et al., 1987)

Dieses Emotionsschema besitzt viele Ähnlichkeiten mit dem Modell von Ekman (2005). Während sich Ekel als Unterkategorie zu Wut eingliedert, findet mit Liebe eine Zuneigungse-motion Einzug in das Modell. Anders wie bei dem mimikbasierten Emotionsmodell kann die Klassifikation der Emotionen nach Shaver et al. (1987) trotz der gleichen Emotionsanzahl als deutlich vollständiger bezeichnet werden, da es sich um ein gekürztes Ergebnis einer Clusteranalyse handelt. Eine Verwendung auf unterster Emotionslistenebene erlaubt deutlich mehr Tiefgang. Das Dendrogramm kann auch als modellimmanentes Ordnungsschema angesehen werden. Durch die Berücksichtigung von Liebe erhöht sich die Balance des Modells. Dieses Verhältnis verbessert sich zusätzlich auf Ebene der Einzelemotionsterme.

#### 2.3.2.14.2 Modellkritik

Die Autoren haben Überraschung in die zu sortierende Liste der Emotionen explizit mit aufgenommen. In einer in diesem Rahmen durchgeführten Voruntersuchung darüber, ob bestimmte Terme aus einer Liste von 213 Wörtern Emotionen darstellen, wurden nur Wörter aufgenommen, die im Mittel eine Wertigkeit von über 2,75 auf einer Vier-Punkt-Skala („*definitely would not call this an emotion* (1)“ bis „*definitely would call this an emotion* (4)“) aufweisen (Shaver et al., 1987, S. 1065). Überraschung fiel mit einem Mittelwert von 2,69 knapp durch das Raster, wurde jedoch mit folgender Begründung aufgenommen, „*because emotion theorists have so often designated it a basic emotion*“ (Shaver et al., 1987, S. 1065). Ortony et al. (1988) stellen heraus, dass Überraschung nicht als Emotionszustand betrachtet werden darf, da es sich hierbei um keinen affektierten Valenzzustand handelt.

Aufgrund von Kritik am Sortierverfahren von Weller & Romney (1988) wurde der Versuch von Alvarado (1998) mit einem geänderten Ansatz wiederholt. Anstelle eines Gruppierungsvorgangs wurde ein Teilvorgang vorgenommen. Diese kleine Anpassung der Rahmenbedingungen führte dazu, dass 13 von den Studenten benannte Kategorien gefunden wurden: evaluierend, Intensität, Dauer, selbst / andere, Beziehung, kategorisch, allgemein / spezifisch, urteilend, Ausdruck / Gefühl, definierend, steuerbar, undifferenziert sowie nicht zuordenbar.

#### 2.3.2.14.3 Realisierbarkeit

Die Emotionen gehören nicht zu den umsetzungsschweren Zuständen. Diese sind inhaltlich deutlich abgegrenzt und eignen sich gut für eine Annotation oder eine Klassifikation.

Das Modell von Shaver et al. (1987) basiert auf einer semantischen Auswahl von Emotionstermen. Bereits vorhandene, annotierte Wörtern haben den Vorteil, dass eine theoriebasierte Zuordnung zu vorgeschlagenen Kategorien besteht. Diese kann für die Gruppierungen in der Emotionserkennung verwendet werden. Für einen lexikonbasierten Ansatz ließe sich

dies als Eingabemerkmale oder als Überprüfungskriterium nutzen, ohne dass ein neues Modell aufgestellt werden muss. Aus diesem triftigen Grund wäre der hier vorliegende Ansatz einem generischen Modell mit einer bloßen Nennung der Emotionskategorien vorzuziehen. Jedoch sei als Einschränkung zu nennen, dass lediglich Nomen als Wortarten verfügbar sind. Mittels Derivation oder anderen morphologischen Wortanpassungen lässt sich diese Liste erweitern.

#### 2.3.2.14.4 Anwendbarkeit auf dimensionale Modelle

Als Alleinstellungsmerkmal soll die von Shaver et al. (1987) herausgearbeitete Kompatibilität zu den dimensional Ansätzen unterstrichen werden. Das Modell lässt sich auf die zwei bzw. drei dimensional Emotionsansätze Valenz („*evaluation*“) und Intensität („*intensity*“) sowie Valenz („*evaluation*“) Potenz („*potency*“) und Aktivierungsgrad („*activity*“) anwenden (Shaver et al., 1987, S. 1070). Damit existiert ein theoretisch gefestigtes und empirisch geprüftes Bindeglied zwischen der diskreten und der dimensional Emotionseinteilung.

### 2.3.2.15 Parrott

#### 2.3.2.15.1 Diskrete Emotionen, Vollständigkeit, Balance und Hierarchie

Parrott (2001b) liefert eines der detailliertesten Emotionsmodelle. Neben Basisemotionen, für die er den aus dem Deutschen entlehnten Begriff „*ur-emotions*“ einführt (Frijda, Robinson & Parrott, 2009, S. 19), existieren auch Nicht-Basisemotionen. In seiner Taxonomie der Emotionen gliedert Parrott (2001a) emotionale Zustände anhand dreier Hierarchiestufen. Wie Tabelle 7 zeigt, identifiziert er über einhundert unterschiedliche diskrete Emotionen. Diese sind ausgehend von sechs primären Emotionen hierarchisch gegliedert und unterteilen sich jeweils auf der sekundären und tertiären Emotionsebene, wobei die Primär- und Sekundäremotionen als Gliederungsstufe und nicht als Ausgangslage einer aus multiplen Komponenten bestehenden Basisemotionstheorie verstanden werden dürfen.

Primäre Emotionen	Sekundäre Emotionen	Tertiäre Emotionen
<b>Liebe</b> („ <i>love</i> “)	Zuneigung („ <i>affection</i> “)	Verehrung („ <i>adoration</i> “), Zuneigung („ <i>affection</i> “), Liebe („ <i>love</i> “), Vorliebe („ <i>fondness</i> “), Mögen („ <i>liking</i> “), Anziehung („ <i>attraction</i> “), Fürsorge („ <i>caring</i> “), Zärtlichkeit („ <i>tenderness</i> “), Mitgefühl („ <i>compassion</i> “), Empfindsamkeit („ <i>sentimentality</i> “)
	Begierde („ <i>lust</i> “)	Erregung („ <i>arousal</i> “), Verlangen („ <i>desire</i> “), Begierde („ <i>lust</i> “), Leidenschaft („ <i>passion</i> “), Vernarrtheit („ <i>infatuation</i> “)
	Sehnsucht („ <i>longing</i> “)	Sehnsucht („ <i>longing</i> “)
<b>Freude</b> („ <i>joy</i> “)	Fröhlichkeit („ <i>cheerfulness</i> “)	Amusement („ <i>amusement</i> “), Glückseligkeit („ <i>bliss</i> “), Frohsinn („ <i>cheerfulness</i> “), Fröhlichkeit („ <i>gaiety</i> “), Freude („ <i>glee</i> “), Lustigkeit („ <i>jolliness</i> “), Heiterkeit („ <i>joviality</i> “), Freude („ <i>joy</i> “), Entzückung („ <i>delight</i> “), Genuss („ <i>enjoyment</i> “), Fröhlichkeit („ <i>gladness</i> “), Glück („ <i>happiness</i> “), Jubel („ <i>jubilation</i> “), Hochstimmung („ <i>elation</i> “), Zufriedenheit („ <i>satisfaction</i> “), Ekstase („ <i>ecstasy</i> “), Euphorie („ <i>euphoria</i> “)
	Begeisterung („ <i>zeal</i> “)	Enthusiasmus („ <i>enthusiasm</i> “), Eifer („ <i>zeal</i> “), Begeisterung („ <i>zeal</i> “), Aufregung („ <i>excitement</i> “), Nervenkitzel („ <i>thrill</i> “), Hochgefühl („ <i>exhilaration</i> “)
	Zufriedenheit („ <i>contentment</i> “)	Zufriedenheit („ <i>contentment</i> “), Vergnügen („ <i>pleasure</i> “)

	Stolz („ <i>pride</i> “)	Stolz („ <i>pride</i> “), Triumphgefühl („ <i>triumph</i> “)
	Optimismus („ <i>optimism</i> “)	Begierde („ <i>eagerness</i> “), Hoffnung („ <i>hope</i> “), Optimismus („ <i>optimism</i> “)
	Intensives Entzücken („ <i>enthralment</i> “)	intensives Entzücken („ <i>enthralment</i> “), Entzücken („ <i>rapture</i> “)
	Relief („ <i>relief</i> “)	Erleichterung („ <i>relief</i> “)
<b>Überraschung („<i>surprise</i>“)</b>	Überraschung („ <i>surprise</i> “)	Verblüffung („ <i>amazement</i> “), Überraschung („ <i>surprise</i> “), Staunen („ <i>astonishment</i> “)
<b>Ärger („<i>anger</i>“)</b>	Irritationen („ <i>Irritation</i> “)	Verschlimmerung („ <i>aggravation</i> “), Reizung („ <i>irritation</i> “), Aufregung („ <i>agitation</i> “), Ärger („ <i>annoyance</i> “), Gereiztheit („ <i>grouchiness</i> “), Grantigkeit („ <i>grumpiness</i> “)
	Verzweiflung („ <i>exasperation</i> “)	Verzweiflung („ <i>exasperation</i> “), Frustration („ <i>frustration</i> “)
	Wut („ <i>rage</i> “)	Ärger („ <i>anger</i> “), Wut („ <i>rage</i> “), Empörung („ <i>outrage</i> “), Rage („ <i>fury</i> “), Zorn („ <i>wrath</i> “), Feindseligkeit („ <i>hostility</i> “), Wildheit („ <i>ferocity</i> “), Bitterkeit („ <i>bitterness</i> “), Hass („ <i>hate</i> “), Verabscheuung („ <i>loathing</i> “), Verachtung („ <i>scorn</i> “), Bosheit („ <i>spite</i> “), Rachsucht („ <i>vengefulness</i> “), Abneigung („ <i>dislike</i> “), Verbitterung („ <i>resentment</i> “)
	Ekel („ <i>disgust</i> “)	Ekel („ <i>disgust</i> “), Abscheu („ <i>revulsion</i> “), Verachtung („ <i>contempt</i> “)
	Neid („ <i>envy</i> “)	Neid („ <i>envy</i> “), Eifersucht („ <i>jealousy</i> “)
	Qual / Schmerz („ <i>torment</i> “)	Qual / Schmerz („ <i>torment</i> “)
<b>Trauer („<i>Sadness</i>“)</b>	Leid („ <i>suffering</i> “)	Heftiger Schmerz („ <i>agony</i> “), Leid („ <i>suffering</i> “), Verletzung („ <i>hurt</i> “), Schmerz („ <i>anguish</i> “)
	Trauer („ <i>sadness</i> “)	Niedergeschlagenheit („ <i>depression</i> “), Verzweiflung („ <i>despair</i> “), Hoffnungslosigkeit („ <i>hopelessness</i> “), Düsterei („ <i>gloom</i> “), Trostlosigkeit („ <i>glumness</i> “), Trauer („ <i>sadness</i> “), Unglücklichkeit („ <i>unhappiness</i> “), Kummer („ <i>grief</i> “), Trauer („ <i>sorrow</i> “), Not („ <i>woe</i> “), Elend („ <i>misery</i> “), Melancholie („ <i>melancholy</i> “)
	Enttäuschung („ <i>disappointment</i> “)	Bestürzung („ <i>dismay</i> “), Enttäuschung („ <i>disappointment</i> “), Missfallen („ <i>displeasure</i> “)
	Scham („ <i>shame</i> “)	Schuld („ <i>guilt</i> “), Scham („ <i>shame</i> “), Bedauern („ <i>regret</i> “), Reue („ <i>remorse</i> “)
	Vernachlässigung („ <i>neglect</i> “)	Entfremdung („ <i>alienation</i> “), Isolation („ <i>isolation</i> “), Vernachlässigung („ <i>neglect</i> “), Einsamkeit („ <i>loneliness</i> “), Ablehnung („ <i>rejection</i> “), Heimweh („ <i>homesickness</i> “), Niederlage („ <i>defeat</i> “), Niedergeschlagenheit („ <i>dejection</i> “), Unsicherheit („ <i>insecurity</i> “), Verlegenheit („ <i>embarrassment</i> “), Demütigung („ <i>humiliation</i> “), Beleidigung („ <i>insult</i> “)
	Sympathie („ <i>sympathy</i> “)	Mitleid („ <i>pity</i> “), Verständnis („ <i>sympathy</i> “)
<b>Angst („<i>Fear</i>“)</b>	Schrecken („ <i>horror</i> “)	Alarmiertheit („ <i>alarm</i> “), Schock („ <i>shock</i> “), Angst („ <i>fear</i> “), Schreck („ <i>fright</i> “), Horror („ <i>horror</i> “), schreckliche Angst („ <i>terror</i> “), Panik („ <i>panic</i> “), Hysterie („ <i>hysteria</i> “), Kränkung („ <i>mortification</i> “)
	Nervosität („ <i>nervousness</i> “)	Angst („ <i>anxiety</i> “), Nervosität („ <i>nervousness</i> “), Angespanntheit („ <i>tenseness</i> “), Unbehaglichkeit („ <i>uneasiness</i> “), Verständnis („ <i>apprehension</i> “), Sorge („ <i>worry</i> “), Bedrängnis („ <i>distress</i> “), große Angst („ <i> dread</i> “)

Tabelle 7: Taxonomie der Emotionen nach (Parrott, 2001a, S. 33–35)

Gemessen an der Vollständigkeit, übertrifft die Detaillierung alle hier erwähnten Ansätze. Sie ist so feingranular, dass sie sich nicht eindeutig in die deutsche Sprache überführen lässt. Auch bei diesem Modell lässt sich ein Überhang der negativen Emotionen erkennen.

### 2.3.2.15.2 Modellkritik

Als Kritik kann dem akribisch ausgearbeiteten Modell entgegengebracht werden, dass es sich um ein sprachenabhängiges Konstrukt handle. Dies wird umso deutlicher, je weiter die einzelnen Emotionen aufgegliedert werden. Beim Übersetzen ins Deutsche verschwimmen die von Parrott (2001a, S. 34f.) festgestellten Grenzen auf der dritten Ebene der Emotionen, wie dies exemplarisch an den Termen Ärger > Wut > Verachtung („*scorn*“) und Ärger > Ekel > Verachtung („*contempt*“) deutlich wird. Hurtado-de-Mendoza et al. (2012) haben in englisch-spanischen Vergleichsstudien zwischen den Emotionsbegriffen Scham („*shame*“) und

Schande / Scham („*vergüenza*“) bewiesen, dass diese von zweisprachigen Personen nicht zwangsläufig als semantisch äquivalent angesehen wird. Die Probleme der Übersetzung sind dem Autor durchaus bewusst (Crystal, Parrott, Okazaki & Watanabe, 2016).

Die Eingliederung der Emotionen stellt sich nicht unproblematisch dar. Dieser aufgefächerte Ansatz bietet zwar eine große Detailstufe, doch die Zuordnung und Aufteilung würde nicht unbedingt von jedem in gleicher Weise vorgenommen werden. Es ist sogar so, dass Emotionstaxonomien sich kulturell oder sprachlich wesentlich voneinander unterscheiden können (Gordon, 1981; Hochschild, 1979).

Parrott (2001b) räumt ein, dass die konstruierten Emotionskonzepte der Wissenschaft nicht zwangsläufig mit dem gängigen Verständnis des sprachlichen Pendant übereinstimmen. Kritisch betrachtet, steht dies der Ansicht von Emotionsforschern wie Shaver et al. (1987) entgegen. Wenn von der Wissenschaft gefundene Emotionskategorien unter dem sprachlich üblichen Label nicht mit dem Alltagsverständnis der Menschen vereinbar sind, so birgt das Akzeptanzprobleme. Parrott (2001b) führt diesen Mangel auf den Umstand zurück, dass Sprachen nicht immer imstande sind, Emotionen in Worte zu kleiden. Als Beispiel führt er das deutsche Wort „schadenfreude [sic]“ an, zu dem es kein sinngleiches englischsprachiges Gegenstück gibt, weswegen er zu dem einfachen Ergebnis kommt, dass „*the correspondence between our language and our experience is imperfect*“ (Parrott, 2001b, S. 384).

### 2.3.2.15.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Die erste Ebene fußt auf dem Modell von Shaver et al. (1987). Da sich der theoretische Unterbau zum Vorgängermodell nicht ändert, sondern darüber hinaus nur ein weiterer, sinnvoll nutzbarer Detaillierungsgrad eingefügt wurde, stellt dieses Modell eine Ergänzung dar.

Folgt man der Modellidee buchstabengetreu, so ist eine Realisierung nur unter großem Aufwand möglich. Eine Emotionsklassifikation auf tertiärer Ebene würde einen immensen Trainingskorpus benötigen und Annotatoren vor viele knifflige Differenzierungsfragen stellen. Zielführender wäre eine Klassifikation auf Basis der zweiten Hierarchiestufe. Diese ist immer noch feingliedriger, aber die zu findenden Emotionsgrenzen werden etwas deutlicher. Darüber hinaus könnten die Terme auf dritter Ebene als Schlüssel- und beschreibende Wörter genutzt werden, was sich, wie oben gezeigt, vorteilhaft für die Sentimentanalyse darstellt.

Wie aus der Kritik bereits ersichtlich wird, liegt bei diesem Modell die größte Schwierigkeit in der Abgrenzung der Emotionszustände. Beispielsweise liegen die Emotionen Leid, Trauer und Enttäuschung sehr nahe beisammen. Sprachlich werden diese sogar als synonym betrachtet (Dudenredaktion, o. J. e.).

Es gibt zahlreiche Emotionen, die im Textgebrauch sehr selten sind oder sich auch nicht direkt manifestieren. Dazu gehören Sympathie, wie in Kapitel 2.3.2.10.3 gezeigt, Neid, wie in Kapitel 2.3.2.5.2 erläutert, oder auch Schmerz und Vernachlässigung. Wie in den Ausführungen in Kapitel 2.3.2.4.3 erwähnt, unterliegt die lustvolle Begierde gesellschaftlichen Konventionen und ist folglich nur in speziellen Textformen bzw. -quellen zu finden.

Im Gegensatz zu Emotionsmodellen, bei denen nur Oberkategorien benannt und klassifiziert werden, ist die Existenz vieler Emotionsterme auf einer weiterführenden Ebene, bezogen auf die Übertragung zu anderen Sprachen, nicht unproblematisch. Durch die Vielzahl der verfügbaren Terme unterliegt die Güte der späteren Anwendung auch in vielen Stellen der Übersetzung, sofern sie in einer anderen als der Ursprungssprache geschieht. Dies liegt zum einen an der unterschiedlichen Konnotation von Emotionstermen, aber auch an sozial und kulturell unterschiedlich geprägten Emotionsverständnissen (Briggs, 1995). Einem übersetzten Modell subjektiver Sprache haftet somit stets der Makel einer möglichen Überschneidung und der Übersetzungsungenauigkeit der verwendeten lexikalischen Emotionsterme an. Daraus ergeben sich einige offene Fragen beim Umgang mit dem Modell. Soll jedes Wort nur mit einem einzigen Term übersetzt werden oder sollen alle synonymen Wörter verwendet werden? Was ist, wenn es für mehrere englische Terme nur eine deutsche Entsprechung gibt? Was ist, wenn ein Lexem ähnlich dem Beispiel der Übersetzung von Izards (1991) Modell in der Übersetzungssprache nicht zielführend, gängig oder gar ambivalent ist – soll dieses dann ausgetauscht werden? Muss die anderssprachige Version in Übereinstimmung mit anderen Beispielen der Modellübersetzung (Merten & Krause, 1993; Ouss et al., 1990) erneut im Vorfeld getestet werden, da sonst die Gefahr besteht, dass man an Modellgüte einbüßt? Derartige Fragen müssen gesondert geklärt werden, sofern ein solches Modell Anwendung finden soll.

### **2.3.2.16 Schmidt-Atzert und Ströhme**

#### **2.3.2.16.1 Diskrete Emotionen, Vollständigkeit und Balance**

Ein Gefühl entspricht gemäß Schmidt-Atzert (1981) dem gängigen Alltagsverständnis eines menschlichen Zustands, das in seiner Qualität sprachlich benannt werden kann. Mittels gruppierter Listen der 56 Emotionswörter von Probanden und einer hierarchischen Clusteranalyse leiteten Schmidt-Atzert & Ströhm (1983) Emotionen ab, deren Zusammensetzung ohne konkrete Benennung der 14 Emotionskategorien in Abbildung 11 dargestellt wird.

In einer neueren Gegenüberstellung spricht sich (Schmidt-Atzert, 1996, S. 124) für die stabilen Emotionscluster „Angst, Unruhe, Ärger, Abneigung oder Ekel, Traurigkeit, Scham, Freude, Zuneigung, sexuelle Erregung und Überraschung“ aus.

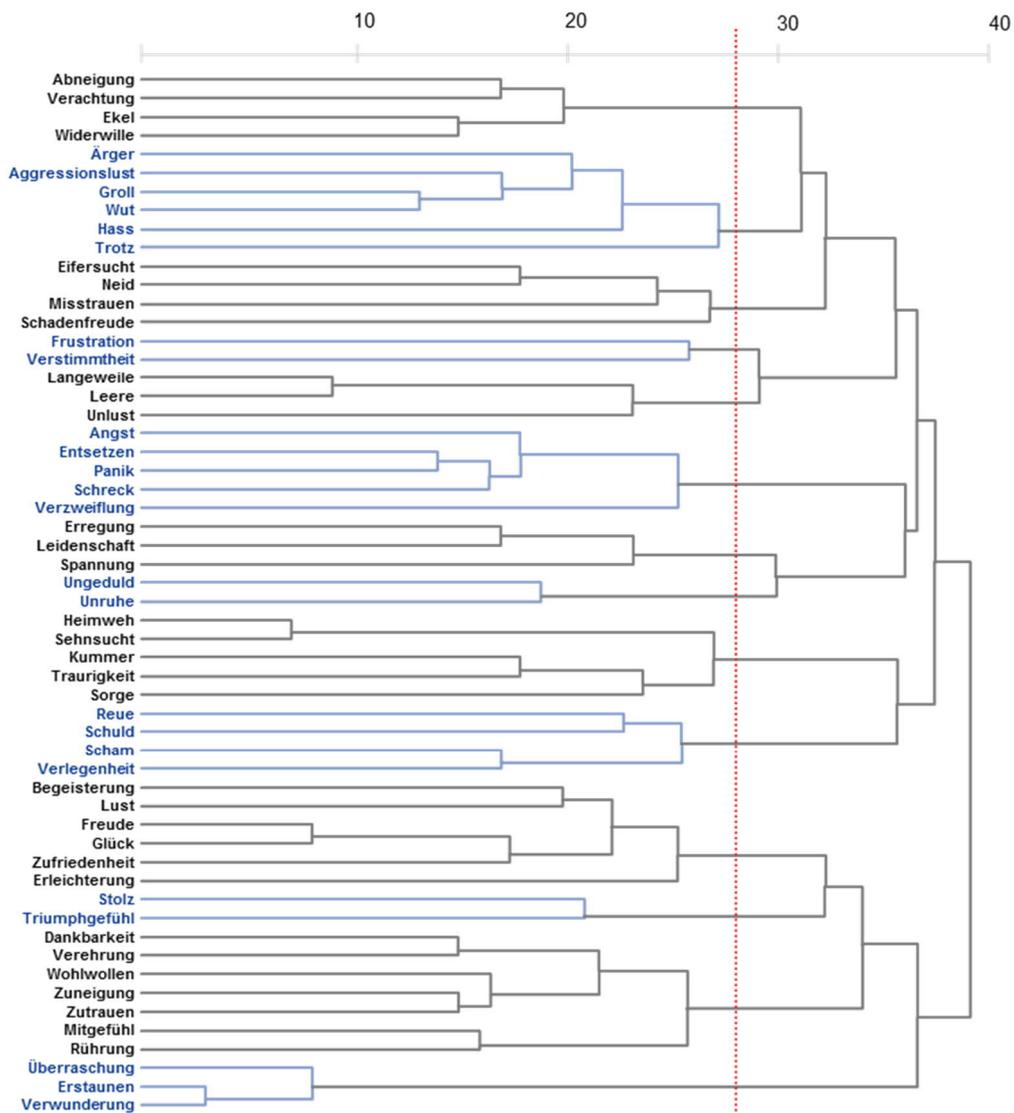


Abbildung 11: Emotionsclusterung durch sprachliche Zuordnung (nach Schmidt-Atzert & Ströhm, 1983)

Dieses Modell glänzt wie vorangegangene in dem Aspekt der Vollständigkeit. Die Liste der Emotionswörter und die 14 Emotionscluster decken ein breites Spektrum ab, was bereits auf der ersten Hierarchiestufe ersichtlich wird. Die Balance ist mit je zwei Dritteln Überhang der negativen Emotionen nicht erkennbar.

### 2.3.2.16.2 Modellkritik

Dem Experiment kann hinsichtlich der Methodik und der Einschränkung der Gültigkeit des Ergebnisses Kritik entgegengebracht werden. Traxel & Heide (1961) bezogen die Kritik zwar auf ihr eigenes Modell, aber der Einwand kann hier ebenfalls angeführt werden: Durch die Vorauswahl und das Zusammenfassen der Emotionswörter entsteht im Versuchsaufbau eine gewisse Verzerrung. Dies muss in Verbindung mit der Integration des valenzfreien

Überraschungszustandes betrachtet werden, was von Ortony & Turner (1990) als Emotionsqualität angezweifelt wurde und somit keine Emotion darstellen sollte.

Die Gültigkeit von linguistikbasierten Modellen unterliegt einer sprachlichen und kulturellen Bindung (Russell, J., 1991). Mayring (2003, S. 151) würdigt diesen Beitrag, da „der dort zugrunde gelegte Ansatz der Kombination empirischer Klassifikation mit theoretischer Analyse [...] heute am fruchtbarsten zur Differenzierung von Emotionen [erscheint]“. Die herausragende Akzeptanz zeigt sich auch darin, dass dieser Forschungsansatz den Grundstein für weitere Modelle dieser Art bildete.

Viele Argumente, die bei Shaver et al. (1987) und Parrott (2001b) in den beiden vorangegangenen Kapiteln erwähnt wurden, können hier wiederholt werden. Dies betrifft die Verfügbarkeit von exemplarischen Termen, die ausgeprägte Abdeckung verschiedenartiger Emotionen, die Beschränkung auf Substantive und die zugrunde liegende Validität, basierend auf empirischen Untersuchungen.

#### 2.3.2.16.3 Realisierbarkeit

Die deutschsprachigen Schlüsselwörter stimmen mit der hier verwendeten Zielsprache überein und bieten daher für diesen Anwendungsfall einen leichten Vorteil gegenüber fremdsprachlichen Modellen. Daher muss keine mit Ungenauigkeiten behaftete Übersetzung der Schlüsselwörter erfolgen.

Das Modell liegt unter den Ansätzen mit Schlüsseltermen im Mittelfeld. Dadurch, dass es viele Emotionscluster gibt und eine kleinere Auswahl an Emotionswörtern herangezogen wurde, bleiben oft nur zwei bis drei Beispielterme je Gliederungspunkt. Dieses Ungleichgewicht kann in der Realisierung Emotionen bevorteilen, zu denen mehrere Schlüsselwörter vorhanden sind und die nicht der natürlichen Emotionshäufigkeit entsprechen.

Unter den 14 Emotionen sind Unruhe und sexuelle Erregung in der Schriftsprache schwieriger auszumachen. Letzteres wurde bereits in Kapitel 2.3.2.4.3 erläutert. Sowohl Unruhe als auch Ungeduld, beides Schlüsselwörter der Emotion Unruhe, sind von Charaktereigenschaften nur schwer zu differenzieren. Sofern eine Person unruhig ist, manifestiert sich dies nur selten in sprachlichen Äußerungen. Somit werden weniger Treffer dieser Emotion erwartet als tatsächliche Vorkommnisse.

Durch die Vielzahl der Kategorien werden Hürden bei der Umsetzung geschaffen. Die Grenzen der Emotionen verschwimmen, wie beispielsweise bei Frustration, Verstimmtheit und Langeweile, Leere sowie Unlust, die sich jeweils in unterschiedlichen Cluster befinden.

Mit der Menge der Emotionen vergrößert sich der Annotationsaufwand, da für alle Emotionen ausreichend Datensätze für eine computerlinguistische Emotionserkennung von Nöten sind.

### 2.3.2.17 Mayring

#### 2.3.2.17.1 Diskrete Emotionen und Vollständigkeit

Mayrings (2003) Abgrenzungsmodell der Emotionen entwickelt die empirische Untersuchung von Schmidt-Atzert & Ströhm (1983) theoretisch weiter. Dabei nimmt Mayring (2003) eine Gruppierung der herausgearbeiteten Emotionen vor, die er in „Zuneigungsgefühle, Abneigungsgefühle, Wohlbefindensgefühle und Unbehagensgefühle“ unterteilt. You (2001) arbeitete in der ersten Ausgabe des Emotionslehrbuchs von Ulich & Mayring (1992) noch 24 Emotionen unter demselben Gliederungsschema heraus. In der überarbeiteten Auflage von Ulich & Mayring (2003) reduzierte Mayring (2003) die Liste auf 18 differenzierbare Emotionen. Dabei wurden die Zustände Mitgefühl, Hoffnung / Sehnen, Verachtung, Hass, Erleichterung / Entspannung sowie Trauer / Kummer / Wehmut aus dem Inventar gestrichen. Die resultierende Liste der abgrenzbaren Emotionen ist in Tabelle 8 zu finden.

Zuneigungsgefühle	Liebe, Sympathie, Bindungsgefühl	Wohlbefindensgefühle	Lustgefühl, Genuss erleben
	Stolz, Selbstwertgefühl		Freude
	(positive) Überraschung, Schreck		Zufriedenheit
Abneigungsgefühle	Ekel, Abscheu	Unbehagensgefühle	Glück
	Ärger, Wut, Zorn		Niedergeschlagenheit, Missmut
	Angst, Furcht		Schamgefühl
	Eifersucht		Schuldgefühl
	Neid		Langeweile, Müdigkeit, Leere
			Anspannung, Nervosität, Unruhe, Stress
			Einsamkeitsgefühl

*Tabelle 8: Emotionsgruppen nach (Mayring, 2003, S. 151)*

Die Kategorisierung der theoretischen Ausarbeitung der Emotionen auf der zweiten Gliederungsstufe weist eine vergleichbare Bandbreite auf wie die hierarchischen Emotionsclusteransätze. Die oberste Ebene besitzt zudem die Charakteristik zweier sich gegenüberstehender Emotionskategorien. Darüber hinaus zeigt das Modell im Vergleich zu den meisten anderen bisher genannten Ansätzen eine relative Ausgeglichenheit positiver und negativer Emotionsqualitäten. Auf der zweiten Ebene zeichnet sich ein Übergewicht der negativen Emotionen ab.

#### 2.3.2.17.2 Modellkritik

Die Theorie wurde noch nicht geprüft, fußt aber auf einer empirischen Untersuchung. Darüber hinaus wurden die abzugrenzenden Emotionen in den folgenden Kapiteln des Buches von Ulich & Mayring (2003) minutiös herausgearbeitet, was die Kriterien des subjektiven

Erlebens sowie der Sachlage, in der das Gefühl auftritt, betrifft. Ferner wird dem Kritikpunkt der Vermengung der Basisemotionen Rechnung getragen, da dies mit der Emotionsdefinition ausdrücklich nicht Bestandteil dieses Theorieverständnisses ist.

Dieser Ansatz berücksichtigt aktuelle Kritikpunkte unterschiedlicher Strömungen in der Emotionsforschung. Dennoch ist dieses Klassifikationsschema nach den gleichen Gesichtspunkten zu bemessen wie die vorangegangenen. Eine Validität der Klassifikation sollte durch eine empirische Beweisführung untermauert werden. Dies gilt umso mehr für die Zugehörigkeit der einzelnen Emotionen zu zusammengefassten Gruppen. Die Ergänzung von Theorie und angewandter Empirie stellt Mayring (2003) selbst als erfolgversprechendste Herangehensweise hinsichtlich der Gliederung der Emotionen heraus.

#### 2.3.2.17.3 Realisierbarkeit

Für die Untersuchung deutscher Texte gibt es keine Sprachbarrieren. Somit entfallen Übersetzungsproblematiken und -fragen, wie bei dem Modell von Parrott (2001b).

Einige Emotionen sind in sprachlichen Repräsentationen selten oder nur in bestimmten Texten vertreten. Darunter fallen unter anderen die bereits oben angesprochene Lust oder die Eifersucht. Letztere entzieht sich einer breiten Textdurchdringung. Für die Umsetzung einer Sentimentanalyse setzt dies die Inklusion spezieller Texte voraus, da dies ansonsten zu einer Unterrepräsentation oder Nichtdarstellung dieser Emotionen führen kann.

Die unterschiedliche Häufigkeit der Emotionsterme je Emotionsgruppierung benachteiligt Gruppen mit weniger Termen. Ähnlich wie beim vorangegangenen Emotionsmodell stellt dies eine Verzerrung dar, die nicht mit der tatsächlichen Emotionshäufigkeit der vorkommenden Emotionstermen übereinstimmt.

Die Anzahl der Emotionen vergrößert den Aufwand bei der Annotation. Um ausreichend Textpassagen für eine maschinelle Klassifikation zur Verfügung zu haben, müssen für Ansätze mit feinerer Granulierung mehr Datensätze annotiert werden.

Die dritte Stufe ist nur als Fließtext verfügbar. Dies stellt für die Annotation einen Vorteil dar, da Emotionen anhand konkreter Beschreibungen definiert werden. In der Beschreibung werden Emotionen auch klar gegen andere abgesteckt, was einer scharfen Abgrenzung entspricht. Andererseits bedarf es zusätzlichen Aufwands, um den Text für die maschinelle Nutzung zu erschließen – sei es durch das Herausarbeiten von Schlüsselwörtern oder durch das Umsetzen der dezidierten Vorgaben.

## 2.3.2.18 Ortony, Clore und Collins

### 2.3.2.18.1 Diskrete Emotionen und Vollständigkeit

Ortony et al. (1988, S. 13) Verständnis von Emotionen ist, dass es sich dabei um „*valenced reactions to events, agents, or objects*“ handle, also um eine Bewertung der Wahrnehmung hinsichtlich Ereignissen, Personen oder Objekten. Emotionszustände können anhand linguistischer Evidenzen, mittels festgehaltener Selbstberichte, an Verhaltensänderungen oder an physischen Reaktionen festgemacht werden. Jedoch liefern Ortony et al. (1988, S. 190) nur ein theoretisches Konstrukt, indem sie einräumen, dass „*we [the authors] have not attempted to review either the theoretical or empirical literature on emotion. Nor have we focused on any of the research designed to test the proposals we have discussed*“. Das Ergebnis des strukturellen Konstrukts von Ortony et al. (1988) sind 22 diskrete Emotionstypen. In Abbildung 12 und Abbildung 13 wird die Struktur von Ortony et al. (1988) aufgeschlüsselt.

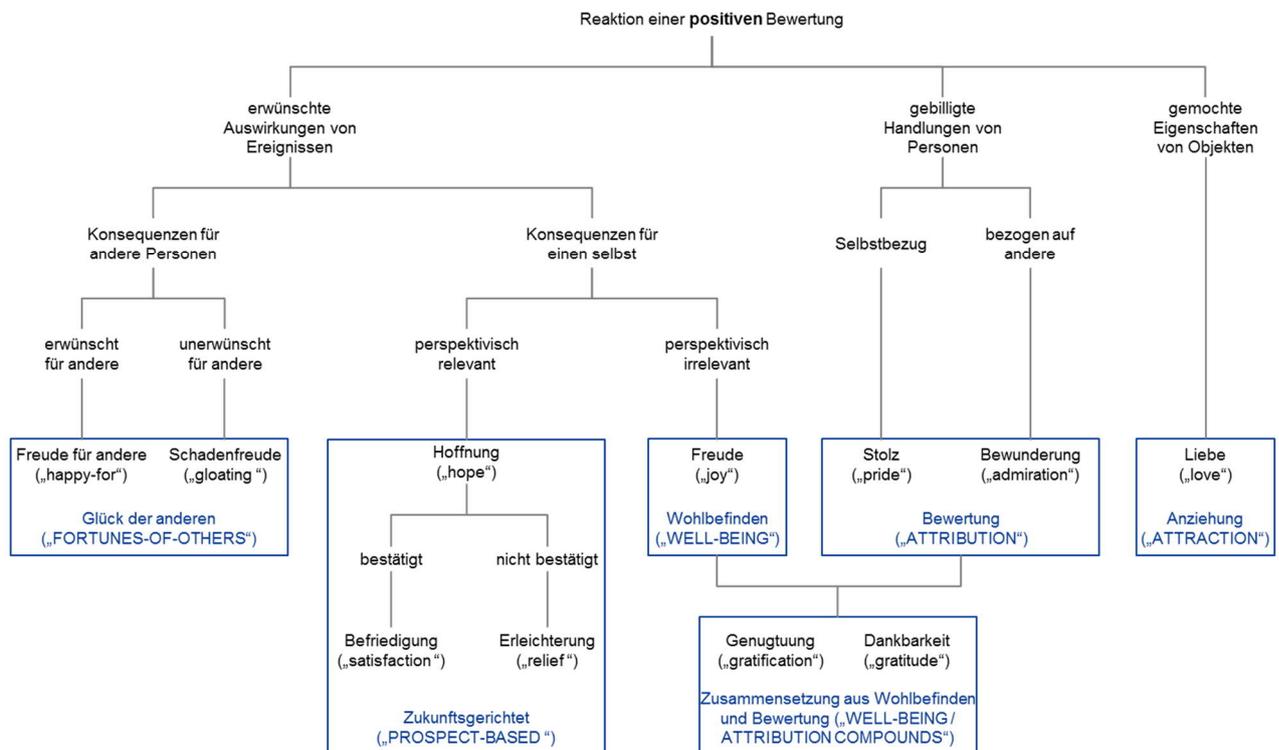


Abbildung 12: Struktur der Emotionen einer positiven Bewertung (nach Ortony et al., 1988)

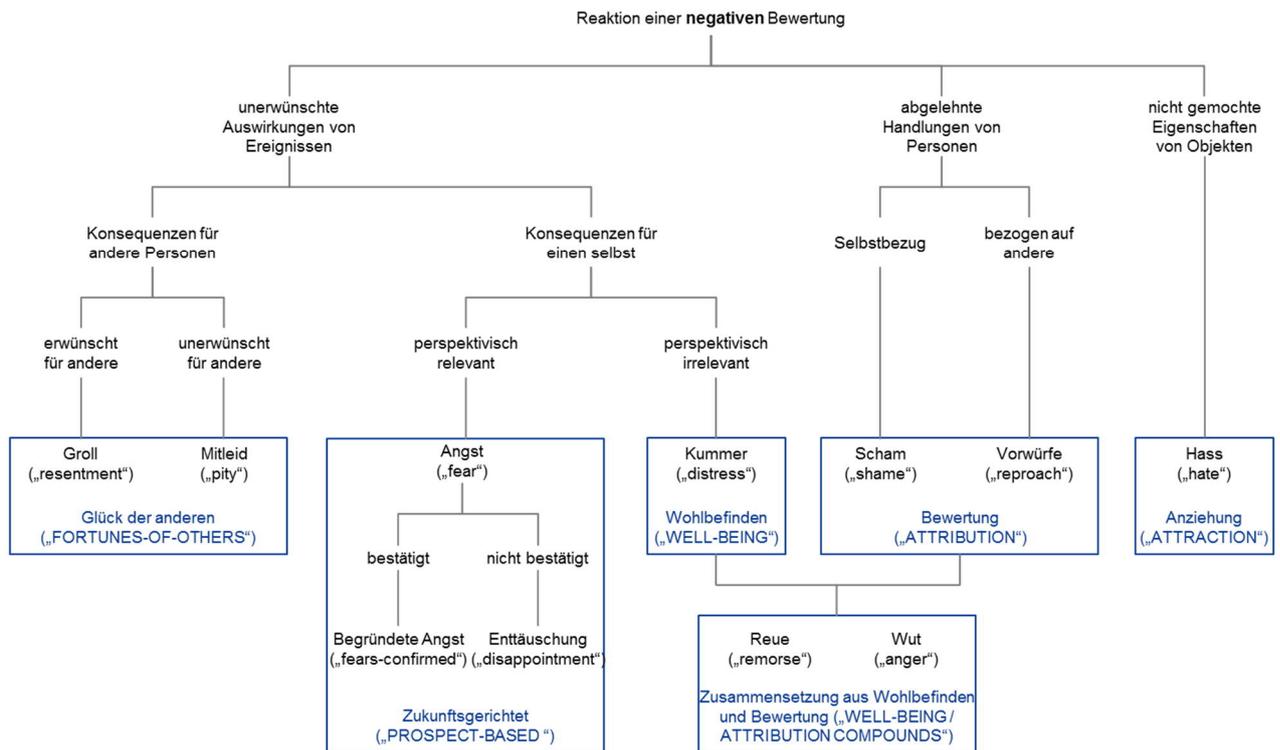


Abbildung 13: Struktur der Emotionen einer negativen Bewertung (nach Ortony et al., 1988)

Diese Emotionsstruktur besitzt neben der Einteilung in positiv und negativ keine hierarchische Gliederungsstruktur, wenngleich es Gruppierungen gibt, die als solche verstanden werden können. Dieses Emotionsmodell ist bezüglich der Vollständigkeit im oberen Drittel zu verorten. Auch in dem Punkt Balance setzt dieses Modell neue Maßstäbe, da es trotz der Fülle der Emotionszustände ausgeglichen ist.

### 2.3.2.18.2 Modellkritik

Ortony et al. (1988) übten an ihrem theoretischen Konstrukt Selbstkritik, was die semantische Repräsentation der Emotionskonzepte, die nicht wahrgenommenen oder unterbewusste Bewertungsfunktion, kognitive Bewältigungsmechanismen von Emotionen oder die computerbasierte Nachvollziehbarkeit der Emotionszustände betrifft. Emotionskonzepte können nur bedingt sprachlich wiedergegeben werden. Sprachübergreifend gibt es große Unterschiede, um Emotionstypen semantisch zu charakterisieren und affektierte Zustände zu benennen. So räumen die Autoren ein, dass „*some [emotion types] (e.g., DISPLEASED ABOUT THE CONFIRMATION OF THE PROSPECT OF AN UNDESIRABLE EVENT) have no English words associated with them*“ (Ortony et al., 1988, S. 172).

Etwas konkreter wird Mees (1991), der an dem Abhängigkeitsmodell von Ortony et al. (1988) inhaltliche Kritik übt. Dies soll jedoch an dieser Stelle nicht weiter ausgeführt werden, da die Einwände von Mees (1991) zum Emotionsmodell im folgenden Kapitel führen.

### 2.3.2.18.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Für die Realisierung wartet diese Theorie für jeden Emotionstypus mit einer unterschiedlichen Anzahl von Schlüsselwörtern auf. Diese Listen reichen von mehreren Exemplaren bis hin zu einem einzelnen Token oder enthalten gar keine Wörter. Wie bereits herausgearbeitet wurde, ist dies für die Sentimentanalyse von Vorteil, da diese direkt beispielsweise in einen wortbasierten Ansatz überführt werden können.

Auch in diesem Modell gibt es Emotionen, die nur in bestimmten Texten vorkommen, und solche, bei denen die inhaltlichen Grenzen eng gesteckt sind. Es gibt eine Reihe von Zuständen, die sich nur unter Einbezug des Kontexts definieren lassen. Dazu gehören die ungerichtete Freude, Freude für andere und Schadenfreude. Hierfür muss in der Sentimentanalyse zusätzlich das Ziel der Emotion erkannt werden. Darüber hinaus muss ergründet werden, ob es eine Freude darüber ist, dass jemandem ein Unrecht, ein Ungeschick oder etwas Missliches geschieht, oder ob es sich um einen positiven Aspekt handelt. Zum anderen muss zwischen generischer Angst und begründeter Angst entschieden werden. Dies zu bewerkstelligen, ist nicht trivial. In ähnlicher Manier stellen sich Mitleid und Kummer dar, deren Unterscheidung auch von dem Bezug abhängig ist. Wie bereits gezeigt, ist Stolz eine Emotion, die nicht zu Schau gestellt wird und daher nur in ausgewählten Texten vorkommt. Wut und Groll, Kummer und Enttäuschung sowie Genugtuung und Schadenfreude liegen nahe beisammen. Eine Abgrenzung mag unter Umständen schwierig zur realisieren sein. Die Fülle an Emotionen und die teils kontextbedingte Differenzierung setzen einen gesteigerten Annotationsbedarf voraus. Wie bereits erläutert, bedarf es für die Klassifikation der Emotionen einer großen Menge annotierter Datensätze. Diese wachsen proportional mit der Anzahl der Emotionen an.

Um es für eine losgelöste Klassifikation von Emotionen zu verwenden, gehört zu den Vorbedingungen des Modells jedoch eine dedizierte Bezugssystemerkennung der Emotionen, die gewissermaßen das Ziel erkennt, worauf sich eine einzelne Emotion richtet. Diese bieten, wie Rübenstrunk (1998) herausarbeitet, Referenzmarker für Ereignisse, Personen bzw. Agenten oder Gegenstände bzw. Objekte. Letzteres ließe sich beispielsweise mittels einer *Named-Entity-Recognition* realisieren (Jurafsky & Martin, 2017; z.B. Krishnan & Ganapathy, 2005).

Das Modell besitzt eine eingeschränkte Abgrenzbarkeit der Emotionen. Einerseits verweisen die Grenzen zunehmend mit der Menge an Emotionen, wie bereits bei anderen Modellen mit einer großen Bandbreite. Andererseits räumen die Ersteller dieses Modells selbst ein, dass *„[w]ithout the benefit of empirical data, we have distributed about 130 tokens between 22 emotion types. In doing this, we did not feel compelled to assign each token to only one*

emotion type” (Ortony et al., 1988, S. 173). Dies könnte sich in der Realisierung als problematisch herausstellen, sofern diese Annahme zutrifft.

Diese Ambivalenz, also die Zuordnung eines Emotionswortes in mehrere Kategorien kann gleichsam als Gegenargument für dieses Modell angeführt werden. Letzteres deutet auf gewisse Ungenauigkeiten bei der Abgrenzung der Emotionstypen hin.

#### 2.3.2.18.4 In Verwendung

Unter der Voraussetzung bestimmter Vorbedingungen ist dieses Modell prädestiniert für computergestützte Anwendungen. Dies ist der Fall, da das Emotionsmodell in der Struktur eines Entscheidungsbaums aufgebaut ist. Ortony et al. (1988, S. 2) heben den Nutzen für computerbasierte Anwendungszwecke besonders hervor, indem sie ein theoretisches Emotionsmodell schaffen, „that could in principle be used in an Artificial Intelligence (AI) system that would, for example, be able to reason about emotions“.

#### 2.3.2.19 Mees

##### 2.3.2.19.1 Diskrete Emotionen und Vollständigkeit

Mees (1991) Modell stellt eine Umsetzung der inhaltlichen Kritik und Abgrenzung zu Ortony et al. (1988) dar. So wurden neben bedingungsanalytischen Anpassungen weitere inhaltliche Änderungen vorgenommen (Bergknapp, 2002). Emotionen aus dem Ursprungsmodell wurden ausgetauscht bzw. abgeändert. In den folgenden zwei Abbildungen sind das Strukturmodell und die 23 diskreten Emotionen von Mees (1991) detailliert dargestellt.

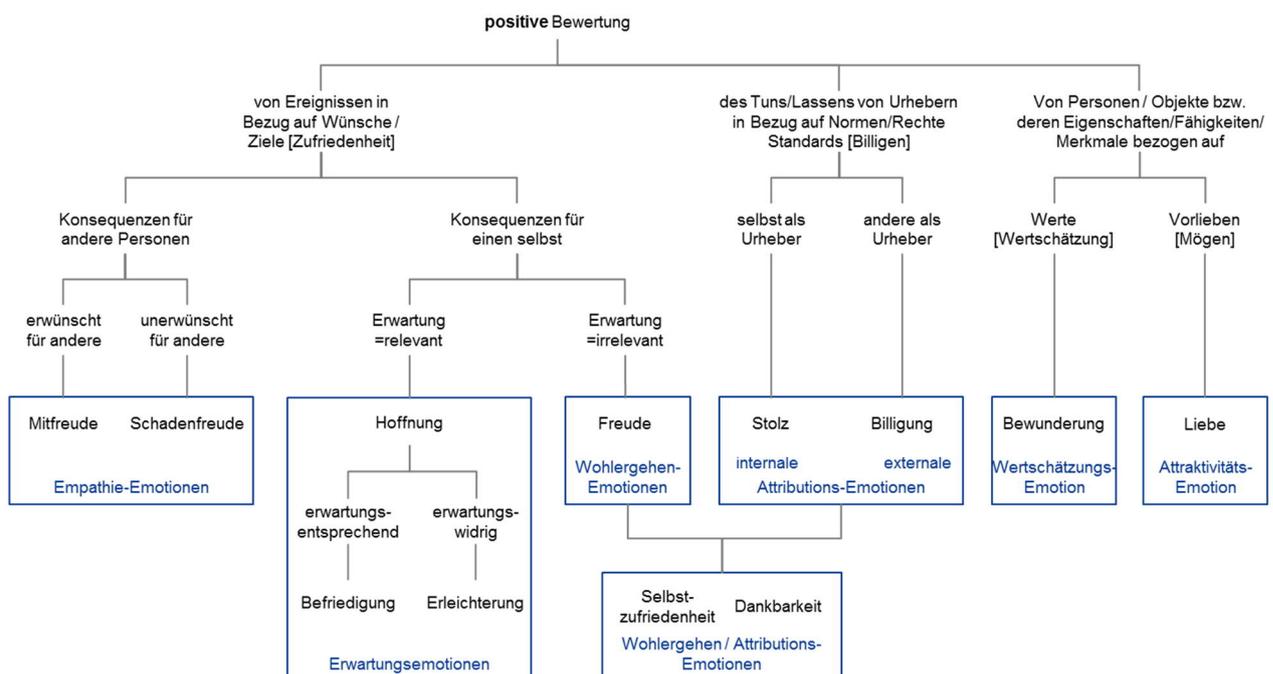


Abbildung 14: Positive Bewertungsschema der Emotionen nach Mees (1991)

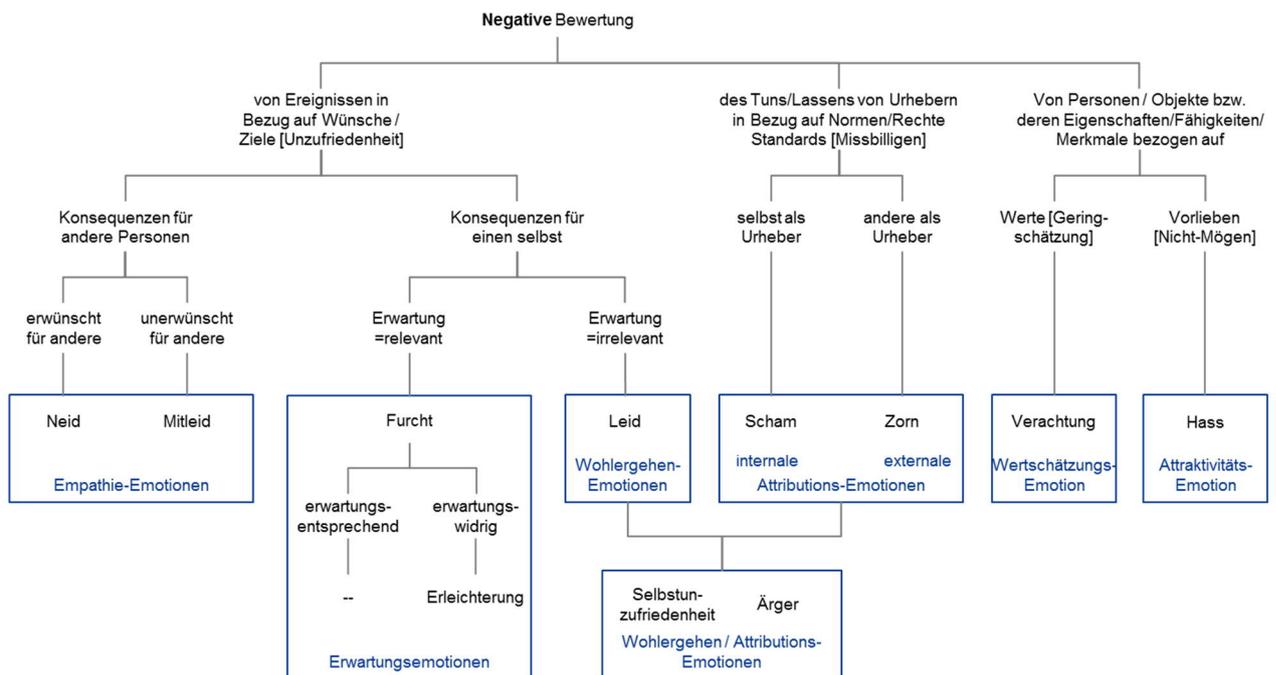


Abbildung 15: Negatives Bewertungsschema der Emotionen nach Mees (1991)

Auch hier kann, bezogen auf die Vollständigkeit, die Balance und die Struktur in Entscheidungsbaumform, auf das vorangegangene Modell verwiesen werden, da dieses eine Ableitung des letzten darstellt. Das Modell ist unter den vorgestellten Ansätzen eines der ausgeglicheneren und vollständigsten.

### 2.3.2.19.2 Modellkritik

Gundermann (2001, S. 16) gibt bezüglich des Modells von Mees zu bedenken, dass „eine Strukturierung der außersprachlichen Wirklichkeit [...] subjektiven Kriterien [unterliegt]“. Demnach kann es zwangsläufig kein allgemeingültiges Emotionschema geben. Als Modellkritik kann angeführt werden, dass es sich von einem rein theoretischen Ansatz ableitet. Folglich muss sich dieses Schema, auch mit Hinblick auf die Komplexität und die Abhängigkeiten, in einer genauen empirischen Überprüfung beweisen. Dieses Emotionsmodell findet insbesondere in der Linguistik großen Anklang und wird als ein valider Ansatz zur Erfassung von Emotionen in Texten angesehen (Jahr, 2000; Ortner, 2014).

### 2.3.2.19.3 Realisierbarkeit und umsetzungsbedingte Implikationen

Da Parallelen zu dem vorangegangenen Modell gezogen werden können, wird hier explizit nur auf die Unterschiede eingegangen. Die Deckung der in der Theorie verwendeten Sprache mit dem Zielkorpus ist dabei vorteilhaft. Außerdem wurde das Modell um zwei schwierig zu differenzierbare Emotionspaare erweitert: Sowohl Hass und Verachtung als auch

Bewunderung und Liebe sind zwei Vertreter, die nur anhand ihrer Intensität und marginal unterschiedlichen Qualität unterschieden werden können. Bei unklarer textueller Formulierung setzt dies Kontextinformationen oder Wissen über die persönlichen Vorstellungen des Autors voraus. Dies dürfte sowohl in der Annotation als auch in der Klassifikation diffizil werden.

Wie im Emotionskonstrukt von Ortony et al. (1988) gibt es auch in diesem Ansatz das Problem der gegenseitigen Abhängigkeiten der Verbindungseemotionen. Dies ist bei Mees (1991) umso gravierender, als zusätzliche kombinierte Emotionen existieren, die bis zu drei verschiedene Emotionen betreffen. Letzteres trifft auf die Emotionsqualität Eifersucht zu.

Auch Mees (1991) gibt in seinem Emotionsmodell unterschiedliche Emotionsbeispiele vor, die sich auf Adjektive, Substantive und wenige ausgewählte Phrasen beziehen. Ähnlich wie bei Ortony et al. (1988) gibt es bei den Termen eine Überschneidung, so dass sieben Emotionsterme in mindestens einer weiteren Kategorie vorkommen. Aus diesem Grund empfiehlt es sich, bei der Kategorisierung der Emotionserkennung ebenfalls weiche Grenzen zu verwenden, um Inkonsistenzen von vornherein auszuschließen.

## **2.4 Fragestellungen und offene Punkte in der Emotionsforschung**

An der Fülle der vorgestellten Emotionsmodelle und an der Divergenz, welcher Zustand bzw. welche Zustandsveränderung letztendlich als Emotion gewertet werden dürfen, wird ersichtlich, wie komplex die maschinelle Emotionserkennung ist. Anhand der theoretischen Auseinandersetzung mit den Emotionsmodellen und dem Einbezug der Kritiken werden nun die drei folgenden offenen Punkte oder Fragestellungen herausgearbeitet: Welche Emotionen gibt es? Wie strukturieren sich die Emotionen? Wie kann man Emotionen bestimmen?

Die erste Frage zielt darauf ab, was alles als Emotion gewertet werden darf bzw. wie ein vollumfängliches Emotionsmodell aussieht. In dieser Arbeit wird sich nicht angemaßt, eine Antwort darauf zu geben, da diese in über einhundert Jahren Emotionsforschung nicht gefunden wurde. Aber es kann ein Schritt in die Richtung der Vollständigkeit gegangen werden, indem ein Emotionsmodell angewendet wird. Es sei jedoch nachdrücklich betont, dass die Auswahl eines Modells für die feingranulare Sentimentanalyse nichts über dessen Richtigkeit oder allgemeingültigen Vorzug gegenüber anderen Modellen ableiten lässt. Es stellt eine empirische Anwendung eines gut für die Emotionserkennung geeigneten Modells dar.

Die zweite Frage der Struktur ist trotz ihrer Kürze äußerst vielschichtig. Einerseits gilt es zu eruieren, ob Emotionen in Abhängigkeit zueinander stehen. Dies kann sich beispielsweise durch konträre Emotionspaare manifestieren, wenn die Negation der einen Emotionen zu einer anderen führt. Ein weiteres Beispiel wäre die Vermengung von Emotionen, wie dies

ursprünglich bei Sekundäremotionen angedacht war. Andererseits steht die unausgesprochene Frage der Struktur der Emotionen im Raum, unabhängig davon, ob der dimensionale oder diskrete Ansatz vorliegt. Bilden die Emotionen voneinander losgelöste, nicht verbundene und singuläre Konstrukte, stellen sie sich als unterschiedlich starke Ausprägung ein und derselben Emotionsrichtung dar oder fügen sie sich in ein geordnetes System oder gar eine Hierarchie ein? Hier schließt sich die Frage an, wie fein sich Emotionen anhand einer inhaltlichen Granularität differenzieren lassen. Allen Ansätzen ist gemein, dass sie versuchen, Emotionen gegeneinander abzuwägen, sie zu verorten und zu bündeln, wo es kausal begründbar ist. Während die erste der offenen Emotionsfragen auf die Breite des Emotionsmodells abzielt, rückt bei dieser übergeordneten Frage die Tiefe in den Vordergrund, sei es aus Nachvollziehbarkeits- oder Machbarkeitsaspekten.

Die letzte Frage bezieht sich auf die Umsetzung. Dies ist gleichzeitig einer der markantesten Punkte, anhand dessen man die gelisteten Modelle unterscheiden kann. Wird induktiv oder deduktiv an die Emotionsbestimmung herangegangen? Bezüglich der Bestimmung gibt es die unterschiedlichen Verfahrensweisen. Sei es durch die Beobachtung von Mimik oder Verhalten, das Ermitteln von Gehirnzuständen oder die sprachliche Annäherung. Es ist noch nicht geklärt, welche diese Methoden am zielführendsten ist bzw. sein wird. Während Gesichtsausdrücke an vielen Stellen zu kurz greifen, lassen neuronale Einblicke aufgrund des derzeitigen technischen Reifegrads noch viel Raum für eine genauere Emotionsermittlung. Eine Emotionsbestimmung durch beobachtete Verhaltensweisen und eine sprachliche Eingrenzung muten aktuell noch am vielversprechendsten an. Diese Methoden stehen sich jedoch oft selbst im Weg, beispielsweise durch zu wenig Beobachtungsfälle bzw. annotierte Textdatensätze, also eine zu geringe oder fehlende empirische Basis. Aber auch kritisch beäugte Verfahren führen zu wissenschaftlichen Diskrepanzen, sei es durch Sortierverfahren oder zwanghaft konstruierter Modelle, um die Erwartungshaltung anderer Emotionsforscher zu treffen.

Es gibt vielversprechende Ansätze mit empirischer Untermauerung. Die Art und Weise der Herangehensweise ist nach wie vor ein offener Punkt. Mit Hinblick auf die zu verknüpfenden Forschungsfeldern und da die Bestimmung der Emotionen untrennbar mit der lexikalischen Greifbarkeit verbunden ist (Briggs, 1995), wird sich hier für den sprachlichen Ansatz ausgesprochen. Es ist nicht ausgeschlossen, dass zukünftige, neuronale Befunde zeigen werden, dass eine sprachliche Unschärfe vorliegt und eine benannte Emotion sich in zwei völlig unterschiedliche zerebrale Zustände differenzieren lässt. Insofern ist es als offener Punkt zu nennen, ob nur eine methodische Herangehensweise letztendlich zur Bestimmung der Emotionen führen kann oder dies nur ein methodenübergreifender Ansatz vermag.

Wie lässt sich dieser Beitrag in die Klärung der Fragestellungen eingliedern? In erster Instanz wird herausgearbeitet, inwiefern die Emotionsforschung von der Computerlinguistik und dem Anwendungsfall der Sentimentanalyse profitieren kann. Mit Hinblick auf die hier untersuchten und vorgestellten Emotionsmodelle wird ein Ansatz ausgewählt und angewendet, der besonders gut für die maschinelle Emotionsdetektion geeignet ist. Die erste Fragestellung bleibt somit unbeantwortet, da kein neues und somit vollumfänglicheres Emotionsmodell generiert wird. In dem Kontext der ganzheitlichen Sentimentanalyse, bei der von null anfangend ebenfalls die Annotation der Textdaten nach computerlinguistischen Gesichtspunkten durchgeführt wird, soll subsequent auf die Beantwortung der zweiten und dritten Frage eingegangen werden. Dem ausgewählten Emotionsmodell soll, entsprechend der zweiten Fragestellung, anhand der forschungsfeldübergreifenden Methode eine tiefere Struktur verliehen werden. An den dritten offenen Punkt wird deterministisch herangegangen, da die Verknüpfung mit der Computerlinguistik eine textbasierte Anwendung der Emotionen bedingt.

## **2.5 Auswahl eines geeigneten Emotionsmodells**

### **2.5.1 Emotionstheorien im Überblick**

Bevor geeignete theoretische Konstrukte für eine feingranulare Sentimentanalyse ausgewählt werden, sollen die hier vorgestellten theoretischen Ansätze nochmals tabellarisch zusammengefasst werden. Dabei finden sich die eingangs in den Kapiteln 2.3.1 und 2.3.1 definierten Bewertungskriterien wieder. Da die Definition der Bemessungskriterien bereits stattgefunden hat, werden lediglich Validität und Realisierbarkeit nochmals herausgegriffen. Beide werden von einer detaillierten Beschreibung auf jeweils einen einzelnen Wert auf der ordinalen Skala reduziert. Die Abstufungen der Skalen bedürfen dabei einer Erläuterung.

Das Kriterium der Validität wird nochmals aufgegriffen, um die hier verwendeten Bewertungsabstufungen umstritten, nicht falsifiziert und Verifizierung ausstehend zu erläutern. Wird einer Theorie ein höheres Maß an Kritik oder ein deutlicher Einwand entgegengebracht, so wird sie hier als umstritten gekennzeichnet. Wurde auf eine Theorie zur Einteilung der Emotionen im wissenschaftlichen Diskurs kritisch Bezug genommen oder gibt es methodische Ungereimtheiten, aber zum aktuellen Zeitpunkt keine vernichtenden Gegenstimmen zur Theorie bzw. wird ein Emotionsansatz durch eine stichhaltige empirische Untersuchung untermauert, so wird der Ansatz als noch nicht falsifiziert eingestuft. Dies entspricht in der hier vorgenommenen Einschätzung der besten Bewertung. Abschließend wird noch eine Bewertungskategorie eingeführt, die ein Emotionsmodell benennt, dessen Überprüfung noch nicht

stattgefunden hat oder zum derzeitigen Forschungsstand nicht möglich ist. Diese Kategorie wird als Verifizierung noch ausstehend umschrieben.

Das Kriterium der Realisierbarkeit wird in fünf Stufen unterteilt. Die Skala fängt mit der Einteilung kaum Schwierigkeiten an. Gefolgt wird diese Abstufung von der Eingliederung leichte Schwierigkeiten, was auf erste Hindernisse hinweist. Bei mittleren Schwierigkeiten kommen entweder Implikationen in der Umsetzung dazu oder eine gesteigerte Komplexität. Die Einteilung erhebliche Schwierigkeiten deutet auf einen sehr hohen Komplexitäts- oder Aufwandsgrad hin. Letztere wird auch zugewiesen, wenn deutliche Diskrepanzen in der Umsetzung erkannt wurden. Die abschließende Kategorie läuft unter der Bezeichnung kaum möglich, wenn nahezu ausgeschlossen ist, dieses Modell vollumfänglich umzusetzen. Es wird an dieser Stelle darauf hingewiesen, dass es durch die Abstraktion sowohl der Validität als auch der Realisierbarkeit an einer Trennschärfe mangelt. Für eine belastbare Einschätzung wird auf die obigen, detaillierten Ausführungen verwiesen.

Ergänzt werden die Bewertungskriterien durch zusätzliche Informationen. Dies können allgemeine Punkte sein, die sowohl für den dimensionalen Aspekt gelten, wie beispielsweise die Frage nach existenten Anwendungen. Das Merkmal in Anwendung führt an, ob dieser Theorieansatz bereits in einer sentimentanalytischen Applikation benutzt wird oder ob es einen anderen computergestützten Anwendungsfall gibt. Obwohl es ein rein deskriptives Merkmal ist, kann es eine praktische Implikation haben. Sofern ein Ansatz in Anwendung ist, existieren gegebenenfalls exemplarische Ausführungen, die sich als Trainingsdaten oder Evaluationskriterien nutzen lassen. Weitere Ergänzungen betreffen Punkte bezüglich der dimensionalen Ansätze, wie die Art der Skalierung, die statistische Abhängigkeit oder exemplarisch abgetragene Emotionen. Die Skalierung der Achsen der dimensional Modelle bezieht sich darauf, ob die Achsen intervall-, ordinal- oder nominalskaliert sind. Die statistische Abhängigkeit greift nur die Ausnahmen heraus, bei denen keine statistische Unabhängigkeit angenommen wurde, also die Achsen nicht zwangsläufig orthogonal verlaufen. Die Anzahl der exemplarisch abgetragenen Emotionen bezieht sich auf die Menge der vektoriell abgebildeten Emotionstypen. Darüber hinaus existieren auch Ergänzungen für diskrete Emotionsansätze, wie der gültige Sprachraum. Wurde ein Modell für einen spezifischen Sprachraum erstellt, sei es durch einen Übersetzung oder eine Erstellung in dieser Sprache, dann wird diese Hintergrundinformation angegeben. Kann dieses Merkmal der Sprache nicht angegeben werden oder ist es universell gültig, wie dies beispielsweise bei mimikbasierten Ansätzen postuliert wird, dann wird dieses Feld leer gelassen.

<b>Autor</b>	<b>Validität</b>	<b>Anzahl</b>	<b>Art der Skalierung</b>	<b>Dimensionale Abhängigkeit</b>	<b>Realisierbarkeit</b>	<b>in Anwendung</b>	<b>Abgetragene Emotionen</b>
<b>Traxel und Heide</b>	nicht falsifiziert	2 Dim.	intervallskaliert		mittlere Schwierigkeiten	–	21
<b>Watson &amp; Tellegen</b>	umstritten	2 Dim.	intervallskaliert	Statistische Abhängigkeit nicht ausgeschlossen	leichte Schwierigkeiten	–	24
<b>Russell</b>	nicht falsifiziert	2 Dim.	intervallskaliert		erhebliche Schwierigkeiten	–	16
<b>Osgood, Suci und Tannenbaum</b>	nicht falsifiziert	3 Dim.	intervallskaliert		leichte Schwierigkeiten	–	135 durch Shaver et al. (1987)
<b>Scherer</b>	Verifizierung ausstehend	5 Dim.	ordinalskaliert		erhebliche Schwierigkeiten	KI-Modell	-
<b>Roseman</b>	umstritten	7 Dim.	ordinal- / nominalskaliert	Abhängigkeit entsprechend Entscheidungsbaum	erhebliche Schwierigkeiten	KI-Modell	17
<b>Smith &amp; Ellsworth</b>	nicht falsifiziert	6 Dim.	intervallskaliert		erhebliche Schwierigkeiten	–	15
<b>Manstead &amp; Tetlock</b>	umstritten	4 Dim.	intervallskaliert		erhebliche Schwierigkeiten	–	7

*Tabelle 9: Bewertung der dimensionalen Emotionsklassifikationsansätze*

<b>Autor</b>	<b>Validität</b>	<b>Anzahl</b>	<b>Gliederungsschema</b>	<b>Balance (+ / o / -)</b>	<b>Realisierbarkeit</b>	<b>in Anwendung</b>	<b>Anwendbarkeit (Seed-Words)</b>	<b>Sprachraum</b>
Gray	nicht falsifiziert	4	Einzelne Emotionen	(1 / 0 / 3)	leichte Schwierigkeiten	–	–	–
McDougall	umstritten	7	Einzelne Emotionen	(2 / 0 / 5)	leichte Schwierigkeiten	–	–	–
Plutchik	umstritten	8 Kategorien	4 Differenziale und jeweils 3-stufige Intensität	(4 / 0 / 4)	erhebliche Schwierigkeiten	EmotiNet, SentiSense	–	–
Panksepp	umstritten	7	Einzelne Emotionen	(3 / 1 / 3)	kaum möglich	–	–	–
Tomkins	umstritten	9	Einzelne Emotionen	(2 / 1 / 6)	leichte Schwierigkeiten	–	–	–
Ekman	umstritten	6	Einzelne Emotionen	(1 / 1 / 4)	kaum Schwierigkeiten	ANEW, WordNet, SemEval	–	–
Izard	nicht falsifiziert	10	2-stufig (3 Oberkategorien)	(3 / 0 / 7)	leichte Schwierigkeiten	–	30 Terme	englisch
Mertens & Krause	nicht falsifiziert	10	2-stufig (3 Oberkategorien)	(3 / 0 / 7)	leichte Schwierigkeiten	–	30 Terme	deutsch
Frijda	umstritten	16 / 6	Einzelne Emotionen	(7 / 2 / 7)	mittlere Schwierigkeiten	KI-Modell, Emotion Markup Language	–	–
Robinson	Verifizierung ausstehend	10	3-stufig (2 Oberkategorien, 5 Unterkategorien)	(21 / 0 / 26)	erhebliche Schwierigkeiten	–	47 Terme	englisch
Levenson	nicht falsifiziert	6 (+3)	Einzelne Emotionen	(1(+3) / 1 / 4)	leichte Schwierigkeiten	ANEW	–	–
Arnold	umstritten	12	Einzelne Emotionen	(5 / 0 / 7)	erhebliche Schwierigkeiten	SentiSense	–	–
Lazarus	umstritten	10 (+3)	Einzelne Emotionen	(4(+3) / 0 / 6)	erhebliche Schwierigkeiten	–	–	–
Shaver	nicht falsifiziert	6 Kategorien	2-stufig (6 Oberkategorien)	(1 / 1 / 4)	kaum Schwierigkeiten	–	135 Terme	englisch
Parrott	nicht falsifiziert	25 Kategorien	3-stufig (6 Oberkategorien, 25 Unterkategorien)	(3 / 0 / 3)	erhebliche Schwierigkeiten	EmotiNet, SentiSense	135 Terme	englisch
Schmidt-Atzert und Ströhme	nicht falsifiziert	14 Kategorien	2-stufig (14 Oberkategorien)	(5 / 0 / 9)	leichte Schwierigkeiten	–	56 Terme	deutsch
Mayring	Verifizierung ausstehend	18 Kategorien	3-stufig (4 Oberkategorien, 18 Unterkategorien)	(7 / 0 / 11)	leichte Schwierigkeiten	–	detaillierte Beschreibung	deutsch
Ortony, Clore und Collins	nicht falsifiziert	22 Kategorien	Abhängigkeitsbaum	(11 / 0 / 11)	mittlere Schwierigkeiten	KI-Modell	viele	englisch
Mees	nicht falsifiziert	23 Kategorien	Abhängigkeitsbaum	(12 / 0 / 11)	mittlere Schwierigkeiten	Linguistik	viele	deutsch

*Tabelle 10: Bewertung der diskreten Emotionsklassifikationsansätze*

## **2.5.2 Bewertung des Kategorisierungsschemas für die Sentimentanalyse**

Nachdem sowohl der dimensionale als auch der diskrete Emotionsansatz näher beleuchtet wurden, soll ein Resümee gezogen werden, welcher Ansatz anhand der hier herausgearbeiteten Kriterien besser für die Emotionsbestimmung geeignet ist. Anfänglich sollen die Vor- und Nachteile der jeweiligen Ansätze komprimiert herausgearbeitet werden. Schließlich werden diese als Begründung für die Entscheidung des Fokus dieser Arbeit herangezogen. Dabei werden feingliedrigere Einteilungen der beiden Ansätze außer Acht gelassen, um die anwendungsorientierte Perspektive in den Mittelpunkt zu rücken.

### **2.5.2.1 Vorteile des dimensionalen Kategorisierungsansatzes**

Ein dimensionales Schema ist, im Gegensatz zum diskreten Emotionsansatz, nicht zwangsläufig an eine vollständige Abbildung der Emotionen gebunden. Durch das Aufspannen der Dimensionen muss im Vorfeld keine Vorauswahl der Anzahl der Emotionen getroffen werden. Dies betrifft abhängig vom zugrunde liegenden Modell sowohl Oberkategorien oder Primäremotionen als auch weiterführende Emotionsausprägungen bzw. Sekundär- und Terziäremotionszustände. Darüber hinaus muss bei einem dimensionalen Emotionsmodell von Beginn an keine vollständige Liste aller differenzierten Emotionszustände vorliegen. Sofern sich beispielsweise die Forschungsgemeinschaft über die Existenz eines neuartigen, bisher nicht klassifizierten Emotionszustands einigen sollte oder eine kulturspezifische Emotionsqualität durch Übersetzung in das Modell aufgenommen werden sollte (vgl. dazu Russell, J., 1983), kann dies ohne weiteres nachträglich passieren. Subsequent kann auch eine Verortung einer solchen Gefühlsqualität vorgenommen werden. Im direkten Vergleich zu den diskreten Methoden kommt es wegen dieser Eigenschaft beim dimensionalen Ansatz nicht zum Balanceakt einer gleichen Aufteilung zwischen positiven und negativen Emotionen. Da eine Dimension zur Bewertung der psychologischen Valenz anstelle einer Kategorisierung existiert, ist die Anzahl der positiven und negativen Elemente weder unausgeglichen noch durch die Bemessungsgrundlage vorgegeben.

Bewertend für die Sentimentanalyse lässt sich ebenfalls sagen, dass der dimensionale Ansatz computerlinguistisch dennoch viele wünschenswerte Eigenschaften hat. Vorteilhaft ist, dass man das schwer greifbare Phänomen der emotionalen Facettierung auf wenige Dimensionen reduzieren und es anhand deren Ausprägungen bestimmen kann. Einzelne Emotionen oder auch ganze Texte lassen sich in den dimensional Emotionsmodellen eines Vektorraums abbilden, so dass weiterführend emotionale Vektoren verglichen werden können oder damit gerechnet werden kann.

Damit einher geht die dimensionale Erweiterung: Sofern sich ein Modell als nicht ausreichend feingranular herausstellt, kann eine zusätzliche Dimension angefügt werden. Sofern diese zu den anderen Achsen statistisch unabhängig ist, sind Verzerrungen ausgeschlossen. Andernfalls müsste das Modell neu berechnet werden. Neue Dimensionen können bei statistischer Unabhängigkeit als orthogonale Achse zu den bestehenden hinzugefügt werden. Um sich auf emotionstheoretisch sicherem Boden zu bewegen, wird jedoch empfohlen, Hinzufügungen nur im Rahmen der existierenden Modelle zu belassen.

Anders als bei diskreten Emotionsmodellen kann hier auch über eine Kombination mehrerer Ansätze nachgedacht werden. Wie aus dem Auszug der vorgestellten dimensional Emotionstheorien bereits ersichtlich wurde, gibt es eine Vielzahl unterschiedlicher Emotionsachsen, die sich nutzen lassen. Ohne sich vom theoretischen Unterbau zu lösen, wofür in dieser Arbeit eindringlich plädiert wird, wäre es möglich, Emotionsmodelle in andere Emotionsmodelle zu übersetzen. Gesetzt den Fall, dass zwei Modelle gänzlich unterschiedliche Dimensionsausprägungen haben, könnte eine Abbildung des einen Vektorraums in den anderen stattfinden. Sofern sich dieser Vorgang zweifelsfrei übersetzen lässt, könnten bestehende Emotionsmodelle durch die abgetragenen Emotionen des anderen Modells ergänzt werden. Hypothetisch könne man somit gleichsam bei einer sentimentanalytischen Texterkennung auf das jeweils andere Modell zurückgreifen und zwei unterschiedliche Klassifikationsverfahren mit gleichem Ergebnisraum nutzen. Es wäre möglich, diesen synthetischen Ansatz um weitere statistisch unabhängige Modelle zu erweitern.

Ein anwendungsspezifischer Vorteil von dimensional Emotionsmodellen besteht darin, dass diese einen unkomplizierten sprach- und kulturübergreifenden Vergleich erlauben. Trainiert man Modelle in zwei oder mehreren Sprach- und Kulturräumen auf die gleiche Art und Weise, so lassen sich die vektoriellen Ausprägungen derselben respektive der übersetzten Emotionszustände vergleichen. Es müsste ausdrücklich sichergestellt werden, dass die Modelle durch die gleichen Methoden erstellt wurden, um eine Vergleichbarkeit zu gewährleisten.

Dimensionen lassen sich für Folgeuntersuchungen besser nutzen als diskrete Emotionen. Dies ist eines der wichtigsten Argumente für die Nutzung und die Existenz dieser Modelle. Der Grund dafür liegt in der Beschaffenheit statistischer Tests, da sich bei einigen Methoden die Anzahl der Eingangskategorien auf das zu erreichende Signifikanzniveau auswirkt, beispielsweise bei Post-hoc-Analysen einer Varianzanalyse, bei der mittels Bonferroni-Korrektur entgegengewirkt werden muss (Bortz, 1993). Ist das komplexe menschliche Phänomen

Emotion auf wenige Merkmalsausprägungen reduziert, dann lässt sich dies leichter mit anderen Zusammenhängen korrelieren oder auf signifikante Unterschiede hin überprüfen.

### 2.5.2.2 Nachteile des dimensionalen Kategorisierungsansatzes

Als Nachteil kann gesehen werden, dass die hier häufig proklamierte Verwendung der Polaritätserkennung eine noch zu klärende Fragestellung darstellt. Kann die psychologische Valenzdimension tatsächlich durch diese computerlinguistische Methode abgedeckt werden? Wie Scherer (2005, S. 719) herausstellte, ist es „*often not clear whether a valence judgment (pleasant or unpleasant) concerns the appraisal of the nature of the stimulus object or event or rather the feeling induced by it*“. Letzteres stellt die hier vertretene Auffassung auf wackelige Beine. Um alle Zweifel auszuräumen, wäre auch diesbezüglich eine empirische Bestätigung anstelle einer argumentativen Untermauerung notwendig.

Als negativ für ein einschlägiges dimensionales Emotionsmodell kann sich herausstellen, dass die Anzahl der Dimensionen im Nachhinein betrachtet nicht ausreichend gewesen ist, beispielsweise wenn bisher unklassifizierte Emotionen aufgenommen werden und es zu nicht zielführenden Überlagerungen kommt. Dies lässt sich an einem Gedankenspiel sehr einfach überprüfen, indem man ein eindimensionales Dimensionskonstrukt wie eine Einteilung in positive und negative Ausprägungen zur Beschreibung aller dezidierten Emotionstypen verwendet. Abscheu, Ärger und Angst wären unbestreitbar auf der gleichen Seite des Kontinuums, dennoch wird jedem Betrachter ersichtlich, dass es sich dabei um nachvollziehbar grundverschiedene Erfahrungsqualitäten handelt. Ein rein auf der psychologischen Valenzdimension existierendes Modell wäre für eine feingranulare Sentimentanalyse oder Emotionserkennung folglich ungeeignet.

Die Exaktheit sowie die ausdrückliche Vollständigkeit der benötigten Daten lässt die dimensionalen Ansätze ebenfalls in einem unvoreilhaftem Licht erscheinen. Bisher wurde zu großen Teilen davon ausgegangen, dass alle achsenspezifischen Informationen exakt und vollständig aus einem Text gelesen werden können. Dies mag selbst für einen menschlichen Betrachter nicht in allen Situationen möglich sein, was Algorithmen der natürlichen Sprachverarbeitung vor noch viel größere Herausforderungen stellt. Wie bereits gezeigt, können selbst kleine Abweichungen auf den Achsen zu maßgeblichen Bedeutungsunterschieden bzw. der Wahl unterschiedlicher Emotionszustände führen. Dies zeigt die Fragilität des Ansatzes, da die Güte des Modells maßgeblich davon abhängt, wie exakt die einzelnen Achsenausprägungen computerlinguistisch erfasst werden können. Viel gravierender fällt der Fehler aus, wenn die nötigen Informationen zu einer bestimmten Dimension gar nicht gegeben sind. Eine

korrekte Klassifikation ist unter diesen Umständen unmöglich. Dieser Fehler ließe sich jedoch durch die kumulative Bewertung größerer Textmengen nivellieren, da durch die Vielzahl der Nennungen ein genaues Bild entsteht. Letzteres setzt jedoch voraus, dass in der gegebenen Textmenge exakt eine Emotion vorliegt.

Somit reihen sich die spezifischen Längenanforderungen in die Nachteile ein, die ein dimensionaler Ansatz an den zu betrachtenden Text stellt. Die Textmenge ist insofern eingeschränkt, als „*[m]ost dimensional representations, moreover, do not model the fact that two or more emotions may be experienced at the same time*“ (Cambria & Hussain, 2015, S. 58). Dies engt die Betrachtung auf kurze Text ein. Cambria & Hussain (2015, S. 58) gehen sogar noch einen Schritt weiter, wenn sie konstatieren, dass „*[e]ventually, all such approaches work at word level [only], which makes them unable to grasp the affective valence of multiple-word concepts*“. Für eine Sentimentanalyse ist dies nicht zielführend.

Der soeben genannte Aspekt bringt für die Annotation und Klassifikation auch den Nachteil der Reinheit einer Emotionsäußerung. Somit ist es für alle dimensionalen Ansätze erforderlich, dass Emotionswechsel im Text erkannt und die jeweilig unterschiedlichen Textfragmente separiert betrachtet werden. Ansonsten kann es bei einer Aggregation zu Überlagerungen kommen. Die Klassifikation ungesehener Text wird damit deutlich schwieriger und ungenauer, da ggf. eine zusätzliche Texttrennung notwendig ist.

Als weiterer Nachteil kann sich die Realisierbarkeit eines dimensionalen Modells erweisen. Unter der Voraussetzung, dass einzelne Emotionen theoretisch gegeben sind oder bereits empirisch auf den jeweiligen Achsen verortet wurden, kann unter optimalen Bedingungen die dimensionale Ausprägung eines Textfragments ermittelt und mittels eines bestehenden Emotionskatalogs verglichen werden. Der Grundgedanke hinter dieser Vorgehensweise ist, dass Emotionen durch ihre charakteristischen Achsenausprägungen sozusagen nachgeschlagen werden. Ist im mehrdimensionalen Emotionsraum für diese vektorielle Ausprägung keine spezifische Emotion hinterlegt, so wird die nächstgelegene Emotionsqualität genommen oder der multidimensionale Raum kann in einem ergänzenden Schritt erweitert werden, wobei die neu gefundene Emotion erst definiert werden muss. Es darf jedoch angezweifelt werden, dass diese gedachte Vorgehensweise in der Praxis ohne weiteres umzusetzen ist. Der Grund dafür liegt darin, dass selbst in einem kurzen Textfragment mehrere Emotionen vorhanden sein können. Selbst wenn jeder dieser Emotionszustände zweifelsfrei erkannt wird, so ist speziell für die Sentimentanalyse noch nicht geklärt, wie damit diesen umgegangen werden darf.

Es stellt sich die Frage, ob man Emotionsvektoren aggregieren kann oder ob diese nur separiert betrachtet werden dürfen. Eine Aggregation mehrerer dimensionsbasierter

Emotionen kann zu Verzerrungen führen. Dies wurde in Kapitel 2.3.1.3 anhand des Beispiels des körperlichen Erschöpfungszustands und des erlebten Glücksgefühls gezeigt, das sich in unerwünschter Weise in den theoretischen Komplex der Ruhe einreichte. Andererseits kann eine kumulierte Betrachtung jedoch auch bedeuten, dass sich zwei Emotionen aufheben. Im ungünstigsten Fall treffen zwei konträre Emotionen aufeinander, wie beispielsweise Hassliebe, die sich in einem dimensionalen Ansatz nahezu vollständig aufheben könnten. Bei diesen Modellen muss sichergestellt werden, dass solchen Überlagerungs- oder Aufhebungseffekten Rechnung getragen wird. An dieser Stelle wurde auch keine sinnvolle und praktikable Aggregationsstrategie für Emotionsvektoren gefunden, die allgemeingültig angewendet werden kann. Aus diesem Grund wird hier dafür plädiert, dass bei einer Sentimentanalyse in Verbindung mit einem dimensionalen Ansatz eine Textseparierung vorgenommen wird. Optimalerweise wird diese an den Emotionsgrenzen durchgeführt, so dass die unterschiedlichen Emotionsqualitäten nicht verwaschen. Exemplarisch wird an dieser Stelle der Ansatz von Riedl & Biemann (2012) erwähnt, der ggf. für dieses Unterfangen umgeformt werden könnte. Es sei explizit darauf hingewiesen, dass die Emotionsabgrenzung beim dimensionalen Ansatz derzeit noch ungeprüft ist. Diese Aufgabe dürfte nicht trivial sein, da ggf. einzelne Aspekte als Rahmenbedingungen für die Betrachtung eines ganzen Textes gelten.

Ein weiterer Aspekt, der als Nachteil von dimensionalen Modellen gewertet werden kann, ist die direkte Proportionalität zwischen Realitätskonformität eines Modells und computergestützte Umsetzungscomplexität. Dimensionale Ansätze rangieren zwischen sogenannten „gesicherten“ Dimensionen (Schmidt-Atzert, 1980) wie der psychologischen Valenz, der Aktivierung oder der Potenz und komplexen relationalen Dimensionen (beispielsweise Roseman, 2001; Scherer, 2001), bei denen Emotionen über die Abhängigkeit einer fühlenden Person und dem emotionsauslösenden Bezugssystem, seien es andere Personen, Objekte, Sachverhalte, Ereignisse oder konstruierte Vorstellungen wie Ziele definiert werden. Zieht man die chronologische Entwicklung und den Auszug der hier vorgestellten vielschichtigeren Dimensionsmodelle in Betracht, so gewinnt man den Eindruck, dass die gesicherten oder greifbaren Dimensionen der Komplexität des Phänomens der Emotionen nicht annähernd gerecht werden und diese Ansätze als zu einfach anmuten.

Bezogen auf die Extraktion von Emotionen in Texten wurde andererseits in den Kapiteln 2.3.1.5 bis 2.3.1.7 argumentiert, dass Modelle mit einer relationalen Abhängigkeit zwischen einem Verfasser und einem Emotionsbezugssystem kaum über die maschinelle bzw. computerlinguistische Schiene ermittelt werden können. Dies gilt jedoch nur in die Richtung der Übertragung einer dimensionalen Ausprägung hin zu diskreten Emotionstypen. Der

Umkehrschluss, also die Übersetzung dezidiert emotionsqualitäten auf einer oder mehreren Achsen, bleibt davon unberührt. Zusammenfassen kann konstatiert werden, dass bei dimensionalen Ansätzen in Verbindung mit einer Sentimentanalyse ein Zielkonflikt zwischen einem ausreichend tauglichen Modell, das der tiefgründigen und schwer greifbaren Natur von Emotionen gerecht wird, und einer computergestützten Machbarkeit besteht.

Die Interpretierbarkeit der Achsen im dimensionalen Modell stellt ebenfalls ein Problem dar. Die vektorielle Abbildbarkeit wurde für die maschinelle Verwendung als Vorteil genannt, entpuppt sich für die menschliche Lesbarkeit jedoch als Nachteil. Emotionen müssen in diesem Ansatz zuerst gefunden und ins Modell eingetragen werden, um wieder bestimmbar zu sein. Da Achsenausprägungen nicht selbstsprechend sind, kann niemand für alle vektoriellen Konstellationen mit Bestimmtheit sagen, für welchen Zustand eine Verortung exakt stehen. Der Interpretationsgehalt einer Emotion mit einer Valenz von 0,2, einer Aktivierung von 0,7 und einer Potenz von 0,66 ist nur für eingefleischte Experten des Dimensionsmodells gegeben. Ohne Benennung der Emotion entzieht sich dies dem menschlichen Verständnis, welches aus Akzeptanzgründen von Shaver et al. (1987) dringend gefordert wird.

Eine Verortung der Emotionen ist in vielen dimensionalen Modellen nicht zweifelsfrei möglich, da die Emotionskategorien oft zu feinmaschig sind. Um die Notwendigkeit einer sentimentanalytischen Zielgenauigkeit zu untermauern, wurde für das Emotionsmodell von Traxel & Heide (1961) in Abbildung 16 ein mathematischer Flächenschluss vorgenommen.

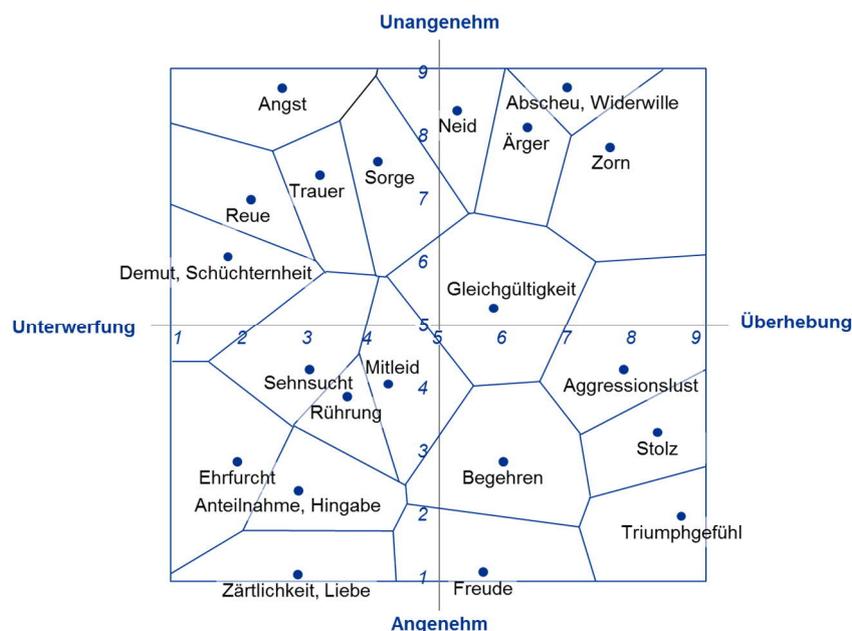


Abbildung 16: Mathematischer Flächenschluss der Emotionen nach (Traxel & Heide, 1961)

Bereits ein minimaler Ausschlag in Richtung Unterwerfung und/oder Angenehm lassen das Modell von Gleichgültigkeit auf Mitleid umschlagen. Das Problem ist, dass dimensionale

Emotionsmodelle dahingehend eingeschränkt sind, „dass die zwei oder drei Dimensionen nicht genügen, um zw. einigen offensichtlich versch. Emotionen wie Angst und Ärger zu differenzieren“ (Wirtz, 2017, S. 467). Es wird zudem die Behauptung aufgestellt, dass eine korrekte Emotionsklassifikation mittels dimensionaler Sentimentanalyse in einem generischen oder kurzen Text kaum erreicht werden kann.

Neben der fehlenden Einigung über die Anzahl der Achsen zeigen sich auch semantische Mängel bei den Dimensionen. So ist beispielsweise die Erregungsdimension nicht eindeutig, da diese „sowohl mit Aufregung und Anspannung, als auch mit Aktiviertheit und Energie assoziiert werden“ kann (Wirtz, 2017, S. 467). Selbst bei der auf den ersten Blick unstrittigen Dimension der psychologischen Valenz legte Barrett (2011) Beispielfälle offen, die strukturelle Fehler offenbaren. So wird beispielsweise die Angst im Dunkeln als negativ, jedoch das Angstempfinden in der Achterbahn als positiv wahrgenommen. Letzteres ist darauf zurückzuführen, dass Emotionen nicht exakt im Vektorraum positioniert werden können. Es liegen vielmehr fluide Bereiche vor, in denen Emotion mit einer gewissen Wahrscheinlichkeit verortet werden können. Die nachfolgende Abbildung 17 soll dies verdeutlichen.

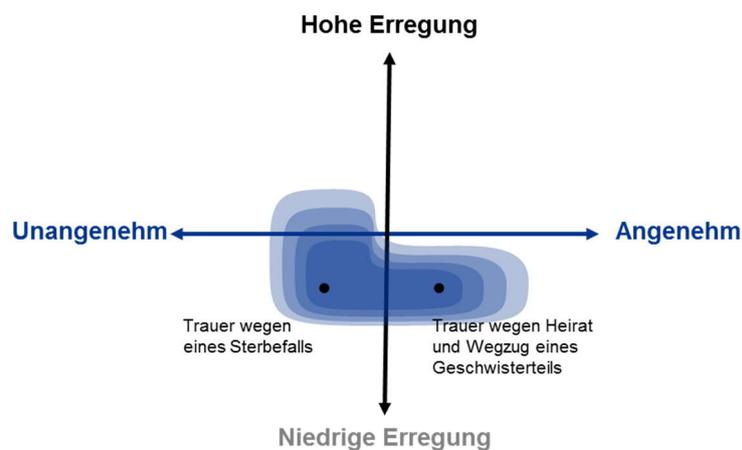


Abbildung 17: Mögliche Verortung der Trauer (nach Barrett, 2011)

Das Problem, dass sich dadurch ergibt, sind überlagernde Bereiche, die zu semantischen Ambivalenzen und einer schwierigen Emotionsbestimmung anhand eines Emotionsvektors führen. Dazu gesellt sich ein Problem, auf das Scherer (2005) hinweist, nämlich die unterschiedliche Ausprägung eines semantischen Emotionsraums je nach Individuum.

Der dimensionale Ansatz erschwert eine Textannotation. Um intervallskalierte Achsenausprägungen zu erreichen, sind zwei Ansätze denkbar. Zum einen kann man Annotatoren anweisen, eine beliebig genaue Abschätzung einer Textpassage anhand einer Emotionsdimension vorzunehmen. Es wird an dieser Stelle zumindest in Frage gestellt, ob ein Annotator z. B. dazu in der Lage ist, zwischen 73 % und 74 % Valenz exakt zu unterscheiden. Zum anderen

kann man eine Textpassage mehrfach binominal, per Likert-Skala oder in einer intervallskalierten Weise durch verschiedene Versuchspersonen annotieren. Durch das Mitteln der Ergebnisse lässt sich eine feine Bestimmung der Aschenausprägung für die jeweiligen Textauschnitte erzielen. Um ein verwendbares Genauigkeitsmaß zu erreichen, dass der feinmaschigen Raumtessellierung diskreter Emotionen gerecht wird, sind zumindest bei nichtintervallskalierten Annotationsansätzen eine erhebliche Menge an Annotatoren notwendig.

Die Kombination offener Fragen bei der Anwendung des Emotionsvektorraums und das unvollständige Emotionsverständnis stellen den Dimensionsansatz für die Sentimentanalyse vor substantielle Herausforderungen. Es gibt viele offene Punkte beim Umgang mit einem emotionalen Vektorraum. Wie geht man beispielsweise mit zwei gleichzeitig auftretenden Emotionen in einem zu klassifizierenden Text um? Sollen diese im Vektorraum vermengt oder voneinander losgelöst betrachtet werden? Dies ist eine vergleichbare Problemstellung wie das computerlinguistische Problem der Polysemie im Vektorraum (Rosario, 2000). Ein ambivalenter Term wird sich im Vektorraum zwischen den beiden Bedeutungen bewegen, doch er ist weder das eine noch das andere. Exakt diese Eigenschaft müsse jedoch auf Emotionen angewendet werden, ansonsten wäre beispielsweise Hassliebe an einer Valenzdimension falsch verortet.

Ein weiteres Problem sind die nicht ausgefüllten Räume in einem Emotionsvektorraum. Sind diese nicht gefüllt, weil ein tiefgreifendes theoretisches Verständnis fehlt oder weil Emotionen tatsächlich einen so großen vektoriellen Raum für sich in Anspruch nehmen, weil empfindende Wesen dies nicht weiter differenzieren können? Hier wird die Ansicht vertreten, dass der dimensionale Ansatz der Psychologie ein Versuch ist, die Natur der Emotionen besser zu verstehen. Der Dimensionsreduktionsvorgang soll wie eine mathematische Hauptkomponentenanalyse ähnliche Dimensionen näher zusammenrücken, um so Rückschlüsse über deren Eigenschaften zu ermöglichen. Dies ist aktuell noch nicht abgeschlossen. Denn, und dass muss bei letztgenannter Aussage berücksichtigt werden, in der Emotionsforschung gibt es immer noch kein einheitliches Verständnis über die Art und Anzahl der Dimensionen. Selbst dem Begriff Emotion fehlt es an einer genauen Bestimmung, wie Otto et al. (2000a, S. 11) herausstellen: „Eine solche Arbeitsdefinition hat durchaus provisorischen und vorläufigen Charakter und spiegelt den aktuellen Erkenntnisstand und den theoretischen Ansatz wider.“ Auch wenn Scherer (2005) erneut einen Vorstoß zur Emotionsdefinition wagte.

In dieser Arbeit wird argumentiert, dass der dimensionale Ansatz für eine feingranulare Sentimentanalyse, die dem einschlägigen Forschungsstand in theoretischer Weise gerecht

werden soll, unzweckmäßig ist. Es sei denn, eine computerlinguistische Herangehensweise hätte das Ziel, das psychologische Emotionsverständnis zu vertiefen.

### **2.5.2.3 Vorteile des diskreten Kategorisierungsansatzes**

Der diskrete Kategorisierungsansatz von Emotionen besteht vor allem durch seine einfache und erweiterbare Herangehensweise. Während bei dimensional Modellen eine Vollständigkeit der Informationen erwartet wird, also eine Bestimmung der Ausprägung aller gegebenen Achsen, können Emotionen bei der diskret kategorischen Vorgehensweise direkt ermittelt werden. Bei dem Beispielsatz „er hat vor seinem Chef Angst“ muss nicht zuerst das sozial konstruierte Abhängigkeitsgefüge analysiert, sondern es kann direkt das Lexem „Angst“ aufgegriffen und für die entsprechende Kategorie gewertet werden. Dies kann, wie das Beispiel zeigt, in sehr vielen Instanzen über das direkte Wortvorkommen gelöst werden. Damit sind in erster Instanz computerlinguistisch kaum Hürden zu nehmen. Mittels einfacher Datenaufbereitungsmethoden können, wie später gezeigt werden soll, die Ergebnisse zusätzlich verbessert werden. Dies könnte eine zusätzliche Datenselektion, wie die Beschränkung auf wenige Wortarten, oder eine gezielte Datenanreicherung, wie die Berücksichtigung der Negation, einschließen.

Diskrete Emotionen lassen sich meist in transparenter Weise abgrenzen. Da sie sich sprachlich greifen lassen, werden sie von Menschen verstanden. Auch die Feinheiten der Differenzierung zweier ähnlicher Emotionen wie Neid und Eifersucht lassen sich definieren und können von Annotatoren in Gänze umrissen werden. Dies erleichtert eine mögliche Annotation eines Textes, da nicht jede Textpassage mehrfach anhand möglicher unterschiedlicher dimensionaler Ausprägungen überprüft werden muss. Stattdessen kann das ganze Set an Emotionen im gleichen Arbeitsschritt überprüft werden.

Abhängig von der zugrunde liegenden Genauigkeit der Emotionsbestimmung können diskrete Modelle direkt evaluiert werden. Beispielenotionswörter stellen theoretische bzw. in manchen Fällen empirisch fundierte Bemessungsgrundlagen für Emotionslexika dar. Lässt man eine geringe Zahl an Schlüsselwörtern für das Training einer wortbasierten Sentimentanalyse heraus, dann können diese wiederum für die Überprüfung verwendet werden. Somit müssen für den lexikalischen Ansatz keine komplizierten Bewertungsskalen geschaffen werden, sondern die verfügbaren Terme können zum Abgleich herangezogen werden.

Darüber hinaus sind diskrete Emotionen in vielen Fällen dem Text unverändert entnehmbar – sei es dadurch, dass Emotionswörter direkt oder in synonyme Form vorkommen oder dass sie in wiederkehrenden Phrasen verwendet werden. Die Anzahl der Wendungen mag

abhängig von der Emotion variieren, doch die meisten diskreten Emotionen sind nicht an das Ergreifen bestimmter Rahmenbedingungen oder subjektiver Zielvorstellungen geknüpft.

Für die Realisierung hat dies mehrere positive Auswirkungen. Erstens kann bereits mit einer Schlüsselwortsuche ein gewisses Ergebnis erzielt werden, wenn Emotionen im Text beispielsweise direkt beim Namen genannt werden. Zweitens ermöglicht das allgemeine Verständnis von Emotionen eine einfache Annotation bei geringem Erläuterungsbedarf. Drittens muss in der Textklassifikation, anders als bei der direkten Anwendung des dimensional Ansatzes, nicht erst der Kontext geprüft werden, um eine valide Aussagekraft bezüglich der Ausprägung einer Dimension zu haben. Viertens lässt sich die diskrete Emotionserkennung auch bei geringeren Textmengen anwenden, weswegen dieser Vorgehensweise eine größere Präzision unterstellt wird. Fünftens können mehrere unterschiedliche Emotionen in einer Textpassage koexistieren und bleiben dennoch für den Menschen und die Maschine unterscheidbar.

Die diskret-kategorische Herangehensweise hat noch einen weiteren Vorteil, der die Koexistenz mehrere Emotionen betrifft. Durch die losgelöste, also statistisch unabhängige Betrachtung der Emotionen ist es unproblematisch, wenn mehrere Emotionen innerhalb eines Textes vorkommen. Der Beispielsatz „er liebt seine Exfreundin noch immer, aber was sie getan hat, verabscheut er“ würde bei einem diskreten Ansatz, abhängig vom zugrunde liegenden Modell, ein Korrelat zwischen Liebe / Zuneigung sowie Ekel / Abneigung hervorbringen. Dies ist der Fall, da sich konträre Emotionen nicht aufheben müssen, sondern auch auf engstem Raum koexistieren können. Dies hat zwei wesentliche Implikationen: Einerseits wird keine zwangsläufige Trennung des Textes an signifikanter Stelle benötigt, um diesen Umstand gerecht zu werden, andererseits kann abhängig vom zugrunde liegenden Text bestimmt werden, ob und wann ein Emotionswechsel stattfindet. Dies erlaubt beispielsweise post hoc zusätzlich zu einer feingranularen Emotionsbestimmung weitere Analysemöglichkeiten der Übergänge eines verfassten Schriftstücks.

Um nochmals den Vergleich mit den dimensional Emotionsmodellen heranzuziehen, kann gesagt werden, dass ein Ansatz mit diskret abgegrenzten Emotionskategorien einen deutlichen Vorteil hinsichtlich der Robustheit hat. Sind einerseits zu viele Emotionsqualitäten vorhanden oder fehlen auf der anderen Seite einige, ist das Modell als Ganzes nicht zwangsläufig falsch, sondern ungenau. Wohingegen die Wahl der Anzahl und Ausprägung der Differentiale bei den dimensional Modellen deutlich einschneidender ist, da dies mitunter einen gravierenden Einfluss auf die getroffene Selektion einer Gefühlsqualität und somit auf die Validität des Modells haben kann. Damit kann gesagt werden, dass die Wahl der diskret abgegrenzten Dimensionen robuster und weniger fehleranfällig ist.

Ein weiterer Vorteil der diskreten Emotionen ist der Umgang mit situativen Ungenauigkeiten und die nachträgliche Möglichkeit der Verfeinerung. Barrett (2011) gibt beispielsweise zu bedenken, dass es in einem dimensionalen Emotionsmodell aus der Bewertungsperspektive heraus einen großen Unterschied macht, ob jemand einen gerechten Zorn aufgrund von Ungerechtigkeit bzw. Wut gegenüber dem Ehepartner empfindet. Aus der Brille der diskreten Emotionen heraus ergibt sich dieses Problem kaum, da in beiden Fällen Zorn / Wut zugeordnet werden kann. Besitzt das Modell diesbezüglich eine hierarchische Gliederung oder eine feingranularere Unterteilung, so kann auch dieser Unterschied differenziert werden. Letzteres wäre nach erfolgreicher Klassifikation auch in einem nachgelagerten Schritt möglich.

Diskrete Emotionen sind, im Gegensatz zu abstrahierten, bedeutungstragenden Dimensionen, leicht verständlich. Die Interpretierbarkeit wird von einigen Emotionsforschern nachdrücklich gefordert (Shaver et al., 1987). Während Dimensionen wie Potenz oder Aktivierung und deren Abstufungen einer ausführlichen Erklärung bedürfen, sind diskrete Emotionen in der Regel selbstsprechend. Mittels Alltagsverständnis ist Personen bewusst, dass beispielsweise Tränen häufig mit Trauer und Lachen mit Freude einhergehen. Auch metaphorische Wendungen wie „bei dieser Ungleichbehandlung bekam sie einen hochroten Kopf“ können richtig in die Emotion Ärger eingeordnet werden. Auch wenn nicht alle textuellen Situationen so zweifelsfrei zuordenbar sind, wird argumentiert, dass dies für den Menschen in den meisten Fällen ersichtlich und möglich ist. Letzteres bedingt jedoch eine empirisch gesicherte Annotation (Brennan & Prediger, 1981; Cohen, 2016).

#### **2.5.2.4 Nachteile des diskreten Kategorisierungsansatzes**

Ein allgemein negativer Aspekt der diskreten Emotionseinteilung besteht darin, dass eine große Bandbreite an Kategorisierungsansätzen vorhanden ist, unter denen man ein adäquates Modell auswählen muss. Dass die Vielzahl der Emotionstheorien Verwirrung stiften können und dies nicht selten zu einer unfundierten Wahl des Emotionsansatzes in der automatisierten Informationsverarbeitung kommen kann, wird an späterer Stelle nochmals deutlicher aufgegriffen. Es kann mit Bestimmtheit gesagt werden, dass es keine einhellige Meinung darüber gibt, welche Theorie letztendlich die zutreffendste ist. Zudem müssen sich die Ansätze der diskreten Emotionen sich den Kritikpunkt der uneinheitlichen Definition gefallen lassen, also dass der wissenschaftliche Konsens trotz der Masse an Publikationen keine allgemeingültige Auswahl der Emotionstypen hervorgebracht hat (Mayring (2003). Die in Kapitel 2.3.2 gelisteten Ansätze liefern trotz stellenweise ähnlicher Herangehensweise unterschiedliche Ergebnisse. Dieses aufwendige literarische Auswahlverfahren, dem der theoretische Teil dieser

Arbeit versucht, gerecht zu werden, war vor allem notwendig, um einen Überblick über die verschiedenen Strömungen zu gewinnen und um daraus ein adäquates Emotionsmodell für die Sentimentanalyse herauszukristallisieren. Es muss nachdrücklich betont werden, dass bei den diskreten, aber sicherlich auch bei den dimensionalen Kategorisierungsansätzen eine valide theoretische Grundlage verlangt wird, um eine profunde Evaluierung der Ergebnisse auch im Sinne der Emotionsforschung zu gewährleisten.

Im Gegensatz zum dimensionalen Modell muss beim diskreten Modell von vorneherein festgelegt werden, welche Emotionsqualitäten existieren und wie sich diese abgrenzen. Wie bereits angeklungen, hat dies den gewichtigen Nachteil, dass, sofern ein Emotionszustand im theoretischen Konstrukt nicht integriert wurde, dieser nicht ermittelt werden kann. Für die Emotionserkennung kann dies zwei Implikationen haben: Einerseits bleiben einem Anwender bestimmte Emotionen verborgen, da diese nicht ermittelt werden können, andererseits können bei zu grober Kategorisierung mehrere Emotionstypen als eine einzige Emotion dargestellt werden. Dies kann gewünscht sein, wenn eine übergreifende Emotion anstelle der dezidierten Ausprägungen verwendet wird, wie dies beispielsweise bei Freude sein kann, anstelle von Amüsiertheit, Glücksgefühl, Begeisterung, Entzücken, Fröhlichkeit, Vergnügen und weiterer detaillierter Vertreter. Die grobe Kategorisierung kann aber auch zu unerwünschten Unschärfen oder Mehrdeutigkeit führen. Neid und Eifersucht sind beispielsweise Emotionsqualitäten, die nur sehr schwer abzugrenzen sind. Ist nur eine der beiden Emotionen im Modell enthalten, kann dies dazu führen, dass beide Emotionstypen unter der gelisteten auftreten, obwohl diese in der Emotionsliteratur als zwei unterschiedliche Qualitäten dargestellt werden (Hupka & Otto, 2000; Legerstee & Hart, 2010).

Ein weiterer Nachteil ist, dass Ansätze unterschiedlicher Sprach- und Kulturräume kaum miteinander verglichen werden können. Diese Erkenntnis mag trivial klingen, hat aber Auswirkungen auf die Übersetzbarkeit von Emotionsmodellen in andere Sprachen (Merten & Krause, 1993; Ouss et al., 1990). Es ist unbestreitbar, dass die gegebenen Emotionskategorien in den meisten Fällen in eine andere Sprache übertragen werden können. Aber wie in Kapitel 2.3.2.8 oder 2.3.2.15 gezeigt wurde, stößt man bei Übersetzungen immer wieder auf Hindernisse, sei es eine unterschiedliche Konnotation der Emotionsterme, eine fehlende Genauigkeit in einer der beiden Sprachen oder ambivalente Übersetzungen der Emotionswörter. Dieser Nachteil tritt umso deutlicher zu Tage, je feingranularer die Emotionskategorien bzw. je detaillierter die Emotionsterme differenziert werden.

Ein weiterer Nachteil besteht darin, dass der Umgang mit der Negation in vielen Modellen nicht geklärt ist. Das Negieren einer Emotion, wie „ich habe keine Angst“, ist bis auf

wenige Ausnahmen undefiniert. Es existieren zwar Emotionsmodelle wie das von Arnold (1960a) oder Plutchik (2001), jedoch ist auch dort die Negation nicht unproblematisch, wie bereits argumentiert wurde. Ist deren theoretisches Fundament wasserdicht, dann wäre die Anwendung der Negation in diesen Fällen optimal. Gibt es jedoch Ungereimtheiten oder gar Ambivalenzen, so wäre dies für die Sentimentanalyse maladaptiv.

Ein Nachteil vieler diskreter Emotionstheorien ist die Unvollständigkeit. Bei vorweggenommener Einteilung in positive und negative Emotionskategorien sind die positiven Emotionen deutlich unterrepräsentiert (Tugade, Shiota & Kirby, 2014). Dies lässt sich anhand einer einfachen Rechnung dokumentieren: Es gibt, bezogen auf alle in Kapitel 2.3.2 vorgestellten Ansätze, aussummiert ungefähr 1,4 Mal so viele negative Emotionen wie positive Vertreter. Man mag einwenden, dass dies der menschlichen Natur entspräche und unerwünschte Emotionen wesentlich klarer differenziert würden. Dem gegenüber stehen die Einwände der positiven Psychologie (Boniwell, 2012; Lopez, 2009; Snyder, 2009) und die der Vertreter der positiven Emotionen (Desmet, 2012; Fredrickson & Levenson, 1998; Fredrickson et al., 2000; Tugade et al., 2014). Das hier eingeführte Kriterium der Balance wurde bewusst als Einordnung aufgenommen, denn drei der gelisteten Emotionstheorien besitzen nur eine einzige bzw. zwei nur zwei positive Kategorien oder Gruppen, denen mehrere negative gegenüberstehen.

#### **2.5.2.5 Auswahl eines geeigneten Kategorisierungsansatzes**

Wie in diesem Kapitel gezeigt wurde, gibt es eine Reihe von Argumenten, die einerseits für und andererseits gegen den dimensionalen sowie den diskreten Kategorisierungsansatz sprechen. Vor allem die noch offenen Fragen, die dargebrachten Mängel und die Schwierigkeiten beim dimensionalen Ansatz geben den Ausschlag dagegen. In dieser Arbeit wird der diskrete Emotionsansatz mit großer Deutlichkeit favorisiert und empfohlen.

#### **2.5.3 Auswahl geeigneter theoretischer Modelle**

Durch die Einschränkung auf die diskreten Emotionen reduziert sich die Menge der relevanten Emotionskategorien auf eine kleinere Auswahl. Im Folgenden sollen anhand der herausgearbeiteten Kriterien die Emotionsmodelle noch weiter eingeschränkt werden. Die Merkmale und Gründe hierfür werden in diesem Kapitel offen und transparent dargelegt. Das Ziel ist es nicht, so lange auszuschließen, bis nur noch ein Ansatz übrig bleibt, der dann für die Erstellung eines annotierten Datensatz verwendet wird, sondern es wird eine Auswahl mehrerer möglicher Theorien für die Nutzung in einer Emotionsdetektion durchgeführt.

Die Validität eines Modells spielt eine zentrale Rolle, weswegen als umstritten deklarierte Theorien ausgeklammert werden. Eine ausstehende Verifizierung wird als neutral

angesehen. Der Grund für den Ausschluss der umstrittenen Emotionstheorien liegt darin, dass von vornherein auf eine valide Basis gesetzt werden soll. Diese Arbeit hat das Bestreben, ein Emotionsmodell eher deutlich nachzuzeichnen und es empirisch zu fundieren, statt ein theoretisches Konstrukt einzureißen oder als falsch darzustellen. Es ist jedoch nie ausgeschlossen, dass in der Fülle der Emotionsliteratur ein entscheidender Einwand oder eine entscheidende Bekräftigung übersehen wurden oder zukünftige Erkenntnisse die gewählten Modelle null und nichtig erscheinen lassen.

Bezogen auf die Anzahl kann die Faustformel, dass mehr Emotionen grundsätzlich besser sind, sicherlich nicht angewendet werden. Jedoch kann behauptet werden, dass, je mehr Emotionen in einem Modell verankert sind, desto größer die Wahrscheinlichkeit ist, dass es ein vollumfänglicheres Spektrum an Emotionen abdeckt und damit vollständiger und genauer ist. Es ist zweifelsohne das Ziel eines Emotionsforschers, eine ganzheitliche Emotionskategorisierung vorzunehmen. Doch bis auf wenige Ausnahmen, z. B. bei Robinson (2008), wird von einem zwanghaften Sammelverhalten abgesehen und stattdessen eine sachlogische Erklärung für die Aufnahme einer Gefühlsqualität herangezogen.

In Kapitel 2.5.2 wurde herausgestellt, dass fehlende Emotionen problematisch sind, da diese zu ungenauen Modellen führen würden, und dass nichtzutreffende Emotionen ergebnislos bleiben und damit diese Kategorie nicht gefüllt werden könnte. Dies sind zwei Punkte, die für möglichst feingranulare Emotionskategorien sprechen. Dennoch wird hier aus zwei Gründen davon Abstand genommen, möglichst kleine Emotionscluster zu bilden. Erstens macht es emotionstheoretisch keinen Sinn, zu viele Kategorien zu definieren, so dass diese kaum mehr voneinander getrennt werden können. Es muss eine überschaubare Liste bleiben, damit die Emotionskategorien alltagssprachlich sind und durch Außenstehende voneinander differenziert werden können (Shaver et al., 1987). Zweitens steigt, abhängig von dem zugrunde liegenden methodischen Ansatz, die Komplexität mit der Vielzahl der möglichen Einordnungskategorien. Es gilt, einen Mittelweg zu finden zwischen einer zu groben und ungenauen Gliederung sowie einer zu detaillierten und zu sehr überangepassten Einteilung. Um dies zu erreichen, wird zum einen ein Schwellenwert definiert, der Emotionsmodelle mit weniger als acht Emotionen ausschließt, und zum anderen werden zu feingranulare Modelle beschnitten.

Aus Anwendungsgesichtspunkten wird sich dafür ausgesprochen, dass alle hier angeführten Modelle, die über mehr als zwei hierarchische Gliederungsebenen verfügen, aus der Perspektive der zweiten Ebene betrachtet werden. Im Vorteil sind hierbei Modelle mit einem immanenten Gliederungsschema in Form einer Taxonomie oder einer hierarchischen Einteilung, da verschiedene Stufen der Detaillierung bedient werden können. Deren positive Seite zeigt

sich im Speziellen dann, falls unterschiedlich aufschlussreiche Texte analysiert werden und man durch die Hierarchisierung die Möglichkeit einer variablen Granulierung hat, wodurch sich einer fehlenden sprachlichen Ausdifferenzierung begegnen lässt.

Es wurde in Kapitel 2.3.2 gezeigt, dass Emotionsforscher deutlich mehr negative als positive Emotionstypen herauskristallisieren. Da in dieser Arbeit nicht geklärt wird, ob das Phänomen der positiven Emotionen tatsächlich unterrepräsentiert ist oder ob negative besser zu differenzieren sind, lässt sich aus diesem Kriterium auch kein autonomes Attribut ableiten, anhand dessen die Entscheidung für einen Ansatz getroffen wird. Dennoch lässt sich dieses Merkmal als Ausschlusskriterium verwenden, da angesichts der Existenz von Forschungsarbeiten mit einer größeren Bandbreite an positiven Emotionen Modelle mit nur einem oder zwei positiven Vertretern als zu ungenau und unvollständig erscheinen. Der Ausschluss nach diesem Schwellenwert wurde anhand der Kritik von Desmet (2012) bemessen, wonach lediglich zwei positive Emotionen definitiv zu wenig wären.

Wie angedeutet, ist die Verfügbarkeit von exemplarischen Emotionstermen ein Vorteil bei der Erstellung und Evaluation eines feingranularen Emotionslexikons. Dafür spricht sowohl die Fokussierung auf textanalytische Verfahren als auch die zwei Aspekte Pragmatik und Genauigkeit. Erstens wäre es ein arbeitsintensiver Nachteil, wenn nur Emotionsoberkategorien ohne dezidierten Vertreter vorhanden wären. Zwar ist es möglich, die vorgegebenen Emotionstypen beliebig zu differenzieren, aber diese müssten in einer vorgelagerten Forschungsunternehmung herausgearbeitet und verifiziert werden. Zur jeweils feingranularen Emotionsbestimmung der einzelnen Typen gesellt sich der Aufbau einer Versuchsanordnung, um die Ergebnisse empirisch zu überprüfen. Daher kann gesagt werden, dass, sofern keine Beispielterme vorhanden sind, dieser erste Schritt deutlich komplizierter ist. Der zweite Punkt ist die Genauigkeit, da gegebene Emotionswörter theoretisch fundiert sind und optimalerweise im wissenschaftlichen Diskurs erörtert wurden. Es wird nicht bezweifelt, dass selbsterstellte Listen eine ähnliche Funktion haben können, aber diese Emotionswörter sind mit einer subjektiven Ungenauigkeit behaftet. Daher wird sich, zumindest für diesen Anwendungsfall, deutlich für die Existenz solcher exemplarischer Emotionsterme ausgesprochen.

Die Einschätzung der Realisierbarkeit ist neben der Validität das wichtigste Entscheidungskriterium, da beide Einfluss auf die Güte des Modells haben. Während bei der Validität die Qualität eines Sentimentanalyseansatzes von vornherein beschränkt ist, führt eine schlechte Umsetzung zur Minderung selbiger. Zwar ist es möglich, die Güte unter Realisierbarkeitsgesichtspunkten durch zusätzliche Kniffe und erhöhten Aufwand zu verbessern, doch eine Machbarkeit zieht zwangsläufig Unstimmigkeiten nach sich. Aus diesem Grund wird der

Rotstift bei den Realisierbarkeitseinordnungen erhebliche Schwierigkeiten haben und kaum angesetzt werden können.

Abschließend sei das Kriterium des einschlägigen Sprachraums erwähnt, das, wie schon mehrfach gezeigt wurde, einen nicht zu vernachlässigenden Einfluss auf die Genauigkeit des Modells haben kann (Briggs, 1995). Aufgrund der oben angebrachten Argumente bleibt festzuhalten, dass ein bereits übersetztes oder ein in der Zielsprache verfasstes Modell präferiert verwendet werden. Jedoch sollte der ursprungssprachliche Aspekt gegenüber anderen Kriterien wie Validität, Vollständigkeit, Beispielausführungen oder Realisierbarkeit nachgelagert in die Auswahl einfließen. Da sich die hier durchgeführte Studie auf deutschsprachige Texte konzentriert, wird Modellen mit deutschen Beispielenotionstermen gegenüber einem englischsprachigen Pendant der Vorzug gegeben.

Zusammenfassend lässt sich sagen, dass ein Ansatz umso vorteilhafter ist, je besser die Validität bzw. die empirische Überprüfung ist, je weiter er von den Extrempunkten der Anzahl an Emotionstypen entfernt ist, je mehr hierarchische Gliederungsstufen er aufweist, je mehr exemplarische Emotionsterme verfügbar sind, je besser die Realisierbarkeit ist und je mehr der Sprachraum der Sprache des zu analysierenden Textes entspricht. Bezieht man alle hier aufgestellten Kriterien mit ein, fallen viele Emotionsmodelle für die Erstellung eines feingranularen Emotionslexikons heraus. Gemessen an diesem Maßstab, werden hier nur die Modelle von Schmidt-Atzert (1996), Merten & Krause (1993), Mayring (2003) und Mees (1991) als zielführend betrachtet. Wenngleich die Modelle von Schmidt-Atzert (1996), Mayring (2003) und Mees (1991) deutlich differenzierter sind als das von Merten & Krause (1993), wird in dieser Arbeit dennoch letzterem der Vorzug gegeben. Der Grund hierfür liegt in der pragmatischen Handhabung: Zum einen sind im Vergleich zu den anderen drei Modellen deutlich weniger Datenannotationen notwendig, da es weniger Kategorien gibt. Damit reduziert sich der aufwendige Annotationsprozess deutlich. Zum anderen ist dieses Modell für Annotatoren leichter erlernbar, da es übersichtlicher ist. Durch die kompaktere Bündelung wird auch unterstellt, dass es seltener zu strittigen Einordnungsentscheidungen kommt. Darüber hinaus hat es, anders als das Modell von Mees (1991) nur einen Bezugsrahmen auf Objekte bzw. Personen bei Ekel respektive Verachtung. Die Auflösung der Referenzen wird als nichttrivial angesehen.

Für diesen Ansatz sollen im Folgenden ein feingranulares Emotionslexikon und ein maschineller Lernvorgang erstellt werden.

## 3 Korpus

### 3.1 Nachrichtenkommentare als geeignete Textgrundlage

Emotionen sind in erster Linie sprachliche Konstrukte, denn nur dann, wenn man eine Emotion benennen kann, wird sie auch greifbar (Briggs, 1975, 1995). Das Schreiben von Texten ist eine Möglichkeit, Emotionen zum Ausdruck zu bringen. Zur Untermauerung dieser Behauptung wird folgendes Zitat angeführt (Liu, B., 2015a, S. 36):

*There are two main ways that human beings express themselves: speech and writing. In addition to choices of grammatical and lexical expressions, which are common to both speech and writing (see later), speaker emotion can also be conveyed through paralinguistic mechanisms such as intonations, facial expressions, body movements, biophysical signals, or changes, gestures, and posture.*

Bei der Erstellung dieser Arbeit wurden über 10 GB an Textdaten gesammelt, in der alle relevanten Emotionen unverblümt zum Ausdruck gebracht werden und deren Inhalt offen zugänglich ist. Diese Rahmenbedingungen schränken die Auswahl an Datensätzen bereits deutlich ein. Angesichts dieser selbstauferlegten Vorgaben rücken Posts aus Onlineforen, Beiträge aus sozialen Medien bzw. Videoplattformen, Produktbeschreibungen und Nachrichtenkommentare in den Fokus. Während in einschlägigen Foren, in sozialen Medien und Videoportalen sowie bei Kommentierungen auf Nachrichtenseiten die ganze Bandbreite an Emotionen vermutet wird, fällt eine Produktbewertung deutlich nüchterner aus. Unter den verbleibenden drei Optionen wurde sich hier für Nachrichtenkommentare entschieden. Dies hat mehrere Gründe:

Durch das Auseinandersetzen einer Person mit einem Nachrichtentext werden bestimmte Emotionen erzeugt bzw. induziert (Barrett, 2017). Die Kommentarfunktion erlaubt es einem Leser, diese Gefühle in Worte zu fassen und seine Position darzustellen. Dieses Argument ließe sich auch bei den anderen beiden verbliebenen Optionen anbringen, jedoch ist bei Nachrichtentexten, zumindest wenn man eine einzelne Meldung für sich betrachtet, anzunehmen, dass die Emotionen homogener sind, als bei losgelösten, voneinander unabhängigen Texten. Neben dieser uniformen Emotionsreaktion ist auch das Kommentarformat zwischen unterschiedlichen Blättern und Meldungen vergleichbar. Darüber hinaus bildet die Leserschaft in gewisser Weise den Bevölkerungsdurchschnitt besser ab, als dies in einschlägigen Foren der Fall ist. Außerdem spricht auch eine ausreichende Textlänge der Kommentare, im Vergleich zu zeichenbegrenzten Mikrobloggingdiensten, für diese Art der Texte. Ein weiterer Punkt, in dem sich Nachrichtenkommentare von Texten aus anderen Quellen differenziert, ist die parallele Verfügbarkeit einer inhaltlichen Meldung zu einem speziellen Thema bei mehreren

Redaktionen. Damit steht ein Merkmal zur Verfügung, das zusätzlich ausgewertet werden kann oder Eingang in die Analyse findet.

## 3.2 Datenakquise

Nachrichtmeldungen und -kommentare sind die relevanten Informationsträger, auf deren Fundament sich diese wissenschaftliche Arbeit begründet. Im Internet werden viele kostenfreie sowie kostenpflichtige Datensätze zu unterschiedlichen Themengebieten und Datenkategorien angeboten (vgl. u.a. Skomoroch, 2008). Da jedoch zum Zeitpunkt der Erstellung dieser Arbeit kein adäquater und gleichzeitig deutschsprachiger Datensatz vorhanden war, werden die dazu notwendigen Nachrichtmeldungen und -kommentare in diesem Rahmen akquiriert.

Um an die relevanten Datenbits zu gelangen, müssen die einzelnen Nachrichtenseiten von Nachrichtenportalen aufgerufen und ausgelesen werden. Obwohl dies eine triviale Tätigkeit ist, kann sie aufgrund der Vielzahl an Nachrichtenseiten und -meldungen nicht mehr von Hand ausgeführt werden. Bevor eine Webseite maschinell eingelesen werden kann, benötigt man den Link zu dieser Seite. Dieser wird mittels Web-Crawler erfasst. Die Herangehensweise mittels Crawler und Scraper soll in den folgenden Absätzen erläutert werden.

### 3.2.1 Web-Crawler

Web-Crawler, auch Crawler, *Spider* oder *Searchbot* genannt, sind Programme, die automatisch Webseiten analysieren und Links zu andern Seiten sammeln (Rouse, 2005). Manning, Raghavan & Schütze (2008) brechen die grundlegende Funktionsweise eines Crawlers auf folgende Schritte herunter:

Der Ausgangspunkt bei einem Crawler ist eine *Seed*-Liste aus Links bzw. URLs. Das Programm nimmt eine Webadresse aus dieser Liste, stellt eine Anfrage über das *World Wide Web*, das Intranet oder über eine Sammlung von Hypertextdokumenten und ruft den Inhalt dieser URL auf. Die abgerufene Seite wird dahingehend analysiert, dass sowohl der enthaltene Text als auch die enthaltenen Links extrahiert werden. Neben der Indexierung des Textes werden die neugesammelten Links wieder in die *Seed*-Liste überführt. Dieser Prozess wird iterativ ausgeführt, wobei die gespeicherten Links in einer gerichteten Graphstruktur abgebildet werden. Die aufgerufenen Seiten bilden dabei das für den Crawler bekannte Netzwerk. Durch das Aufrufen neuer Seiten und das Hinzufügen neuer Links erweitert der Crawler stets die Grenzen des bekannten Internets. Nach definierten Zeitabschnitten wiederholt der Crawler

die Anfragen auf bereits bekannten Webseiten, um gelöschte oder geänderte Inhalte aufzunehmen.

Die Art der Speicherung der neu gewonnenen Links, ob als *Queue* oder als *Priority-Queue* (vgl. Sedgewick & Wayne, 2011), bestimmt das Verhalten des Crawlers. Liu, B. & Menczer (2011) unterscheiden dabei zwischen einem *Breadth-First-Crawler*, der das FIFO-Prinzip einer *Queue* bei der Aufnahme neuer Links umsetzt, und einem *Preferencial Crawler*, der die noch nicht besuchten Seiten anhand eines errechneten Werts priorisiert. Eine *Depth-First-Pfadanalyse* der gerichteten Graphstruktur des Netzwerks mittels der Speicherung eines *Stacks* findet indes bei der üblichen Crawler-Technologie kaum Anwendung (vgl. Sedgewick & Wayne, 2011), da dieser Ansatz in die Falle einer sogenannten *Spider-Trap* treten kann. Bei *Spider-Traps* werden von einem Webserver stets neue Seiten und Links generiert, so dass der Crawler in dieser Generierungsschleife gefangen bleibt (Manning et al., 2008).

Die beiden Ansatz des Sammelns von Nachrichten-URLs über *RSS-Feeds* und der Ansatz eines *Topical Crawlers* sind nur bedingt zielführend. Durch die Modifikation der Crawler-Herangehensweise in ein regelbasiertes *Crawling* kann von dem speziellen Angebot der Nachrichtenportale, ein Onlinearchiv zu verwalten, Gebrauch gemacht werden. Ziel dieser Methode ist es, die URLs zu den Nachrichtenmeldungen lediglich durch das Auslesen der im Archiv gespeicherten Links zu akquirieren, ohne auf andere Quellen der Seiten zuzugreifen.

Ein regelbasierter Crawler hat jedoch mehrere Implikationen. Erstens schränkt dies die Auswahl der Nachrichtenseiten auf die Onlineplattformen ein, die ein Archiv pflegen bzw. die historische Pressemeldungen zur Verfügung stellen. Werden die Nachrichten nach einem bestimmten Zeitraum gelöscht, sind sie nicht mehr oder nur gegen Zahlung verfügbar, sind dies Kriterien, die gegen eine Einbindung dieser Nachrichtenseiten sprechen. Zweitens findet die übliche Crawler-Herangehensweise, die das gleichzeitige Lesen der Links und der Inhalte zum Indexieren vorsieht (vgl. Manning et al., 2008), keine Anwendung, da auf den Archivseiten keine relevanten Informationen vorhanden sind. In dem Prozessschritt der Anwendung des Crawlers werden nur Nachrichten-URLs gesammelt, die zu einem späteren Zeitpunkt aufgerufen, eingelesen und analysiert werden. Drittens und letztens kann es keinen universal gültigen regelbasierten Crawler geben. Dies bedeutet, dass für jedes einzulesende Nachrichtenarchiv ein separater Crawler geschrieben werden muss, um der unterschiedlichen Gestaltung der Onlineportale Rechnung zu tragen. Dabei ist die Art der Sortierung des Nachrichtenarchivs der entscheidende Komplexitätstreiber.

### 3.2.2 Web-Scraper

*Web-Scraping* ist der Vorgang, bei dem ausgewählte Daten aus Webseiten extrahiert werden (Brody, H., 2013). In dieser Arbeit wurde ein selbsterstellter *Web-Scaper* eingesetzt, der Datenfragmente von bestimmten Nachrichtenseiten erhob. Dies passierte unter Berücksichtigung der Netiquette, Einschränkungen der robots.txt und der deutschen Datenschutzbestimmungen (§ 87f Absatz 1 UrhG; § 87g Absatz 4 UrhG; Hambridge, 1995; Hewson, Vogel & Laurent, 2016). Darüber hinaus wurde dieser *Web-Scraper* nur eingesetzt, sofern eine persönliche Nutzung durch die jeweiligen AGBs des Nachrichtenportals explizit gestattet war. Die gesammelten Daten werden, sofern keine schriftliche Vereinbarung mit den Betreibern der Nachrichtenseiten getroffen wurde, nicht an Dritte weitergegeben und keiner kommerziellen Nutzung zugeführt. Es wurde darauf geachtet, dass, sofern ausgewählte Daten gespeichert wurden, dies unter der rechtlichen Einschränkung der Zitation (§ 51 UrhG), der unveränderten, originalen Wiedergabe (§§ 39 und 62 UrhG) und unter Angabe der Quellen und Urhebernennung (§ 63 UrhG) passierte.

### 3.3 Datensatz

In Rahmen einer mehrere Monate andauernden Datenakquise wurden Kommentare von ca. 800.000 Nachrichtmeldungen geladen und verarbeitet. Dies entspricht einer Gesamtmenge von ca. 10.000.000 Kommentaren. Diese Kommentare besitzen insgesamt eine Länge von ca. 680.000.000 Token. Im nicht vorverarbeiteten Zustand kommen ca. 1.200.000 unterschiedliche Terme vor und ungefähr 540.000 Terme, sofern die später erläuterten Methoden der Datenbereinigung angewendet wurden. Wird auf die korrigierten Terme noch eine Lemmatisierung angewendet, wie in Kapitel 7.1.5.1 beschrieben, dann reduziert sich die Termvielfalt weiter auf 400.000 Lemmata.

Dreh und Angelpunkt dieser Arbeit sind benutzergenerierten Textdaten, aus denen eine Struktur abgeleitet und Meinungsinformationen gewonnen werden. Ausschlaggebend für einen datenzentrierten Ansatz ist die Berücksichtigung und Nutzung der speziellen Eigenschaften der selbigen. Im Folgenden werden die Charakteristika der Nachrichtenkommentare und die für die Analyse wichtigsten Merkmale herausgestellt.

#### 3.3.1 Textmenge

Ein Schlüssel zum Erfolg bei der Analyse von textuellen Daten ist ohne Zweifel die zur Verfügung stehende Menge an Trainingsdaten. Rajaraman (2008) bringt diese Richtlinie mit folgendem Zitat auf den Punkt: „*[T]he bigger point is, adding more, independent data usually*

*beats out designing ever-better algorithms to analyze an existing data set.*” Wie bereits angedeutet, wird das Datenrauschen mit zunehmender Datenmenge reduziert, die lexikalische Reichweite der abgedeckten Wörter wird erhöht und die Möglichkeit eröffnet, unterschiedliche Domänen zu integrieren (Cambria, Song, Wang & Newton, 2014b).

Wenngleich Onlineressourcen kein Garant für große Datenvolumina bei Nachrichtenkommentaren sind, so wird die Grundlage dazu durch mehrere Faktoren begünstigt. Eine Voraussetzung, um Kommentare abzugreifen, sind Zeitungsverlage, die neben ihrem Printgeschäft auch im Onlinebereich tätig sind. Ferner müssen die Seiten der Nachrichtenportale eine integrierte Kommentarfunktion besitzen. Sowohl der Onlineauftritt als auch ein Kommentarbereich sind bei den meisten großen deutschen Zeitungen vorhanden. Eine weitere Bedingung ist die Nutzung der Kommentarfunktion durch den Leser. Dies bestätigen sowohl formlose Stichproben bei dem Onlineangebot großer Zeitungen als auch eine von Statista (2011) unter Journalisten durchgeführte Umfrage. Bei der Stichprobe zeigte sich die Tendenz, dass aktuellere Artikel mehr Kommentare haben als noch vor ein paar Jahren, was auf einen leichten Anstieg der Kommentarfrequenz hinweist. Ein weiterer positiver Faktor, der für die Nutzung von Nachrichtenkommentaren spricht, ist der freie und uneingeschränkte Zugang zu diesem Medium.

### **3.3.2 Textlänge**

Texte in sozialen Medien zeichnen sich vor allem durch ihre Kürze aus. Sie bestehen oft nur aus wenigen Worten oder Sätzen, obwohl nicht generalisiert werden kann (Hu, X. & Liu, 2012). Beschränkungen, welche die Textlänge betreffen, werden nicht nur bei Twitter eingesetzt, sondern kommen auch bei vereinzelt Nachrichtenportalen zum Einsatz. Das Zeichenlimit ist dort jedoch deutlich höher gesetzt als bei dem Kurznachrichtendienst und dürfte nur in den seltensten Fällen ausgereizt werden. Bei der Länge der Kommentare ergeben sich enorme Unterschiede, die auch abhängig vom Nachrichtenportal sind. Da die betrachtete Textmenge kleiner ist als die meisten Nachrichtenkommentare, wie später noch gezeigt wird, fällt die unterschiedliche Länge nicht ins Gewicht. Die Information über die Länge der Kommentare wird darüber hinaus nicht als Eingabemerkmal verwendet.

### **3.3.3 Strukturierung der Nachrichtentexte**

Pressemeldungen sind bei den meisten Onlineportalen bereits vorsortiert und in diversen Rubriken zusammengefasst. Mittels der von den Redaktionen definierten Kategorien kann im Sinne einer domänenspezifischen Wortschatzfokussierung eine Abgrenzung der

Nachrichtentexte vorgenommen werden. Jedoch gibt es keine universell gültige Einteilung und die Kategorien der einzelnen Nachrichtenportale unterscheiden sich sowohl in der Gliederungsschärfe als auch in der Themenabdeckung.

Darüber hinaus besitzen alle Nachrichten einen Veröffentlichungszeitpunkt. Dieser stellt das zweite Strukturierungsmerkmal dieser Texte dar. Redaktionen haben den Anspruch, Neuigkeiten und relevante Meldungen des aktuellen Tagesgeschehens abzudecken. Diese zeitnahe Berichterstattung ermöglicht sowohl die Abgrenzung von Ereignissen als auch eine chronologische Gliederung und Nachverfolgung von Begebenheiten.

### **3.3.4 Strukturierung der Kommentare**

Eine Nachrichtenmeldung wird nicht von allen Internetnutzern gleichzeitig gelesen. Durch die Asynchronität werden die Kommentare auch zeitlich versetzt abgegeben. Auf Nachrichtenportalen mit einer Kommentarfunktion werden die Meldungen der Nutzer üblicherweise in chronologischer Reihenfolge dargestellt bzw. steht diese Art der Sortierung zur Verfügung. Ein Grund dafür dürften sicherlich die Bezüge auf vorhergegangene Meldungen und die Nachvollziehbarkeit der Argumente in der Diskussionslinie sein. Darüber hinaus bieten vereinzelte Portale eine hierarchische Strukturierung an, bei der die Bezüge noch deutlicher in den Vordergrund gerückt sind. Ist letztere Funktion nicht verfügbar, dann behelfen sich die Nutzer mit Nennungen oder Referenzen auf andere Autoren.

### **3.3.5 Subjektive und nichtsubjektive Sprache**

Nachrichtenkommentare enthalten emotionale Sprachmuster. Damit sind nicht nur direkte Formen des Ausdrucks des *Private States* gemeint (Quirk, 1985; vgl. dazu Wiebe, Wilson & Cardie, 2005), sondern auch affektive Konnotationen bestimmter Wörter oder Phrasen. Kommentare dienen als Sprachrohr für Leser eines Presseartikels, um deren Meinung zu einem Thema kundzutun. Diese Behauptung wird ebenfalls an anderer Stelle in der wissenschaftlichen Literatur untermauert (Meiselman, 2016). Reaktionen auf Nachrichtenmeldungen sind ein Fundus an subjektiven Texten, wie die folgende Belegstelle zeigt: „*These social media data provide a potential source of real-time opinion from people around the world*“, wobei die Autoren soziale Medien als „*Web logs (known as blogs), online forums, comment sections on media sites, and social networking sites*“ definieren (Fink, Chou, Kopecky & Llorens, 2011, S. 22f.). Die Eigenschaft der emotionalen Sprache ist ein essentieller Bestandteil dieser Arbeit, da es diese zu ergründen gilt.

Nichtsubjektive Sprache kann am einfachsten dadurch abgegrenzt werden, dass sie dem Gegenteil subjektiver Sprache entspricht. Wie bereits erwähnt, gehen die Anfänge der Sentimentanalyse darauf zurück, diese beiden Sprachmuster zu trennen. Die *Subjectivity-Detection* hat das Ziel, subjektive Meinungsäußerungen von objektiven Phrasen oder Fakten zu differenzieren (Lin, He & Everson, 2011). Nichtsubjektive Sprache betrifft wertneutrale Äußerungen oder auch eine neutrale Emotionskategorie.

### **3.3.6 Datenqualität**

Nachrichtentexte sind überwiegend frei von orthografischen und grammatikalischen Fehlern. Auch die inhaltliche Korrektheit, also der Wahrheitsgehalt einer Aussage, ist bei Artikeln in der Regel gegeben. Aufgrund der im Journalismus üblichen Textstrukturierung sind viele Beiträge nach dem Prinzip der umgekehrten Pyramide gegliedert (weiterführend dazu Pöttker, 2005). Kurz gesagt, sind Nachrichtentexte ohne übermäßigen Pflegeaufwand zur Herstellung einer geeigneten Datenqualität für eine textuelle Datenanalyse einsetzbar. Lediglich die Einbettung der Nachrichtentexte in die Aufmachung der Webseite kann zu Komplikationen beim Extrahieren führen, da HTML-Skripte, Werbeblöcke und sogenannte *Boilerplates* entfernt werden müssen (Klein et al., 2012).

Anders verhält es sich mit den Nutzerkommentaren. Diese sind meist informell geschrieben und beinhalten ein großes Datenrauschen. Sie zeigen eine deutlich weniger homogene Datenqualität als die Nachrichtentexte. Die Bandbreite an Qualitätsunterschieden ist viel größer und reicht von einer makellosen Sprachwiedergabe bis hin zu einem maschinell kaum verwertbaren Text. Sowohl grammatikalische Verstöße als auch Rechtschreibfehler, Buchstaben-dreher, gezielte Wortverlängerungen, bewusste und unbewusst Groß- und Kleinschreibung, Umgangssprache sowie spontane Neologismen mindern die Güte der Daten (Runkehl, Schlobinski & Siever, 1998). Auch Stilmittel wie Metaphern, Allusionen, Sarkasmus und Ironie stellen für eine maschinelle Eingliederung der Emotionen eine Herausforderung dar.

## 4 Annotation

Die Annotation eines Datensatzes ist ein langwieriger und aufwendiger Prozess (McEnery, Xiao & Tono, 2008). Bevor ein neuer Korpus annotiert wird, soll geprüft werden, ob bereits ein entsprechender Referenzkorpus verfügbar ist. Einerseits soll dabei ausgeschlossen werden, dass Datensätze doppelt annotiert werden. Andererseits kann bei bestehender Existenz eines Datensatzes darauf aufgebaut bzw. dieser zielführend erweitert werden. Folgende Referenzdatensätze wurden bei der Recherchearbeit ausgemacht:

An der Universität Jena wurde ein englischsprachiger Korpus mit dem Namen EmoBank auf Satzebene entsprechend einem Schema, das mit den vorgestellten Dimensionen von Osgood et al. (1957) vergleichbar ist, annotiert (Buechel & Hahn, 2017; Hahn & Buechel, 2017). Unter dem Namen EmoInt ist ein Korpus bekannt, bei dem Tweets entsprechend den vier Emotionen Angst, Freude, Trauer und Wut annotiert sind (Mohammad & Bravo-Márquez, 2017). Ein weiterer Datensatz der *University of Pennsylvania*, der unter dem Namen *Valence and Arousal Facebook Posts* gelistet ist, beinhaltet Meldungen von Facebook, die in einem Emotionsschema entsprechend dem von Russell, J. (1980) annotiert sind (Balahur, van der Goot, Vossen & Montoyo, 2016). Ein ebenfalls englischer Datensatz mit dem Namen *Affect Data* von Alm (2009), der im Rahmen einer Dissertation entstanden ist, klassifiziert Emotionen in einem Schema, das an Ekman & Friesen (1971) angelehnt ist und die Emotionen Wut, Abneigung, Angst, Freude, Trauer und Überraschung beinhaltet. Das englische Korpus *Emotion in Text* von der Firma CrowdFlower (2016) beinhaltet die 13 diskreten Kategorien Trauer, Enthusiasmus, Neutral, Sorge, Überraschung, Liebe, Spaß, Hass, Freude, Langeweile, Erleichterung, Wut und Leere. Von derselben Firma wurde ebenfalls ein Datensatz entsprechend dem Emotionsmodell von Plutchik (1984) erstellt (CrowdFlower, 2015). Eine englische Liste annotierter Sätzen mit dem Namen *International Survey On Emotion Antecedents And Reactions* (ISEAR), die die Emotionen Freude, Angst, Wut, Trauer, Abneigung, Scham und Schuld beinhaltet, stammt von unterschiedlichen Forscherteams (Scherer & Wallbott, 1994; Scherer & Wallbott, 2006). Für die Konferenz SemEval wurde von Strapparava & Mihalcea (2007a) ein englischer Datensatz gemäß dem Emotionsmodell von Ekman & Friesen (1971) annotiert zur Verfügung gestellt. In der gleichnamigen Veranstaltung wurde 2017 unter dem Namen *Stance and Sentiment in Tweets* ebenfalls ein Textkorpus mit den Emotionen Wut, Erwartung, Abneigung, Angst, Freude, Trauer, Überraschung und Vertrauen entsprechend Plutchik (1984) und Ekman & Friesen (1971) annotiert (Mohammad, Sobhani & Kiritchenko, 2017). Der EmoTweet-28-Korpus ist einer der differenziertesten mit 28 unterschiedlichen

Kategorien, angewendet auf Tweets (Liew, Turtle & Liddy, 2016). Schließlich existiert noch ein englischer Datensatz von Mohammad, Zhu, Kiritchenko & Martin (2015) mit den Kategorien Intensität, Vertrauen, Angst, Überraschung, Abneigung, Wut, Erwartung und Freude.

Unter den gefundenen annotierten Datensätzen ist kein Korpus enthalten, der deutschsprachig ist oder eines der in der engeren Auswahl befindlichen Emotionschemas beinhaltet. Daher wird an dem bestehenden Vorhaben, einen deutschsprachigen Datensatz mit dem ausgewählten Emotionsmodell von Merten & Krause (1993) zu verwenden, festgehalten.

Da die manuelle Annotation eines Korpus eine kostspielige und zeitaufwendige Aufgabe ist, wird nicht das ganze Korpus, sondern nur ein kleiner Teil handannotiert (McEnery et al., 2008). Nur ein kleiner Bruchteil der gesammelten Nachrichtenkommentare wird durch menschliche Annotatoren mit einem Label versehen. Der Großteil der Daten ist nicht kategorisiert und somit von der direkten Nutzung ausgeschlossen. Dennoch sollen die Daten nicht brach liegen, sondern dem Modell in Form von externem Wissen wieder zugeführt werden.

Bei einer Annotation wird einer Textpassage  $x \in X$  eine Kategorie  $y \in Y$  zugewiesen. Die Emotionskategorie  $y$  ist in dieser Arbeit eine Emotion aus dem definierten Set  $C = \{\text{Interesse, Freude, Überraschung, Trauer, Wut, Ekel, Verachtung, Angst, Scham, Schuld}\}$  an Emotionen aus dem psychologischen Emotionsmodell von Merten & Krause (1993). Da die Klassifikation auf Satzebene stattfindet, kann für jeden Fall  $i$  einem Satz  $x_i$  nur exakt eine Emotion  $y_i$  zugewiesen werden.

Für die Annotatoren wurden Definitionen der jeweiligen Emotionskategorien nach Merten & Krause (1993) erstellt. Dabei wurde sich der zugehörigen Modellausprägungen bedient. In diesem Emotionsmodell besitzt jede Emotion drei Ausprägungen. Dies wurde für die Annotation und Umsetzung nicht als hierarchische Gliederung verstanden, sondern die jeweils genannten Emotionsausprägungen entsprechen der zugehörigen Emotionskategorie.

## 4.1 Klassifikationskategorien

Wie als Kritikpunkt an Emotionsmodell schon angeklungen ist, dürfen emotionale Zustände keine rein theoretischen Konstrukte sein, die am Reißbrett entstanden sind. Es ist für die einzelnen Gefühlsqualitäten von immanenter Wichtigkeit, dass diese dem semantischen Alltagsverständnis entsprechen (Shaver et al., 1987). Daher wird hier der literarische Bezugsrahmen nicht als gedankliches Korsett, sondern als richtungsweisende Vorgabe, die durch eine gängige Interpretation der jeweiligen Emotion ergänzt wird, verstanden.

Im Folgenden werden zu jeder Emotionskategorie und deren Ausprägungen exemplarische Sätze formuliert, um den Zustand der Emotion näher zu beschreiben. Dabei werden

zusätzliche Kontextinformationen in eckigen Klammern vorangestellt, um die Beispielsätze für die Annotatoren besser einordenbar zu machen. Es wird explizit darauf hingewiesen, dass die gegebenen Beispiele und Kontexte nicht vollumfänglich sind, sondern nur mögliche Ausprägungen der Emotion darstellen. Darüber hinaus wurden Terme gemeinsam betrachtet, sofern die Emotionskategorie eine Derivation einer der jeweiligen Emotionsausprägungen darstellt.

#### 4.1.1 Interesse

Emotionskategorie und -ausprägungen	Beispielsätze
<b>Interesse</b>	<ul style="list-style-type: none"> <li>• [bestehendes Interesse] Schon immer hat mich dieser Punkt interessiert.</li> <li>• [entstandenes Interesse] Dieser Aspekt hat mein Interesse geweckt.</li> <li>• [geplante Handlung] Ich werde weitere Nachforschungen dazu anstellen.</li> </ul>
<b>Aufmerksam</b>	<ul style="list-style-type: none"> <li>• [entstandenes Interesse] Das Thema hat meine Aufmerksamkeit geweckt.</li> <li>• [Erwartung einer Reaktion] Du hast meine volle Aufmerksamkeit, ich bin gespannt, was du sagen wirst.</li> </ul>
<b>Konzentriert</b>	<ul style="list-style-type: none"> <li>• [Zustand geistiger Fokussierung] Um die Zusammenhänge zu verstehen, muss ich mich jetzt konzentrieren.</li> </ul>
<b>Wach</b>	<ul style="list-style-type: none"> <li>• [entstandenes Interesse] Jetzt bin ich wach!</li> <li>• [Zustand geistiger Fokussierung] Ich bin ausgeschlafen genug, um mich dieser Aufgabe zu stellen.</li> </ul>

*Tabelle 11: Beispielsätze für die Emotion Interesse*

#### 4.1.2 Freude

Die Emotionsausprägungen vergnügt und fröhlich lassen sich auch in der Alltagssprache nur sehr schwer unterscheiden, weswegen hier auf ganz bestimmte Bedeutungen im Duden zurückgegriffen wird. Bei vergnügt ist dies die Bedeutung 1 und bei fröhlich die Bedeutung 1a (Dudenredaktion, o. J. d., o. J. f.).

Emotionskategorie und -ausprägungen	Beispielsätze
<b>Freude / erfreut</b>	<ul style="list-style-type: none"> <li>• [Vorfreude] Ich freue mich schon auf den Start der Liga nächsten Samstag.</li> <li>• [Freude wegen eines positiven Ereignisses] Ich freue mich, dass mein Club gewonnen hat.</li> </ul>
<b>Vergnügt</b>	<ul style="list-style-type: none"> <li>• [zufriedene Stimmung] Ich habe alle meine Aufgaben für heute erledigt und jetzt den restlichen Nachmittag für mich.</li> </ul>
<b>Fröhlich</b>	<ul style="list-style-type: none"> <li>• [Freude ohne speziellen Grund] Heute bin ich richtig gut gelaunt.</li> </ul>

*Tabelle 12: Beispielsätze für die Emotion Freude*

Wie in Kapitel 2 bereits erwähnt, existieren Emotionsmodelle, wie beispielsweise das von Ortony et al. (1988) oder Mees (1991), die ausdrücklich zwischen positiver und negativer Freude unterscheiden. Diesem Beispiel folgend, wird in der Annotation ebenfalls zwischen Freude und hämischer Freude bzw. Schadenfreude unterschieden. Da Merten & Krause (1993) die Emotion Freude als positiv eingestuft haben, wird in der Kategorisierung der Texte dezidiert darauf geachtet, dass Schadenfreude repräsentativ für eine negative oder hämische Freude separiert annotiert wird. Während andere Emotionsforscher wie Mees (1991) oder

Ortony et al. (1988) Freude und Schadenfreude gesondert ausweisen, taucht bei Merten & Krause (1993) die Schadenfreude in Form von Spott wieder in der Emotionskategorie Verachtung auf. Getreu dem Ausspruch „Rache ist süß“, kann man auch in der Durchführung eines Racheakts Genugtuung finden. Diese wird hier jedoch weder als Freude noch als Verachtung angesehen und entsprechend dem Modell als keiner Emotionskategorie zugehörig eingestuft.

Emotionskategorie und -ausprägungen	Beispielsätze
<b>Hämische Freude / Schadenfreude</b>	<ul style="list-style-type: none"> <li>• [Vorfreude auf ein negatives Ereignis] Ich freue mich schon auf die Schnute, die er ziehen wird, wenn er das erfährt.</li> <li>• [Freude aufgrund eines negativen Ereignisses] Ich freue mich, dass gerade ihm das widerfahren ist.</li> <li>• [Selbstbezug] Ich freue mich, dass er es auch nicht geschafft hat.</li> <li>• [Fremdbezug] Das geschieht ihm recht.</li> </ul>
<b>Rache</b>	<ul style="list-style-type: none"> <li>• [Genugtuung] Das kommt davon, dass du dich mit mir anlegst. Jetzt geht es mir besser.</li> </ul>

*Tabelle 13: Beispielsätze für die Emotion Schadenfreude*

### 4.1.3 Überraschung

Die Autoren sprechen bei diesem Emotionsmodell explizit von positiver Überraschung (Merten & Krause, 1993). Daher werden bei der Annotation sowohl positive als auch negative Überraschung annotiert, um diese zu differenzieren.

Emotionskategorie und -ausprägungen	Beispielsätze
<b>Positive Überraschung / überrascht</b>	<ul style="list-style-type: none"> <li>• [Erkenntnisgewinn] Das war mir neu, aber schön, dass es das gibt.</li> <li>• [entgegengesetzte Erwartung] Ich hätte nicht gedacht, dass die das Spiel doch noch gewinnen werden.</li> <li>• [Überraschung] Ich war von dem Ereignis positiv überrascht.</li> </ul>
<b>Erstaunt</b>	<ul style="list-style-type: none"> <li>• [Erkenntnisgewinn] Was die alles können, versetzt mich immer wieder in Erstaunen.</li> <li>• [entgegengesetzte Erwartung] Ich bin erstaunt über die plötzliche Wendung zum Guten.</li> </ul>
<b>Verblüfft</b>	<ul style="list-style-type: none"> <li>• [Erkenntnisgewinn] Ich bin sprachlos wegen dieser erfreulichen Neuigkeit.</li> <li>• [positive Überraschung aufgrund eines Ereignisses] Wenn ich so etwas Positives lese, kriege ich vor Verblüffung den Mund nicht mehr zu.</li> </ul>

*Tabelle 14: Beispielsätze für die positive Emotion Überraschung*

Analog zur Vorgehensweise bei der positiven und negativen Freude wird die negative Überraschung nicht gewertet und für die Analyse als neutral eingestuft. Darunter würde auch die Negation der Überraschung bzw. das Ausbleiben der Überraschung fallen.

Emotionskategorie und -ausprägungen	Beispielsätze
<b>Negative Überraschung</b>	<ul style="list-style-type: none"> <li>• [negative Überraschung aufgrund eines Ereignisses] Das überrascht mich jetzt, dass er nicht nochmals die Wahl gewonnen hat, obwohl er der beste Kandidat wäre.</li> <li>• [negative Überraschung aufgrund eines Ereignisses] Die Naturkatastrophe hat uns alle überrascht.</li> </ul>
<b>Keine Überraschung</b>	<ul style="list-style-type: none"> <li>• [Ereignis entsprechend der Erwartung] Das überrascht mich kein bisschen, dass das nun endlich eingetroffen ist.</li> <li>• [nicht überraschende Handlung] War ja klar, bei dem Sportler überrascht mich nun gar nichts mehr.</li> </ul>

*Tabelle 15: Beispielsätze für die negative Emotion Überraschung*

#### 4.1.4 Trauer

Trauer ist eine Emotion, die in nahezu allen Emotionsmodellen vorkommt. Merten & Krause (1993) differenzieren dies in Trauer, Niedergeschlagenheit und Entmutigung. Dementsprechend finden sich hierzu folgende Beispielsätze:

Emotionskategorie und -ausprägungen	Beispielsätze
<b>Trauer / traurig</b>	<ul style="list-style-type: none"> <li>• [Verlust einer nahestehenden Person] Es schmerzt mich immer noch, dass er von uns gegangen ist.</li> <li>• [Trauer aufgrund eines Ereignisses] Die Niederlage meines Vereins stimmt mich sehr traurig.</li> <li>• [Unbestimmte Trauer] Es macht mich traurig, dass die Welt so ein schlechter Ort ist.</li> <li>• [Enttäuschung] Es ist echt traurig, dass du in dieser Situation nicht eingegriffen hast.</li> </ul>
<b>Niedergeschlagen</b>	<ul style="list-style-type: none"> <li>• [unbestimmte Trauer] Heute fühle mich richtig niedergeschlagen. Ich weiß auch nicht, warum.</li> <li>• [Misserfolg] Dass es nicht geklappt hat, macht mich wirklich ratlos.</li> </ul>
<b>Entmutigt</b>	<ul style="list-style-type: none"> <li>• [Trauer aufgrund eines Ereignisses] Dass dies schon wieder passiert ist, raubt mir jede Kraft.</li> <li>• [wiederholtes Versagen] Wenn ich wieder in diese Situation komme, werde ich es sicher nicht noch einmal probieren.</li> <li>• [Perspektivenlosigkeit] Wenn ich das schon höre, dann weiß ich echt nicht, wie es weiter gehen soll.</li> </ul>

*Tabelle 16: Beispielsätze für die Emotion Trauer*

#### 4.1.5 Wut

Auch Wut ist eine Emotion, die in den meisten Emotionsschemata wiederzufinden ist, wengleich unter synonymem Bezeichnung. Im Folgenden finden sich exemplarische Vertreter generischer Wutformulierungen.

Emotionskategorie und -ausprägungen	Beispielsätze
<b>Wut / wütend</b>	<ul style="list-style-type: none"> <li>• [Kausaler Zusammenhang] Das macht mich tierisch wütend, dass hier keiner eingreifen kann.</li> <li>• [Kausaler Zusammenhang] Wenn ich so etwas schon höre, dann könnte ich durch die Decke gehen.</li> <li>• [Wut, bezogen auf ein Ereignis] Es war von vornherein klar, dass so etwas passieren wird, und jetzt müssen wir es wieder auslöffeln.</li> </ul>
<b>Ärgerlich</b>	<ul style="list-style-type: none"> <li>• [Fremdbezug] Ich ärgere mich über deine unverschämte Art und Weise.</li> <li>• [Reaktion auf einen Dritten] Deine Anschuldigungen sind völlig haltlos.</li> </ul>
<b>Zornig</b>	<ul style="list-style-type: none"> <li>• [negative Stimmung] Ich bin heute richtig schlecht gelaunt, ich könnte alles kurz und klein schlagen.</li> <li>• [Fremdbezug] Wenn ich dich schon wieder sehe, steigt mir die Zornesröte ins Gesicht.</li> </ul>

*Tabelle 17: Beispielsätze für die Emotion Wut*

#### 4.1.6 Ekel

Die Autoren des Emotionsmodells differenzieren zwischen Abneigung, bezogen auf Objekte und bezogen auf Personen. Die Gefühlsqualität Ekel wird hier nicht nur auf Gegenstände bezogen, sondern in dieser Arbeit auch auf Sachverhalte ausgeweitet. Letztere können

sich auf Handlungen von Akteuren oder zwischenmenschliche Umgangsweisen beziehen, nicht jedoch auf die Person selbst.

Emotionskategorie und -ausprägungen	Beispielsätze
<b>Ekel / angeekelt</b>	<ul style="list-style-type: none"> <li>• [körperliche Abwehrreaktion] Ein Gedanke an das Gericht von letzter Woche und ich muss schon wieder würgen.</li> <li>• [körperliche Abwehrreaktion] Das fühlt sich so unangenehm an, dass es mich davor ekelte, dies in die Hand zu nehmen.</li> </ul>
<b>Angewidert</b>	<ul style="list-style-type: none"> <li>• [abstoßende Verhaltensweise] Dass er ihm das angetan hat, finde ich widerlich.</li> <li>• [unangenehme Situation] Ich war so angewidert, dass ich nicht hinschauen konnte.</li> </ul>
<b>Abgestoßen</b>	<ul style="list-style-type: none"> <li>• [Erkenntnisgewinn] Das man so etwas überhaupt machen kann, finde ich mehr als abstoßend.</li> <li>• [tiefe persönliche Abneigung] Ich könnte nicht einmal daran denken, diese Praktiken auszuführen.</li> </ul>

*Tabelle 18: Beispielsätze für die Emotion Ekel*

### 4.1.7 Verachtung

Die Verachtung stellt das zweite Gegenstück der emotionalen Abneigung dar. Diese Emotion bezieht sich auf die Verachtung und Geringschätzung von Personen. Die Eingrenzung auf eine Person wird in dieser Arbeit etwas aufgeweicht und es wird zudem auf Gruppen und spezielle Organisationen Bezug genommen, wie eine Partei, ein Verein, eine Firma oder eine Abteilung, die repräsentativ für die dort arbeiten Angestellten sind.

Emotionskategorie und -ausprägungen	Beispielsätze
<b>Verachtung / verachtungsvoll</b>	<ul style="list-style-type: none"> <li>• [Verachtung einer Person] Du bist so eine minderwertige Person, von dir habe ich nichts anderes erwartet.</li> <li>• [Verachtung einer Person] Der war schon immer jemand mit zwei linken Händen und wird es auch bleiben.</li> <li>• [Verachtung einer Gruppe] Diese Partei finde ich einfach nur noch schäbig.</li> </ul>
<b>Spöttisch</b>	<ul style="list-style-type: none"> <li>• [Spott gegenüber einer Person] Das geschieht ihr recht, dass ihr das passiert ist.</li> <li>• [Spott gegenüber einer Gruppe] Wie lustig! Damit gibt sich der Verein nun vollkommen der Lächerlichkeit preis.</li> </ul>
<b>Geringschätzend</b>	<ul style="list-style-type: none"> <li>• [Beleidigung] Sie können mich mal!</li> <li>• [Ignorieren einer Person] Deine Meinung geht mir so was von am Allerwertesten vorbei.</li> </ul>

*Tabelle 19: Beispielsätze für die Emotion Verachtung*

### 4.1.8 Angst

Angst ist ebenfalls eine Emotionskategorie, die bei den meisten Modellen aus der Emotionspsychologie wiederzufinden ist. Eine leichte Schwierigkeit bei dieser Kategorie besteht darin, negative Überraschung und einen Schockzustand zu differenzieren. Angst wird hier insofern erweitert, als Phobien, also eine generelle Angst vor etwas, inkludiert werden, auch wenn sich eine Person beim Schreiben nicht in einer solchen Situation befindet.

Emotionskategorie und -ausprägungen	Beispielsätze
<b>Angst</b>	<ul style="list-style-type: none"> <li>• [Angst vor jemand] Ich habe Angst vor meinem Partner, weil es sehr gewalttätig ist.</li> </ul>

	<ul style="list-style-type: none"> <li>• [Angst vor etwas] Enge Räume und Fahrstühle jagen mir einen Schauer über den Rücken.</li> <li>• [Angst vor einem zukünftigen Ereignis] Ich habe Angst um mich und meine Kinder, wenn der wieder auf freien Fuß ist.</li> <li>• [unbestimmte Angst oder Sorge] Dass das noch ein Nachspiel haben könnte, macht mir Sorgen.</li> <li>• [Phobie] Wenn ich Mäuse sehe, kann ich gar nicht schnell genug auf den Stuhl springen.</li> </ul>
<b>Erschreckt</b>	<ul style="list-style-type: none"> <li>• [Schock] Das Ergebnis der Wahl schockiert mich zutiefst.</li> <li>• [Schockstarre] Als die Riesenspinne auf meinem Arm krabbelte, konnte ich mich nicht mehr bewegen.</li> </ul>
<b>Furchtsam</b>	<ul style="list-style-type: none"> <li>• [ängstliches Wesen] Ich bin ein absoluter Angsthase, so dass ich mir das auf keinen Fall zutrauen würde.</li> </ul>

*Tabelle 20: Beispielsätze für die Emotion Angst*

#### 4.1.9 Scham

Scham ist eine Gefühlsqualität mit niedriger Aktivierung. Daher wird vermutet, dass die Emotion dazu führt, dass sich eine schämende Person keine Blöße gibt und keinen weiteren Beitrag im Kommentarbereich tätigt. Dies betrifft jedoch nur die Scham über die eigene Person. Da der personelle Fokus bei Merten & Krause (1993) nicht weiter angegeben wurde, wird die Scham hier ausgeweitet auf eine Emotion mit Selbst-, Kollektiv- und Fremdbezug. Entsprechend dazu sind die Beispielsätze wie folgt:

<b>Emotionskategorie und -ausprägungen</b>	<b>Beispielsätze</b>
<b>Scham</b>	<ul style="list-style-type: none"> <li>• [Scham mit Selbstbezug] Ich schäme mich für mein desolates Aussehen.</li> <li>• [kollektive Scham] Es ist beschämend, wohin sich der Mensch und unsere Nation im Speziellen entwickelt haben.</li> <li>• [Fremdscham] Ich schäme mich für dich, weil die Aktion so blamierend war.</li> </ul>
<b>Gehemmt</b>	<ul style="list-style-type: none"> <li>• [Zustand niedriger Aktivierung] Ich möchte mich am liebsten in einem Mauselloch verstecken, so sehr schäme ich mich.</li> </ul>
<b>Verschämt</b>	<ul style="list-style-type: none"> <li>• [schüchterner Charakter] Mich nackt in der Sauna zu zeigen, wäre für mich ein Ding der Unmöglichkeit.</li> </ul>
<b>Verlegen</b>	<ul style="list-style-type: none"> <li>• [Unschlüssigkeit] Ich weiß nicht, ob ich ihn zurückrufen oder auf seinen Anruf warten soll.</li> </ul>

*Tabelle 21: Beispielsätze für die Emotion Scham*

#### 4.1.10 Schuld

Analog zur soeben genannten Emotion Scham werden auch hier Selbst- und Kollektivschuld als der Emotionskategorie zugehörig verstanden. Sätze, in denen Schuld eingeräumt wird, können beispielsweise wie folgt klingen:

<b>Emotionskategorie und -ausprägungen</b>	<b>Beispielsätze</b>
<b>Schuld / schuldig</b>	<ul style="list-style-type: none"> <li>• [Schuld mit Selbstbezug] Das habe ganz alleine ich zu verantworten, mit meiner ungestümen Art.</li> <li>• [kollektive Schuld] Wir alle tragen Schuld daran, dass auf der letzten Versammlung keiner aufgestanden ist, um dagegen etwas zu sagen.</li> <li>• [kollektive Schuld] Ich fühle mich als Deutscher immer noch schuldig für das, was damals passiert ist.</li> </ul>
<b>Reumütig</b>	<ul style="list-style-type: none"> <li>• [Reue über eine rückblickende Entscheidung] Ich bereue, dass ich mich damals nicht für diesen Job entschieden habe.</li> </ul>

	<ul style="list-style-type: none"> <li>• [Reue mit angekündigter Verhaltensänderung] Dass ich schon wieder zu viel getrunken habe, tut mir Leid. Ich gelobe Besserung und werde zukünftig nicht mehr so viel über die Stränge schlagen.</li> </ul>
<b>Tadelnswert</b>	<ul style="list-style-type: none"> <li>• [Selbstbezug] Ich ärgere mich über mich selbst, dass ich dem zugestimmt habe.</li> </ul>

Tabelle 22: Beispielsätze für die Emotion Schuld

## 4.2 Erstellung eines Goldstandards

### 4.2.1 Problemstellung

Die Annotation der Daten bei einer Klassifikationsaufgabe wie der hier vorliegenden ist nicht trivial. Auch wenn dieses Emotionsmodell nicht das umfangreichste ist, so liegt mit zehn Emotionen und einer nicht emotionalen Klasse dennoch eine größere Anzahl vor als bei vielen feingranularen Sentimentanalysen (Alm, 2009; Balahur et al., 2016; CrowdFlower, 2015, 2016; Mohammad et al., 2015; Mohammad & Bravo-Márquez, 2017).

Bei der Erstellung eines Goldstandards bewegt man sich in dem Spannungsfeld zwischen einer hinreichenden Annotationsmenge und der aufwendigen Realisierbarkeit. Eine ausreichend große Menge annotierter Datensätze ist dabei entscheidend für das Erreichen zufriedenstellender Klassifikationsergebnisse. Bei der quantitativen Herausforderung weisen Wang, Z. et al. (2016, S. 1361) zudem darauf hin, dass „*in most social media contexts, it is difficult to determine what size of labelled data qualifies as being sufficient because the diversity of the social discussion is not known a priori*“. Dem gegenüber stehen zum einen die Verfügbarkeit der Datensätze und zum anderen der immense manuelle Aufwand.

Während Ersteres aufgrund des ausreichend großen Korpus weniger ein Problem darstellen sollte, wird Zweiteres als problematisch erachtet. McEnery et al. (2008, S. 33) konstatieren: „*As manual annotation is expensive and time-consuming, it is typically only feasible for small corpora*“.

Mohammad & Turney (2010) schlagen bei der manuellen Annotation den Einbezug unbekannter Annotatoren im Netz vor, jedoch ist dies meist auf die englische Sprache begrenzt. Darüber hinaus existieren auch Unternehmen, die gegen Gebühr annotieren. Für die vorliegende wurde jedoch ein anderer Weg beschritten, indem die Familie, Freunde, Kollegen und Bekannte des Autors einbezogen wurden.

### 4.2.2 Vorgehensweise

Die Vorbereitung lässt sich in drei übergeordnete Prozessschritte unterteilen. Darunter fällt die Vorbereitung, die sowohl die Daten als auch die Annotationssoftware betrifft. Der zweite Schritt ist die eigentliche Annotation, bei der andere Personen hinzugezogen werden, und schließlich die Bewertung der annotierten Datensätze.

#### 4.2.2.1 Vorbereitung

Die Auswahl der Emotionssätze erfolgte nach einem vorgegebenen Muster. Um später eine ausreichende Anzahl an Annotationen einer Kategorie zu bekommen, wurde unter anderem bei der Datenselektion auf eine boolesche Suche mit UND- und ODER-Operatoren zurückgegriffen (Manning et al., 2008). Dabei wurden häufige Phrasen und Wendungen in näheren Augenschein genommen, die mit den Emotionen nach Merten & Krause (1993) im allgemeinen Sprachgebrauch assoziiert werden. Obschon einige Anfragen ins Leere liefen und viele wenig brauchbare Ergebnisse lieferten, sind diese der Vollständigkeit wegen im Anhang in Kapitel 12.1 angeführt. Dabei sei anzumerken, dass der UND-Operator nach dem ODER-Operator ausgewertet wurde. Unter den Suchergebnissen wurden nochmals manuell gefiltert und vielversprechende Passagen für die Annotation wurden ausgewählt. Semi-automatische Methoden wie die hier verwendete stehen im Einklang mit einer gängigen wissenschaftlichen Praxis bei der Datenannotation (McEnery et al., 2008). Alternativ hätte eine Filterung mittels regulärer Ausdrücke verwendet werden können. Neben der zielgerichteten Auswahl von Datensätzen wurden zudem zahlreich weitere Phrasen ohne dezidierte Heuristik ausgewählt.

Die Bestimmung der Annotationssoftware stand im Zeichen der Benutzerfreundlichkeit und Bedienbarkeit. Kriterien wie Plattformabhängigkeit, Mehrbenutzerfähigkeit, Existenz von Benutzerrollen, Workflow-Integration oder automatische Berechnung von Beurteilungskriterien wurden hintenangestellt. Untersucht wurden die Softwarelösungen Brat (Stenetorp et al., 2012), GATE (Cunningham, 2002), Knowtator (Ogren, 2006), MMAX2 (Müller & Strube, 2006), Stanford Manual Annotation Tool (Lee, M., 2004), SUTDAnnotator (Yang, J., 2017) und WordFreak (Morton & LaCivita, 2003). Unter den oben genannten Gesichtspunkten der Einfachheit wurden nur SUTDAnnotator und das *Stanford Manual Annotation Tool* in die engere Auswahl aufgenommen. Beide überzeugen durch eine schnelle Datenannotation, eine unkomplizierte Benutzungsweise und eine farbliche Hervorhebung markierter Stellen. Während dies den Funktionsumfang des *Stanford Manual Annotation Tool* bereits abdeckt, verfügt der SUTDAnnotator zusätzlich über die Möglichkeit der Schnellannotation mittels Tastenkürzel, was den Ausschlag für die Wahl für diese Softwarelösung gab.

In der Konfiguration und Weitergabe entspricht der SUTDAnnotator (Yang, J., 2017) seinem einfachen, puristischen Auftreten. In einer Konfigurationsdatei bzw. im Benutzerinterface werden die Emotionskategorien eingestellt. Der Quelltext kann derart angepasst werden, dass benutzerdefinierte Stichwörter in einer anderen Farbe hervorgehoben werden. Die Speicherung der Datei passiert automatisch nach jedem Annotationsvorgang. Die Verteilung der

Software bei den Annotatoren erforderte lediglich eine Installation der Python-2.7-Entwicklungsumgebung.

#### 4.2.2.2 Annotation

Alle Annotatoren wurden eingehend mit dem Emotionsmodell von Merten und Krause (1993) vertraut gemacht. Als Vorlage und als Nachschlagewerk dienten dazu die Beispiele und Erläuterungen aus Kapitel 4.1. Darüber hinaus wurden bereits klassifizierte Beispielannotationen aus der Datenauswahl herangezogen und Rückfragen beantwortet, damit die Annotatoren bestens gerüstet waren. Die Klassifikation entsprechend dem Emotionsschema erfolgte Satzweise. Da die Satztrennung, die in 7.1.2.3 beschrieben wurde, auf den unbearbeiteten Text angewendet und satzweise nach Annotationsmustern gesucht wurde, war es für die Annotation ausreichend, wenn ein Wort in diesem Satz markiert wurde.

Die Annotatoren erhielten eine zufällige Liste an Sätzen aus den zuvor ausgewählten Datensätzen. Jeder Datensatz wurde von mindestens zwei Personen mit einem Label versehen. Durch eine Randomisierung wurde versucht, sicherzustellen, dass sich nicht ausschließlich zwei Annotatoren in einer Emotionskategorie gegenüberstehen. Insgesamt waren über 22 unterschiedliche Annotatoren beteiligt. Keine dieser Personen hat einen psychologischen Hintergrund oder eine Ausbildung in Emotionstheorien. Jedoch erhielten alle eine Unterweisung, die jeweils zwischen zwei und drei Stunden dauerte. In dieser Unterweisung wurden alle Kategorien anhand der Beispiele aus Kapitel 4.1 durchgegangen. Darüber hinaus wurden mit jeder Person zufällige Beispielsätze gemeinsam annotiert, wobei diese Sätze wiederum anderen Teilnehmern zur Zweitannotation übergeben wurden. Rückmeldungen, wie z.B. die Annotation von emotionsgeladenen Textpassagen wie Bewunderung, die jedoch nicht im gewählten Emotionsmodell vorhanden war, handzuhaben ist, wurden nach den Fragestellungen der ersten Annotatoren an alle folgenden zurückgespielt. An dieser Stelle sei der Hinweis gegeben, dass sich eine Probeannotation mit wenigen Personen bezahlt macht, da sich mit zunehmender Kenntnis über knifflige Fragestellungen die Annotationsqualität verbessert. Es sei auch zu erwähnen, dass sich bei der Annotation eine Routine einstellt und Annotatoren mit mehr Erfahrung weniger Abweichung zueinander haben. Die Menge der annotierten Texte je Person reichte von knapp 200 bis ca. 2.800 Sätzen, wobei es wenige Annotatoren gab, die sehr viel annotierten und viele, die nur einige hundert Sätze annotierten.

Die Annotatoren erhielten die unveränderten Auszüge aus den Nachrichtenkommentaren zusammen mit den Überschriften der jeweiligen Nachrichtenmeldung. Neben dem im Vorfeld ausgewählten Satz wurde zusätzlich der Kontext in Form des vorangegangenen und des

nachfolgenden Satzes als Einordnungshilfe gegeben. Annotiert werden sollte jedoch ausschließlich der zentrale Satz, unter Berücksichtigung der angrenzenden Sätze. Sofern einer der beiden umrahmenden Sätze nicht neutral war, galt es, diesen ebenfalls zu annotieren. In diesem Fall wurde die Sätze getrennt voneinander in den annotierten Datensatz aufgenommen.

Die für die spätere Analyse relevante Annotation erfolgte nach den elf Kategorien, also den zehn Emotionen und einer neutralen Kategorie. Es war möglich, Sätze auszulassen. Nichtannotierte Sätze wurden anderen Annotatoren vorgelegt. Es gab zusätzlich die Möglichkeit, einen Satz einer nicht zugeordneten Kategorie zuzuführen. Dieses Vorgehen hatte zwei Ziele: Einerseits soll damit deutlich gemacht werden, dass ein Satz von einem Annotator bearbeitet wurde, im Vergleich zu einem ausgelassenen bzw. übersprungenen Satz. Zum anderen sollte dies genutzt werden, wenn die Einordnung eines Satzes nicht zweifelsfrei durchführbar erschien. Darunter fallen Sätze, die zwar eine starke emotionale Färbung aufweisen, bei denen es dem Annotator aufgrund des fehlenden Kontexts aber nicht möglich war, diese eindeutig zuzuordnen.

Weitere Sätze, die mit diesem Merkmal gekennzeichnet werden soll, waren solche mit zwei oder mehreren gleichwertigen Emotionen, z. B. „ich fühle mich ängstlich, traurig und wütend zugleich“. Es wurde jedoch darauf aufmerksam gemacht, dass mehrere Emotionen in einem Satz vorkommen können und diese annotiert werden dürfen. Wenn eine Emotion als deutlich betonter angegeben wurde, wie bei „ich fühle mich etwas schuldig, aber mein Zorn überwiegt das bei weitem“, oder eine Kausalkette auf die empfundene Gefühlsregung hinweist, z. B. „ich war zornig auf ihn, habe sofort Schluss gemacht und jetzt schäme ich mich immer noch für mein Verhalten“, dann konnte vom Annotator eine Kategorisierung vorgenommen werden. Es konnte jedoch keine Doppelannotierung vorgenommen werden.

#### **4.2.2.3 Bewertung**

Die manuelle Annotation der Datensätze durch mehrere Personen hat unterschiedliche Ziele. Zum einen soll ein valider Standard erstellt werden. Der Datensatz wird dann zum Training und zur Evaluation der verwendeten maschinellen Lernaufgabe herangezogen. Des Weiteren kann anhand der Übereinstimmung der menschlichen Annotatoren die Schwierigkeit der Aufgabe abgelesen werden. Zeigt sich eine hohe Deckungskraft, dann ist dies ein Indiz für eine leichte Aufgabe. Eine komplizierte Aufgabenstellung führt zu einem geringen Beurteilungsmaß der Annotation.

In den Evaluationsprozess gelangten alle Datensätze, die von zwei Annotatoren einer der zwölf Kategorie zugeordnet wurden. Für den finalen Datensatz wurden einzelne Sätze

ausgeschlossen, sofern zwei Annotatoren bei demselben Kommentarfragment unterschiedlicher Meinung waren. Auch Sätze, die in die Kategorie nicht zuordenbar fielen, wurden nicht in das Gesamtgefüge der annotierten Daten eingebracht. Somit wurden nur Sätze aufgenommen, die eine Übereinstimmung im zentralen Satz zeigten. War der nachfolgende oder der vorangegangene Satz von beiden Annotatoren gleich markiert, wurde dieser ebenfalls aufgenommen. Sofern nur ein Annotator einen umrahmenden Satz kategorisierte, wurde dieser für den späteren Datensatz aus dem Kontext entfernt. Dieser Satz ging dann aus zweierlei Gründen nicht in die Bewertung ein: Zum einen gab es nur einen Annotator, weswegen keine Übereinstimmung berechnet werden konnte, zum anderen war die Aufgabenstellung so formuliert, dass nur der zentrale Satz markiert werden sollte. Die Einordnung der Kontextsätze wurde nicht explizit angegeben. Deswegen kann nicht ausgeschlossen werden, dass einige Annotatoren dies als optional betrachteten.

Für die Berechnung des *Inter-Annotator-Agreement* stehen je Datensatz nur zwei Bewertungen unterschiedlicher Annotatoren zur Verfügung (Brennan & Prediger, 1981). Aus diesem Grund wird als Beurteilungsmaß Cohens Kappa herangezogen (Cohen, 2016). Dieses Kriterium kann anhand einer Kontingenztabelle berechnet werden, in der gegenübergestellt wird, inwieweit sich die Einschätzungen der menschlichen Annotatoren gleichen bzw. unterscheiden. Anhand folgender Formel lässt sich die Güte der Annotation bestimmen:

$$\kappa = \frac{p_0 - p_c}{1 - p_c}, \quad (1)$$

wobei  $p_0$  die tatsächliche Übereinstimmung der Annotatoren und  $p_c$  die zufällige Übereinstimmung ist. Um dies zu ermitteln, werden die Einzelwahrscheinlichkeiten  $p_{ij}$  der  $i \times j$ -dimensionalen Kontingenztabelle benötigt, in der sowohl  $i$  als auf  $j$  für eine Annotation der zwölf Kategorien steht. Diese Wahrscheinlichkeit ist somit definiert als:

$$p_{ij} = \frac{u_{ij}}{U}, \quad (2)$$

wobei  $u_{ij}$  der Anzahl der Bewertungspaare entspricht, in denen der erste Annotator die Emotionskategorie  $i$  gewählt hat und der zweite Annotator die Kategorie  $j$ .  $U$  bemisst alle insgesamt abgegebenen Bewertungspaare.

Die gemessene Übereinstimmung ergibt sich aus der Wahrscheinlichkeit der kongruenten Bewertungspaare  $p_{ii}$  in der Kontingenztabelle  $p_0 = \sum_i p_{ii}$ . Die erwartete Wahrscheinlichkeit  $p_c$  ermittelt sich aus der Summe der multiplizierten Randwahrscheinlichkeiten und entspricht:

$$p_c = \sum_i p_{i\cdot} \cdot p_{\cdot i}. \quad (3)$$

Manning et al. (2008) betrachten  $\kappa$ -Werte über 0,8 als eine gute, Werte im Intervall  $0,67 \leq \kappa \leq 0,8$  als akzeptable und Werte  $\kappa < 0,67$  als zweifelhafte Übereinstimmung. Im folgenden Kapitel werden die Annotationsergebnisse angeführt.

### 4.2.3 Annotationsergebnisse

Von den Annotatoren wurden insgesamt 11.872 Datensätze mit einem Label versehen. Davon wurden 723 Datensätze keiner zweiten Annotation zugeführt, da diese bereits vom ersten Annotator als nicht zuordenbar klassifiziert wurden. Die somit verbliebenen 11.149 Emotionszuordnungen teilen sich auf in 8.417 gültige Datensätze, bei denen sich jeweils zwei Annotatoren einig waren und eine Emotion bzw. eine neutrale Kategorie vorlag, 1.979 abweichende Zuordnungen und 753 übereinstimmende, aber nicht zuordenbare Sätze. Damit ergibt sich ein Wert von  $\kappa = 0,794$  mit einem Standardfehler  $SE = 0,004$  unter Berücksichtigung der nicht zuordenbaren Datensätze und ein Wert von  $\kappa = 0,857$  ebenfalls mit einem Standardfehler  $SE = 0,004$  unter Ausschluss der nicht zuordenbaren Dateien. In Tabelle 23 sind die Zuordnungen der Annotatoren zu den jeweiligen Kategorien tabellarisch aufgelistet.

		Annotatoren 1											Summe	
		Interesse	Freude	Überra- schung	Trauer	Wut	Ekel	Ver- ach- tung	Angst	Scham	Schuld	Neut- ral		Nicht zu- orden- bar
Annotatoren 2	Interesse	408	2	1	0	0	0	7	0	0	1	45	33	<b>497</b>
	Freude	4	605	14	0	0	0	3	0	0	0	35	8	<b>669</b>
	Überraschung	0	6	287	2	1	1	1	0	0	1	37	19	<b>355</b>
	Trauer	0	0	2	526	0	2	5	3	0	5	38	24	<b>605</b>
	Wut	1	0	0	3	1.009	24	56	4	0	0	72	54	<b>1.223</b>
	Ekel	0	0	0	0	23	710	10	0	0	0	58	31	<b>832</b>
	Verachtung	10	9	5	2	44	17	920	5	11	1	54	72	<b>1.150</b>
	Angst	0	1	0	7	7	5	10	518	0	1	36	12	<b>597</b>
	Scham	1	0	0	0	1	3	9	0	395	24	12	11	<b>456</b>
	Schuld	0	0	0	0	0	2	0	1	6	332	24	18	<b>383</b>
	Neutral	27	24	20	48	67	43	67	55	17	10	2.707	79	<b>3.164</b>
	Nicht zuorden- bar	43	8	30	27	97	28	81	12	10	15	114	753	<b>1.218</b>
<b>Summe</b>	<b>494</b>	<b>655</b>	<b>359</b>	<b>615</b>	<b>1.249</b>	<b>835</b>	<b>1.169</b>	<b>598</b>	<b>439</b>	<b>390</b>	<b>3.232</b>	<b>1.114</b>	<b>11.149</b>	

*Tabelle 23: Detaillierte Aufschlüsselung der Annotatorenzuordnungen*

## 5 Computerlinguistische Grundlagen der Sentimentanalyse

Wie eingangs in der Arbeit angeführt, ist eine Sentimentanalyse die Extraktion von Meinungen, Gefühlen oder Emotionen. Wenngleich dies auf unterschiedliche Quellen wie Gesichtsausdrücken (Ekman, 2005; Tomkins & Demos, 1995), Stimmlagen (Chaspari, Dimitriadis & Maragos, 2014), gesprochener Sprache (Chernykh, Sterling & Prihodko, 2017; Han, K., Yu & Tashev, 2014; Lee, J. & Tashev, 2015) Audiosignalen oder Musik (Han, K. Moe, Zin & Tun, 2016; Zhang, F., Meng & Li, 2016) angewendet werden kann, liegt hier der Fokus auf der textuellen Repräsentation von Emotionen. Folglich wird für die Bearbeitung auch das Teilgebiet der Computerlinguistik verwendet.

In diesem Kapitel soll ein Überblick über die Forschungsrichtung der textbasierten Sentimentanalyse nachgezeichnet werden, um davon ausgehend einen wissenschaftlichen Beitrag zu diesem Thema zu generieren. Die historische Entwicklung soll anhand der Art der Ergebnisunterteilung, der Granularitätsstufe der Textklassifikation sowie der Herangehensweise verdeutlicht werden.

### 5.1 Differenziertheit der Ergebnisunterteilung

Die Ergebnisgenauigkeit ist eines der offensichtlichsten Merkmale, anhand deren man die Forschungsströmungen der Sentimentanalyse verfolgen und abgrenzen kann. Nachdem zunächst eine binäre Differenzierung zwischen subjektiven und objektiven Texten vorgenommen wurde, folgte eine Dreiteilung in positiv, neutral und negativ. Die diskreten Modelle wurden um kontinuierliche Sentimentskalen erweitert. Ab diesen Punkt gabelten sich die Forschungsrichtungen auf: Einerseits wurde der bipolare Ansatz der Bezugsebene vertieft, indem mit dem Aspektfokus ein dezidiertes Bezugssystem hinzugefügt wurde, andererseits wurde das Polaritätskontinuum durch eine Emotionserkennung ersetzt bzw. ergänzt, da deren feingranulare Einteilungen meist auf eine positiv-negative oder auch eine positiv-neutral-negative Zusatzeinordnung zurückgreifen. Anhand der Entwicklung dieses Forschungsfelds lässt sich ein klarer Trend ablesen. Die Unterteilung der im Text verborgenen Meinung wird vielschichtiger, was in den nächsten Absätzen ausführlicher dargestellt wird.

#### 5.1.1 Subjektivitätserkennung

Gemäß Liu, B. (2012) prägten zunächst unter anderem Das & Chen (2001) mit dem *sentiment parsing* diesen Wissenschaftszweig. Auch das Forscherteam um Wiebe begann bereits früh, sich aus einer computerlinguistischen Betrachtungsweise und über den *Private State* (vgl.

Quirk, 1985) dem Thema *Subjectivity-Classification* zu nähern (Hatzivassiloglou & Wiebe, 2000; Wiebe, Bruce & O’Hara, 1999; Wiebe, 2000). In der initialen Phase der Sentimentanalyse stand vor allem die Subjektivitätserkennung im Fokus, also die Differenzierung von objektiven und subjektiven Textpassagen. Hierzu wurden neben Wortlisten (Stone, Dunphy, Smith & Ogilvie, 1966), auch Zeichendopplungen (Brody, S. & Diakopoulos, 2011), Großbuchstaben (Prasad, 2010) und Interpunktationen verwendet. In einer 2012 (Bakliwal et al.) durchgeführten Studie zur Klassifikation wurde ein Ausrufezeichen als leichtes Indiz für Subjektivität und ein Fragezeichen als ein Indiz für Objektivität genommen.

Die Bestimmung der Subjektivität und der Objektivität ist im Speziellen für die Erstellung von emotiven Datensätzen relevant, da anhand dieser Methoden eine Vorselektion getroffen werden kann. Wie später noch gezeigt wird, kann die Subjektivitätserkennung mit einer Sentimentanalyse durch einen zweistufigen Prozess kombiniert werden.

### **5.1.2 Polaritätserkennung**

Die Subjektivitätserkennung wurde bald durch den differenzierteren Ansatz der Polaritätserkennung abgelöst. Bereits wenig später folgte mit dem Ansatz der *Sentiment-Classification* von Pang, Lee & Vaithyanathan (2002) eine zweigliedrige Betrachtung der Meinungsäußerung. Das Ergebnis entsprach einer einfachen Unterteilung mit genau einem positiven und einem negativen Zustand. Die binäre Einteilung wurde relativ lange als angemessener Ansatz wahrgenommen, was unter anderem die zahlreichen und bis heute anhaltenden Entstehungen von Meinungslexika nach diesem Gliederungsschema belegen (Hamilton, Clark, Leskovec & Jurafsky, 2016; Hu, M. & Liu, 2004; Mohammad, Dunne & Dorr, 2009). Ein nichtsubjektiver Zustand zeigt sich bei der zweigliedrigen Einteilung beispielsweise durch die Abwesenheit meinungsgeladener Wörter. Doch auch hier wurde sich nicht ausschließlich auf Worte konzentriert, sondern auch, wie schon bei der Subjektivitätserkennung, die Interpunktation bemüht. Beispielsweise wurde ein Ausrufezeichen am Ende eines Satzes, zusammen mit den großgeschriebenen Wörtern und Hashtags, die semantisch mit einer Polarität behaftet sind, als kumuliertes Merkmal für Polarität verwendet (Agarwal, A., Xie, Vovsha, Rambow & Passonneau, 2011). Prasad (2010) extrahierte Ausrufezeichen sowie Ausrufezeichen, gefolgt von einem Fragezeichen, und ließ dies als Merkmal in die Polaritätsklassifikation von Tweets einfließen.

Als Folge der Aufgliederung in positive und negative Meinungen wurde die Polaritätserkennung mit der Subjektivitätserkennung gekreuzt und daraus entstand die dritte neutrale Kategorie. Das SentiWordNet beispielsweise setzt diese Gliederung in drei Dimensionen um, die

jeweils die positive, die negative und die neutrale Ausprägung wiedergeben (Esuli & Sebastiani, 2006). Die Ausprägung in Summe entspricht einer prozentualen Verteilung über die drei Dimensionen. Der von der Forschungsgemeinschaft favorisierte Ansatz ist jedoch eine eindimensionale Betrachtungsweise einer wiedergegebenen Meinung. Die drei voneinander losgelösten Dimensionen werden dabei zu einer Dimension zusammengeführt. Das somit entstandene Kontinuum weist einen positiven und einen negativen Endpunkte sowie eine neutrale Abgrenzung dazwischen auf. Üblicherweise ist der Meinungswert kontinuierlich, es existieren jedoch auch Varianten mit diskreter Abstufung (beispielsweise Nielsen, F. Arup, 2011).

Die *Sentiment-Phrase-List* ist andererseits ein Meinungslexikon, bei dem die Wertigkeit eines Wortes zwischen den Fließkommazahlen  $-1.0$  für den negativsten und  $+1.0$  für den positivsten Zustand liegen kann. Je weiter sich dieser Valenzwert der numerischen Null annähert, desto geringer ist seine Wertigkeit. Ist einem Wort in diesem Lexikon der Wert null zugeschrieben, so entspricht dies einem neutralen Ausdruck (Rill et al., 2012b; Rill et al., 2012a).

Ferner existiert auch eine valide, aber weniger populäre Einteilung mit vier Kategorien, die besagt, dass ein Term sowohl positiv als auch negativ geladen bzw. nicht geladen sein kann. Bezogen auf ein Koordinatensystem, würde dies einer zweidimensionalen Betrachtung entsprechen, bei der die Meinungseinteilungen jeweils zwischen objektiv-subjektiv-positiv und objektiv-subjektiv-negativ zu verorten sind. Der *MPQA-Opinion-Corpus*, ein Vertreter dieser Einteilung, beinhaltet auch ambigüe Terme, die sowohl positiv als auch negativ geladen sein können (Wiebe et al., 2005; Wilson, Wiebe & Hoffmann, 2005).

### **5.1.3 Emotionserkennung**

Neuere linguistische und computerlinguistische Ansätze in der Sentimentanalyse gehen noch einen Schritt weiter und ermitteln unterschiedliche Emotionen in Texten. Die definierten Zielkategorien sind in großen Teilen an eine psychologische Theorie angelehnt, wenngleich sich hier die Kluft zwischen den beiden Wissenschaften deutlich bemerkbar macht. Während sich Emotionsforscher bisher immer noch nicht über ein allgemeingültiges Emotionsmodell einigen konnten und sich in theoretischen Spitzfindigkeiten verlieren, ignorieren Computerwissenschaftler die theoretische Basis oft gänzlich und greifen aus einer strikten Anwendungsorientierung zu einer vereinfachten, kombinierten oder nicht theoriekonformen Emotionsmodellauslegung. Besonders Cambria & Hussain (2012), die Gründer des SenticNet (Cambria et al., 2016), brachen als Informatiker eine Lanze für die Emotionsforschung und wiesen auf die Relevanz psychologischer Theorien hin. In ihrer wissenschaftlichen Aufarbeitung listen sie zwar die Theorien von Arnold (Kapitel 2.3.2.12), Ekman (Kapitel 2.3.2.6), Izard (Kapitel

2.3.2.7), Parrot (Kapitel 2.3.2.15), Frijda (Kapitel 2.3.2.9), Levenson (Kapitel 2.3.2.11), Plutchik (Kapitel 2.3.2.3) und Tomkins (Kapitel 2.3.2.5), setzen sich in ihrer Untersuchung jedoch nur marginal und deskriptiv mit den soeben genannten Emotionsmodellen auseinander.

Cambria & Hussain (2012) führen in ihrer Ausarbeitung zahlreiche Praxisanwendungen dieser Emotionsmodelle ins Feld, die im Nachfolgenden näher beleuchtet und ergänzt werden sollen.

Häufig wird das allgemein bekannteste Emotionsschema von Ekman (2005) in unveränderter Form herangezogen. Die sechs Basisemotionen wurden unter anderem im Kontext sozialer Medien (Wang, Y. & Pal, 2015) oder von Blogs (Mishne, 2005; Mishne & Rijke, 2006) untersucht. Für dieses Emotionsmodell wurde im Zuge der SemEval-Konferenz ein eigener Datensatz kreiert bzw. annotiert (Strapparava & Mihalcea, 2007a). Auch der auf Scherer & Wallbott (1994) basierende Datensatz ISEAR wird kurzerhand zur Prüfung des Ekman'schen Modells in Sentimentanalysen herangezogen (Shaheen, El-Hajj, Hajj & Elbassuoni, 2014; Wang, Y. & Pal, 2015), da es eine Überschneidung der Emotionskategorien gibt und zum ursprünglichen Modell von Ekman & Friesen (1971) nur Überraschung fehlt.

Der theoretische Ansatz von Plutchik stellt die Grundlage für die semantische Wissensdatenbank SenticNet dar (Cambria et al., 2012b; Cambria et al., 2016). Die Ersteller der ontologischen Wissensbasis spannen die Emotion als ein dreidimensionales Konstrukt auf, das aus der Dimensions-Polarität, den diskreten Elementaremotionen und der Intensität besteht, wie in Kapitel 2.3.2.3 weiterführend gezeigt wird. Dies bedeutet, dass mit dem SenticNet sowohl eine Polaritäts- als auch eine Emotionserkennung durchgeführt werden kann.

Neben dem SenticNet basiert auch das *word-emotion association lexicon* von NRC (Mohammad & Turney, 2010) auf dem von Plutchik (2001) vorgeschlagenen Ansatz der kategorischen Auffächerung der Emotionen. Dieser Emotionsansatz erfreut sich vermutlich aufgrund seiner konstruierten Eigenschaften der bipolaren Emotionsdimensionen, seiner Kombinierbarkeit und der breiten inhaltlichen Abdeckung größter Beliebtheit und wird besonders im wirtschaftlichen Kontext gern verwendet. Dies beweist die zentrale Stellung, die Plutchiks Emotionsrad beim jährlich stattfindenden Sentiment-Analysis-Symposium innehat. Denn dieses Emotionsmodell wird dort von den vertretenen Repräsentanten aus Wirtschaft und Forschung häufig in Anwendung gezeigt. Plutchicks Rolle ist in dieser Interessensgemeinschaft so zentral, dass das Emotionsrad sogar im Logo der Veranstalter verankert wurde. In den letzten Jahren proklamierten zahlreiche Sprecher der Konferenz die gewonnenen Erkenntnisse und Vorteile für die Praxis, die sie durch die Anwendung dieses Emotionsmodells gewonnen haben. Hier soll jedoch nicht in einen Funktionsoptimismus verfallen werden, sondern es wird auf die

detaillierte Auseinandersetzung in dieser Arbeit hingewiesen, bei der die emotionstheoretische Fundierung des Modells als fragwürdig eingestuft wurde.

Die von Parrott (2001a) geschaffene Abhängigkeitsstruktur wurde zusammen mit dem *Wheel of Emotion* (Plutchik, 2001) unter Benutzung der ontologischen Wissensdatenbank *Rei-Action* (Kagal, 2002) und der Familien-Ontologie (Stevens, o.J.) evaluiert. Daraus entstand das *EmotiNet*, eine Wissensdatenbank zur Eingliederung der sieben Emotionen Ärger, Ekel, Furcht, Schuld, Freude, Trauer und Scham (Balahur, Hermida & Montoyo, 2012).

Eine weitere Bemühung, die in diese Richtung geht, basiert ebenfalls auf einer Vermengung der Emotionen der beiden soeben genannten Autoren und der Emotionen nach Arnold (1960a). Die daraus resultierenden Emotionen wurden mit den Basisemotionen von Plutchik (2001) und den Emotionen des zuletzt genannten Parrott (2001a) in einem neuen Modell vereint. Die so entstandene Liste wurde um vier weitere Antonyme angereichert, woraus sich letztendlich die konsolidierte Fassung der 20 Emotionen oder der 10 gegensätzlichen Emotionspaare im *SentiSense* ergab (Carrillo de Albornoz, Plaza & Gervás, 2012).

Im Meinungslexikon ANEW (Bradley & Lang, 1999) wird angegeben, dass man sich auf die emotionalen Wortbedeutungen der Ausprägungen von Russell, J. A. & Mehrabian (1977) stütze. Somit liegt hier ein dreidimensionaler Ansatz vor, der die Dimensionen „*pleasure*“, „*arousal*“ und „*dominance*“ abdeckt (Russell, J. A. & Mehrabian, 1977, S. 273).

Die Verbreitung dieses Emotionsschemas hängt sicherlich zu einem großen Teil damit zusammen, dass Emotionen im *WordNet-Affect* ebenfalls anhand dieser Kategorien annotiert sind (Strapparava & Valitutti, 2004) und dies eine Aufgabe beim *SemEval-2007-Workshop* war (Strapparava & Mihalcea, 2007b). Aman & Szpakowicz (2007) führten, exemplarisch für viele andere Studien, eine Analyse durch, bei der sie sich auf die sechs Grundemotionen Ärger, Ekel, Angst, Freude, Trauer und Überraschung von Ekman (2005) stützten. Als Analysewerkzeug verwendeten sie einen naiven Bayes-Klassifikator und eine *Support-Vector-Machine*, wobei die letztere Methode marginal besseres Gesamtergebnis erzielte. Sie extrahierten Wörter und Sätze der jeweiligen Emotionskategorie und maßen zusätzlich die Intensität der Emotionen. Eine geringe Abwandlung der Emotionsklassen ist bei Alm & Sproat (2005) zu finden, die bei ihrer Analyse von Märchen auf eine positive und negative Überraschung setzten.

Unter anderem untersuchten Neviarouskaya, Prendinger & Ishizuka (2007) Blogbeiträge mit einem regelbasierten Algorithmus unter Verwendung der *Differential-Emotions-Theory* von Izard (1991). Das hier verwendete deutsche Pendant von Merten & Krause (1993) war bis dato noch nicht Grundlage für computerlinguistische Sentimentanalysen.

Schließlich führten Cambria & Hussain (2012) eine in der Sentimentanalyse und Emotionsforschung wenig bekannte Theorie von Matsumoto ins Feld. Auch die auf den niederländischen Forscher Frijda (1986) zurückführende Bewertungstheorien der Emotionen findet in der Sentimentanalyse noch wenig Anklang, obwohl in der Emotion Markup Language, eine Sprache, die speziell für die maschinelle Handhabung von Emotionen und emotionaler Sprache geschaffen wurde, eigens dafür ein Vokabular angelegt wurde (Ashimura, Baggia, Oltramari, Peter & Zovato, 2014). Bei dem zuletzt genannten Theorieansatz steht die Entstehung der Emotionen im Vordergrund. Emotionen sind demnach Verhaltenstendenzen einer Person, die durch Bedürfnisse beeinflusst und ausgelöst werden.

Neben den genannten Emotionsklassifikationen gibt es einige Forschungsarbeiten, die nicht auf einem theoretischen Fundament gegründet sind, sondern bei denen man sich bezüglich der Einordnung der Emotionen am Datensatz orientiert. Beispielsweise definierten Davidov, Tsur & Rappoport (2010) die Zielkategorien anhand von 15 Emoticons und 50 Hashtags. Maas, Ng & Potts (2011, S. 2) übernahmen ebenfalls die Zielkategorien aus den nutzerbasierten Bewertungen mit den Ausprägungen „*sorry*“, „*hugs*“, „*that rocks*“, „*tee-hee*“, „*I understand*“, und „*wow, just wow*“. In gleicher Weise verfahren Rao, Li, Mao & Wenying (2014), die vorgegebene Smileys bei den Leserwertungen eines bekannten chinesischen Nachrichtenportals als Zielkategorie verwendeten. Die Abbildungen der Smilies standen für „*touching*“, „*empathy*“, „*boredom*“, „*anger*“, „*amusement*“, „*sadness*“, „*surprise*“ und „*warmness*“ (Rao et al., 2014, S. 91).

#### **5.1.4 Bewertung**

Es bleibt abschließend festzuhalten, dass eine bipolare Einstufung in eine positive und eine negative Kategorie eine erste Einschätzung eines Textes erlaubt. Dieses Grundschema ist additiv auch bei den meisten Emotionsmodellen anwendbar. Doch wie schon der Schritt von der rein diskreten Zweiteilung zu einer kontinuierlichen Skala zwischen positiv und negativ zeigt, ist eine grobe Kategorisierung für viele Anwendungsfälle nicht weitreichend genug oder schlicht zu ungenau. Die Auffächerung der Sentimentanalyse in eine feinere Emotionserkennung soll nach aktuellen Gesichtspunkten diese Lücke füllen. Um dem gegenwärtigen Stand der Forschung zu entsprechen, wird an dieser Stelle angesetzt. Die hier geplante Anwendung einer feingranularen Sentimentanalyse bzw. einer Emotionserkennung ist somit kongruent mit der aktuellen Forschungsrichtung.

## 5.2 Die Ebene der Granularität

Die Granularitätsebene entspricht der Detailstufe, auf die sich eine Sentimentanalyse bezieht (Tromp, 2012). Wie Liu, B. (2012) herausstellt, sind Granularitätsstufen insbesondere für die Anwendung einer Sentimentanalyse relevant. Demnach liegt der Bezugsbereich bei dieser Art der Analyse meist auf der Ebene eines Dokuments, eines Satzes, eines Wortes oder einer Entität bzw. eines Aspekts. Wie Ravi & Ravi (2015) betonen, existieren auch einige Analysen, die sich auf der Konzept-, der Phrasen-, der Internetverlinkungs-, der Abschnitts- oder der Sinnebene bewegen. Im Gegensatz zur Differenziertheit der Ergebnisse lässt sich hier keine klare Entwicklungsrichtung ablesen. Die Bearbeitung von Dokumenten in der Sentimentanalyse liefert nur abstrahierte Ergebnisse, ist jedoch nach wie vor relevant. Letzteres liegt sicherlich darin begründet, dass viele Annotationen nur dokumentweise vorgenommen wurden bzw. vorliegen. Unter anderem wird auch die große Verfügbarkeit hierbei eine Rolle spielen, zumal Kurznachrichtendienste wie Twitter kleine, zusammengehörige Textpassagen frei sowie in großer Menge anbieten und diese einfach akquiriert werden können.

Während die Bedeutung von Phrasen bereits frühzeitig hervorgehoben wurde (Wilson et al., 2005), führten erst deutliche Fortschritte in der analytischen Herangehensweise zum Durchbruch der selbigen (beispielsweise Ouyang, Zhou, Li & Liu, 2015). Auch das Interesse an der Erstellung von meinungsbezogenen Lexika scheint weiterhin ungebrochen zu sein, auch wenn elaboriertere Methoden (beispielsweise Hamilton et al., 2016) die manuellen Selektionsvorgänge zunehmend ablösen (exemplarisch dazu Stone et al., 1966).

Eine gänzlich unterschiedliche Betrachtung stellen aspektbasierte Sentimentanalysen dar. Diese agieren zwar ebenfalls innerhalb eines Dokuments, werden hier jedoch gesondert behandelt. Der Grund dafür ist, dass bei Letzterem weniger die Abgrenzung der Sinneinheiten im Fokus steht als die Relation zwischen abgegrenzten Eigenschaften und der Meinung. Dieser Ansatz stellt somit eine nicht zu vernachlässigende Sonderform der Sentimentanalyse dar.

### 5.2.1 Dokumentenebene

Bei der Analyse auf Dokumentenebene wird meist vereinfacht davon ausgegangen, dass ein meinungsgeladener Text eine einzige oder eine dominierende Meinung vertritt und diese einem relevanten Bezugspunkt zugeordnet werden kann (Liu, B., 2012). Diese Herangehensweise hat einige Vorteile. Sie ist leicht zu realisieren, da kaum auf linguistische Spitzfindigkeiten eingegangen werden muss. In der Regel sind ausreichend meinungsgeladene Textbausteine vorhanden. Somit kann man sich auf die überdeutlichen Passagen konzentrieren. Um eine dokumentbasierte Sentimentanalyse zu realisieren, können bereits mit rudimentären Methoden Erfolge

erzielt werden, wie beispielsweise mit dem naiven Bayes-Algorithmus (Jurafsky & Martin, 2017) oder einfachen Kookkurrenzmodellen (Hu, X. & Liu, 2012).

Viele Meinungen innerhalb eines Dokuments werden bei dieser Analyse dann zum Problem, wenn diese konträr sind und sich gegenseitig aufzuheben drohen. Für eine Anwendung dieser groben Form der Klassifikation benötigt man einen sinnvollen Aggregationsalgorithmus, der die Wertigkeiten konsolidiert, oder eine *Aggregation-Strategy* bzw. *Mixing-Strategy* (Harrispe, Ranwez, Janaqi & Montmain, 2013, S. 104), um Ähnlichkeiten zwischen annotierten Dokumenten zu finden. Geht man von der Annahme aus, dass ein Autor unterschiedliche Meinungen zu einem Thema vertreten kann, seine eigentliche Einstellung im Text jedoch hervorsteht, dann kann auf Dokumentebene zumindest die Meinungstendenz mit einer gewissen Unschärfe bestimmt werden. Selbiges mag für eine Emotionserkennung gelten, bei der nur eine einzige oder eine dominante Gefühlsqualität im Text ausgedrückt wird.

Die Sentimentanalyse auf Dokumentebene besitzt jedoch einen weiteren Nachteil: Die Dokumente können einerseits zu lang sein, so dass sich deutliche, aber punktuelle Meinungsakzente im Gesamttext aufheben, andererseits ist die Abgrenzung von Dokumenten nicht immer zweifelsfrei möglich. Dies lässt sich jedoch mit der partiellen Betrachtung von Dokumenten lösen, sei es anhand von Absätzen oder errechneten Grenzen, beispielsweise durch das Topic Tiling (Riedl & Biemann, 2012). Die nun folgende Textbetrachtung stellt ebenfalls eine Sonderform der partiellen Textbewertung dar.

### **5.2.2 Satz- und Phrasenebene**

Mit der Absicht, die Schärfe eines Modells zu erhöhen, wurden die Interpunktion als Abgrenzungsmerkmal oder auch eine Beschränkung auf zusammengehörende Textbausteine herangezogen. Die ersten wissenschaftlichen Schritte in der Identifikation semantischer Orientierung von bestimmten Wörtern machten Hatzivassiloglou und McKeown Hatzivassiloglou & McKeown (1997), indem sie die Kookkurrenz zweier Adjektive innerhalb eines Satzes bewerteten, sofern diese durch die Konjunktionen „and“ oder „but“ verknüpft waren. Das Satzfenster wurde somit auf die links- und rechtsstehenden Terme der beiden Schlüsselwörter eingegrenzt. Die Reihenfolge wurde insofern vernachlässigt, als die Autoren die Kookkurrenz unter der Bedingung des Auftretens von „and“ als gleichwertig und das Vorhandensein von „but“ als gegenpolig ansahen, unabhängig von deren Position neben dem Schlüsselwort.

Diesen Ansatz verfeinerten Yu & Hatzivassiloglou (2003) wenig später: Sie nutzten 1336 manuell annotierte Adjektive in Verbindung mit dem gemeinsamen Auftreten eines anderen Adjektivs in diesem Satz als Eingangsdaten für ein bayes'sches Klassifikationsmodell.

Turney & Littman (2002) wurden ebenfalls durch die Kookkurrenz semantisch ähnlicher Wörter inspiriert und nutzten die Suchergebnisse der damaligen Suchmaschine Altavista, die über einen NEAR-Operator verfügte. Mit dieser speziellen Suchfunktion kann das gemeinsame Auftreten zweier Wörter innerhalb einer definierten Fenstergröße überprüft werden, da die entsprechenden Treffer als Ergebnis zurückgegeben werden. Die Relation zwischen einem unbekanntem und einem handverlesenen, annotierten Wort wurde als Klassifikationskriterium für eine positive oder negative Konnotation verwendet.

Obwohl einige Studien verbesserte Ergebnisse erzielten (Hatzivassiloglou & Wiebe, 2000; beispielsweise Wilson, Wiebe & Hoffmann, 2009), gelang dieses Unterfangen in den Anfängen nur zum Teil, da gewisse Hindernisse im Weg standen. Mittels sprachlicher Konstruktionen wie Hypotaxen oder unter Verwendung von Konnektoren ist es beispielsweise immer noch möglich, auf Satzebene unterschiedliche Meinungen auszudrücken (Liu, B., 2012). Außerdem ist es keine Seltenheit, dass sich Bezüge über Satzgrenzen hinweg erstrecken und Bezugsentitäten mittels Pronomen aufgegriffen werden (Sadamitsu, Sekine & Yamamoto, 2008). Speziell bei Produktbewertungen tendieren Autoren dazu, abwechselnd subjektive oder objektive Sätze zu formulieren, was als Argument gegen die strikte satzweise Betrachtung in Verbindung mit den damaligen Forschungsmethoden spricht (Cambria, Schuller, Xia & Havasi, 2013).

Auch die Reihenfolge der Sätze wurde bereits in früheren Studien als Eingangsmerkmal verwendet, beispielsweise als Reihenfolge aufeinanderfolgender Sätze, wie bei einem auf *Conditional Random Fields* basierenden *Constrained-Viterbi*-Algorithmus, um Meinungen in aufeinander folgenden Sätzen zu klassifizieren. Der sequenzbasierte Algorithmus wurde dadurch eingeschränkt, dass die Meinungen auf Dokumentebene mit denen der Paragraphen verlinkt wurden und diese wiederum mit den Meinungen der enthaltenen Sätze (McDonald, Hannan, Neylon, Wells & Reynar, 2007).

Kanayama & Nasukawa (2006) nutzten aufeinanderfolgende Sätze ebenfalls als Eingangsmerkmal, um die von ihnen genannte *Context-Coherency* zu ermitteln. Sie gingen davon aus, dass die Polarität in benachbarten Sätzen gleich ist und man bei bekannter Polarität des einen Satzes auf die des anderen Satzes schließen kann. Wie man sieht, kann bei einer Satztrennung ein Dokument nicht nur dezidiert betrachtet werden, sondern es ergeben sich auch zusätzliche Merkmale, die genutzt werden können.

Neuere Ansätze gehen in eine deutliche Richtung hin zur Nutzung der Satzebene. Darunter fallen aufwendige Ansätze, bei denen der Satzbaum und die Abhängigkeiten der Wörter zueinander aufgeschlüsselt werden (Socher et al., 2013), aber auch pragmatischere Ansätze, in denen syntaktische Informationen mittels *Word-Embedding* kombiniert mit maschinellen

Lernmethoden verarbeitet werden (beispielsweise Kim, Y., 2014; Ouyang et al., 2015). Die fortschrittlichen Methoden in Verbindung mit Wortvektoren zeigen ausgezeichnete Ergebnisse auf dieser Granularitätsstufe und bieten ein deutliches Argument für eine genauere Betrachtung als auf der Dokumentenebene.

### 5.2.3 Wortebene

Eine Sentimentanalyse auf Wortebene entspricht dem lexikalischen Ansatz, d. h. dass damit ein Meinungslexikon oder eine emotive Wortliste erzeugt werden, die an sich jedoch selbst nur einen Zwischenschritt darstellen. Der Grundgedanke dahinter ist, dass diese annotierte Liste als Basis für weiterführende Analysen auf höherer Granularitätsstufe dienen kann. Der Grund dafür, dass dieser Ansatz hier ebenfalls unter der Einordnung anhand der Granularität zu finden ist, besteht darin, dass einige Ansätze Wortlisten als Bewertungsgrundlage heranziehen, wie beispielsweise die Arbeiten von Taboada, Brooke, Tofiloski, Voll & Stede (2011), die ihre Ergebnisse anhand des *Mechanical-Turk*-Dienstes von Amazon überprüfen ließen. Ebenso zählen Ansätze der Lexikonerstellung darunter (Medhat et al., 2014). Somit wird dieses Zwischenergebnis auf Wortebene in der Forschergemeinde als valider Ansatz und Aufsatzpunkt wahrgenommen.

Ein Meinungslexikon im Sinne der Sentimentanalyse besteht aus einer Liste von Wörtern, Wortpaaren oder in wenigen Fällen auch Satzfragmenten und einer zugehörigen Meinungskategorie. Elaboriertere Lexika geben zusätzlich an, zu welchem Grad ein bestimmtes Wort einer Kategorie zugehörig ist. Die meinungsspezifischen Zielkategorien, oder anders gesagt die Differenziertheit eines Lexikons, sind bereits mit der Zugehörigkeit der Wörter zu den einzelnen Gruppen strukturell vorhanden. Dabei können Wörter, abhängig von dem zugrunde liegenden Modell, eindeutig jeweils einer Kategorie oder sogar mehreren Kategorien zugeordnet werden. Sofern Letzteres für das Meinungslexikon zutrifft, wird eine Zuordnung mittels eines zugrunde liegenden Wahrscheinlichkeitsmodells vorgenommen. Beispielsweise kann das Adjektiv „klein“ unterschiedlich konnotiert sein, wie die nachfolgenden Sätze untermauern. Sei es positiv, wie im folgenden Satz: „Das Auto ist klein und passt deswegen in die Parklücke“, negativ im Vergleich dazu im Satz: „Die Parklücke ist zu klein für das Auto“ oder neutralwertig bzw. deskriptiv in dritten Satz: „Der Gegenstand ist klein.“

Die Anwendung eines Emotionslexikons ist einfach gestaltet, da dies einem schlichten Indexierungs- oder Suchvorgang entspricht. Der zu analysierende Text wird mit Einträgen im Lexikon verglichen. Dabei gehen in die Analyse Merkmale ein wie die Präsenz eines bestimmten Terms oder Ausdrucks, die Häufigkeit des Wortvorkommens und die im Lexikon immanente

Zielkategorie inklusive des Zugehörigkeitsgrades, sofern Letzterer vorhanden ist (Cambria et al., 2013). In der Analyse, bei der mitunter weitere Merkmale in die Gleichung einfließen können, wird eine Bewertung der Zugehörigkeit des Textes zu einer der per Zielkategorie abgegrenzten Gruppen vorgenommen.

Die meisten verfügbaren Lexika sind in englischer Sprache verfasst, sicherlich auch weil das die *lingua franca* und die dominierende Sprache der internationalen Forschergemeinde ist (Medhat et al., 2014). Vermutlich spielt ebenso die leichte Grammatik des Englischen und die Verfügbarkeit annotierter Datensätze, Korpora und computerlinguistischer Werkzeuge eine Rolle. Es gibt jedoch auch Bestrebungen, Lexika für die deutsche Sprache zu erstellen, beispielsweise die Sentiment Phrase List der Hochschule Hof (Rill et al., 2012b; Rill et al., 2012a) oder das *German-Polarity-Clues-Lexikon* (Waltinger, 2010). Anhand der Anzahl der beinhalteten Einträge lässt sich die lexikalische Reichweite ablesen.

Ferner ist die Anzahl der Kategorien ein entscheidendes Differenzierungsmerkmal. Diese reichen von einfachen Wortlisten wie der *Positive Word List* (Calin, o.J.) bis hin zu einfachen Lexika wie dem *Affix Seeds Lexicon* (Mohammad et al., 2009), dem Lexikon von Hatzivassiloglou & McKeown (1997), dem Lexikon von Turney & Littman (2003), dem *Macquarie Semantic Orientation Lexicon* (Mohammad et al., 2009) oder dem *Opinion Lexicon* (Hu, M. & Liu, 2004; Liu, B., Hu & Cheng, 2005), die lediglich über die positive und negative Polarität mittels eines kategorischen Indikators Auskunft geben. Lexika wie die deutsche *Sentiment Phrase List* (Rill et al., 2012b; Rill et al., 2012a), das Lexikon AFINN (Nielsen, F. Arup, 2011), das *English Twitter Sentiment Lexicon* (Rosenthal et al., 2015), das SentiWordNet (Baccianella, Esuli & Sebastiani, 2010), das MPQA *Subjectivity Lexicon* (Wilson et al., 2005) sowie die Yelp- und Amazon-*Sentiment-Lexicons* (Kiritchenko, Zhu, Cherry & Mohammad, 2014) geben eine feinere Abstufung der Polarität wieder. Emotionen als Zielkategorie können beispielsweise mit den Lexika *Affective Norms for English Words* (Bradley & Lang, 1999), *NRC word-emotion association lexicon* (Mohammad & Turney, 2010), SentiSense (Carrillo de Albornoz et al., 2012), EmotiNet (Balahur et al., 2012), Emotion Words von DeRose (2005), dem SenticNet (Cambria, Speer, Havasi & Hussain, 2010; Cambria, Havasi & Hussain, 2012a; Cambria, Olsher & Rajagopal, 2014a) oder dem *Word-Emotion Association Lexicon* (Mohammad, 2012; Mohammad & Kiritchenko, 2015) analysiert werden.

Eine Sonderkategorie der Emotionen stellt das *Language Assessment by Mechanical Turk* Lexikon dar, das den auf Suchmaschinen basierten Rang der *Happiness* wiedergibt (Dodds, Harris, Kloumann, Bliss & Danforth, 2011). Eine dezidierte Betrachtungsweise ermöglichen das *General-Inquirer-Lexikon* (Stone, o.J.; Stone et al., 1966; Stone, 1997) mit 182 Kategorien

und der *Linguistic Inquiry and Word Count* mit über 70 Zielgruppen (Pennebaker, Francis & Booth, 2001). Aufgrund der immanenten Struktur von WordNet ist bei dem WordNet-Affect ebenfalls eine hierarchischen Struktur hinterlegt (Strapparava & Valitutti, 2004; Strapparava, Valitutti & Stock, 2006; Valitutti, Strapparava & Stock, 2004). Darüber hinaus gibt es wenige Lexika, die eine dimensionale Emotionsausrichtung vorgeben, wie *the Dictionary of Affect* (Whissell, 1989, 2009), die Liste *Norms of valence, arousal, and dominance* (Warriner, Kuperman & Brysbaert, 2013) oder das *English EMotional TERms* (EMOTE) (Grühn, 2016). Die genannten Lexika sind in Tabelle 24 nochmals zur Übersicht dargestellt. Es sei an dieser Stelle angemerkt, dass dies nur einen Bruchteil der verfügbaren Lexika in der Sentimentanalyse darstellt und keiner vollumfassenden Liste entspricht.

Lexikon	Anzahl der Kategorien	Anzahl der Einträge	Werte
<i>Affective Norms for English Words</i> (ANEW)	Glück, Wut, Trauer, Angst, Ekel	1.034 Wörter	$\{x \in \mathbb{N}   1 \leq x \leq 5\}$
AFINN-111	3 (positiv, negativ, neutral)	2.477 Wörter	$\{x \in \mathbb{Z}   -5 \leq x \leq 5\}$
<i>Affix Seeds Lexicon</i> (ASL)	2 (positiv und negativ)	5.031 (2.379 positive und 2.652 negative)	$\{0, 1\}$
<i>Amazon Laptop Sentiment Lexicon</i>	2 (positiv und negativ)	26.577 Unigramme, 155.167 Bigramme	$\{x \in \mathbb{R}   0 \leq x \leq 1\}$
<i>DeRoses Emotion Words</i>	10 (Pleasure/Pain, Power / Control / Responsibility, Attachment, Social standing / Face, Acceptance, Justice, Freedom, Direction / Focus, Desire / Interest, Safety / Security)	578 Wörter	$\{0, 1\}$
EmotiNet	7 (Ärger, Ekel, Furcht, Schuld, Freude, Trauer, Scham)	Nicht verfügbar	$\{0, 1\}$
<i>English EMotional TERms</i> (EMOTE)	( <i>valence, arousal, emotionality, concreteness, imagery, familiarity, clarity of meaning</i> )	2.237 Wörter	–
<i>English Twitter Sentiment Lexicon</i>	2 (positiv und negativ)	ca. 1.500	$\{x \in \mathbb{R}   0 \leq x \leq 1\}$
<i>General Inquirer</i> (inklusive Harvard-IV-4 und Lasswell)	182 Kategorien, darunter positiv und negativ	4.206 (Positiv 1.915, Negativ 2.291)	$\{0, 1\}$
<i>GermanPolarityClues Lexikon</i>	3 (positiv, negativ, neutral)	56.200 (3.632 positive, 5.929 negative und 1.229 neutrale)	$\{x \in \mathbb{R}   0 \leq x \leq 1\}$
<i>Language Assessment by Mechanical Turk</i> (labMT) 1.0	<i>Happiness rank</i> , Twitter und Google Rang	10.222 Wörter	$\{x \in \mathbb{R}   1,3 \leq x \leq 8,5\}$
<i>Lexikon von Hatzivassiloglou und McKeown</i>	2 (positiv und negativ)	1.336 (657 positive und 679 negative)	$\{0, 1\}$
<i>Lexikon von Turney und Littman</i>	2 (positiv und negativ)	3.596 (1.614 positive und 1.982 negative)	$\{0, 1\}$
<i>Linguistic Inquiry and Word Count</i> (LIWC)	Mehr als 70 Klassen	2,300 Wörter	$\{0, 1\}$
<i>Macquarie Semantic Orientation Lexicon</i> (inklusive ASL und General Inquirer)	2 (positiv und negativ)	76.400 (30,458 positive und 45.942 negative)	$\{0, 1\}$
<i>MPQA Subjectivity Lexicon</i>	4 (jeweils schwache und starke Ausprägung von positiv und negativ)	6,885 Wörter 8,221 Lemmata (2,718 positive und 4,912 negative)	$\{x \in \mathbb{N}_0   -2 \leq x \leq 2\}$
<i>Norms of valence, arousal, and dominance</i>	3 ( <i>valence, arousal, dominance</i> )	13.915 Wörter	$\{x \in \mathbb{R}   1 \leq x \leq 9\}$
<i>NRC word-emotion association lexicon</i>	2 (positiv und negativ), 8 (Freude, Trauer, Ärger, Angst, Überraschung, Erwartung, Vertrauen, Ekel)	Mehr als 24.200 Bedeutungen, ca. 14.200 Wörter	$\{0, 1\}$

<b>Opinion Lexicon</b>	2 (positiv und negativ)	6.789 (2.006 positive, 4.783 negative)	$\{-1, 0, 1\}$
<b>Positive Word List</b>	1 (nur positiv)	1.352	$\{0, 1\}$
<b>SenticNet</b>	<i>Pleasantness, Attention, Sensitivity, Aptitude, Polarity</i>	13.741 Wörter	$\{x \in \mathbb{R} \mid -1 \leq x \leq 1\}$
<b>Sentiment Phrase List (SePL)</b>	3 (positiv, negativ, neutral)	Mehr als 14.000 Wörter und Phrasen	$\{x \in \mathbb{R} \mid 0 \leq x \leq 1\}$
<b>SentiSense</b>	20 Emotionen	2.190 Synsets, 5.496 Wörter	$\{0, 1\}$
<b>SentiWordNet</b>	3 (positiv, negativ, neutral)	56.200 (47.806 positive und 8397 negative)	$\{x \in \mathbb{R} \mid 0 \leq x \leq 1\}$
<b>The Dictionary of Affect</b>	3 ( <i>pleasantness, activation, imagery</i> )	8.734 Wörter	$\{x \in \mathbb{R} \mid 1 \leq x \leq 3\}$
<b>WordNet-Affect</b>	Hierarchische Struktur	918 Synsets, 1637 Wörter, 2215 Bedeutungen	$\{0, 1\}$
<b>Word-Emotion Association Lexicon</b>	8 (Ärger, Ekel, Furcht, Erwartung, Freude, Trauer, Überraschung, Vertrauen)	16.862 Wörter	$\mathbb{R}_+$
<b>Yelp Restaurant Sentiment Lexicon</b>	2 (positiv und negativ)	39.274 Unigramme, 276.651 Bigramme	$\{x \in \mathbb{R} \mid 0 \leq x \leq 1\}$

Tabelle 24: Übersicht gängiger Lexika im Bereich der Sentimentanalyse

Wenngleich es eine gewisse lexikalische Überlagerung zwischen den oben genannten Listen gibt, so unterscheiden sich die Zuordnungen der Terme in den Lexika doch unverkennbar, wie Potts (2011a) herausarbeitete. Wobei er in seiner Gegenüberstellung graduelle Abstufungen der Polaritätswertigkeit ignorierte und eine eindeutige Zuordnung zu einer Zielkategorie vornahm, sofern der eine bzw. der andere Wert höher war. Gab es eine Bewertung und war diese Bewertung hinsichtlich der positiven und der negativen Ausprägung gleich, so wurde dies von ihm als Zeichen für die Zugehörigkeit zur neutralen Kategorie gesehen.

In der nachfolgenden Tabelle 25 werden die Anzahl der abweichenden Terme, die Gesamtzahl der in beiden Lexika existenten Terme und die prozentuale Abweichung der Untersuchung von Potts (2011a) dargestellt. Ungleiche Methoden als Grund für Unterschiede in den Lexika sind nicht von der Hand zu weisen, doch einen größeren Anteil hat die Domäne, in der die Wörter verwendet werden (Pang & Lee, 2008). An dieser Stelle soll erwähnt werden, dass der für die Erstellung zugrunde liegende Eingangsdatensatz einen maßgeblichen Einfluss auf das Ergebnis hat.

	<b>MPQA</b>	<b>Opinion Lexicon</b>	<b>Inquirer</b>	<b>SentiWord Net</b>	<b>LIWC</b>
<b>MPQA</b>	–	33/5402 (0.6 %)	49/2867 (2 %)	1127/4214 (27 %)	12/363 (3 %)
<b>Opinion Lexicon</b>		–	32/2411 (1 %)	1004/3994 (25 %)	9/403 (2 %)
<b>Inquirer</b>			–	520/2306 (23 %)	1/204 (0.5 %)
<b>SentiWordNet</b>				–	174/694 (25 %)
<b>LIWC</b>					–

Tabelle 25: Abweichungsgrad bei ausgewählten Meinungslexika (Potts, 2011a)

## 5.2.4 Entität- oder Aspektebene

Eine Sonderform der Sentimentanalyse bezieht sich auf die Entität- oder Aspektebene, die aufgrund des Fokus dieser Arbeit nur der Vollständigkeit wegen genannt wird. Der Grundgedanke dahinter besteht darin, die Meinung in Kombination mit einem Bezugspunkt zu erfassen (Liu, B. & Zhang, 2012; Liu, B., 2012). Um ein Ergebnis auf der Entitäts- oder Aspektebene zu erhalten, gibt es zwei verschiedene Ansätze: Zum einen können zuerst die Entitäten bzw. die dazugehörigen Aspekte identifiziert werden, um anschließend eine Sentimentanalyse durchzuführen (Yi, Nasukawa, Bunescu & Niblack, 2003), zum anderen kann man sich an dem Forschungszweig der aspektbasierten Sentimentanalyse orientieren (Lu, B., Ott, Cardie & Tsou, 2011; Titov & McDonald, 2008).

## 5.2.5 Bewertung

Die Bewertung wird mit Hinblick auf den zugrunde liegenden Textkorpus getroffen. Eine Sentimentanalyse auf Dokumentebene ist, wie oben gezeigt, nur bedingt sinnvoll, da es dabei oft an Genauigkeit mangelt und Meinungsgrenzen verschwimmen. Ein weiterführendes Problem ist die Bandbreite der Nachrichtenkommentare, die von einzelnen Wörtern bis hin zu langen Ausführungen reichen kann. Hinzu kommt die urheberrechtliche Situation, die die Speicherung längerer Texte aus besagten Quellen einschränkt. Aus diesen Gesichtspunkten heraus wird eine Betrachtung auf Textpassagenebene ebenfalls als zielführend und notwendig erachtet. Eine partielle Unterteilung eines Dokuments ist nicht trivial. Hierzu könnten beispielsweise inhaltliche Abgrenzungen vorgenommen oder satzbasierte bzw. textbausteinzugrundeliegende Heuristiken verwendet werden.

Die Suche nach der optimalen Granularitätsstufe lässt sich in die Frage nach der richtigen Länge des zu untersuchenden Textes umformulieren. Dies ist ein Aspekt, der nur bedingt durch die oben genannten Aufteilungsschemata beantwortet wird. An dieser Stelle wird die Forschungsfrage aufgeworfen, wie groß die Passage des zu bewertenden Textes sein soll, um eine optimale Meinungsklassifikation zu ermöglichen.

## 5.3 Herangehensweise existenter Sentimentanalysen

Ein drittes Kriterium, um Forschungsströmungen rund um die Sentimentanalyse einzuordnen, ist die Herangehensweise. Die Einordnung ist nicht überschneidungsfrei. Denn die Auswahl bzw. Verwendung einzelner Merkmale oder die Stufe der Granularität haben einen Einfluss auf die Wahl der Methode. Als Überblick der einzelnen Sentimentanalyseverfahren wird sich hier grob an dem Schema von Medhat et al. (2014) und Ravi & Ravi (2015) orientiert,

welches in Abbildung 18 in einer abgewandelten Baumstruktur dargestellt ist. Im Vergleich zu Liu, B. (2012), auf dessen Gedanken diese Differenzierung fußt, fächern Medhat et al. (2014) die korpusbasierten Ansätze weiter auf.

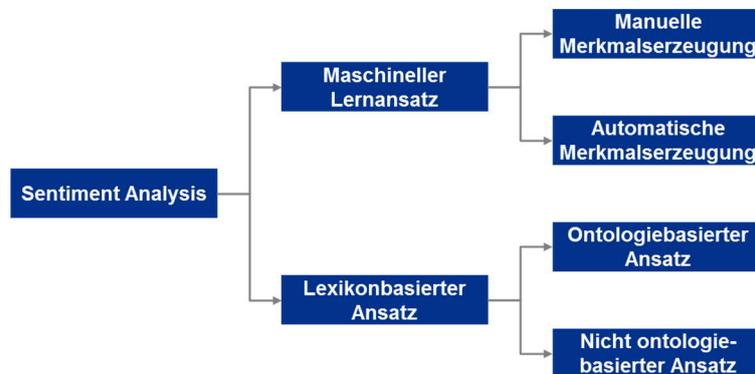


Abbildung 18: Unterscheidungen der Sentimentanalyse (nach Medhat et al., 2014; Ravi & Ravi, 2015)

Im Gegensatz zur Granularität des Betrachtungsumfangs und analog zur Differenziertheit der Ergebnisunterteilung lässt sich bei der Sentimentanalyse aus methodischer Sicht eine Entwicklungstendenz herausarbeiten. Während die Sentimentanalyse anfänglich hauptsächlich auf lexikonbasierten Ansätzen basierte, fand zunehmend eine Verschiebung hin zu maschinellen Lernverfahren statt. Nichtsdestotrotz gibt es zum lexikalischen Ansatz immer noch einige Forschungsarbeiten (Liu, B., 2015c; Ravi & Ravi, 2015), wobei rein manuelle Siebungsverfahren durch unterschiedliche elaboriertere mathematische Verfahren, beispielsweise das Labelpropagationsverfahren, zunehmend abgelöst werden (Hamilton et al., 2016).

Ohne die Einteilung von Medhat et al. (2014) bzw. Ravi & Ravi (2015) überzustrapazieren, soll hier ein Überblick über die lexikalischen Verfahren und die maschinellen Lernansätze der Sentimentanalyse gegeben werden. Eine bloße Zweiteilung scheint dem Umfang der in der Sentimentanalyse existierenden Forschungsarbeiten kaum gerecht zu werden. Doch diese Aufteilung wurde bewusst gewählt, weil hier exakt diese beiden Forschungsgebiete bedient werden sollen.

### 5.3.1 Erstellung eines Meinungslexikons

Die Bandbreite bei der Erstellung von Meinungslexika erstreckt von der handverlesenen Worttrennung in unterschiedliche Kategorien (Stone et al., 1966) bis hin zur nahezu vollständig automatischen Generierung eines kompletten und kontextspezifischen Meinungslexikons (beispielsweise Hamilton et al., 2016). Dabei fällt, wie in Kapitel 2.5 bereits dargestellt wurde, den *Seed-Words* eine entscheidende Rolle bei der Generierung von Lexika zu. Bekannte oder manuell annotierte Schlüsselwörter werden gegen ein Wörterbuch, einen Thesaurus oder eine externe Wissensdatenbank gespiegelt, um den Wortschatz der einzelnen Zielkategorien zu

vergrößern. Die Einbeziehung von ontologischen Wissensdatenbanken, die Synonyme, Antonyme und Hyponyme als semantische Relation enthalten, ist gleichsam die häufigste Form der Lexikonerstellung (Andreevskaia & Bergler, 2006; Baccianella et al., 2010; Carrillo de Albornoz et al., 2012; Esuli & Sebastiani, 2006; Godbole, Srinivasaiah & Skiena, 2007; Hu, M. & Liu, 2004; Kim, S.-M. & Hovy, 2006b; beispielsweise Strapparava & Valitutti, 2004).

Seit den Anfängen dieses Wissenschaftszweigs gibt es die Bestrebung, Wortlisten größtenteils automatisiert bzw. mit minimalem manuellen Aufwand zu erstellen. Frühe Schritte in der Sentimentanalyse können noch in das unüberwachte Lernen eingegliedert werden. Hatzivassiloglou & McKeown (1997) untersuchten beispielsweise in einer Studie die semantische Orientierung von Adjektiven. Die Kategorienbezeichnungen wurden dabei erst im Nachgang zum Clustering vergeben. Bei der Auswahl der Kategorienamen gaben sie einfach derjenigen Wortgruppe, die die höhere durchschnittliche Häufigkeit besaß, eine positive Bezeichnung und nach dem Ausschlussverfahren dem anderen Cluster das negative Label. Auch in jüngerer Zeit wurde die Herangehensweise des unüberwachten Lernens noch herangezogen (beispielsweise Pang & Lee, 2008).

Bereits relativ früh in der Historie dieses Forschungszweigs wurden jedoch semi-überwachte oder überwachte Lernansätze bemüht. Diese verwenden *Seed-Words*, die die Eckpunkte der Meinungskategorien darstellen (Mohammad et al., 2009; Turney & Littman, 2003; beispielsweise Yu & Hatzivassiloglou, 2003; Zagibalov & Carroll, 2008). Bekannte oder gewünschte Kategorien bilden das Grundgerüst für diese Herangehensweise. Dabei werden typische Wörter, deren Polarität oder Emotionszugehörigkeit bekannt ist, in den Verarbeitungsschritt übergeben. Exemplarisch für dieses Vorgehen verwendeten Turney & Littman (2003), zwei Pioniere in der Sentimentanalyse, mit dem General Inquirer (Stone et al., 1966) eine manuell erstellte Liste, die sowohl eine positive als auch eine negative Kategorie beinhaltete. Mittels Anfragen auf den Suchmaschinenindex von 350 Millionen Webseiten vergrößerten sie die Liste kohärenter Wörter (Turney & Littman, 2003). Wilson et al. (2005) nutzten den *Multi-perspective Question Answering Opinion Corpus* (Wiebe et al., 2005) als Basis, um die als subjektiv gekennzeichneten Textpassagen und Wörter anhand des Schemas positiv, negativ, ambig und neutral zu annotieren. Dieser Datensatz wurde als Goldstandard für einen englischsprachigen Klassifikator verwendet (Wilson et al., 2005).

Die soeben genannten Beispiele lassen sich in den Bereich des korpusbasierten Ansatzes verorten (Medhat et al., 2014). Weiterführende Methoden vertrauen hingegen anderen Arten der Wissensrepräsentation. Medhat et al. (2014) bezeichnet diese als wörterbuchbasierte Ansätze. Dies ist jedoch nicht weit genug gegriffen. Ruft man sich unterschiedlichen Stufen der

semantischen Wissensrepräsentation in Gedächtnis (Harispe, Ranwez, Janaqi & Montmain, 2015) bzw. blickt man auf Abbildung 19, so stellt man fest, dass sich dieses Gliederungs-schema sehr viel besser auf die nichtlexikalischen Sentimentanalyseansätze anwenden lässt. Letztere werden in den folgenden Paragraphen anhand einiger Exemplare umrissen.

Die Verwendung eines Wörterbuchs als Grundlage in der Lexikonerstellung entspricht einer der einfachsten Formen der Differenzierung. Das bereits erwähnte *Affix Seeds Lexicon* (ASL) ist ein Vertreter dieser Kategorie. Terme, die durch das Anhängen von Präfixen oder Suffixen an bekannte Meinungswörter entstanden, wurden mit einem Wörterbuch abgeglichen. Existierten die Terme im Wörterbuch, gab das neue Affix den Ausschlag für eine mögliche Polaritätsannotation (Mohammad et al., 2009).

Ein Beispiel für die komplexere Differenzierung im Sinne einer höherwertigen semantischen Wissensrepräsentation nach Harispe et al. (2015) ist die Erstellung eines niederländischen Meinungslexikons mittels der Integration eines semantischen Netzwerks. Ein Grundgedanke bei der Ableitung eines Meinungslexikons aus einer semantischen Wissensbasis ist, dass alle Synonyme die gleiche Grundbedeutung und ebenfalls die gleiche Polaritätsorientierung haben (Maks & Vossen, 2010). Da der Polaritätsgrad zwischen den Synonymen abweichen kann, wurde die Stärke der Meinungsladung in einer weiterführenden Arbeit von Maks & Vossen (2012) um eine zusätzliche Datenschicht pro lexikalischer Einheit ergänzt, um den Subjektivitätsgrad eines Terms zu modellieren. Beginnend mit wenigen Wörtern mit bekannter Polarität, wird mittels der semantischen Relationen der Pool der bekannten Wörter iterativ durch Pfadanalysen oder ein Kriterium der minimalen Distanz erweitert. Der Lexikongenerierungsprozess stoppt, wenn keine weiteren Wortrelationen gefunden werden können oder wenn der Algorithmus einen parametrisierten Schwellenwert erreicht (Liu, B., 2012).

Der Vorteil dieses Ansatzes liegt in der bereits ausgearbeiteten Verfügbarkeit der Wörterbücher bzw. der semantischen Wissensquellen. Des Weiteren lässt sich beispielsweise relativ unkompliziert und schnell ein praktikables Meinungslexikon über ein Online-Tool erstellen (Potts, 2011a, 2011b). Die Güte des resultierenden Lexikons hängt selbstverständlich vom Umfang und dem Vernetzungsgrad der zugrunde liegenden semantischen Wissensbasis ab sowie von dem zugrunde liegenden semantischen Ansatz.

Als nächste Stufe der semantischen Wissensrepräsentation nach Harispe et al. (2015) wird bei der Erstellung von Sentimentlexika auf externe Wissensquellen in Form von webbasierten Ontologien oder auch auf Domänenwissen zurückgegriffen (Olsher, 2012). Potts (2011a) zeigt die häufig genutzte *WordNet-Propagation* auf, bei der Lexika ebenfalls mittels verlesener *Seed-Words* aus den Strukturen und Abhängigkeiten der Terme innerhalb von WordNet

generiert werden. Ein minimalistischer Ansatz für die Verwendung von *Seed-Words* in Verbindung mit WordNet stellt die Forschungsarbeit von Kamps, Marx, Mokken & Rijke (2004) dar. Sie verwendeten lediglich die zwei *Seed-Words* „good“ und „bad“, um weitere Adjektive mittels der geringeren WordNet-Distanz einer der beiden Gruppen zuzuordnen. Andreevskaia & Bergler (2006) kreierte mittels weniger *Seed-Words* und iterativer Anfragen an WordNet, bei der sie sich auf Synonyme, Antonyme und Hyponyme konzentrierten, ein Lexikon mit abgestuften Polaritätsausprägungen. Letztere errechneten sie durch einen *Net-Overlap-Score* der Häufigkeit der positiven und negativen Zuweisungen in den jeweiligen Durchgängen (Andreevskaia & Bergler, 2006). Das bloße Einbeziehen des Bedeutungsabstandes, gemessen an der Anzahl der Sprünge mittels Synonymen und Antonymen, wird an anderer Stelle jedoch angefochten (Godbole et al., 2007), da die iterativ wachsende Synonymgruppe die Distanz zu anderen Termen verringert. In ihrer Forschungsarbeit schlagen sie daher vor, den Pfad zwischen einem *Seed-Word* und einem untersuchten Wort miteinzubeziehen. Die auf dem Pfad liegenden Wörtern und deren Polarität werden als Eingangsgröße in das Modell zurückgeführt.

Der bequemeren Handhabung einer elaborierteren Wissensrepräsentation steht jedoch auch eine Kehrseite gegenüber. Wie bei Medhat et al. (2014) hervorgeht, birgt ein Lexikon, das auf diesem Wege erzeugt wurde, immer die Gefahr, dass die Kontextorientierung auf eine bestimmte Domäne nur bedingt gegeben ist. Die Abhängigkeit von semantischen Wissensdatenbanken ist auch von Nachteil, denn die Wissensrepräsentation ist fest vorgegeben und erlaubt keine strukturellen Abweichungen von der immanenten Wissensdarstellung (Cambria, 2013). Darüber hinaus haftet den nicht korpusbasierten Wissensrepräsentationen ein weiterer Makel an, nämlich dass die Reichweite semantischer Netzwerke begrenzt ist (Zhekova, 2013). Gleiches gilt sicherlich in deutlicherem Maße auch für eine lexikalische oder taxonomiebasierte Wissensbasis. Somit stellt die Verfügbarkeit solcher Wissensrepräsentationen für einen spezifischen Kontext und die eingeschränkte Reichweite ein deutliches Hindernis dar, das angesichts der deutschsprachigen Nachrichtenkommentare mit niedriger Datenqualität und spezifischer Ausdrucksweisen noch schwerer wiegt.

Neuere Forschungsarbeiten hingegen zeigen einen Ausweg, um diese Hürden zu umgehen: Einerseits besinnen sie sich der korpusbasierten Grundlage und andererseits vereinen sie das Beste aus beiden Welten. Realisiert wird dies, indem eine semantische Wissensrepräsentation aus einem Textkorpus gebildet wird. Mittels der in Kapitel 7.2.2.2 und 7.2.2.3 vorgestellten Methoden kann ein kontextabhängiges, aber dennoch weitreichendes semantisches Netz gebildet werden, dessen Termreichweite nur durch den Parameter der minimalen Wortanzahl begrenzt ist. Hamilton et al. (2016) nutzten eine kleine Anzahl an *Seed-Words*, um aus einem

kontextrelevanten Korpus mittels der *Singular-Value-Decomposition*-Methode, die in Kapitel 7.2.2.2.1 beschrieben wird, semantische Ähnlichkeiten zu extrahieren.

Anhand des k-nächste-Nachbarn-Algorithmus und einer auf der Kosinusähnlichkeit basierenden Gewichtung wurde daraufhin ein *Markov-Random-Walk* angewandt (Bengio, Delalleau & Le Roux, 2006; Hamilton et al., 2016), mit dem Ziel, „to predict the labels of the unlabeled points“ (Zhou, Bousquet, Lal, Weston & Schölkopf, 2004, S. 321). Auf dieser Grundlage wurden die Polaritäten der bekannten Terme innerhalb des Netzwerkes weitergegeben werden. Hamilton et al. (2016) ihrerseits wenden diesen Ansatz mit der Wissensrepräsentation auf unterschiedliche *Random-Walk*-Herangehensweisen an (darunter Velikovich, Blair-Goldensohn, Hannan & McDonald, 2010; Zhou et al., 2004; Zhu & Ghahramani, 2002; Zhu, Ghahramani & Lafferty, 2003). Alle Varianten erzielten äquivalente oder vergleichbare Ergebnisse (Hamilton et al., 2016). Auch der Ansatz von Alhothali & Hoey (2017, S. 4) reiht sich in diese sogenannte „*Corpus-Based Label-Propagation*“ ein, wobei an dieser Stelle *Word-Embeddings* als Wissensrepräsentation verwendet werden und eine Wortannotation anhand eines dreidimensionalen Emotionsschemas (vgl. Kapitel 2.3.1.4) stattfindet.

### **5.3.2 Maschinelle Lernansätze in der Sentimentanalyseforschung**

Anders als bei dem eingangs vorgestellten Unterscheidungsmuster von Medhat et al. (2014) wird hier nicht eine Differenzierung zwischen überwachtem und unüberwachtem Lernen gewählt. Unüberwachte Lernvorgänge führen in der Sentimentanalyse eher ein Schattendasein, da es nur sehr wenige Ansätze gibt, wie das auf der latenten Dirichlet-Allokation basierende *Joint-Sentiment/Topic-Model* (Lin & He, 2009). Letzteres gilt auch für semi-überwachte Lernumgebungen, beispielsweise bei Scheible & Schütze (2013), die bei der Subjektivitätsanalyse von Filmbewertungen einen semi-überwachten Lernansatz und Transferlernen anhand semantischer Merkmale aus Worttaxonomien, Eigennamen und Merkmalssequenzen verwenden. Auch Liu, B., Dai, Li, Lee & Yu (2003) beschreiten einen nur teilweise überwachten Lernansatz, indem sie nur positiv und nicht annotierte Textbeispiele in einem zweistufigen Prozess mit der *Support-Vector-Machine*-Methode geben.

Neuere Studien lassen sich von früheren Forschungsarbeiten dadurch unterscheiden, dass in aktuellen Forschungsarbeiten der manuelle Merkmalserschöpfungsprozess kaum oder gar nicht mehr vorhanden ist. Die handverlesene Merkmalsgewinnung wird zunehmend abgelöst durch maschinell gewonnene Merkmale. Wie in Kapitel 7.3 noch detailliert ausgeführt wird, kamen in den Anfängen unter anderem konstruierte Merkmale wie Wortarten, Diathese bzw. auch andere morphemische Informationen, Dependenzgraphen, vereinfachte und syntaktische

korrekte Negationsansätze, Wertigkeitsnivellierung, Satzzeichen, Satzposition eines Wortes, Kontextwörter, verlängerte Schreibweise, Emoticons, Hashtags, Großschreibung oder auch Eigennamen zum Einsatz. Während in den ersten Zügen nur wenige Merkmale Einzug in die Analyse fanden (beispielsweise Pang et al., 2002), nahm die Anzahl der Merkmale über die Jahre hinweg zu (exemplarisch dazu Kim, S.-M. & Hovy, 2006a; Wilson et al., 2005) oder wurde mittels interner Schleifen (Hu, M. & Liu, 2004), einer Kombination mit Aspekten (Titov & McDonald, 2008), dem Zutun externer Wissensdatenbanken (z.B. Biagioni, 2016) oder anderer Modifikationen immer ausgefeilter.

Selbstredend kann dieselbe Entwicklung auch anhand der Wahl der Methoden nachgezeichnet werden. So wurde die Sentimentanalyse in der frühen Phase noch unter Zuhilfenahme von *Information-Retrieval*-Systemen wie AltaVista gelöst (Turney, 2002). Auch die unterschiedlichen vektoriellen Ähnlichkeitsmaße, die in Kapitel 7.2.1 vorgestellt wurden, der *Expectation-Maximization*-Algorithmus oder der naive Bayes-Klassifikator ebneten den Weg für die Sentimentanalyse (Das & Chen, 2001; Koller & Sahami, 1996; Nigam, Lafferty & McCallum, 1999; Yu & Hatzivassiloglou, 2003). Jedoch fanden auch früh Ansätze wie die *Support-Vector-Machine* (Pang et al., 2002) oder auch Methoden in Verbindung mit semantischen Netzwerken (Andreevskaia & Bergler, 2006) den Weg in die Sentimentanalyse. Methodisch ist auch in neueren Studien noch die komplette Bandbreite der soeben genannten Ansätze vertreten (auszugsweise Dey, Chakraborty, Biswas, Bose & Tiwari, 2016; Wang, S. & Manning, 2012). In den weit über hundert Artikeln über Sentimentanalyseanwendungen waren neben dem lexikonbasierten Ansatz die Herangehensweisen mittels *Support-Vector-Machine* und naivem Bayes-Klassifikator besonders häufig vertreten (ausführlich dazu Medhat et al., 2014; Ravi & Ravi, 2015). Nicht zu vergessen sind Sentimentanalysen, basierend auf neuronalen Netzen (z.B. Moraes, Valiati & Gavião Neto, 2013; Socher et al., 2013). Die aspektbasierte Sentimentanalysebewegung löste ein Aufleben der latenten Dirichlet-Allokation aus (z.B. Lin, He, Everson & Ruger, 2012; Moghaddam & Ester, 2013; Titov & McDonald, 2008), was auch andere Methoden wie die *Probabilistic-Latent-Semantic-Analysis* (Lu, Y. & Zhai, 2008; Moghaddam & Ester, 2011) auf den Plan rief.

Erst jüngst ist eine Tendenz zur Abkehr von *Bag-of-Words*-Modellen mit oder ohne Rückgriff auf N-Gramme erkennbar, wodurch nahezu alle hier genannten Herangehensweisen geprägt waren. Es stellte einen Meilenstein in der Sentimentanalyse dar, dass begonnen wurde, eine Klassifikation auf Basis der syntaktisch korrekten Wortreihenfolge in Verbindung mit Wortrepräsentationen, wie in Kapitel 7.2 beschrieben, durchzuführen. In diese Herangehensweisen der Sentimentanalyse sind Conditional-Random-Fields (Hao, Z., Cai, Yang, Wen &

Liang, 2017; Samha, Li & Zhang, 2015; Wang, Y., Feng, Wang, Yu & Zhang, 2016), *Long-Short-Term-Memory* (Barry, 2017; Feng, S., Wang, Liu, Wang & Yu, 2019), *Recursive-Neural-Network* (Al-Smadi, Qawasmeh, Al-Ayyoub, Jararweh & Gupta, 2018; Cheng, Li, Ding, Zhang & Wang, 2016; Dong et al., 2014; Majumder et al., 2018) *Convolutional-Neural-Network* (Alali, Sharef, Hamdan, Murad & Husin, 2018; Chen, Y., Hou & Cheng, 2018; Ebert, Vu & Schütze, 2015; Hamdi, Rady & Aref, 2018; Kim, Y., 2014; Segura-Bedmar, Quirós & Martínez, 2017), *Recurrent-Convolutional-Neural-Network* (Kim, Y. & Lee, 2018), oder kombinierte Methoden wie *Convolutional-Neural-Network* mit *Long-Short-Term-Memory* (Khanpour & Caragea, 2018; Shen, Wang & Sun, 2017) bzw. auch *Long-Short-Term-Memory* mit *Convolutional-Neural-Network* (Ong, 2019; Sosa, 2017) einzuordnen. Wie an der aktuellen Forschung ersichtlich wird, gibt es zahlreiche Methoden, die syntaktische Informationen berücksichtigen. Bei der Erstellung des Versuchsaufbaus wurde der *Convolutional-Neural-Network* Methode gegenüber der berechnungsintensiveren *Long-Short-Term-Memory* Methode der Vorzug gegeben.

Auf dieser Grundlage erstellte beispielsweise Kim, Y. (2014) ein *Convolutional-Neural-Network* (CNN), mit dem er eine satzbasierte Polaritätserkennung durchführte. Davon inspiriert, führten Tripathi, Acharya, Sharma, Mittal & Bhattacharya (2017) eine ähnliche Untersuchung durch, jedoch bezog sich deren Ergebnis auf die psychologischen Valenz- und Aktivitätsdimensionen der Emotionen. Der gleiche Weg über das word2vec-Verfahren und ein CNN wird auch bei sozialen Medien (Ouyang et al., 2015), Mikrobloggingdiensten (Deriu & Cieliebak, 2016; He, Zhang, Ren & Sun, 2014; Kalchbrenner, Grefenstette & Blunsom, 2014; Stojanovski, Strezoski, Madjarov & Dimitrovski, 2015) oder Produktbewertungen (Gui, Zhou, Xu, He & Lu, 2017) beschritten. Zhang, Y. & Wallace (2015) steuerten bei der Satzklassifikation mittels dieser Methode eine großflächige Untersuchung der Parametereinstellungen bei. Auch diese Arbeit baut auf dem aktuellen Stand der Forschung auf, fußt auf jener Idee der Kombination von vektorialen Wortrepräsentationen und der CNN-Methode und beschreitet ähnlich wie der zuletztgenannte Ansatz eine Untersuchung des Parameterhyperraums, jedoch mit dem Fokus Designalternativen zu explorieren.

### 5.3.3 Bewertung

Es bleibt festzuhalten, dass es grundsätzlich zwei methodische Ansätze gibt. Einerseits die lexikonbasierten, die ausgehend von einem Zwischenschritt der Einzelwortbetrachtung über eine Meinungsaggregation auf Textpassagenebene zu einem Ergebnis kommen. Andererseits

die maschinellen Lernvorgänge, die das gesamte Textfragment betrachten und ohne den Umweg einer Zwischenbewertung eine Sentimentklassifikation vornehmen.

Unter den lexikonbasierten Verfahren beschreiten nur wenige den Weg der Emotionsdetektion. Neben handsortierten Listen sind dort überwiegend netzwerkbasierende Verfahren anzutreffen, deren Grundlage ein existentes semantisches Netzwerk oder eine Ontologie bilden. Letzteren haften die fehlende Reichweite, die kostspielige Erstellung und die eingeschränkte nichtenglischsprachige Verfügbarkeit an. Diese weiterführende Wissensgrundlage wurde im Zuge neuerer Verfahren durch eine vektorielle Informationshaltung abgelöst, indem die semantischen Netzwerke mittels unterschiedlicher Methoden korpusbasiert erstellt wurden. Unter diesen Methoden finden sich bis dato jedoch nur bipolare Ansätze. Dieser Faden wird in dieser Arbeit aufgenommen und ein mehrgliedriges Emotionslexikon gesponnen.

Darüber hinaus wird ebenfalls an der aktuellen Forschung der Textklassifikation mittels maschineller Lernansätze angesetzt. Die Tendenz weist hier deutlich in Richtung des überwachten Lernens in Verbindung mit automatisch generierten Merkmalen. Ähnlich wie bei den lexikalischen Ansätzen wurden die neusten Methoden kaum auf nichtenglischsprachige Texte und auf eine feingranulare Sentimentanalyse angewendet. Auch diese Lücke soll mit dieser Arbeit partiell geschlossen werden.

Anders als bei der computerlinguistischen Stoßrichtung konzentriert sich diese Arbeit nicht ausschließlich auf automatisch generierte Merkmale. Vielmehr wird unabhängig vom lexikalischen oder maschinellen Lernansatz die Frage gestellt, inwieweit sich eine zusätzliche Merkmalsanreicherung positiv auf die Sentimentanalyse auswirkt.

## 6 Hypothesen

Bis zum jetzigen Zeitpunkt fußt die Auswahl eines geeigneten Emotionsmodells aus Kapitel 2.5 auf einer rein argumentativen Basis. Unter Verwendung des annotierten Textkorpus und unter Berücksichtigung der aktuellen Sentimentanalyseforschung soll dieses theoretische Konstrukt überprüft werden. Dies stellt somit die empirische Überprüfung eines theoretischen Modells der Psychologie mit Methoden der Computerlinguistik dar. Die Ergebnisse der Anwendung des Emotionsmodells werden anhand methodenspezifischer Beurteilungskriterien überprüft, um den Beweis der Eignung dieses theoretischen Unterbaus anzutreten.

### 6.1 Hypothese zur Ebene der Granularität

Die in Kapitel 5 herausgearbeiteten Entwicklungsrichtungen werden im Folgenden als Frage formuliert. Das bezieht sich auf die Granularität der Eingabe, die methodische Herangehensweise sowie Datenreduktionen und -anreicherungen. Alle Punkte werden unterschiedlich bearbeitet und mittels statistischer Signifikanztests einer Hypothesenüberprüfung unterzogen.

In Kapitel 5.2 wurde hinsichtlich der Granularitätsstufe bereits herausgearbeitet, dass nur eine Betrachtung auf Phrasenebene sinnvoll ist. Die Größe der Textmenge stellt jedoch ein offenes Feld dar, speziell mit Hinblick auf die Emotionserkennung. Ist der einzelne Satz mit dem Emotionsvorkommen für eine computerlinguistische Bestimmung ausreichend oder kann zusätzlicher Kontext die Ergebnisqualität verbessern? Dafür spricht beispielsweise, dass sich Bezüge über Satzgrenzen hinweg erstrecken und Bezugsentitäten mittels Pronomen aufgegriffen werden können (Sadamitsu et al., 2008). Geprüft werden soll somit, ob der Emotionssatz allein, der Emotionsatz mit vorangegangenem Satz, mit nachfolgendem Satz oder mit beiden angrenzenden Sätzen besser für eine feingranulare Sentimentanalyse geeignet ist. Es wird vermutet, dass sich zusätzliche Informationen positiv auswirken. Da die Frage, ob der vorangegangene oder der nachfolgende Satz einen größeren Mehrwert liefert, nicht mittels einer argumentativen Logik beantwortet werden kann, wird ein unbestimmtes Signifikanzniveau für die Überprüfung zugrunde gelegt. Diese und alle nachfolgenden Hypothesen werden direkt als Nullhypothesen formuliert, die es mit statistischen Mitteln zu falsifizieren gilt, um die Behauptung des Unterschieds zwischen zwei oder mehreren Gruppen zu untermauern. Die zu widerlegende Gegenhypothese lautet in diesem Fall:

H1: Die Granularitätsebene, ob ein Emotionsatz mit oder ohne Kontext in die Analyse eingeht, hat keinen Einfluss auf die Ergebnisse.

## 6.2 Hypothesen zur methodischen Herangehensweise

In Kapitel 5.3 wurden zwei methodische Herangehensweisen als die aktuell in der Forschung dominierenden Ansätze herausgearbeitet. Im Folgenden sollen der lexikonbasierte und der textpassagenumspannende Ansatz einander gegenübergestellt werden. In diesem Zusammenhang sollen zwei Hypothesen überprüft werden. Bezogen auf den lexikonbasierten Ansatz soll in erster Instanz ein unüberwachter, lexikonbasierter Ansatz einer handverlesenen Emotionswortliste gegenübergestellt werden. Darüber hinaus soll in zweiter Instanz geprüft werden, ob sich der lexikonbasierte oder der maschinelle Ansatz besser für eine maschinelle Emotionserkennung eignet.

Es wird angenommen, dass eine manuell erstellte Emotionsliste besser ist als eine maschinell generierte Wortliste, basierend auf minimale Eingabewerte in Form von Schlüsselwörtern. Argumentiert wird hierbei damit, dass maschinelle Methoden der Lexikonerstellung Synonyme nicht auf der Ebene eines Muttersprachlers identifizieren können (Freitag et al., 2005), wengleich auch in diesem Feld beträchtliche Fortschritte erzielt werden konnten (Kiela, Hill & Clark, 2015). Darüber hinaus können bei der manuellen Betrachtung Spitzfindigkeiten der jeweiligen Theorie berücksichtigt werden. Um den Unterschied der beiden Vorgehensweisen der Lexikonerstellung zu überprüfen, wird die dazugehörige, gerichtete Nullhypothese formuliert:

H2: Unter Verwendung eines lexikonbasierten Ansatzes liefert eine manuell erstellte Emotionsliste keine besseren Ergebnisse als eine maschinell generierte.

Mit Hinblick auf die methodische Herangehensweise aus Kapitel 5.3 wird als Hypothese postuliert, dass der wortbasierte Ansatz mit anschließender Aggregation gegenüber einem aktuellen maschinellen Lernansatz das Nachsehen hat. Erstens greift ein rein lexikonbasierter Ansatz zu kurz, da sich die Komplexität der Emotionen nicht auf einzelne Worte beschränken lässt, wie bereits an zahlreichen Beispielsätzen herausgearbeitet wurde. Zweitens bietet beim lexikonbasierten Ansatz der Umweg über eine Aggregationsstrategie der Einzelemotionswerte, die ebenfalls unvollkommen ist, eine zusätzliche Fehlerquelle. Drittens haben syntaktische Informationen einen deutlichen Einfluss auf die Güte einer Sentimentanalyse (beispielsweise Socher et al., 2013), weswegen Modelle wie das CNN, die dies berücksichtigen, einen Vorteil haben. Die gerichtete Nullhypothese zur Abwägung der beiden Ansätze lautet folglich:

H3: Ein lexikonbasierter Ansatz erzielt keine schlechteren Ergebnisse als ein maschineller Lernansatz.

### 6.3 Hypothesen zur Datenreduktion

Darüber hinaus soll geprüft werden, inwieweit sich die Datenreduktion positiv auf den Klassifikationsvorgang auswirkt. Dies soll anhand zweier Szenarien überprüft werden: zum einen anhand der Datenbereinigung, die mit einer Reduktion der Komplexität einhergeht, und zum anderen anhand der Wortstammreduktion. Beide Punkte werden damit begründet, dass sowohl die unsaubere Schreibweise in Nachrichtenkommentaren als auch die flexionsreiche Sprache Deutsch nachteilig für die Klassifikation sind. Der datensatzspezifische Nachteil der geringen Textqualität soll durch gezielte Vorverarbeitungsmaßnahmen mittels Datenbereinigung und -harmonisierung nivelliert werden. Folglich wird behauptet, dass die Datenbereinigung einen positiven Effekt auf die Beurteilungskriterien der beiden Herangehensweisen hat. Als Gegenhypothese, bezogen auf beide Methodenansätze, entspricht dies:

H4a: Die Datenbereinigungsschritte haben weder bei dem lexikonbasierten noch bei dem maschinellen Lernansatz eine positive Wirkung auf die Emotionsklassifikation.

Dem sprachspezifischen Komplexitätstreiber der Flexion soll durch die Zurückführung auf die lexikalische Form entgegengewirkt werden. Hier werden abhängig vom zugrunde liegenden Methodenansatz unterschiedliche Effekte erwartet. Es wird behauptet, dass der lexikonbasierte Ansatz zusätzlich von der Wortstammreduktion profitiert, weil sich die Vielfalt des Vokabulars reduziert und auch seltene Formen der Schlüsselwörter gefunden werden können. Da die Lemmatisierung auf dem bereinigten Datensatz aufbaut, ergibt sich somit eine gestaffelte Betrachtung des unveränderten Datensatzes, des bereinigten Datensatzes auf Wortebene und des bereinigten Datensatzes auf Ebene der lexikalischen Form. Als Nullhypothese formuliert, lautet die Behauptung für Emotionserkennung mittels Lexikon:

H4b: Bei der Emotionsklassifikation mittels lexikonbasierter Herangehensweise hat die Verwendung des Wortstamms weder im Vergleich zu den bereinigten noch zu den unveränderten Wörtern einen positiven Effekt.

In Verbindung mit dem CNN wird die Einschätzung der Klassifikation diffiziler. Einerseits wird davon ausgegangen, dass die Wortstammreduktion beispielsweise durch das Neutralisieren des Kasus oder der Flexion Störquellen eliminiert. Andererseits gehen durch die Reduktion auf den Wortstamm syntaktische und referentielle Informationen wie die Person, der Numerus oder Möglichkeitsformen verloren, die sich als relevant für die Klassifikationsfähigkeit des CNN herausstellen können. Letzteres sei Gegenstand einer eigenständigen Hypothesenüberprüfung.

Bedingt durch diese entgegengerichteten Einflüsse kann die Behauptung aufgestellt werden, dass neben der Datenbereinigung auch die Lemmatisierung einen Vorteil gegenüber den unbehandelten Texten hat. Es kann jedoch nicht, wie bei der lexikonbasierten Methode, eine Aussage zur Gegenüberstellung des bereinigten Datensatzes und des Datensatzes der lemmatisierten Form gemacht werden. Aus diesem Grund lautet die ergänzende Nullhypothese zu H4a wie folgt:

H4c: Bei der Emotionsklassifikation mittels CNN schneiden Modelle mit Eingabe wortstammreduzierter Wörter nicht schlechter ab als Modelle mit unbearbeiteten Texten als Eingabe.

## 6.4 Hypothesen zur Datenanreicherung

Ausgehend von der Lemmatisierung soll anhand unterschiedlicher Informationskombinationen überprüft werden, inwieweit sich eine Anreicherung zielführend für die Klassifikation herausstellt. Erstens soll geprüft werden, inwieweit grammatikalische und morphologische Informationen einen Einfluss auf die Klassifikationsergebnisse haben. Zweitens wird untersucht, ob die Zugabe von Merkmalen einer Negationserkennung die Beurteilungskriterien der Emotionserkennung positiv beeinflussen kann.

Die Anreicherung der grammatikalischen Person, des Numerus und der Möglichkeitsform sowie Kombinationen selbiger werden bei der wortstammreduzierten Methode als besonders relevant erachtet. Wie bereits gezeigt, besitzt das Emotionsmodell von Merten & Krause (1993) diffizile Unterschiede, die die Sätze „du bist ein Angsthase“ bzw. „ich bin ein Angsthase“ entweder als Verachtung oder als Angst kategorisieren lassen, abhängig von der Person des Satzes, welche hier nur durch das Personalpronomen ausgedrückt wird. Beim gleichen Beispiel bleibend, kann der Satz bei einer Veränderung des Numerus zu „wir sind Angsthasen“ auch als Schuldeingeständnis gewertet werden. Somit wird vermutet, dass morphologische und grammatikalische Informationen, insbesondere die Person und der Numerus, einen Einfluss auf die Klassifikation haben.

Neben dem grammatikalischen Numerus kommt auch dem Konjunktiv eine Rolle zu. Denn die Möglichkeitsform entscheidet in den Beispielen „wenn ich das Referat halte, dann habe ich Lampenfieber“ und „wenn ich das Referat hielte, dann hätte ich Lampenfieber“ zwischen Angst und der Kategorie Neutral. Folglich wird angenommen, dass die Hinzugabe der Wortarten in Verbindung mit morphologischen Informationen einen positiven Einfluss auf die Kategorisierung ausübt.

Zusammengefasst werden folgende gerichtete Nullhypothesen aufgestellt:

H5a: Das Hinzunehmen der wortbedingten Information der Person hat keinen positiven Einfluss auf die Klassifikation.

H5b: Die zusätzliche Verwendung des Numerus zur grammatikalischen Person als Eingabemerkmale hat keine positive Auswirkung auf die Modellgüte.

H5c: Die zusätzliche Verwendung der Möglichkeitsform zur grammatikalischen Person als Eingabemerkmale hat keine positive Auswirkung auf die Modellgüte.

Schließlich soll nochmals die Negation in der Klassifikation aufgegriffen werden. Einige der vorgestellten diskreten Modelle regeln explizit den Umgang bei einer Bedeutungsnegation (beispielsweise Plutchik, 2001; Robinson, 2008). Dies wurde jedoch argumentativ als problematisch herausgestellt, da die Negation einer Emotion nicht zwangsläufig in einer anderen spezifischen Emotion münden muss. Das gewählte Emotionsmodell lässt diese Facette jedoch offen. Nichtsdestotrotz hat die Negation einen entscheidenden Einfluss auf die Sentimentanalyse (Carrillo de Albornoz & Plaza, 2013). Daher soll diese Aussage mit Hinblick auf das Modell von Merten & Krause (1993) überprüft werden, indem sie einer Klassifikation ohne Anwendung einer Negationserkennung gegenübergestellt wird. Letzteres geschieht insbesondere mit Hinblick auf die mehrere Kategorien umfassende Emotionserkennung, anstelle der Anwendung im bipolaren Kontext der Sentimentanalyse. Die folgende Gegenhypothese wird dazu aufgestellt:

H6: Die Anwendung einer Negation hat keinen positiven Einfluss auf das Klassifikationsergebnis.

## 7 Methodisches Vorgehen

Nachdem nun ein adäquates theoretisches Emotionskonstrukt ausgewählt, freie Felder der übergreifenden Forschungsrichtung offengelegt und die zu bestimmende Analysedimensionen definiert wurden, konzentriert sich die Arbeit auf das methodische Vorgehen der Sentimentanalyse. Bei der computerlinguistischen Vorgehensweise steht dabei die Überprüfung der Hypothesen im Mittelpunkt.

Einleitend dazu werden Datenvorbereitungsmethoden vorgestellt, die bereits in der klassischen Sentimentanalyseforschung Anwendung fanden und hier einfließen werden, damit ihr Benefit für die aktuelle Sentimentanalyseforschung bestimmt werden kann. Die beiden computerlinguistischen Ansätze werden im Folgenden dezidiert beschrieben. Da sowohl der wortbasierte als auch der maschinelle Lernansatz auf vektoriellen Wissensrepräsentationen basieren, wird vorausgehend dazu erläutert, inwieweit korpusimmanente Informationen integriert werden können.

### 7.1 Datenvorverarbeitungsschritte

Die Datenvorbereitung umfasst sowohl die Überprüfung der relevanten Aspekte der Hypothesen als auch die maschinelle Nutzbarmachung des Textkorpus. Um Letzteres zu erreichen, wird, bedingt durch die niedrige Datenqualität, ein erhebliches Maß an Aufarbeitung unternommen. Die Aufwertung der Textqualität ist notwendig, um die existenten computerlinguistischen Methoden anwenden zu können. In den folgenden Kapiteln werden somit auf die Datenexklusion, -trennung, -bereinigung und -harmonisierung eingegangen. Anschließend werden zielrelevante Merkmalsanreicherungen beschrieben.

#### 7.1.1 Datenexklusion

##### 7.1.1.1 Entfernen der HTML-Formatierung

Bei Internettextrn gibt es bei einigen Kommentarfunktionen die Möglichkeit der Formatierung der Texte. Die Formatierungsmöglichkeiten sind sehr heterogen und reichen von einfachen Schriftformatierungen bis hin zu „*what you see is what you get*“ (WYSIWYG)-Editoren, bei denen der HTML-Code punktuell verändert werden kann. Neben der Gestaltung der Schriftart bieten einige Webseitenbetreiber ein vordefiniertes Set sogenannter Emojis an, kleine Bilder mit lachenden Gesichtern. Emojis werden auf Webseiten als eingebettete Bilder wiedergegeben und sind somit ähnlich wie Textformatierungsanweisungen als HTML-Tag im Text hinterlegt.

In dieser Arbeit werden alle HTML-Tags entfernt. Da die Textformatierung einen bewussten Akt der Hervorhebung darstellt und die Kontextsetzung des geschriebenen Wortes beispielsweise durch ein eingefügtes Bild beeinflusst wird, fällt diesen sprachlichen Markierungen zweifelsohne eine gewisse Bedeutungsrelevanz zu. Wegen der geringen Verbreitung der Textgestaltungsoptionen bei Nachrichtenkommentaren und der uneinheitlichen Umsetzung der Hervorhebungsmarker werden diese jedoch in dieser Arbeit nicht untersucht. Somit werden, ähnlich wie bei Project FIRST, nicht nur sogenannte *HTML-Boilerplates* entfernt (Klein et al., 2012), sondern auch formatierungsbedingte Markierungen.

### **7.1.1.2 Exklusion von Fremdsprachen und unbekanntem Texten**

In benutzergeschriebenen Kommentaren werden häufig fremd- und dialektsprachliche Phrasen oder in extremen Fällen völlig unbekannte Wörter verwendet. Beim sogenannten *Code-Switching* werden entweder einzelne Wörter aus einer Fremdsprache entlehnt oder ganze Phrasen in einer anderen Sprache geschrieben (Auer, 2003). Dies passiert, wenn z. B. auf Zitate berühmter Persönlichkeiten zurückgegriffen oder man sich der Titel bekannter Filme und Musikstücke bedient. Es kann aber auch den einfachen Grund haben, dass das deutschsprachige Wort weniger gängig, deutlich länger oder komplizierter ist als das fremdsprachige Pendant.

Die Verwendung der Mundart in Nachrichtenkommentaren ist ein häufig anzutreffendes linguistisches Phänomen. In der deutschen Sprache ist die sprachliche Vielfalt stark in der Gesellschaft verankert, so dass es beispielsweise eine eigene Wikipedia-Version in bayrischem Dialekt gibt. Angesichts der großen Anzahl deutschsprachiger Dialekte und der fehlenden Einheitlichkeit der Schreibweise stellt dies einen Sprachforscher vor ein nicht zu vernachlässigtes Problem. Denn mit der Verwendung dialektspezifischer Worte in der geänderten Schreibweise geht mundartabhängig auch eine angepasste Grammatik einher.

Darüber hinaus trifft man bei der Auswertung von benutzergeschriebenen Kommentaren auf zahlreiche *Out-of-Vocabulary*-Terme (Chu & Kurohashi, 2016, S. 644), die nicht in die beiden oben genannten Kategorien eingegliedert werden können. Ungeachtet dessen, ob diese Wörter aufgrund fehlerhafter Tastatureingaben, angesprochener Benutzernamen mit alphanumerischen Zeichenfolgen, Neologismen oder aus sonstigen Gründen verwendet werden, kann dies zu Problemen bei der natürlichen Sprachverarbeitung führen. Diese Wörter kommen meist extrem selten bzw. nur ein einziges Mal vor und entziehen sich somit einer automatisierten Bedeutungsergründung.

Allen soeben genannten Ursachen für eine geringe Datenqualität bei benutzerverfassten Texten wird in dieser Arbeit auf die gleiche Art und Weise begegnet: Vereinzelt von der Norm abweichende Textstellen werden toleriert, Textpassagen, die vollständig oder zu großen Teilen nicht der deutschen Sprache zuzuordnen sind, werden entfernt. Um nicht fälschlicherweise Komposita und Wörter in einem korrigierbaren orthographischen Zustand auszuschließen, wobei Letzteres auch nichtextreme Formen der Dialektschreibweise einschließt, wird dieser Filterprozess nach der Kompositatrennung aus Kapitel 7.1.2.2 und der Rechtschreibkorrektur aus Kapitel 7.1.3.3 durchgeführt. Es wird ein parametrisierbarer Schwellenwert festgelegt, um eine gewisse Toleranzgrenze für einzelne Vorkommnisse oben genannter Phänomene zuzulassen. Die Toleranzgrenze bekannter Wörter wird auf 50 % festgelegt. Angewendet wird dieser Filter satzweise. Dies bedeutet, dass Sätze, in denen weniger als die Hälfte der Wörter bekannt sind, aus dem Gesamtkorpus entfernt werden. Die Toleranzgrenze wird deswegen so hoch angesetzt, da nicht ausgeschlossen ist, dass aufgrund der sprachlichen Nähe der deutschen und englischen Sprache und der automatischen Rechtschreibkorrektur englische Wörter so korrigiert werden, dass quasi-deutsche Sätze entstehen. Um eine mangelnde Datenqualität durch fehlerhaft korrigierte Sätze und somit eine Sinnverschiebung zu vermeiden, werden Sätze, die unter das Filterkriterium fallen, aus der Gesamtheit entfernt.

### **7.1.1.3 Exklusion von Zahlen, E-Mail-Adressen und Links**

Vorkommnisse von Zahlen, E-Mail-Adressen und Links können als Merkmal fungieren. Während diesen Elementen im *Information-Retrieval* eine bestimmte Bedeutung zukommt (Manning et al., 2008), sind sie für die Emotionserkennung weniger relevant. Diese Textobjekte vergrößern das Vokabular und werden daher reduziert auf Substitutionsbegriffe. Unabhängig davon, ob es sich um Ordnungs-, Fließkomma- oder Ganzzahlen handelt, werden sie aus dem Korpus entfernt und durch NUMBER ersetzt. Emailadressen bzw. Internetlinks werden durch EMAIL\_ADDRESS bzw. HYPERLINK substituiert.

## **7.1.2 Datentrennung und -struktur**

### **7.1.2.1 Tokenisierung**

Tokenisierung bezeichnet einen Vorgang, bei dem man Wörter voneinander trennt, um diese nicht als langen, zusammenhängenden String, sondern in subsequenten Verarbeitungsschritten einzeln zu betrachten. Auf den Umstand, dass die Tokenisierung kein einfaches Unterfangen ist, weisen Manning et al. (2008) hin. Neben Leerzeichen gilt es unter anderem,

apostrophiierte Buchstaben, Abkürzungen, Satzzeichen, mathematische Operatoren, Zahlen, Telefonnummern, URLs sowie Binde- und Ergänzungsstriche korrekt zu separieren.

Tokenisierung ist ein Standardvorgang in der natürlichen Sprachverarbeitung, weswegen bereits zahlreiche Lösungen für diese Problemstellung existieren. Aus diesem Grund wurden initial zwei Lösungen für dieses Standardproblem überprüft. Zum einen wurden der PTBTokenizer (Manning, Grow, Grenager, Finkel & Bauer, o.J.) und zum anderen der TokenizerME, der auf der Arbeit von Reynar (1998) basiert, für die Verwendung getestet. Nach Angaben von Manning et al. (o.J.) handelt es sich dabei um einen für die englische Sprache angepassten Tokenisierer, der das Separierungsverhalten des Penn-Treebank-3-Datensatzes nachahmen soll. Diese Lösung basiert auf dem Modell eines endlichen Automaten. Der PTBTokenizer ist damit im Betrieb deutlich schneller als etwaige Splitter, basierend auf regulären Ausdrücken. Der TokenizerME hingegen basiert, wie der Name schon andeutet, auf einem Maximum-Entropie-Modell und ist eine Implementierung des Apache-OpenNLP-Tokenisierers. Dadurch lassen sich sprachspezifische Modelle bilden und somit kann auf die Feinheiten der jeweiligen Sprachfamilie eingegangen werden. Für die deutsche Sprache ist bereits ein trainiertes Modell vorhanden, das anhand des TIGER-Korpus optimiert wurde.

Sowohl die Softwarelösung PTBTokenizer als auch der TokenizerME mit englischem bzw. deutschem Modell sind für Nachrichtenkommentare in der vorliegenden Textgüte nicht geeignet. Einige Sprachbesonderheiten der deutschen Sprache wie Binde- und Ergänzungsstriche führen zu Schwierigkeiten bei den englischsprachigen Vertretern. Darüber hinaus sind Tokenizer, die auf Maximum-Entropie-Modellen basieren, um ein vielfaches langsamer. Eine Stichprobe mehrerer deutscher Buch- und Nachrichtentexte zeigte, dass alle Tokenisierungslösungen sehr gute Ergebnisse liefern. Wendet man nun die gleichen Tokenisierer auf Nachrichtenkommentare an, so zeigt sich, dass sie der schlechten Datenqualität sowie dem Netzjargon kaum gewachsen sind. Fehlende Leerzeichen zwischen den Sätzen, die Binnenmajuskelschreibweise, Paranthesekonstruktionen, Emoticons und mannigfaltige Interpunktionsdopplungen führen neben vielen weiteren Fehlerquellen zu unzureichenden Ergebnissen. Aus diesem Grund fallen die bereits existierenden Lösungen für den vorliegenden Datensatz weg, da die mangelnde Datenqualität besondere Maßnahmen erfordert.

Um diesen Datensatz möglichst korrekt zu tokenisieren, wurde ein eigener sequenzbasierter Tokenisierer erstellt. Dieser arbeitet in drei Schritten. Zuerst wird ein String an jeder möglichen Trennstelle separiert. Anschließend wird jeder separierte Abschnitt in eine der folgenden Kategorien eingeordnet:

Typ	Beispiele	Typ	Beispiele
-----	-----------	-----	-----------

<b>Alphanumerischer String</b>	3com, 1Live	Zahl	1, 23, 456
<b>Klammer</b>	(, [, ], )	Operator	&,  , +, *, /, -, =, %, #, \
<b>Doppelpunkt</b>	:	Paragraphzeichen	§
<b>Komma</b>	,	Interpunktion	;, !, ?
<b>Währung</b>	\$500, 400€	Einfaches Anführungszeichen	'
<b>Punkt</b>	.	Leerzeichen	
<b>Doppeltes Anführungszeichen</b>	„	Tabulator	\t
<b>Größerzeichen</b>	>	Unterstrich	_
<b>Bindestrich</b>	-	Wort	nlp, Psychologie
<b>Kleinerzeichen</b>	<	Unbekanntes Zeichen	и, л, я
<b>Einzelner Buchstabe</b>	a, b, c	Unbekannter String	日本語
<b>Zeilenumbruch</b>	\n, \r		

Tabelle 26: Typen der Zeichen und Zeichenfolgen für den Tokenizer

In einem zweiten Schritt werden die so klassifizierten Token teilweise zusammengefasst, wenn sie einer bestimmten Sequenz entsprachen. Als verkettbare Sequenz wurden folgende Kombinationen definiert:

Neues Label	Sequenz
<b>Leerzeichen</b>	Mehrere Leerzeichen
<b>Punktfolge</b>	Mehrere Punkte oder Punktfolgen Mehrere Punkte oder Punktfolgen, die durch Leerzeichen separiert sind
<b>Interpunktionsfolge</b>	Mehrere Interpunktionen Mehrere Interpunktionen, die durch Leerzeichen separiert sind

Tabelle 27: Verkettete Zeichensequenzen

Im letzten Schritt werden gültige Kombinationen der kategorisierten Token gebildet. Ausgehend von gesicherten Trennungsmerkmalen wie einem Leerzeichen, werden die so abgegrenzten Sequenzen jeweils für sich untersucht. Die Untersuchung startet mit der längstmöglichen Sequenz und verringert sich so lange, bis eine gültige Sequenz gefunden wurde oder die betrachtete Sequenz nur noch eine Länge von einem Token hat. Wurde der Anfang einer längeren Sequenz einer gültigen Tokenkonstellation aus der Liste zugeordnet, so werden die übrigen kategorisierten Token nach dem gleichen Schema bearbeitet.

Nachfolgend findet sich eine Liste valider Sequenzen, die sich für die Aufgabe der Tokenisierung von deutschen Nachrichtenkommentaren als am zielführendsten herausgestellt haben:

Pfeil links	Größerzeichen, Operator
<b>Negative Ganzzahl</b>	Bindestrich, Zahlen
<b>Negative Fließkommazahl (deutsche Schreibweise)</b>	Bindestrich, Zahlen, Komma, Zahlen
<b>Negative Fließkommazahl (amerikanische Schreibweise)</b>	Bindestrich, Zahlen, Punkt, Zahlen
<b>Ergänzungstich und Grundwort</b>	Bindestrich, Wort
<b>Pfeil rechts</b>	Kleinerzeichen, Operator
<b>Abkürzung oder römische Listung</b>	Einzelner Buchstabe, Punkt
<b>Abkürzung oder römische Listung</b>	Einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt
<b>Abkürzung oder römische Listung</b>	Einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt, einzelner Buchstabe

<b>Abkürzung oder römische Listung</b>	Einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt
<b>Abkürzung oder römische Listung</b>	Einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt
<b>Abkürzung oder römische Listung</b>	Einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt, einzelner Buchstabe, Punkt
<b>Buchstabe mit Wort (z. B. C-Dur, O-Ton)</b>	Einzelner Buchstabe, Bindestrich, Wort
<b>Apostrophierter Buchstabe am Anfang des Wortes</b>	Einzelner Buchstabe, Einfaches Anführungszeichen, Wort
<b>Uhrzeit oder Sportergebnis</b>	Zahlen, Doppelpunkt, Zahlen
<b>Fließkommazahl (amerikanische Schreibweise)</b>	Zahlen, Komma, Zahlen Zahlen, Komma, Zahlen, Komma, Zahlen, Komma, Zahlen, Punkt, Zahlen Zahlen, Komma, Zahlen, Komma, Zahlen, Punkt, Zahlen Zahlen, Komma, Zahlen, Punkt, Zahlen
<b>Ordnungszahl</b>	Zahlen, Punkt
<b>Fließkommazahl (amerikanische Schreibweise)</b>	Zahlen, Punkt, Zahlen
<b>Fließkommazahl mit Tausendertrennzeichen (deutsche Schreibweise)</b>	Zahlen, Punkt, Zahlen, Komma, Zahlen
<b>Datum</b>	Zahlen, Punkt, Zahlen, Punkt, Zahlen
<b>Fließkommazahl mit Tausendertrennzeichen (deutsche Schreibweise)</b>	Zahlen, Punkt, Zahlen, Punkt, Zahlen, Komma, Zahlen
<b>Ganzzahl mit Tausendertrennzeichen (amerikanische Schreibweise) oder IP-Adresse</b>	Zahlen, Punkt, Zahlen, Punkt, Zahlen, Punkt, Zahlen
<b>Fließkommazahl mit Tausendertrennzeichen (deutsche Schreibweise)</b>	Zahlen, Punkt, Zahlen, Punkt, Zahlen, Punkt, Zahlen, Komma, Zahlen
<b>Formel, Zahlenvergleich</b>	Zahlen, Operator, Zahlen
<b>Von-bis-Angaben</b>	Zahlen, Bindestrich, Zahlen
<b>Pfeil rechts</b>	Operator, Größerzeichen
<b>Mathematischer Vergleich</b>	Operator, Kleinerzeichen
<b>Apostrophierter Buchstabe am Ende des Wortes</b>	Einfaches Anführungszeichen, einzelner Buchstabe
<b>Grundwort und Ergänzungsstich</b>	Wort, Bindestrich
<b>Wort mit Buchstabe (z. B. Big-O)</b>	Wort, Bindestrich, einzelner Buchstabe
<b>Wortfolge mit Bindestrich (z. B. Vis-à-vis)</b>	Wort, Bindestrich, einzelner Buchstabe, Bindestrich, Wort
<b>Wortschreibung mit Bindestrich</b>	Wort, Bindestrich, Wort
<b>Wortschreibung mit zwei Bindestrichen</b>	Wort, Bindestrich, Wort, Bindestrich, Wort

*Tabelle 28: Gültige Token für die Tokenisierung*

### 7.1.2.2 Trennungen innerhalb eines Wortes

Neben der in der natürlichen Sprachverarbeitung üblichen Tokenisierung wird eine weitere Separierung der Worte vorgenommen. Dies ist einerseits der Datenqualität geschuldet, aufgrund der ausgelassenen Leerzeichen korrigiert werden müssen. Andererseits betrifft dies eine Eigenart der deutschen Sprache, bei der Wörter zu einem Kompositum zusammengeführt werden.

#### 7.1.2.2.1 Binnenmajuskel

Eine andere Form der Großschreibung innerhalb eines Wortes ist die Verwendung der Binnenmajuskelschreibweise. Bei dieser Form werden zwischen Worten keine Leerzeichen verwendet, sondern der Wortanfang des nachfolgenden Wortes durch die Verwendung eines Großbuchstaben abgegrenzt. Der Satz „Dieser Text ist ohne Leerzeichen geschrieben“ würde zu „DieserTextIstOhneLeerzeichenGeschrieben“. Besonders häufig wird dies bei Texteingaben mit Zeichenbeschränkung verwendet. Es kann sich dabei jedoch auch um ein Wort handeln, das tatsächlich in dieser Form geschrieben wird, sowie um einen Tippfehler, bei dem das Leerzeichen vergessen wurde.

In dieser Arbeit werden Wörter dieser Form getrennt. Wird in einem benutzergeschriebenen Text ein Wort mit Binnenmajuskelschreibweise gefunden, so werden daraus zwei oder mehr Token gebildet. Dies geschieht jedoch unter Berücksichtigung der Existenz der Subwörter in einer Wortliste. Letzteres soll verhindern, dass korrekt geschriebene Wörter wie iPhone, McDonald oder SpaceX fälschlicherweise getrennt werden. Fehlerhafte Großschreibungen, die durch die Verwendung von getrennten Wörtern mit Binnenmajuskel entstehen, werden durch die automatische Rechtschreibkorrektur berichtigt.

#### 7.1.2.2.2 Kompositazerlegung

Ein Kompositum ist eine Wortzusammensetzung, bei dem mehrere Worteinheiten zusammengefügt werden, um daraus ein neues Wort zu bilden. Bei der Zusammenstellung eines Kompositums sind mindestens zwei Terme beteiligt und dies ist über unterschiedliche Wortarten möglich. So gibt es in der deutschen Sprache Nomenkomposita wie „Computerlinguistik“ oder „Wissensmanagement“, Adjektivkomposita wie „schnellberechnend“ oder „neuwissenschaftlich“, Verbkomposita wie „zusammenkommen“ oder „kennenlernen“, Konfixkomposita wie „Psychologe“ oder weitere Komposita sonstiger Wortarten wie „nebenbei“ oder „seitwärts“ (Donalies, 2011b). Komposita existieren sowohl mit Bindestrich, beispielsweise „deutsch-französisch“, als auch ohne Bindestrich, wie die zuvor genannten Beispiele (Kunkel-Razum & Eisenberg, 2009). Eine Komposition ist nicht auf die deutsche Sprache beschränkt, jedoch kommt diese Art der Wortbildung besonders in germanischen Sprachen sehr häufig vor. Wie Gaeta & Schlücker (2012) zeigen, gehört Deutsch zu den Sprachen, in denen die Wortzusammensetzung am häufigsten praktiziert wird.

Wortzusammensetzungen sind computerlinguistisch schwierig zu greifen, sofern sie als singuläre Worteinheit betrachtet werden. Zum einen komprimieren sie multiple Teilaspekte, durch die Verkettung mehrere semantische Einheiten, auf einen einzigen Informationsträger. Dies ist umso gewichtiger, je komplexer bzw. länger Komposita werden. Zum anderen variiert

die Wortgewichtung der Teilelemente eines Kompositums. Heck (2007, S. 20) unterscheidet zwischen „Kopf-Modifikator-Komposita[, bei denen] das zweite Glied [...] durch das erste modifiziert“ wird, „[k]opulative Komposita[, bei denen] die Bedeutung des Ganzen [...] ein[en] Schnitt seiner Teile“ darstellt und „[s]ynthetische[n] Komposita[, bei denen] [d]as erste Glied [...] Argument des deverbale[n] zweiten Gliedes“ ist.

Ein weiterer praktischer Grund für die schwere Greifbarkeit in der natürlichen Sprachverarbeitung ist die Häufigkeit, mit der ein bestimmtes Kompositum auftaucht. Sind Terme weniger als fünfmal im gesamten Korpus vertreten, können diese beispielsweise für weiterführende Analysen, wie die in Kapitel 7.2.2.3 vorgeschlagenen, nicht verwendet werden. Ebenfalls ein Problem der Komposita stellt die automatische Rechtschreibkorrektur aus Kapitel 7.1.3.3 dar. Die orthographische Prüfung und Ausbesserung kann nämlich nur dann stattfinden, wenn ein Wort bekannt und in der Liste hinterlegt ist. Wie bereits im Vorfeld gezeigt, sind seltene und damit oft auch unbekannte Terme Komposita, bei denen die automatische Rechtschreibkorrektur fehlschlägt.

Mit *jWordSplitter* existiert eine Softwarelösung zur Trennung der Komposita. Die Java-Bibliothek basiert auf einer rekursiven Vorgehensweise mittels Wörterbüchern und Ausnahmeregelungen. Die Überprüfung mit dem Wörterbuch findet Buchstabe für Buchstabe statt und kann auf eine beliebige Termlänge angewendet werden (Naber, 2015). Im Testbetrieb erwies sich der *jWordSplitter* jedoch als langsam. Zerlegte Nomen, die nicht am Wortanfang standen, wurden in zerlegter Form kleingeschrieben. Darüber hinaus war die Java-Lösung einerseits zu rigoros im Zerlegungsverhalten und andererseits unzureichend, da das zugrunde liegende Lexikon unvollständig ist. Die letzten beiden Punkte könnten jedoch mit Ausnahmeregelungen und einer Anpassung des Wörterbuchs in den Griff bekommen werden. Da jedoch einige Verbesserungen eingebaut werden sollen, wurde sich hier gegen die Verwendung der existenten Softwarelösung und für die Entwicklung einer eigenen Applikation entschieden.

Die selbsterstellte Kompositazerlegung geschieht, ähnlich wie bereits die Lösung von Naber (2015), auf Grundlage eines Wörterbuchs. Darüber hinaus wird bei dieser Anwendung die Häufigkeit der jeweiligen Terme berücksichtigt, so dass bei multiplen Aufteilungsmöglichkeiten eines Kompositums dasjenige berücksichtigt wird, dessen Unterworte am zahlreichsten erscheinen. Die Grundlage dafür bildeten die häufigsten Wörter, welche im gesammelten Korpus vorkamen. Ein weiteres Feature des hier erstellten Splitters ist, dass er mehrere Modi zulässt. So kann beim Verhalten des Programms zwischen dem wahrscheinlichsten Trennverhalten mit den zugrunde liegenden Häufigkeiten und maximal möglicher Worttrennung gewählt

werden. Darüber hinaus werden wenige Trennungen durch das Erhöhen eines internen Gewichtungswerts belohnt. Analog dazu führen häufige Trennungen zur Verringerung jenes Werts.

Während die Kompositazerlegung im Wahrscheinlichkeitsmodus eingesetzt wurde, ist der zweite Modus speziell für die Auflösung der Ergänzungsstriche aus Kapitel 7.1.3.6 relevant. Beginnend von einem Ausgangspunkt, der entweder der Wortanfang oder der Folgestring eines innerhalb des Wortes erkannten Unterterms sein kann, betrachtet die Kompositazerlegung jeden Buchstaben einzeln. Ist die Buchstabenreihung ein Wort, das in der Liste hinterlegt ist, so wird ein möglicher Trennungspunkt hinzugefügt. Ist der Folgebuchstabe eines Wortes ein Fugenmorphem des Typs s-Fuge (vgl. Donalies, 2012), so werden mit dem übersprungenen s und dem regulären Folgestring zwei mögliche Worttrennungspunkte hinzugefügt. Des Weiteren verhält sich der Splitter so, dass ein Bindestrich immer zu einem inserierten Trennpunkt führt. Die Zerlegung wird so lange fortgeführt, bis alle Worttrennpunkte gefunden wurden. Ausgehend vom Wortanfang, bleibt jeder mögliche Trennungspfad innerhalb eines Wortes unberücksichtigt, sofern dieser nicht vollständig bis zum Wortende aufgelöst werden kann. Final wird, abhängig vom Modus, das maximale oder das wahrscheinlichkeitsgewichtete Trennverhalten zur Selektion der entsprechenden Subwortsequenz angewendet.

Anhand einer Auswahl an Komposita mit ungünstigen Silbentrennungen, die zu einer falschen semantischen Zerlegung führen können, wurde die Kompositazerlegung getestet. Das konservative Zerlegungsverhalten führte dazu, dass die folgenden Terme nicht zerlegt bzw. in dieser Form beibehalten wurden:

Terme	Terme	Terme	Terme
Abtreibung	Eileiter	Hostessen	Staubecken
Alpenostrand	Erblasser	Kaufladen	Talentförderung
Altersteilzeit	Erblasser	Kirschwein	Tangente
Analphabeten	Erbrecht	Musiknoten	Teenager
Arbeitsamt	Erdachse	Nachtruhe	Teilerfolge
Arbeitsamt	Erdrückend	Punktrichter	Urinsekten
Aussendung	Gastraum	Schweinigelei	Urininstinkt
Autorennen	Gauleiter	Siebente	Versendung
Barkasse	Gelächter	Spargelder	Wachstube
beinhalten	Gründung	Spielende	Wachstube
Dudelei	Gründung	Staatsexamen	Zuckerguss
Eidotter	Hausaufgabe	Staubecken	

*Tabelle 29: Nicht zerlegte Komposita*

Außerdem wurden die folgenden Terme mit mehrfacher Trennmöglichkeit richtig zerlegt:

Kompositum	Zerlegte Terme
Heimatschlager	Heimat Schlager
Müllerzeugung	Müll Erzeugung
Nachteilzug	Nacht Eilzug

Spieleröffnung	Spiel Eröffnung
Streikende	Streik Ende
Talentwässerung	Tal Entwässerung
Talgrund	Tal Grund
Textillustration	Text Illustration
Torflaute	Tor Flaute
Verandabrüstung	Veranda Brüstung
Wasserschieber	Wasser Schieber
Zwergelstern	Zwerg Elstern

*Tabelle 30: Korrekt zerlegte Komposita*

Folgende Resultate hingegen zerlegte die Applikation nicht korrekt:

Kompositum	Zerlegte Terme	Richtige Zerlegung
Panamazone	Pan Amazone	Panama Zone
Patentrichter	Paten Trichter	Patent Richter
Musikerleben	Musik erleben	Musiker Leben
Gelbrand	Gelb Rand	Gel Brand
Rinderdung	Rind Erdung	Rinder Dung

*Tabelle 31: Nicht korrekt zerlegte Komposita*

Eine Reihe weiterer komplexer Komposita zerlegte diese Anwendung jedoch ohne Schwierigkeiten, wie die nachfolgenden Beispiele zeigen:

Kompositum	Zerlegte Terme
Aktionärsrechterichtlinie	Aktionär rechte Richtlinie
Altersvorsorgewirksame	Altersvorsorge wirksame
ArbeitnehmerInnenschutzgesetz	Arbeitnehmerinnen Schutzgesetz
Arbeitsstättenrichtlinie	Arbeitsstätten Richtlinie
Aufstiegsfortbildungsförderungsgesetz	Aufstieg Fortbildung Förderung Gesetz
Auslandsunterhaltsgesetz	Ausland unterhalt Gesetz
Beleihungswertermittlungsverordnung	Beleihung Wertermittlung Verordnung
Berufsanerkenntnisrichtlinie	Beruf Anerkennung Richtlinie
Bundeseisenbahnverkehrsverwaltungsgesetz	Bunde Eisenbahnverkehr Verwaltung Gesetz
Hochgeschwindigkeitsaufnahmen	Hochgeschwindigkeit Aufnahmen
Hochzeitsbankett	Hochzeit Bankett
Luftfahrzeugkennzeichen	Luftfahrzeug Kennzeichen
nichtklassisch	nicht klassisch
Reaktionsdiffusionsgleichung	Reaktion Diffusion Gleichung
Rechtsschutzbedingungen	Rechtsschutz Bedingungen
Satzbuchstaben	Satz Buchstaben
Schlachtfeldarchäologie	Schlachtfeld Archäologie
Staatszugehörigkeitszeichen	Staat Zugehörigkeit Zeichen
Straßenheizung	Straßen Heizung
Vertragsrichtlinien	Vertrag Richtlinien

*Tabelle 32: Komposita mit richtiger Zerlegung*

### 7.1.2.3 Satztrennung

Die Satztrennung ist ein Vorgang, bei dem die syntaktische Struktur eines Satzes erhalten bleibt und jeweils am Satzende eine Abgrenzung vorgenommen wird. Die Auftrennung eines Dokuments in Sätze kann beispielsweise als Zwischenschritt genutzt werden, um kohärente Sinneinheiten wieder zusammenzuführen, beispielsweise beim *Topic-Tilling* (Riedl & Bie-mann, 2012).

In dieser Arbeit wird die Satztrennung aus dreierlei Gründen eingesetzt. Erstens wird sie benötigt, um inhaltlich geschlossene Einheiten abzugrenzen. Was, im Sinne der aufgestellten Hypothesen, eine feinere Betrachtung von Textpassagen ermöglicht, da die Wortebene um ein zusätzliches Kohärenzmerkmal ergänzt wird. Zweitens können dadurch einfache oder gedoppelte Satzzeichen wie ein Ausrufezeichen oder ein Fragezeichen als Merkmal in die Analyse einfließen. Satzzeichen dienen als Indikator für die Textsubjektivität bzw. -objektivität und haben einen verstärkenden Effekt (Bakliwal et al., 2012; Davidov et al., 2010; Prasad, 2010). Der dritte Grund für die Verwendung einer Satztrennung besteht darin, dass aufgrund der urheberrechtlichen Datenschutzbestimmungen nur Teile der Inhalte behalten werden dürfen. Letzteres schafft beim Webscraping die Obliegenheit, längere Texte zu fragmentieren, diese Teileinheiten nach Relevanz zu gewichten und nur dann zu speichern, sofern die rechtlich maximale speicherbare Länge in Abhängigkeit von der Kommentargesamtlänge nicht überschritten ist. Aus dieser juristischen Obliegenheit erwuchs auch der Umstand, dass die Trennung der Sätze ad hoc und noch vor der Speicherung ausgewählter Inhalte stattfinden muss. Da zu diesem relativ frühen Zeitpunkt mögliche Tücken der Tokenisierung angesichts der Datenqualität noch nicht bekannt waren, wurde zu einer Satztrennung mittels regulärer Ausdrücke (RegEx) gegriffen.

Die hier vorgeschlagene Lösung, basierend auf regulären Ausdrücken, ist an deutsche Sonderfälle und die bereits mehrfach erwähnte niedrige Datenqualität der Nachrichtenkommentare angepasst. Der hier entwickelte reguläre Ausdruck behandelt elf unterschiedliche Sonderfälle. Pro Fall wird ein String in maximal drei Teile aufgeteilt, die sich mindestens aus der Satzgrenze und zusätzlich aus dem rechts oder links davon befindlichen Teilstring zusammensetzen können.

Der erste Fall beinhaltet ein XML-Tagset, das ignoriert wird und sich somit als Ganzes links neben einen Satztrenner einreicht. Der Hintergrund hierfür ist, dass mögliche HTML-Hervorhebungen persistiert werden, sofern diese zu einem späteren Zeitpunkt ausgewertet werden sollten. Der reguläre Ausdruck für diese RegEx-Gruppierung (#1) ist:

#1 Links: (<[^>+?>.+?<\\/[>+?>)

Der zweite Fall umfasst linksseitig ein Satzende (#2), bestehend aus einem kleingeschriebenen Wort mit einer Länge von mindestens zwei Zeichen, einem Wort in Großbuchstaben mit mindestens drei Zeichen, einer Zahl mit Zeichen wie 3m, mindestens drei Zahlen, z. B. 2017, oder einem Leerzeichen. Als Satztrenner (#3) werden eine oder mehrere Punkte, gefolgt von einem oder mehreren Leer- bzw. Separierungszeichen akzeptiert, sofern rechtsseitig ein regulärer Satzanfang (#4) folgt, bestehend aus einem großgeschriebenen Wort. Der reguläre Ausdruck für dieses Dreierkonstrukt ist:

#2 Links: ([a-zäöüß]{2,}|[A-ZÄÖÜ]{3,}|\d[a-z]|\d{3,}|\s)

#3 Mitte: ([\.;:\?!\?;!;]+)[\s\t\n\r]+

#4 Rechts: ([A-ZÄÖÜ][a-zA-ZäöüÄÖÜß]+)

Beim dritten Fall wird ein klein- oder großgeschriebenes Wort (#5) mit mindestens vier Buchstaben an linker Stelle abgehandelt. Gefolgt ist das Wort von einer Interpunktion (#6) und einer vorausschauenden Prüfung, ob es sich um eine Datei- oder Domainendung handelt (ohne RegEx-Gruppierungsnummer). Am nachfolgenden Satzanfang zur rechten Seite der Satztrennung wird ein Wort mit mindestens drei Zeichen erwartet (#7). Die vier dafür benötigten regulären Ausdrücke sind:

#5 Links: ([a-zA-ZäöüÄÖÜß][a-zäöüß]{3,})

#6 Mitte: \s?([\.;:\?!\?;!;]+)

Einschub: (?!\.jpe?g|gif|html?|pdf|png|bmp|com|org|edu|net|tv|(?:(de)[\s])

#8 Rechts: \s?([a-zA-ZäöüÄÖÜß][a-zäöüß]{2,})

Der vierte Fall behandelt einen oder mehrere Punkte in Verbindung mit einem Leer- bzw. Separierungszeichen (#8) als Satzseparierung. Zusätzlich wird noch eine Liste (#9) an sehr häufigen, zwei bis drei Zeichen langen Satzanfängen abgeprüft. Diese fest verdrahtete Liste ist nicht besonders elegant und nur für deutschsprachige Texte geeignet, erfüllt aber aufgrund der empirisch ermittelten kurzen Satzanfangsworte ihren Zweck auch bei unsauberem Satzenden. Nachfolgend die regulären Ausdrücke hierfür:

#8 Mitte: \s?((?:[a-zA-ZäöüÄÖÜß][a-zäöüß]{2,})|

#9 Rechts: ((?:[aA]ls|[aA]m|[aA]n|[aA]u[fs]|[bB]ei|[bB]is|[dD]as?|

[dD]e[mnrs]|[dD]ie|[eE]in|[eE][rs]|[fF]ür|[gG]ut|[hH]at|

[iI]ch|[iI]h[mnr]|[iI][mn]|[iI]st|[jJ]a|[mM]al|[mM]an|

[mM]i[rt]|[nN]u[nr]|[oO]b|[oO]ft|[sS]ie|[sS]o|[uU]m|

```
[uU]n[ds] | [vV]o[mnr] | [wW]a[rs] | [wW]er | [wW]i[er] | [wW]o |
[zZ]u[mr]?)\s)
```

Der fünfte Sonderfall umfasst nur Satztrenner (#10), die aus einer Reihung von Punkten oder anderen Interpunktionszeichen besteht. Der reguläre Ausdruck dafür ist wie folgt:

```
#10 Mitte: \s?(\.+ \s?[:;:\?!\!¿;]+)\s?
```

Der sechste Fall trennt ein Satzende, das mit einem Doppelpunkt (#12) eingeläutet wird. Linksbündig wird ein Wort mit mindestens drei Zeichen erwartet (#11), wohingegen rechtsseitig sowohl eine alphabetische Folge beliebiger Länge stehen darf oder eine mindestens dreistellige Zahl (#13). Die drei beschreibenden regulären Ausdrücke dazu sind:

```
#11 Links: ([a-zA-ZäöüÄÖÜß]{3,})
```

```
#12 Mitte: \s?(\:)\s?
```

```
#13 Rechts: ([a-zA-ZäöüÄÖÜß]+\d{3,})
```

Der siebte Sonderfall umfasst eine beliebige Folge von Punkten (#14) sowie rechts des Trennzeichens eine sich öffnende Klammer (#15). Die beiden regulären Ausdrücke dazu sind:

```
#14 Mitte: (\.\+)\s?
```

```
#15 Rechts: (\()
```

Für den achten Fall wird eine sich schließende Klammer (#16) in Verbindung mit einer Punktfolge (#17) als Indikation genommen, wobei die Klammer das Ende des Satzes markiert und die Punktfolge die Satztrennung darstellt. Der reguläre Ausdruck dazu ist:

```
#16 Links: (\))\s?
```

```
#17 Mitte: (\.\+)
```

Der neunte Fall exkludiert Ordinalzahlen oder numerische Aufzählungen (#18). Dabei sind nur zweistellige Zahlen zugelassen, um keine Konflikte mit Jahreszahlen oder sonstigen Nummernfolgen wie IP-Adressen zu verursachen.

```
#18 Links: \s(\d{1,2}\.)
```

Der zehnte Fall stellt ein Auffangbecken für alle Interpunktionszeichen dar (#19), die noch nicht in die zuvor genannten Sonderfälle einzugliedern wurden. Da der reguläre Ausdruck linear abgearbeitet wird und bei der Ausführung dieser Anweisung schon alle Ausnahmen vorweggenommen wurden, kann eine einfache Trennung vorgenommen werden. Der reguläre Ausdruck dafür ist:

```
#19 Mitte: ([;\?!\!¿;…\n]+\.\.){3,})
```

Abschließend bildet der elfte Fall das Ende des Strings, wobei hier, sofern vorhanden, die abschließende Interpunktion (#20) aufgegriffen wird, um diese ggf. separiert zu behandeln. Der Ausdruck dafür ist:

```
#20 Mitte: ([\.,;\?!\;i...]+$)
```

Alle Sonderfälle werden per Oder-Zeichen gebündelt in einem großen Ausdruck abgearbeitet. In der sich vollziehenden Satztrennung werden alle Ergebnisse auf die entsprechende Seite geschrieben, wobei die linken und mittleren gefundenen Zeichenketten das Ende eines Satzes markieren und der rechte Teilstring den Anfang eines neuen Satzes anzeigt. Als Verbesserungsvorschlag sei an dieser Stelle angemerkt, dass die Satztrennung in Kombination mit der Tokenisierung deutlich zielführender wäre, ähnlich wie dies von Manning et al. (o.J.) mit der Aussage „*Sentence splitting is a deterministic consequence of tokenization*“ vorgeschlagen wird. Doch da dieser Trennungsschritt für eine frühe Filterfunktion während der Datenakquise benötigt wurde und dies zu einem Zeitpunkt geschah, an dem die kreative Wort- und Satzgrenzengestaltung der Nutzer noch nicht bekannt war, stellte dies einen gangbaren Kompromiss dar.

### **7.1.3 Datenbereinigung**

#### **7.1.3.1 Entfernen von Zeichendopplungen**

Die Verbalkommunikation hat der schriftlichen Kommunikation einiges voraus, können doch durch Intonation und Stimmlage, durch die Sprechgeschwindigkeit und die Lautstärke Informationen mitschwingen, die in geschriebener Weise kaum transportiert werden können. Um die schriftbasierte Kommunikation im Internet anzureichern, haben sich spezielle Schreibweisen herauskristallisiert, die den gehobenen Nachdruck einer Textmeldung hervorheben.

Eine häufig verwendete Form der internettypischen Hervorhebungsmarker ist die „Intensivierung [...] durch Iteration von Zeichen“ (Runkehl et al., 1998, S. 77). Dadurch wird mittels der Aneinanderreihung von Buchstaben ein lang und besonders nachdrücklich gesprochenes Wort in der Schriftsprache nachgeahmt. Üblicherweise werden Vokalbuchstaben dabei durch eine Dopplung oder Vervielfachung gedehnt, jedoch sind diese sprachlichen Anpassungen auch bei Konsonanten zu beobachten. Eine Wortverlängerung bietet einen deutlichen Hinweis auf eine subjektive und meinungsgeladene Sprache und kann beispielsweise bei Twitter im Schnitt bei jedem sechsten Tweet beobachtet werden (Brody, S. & Diakopoulos, 2011).

Die unterschiedlichen Schreibweisen werden in der Sprachverarbeitung als unterschiedliche Terme wahrgenommen. Die Schwierigkeit dabei ist, dass Wortverlängerungen an sich

nahezu nie einheitlich in ihrer Länge sind, sondern sich abhängig von der Vervielfachung der jeweiligen Buchstaben unterscheiden. Um diese zuletzt genannte Hürde zu nehmen, transformierten Agarwal, A. et al. (2011, S. 32) Wörter wie „coooooooooool“ zu „coool“. Durch die Eingrenzung der Buchstabenvervielfachung reduzierten sie die ungewollte Termvielfalt. Jedoch verzichteten sie auf die Abbildung der orthographisch korrekten Form, um das Nachdruckmerkmal nicht zu verlieren.

Umgesetzt wird diese Art der Korrektur in dieser Arbeit für Sequenzen der Länge von einem bis vier Buchstaben. Die Länge der Sequenz gibt an, wie viele Buchstaben als Einheit gesehen werden. So ist beispielsweise „hahahahaha“ eine mehrfache Wiederholung der aus zwei Buchstaben bestehenden Sequenz „ha“ und „lollollo“ eine Vervielfachung der Dreierbuchstabenfolge „lol“. Die Korrektur erfolgt nach folgendem Muster:

<b>Zeichenzahl</b>	<b>Maximal zulässige Wiederholungen</b>	<b>Korrekturbeispiel</b>
1	3	Cooooooooool → Coool
2	2	hahahahaha → haha
3	2	wtfwtfwtfwtf → wtfwtf
4	2	roflroflrofl → roflrofl

*Tabelle 33: Exemplarische Korrektur von Zeichendopplungen*

Dies bedeutet, dass einzelne Buchstaben maximal dreimal wiederholt werden dürfen, Zweier-, Dreier- und Viererzeichenfolgen hingegen nur zweimal. Es wird an dieser Stelle eingeräumt, dass diese Art der Korrektur nicht optimal ist, dennoch reduziert sie die Termvielfalt unterschiedlich langgezogener Zeichenketten durch die Limitierung der Wiederholungen. Dazu kommt, dass, bezogen auf die mehrfache Iteration von einzelnen oder gemeinsam zusammengehörenden Zeichen, die automatische Rechtschreibkorrektur greift und diese auf die richtige Schreibweise verkürzt werden können.

In der schriftlichen Kommunikation werden auch Ausrufezeichen oft verdoppelt oder vervielfacht, wenn der Autor einen besonderen Nachdruck auf die getroffene Aussage legen möchte. Aneinanderreihungen von Ausrufezeichen werden in einer Datenvorbereitungsphase korrigiert oder bei der Merkmalerkennung ignoriert, da in der Literatur davon ausgegangen wird, dass diese den Nachdruck einer Aussage nicht vergrößern (Dalal & Zaveri, 2014; Semantria, 2013). Hier werden Zeichendopplungen bei Interpunktationen analog zu dem oben genannten Schema harmonisiert und finden somit Einzug in die Analyse.

### 7.1.3.2 Großschreibung

Neben der Zeichendopplung ist die Verwendung einer vollständigen Großschreibung eine weitere Form der Emphase. Das Phänomen der Großschreibung eines ganzen Wortes oder

eines Satzteils wird in der schriftlichen Kommunikation im Internet zur Fokussierung genutzt, da sich diese Wörter von den umliegenden abgrenzen (Runkehl et al., 1998). Generell beeinflusst die Groß- und Kleinschreibung Analyseverfahren im Text-Mining, da gleiche Wörter bei unterschiedlicher Schreibweise als unterschiedliche Terme wahrgenommen werden. Um diese Hürde zu umgehen, werden in der Datenbereinigung alle Großbuchstaben durch Kleinbuchstaben ersetzt. Dadurch gehen potenziell Informationen verloren, jedoch wird durch die einheitliche Schreibweise die Termvielfalt deutlich reduziert.

### **7.1.3.3 Rechtschreibkorrektur**

### **7.1.3.4 Alte Rechtschreibung**

Durch die Rechtschreibreform 1996 gab es zahlreiche Eingriffe in die deutsche Schriftsprache. Personen, die sich immer noch der alten Rechtschreibung bedienen, sind inzwischen selten, jedoch findet man in Nachrichtenkommentaren noch vereinzelt die frühere Schreibweise. Auch bei älteren Büchern, die für diese Arbeit ebenfalls in einem bestimmten Teilaspekt als Trainingskorpus herangezogen werden (vgl. Kapitel 7.2), wurde die neue Rechtschreibung nicht immer nachgezogen.

Grammatikalische Aspekte bleiben in dieser Arbeit unberücksichtigt, Schreibweisen hingegen werden korrigiert. Letzteres betrifft im Speziellen die Schreibung von ss und ß. Realisiert wurde dies durch das Nachschlagen in einer Liste. Wird beispielsweise das Wort „muß“ in der Liste aller gültigen Worte nicht gefunden, so wird vor Durchführung der automatischen Rechtschreibkorrektur das Zeichen ß durch zwei ss ersetzt und erneut in der Liste nachgeschlagen. Ist das korrigierte Wort vorhanden, so wird dieses anstelle der originalen Schreibweise verwendet.

### **7.1.3.5 Rechtschreibfehler**

Orthografische Fehler können nie ausgeschlossen werden. Bei Texten wie Nachrichtenmeldungen herrscht aufgrund der Ausbildung der Autoren und eines professionellen Lektorats ein hoher Qualitätsstandard. Bei Nachrichtenkommentare stellt sich die Situation komplett anders dar und es gibt auch keine qualitative Kontrollinstanz. Viele Benutzer von Presseportalen eine hohe Freizügigkeit in der Interpretation der orthografischen Regelauslegung an den Tag. Die absente Konformität mit der deutschen Rechtschreibung reicht von dem Ignorieren der Großschreibung über fehlende oder falsche Zeichensetzung bis hin zu groben Rechtschreib- oder Grammatikfehlern. Erschwerend kommt die Verwendung von Zeichendrehern, Sonderzeichen,

Neologismen, linguistischer Kontamination, Netzjargon, Slang oder Mundart sowie fehlende Leerzeichen in den Kommentaren hinzu.

Für computerlinguistische Anwendungen stellen Rechtschreibfehler gleich eine mehrfache Herausforderung dar. Zum einen vergrößern sie das Vokabular und schaffen viele Terme mit gleicher Bedeutung, aber unterschiedlicher Schreibweise. Dieser Umstand würde sich jedoch nivellieren, wenn der Korpus groß genug wäre, da auch die Schreibweisen mit Rechtschreibfehlern mehrfach auftauchen würden und durch ihre schiere Anzahl zugeordnet werden könnten. Viel gravierender wiegt jedoch das Problem, dass viele der hier eingesetzten Datenbereinigungs- und -anreicherungswerkzeuge in die Irre geführt werden und fehlerhafte Ergebnisse produzieren. Da diese Fehlerquellen an frühen Stellen der sprachverarbeitenden Prozesskette auftauchen, sind ebenso nachfolgende Schritte davon betroffen, die auf die Korrektheit der vorangegangenen Resultate aufbauen. Es wird an dieser Stelle eingeräumt, dass eine Verbesserung nur zu einem gewissen Grad stattfinden kann und in manchen Fällen sogar maladaptive Korrekturen vornehmen wird.

Bei der Herangehensweise wird sich der Rechtschreibkorrektur von Norvig (2007) und einem selbsterstellten Wörterbuch bedient. Das automatische Korrekturwerkzeug selbst umfasst zwei Schritte, sofern ein Term unbekannt ist, also nicht in der Liste der korrekten Terme auftaucht. In erster Instanz werden alle möglichen Kandidaten mittels der Levenshteindistanz ermittelt (Manning et al., 2008). Unter den resultierenden Termen wird mittels Bayes'scher Statistik der korrigierte Term gewählt (Norvig, 2007).

Die Levenshtein-Distanz ist die Anzahl der Operationen, die notwendig sind, um einen Term in einen anderen zu transformieren. Die Bearbeitung des anzugleichenden Terms erfolgt auf Buchstabenebene. Als gleichwertige Operationen stehen das Löschen, das Hinzufügen oder das Ersetzen von Zeichen zur Verfügung, wenngleich auch eine Gewichtung der unterschiedlichen Schritte oder beispielsweise eine unterschiedliche Bewertung der ersetzten Buchstaben verwendet werden kann (Manning et al., 2008). Die Anwendung der Levenshtein-Distanz ist eine rechnerisch intensive Operation, da ein fehlerhafter Term gegen das ganze Wörterbuch geprüft werden muss. Auch wenn es eine Abbruchbedingung nach einer Distanz größer als 2 gibt, so ist dies nach wie vor eine zeitraubende Angelegenheit. Aus diesem Grund wurde die Rechtschreibprüfung hier an die deutschen Sprachbesonderheiten adaptiert und einige vorausgehende Prüfungsschritte wurden eingebaut, bevor die weiter unten beschriebene Auswahl des zutreffendsten Terms stattfand. Dies betrifft zum einen die Großschreibung, die im Deutschen sowohl bei Namen als auch bei Nomen gefordert ist und sich als häufige Fehlerquelle im Korpus herausstellt, zum anderen wird eine Ersetzung des kleinen  $\beta$  durch ein doppeltes ss geprüft,

was insbesondere bei Texten der alten Rechtschreibung zu frühen Abbrüchen der aufwendigen Überprüfung führt. Eine weitere Fehlerquelle wird einem fehlenden deutschen Tastaturlayout zugeschrieben. Personen, die nicht über die Tasten mit den deutschen Umlauten verfügen, behelfen sich in der Praxis durch die Verwendung der langen Schreibweise, in der ä zu ae, ö zu oe und ü zu ue wird. Findet sich ein solcher Term, bei dem eine Ersetzung der soeben genannten Umlaute in Groß- oder Kleinbuchstaben stattgefunden hat, in der Nachschlageliste, dann wird die Rechtschreibkorrektur ebenfalls frühzeitig erfolgreich abgebrochen. Sofern keine der frühen Abbruchbedingungen greift, werden alle möglichen Terme mit einer Levenshtein-Distanz, die kleiner oder gleich 2 ist, als mögliche Kandidaten dem nächsten Prozessschritt übergeben.

Um aus der Liste aller möglichen Terme den besten auszuwählen, wird das Theorem von Bayes angewendet. Ziel ist es, unter allen verfügbaren Kandidaten  $L$  die bedingte Wahrscheinlichkeit zu maximieren, mit der ein gegebenes Wort  $w$  dem Korrekturwort  $l$  entspricht, oder:

$$\operatorname{argmax}_{l \in L} P(l|w) = \operatorname{argmax}_{l \in L} \frac{P(l)P(w|l)}{P(w)}. \quad (4)$$

Die Ermittlung kann noch weiter vereinfacht werden, da  $P(w)$  für alle Terme mit entsprechend geringer Levenshtein-Distanz  $l$  gleich ist und somit aus der Gleichung genommen werden kann (ausführlich dazu Norvig, 2007).

Neben den vorgeschalteten Prüfschritten, die Sonderfälle der deutschen Sprache und des deutschen Tastaturlayouts abfangen, wurde auf eine fertige Java-Implementierung der automatischen Rechtschreibkorrektur von Norvig (2007) durch Cunha (2007) gesetzt. Als Wörterbuch wurde eine Liste deutscher Wiktionary-Terme verwendet, die mit Hilfe der Indexierung des Buchkorpus hinsichtlich der Häufigkeiten angereichert wurden. Orts-, Personen- und Firmennamen wurden aus diesem Wörterbuch entfernt und als Ausnahmeliste bei der Rechtschreibprüfung hinzugefügt, so dass diese übersprungen werden, aber nicht als Grundstock für mögliche Rechtschreibanpassungen zur Verfügung stehen.

Abschließend kann gesagt werden, dass dieser außerordentlich wichtige Schritt durch einen großen Rechenaufwand in der Datenaufbereitung erkauft wird. Sind mehr als zwei Fehler in einem Wort vorhanden oder ist das Lexikon nicht vollständig, kann dies in Einzelfällen zu unerwünschten Ergebnissen führen. Nichtsdestotrotz werden dadurch viele geringfügige Rechtschreibverstöße, besonders bezüglich der Groß- und Kleinschreibung, korrigiert und es kommt somit zu einer deutlich besseren Grundlage für die weiterführenden Schritte der Datenaufbereitung. Der gesammelte Korpus gewinnt durch diesen Schritt an Datenqualität.

### 7.1.3.6 Ergänzungsstriche

Im Vergleich zu anderen Sprachen können im deutschen Sprachraum Bindestriche als Ergänzungsstriche verwendet werden. Aufzählungen verkürzen die geschriebene Menge und erhöhen so die Lesbarkeit von Texten. Der Duden gibt dazu drei gültige Anwendungsfälle an (Dudenredaktion, o. J. c.). Die einfachste Anwendung ist die Ersetzung eines gleichen Grundworts beispielsweise bei der Auflistung einer oder mehrerer Wörter durch einen Ergänzungsstrich. Der Ergänzungsstrich kann sowohl beim ersten Wortfragment stehen, wie bei „Sprach- und Geisteswissenschaft“, als auch beim zweiten Wortteil, z. B. bei „Berechnungskomplexität und -geschwindigkeit“. Darüber hinaus lässt der Duden als zweiten Anwendungsfall auch Adjektivkonstruktionen wie beispielsweise „Daten- und sonstige Verarbeitung“ zu. Drittens ist auch die dreigliedrige Verwendung der Wortzusammensetzung mit Hilfe der Bindestriche als Ergänzungsstriche legitim, wie das Beispiel „Datenein- und -ausgabe“ verdeutlichen soll. Unabhängig davon, welcher Anwendungsfall vorliegt, kann dies für die natürliche Sprachverarbeitung ein Hindernis darstellen, sofern die Ergänzungsstriche nicht aufgelöst werden. Der einfache Satz „Das hat sowohl Vor- als auch Nachteile“ kann eine einfache Polaritätserkennung irreführen, da der Term „Vorteil“ nicht explizit ausgeschrieben ist und nur der negativ konnotierte „Nachteil“ gefunden wird.

Um diesem Hindernis vorzubeugen, werden der erste und dritte vom Duden vorgestellte Anwendungsfall der Ergänzungsstriche aufgelöst. Bei der Tokenisierung, die in Kapitel 7.1.2 näher erläutert wird, werden Ergänzungsstriche persistiert, d. h. diese werden nicht von den zugehörigen Wörtern getrennt. Dieser Datenbereinigungsschritt findet folglich nach der Trennung der Token statt. Wird an erster oder letzter Stelle eines Tokens ein Bindestrich festgestellt, dann werden die folgenden Token an dessen Wortseite überprüft. Sofern es sich um eine Konjunktion oder ein Komma, gefolgt von einem mehrgliedrigen Grundwort handelt, wird das unvollständige Wort so lange mit Wortfragmenten des mehrgliedrigen Grundworts ergänzt, bis sich das unvollständige Wort zusammen mit den angefügten Grundworten in einem Wörterbuch finden lässt. Zur Auftrennung des mehrgliedrigen Grundworts wird die Einstellung des maximalen Trennverhaltens bei der Kompositazerlegung aus Kapitel 7.1.2.2.2 verwendet. Pro Satz wird die Auflösung der Ergänzungsstriche zweimal angewendet, um beide Einsparungsrichtungen abzudecken. Durch diese Vorgehensweise lassen sich die oben genannten dreigliedrigen Verwendungen der Wortzusammensetzung problemlos auflösen.

## 7.1.4 Datenharmonisierung

### 7.1.4.1 Abkürzungen

Eine Form der Datenaufbereitung ist das Austauschen der Abkürzungen mit ihren Langformen. Einerseits wird dadurch die Tokenisierung erleichtert, andererseits wird unterschiedlichen Schreibweisen bei gleicher Bedeutung Rechnung getragen. Die nachfolgende Liste gängiger Abkürzungen wird in der Vorverarbeitung durch folgende Langformen ersetzt:

Abkürzung	Ersetzung	Abkürzung	Ersetzung	Abkürzung	Ersetzung
Abb.	Abbildung	mio.	Millionen	v.	von
allg.	allgemein	mil.	Milliarden	vllt.	vielleicht
bspw.	beispielsweise	m.E.n.	meines Erachtens nach	z. B.	zum Beispiel
b.z.w.	beziehungsweise	m.E.	meines Erachtens	z.T.	zum Teil
b.w.	bitte wenden	m.W.	meines Wissens	z.Zt.	zur Zeit
ca.	circa	n. Chr.	nach Christus	z.G.	zu Gunsten
cu	man sieht sich	o.ä.	oder ähnlich	i.d.R.	in der Regel
d.h.	das heißt	o.a.	oben angegeben	i.H.v.	in Höhe von
d.i.	das ist	od.	oder	u.a.	unter anderem
etc.	etcetera	o.	oder	u.ä.	und Ähnliche
E.U.	Europäischen Union	p.a.	per annum	u.s.w.	und so weiter
evtl.	eventuell	s.	siehe	u.s.f.	und so fort
GLG	ganz liebe Grüße	s.a.	siehe auch	u.z.	und zwar
geb.	geboren	s.o.	siehe oben	u.v.a.	und viele andere
ggf.	gegebenenfalls	s.u.	siehe unten	u.u.	unter Umständen
LG	liebe Grüße	r.k.	römisch katholisch	u.	und
mfg	mit freundlichen Grüßen	Tel.	Telefon	U.S.	United States
i.e.	zum Beispiel	btw	übrigens	WE	Wochenende
i.d.R.	in der Regel	Vgl.	vergleiche	Zit.	Zitat
i.d.	in die	v.a.	vor allem		
Jhdt.	Jahrhundert	v. Chr.	vor Christus		

Tabelle 34: Ersetzungstabelle der Abkürzungen

Agarwal, A. et al. (2011) empfehlen diese Vorgehensweise zusätzlich bei sinntragenden und meinungsgebenden Akronymen, beispielsweise eine Ersetzung von „lol“ durch „*laughing out loud*“. In dieser Arbeit werden für die Verarbeitung Abkürzungen aus Gründen der Harmonisierung ebenfalls ausgeschrieben.

## 7.1.4.2 Netzjargon und internetspezifische Sprachmerkmale

### 7.1.4.2.1 Parenthesenkonstruktionen und Auszeichnungssprache

In der geschriebenen Sprache des Internets gibt es eine spezielle Ausdrucksweise, um Emotionen, Gefühlszustände oder den Kontext direkt zu kennzeichnen. Hierzu werden Inflektivkonstruktionen verwendet, die meist zwischen Sternsymbolen oder Auszeichnungsmarkierungen geschrieben werden (Schlobinski, 2001). Da dabei Gefühle und Emotionen explizit versprachlicht werden, sind diese rhetorischen Figuren der Parenthese in dieser Arbeit von essentieller Wichtigkeit. Aus diesem Grund soll eine Datenaufbereitung in Form einer Harmonisierung stattfinden, um semantisch ähnliche Inhalte noch stärker zu vereinheitlichen und um deren zahlreichen Schreibformen entgegenzuwirken.

Die Gefühlsqualität oder auch der Kontext einer Aussage werden dabei als Phrase oder als einzelnes Verb in der Inflektivform, also als infinites und unflektiertes Verb, geschrieben (Teuber, 1998), beispielsweise \*freu\* oder \*seufz\*. Mitunter werden auch Abkürzungen der verwendeten Verben benutzt, so dass \*g\* und \*grins\* in den meisten Fällen bedeutungsäquivalent sind. Das zuletzt genannte Beispiel taucht mit \*ggg\* auch oft in Verbindung mit einer Zeichen-dopplung auf, die in Kapitel 7.1.3.1 bereits beschrieben wurde. Bei Textphrasen, die von Sternsymbolen umrahmt werden, wird sich oft einer metaphorischen Sprache bedient, wie \*Mundwinkel verzieh\* oder \*Kopf schüttel\*, so dass vor einer Sentimentanalyse die zugrunde liegende Mimik oder Gestik bewertet werden muss.

Die zweite Form der Kontextsetzung oder der Art und Weise, wie das Gesagte zu verstehen ist, ist die Verwendung von Auszeichnungsmarkierungen (Schlobinski, 2001). Hier bedienen sich einige Verfasser von Nachrichtenkommentaren der Tag-Symbole aus Markup-Programmiersprachen, um zu signalisieren, wie die eingerahmte Textpassage zu verstehen ist. Eine ironische Bemerkung kann z. B. durch die programmiersprachenentlehnten Elemente <ironie>das ist unheimlich toll</ironie> betont werden. Es finden sich ebenfalls abweichende Schreibformen wie <Sarkasmus an>habe ich doch gleich gesagt<Sarkasmus aus>.

Eine Stichprobe des Korpus durch Indexierung ergab, dass die erstgenannte Parenthesenschreibweise mit Sternen sehr viel häufiger vorkommt als die Kontextsetzung mittels Markup-Symbolen. Darüber hinaus transportierte die Schreibweise mit Tag-Elementen überwiegend die Information der Ironie oder des Sarkasmus. Aus diesem Grund und der vernachlässigbaren Anzahl der Vorkommnisse wird die Auszeichnungsmarkierung mittels Größer- und Kleinerzeichen für diese Analyse nicht berücksichtigt und in dem Schritt der Formatierungsreinigung

aus Kapitel 7.1.1.1 entfernt. Stattdessen wird sich auf die Stern-Schreibweise fokussiert und diese durch eine Harmonisierung zusätzlich aufbereitet.

Realisiert wird die sprachliche Harmonisierung durch eine selbsterstellte Liste, in der im Zuge der Datenaufbereitung bestimmte Schlüsselwörter der Parenthesenkonstruktionen nachgeschlagen werden. Um die Liste anzulegen, wurden bei der Erstellung des Korpus alle Textkonstruktionen gesondert notiert, die zwischen zwei Sternen standen und einen Abstand von 30 Zeichen nicht überschritten. Aus der so resultierenden Ansammlung an Texten wurden jeweils Token gebildet und diese indexiert (vgl. Manning et al., 2008). Die häufigsten Terme wurden überprüft und manuell einem Substitutionsbegriff zugeordnet. Taucht einer der genannten Terme innerhalb einer Parenthesenkonstruktion von zwei Sternsymbolen oder Tag-Elementen auf, so wird dieser in den entsprechenden Begriff übersetzt. Die Reihenfolge der abgearbeiteten Begriffe ist dabei entscheidend, so dass der von oben anfangend zuerst erkannte Begriff das übersetzte Schlüsselwort definiert. Dies bedeutet, dass keine Doppelkonstruktionen zweier Gefühlsqualitäten innerhalb einer Parenthese vorkommen können.

Nachfolgend findet sich die Liste der gesammelten und zugeordneten Wortvorkommnisse und der in der Datenreinigung vorgenommenen Ersetzungen:

<b>Schlüsselwort</b>	<b>Ersetzung</b>
lach, looo, lool, lööl, löl, lol, rofl, roofl, roof, roffl, prust, pruuust, pruuus, wegschmei, muuh, muuu, muua, muha, muah, muaa, mmmu	INTERNET_SLANG_LOL
ironi, scherz, nichtganzernstgemeint, nichternstgemeint, nicht ernst gemeint, spass, spaß, joke, kidding	INTERNET_SLANG_IRONIE
sarkas, sarcas	INTERNET_SLANG_SARKASMUS
satir	INTERNET_SLANG_SATIRE
zyn	INTERNET_SLANG_ZYNISMUS
verschwö	INTERNET_SLANG_VERSCHWOERUNG
übertreib, überzogen, überspitz	INTERNET_SLANG_UEBERTREIBUNG
schadenfreu, schadenfroh, fail	INTERNET_SLANG_SCHADENFREUDE
zwink	INTERNET_SLANG_ZWINKER
zustimm, zugeb, zugegeb, zu stimm, richtig	INTERNET_SLANG_ZUSTIMM
würg, kotz, wüü, wuu, würr, wuerg, wüa, wuah, widerw, vomit, übel, rümpf, ruempf, fingerimhals, fingerinhals	INTERNET_SLANG_KOTZ
tztz, tzz	INTERNET_SLANG_TZTZ
traeum, träum, wünsch, wunsch, willauch, habenwill, haben will	INTERNET_SLANG_TRAEUM
thumbsdown, thumbs down, daumenrunter, daumen runter	INTERNET_SLANG_DAUMEN_RUNTER
thumbs, daumenhoch	INTERNET_SLANG_DAUMEN_HOCH
daumendrück, daumen drück	INTERNET_SLANG_DAUMEN_DRUECK
angst, panik, panic, fürcht, furcht, hysterisch, feear, feear	INTERNET_SLANG_ANGST
sing, gröhl, grööh, gröööh, zirp, zisch, stöhn, ugh, uiui, ufftata, tüüüt, tuuut, pfeif, tüdel, tröööt, trööt, träller, röchel, reusp,	INTERNET_SLANG_LAUT_GEBEN

raschel, rassel, rabää, rabbä, rabbbä, kreisch, kreiii, krächz, jaul, jauul, jauuul, gagger, furz, fuurz, fuuurz, flöt, flööt, flöööt	INTERNET_SLANG_SEUFZ
seufz	INTERNET_SLANG_SEUFZ
scnr	INTERNET_SLANG_SCNR
schulterzuck	INTERNET_SLANG_SCHULTER_ZUCK
schnief	INTERNET_SLANG_SCHNIEF
schnarch	INTERNET_SLANG_SCHNARCH
schmunzel	INTERNET_SLANG_SCHMUNZEL
schauder, brr, zitter, bibber, grussel, gruus, gruuus, grusl, grusäl, gänsehaut	INTERNET_SLANG_SCHAUDER
schäm, shame, schande, peinlich, erröt	INTERNET_SLANG_SCHAEM
sabber, lechz, hechel	INTERNET_SLANG_SABBER
räuser, hust, hüstel, hüstl, hmpf	INTERNET_SLANG_HUST
piep, beep, beep, beeb	INTERNET_SLANG_PIEP
lacht, lache, laaac, lächl, lächel, smile, hehe, haha, hihi, kicher, kicha, witz, lustig, lustich, lustisch	INTERNET_SLANG_HAHA
kratz	INTERNET_SLANG_KOPFKRATZ
schuett, schütt	INTERNET_SLANG_KOPFSCHUETTEL
klatsch	INTERNET_SLANG_KOPFKLATSCH
kopf, facepalm, face palm	INTERNET_SLANG_KOPFFASS
hrhr	INTERNET_SLANG_HRHR
heul, heuul, heuuul, heeu, heeeu, traurig, wein, träne, traene, schnief, snief, sniiief, seuft, schluch, jammer	INTERNET_SLANG_TRAURIG
grusel	INTERNET_SLANG_GRUSEL
grummel, grml	INTERNET_SLANG_GRUMMEL
grübel	INTERNET_SLANG_GRUEBEL
grrr	INTERNET_SLANG_GRR
grins, griins, griiins, grinz, griinz, griiinz, grinn, griens, grintz, freu, jipp, glücklich	INTERNET_SLANG_FREUDE
gäh, gää, gaehn, gaehhn, gaehhhn	INTERNET_SLANG_GÄHN
flip	INTERNET_SLANG_FLIP
duck, renn, lauf, flitz, weg hier, schnell weg, verdrück, un wech, und wech, und weg, todstell	INTERNET_SLANG_ABTAUCHEN
blub	INTERNET_SLANG_BLUB
klugsch, klugshic, klügerscheiss, klugmode	INTERNET_SLANG_KLUGSCHEISS
pfui	INTERNET_SLANG_PFUI
argh	INTERNET_SLANG_ARGH
ärger, zorn, wut, wüt, schnaub, schimpf, streit, sauer, stink, stampf, luft geh, luftgeh, dicken hals, damn	INTERNET_SLANG_AERGER
schwachsinn, troll, noob, boon, blödsinn, sinnlos, idiot, vogel, stupid, provo, lächerlich	INTERNET_SLANG_SCHWACHSINN
roll, augenverdreh, augenverzieh, augenimkoppverdreh, augendreh	INTERNET_SLANG_AUGENROLL
zunge	INTERNET_SLANG_FRECH
trotzig, trotz , zick	INTERNET_SLANG_TROTZ
wunder, verwirr, verständnis	INTERNET_SLANG_WUNDER_POS
erstaun, überrasch, surpri	INTERNET_SLANG_WUNDER_NEG
hübsch, niederkniet, wow, woow, woow, woah, wooah, geil, uii, uih, spitze	INTERNET_SLANG_ERSTAUNT
runzel, ratlos, krank, irre	INTERNET_SLANG_BEWUNDERUNG

wortlos, ohne wort, keine wort, worte fehl, wort fehl, sprachlos, ohneworte, ohneweitereworte, ohneweitere worte, ohne weitere worte, irriti	INTERNET_SLANG_WORTLOS
besorgt, worry, worried	INTERNET_SLANG_BESORGT
zaun	INTERNET_SLANG_ZAUNPFAHL
warn, vorsicht, achtung, tadel	INTERNET_SLANG_WARNUNG
neid	INTERNET_SLANG_NEID
verzweif	INTERNET_SLANG_VERZWEIFLUNG
verzeih, sorry, tschuldig, mir leid, leidtu, leid tu, tschulig, pardon, ooops	INTERNET_SLANG_SRY
unglaub, ungläub, wahnsinn, irrsinnig, unfass, staun, glaubsnicht, glaubesnicht, glaubnicht, glaub es nicht, fassesnicht, fass es nicht	INTERNET_SLANG_UNGLAUBLICH
tröst, trööst, tröööst, mitleid, mitfühl	INTERNET_SLANG_MITFUEHL
stolz, selbstlob, harr	INTERNET_SLANG_STOLZ
spott	INTERNET_SLANG_SPOTT
skepti	INTERNET_SLANG_SKEPTISCH
shock, schockier, autsch, au weia	INTERNET_SLANG_SCHOCK
neugier, sehenwill, sehen will, sehen-will, will sehen, willsehen, auchsehen, auchwill, auch-will, auchhabenwill, auch-haben-will, schnüffel, popcorn, gespannt, augenbrauen	INTERNET_SLANG_NEUGIER
gott, my god, oh herr, oh man	INTERNET_SLANG_OMG
mecker, nörgel, nerv, nerf, motz, langweil, laaangw, laangw, korientenkack	INTERNET_SLANG_MECKER
kuschel, knuddel, knuddl, knuff, knutsch, knuutsch, knuuutsch, bussi, gernhab, liebhab, love, liebe, herzchen	INTERNET_SLANG_ZUNEIGUNG
igitt, iiigi, iigi, iiigg, iiiee, iiihh, eckel, dislike, horror, hasse, greuel, greul, grausel, grauss, grauslig	INTERNET_SLANG_ABNEIGUNG
gratz, gratu, glückwunsch	INTERNET_SLANG_MITFREUDE

*Tabelle 35: Liste der Harmonisierungen für Parenthesenkonstruktionen*

Anhand der Liste ist ersichtlich, dass manche Schlüsselbegriffe nicht vollständig ausgeschrieben wurden. Das Motiv dahinter ist, dass so verschiedene Wortendungen und Verbformen abgedeckt werden können. Oft gibt es dabei mehrere Varianten, da die Zeichendopplung bei diesem sprachlichen Phänomen des Netzjargons besonders häufig eingesetzt wird. Dieser Schritt wird nach der Entfernung der Dopplungen durchgeführt, so dass maximal drei aufeinanderfolgende Zeichen gleich sein können.

#### 7.1.4.2.2 Fluch- und Schimpfwörter

Fluch- und Schimpfwörtern kommt in dieser Analyse eine besondere Bedeutung zu, denn sie sind meist ein Ausdruck einer spontanen und starken emotionalen Regung (Anderson & Phelps, 2002). Eine vulgäre oder fäkale Sprache wird jedoch nicht von jedem Nachrichtenportal geduldet. Es kann vorkommen, dass die Redaktion Kommentare, die sich einer besonders unflätigen Sprache bedienen oder anstößig sind, entfernt oder mit dem Hinweis auf den unangemessenen Inhalt und die gewünschten Verhaltensregeln ersetzt. Um dieser Zensur zu entgehen und womöglich auch als Zeichen des Anstands, wird oft eine schriftliche Verschleierung

der Kraftausdrücke vorgenommen. Dabei werden Wörter durch das Ersetzen des Mittelteils oder des Wortendes angedeutet. Als Ersetzungszeichen dienen meist Sternchen, so dass z. B. aus dem fäkalen Ausdruck „Scheiße“ das Wort „Sch\*\*\*e“ wird. In einer Stichprobe des vorliegenden Korpus wurden auch Rauten- und Punktfolgen gefunden. Weiterhin wurde bei einer Überprüfung der Kommentare erkannt, dass die Anzahl der ausgelassenen Zeichen und die Ersetzungszeichen nicht zwangsläufig übereinstimmen müssen. Bei der Verschleierung dieser Wörter wird eine große Kreativität an den Tag gelegt, weswegen es sehr viele Schreibweisen der jeweiligen Fluch- und Schimpfwörter gibt. Für eine Analyse ist dies jedoch problematisch, da sich diese meinungsgeladenen Wörter einer algorithmischen Determinierung partiell entziehen, sofern die semantische Ähnlichkeit zwischen den seltenen Vertretern einer Schreibweise nicht mit den gängigen Formulierungen dieser Wörter übereinstimmt. Dies tritt umso deutlicher zu Tage, je mehr Schreibweisen es für einen Term gibt und je weniger Vertreter einer Verschleierung im Korpus für die jeweilige Form vorhanden sind.

Um der Verschleierungstaktik und der damit einhergehenden Termvielfalt zu begegnen, wurde im Korpus eine Ersetzung vorgenommen. Diese zeichenbasierte Ersetzung wurde analog zur Vorgehensweise bei der Auszeichnungssprache ermittelt und mit regulären Ausdrücken (RegEx) realisiert. Auch wenn dies in der nachfolgenden Liste nicht explizit angeführt ist, so schließt die Schreibweise eine beliebige Anzahl und Art an Ersetzungszeichen ein.

Schreibweise	Ersetzung	Schreibweise	Ersetzung	Schreibweise	Ersetzung
a*	Arsch	fr*	Fresse	sche*ß	Scheiß
a*ch	arsch	fre*e	Fresse	schei*	Scheiß
a*g	Arschg	fu*	fuck	schei*e	Scheiße
a*h	arsch	h*e	hure	schei*en	scheissen
A*hole	Asshole	hu*	hure	shi*	schissen
a*l	Arschl	id*	idiot	shi*en	schissen
a*o	Arschlo	k*	kotz	shi*enen	schissen
a*ö	Arschlö	k*ck	kack	schl*	schlampe
a*sch	arsch	k*e	kotze	schl*e	schlampe
a*t	arscht	k*k	kack	schl*n	schlampen
a*ung	arschung	k*n	kotzen	schl*pe	schlampe
ar*	arsch	k*t	kotzt	schn*ze	Schnauze
ar*ch	arsch	k*z	kotz	schw*	Schwanz
ar*h	arsch	ka*	kack	schw*el	Schwuchtel
ars*	arsch	ka*n	kacken	schw*n	Schwein
ars*ch	arsch	ka*r	kacker	schw*t	Schwucht
ars*cher	arschlöcher	ko*	kotz	schw*tel	Schwuchtel
ars*er	arschlöcher	ko*t	kotzt	schw*z	Schwanz

ars*h	arsch	ko*z	kotz	schwa*	schwanz
ars*l	arschlo	nu*	nutt	t*n	titten
ars*o	arschlo	pi*	piss	t*te	titte
ars*ö	arschlö	pi*el	pimmel	ti*	titten
b*d-	Bild-	pi*l	pimmel	ti*en	titten
b*d	Bild	s*ei	schei	ti*n	titten
f*	fuck	sch*	Scheiß	verf*	verflucht
f*ck	fuck	sch*e	Scheiße	w*	wichser
f*cken	ficken	sch*egal	scheißegal	w*er	wichser
f*cker	ficker	sch*en	scheißen	w*r	wichser
f*ckt	fickt	sch*pe	schlampe	w*s	wichs
f*en	ficken	sch*ß	Scheiß	w*ser	wichser
f*er	Ficker	sch*ße	Scheiße	wi*	wichser
f*k	fuck	sch*tel	Schwuch- tel	wi*er	wichser
f*t	fickt	sch*z	Schwanz	wi*r	wichser
fi*	ficken	sch*ze	Schwänze	wi*s	wichs
fi*en	ficken	sch*zes	Schwanzes	wi*ser	wichser
fi*t	fickt	sche*	Scheiß		

*Tabelle 36: Ersetzungen der Schimpfwortschreibweisen*

Manche der hier gelisteten Wörter brechen in der Wortmitte ab. Dies liegt daran, dass verschiedene ausgeschriebenen Wortendungen folgen können oder Wörter an den Casus und Numerus angepasst wurden und nicht jeder Einzelfall berücksichtigt wird.

#### 7.1.4.2.3 Emoticons

Emoticons sind sprachliche Kurzformen, bei denen mit Sonderzeichen, Punkten und Klammern versucht wird, das menschliche Gemüt und die damit verbundenen Gesichtsausdrücke einzufangen und in wenige Zeichen darzustellen. Emoticons werden hauptsächlich aus vier Gründen verwendet. Erstens, um mehrdeutige Meinungspassagen in Texten in ihrer Orientierung zu kennzeichnen. Zweitens können Emoticons die Aussage eines Meinungssatzes nochmals in dessen Intensität verstärken. Drittens können sie die ausgedrückte Meinung in einem Satz umkehren (Hogenboom et al., 2013). Letzteres trifft beispielsweise bei Ironie oder Sarkasmus zu, die durch Emoticons angezeigt werden (Rojas et al., 2012). Dabei birgt nicht nur eine dedizierte Betrachtung der unterschiedlichen Formen von Emoticons eine gewisse sprachliche Unschärfe, sondern auch eine Verallgemeinerung der Emoticons als Indikator für eine Polarisierung. Eine Kurzform der Meinungsanzeige kann nicht losgelöst betrachtet werden, da beispielsweise ein lachendes Emoticon abhängig vom Zusammenhang freudig oder abschwächend interpretiert werden kann (Balnat, 2011). Das vierte Argument für die Integration von Emoticons, also Zeichenfolgen, die der Mimik des menschlichen Gesichts nachempfunden sind, ist

die menschliche Abstraktionsfähigkeit von Emoticons (Oleszkiewicz, Frackowiak, Sorokowska & Sorokowski, 2017). Sie sind somit ein ausdrucksstarker Informationsträger.

Trotz des Interpretationsspielraums und der Bandbreite an möglichen Bedeutungen sind Emoticons ein nicht selten anzutreffendes Merkmal in der Sentimentanalyse der schriftlichen Kommunikation. Die Verwendung von Emoticons als Eingabemerkmale reicht von einer einfachen, positiven bzw. negativen Untergliederung bis hin zu einer dezidierten Aufteilung unterschiedlicher Eingangskategorien. Go, Bhayani & Huang (2009) nutzten Emoticons in ihrer Grundform mit einem lachenden und einem traurig verzogenen Mund als Filter, um bei einer Suchanfrage bei Twitter positive und negative Tweets zu erhalten. Die resultierenden Daten wurden für drei unterschiedliche Klassifikationen verwendet, wobei die dritte Kategorie das Auftreten beider Emoticons umfasste. Wenngleich das Forscherteam angab, dass die Emoticons bei der naiven Bayes-Klassifikation nur einen geringen Einfluss auf die Modellgüte hatten, entfernten sie die Emoticons in allen drei Modellen, da diese sowohl das Ergebnis des Maximum-Entropie-Modells als auch des *Support-Vector-Machine*-Klassifikators verschlechterten. Ein weiterführender Ansatz untersuchte die Abstufung der positiven und negativen Emoticons in deren Intensität als Eingangsmerkmal (Agarwal, A. et al., 2011). Vashisht & Thakur (2014) bewerteten Meldungen in Facebook mit einem endlichen Automaten, der die einzelnen Zeichen eines Emoticons auswertete. Sie verwendeten 21 unterschiedliche Eingangskategorien, um sowohl eine feingranulare Emotionsbestimmung als auch eine Positiv-negativ-Klassifikation durchzuführen.

Um der Vielzahl der Schreibweisen der Emoticons gerecht zu werden und um Sonderzeichen an anderen Textstellen ersetzen zu können, muss eine Harmonisierung stattfinden. Laut einer Twitteranalyse, der 96.269.892 Tweets zugrunde liegen, sind die am häufigsten verwendeten Emoticons folgende aneinandergereihten Symbole (Berry, 2012):

Rang	Emoti-con	Abs. Häufigkeit	Proz. Häufigkeit	Bedeutung
1.	:)	32.115.789	33,36 %	Freude
2.	:D	10.595.385	11,01 %	Freude
3.	:(	7.613.014	7,91 %	Trauer, Unglück
4.	:)	7.238.295	7,52 %	(Ironisches) Zwinkern
5.	:-)	4.254.708	4,42 %	Freude
6.	:P	3.588.863	3,73 %	Jemanden ärgern, frech sein
7.	=)	3.564.080	3,70 %	Freude
8.	(:	2.720.383	2,83 %	Freude
9.	;)	2.085.015	2,17 %	(Ironisches) Zwinkern
10.	:/	1.840.827	1,91 %	Unentschlossen, skeptisch oder verärgert
11.	XD	1.795.792	1,87 %	Breites Grinsen
12.	=D	1.434.004	1,49 %	Freude
13.	:o	1.077.124	1,12 %	Schock oder Erstaunen
14.	=]	1.055.517	1,10 %	Freude
15.	D:	1.048.320	1,09 %	Trauer, Unglück

16.	;D	1.004.509	1,04 %	(Ironisches) Zwinkern und Freude
17.	:]	954.740	0,99 %	Freude
18.	:-(-	816.170	0,85 %	Trauer, Unglück
19.	=/	809.760	0,84 %	Unentschlossen, skeptisch oder verärgert
20.	=(	760.600	0,79 %	Trauer, Unglück

Tabelle 37: Liste der häufigsten Emoticons

Emoticons werden in dieser Arbeit als ein zusammengefasstes Eingangsmerkmal verwendet. Dies bedeutet, dass die Zeichenfolgen harmonisiert werden, indem sie durch ein Schlüsselwort ersetzt werden. Als Differenzierungsgrundlage werden folgende Kategorien verwendet:

Emoticon Kopfende links	Emoticon Kopfende rechts	Schlüsselwort
:-) :) (=) :c) x) :o)	(-: (: (= c: (x (o:	EMOTI- CON_FREUDIG
:-(: (= (x (:o(:C	):-: :) =) x) o: D:	EMOTI- CON_TRAURIG
:(' :C ;(: ;-(	)): D': ); )-;:	EMOTI- CON_WEI- NEND
;-) ;) ;] ;o)	(; (; [; (o;	EMOTI- CON_ZWIN- KERND
:-P :b :p =P :P xP ;-P :oP	d-: d: q: d= d;	EMOTI- CON_FRECH
:-D ;D :D =D xD XD :oD		EMOTI- CON_LA- CHEND
:0 :-o :o :O =O :0 =o	0-: o-: o: O= 0: o=	EMOTI- CON_ER- STAUNT

Tabelle 38: Harmonisierung der Emoticons in Schlüsselwörter

### 7.1.4.3 Sonderzeichen und nichtdeutsche Alphabete

Der Zeichensatz Unicode, der bei den meisten neueren Systemen verwendet wird, besitzt in der Version 10.0.0 aktuell 136.690 Zeichen und 139 komplett abgebildete Schriftsysteme unterschiedlicher Sprachen (Unicode Consortium, 2017). Für die deutschsprachige Sprachverarbeitung sind im Grunde nur wenige relevant. Dazu gehören das lateinische Alphabet sowie drei Buchstaben mit Umlauten und ein kleingeschriebenes ß. Darüber hinaus werden noch die arabischen Zahlen, Interpunktionszeichen, Leerzeichen, Zeilenumbrüche und wenige sonstige Zeichen benötigt. Arbeitet man mit Buch- oder Nachrichtentexten, so ist dieser Zeichenvorrat meist ausreichend, solange man von mathematischen Abhandlungen und fremdsprachigen Wortvorkommnissen absieht. Für die Texte von Nutzern der Nachrichtenportale trifft dies jedoch nicht zu. Buchstaben, die dem uns gewohnten Alphabet ähneln und für einen menschlichen Leser oft nicht unterscheidbar sind, führen bei der exakten Bearbeitung des zugrunde liegenden Unicodes durch einen Computer zu Komplikationen. Manchmal möchten die Verfasser von Kommentaren bewusst durch den Gebrauch von Sonderzeichen hervorstechen oder Schimpfwörter verschleiern, da sie menschlich, jedoch nicht maschinell lesbar sind. Im

günstigsten Fall entsteht dadurch ein neuer Term, der aufgrund gleichen Aussehens, aber unterschiedlichem Unicode separiert betrachtet wird. Im ungünstigsten Fall führen Steuer- und Befehlszeichen zu Ablaufproblemen im Programm oder unerwünschten, nicht nachvollziehbaren Ergebnissen.

Um der besonderen Vielfalt an Zeichen in den Nachrichtenkommentaren entgegenzuwirken und diese auf ein beherrschbares Maß herunterzubringen, wird für diesen Korpus eine Harmonisierung verwendet. Dieser Prozessschritt sieht mehrere Datensäuberungsstrategien vor. Zum einen werden fremdländische Alphabete ins Deutsche übertragen. Dies passiert durch das Austauschen auf Buchstabenebene. Folgende Buchstaben werden dabei sozusagen eingedeutscht:

Buchstabe	Deutsche Entsprechung	Buchstabe	Deutsche Entsprechung
Ă Ă Ă Ă Ǻ Ǻ Ǻ Ǻ	A	Ñ Ñ Ñ	N
â â â â ã à á ā	a	ñ ñ ñ	n
Æ	Ae	Ó Ó Ø Ò Õ Ö Ö	O
æ	ae	ó ô ø ò õ ö ö	o
Ç Ç Ç Ç	C	Œ	Oe
ç ç ç ç	c	œ	oe
Đ Đ	D	Ř	R
đ đ	d	ř	r
É Ě È Ê Ě Ě Ě	E	Š Š Š Š Š	S
é ě è ê ě ě ě	e	š š š š š	s
Ĝ Ĝ	G	Ť Ť Ť þ	T
ĝ ĝ	g	ť ť þ	t
Ĥ	H	Ú Ú Ů Û Ú Ú Ů	U
ĥ	h	ú ů Ů Û ú ú Ů	u
Î Î Î Î Î	I	Ŵ Ŵ Ŵ Ŵ	W
î î î î î	i	ŵ ŵ ŵ ŵ	w
Ĵ	J	Ŷ Ŷ Ŷ Ŷ	Y
ĵ	j	ŷ ŷ ŷ ŷ	y
Ł	L	Ž Ž Ž	Z
ł	l;	ž ž ž	z

Tabelle 39: Ersetzung und Harmonisierung der verwendeten Zeichen

Der nächste Schritt zur Verringerung der Zeichenvielfalt ist die Filterung unerwünschter Zeichen und Symbole. Hiermit werden beispielsweise alle chinesischen, koreanischen oder japanischen Schriftzeichen sowie unerwünschte Sonder-, Steuer- und Befehlszeichen gefiltert. Dadurch, dass durch den Harmonisierungsschritt etwaige fremdsprachige Namen oder Begriffe in einen deutschen Zeichensatz überführt wurden, soll sichergestellt werden, dass hier nicht fälschlicherweise ganze Wörter verschwinden oder nicht nachvollziehbar entstellt werden.

Folgende Zeichen wurden für diese Arbeit als gültig befunden, alle restlich wurden aus dem Korpus entfernt:

Bezeichnung	Beschreibung
Buchstaben	Lateinisches Alphabet, ä, ö, ü, ß, Ä, Ö, Ü
Zahlen	0 bis 9

<b>Interpunktion</b>	, , , ; , !
<b>Sonderzeichen</b>	, ' , - , * , + , = , < , > , # , @ , ' , \ , , , ' , ` , € , \$ , % , & , ( , ) , [ , ] , § , μ , _ sowie Leerzeichen, Zeilenumbrüche und Tabulatoren

Tabelle 40: Zeichenpersistierung im Korpus

## 7.1.5 Merkmalsanreicherung

### 7.1.5.1 Wortarten

Das *Part-of-Speech-Tagging* ist ein Vorgang, bei dem Wortarten im Text erkannt und angereichert werden. Gemäß Brill (2000) stellt das *Part-of-Speech-Tagging* einen Kompromiss zwischen der einfachen Verfügbarkeit von Informationen und einem wesentlich aufwendigeren Prozess der Strukturerkennung dar. Neben der Wortartenerkennung kann auch eine morphologische Analyse und Annotation stattfinden, die gerade für flexionsreiche Sprachen wie das Deutsche von Interesse ist. Ein wesentlicher Vorteil stellt die Reduktion der Morphemvielfalt dar, die der deutschen Sprache anhaftet. Letztere kann, zumindest für flexionsreiche Sprachen, nicht durch einen sogenannten Stemmer, also ein regelbasiertes Werkzeug zum Kürzen der Endungen (Porter, 1980), realisiert werden.

Die Eingabe der Wortarten kommt im Allgemeinen in der natürlichen Sprachverarbeitung als Grundlage für weiterführende Verarbeitungsschritte zum Einsatz, sei es beispielsweise der Aufbau eines Abhängigkeitsbaums oder die Erkennung der Negation. In der Sentimentanalyse wird dieser Verarbeitungsschritt häufig auch dafür genutzt, um spezielle Wortarten zu filtern, da beispielsweise Adjektiven ein höherer subjektiver Gehalt zugeschrieben wird als Nomen (Xia, Zong, Hu & Cambria, 2013). Gleiches gilt für Wortartsequenzen, die auch in den Fokus der Sentimentanalyse rücken (Turney, 2002). Außerdem kann dies neben anderen Merkmalen als Eingangsmerkmal bei einer Referenzerkennung oder einer Polaritätserkennung genutzt werden (Kim, S.-M. & Hovy, 2006a; Pang et al., 2002). Eine Filterung nach Wortarten findet in dieser Arbeit ebenso wenig Anwendung wie der Aufbau eines Abhängigkeitsbaums.

#### 7.1.5.1.1 Auswahl der Softwarelösung

Die natürliche Sprachverarbeitung wird zu einem großen Teil mit englischen Texten erforscht. Anderssprachige Werkzeuge sind existent, jedoch weitaus dünner gesät. Das *Part-of-Speech-Tagging* ist eine Standardanwendung in der Computerlinguistik. Daher sind sowohl annotierte Datensätze zum Selbstkreieren eines Klassifikators als auch fertige Softwarelösungen mit Parametersätzen für die deutsche Sprache vorhanden. Unter den verfügbaren Lösungen sollen die vier Sprachwerkzeuge *TreeTagger*, *RFTagger*, *Trigrams'n'Tags* (TnT) und der

*Memory-based Tagger* kurz skizziert und bezüglich ihrer Zweckdienlichkeit für diese Arbeit eingeschätzt werden (Manning, 2014).

Der TreeTagger, der von Schmid (1994, 1999) federführend entwickelt wurde, ist ein Instrument zur Anreicherung von Wortarten und zur Ableitung von Lemmata. Als Basis für die Wortklassifikation dient ein abgewandelter ID3-Entscheidungsbaum (weiterführend dazu Quinlan, 1986). Mit dem deutschen Parametersatz können Texte anhand des Stuttgart-Tübingen Tagsets (STTS) annotiert werden. Dieses Set besteht aus „54 tags, von denen 48 reine POS-tags sind und 6 zusätzliche tags für fremdsprachliches Material (FM), Kompositions Erstglieder (TRUNC), Nichtwörter (XY) und Satzzeichen(\$, \$., \$)“ (Schiller, Teufel, Stöckert & Thielen, 1995, S. 6). Die TreeTagger-Software ist für Forschungs- und Bildungszwecke frei verfügbar. Ferner existieren Wrapper-Klassen für zahlreiche Programmiersprachen.

Aus der gleichen Feder stammt die RFTagger-Softwarelösung, die darüber hinaus eine feingranulare Annotation der Wortarten vornimmt (Schmid & Laws, 2008). Anders als der zuvor erwähnte TreeTagger basiert der RFTagger auf Entscheidungsbäumen und auf *Hidden Markov-Models* (HMM). Neben der Wortart sowie dem Lemma werden die morphologischen Informationen Kasus, Tempus, Numerus und Genus erkannt. Für diesen *Part-of-Speech-Tagger* sind bereits deutsche, tschechische, slowakische, ungarische und russische Trainingsmodelle vorhanden. Darüber hinaus existiert eine Java-Implementierung, bei der eine Zuordnung zum bereits erwähnten STTS vorhanden ist (Ziai & Ott, 2014).

TnT ist ein statistischer *Part-of-Speech-Tagger*, der Trigramme ebenfalls mittels HMMs klassifiziert. Das Modell wurde mit dem deutschen NEGRA-Korpus trainiert, ergo sind die Tags mit dem STTS-Schema klassifizierbar (Brants, 2000). Mit dem *TnT-Tagger* können neben der Annotation der Wortarten keine Lemmata abgeleitet werden. Zur Nutzung des *TnT-Taggers* ist eine Registrierung über eine Unterzeichnung der Lizenzvereinbarung notwendig.

Der *Memory-based Tagger* stellt ebenso wie der TreeTagger eine überwachte Form des maschinellen Lernens dar (Daelemans, Zavrel, Berck & Gillis, 1996). Die ähnlichkeitsbasierte Klassifikation beruht auf dem *Memory-based Learning*, das eine Abstandsmetrik, eine Liste der nächsten Nachbarpunkte und eine Gewichtungsfunktion verwendet. Die Klassifizierung wird durch Vergleiche mit ähnlichen, gespeicherten Sätzen erzielt (Daelemans & Bosch, 2005). Der Vorteil dieses *Tagger* gegenüber dem HMM basierten *TnT-Tagger* besteht darin, dass der Kontext per Einstellung beidseitig betrachtet werden kann, was zu einer Verbesserung der Modellgüte führt (Ivanova & Kuebler). In gleicher Weise wie beim TreeTagger können mit der *Memory-based Lemmatization* (MBLEM) und den *Memory-based Tagger-Generation and Tagging* (MBT) sowohl eine Klassifikation der Lemmata als auch der *Part-of-Speech-Tags*

vorgenommen werden. An dieser Stelle sei erwähnt, dass auf der niederländischen Seite des Anbieters der deutsche Parametersatz für den MBT derzeit bzw. generell nicht mehr verfügbar ist.

In dieser Arbeit wird der RFTagger verwendet. Dies hat im Wesentlichen vier Gründe. Erstens können Lemmata aus den Termen abgeleitet werden. Dadurch kann die Anzahl der Terme im Index deutlich reduziert werden. Der zweite Grund ist die freie Verfügbarkeit des *Tagger* und der Parameterdatensätze. Und drittens ist für diesen *Part-of-Speech-Tagger* eine Java-Schnittstelle verfügbar. Letztere erlaubt eine nahtlose Integration in den übrigen für diese Arbeit verwendeten Java-Quelltext und damit einen unterbrechungsfreien Programmablauf. Der wichtigste Grund für die Verwendung dieses *Tagger* ist die Möglichkeit, gezielt morphologische Informationen anzureichern.

Die Leistungsfähigkeit eines *Part-of-Speech-Tagger* ist eng mit der Datenqualität verknüpft. In der Studie von Rehbein (2013) wurden vor dem *Part-of-Speech-Tagging* alle URLs, Hashtags, Emoticons und Referenzen auf andere Benutzernamen durch Schlüsselwörter ersetzt. Auch hier werden vor diesem maschinellen Annotationsschritt alle Vorverarbeitungsprozesse zur Verbesserung der Datenqualität und zur Harmonisierung der Daten durchgeführt.

### **7.1.5.2 Negation**

Die Negation spielt in der Sentimentanalyse bei der Bedeutungserkennung eines Terms eine wichtige Rolle. Sie ist deswegen entscheidend, weil eine Bedeutungsverschiebung stattfindet, die die Güte des Modells tiefgreifend beeinflussen kann (Carrillo de Albornoz & Plaza, 2013). Die Verneinung zieht bei bipolaren Zielkategorien eine nachvollziehbare Bedeutungsverschiebung in die jeweils andere Kategorie nach sich. Dieses Prinzip lässt sich bei einer Emotionserkennung nur dann in analoger Weise anwenden, wenn es komplementäre Emotionskategorien gibt. Sind die Emotionsmodelle gleichrangig und ohne Gegenpol, dann spricht dies nicht gegen eine Verwendung der Negationserkennung. Wie im Theorieteil zu den Emotionen gezeigt wurde, ist die Negation einer emotionalen Qualität nicht zweifelsfrei auflösbar. Durch die Markierung von negierten Token soll eine Abgrenzung zu nicht verneinten Token erreicht werden, um beide in die korrekte Zielkategorie einordnen zu können und um so eine geeignete Disambiguierung der Wortbedeutung zu ermöglichen.

#### **7.1.5.2.1 Negation in der Sentimentanalyse**

Der Grundgedanke bei der Negation ist die Umkehrung einer Aussage in die gegenteilige Aussage (Miestamo, 2007), was besonders für die Sentimentanalyse einen entscheidenden Unterschied ausmacht, da die Richtung der Meinung maßgeblich für deren Interpretation ist. Die

Verneinung eines Textfragments kann sprachlich durch Präfixe, Suffixe, Negationswörter, Konjunktionen oder Präpositionen transportiert werden (Bensch & Stetter, 2007). Wenngleich die Negation keine triviale Angelegenheit ist, so wird in der Sentimentanalyse oft nur ein pragmatischer Ansatz verfolgt, was in den nachfolgenden Absätzen angedeutet wird.

Die morphologische Negation erfolgt auf Wortebene, indem durch Präfixe oder Suffixe die Bedeutung eines Wortes umgekehrt wird. Beispielsweise wird das Wort „instabil“ durch das Präfix „in-“ zum Gegenteil von „stabil“. In ähnlicher Weise werden das positiv konnotierte Nomen „Humor“ und das Adjektiv „lieb“ durch das Anhängen des Suffixes „-los“ ins Negative konvertiert (Bensch & Stetter, 2007). Aufgrund der Polysemie können bei dieser Art der Negation nicht alle möglichen Wortbedeutungen erfasst werden, wie das Beispiel des Adjektivs „günstig“ in der morphologisch abgewandelten Form „ungünstig“ im Vergleich zum Adjektiv „teuer“ zeigt. Nichtsdestotrotz ermöglicht diese Herangehensweise eine einfache Art der Bildung von Antonymen, weswegen sie sich zur Polaritätserkennung eignet. Diese Idee wurde exemplarisch in dem *Affix Seeds Lexicon* (ASL) verwirklicht. Aus den Wortkombinationen mit allen möglichen Präfixen oder Suffixen, wurden alle im Lexikon befindlichen Terme verwendet. Mit der bekannten Wertigkeit und dem Gegenpart fanden diese Antonympaare in das Lexikon Eingang (Mohammad et al. (2009). Neben der Erstellung eines Lexikons mittels Affixen gibt es einen Aufsatz über die Polaritätsklassifikation unter der Berücksichtigung morphologischer Ableitungen von Präfixen und Suffixen sowie affixähnlicher Wortanhänge wie „*well-built*“ oder „*strange-looking*“, die typisch für die englische Sprache sind (Moilanen & Pulman, 2008). Bei der Recherche für diese Arbeit fiel jedoch auf, dass diese Art der Negation als Eingangsmerkmal kaum Verwendung findet. In wenigen Studien wie der von Lapponi, Read & Øvrelid (2012) wird sich sogar deutlich von der Betrachtung morphologisch veränderter Wörter abgegrenzt. Dies deckt sich mit der üblichen Herangehensweise in der Textanalyse von Meinungen, bei der Wörter mit veränderten Affixen grundsätzlich als unterschiedliche Terme behandelt werden und somit gesondert in den Verarbeitungsschritt eingehen.

Neben der Negation durch Präfixe oder Suffixe bei einzelnen Wörtern wird die Bedeutungsumkehrung in den überwiegenden Fällen mit Negationswörtern realisiert. Sprachlich kann, bezugnehmend auf eine vorher getroffene Aussage, somit eine Verneinung oder Bejahung stattfinden. Diese Art der Zustimmung oder Ablehnung wird durch die Wörter „ja“ und „nein“ gebildet, wobei sich diese Haltung prinzipiell auf den ganzen nachfolgenden Satz bezieht, sofern dies nicht durch andere Konstruktionen aufgehoben wird (Bensch & Stetter, 2007). Eine Bejahung und Verneinung einer Aussage ist häufig in Dialogen zu finden und seltener in Bewertungen, Kommentaren oder Texten, die üblicherweise in der Sentimentanalyse

verwendet werden. Daher findet man auch zu dieser speziellen Thematik keine explizite Untersuchung der Negation eines Aussagesatzes. Vielmehr werden bedeutungsändernde Schlüsselwörter, die in einem Satz mit „nein“ in den meisten Fällen beinhaltet sind, analysiert, wie die folgenden Methoden zeigen.

Wird ein Satz, ein Satzfragment oder ein bestimmtes Wort negiert, kann der Negationspartikel „nicht“ oder das Indefinitpronomen „kein“ dafür eingesetzt werden (Bensch & Stetter, 2007). Ein einfaches Verneinen eines Satzteils oder eines Worts mit diesen Negationswörtern wurde an anderer Stelle in der Sentimentanalyteliteratur auch als *Right Flip* bezeichnet, bei dem die englischen Übersetzungen „*not*“ und „*no*“ als Eingangsmerkmal eingehen (Tromp, 2012). Das & Chen (2001) sowie Pang et al. (2002) implementierten in ihrer Herangehensweise die Verneinung durch das Anhängen des künstlichen Suffixes -n bzw. Präfixes NOT\_ an alle Wörter zwischen dem Negationswort und dem Satzende bzw. dem ersten Satzzeichen. Dieser vereinfachte und linguistisch inkorrekte Ansatz führte nur zu einer marginalen bzw. vernachlässigbaren Verbesserung der Ergebnisse (Pang et al., 2002). Darüber hinaus ist dieser Ansatz für die deutsche Sprache nur bedingt praktikabel, da das Partikel „nicht“ abhängig von der Position der Präposition auch vor dem Verb am Ende des Satzes stehen kann (Bensch & Stetter, 2007; Wiegand, Balahur, Roth, Klakow & Montoyo, 2010). Eine einfache Alternative, um Negationswörter in die Analyse miteinfließen zu lassen, ist die Verwendung von n-Grammen, wengleich sich der Wirkungskreis eines Negationsworts auf die Länge des n-Gramms beschränkt (Wiegand et al., 2010).

Weitere Negationswörter aus der Wortartfamilie der Umstandswörter und Indefinitpronomen wie beispielsweise „niemand“, „nichts“, „nie“, „niemals“, „nirgendwo“, „nirgendwärts“, „nirgendwohin“ (Bensch & Stetter, 2007) bzw. die anderssprachlichen Übersetzungen dazu werden nie gesondert und ausschließlich betrachtet, sondern in neueren Ansätzen der sprachlichen Negationsauflösung in Verbindung mit den bereits genannten Verneinungen „nicht“ und „keine“. Bezüglich der Polarität lösen diese Schlüsselwörter als Eingabemerkmal die gleiche negierte Wertänderung aus.

Während in den anfänglichen Studien zur Verneinung von Meinungen der Fokus auf der Betrachtung des ganzen Satzes lag (Polanyi & Zaenen, 2006), werden in neueren Forschungsarbeit jeweils zwei Aspekte der Verneinung untersucht, um eine deutlichere Abgrenzung zu erreichen (Lapponi et al., 2012): *Cues*, also Negationswörter im Sinne der gerade genannten Beispiele, und *Scopes*, die die Reichweite des zu negierenden Satzes betreffen. Zusammen bilden die Hinweise und der Skopus eine Negationssequenz, die exemplarisch mittels eines *Conditional-Random-Field* (CRF) annotiert werden kann. In dieser Studie dienten sowohl lexikalische

und syntaktische als auch Abhängigkeitsdistanzen und -pfade als Merkmal, um den maschinellen Lernalgorithmus zu trainieren (Lapponi et al., 2012). *Cues* oder Negationshinweise können mit einem lexikalischen Abgleich bestimmter Wörter gefunden werden. Die Schwierigkeit liegt in der Negation. Weiterführend dazu stellten Council, McDonald & Velikovich (2010) Richtlinien auf, um die Eingrenzung des Skopus zu bewerkstelligen. Dazu zählen die Exklusion des Negationsworts, die Integration des ganzen Nominal- bzw. des Verbalsatzes, die Beschränkung auf ein Adjektiv, sofern vorhanden, und die vollständige Annotation eines Adverbialsatzes bzw. der Adjektivgruppe.

Verneinungen, die mit der Konjunktion „weder ... noch ...“ gebildet werden (Bensch & Stetter, 2007), fallen ebenfalls in die Kategorie der Negationshinweise. In den früheren Phasen der Negationsbetrachtung innerhalb des Forschungsgebiets der Sentimentanalyse stellte diese Konjunktion einen Trigger dar, bei dem der ganze Satz negiert wurde (Polanyi & Zaenen, 2006). In neueren Ansätzen wird analog zu den oben genannten Negationswörtern ein Skopus über jene zwei Satzfragmente gelegt, die zwischen und nach dieser Konstruktion angeordnet sind (Vinodhini & Chandrasekaran, 2012).

Sätze, die die Präpositionen „ohne“, gefolgt von einem Akkusativsatz, und „außer“, gefolgt von einem Dativsatz, beinhalten, fallen ebenfalls in die Kategorie der Verneinung (Bensch & Stetter, 2007). Neben der Exklusionsfunktion der Schlüsselwörter können sie, abhängig vom Kontext, ebenfalls als Bedingungskriterium interpretiert werden (Schwartz, 2009). Letzteres erhöht den Komplexitätsgrad bei einer Analyse geringfügig. Da sie jedoch einen Hinweis auf einen möglichen Bedeutungswechsel anzeigen, findet sich auch diese Präpositionen im Gebrauch (Hogenboom, van Iterson, Heerschop, Frasinca & Kaymak, 2011; Syed, Aslam & Martinez-Enriquez, 2011).

Abschließend zur Negation und überleitend zum nächsten Thema soll angedeutet werden, dass es neben dem oft pragmatischen Ansatz der Negation in der Sentimentanalyse auch eine dezidiertere Betrachtungsweise dieses Eingangsmerkmals gibt. Hogenboom et al. (2011) kritisieren in diesem Zusammenhang, dass negierte Wörter in ihrer Deutlichkeit von dem tatsächlichen Antonym abweichen. So ist, deren Beispiel folgend, „nicht gut“ weniger nachdrücklich und damit weniger negativ konnotiert als das Adjektiv „schlecht“. Die Lösung für dieses semantische Unschärfeproblem ist die Einführung einer Abstufung der Negierung. Das Forscherteam verwendet dazu den von ihnen geprägten Faktor *Modified Inversion-Strength*, der jeden Wert in dem Intervall [-2, 0] annehmen kann (Hogenboom et al., 2011, S. 2590).

#### 7.1.5.2.2 Negation mittels Softwarelösung

Eine Negationsannotation eines deutschen Datensatzes stellt eine Herausforderung dar, da die deutsche Syntax Negationsmorpheme an unterschiedlicher Stellung erlaubt. Im Vergleich zu Fremdsprachen, wie beispielsweise dem Englischen, gibt es im Deutschen keine starren Regeln zur syntaktischen Positionierung des Verneinungsausdrucks im Satz (Lerot, 1972). Folglich und aufgrund des allgemeinen anglistischen Forschungsfokus in der Computerlinguistik gibt es nur wenig rechnergestützte Werkzeuge für den deutschsprachigen Raum. Remus (2013) untersuchte die zwei Softwarelösungen NegEx und LingScope, die an dieser Stelle kurz beleuchtet werden. NegEx ist eine Negationsroutine für den biomedizinischen Bereich basierend auf regulären Ausdrücken (Chapman, Bridewell, Hanbury, Cooper & Buchanan, 2001). Mit einer mehrsprachigen Erweiterung können auch Negationen in deutschen Texten markiert werden (Chapman et al., 2013), jedoch mit der domänenspezifischen Einschränkung. LingScope ist eine Java Applikation auf der Grundlage von *Conditional Random Fields* mit demselben Anwendungszweck. Ferner werden bei dem Programm LingScope Token in einem Satz durch die entsprechenden *Part-of-Speech-Tags* ersetzt, um das Negationsergebnis zu verbessern (Agarwal, S. & Yu, 2010). Hier stehen ebenfalls Texte aus der Biomedizin im Fokus. Darüber hinaus wurde das Modell an einem englischen Datensatz trainiert. Jedoch ist es möglich selbst Modelle durch einen geeigneten Trainingskorpus anzupassen. Wenngleich Remus (2013), aufgrund der besseren Ergebnisse, dem Programm LingScope den Vorzug gegenüber NegEx einräumt, so sind dennoch beide Lösungen aufgrund des Domänenfokus und des fehlenden annotierten Datensatzes ungeeignet.

#### 7.1.5.2.3 Regelbasierte Negation

Um dennoch die Negation in das Modell zu integrieren und der Hypothesenüberprüfung zuzuführen, führt kein pragmatischer Weg an manuell erstellten Regeln vorbei. Diese werden in Anlehnung an die Feinheiten der deutschen Sprache formuliert, so dass die in Kapitel 7.1.5.2.1 bereits angeführten Negationshinweise berücksichtigt werden. Hier wird für die Verneinung ein praktikablerer Ansatz gewählt, was bedeutet, dass die Negation nur auf die im Fokus befindlichen Verben, Adjektive und Nomen angewendet wird. Prozessual ist das *Part-of-Speech-Tagging* aus dem vorangegangenen Kapitel 7.1.5.1 eine notwendige Grundbedingung für diese Merkmalsanreicherung. Negationsmorpheme sollen dabei als Hinweis für verneinte Phrasen verwendet und Terme im Skopus durch das Anfügen eines künstlichen Negationssuffixes „\_neg“ markiert werden.

An dieser Stelle seien ein paar grundlegende Verhaltensmuster des programmierten Skripts der hier verwendeten, regelbasierten Negation anzumerken. Die Negationsregeln

werden immer der Reihe nach, von oben nach unten geprüft. Dies hat den Hintergrund, dass spezielle immer vor allgemeineren Regeln angewendet werden. Trifft keine der gelisteten Negationsbedingungen zu, so bezieht sich die Negation auf ein in dieser Arbeit nicht berücksichtigtes Verb oder der Bezug zu einem Adjektiv oder Nomen kann aufgrund der Satzstellung nicht gefunden werden. In beiden Fällen wird keine Negation durchgeführt. Ferner ist es bei der punktweisen Abarbeitung der Bedingungen nicht möglich, dass mehrere Negationsregeln greifen. Es trifft also maximal eine Negationsregel pro Verneinungshinweis zu. Doppelte Negationen wie in dem Satz „es gab keine nicht-gültigen Stimmzettel“ werden insofern berücksichtigt, als die zweite Negation die erste aufhebt bzw. rückgängig macht. Außerdem beziehen sich alle nachfolgenden Verneinungsregeln immer auf das nächstgelegene Token einer Wortart zum Negationswort, sofern dies nicht explizit anders angegeben wird. Beinhaltet der zu analysierende Satz mehrere Nebensätze oder durch eine Konjunktion verknüpfte Sätze, so werden diese getrennt voneinander betrachtet. Folgender Satz wird für die Untersuchung in drei Sätze gegliedert: „Er ging kein Risiko ein und stieg nicht in den Bus, weil er ohne Fahrschein war“. Diese Separierung ist notwendig, um mehrere Negationen unterschiedlicher Art oder des gleichen Typs zu erfassen.

Im Folgenden wird der Umgang mit den einzelnen Negationspartikeln und -hinweiswörtern anhand sprachlicher Regeln erläutert.

#### **7.1.5.2.3.1 Niemand, nichts, nie, niemals, nirgendwo, nirgends, nirgendwohin und außer**

Negationswörter die Personen-, Sach-, Zeit-, Orts- und Richtungsbezüge beinhalten, bieten eine unkomplizierte Möglichkeit der Verneinung. Dazu gehören „niemand“, „nichts“, „nie“, „niemals“, „nirgendwo“, „nirgends“ und „nirgendwohin“ (Bensch & Stetter, 2007). Satzkonstruktionen mit diesen Pronomina und Adverbien kommen oft in wiederkehrenden Strukturen vor. Adjektive und Nomen, bei denen eine verlässliche Aussage über den Skopus der Verneinung getroffen werden kann, befinden sich rechts der genannten negativen Indefinita. Dieser Regel folgend, würde der Satz „er sieht nie schöne Häuser“ für die maschinelle Verarbeitung in die Wortfolge „er sieht nie schöne \_neg Häuser \_neg“ übersetzt werden.

Diese einfache Form der Negation wird auch auf die Negationspräposition „außer“ angewendet. Da der für die Negation relevante Dativfall in einer regelbasierten Annotation nur schwierig erkannt werden kann, wird der pragmatische Ansatz der Negation des Nomens oder der Adjektiv-Nomen-Folge gewählt.

In der folgenden Tabelle sind die Negationsregeln, die die beiden vorhergehenden Absätze betreffen, in Wortform ausgeführt:

Regel	Verneinung	Regel
1.1	Verneinung des Adjektivs rechts des Negationsworts	Das Adjektiv befindet sich an erster bis vierter Stelle nach dem Negationswort und steht direkt vor einem Nomen.
1.2	Verneinung des Nomens rechts des Negationsworts	Das Negationswort steht an erster oder zweiter Stelle, gefolgt von einem Nomen oder einem Eigennamen.

*Tabelle 41: Regel für die Negation durch nie, nicht und außer*

#### 7.1.5.2.3.2 Ohne

Die Präposition „ohne“ wird nach den gleichen Regeln wie ebenda behandelt (Bensch & Stetter, 2007). Das Nomen in dem Satzgefüge „er ging, ohne die Ampel zu beachten“ wird verneint. Jedoch darf bei dem leicht abgeänderten Satz „er ging, ohne die rote Ampel zu beachten“ das Eigenschaftswort in der Adjektiv-Nomen-Folge nicht negiert werden.

Im Folgenden werden die Regeln erneut tabellarisch dargestellt.

Regel	Verneinung	Regel
2.1	Negation des Verbs rechts von „ohne zu ...“	Das Negationswort bezieht sich in der Kombination „ohne zu“ auf die Verneinung des Verbs.
2.2	Adjektiv rechts des Negationsworts	Das Adjektiv befindet sich an erster bis vierter Stelle nach dem Negationswort und steht direkt vor einem Nomen.
2.3	Nomen rechts des Negationsworts	Das Negationswort steht an erster oder zweiter Stelle, gefolgt von einem Nomen oder einem Eigennamen.
2.4	Nomen rechts des Negationsworts	Das Negationswort steht an erster bis dritter Stelle, gefolgt von einem Nomen oder einem Eigennamen und der Kombination zu + Verb im Infinitiv am Ende des Satzteils.

*Tabelle 42: Regel für die Negation durch ohne und ohne ... zu*

#### 7.1.5.2.3.3 Weder ... noch

Die Konjunktion „weder ... noch“ wird bei der Negierung von zwei Aussagen bzw. zwei Elementen verwendet (Bensch & Stetter, 2007). Durch den doppelten Skopus werden bei dieser Art der Negation die oben bereits genannten Regeln nach beiden Hinweiswörtern angewendet. Entsprechend verhalten sich die programmierten Richtlinien wie folgt:

Regel	Verneinung	Regel
3.1	Adjektiv rechts des Negationsworts „weder“	Das Adjektiv befindet sich an erster bis vierter Stelle nach dem Negationswort „weder“ und steht direkt vor einem Nomen.
3.2	Nomen rechts des Negationsworts „weder“	Das Negationswort „weder“ steht an erster oder zweiter Stelle, gefolgt von einem Nomen oder einem Eigennamen.
3.3	Adjektiv rechts des Adverbs „noch“	Das Adjektiv befindet sich an erster bis vierter Stelle nach dem Negationswort „noch“ und steht direkt vor einem Nomen.
3.4	Nomen rechts des Adverbs „noch“	Das Negationswort steht an erster oder zweiter Stelle, gefolgt von einem Nomen oder einem Eigennamen.

*Tabelle 43: Regel für die Negation durch weder ... noch*

#### 7.1.5.2.3.4 Kein

Neben dem ebenfalls bei dem Negationswort „kein“ auftretenden Skopus der rechtsgelegenen Adjektive und Nomen gibt es bei diesem Indefinitpronomen häufig Vorkommnisse in anderen Satzkonstellationen. Blühdorn (2008) geht in seiner linguistischen Untersuchung genauer auf die Eigenheiten des indefiniten Pronomens „kein“ ein. Die bereits bekannte, bei den obigen Negationen angewandte Regel der Negation der rechtsstehenden Satzglieder entspricht dem Fall, dass „kein“ „vor einem [...] nicht-referentiellen indefiniten Nominale“ auftritt (S. 130). Nach der gleichen Regel sind Vorkommnisse von „kein“ vor „einem Kardinal-Numeral oder einem anderen lexikalischen Quantifikator“ zu behandeln (S. 131). Jedoch kann das Negationswort „kein“ auch am Ende oder in der Mitte eines Satzes positioniert sein und „ein Substantiv, teilweise mit Attributen, im Vorfeld und offenbar dazugehörigen Determinanten, Quantifikatoren und / oder teilweise weitere Attribute im Mittelfeld stehen“ (S. 133). Um diese Form der Negation abzugreifen, sind weiterführende Regeln notwendig, die auch Adjektive in Verbindung mit Nomen oder nur Nomen links des Negationsworts markieren. Durch das Anfügen der zusätzlichen Bedingungen in Tabelle 44 an der vorletzten und letzten Stelle der Überprüfungsschritte werden auch Sätze wie „große Ahnung hatte er keine“ richtig negiert. Jedoch löst „kein“ in der Satzmitte nicht, wie von Blühdorn (2008) gefordert, die Negation des Nomens und des Adjektivs aus, da dies mit der ersten Regel in Tabelle 44 nicht vereinbar ist. So wird beispielsweise in dem Satz „Texte gab es keine neuen“ nur das Adjektiv „neuen“ annotiert, was der hier beabsichtigten Negationsfunktion im ausreichenden Maße genügt.

Im Folgenden finden sich die Negationsregeln für das Hinweiswort „kein“:

<b>Regel</b>	<b>Verneinung</b>	<b>Regel</b>
<b>4.1</b>	Adjektiv rechts des Negationsworts	Das Adjektiv befindet sich an erster bis vierter Stelle nach dem Negationswort und steht direkt vor einem Nomen.
<b>4.2</b>	Nomen rechts des Negationsworts	Das Negationswort steht an erster oder zweiter Stelle, gefolgt von einem Nomen oder einem Eigennamen.
<b>4.3</b>	Adjektiv rechts des Negationsworts	Das Negationswort steht an erster oder zweiter Stelle, gefolgt von einem Adjektiv.
<b>4.4</b>	Nomen links des Negationsworts	Ein Adjektiv, gefolgt von einem Nomen oder einem Eigennamen, befinden sich links des Negationsworts und im gleichen Satzteil.
<b>4.5</b>	Nomens links des Negationsworts	Ein Nomen oder ein Eigenname befindet sich links des Negationsworts und im gleichen Satzteil.

*Tabelle 44: Regel für die Negation durch kein*

#### 7.1.5.2.3.5 Nicht

Das Negationswort „nicht“ stellt die Königsdisziplin in der Verneinung dar. Dieser Negationspartikel ist im Deutschen an unterschiedlichen Positionen im Satz zu finden, jedoch ist trotz der linguistischen Freiheit die Stellung nicht frei wählbar. Abhängig von der Position des

Negationsworts kann die „Intonation und Akzentuierung negationshaltiger Äußerungen“ beeinflusst werden oder eine Bedeutungsverschiebung einsetzen (Blühdorn, 2008, S. 39).

In Anlehnung an die Thesen zur Satzposition des Negationspartikels „nicht“ von Helbig & Albrecht (1993) sollen hier Regeln zur Negationsklassifikation abgeleitet werden, die einen großen Teil der häufig verwendeten Negationsfälle bezüglich Adjektiven und Nomen abdeckt. In erster Instanz kann die probate Negationsregel, „daß die Satznegation ‚nicht‘ am Ende des Satzes (bzw. vor infiniten Verbformen und Verbzusätzen), die Satznegation unmittelbar vor dem zu verneinenden Glied zu stehen habe“ (Helbig & Albrecht, 1993, S. 26), aufgegriffen werden. Deutlich wird dies durch die folgenden Beispielsätze 1 bis 4, bei der durch die Negation des Verbs der gesamte Satz negiert wird.

Fall 1: Der Student mag das Einschreiben nicht.

Fall 2: Der Student schrieb sich nicht ein. (Verbzusatz)

Fall 3: Der Student hat sich nicht eingeschrieben. (Partizip)

Fall 4: Der Student will sich nicht einschreiben. (Infinitiv)

Wenngleich aus intonatorischer Sicht Brüche mit diesem Satzgliederungsschema möglich sind, so soll die Negation des Verbs an dieser Stelle vernachlässigt werden, da sich weder Substantive noch Adjektive im direkten Skopus dieser Negationsregel befinden. Nichtsdestotrotz soll dieser Sachverhalt als Ausschlusskriterium für die regelbasierte Negation genommen werden. Dies wirkt sich insofern aus, als es bei „kein“ nicht, wie bei den Verneinungsregeln 4.4 und 4.5, eine Beeinflussung der Nomen oder Adjektive links des Verneinungsworts gibt. Außerdem wird mit der Regel 5.1 eine Abbruchbedingung definiert sofern dem Negationswort ein Verbzusatz, Partizip oder ein Verb im Infinitiv folgt.

Bei Nebensätzen, die mit einem Einleitewort an den Hauptsatz gekoppelt sind, steht das finite Verb ebenfalls an der letzten Position im Satz, weswegen im Deutschen ebenfalls eine Verbindung des Verbs mit dem Negationswort zustande kommen kann, wie die Fälle 5 und 6 zeigen (Helbig & Albrecht, 1993).

Fall 5: ..., dass er nicht zuhört.

Fall 6: ..., weil er nicht zuhört.

Fall 7: ..., weil er nicht mit voller Aufmerksamkeit zuhört.

In beiden Fällen wird die Negation durch die Regel 5.1 richtigerweise abgefangen, so dass hier keine Modifikation notwendig ist. Das Gleiche gilt für dazwischengeschobene Objekte, die mit den zum Teil noch folgenden Regeln 5.3 bis 5.6 abgedeckt sind.

Wird das Negationswort vor dem Präpositionalobjekt positioniert, so bezieht es sich wie im Fall 7 auf das Nomen bzw. auf die Kombination des Adjektivs mit dem Substantiv wie im

Fall 8 (Helbig & Albrecht, 1993). Ähnlich verhalten sich dazu adverbiale Bestimmungen, wie Fall 9 zeigt.

Fall 8: Sie wartete nicht auf den Bus. (Präpositionalobjekt)

Fall 9: Sie wartete nicht auf den verspäteten Bus. (Präpositionalobjekt)

Fall 10: Sie wartete nicht die ganze Zeit. (Adverbialbestimmung)

Daraus leiten sich, ähnlich wie bei den anderen Negationen, die Regeln 5.5 und 5.6 ab. Vergleicht man die beiden Regeln mit den zuvor genannten Richtlinien, fällt auf, dass die Distanz zum Negationswort um ein Wort verringert wurde. Diese Einschränkung wurde getroffen, um der variablen Satzposition von „nicht“ gerecht zu werden und Falschannotationen zu vermeiden. Durch die strengeren Bedingungen würden jedoch die beiden Beispielfälle 7 bis 9 nicht negiert werden, weswegen diese striktere Regel gelockert und damit die Distanz vergrößert wird, sofern sich ein Artikel zwischen dem Negationswort und dem Nomen befindet. Da die Regeln 5.3 und 5.4 spezieller sind, werden sie den beiden anderen vorangestellt.

Das Negationswort „nicht“ kann auch führend vor die Ergänzung eines Prädikats geschrieben werden. Dies betrifft Nomen, Adjektive oder Adverbien als Prädikativ. Bei Nomen und Adjektiven ist die Satzgliederung grammatikalisch vorgeschrieben, bei einer adverbialen Verneinung kann die Position des Negationsworts variieren, wie die Fälle 13 und 14 zeigen (Helbig & Albrecht, 1993).

Fall 11: Er spielt nicht Fußball. (Nomen im Akkusativsatz)

Fall 12: Er rennt nicht schnell. (Adjektiv)

Fall 13: Sie kam nicht sofort. (Adverb – Sondernegation)

Fall 14: Sie kam sofort nicht. (Adverb – Satznegation)

Für die Art der Negation im Fall 10 müssen keine neuen Negationsregeln geschaffen werden, da diese bereits durch die Regel 5.6 abgedeckt ist. Jedoch muss für den Fall 11 eine neue Regel definiert werden. Um nicht in Konflikt mit der Regel zu kommen, die Adjektiv-Nomen-Verbindungen betrachtet, muss die Regel 5.7 zur Annotation von Adjektiven hintangestellt werden. Da Adverbien nicht im Fokus dieser Arbeit stehen, werden diese Satznegationen nicht weiter ausgeführt.

Satzkonstruktionen, bei denen der Skopus der Negation explizit aufgehoben wird, beispielsweise bei Sätzen mit „nicht ... sondern ...“, stehen nicht im Gegensatz zu bereits bestehenden Regeln. Da der Skopus aller Regeln nur wenige Token beträgt und jeweils nur das Wort bzw. das Wortpaar mit der geringsten Distanz zum Negationspartikel negiert wird, werden auch Sätze wie der nachfolgende Fall 15 richtig klassifiziert (Helbig & Albrecht, 1993).

Fall 15: Sie war nicht langsam, sondern schnell

Eine sprachliche Akzentuierung, die durch das Vertauschen der Satzglieder entsteht, führt bei den hier vorgestellten Regeln zu ungleichen, aber durchaus nicht ungewollten Ergebnissen. Sowohl ortsbetreffende Präpositionalphrasen in den Fällen 16 und 17 als auch Adverbien wie in den Fällen 18 und 19 fallen beispielsweise in diese Kategorie (Helbig & Albrecht, 1993).

Fall 16: Sie fand ihm im Auto nicht. (Negation nach der Präpositionalphrase)

Fall 17: Sie fand ihn nicht im Auto. (Negation vor der Präpositionalphrase)

Fall 18: Er kommt heute nicht nach Hause. (Negation nach dem Adverb)

Fall 19: Er kommt nicht heute nach Hause. (Negation vor dem Adverb)

Das Negationswort „nicht“ ist kein Garant für einen Hinweis auf eine Verneinung. Es gibt Wortkombinationen, die einen relativierenden, verkettenden oder vergleichenden Charakter haben und keine Bedeutungsumkehrung der Adjektive oder Nomen nach sich ziehen (Blühdorn, 2008). Dies trifft beispielsweise auf die Verknüpfung „nicht dass“, „nicht nur“ und „nicht wie“ zu, wie die folgenden Fallbeispiele zeigen.

Fall 20: ..., nicht dass du einen Fehler machst.

Fall 21: Nicht nur Stuttgart, sondern ganz Baden-Württemberg hat er bereist.

Fall 22: Er ist nicht wie sein Bruder.

Um Falschklassifikationen zu umgehen, wurde eine zusätzliche Regel eingeführt, die diese Sonderfälle abfängt. Daher wurde die Regel 5.2 vor die potentiell gefährdeten Regeln 5.3–5.6 geschaltet und ohne Funktion hinterlegt.

Abschließend sei gesagt, dass die hier verwendeten Negationsbedingungen wegen flexibler Satzstellung des Negationsworts „nicht“ und möglicher Hypotaxen in den zugrunde liegenden Texten keine Allgemeingültigkeit besitzen. Ebenso sind diese Regeln nicht vor Falschklassifikationen gefeit. Jedoch bieten sie angesichts der absenten Alternativen einen brauchbaren und pragmatischen Ansatzpunkt zur Negationsannotation von Substantiven und Adjektiven.

Regel	Verneinung	Regel
5.1	Ignoriere Negation	Das Negationswort ist direkt gefolgt von einem Verb.
5.2	Ignoriere Negation	Das Negationswort tritt nicht in der Kombination „nicht nur“, „nicht dass“ oder „nicht wie“ auf.
5.3	Adjektiv rechts des Negationsworts	Das Adjektiv befindet sich an erster bis vierter Stelle nach dem Negationswort, steht direkt vor einem Nomen und zwischen dem Negationswort und dem Nomen befindet sich ein Artikel.
5.4	Nomen rechts des Negationsworts	Das Negationswort steht an erster oder dritter Stelle, gefolgt von einem Nomen oder einem Eigennamen und zwischen dem Negationswort und dem Nomen befindet sich ein Artikel.
5.5	Adjektiv rechts des Negationsworts	Das Adjektiv befindet sich an erster bis dritter Stelle nach dem Negationswort und steht direkt vor einem Nomen.
5.6	Nomen rechts des Negationsworts	Das Negationswort steht an erster oder zweiter Stelle, gefolgt von einem Nomen oder einem Eigennamen.
5.7	Adjektiv rechts des Negationsworts	Das Negationswort ist direkt gefolgt von einem Adjektiv.

*Tabelle 45: Regel für die Negation durch nicht*

## 7.2 Externe und korpusbasierte Wissensbasis

Für die Anreicherung der *Seed-Words* und die Durchführung der beiden computerlinguistischen Methoden werden semantische Funktionen benötigt. Die *Seed-Words* sollen einerseits um inhaltsgleiche Wörter erweitert werden. Andererseits basieren sowohl der lexikonbasierte als auch der maschinelle Lernansatz auf der Grundlage vektorieLL repräsentierter Terme. Dies kann unter dem Sammelbegriff externen Wissens subsummiert werden. Als externes Wissen wird hier vereinfacht jegliche Form der zusätzlichen Merkmalseingabe angesehen, mit deren Hilfe eine konzeptbasierte oder semantische Wissensaufbereitung innerhalb der Eingabedaten vorgenommen werden kann.

Harispe et al. (2013) unterteilen den Typ der Eingabedaten in drei Kategorien. Dies sind zum einen un- bzw. semistrukturierte Texte, zweitens strukturierte Wissensrepräsentationen und drittens logikbasierte Wissensbasen, wie die von Jimeno-Yepes, Jiménez-Ruiz, Berlanga Llavori & Rebholz-Schumann (2009) adaptierte Abbildung 19 dargestellt.

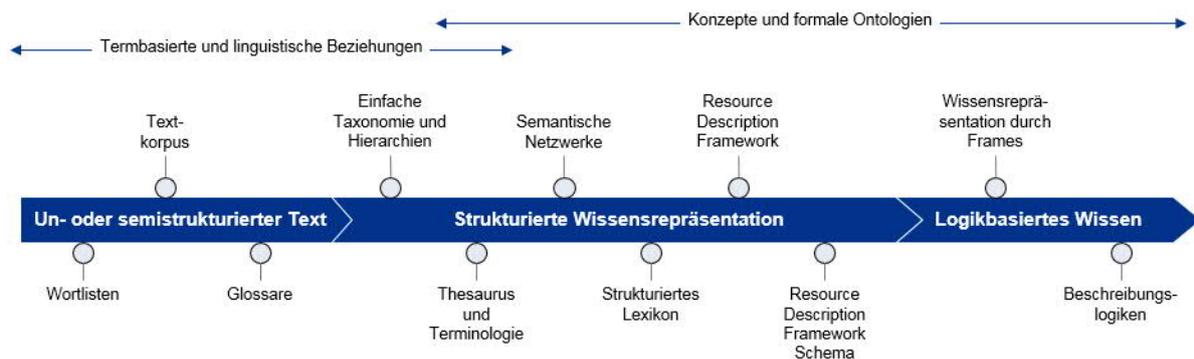


Abbildung 19: Semantische Wissensrepräsentation (nach Harispe et al., 2013)

Auszugweise werden hier einzelne Arten der Wissensrepräsentation herausgegriffen. Für eine vollumfängliche Betrachtung wird auf Harispe et al. (2013, 2015) verwiesen. Generell gilt, je weiter eine Wissensrepräsentation auf der rechten Seite verortet ist, desto einfacher und direkter ist sie für die maschinelle Verarbeitung nutzbar (Leibold, Krieger & Spies, 2010; beispielsweise Spies & Roche, 2008; Spies, 2010).

Für dieses Unterfangen sind auf der Eingabeseite insbesondere eine Wortliste und ein Textkorpus von Bedeutung. Das Textkorpus ist in diesem Fall eine unstrukturierte Dokumentensammlung aus Nachrichtenkommentaren und zusätzlichen Texten. Es kann als Quelle für Häufigkeiten, Kookkurrenzen oder Wortkontexte direkt genutzt werden. Andererseits lässt es sich durch eine weiterführende Aufarbeitung in eine Wissensrepräsentation überführen, mit deren Hilfe semantische Ähnlichkeiten näherungsweise bestimmt werden können.

Auf der Verarbeitungsseite werden semantische Netzwerke und einfach strukturierte Wissensrepräsentationen benötigt. Das soeben angesprochene semantische Netzwerk in Form von Vektorrepräsentationen der Terme ist die Verarbeitungsbasis der Sentimentanalyse. Um auf das gespeicherte Wissen der jeweiligen Wortvektoren zuzugreifen und daraus semantische Ähnlichkeiten zu errechnen, werden vektorielle Vergleiche benötigt, welche in Kapitel 7.2.1 näher erläutert wird. Die Komprimierung bzw. Aufbereitung des korpusimmanenten Wissens zu sinntragenden Wortvektoren wird in Kapitel 7.2.2 mittels unterschiedlicher Herangehensweisen diskutiert und für diesen Anwendungsfall abgewogen. Schließlich wird in Kapitel 7.2.3 auf bestehende Möglichkeiten der Erweiterung der *Seed-Words* eingegangen.

### 7.2.1 Vektorieller Vergleich zur Nutzung von Wissensrepräsentationen

Als Grundlage für einen Vergleich mit den nachfolgenden Modellen werden Texte in ein Vektorraummodell übersetzt. Die Vektoren stellen dabei durch ihre Komponenten Eigenschaften oder Muster dar (Spies, 1993). Die Methoden des vektoriellen Vergleichs können unabhängig davon genutzt werden, ob es sich dabei um Term-, Dokumentvektoren oder dimensionsreduzierte Wortvektoren handelt.

Formal gesprochen, werden bei einem direkten Vektorenvergleich zwei beliebige  $n$ -dimensionale Vektoren  $v_j \in \mathbb{R}^n$  und  $v_k \in \mathbb{R}^n$  einander gegenübergestellt. Mittels einer Bewertungsfunktion  $sim(v_j, v_k)$  werden die beiden Vektoren auf ihre Ähnlichkeit bzw. Distanz hin überprüft. Das Ergebnis der Funktion ist eine reelle Zahl, mit deren Hilfe man eine relative Aussage darüber machen kann, ob sich beispielsweise die beiden Vektoren  $v_1$  und  $v_2$  oder die beiden Vektoren  $v_1$  und  $v_3$  ähnlicher sind.

Vektorielle Vergleiche können anhand zahlreicher Methoden durchgeführt werden. Für eine tiefgreifende Betrachtung und weiterführende Vektorvergleiche wird auf Harispe et al. (2013, 2015), Dagan et al. (1994; 1999) sowie Mohammad und Hirst Mohammad & Hirst (2012) verwiesen. Darunter fallen mengenbasierte Ähnlichkeitsmaße, wie der Jaccard-Koeffizient oder der Dice-Koeffizient (Mohammad & Hirst, 2012), geometrische Ähnlichkeitsmaße, wie die Minkowsky-Distanzen oder die Kosinusähnlichkeit (Harispe et al., 2013), oder stochastische Ähnlichkeitsmaße, wie das Maß *Maximum-Likelihood-Estimate* (Manning et al., 2008), die Maße *Pointwise Mutual Information* (Bouma, 2009) bzw. *Positive Pointwise Mutual Information* (Niwa & Nitta, 1994) oder die Kullback-Leibler-Divergenz bzw. die Jensen-Shannon-Divergenz als symmetrische Versionen davon (Dagan et al., 1999; Harispe et al., 2013).

In dieser Arbeit wird ausschließlich die Kosinusähnlichkeit für den vektoriellen Vergleich herangezogen. Dabei werden die Winkelabstände zweier inhaltstragender Vektoren  $v_j$  und  $v_k$  auf dem Einheitskreis ermittelt. Das somit längennormalisierte Ähnlichkeitsmaß misst die Relation zwischen den Dimensionskoordinaten der Vektoren allein durch die Winkelfunktion (Manning et al. (2008). Je geringer ein Winkel ausfällt, desto ähnlicher sind sich zwei Vektoren. Die Kosinusähnlichkeit zwischen zwei Vektoren wird aus dem Skalarprodukt zweier Vektoren gebildet, welches durch das Produkt der Beträge der jeweiligen Vektoren dividiert wird. Algebraisch wird das Ähnlichkeitsmaß wie folgt ausgedrückt (Mohammad & Hirst, 2012; Spies, 1993):

$$sim_{\text{Kosinus}}(v_j, v_k) = \frac{v_j \cdot v_k}{|v_j| |v_k|} \quad (5)$$

Die Wertemenge der Kosinusähnlichkeit liegt im Intervall  $[-1, 1]$ . Die Vektoren sind orthogonal bzw. sich vollkommen unähnlich, sofern das Ergebnis der Gleichung 0 ist, identisch, sofern das Ergebnis 1 ist, und entgegengerichtet bei  $-1$ . Wird dieses Maß für Vergleiche herangezogen, die auf Häufigkeiten beruhen, dann können aufgrund der ausschließlich positiven Eingangsgrößen nur Werte im Intervall  $[0; 1]$  auftreten. Da die Dreiecksungleichung nicht erfüllt ist, kann bei Werten zwischen den Intervallgrenzen kein linearer Zusammenhang hergestellt werden. Folglich kann auch keine trennscharfe Aussage darüber getroffen werden, was die Differenz zwischen zwei Vektoren exakt bedeutet. Aufgrund dieses Umstandes müssen die Ergebnisse der Ähnlichkeitsmessung als skalenlose Werte betrachtet werden, aus denen eine Rangfolge der ähnlichen Vektoren abgelesen werden kann (Dittenbach, 2010).

## 7.2.2 Korpusbasierte Wissensrepräsentation

Der lexikonbasierte und der maschinelle Lernansatz der Emotionserkennung benötigen zur Verarbeitung eine vektorielle Repräsentation der Wörter. Grundsätzlich lassen sich für diesen speziellen Anwendungsfall alle Vektorabbildungen nutzen, mit denen sich eine semantische Ähnlichkeit annähern lässt. Anders als beim vektoriellen Vergleich aus dem vorangegangenen Kapitel soll hier keine Methode vorgegeben werden, sondern es findet eine Auswahl aufgrund einer theoretischen Auseinandersetzung und dem Abwägen der Vor- und Nachteile der jeweiligen Methoden statt.

### 7.2.2.1 Wissensrepräsentation mittels worthäufigkeitsbasierter Kookkurrenz

Bezogen auf eine worthäufigkeitsbasierter Kookkurrenz, wird in diesem Zusammenhang von Modellen der *First-Order-Co-Occurrence* gesprochen, also Ansätze, die nur tatsächliche Kookkurrenzen innerhalb der jeweiligen Dokumentgrenzen berücksichtigen (Harispe et al.,

2013, S. 37). Darunter fällt der direkte Termvergleich anhand der Worthäufigkeit in einem Dokument. Für eine Termgegenüberstellung können, je nach Abgrenzungsmerkmal, Vektoren aus der Dokument-Term-Matrix oder der Wort-Kontext-Matrix gezogen werden. Diese Vektoren beschreiben mit ihren Elementausprägungen, in welchen Dokumenten der jeweilige Term vorkommt, sei es als binäres Merkmal, als Häufigkeit oder als eine darauf beruhende Berechnung (Feinerer, 2017; Manning et al., 2008; Turney & Pantel, 2010).

Prinzipiell könnte man die Wortvektoren der Dokument-Term-Matrix für die angedachte Emotionsdetektion verwenden. Der Vorteil der einfachen Realisierbarkeit wiegt die zahlreichen Nachteile nicht auf. So haftet direkten Kookkurrenzmodellen unabhängig vom zugrunde liegenden Vektorenvergleich die mangelhafte Abbildung von Synonymie und Polysemie an (Huang, A., 2008; Manning et al., 2008). Darüber hinaus leidet dieses Verfahren deutlicher als die nachfolgenden Methoden unter der *Data-Sparsity* (Huang, F. & Yates, 2009). Und schließlich wird an diesen Methoden die Kritik geäußert, dass die direkten vektoriellen Vergleiche Schwierigkeiten haben, den Wortkontext zu greifen (Harispe et al., 2013).

In der Anwendung der Vektoren aus der Dokument-Term-Matrix kommt es, abhängig von der zugrunde liegenden Anzahl an Dokumenten, zu extrem großen vektoriellen Wortrepräsentationen. Neben der angesprochenen Ungenauigkeit würden subsequente Ansätze des maschinellen Lernens um ein Vielfaches langsamer werden, sofern die Vektoren, die so viele Ausprägungen haben, wie es Dokumente im Korpus gibt, als Eingabemerkmal verwendet werden. Die kurz angerissenen Nachteile sprechen deutlich gegen den Einsatz der direkten Kookkurrenz mittels Dokument-Term-Matrix.

#### **7.2.2.2 Wissensrepräsentation mittel prozessierter Dokument-Term-Matrix**

Um auf die korpusimmanente Informationen in aufbereiteter Weise zurückzugreifen, können auch Ansätze verwendet werden, die hier als Wissensrepräsentation prozessierter Dokument-Term-Matrizen definiert werden. In der Literatur findet man dazu auch Bezeichnungen wie Kookkurrenzmodelle höherer Ordnung (Harispe et al., 2013), da es sich um dokumentgrenzenübergreifende Kookkurrenzen handelt, bzw. zählbasierte Methoden, in Abgrenzung zu den vorhersagenden Methoden (Baroni, Dinu & Kruszewski, 2014). Mittels dieser Herangehensweise kann eine semantische Ähnlichkeit zwischen Termen hergestellt werden, auch wenn diese selten oder gar nicht im gleichen Dokument vorhanden, aber häufig im gleichen thematischen Kontext eingebettet sind. Über den Umweg der Vergleichbarkeit der benachbarten Wörter werden semantisch ähnliche Wortcluster gebildet. Es handelt sich dabei um die bereits oben erwähnte Dokument-Term-Matrix, die in einer informationskonservierenden Art komprimiert

wurde. Grundlage für diese Verfahren sind ebenfalls *Bag-of-Words*-Modelle und eine Textmatrix (Jurafsky & Martin, 2017, S. 78), in der Terme und Dokumente einander zugeordnet sind. Da alle nachfolgenden Varianten davon betroffen sind, sei an dieser Stelle angemerkt, dass mit einer prozessierten Dokument-Term-Matrix oft auch das Entfernen von Stoppwörtern und sehr frequenten Wörtern einhergeht. Während frequente Wörter eher hinderlich für diese Art der Modelle sind, gibt es auch Stimmen, die sich gegen eine exzessive Aufbereitung von Stoppwortlisten aussprechen (Schofield, Magnusson & Mimno, 2017).

Das Ergebnis der hier vorgestellten Algorithmen, bzw. der Auswahl einiger Vertreter davon, ist üblicherweise eine Zusammenfassung der Terme und der Dokumente in Form von Vektoren, anhand derer mit vektoriellen Vergleichen aus dem vorangegangenen Kapitel die Ähnlichkeit überprüft werden kann.

Im Folgenden werden drei Herangehensweisen der gleichen Stoßrichtungen kurz zusammengefasst und bezüglich der hier vorliegenden Aufgabe bewertet. Dabei wird grundsätzlich zwischen einer mathematisch-deterministischen und einer probabilistischen Ergebnisbestimmung differenziert. Die dritte Methode ist eine abgewandelte Form des ersten Modells.

#### 7.2.2.2.1 Deterministisch prozessierte Dokument-Term-Matrix

Das von Deerwester, Dumais, Furnas, Landauer & Harshman (1990) entwickelte Verfahren des *Latent Semantic Indexing* (LSI), das manchmal auch als *Latent Semantic Analysis* (LSA) bezeichnet wird, ist eine deterministisch prozessierte Dokument-Term-Matrix, die auf der Singulärwertzerlegung beruht (Mitesser, 2008). Im Folgenden soll dieses Verfahren kurz vorgestellt und hinsichtlich seiner Relevanz bewertet werden. Es handelt sich um ein *Soft-Clustering*-Verfahren, bei dem ein Term oder ein Dokument partiell allen Clustern zugeordnet wird (Manning et al., 2008).

Die LSI-Methode reduziert die Anzahl der Dimensionen im semantischen Raum. Die Grundlage dafür bildet eine  $m \times n$ -dimensionale Term-Dokument-Matrix  $\mathbf{X}$ , wobei  $m$  die Anzahl der Terme und  $n$  die Anzahl der Dokumente ist. Mittels einer Singulärwertzerlegung werden aus der Matrix  $\mathbf{X}$  thematische Cluster gebildet. Dabei wird die Matrix  $\mathbf{X}$  in die drei Matrizen  $\mathbf{T}$ ,  $\mathbf{S}$  und  $\mathbf{D}^T$  aufgeteilt. In der  $m \times m$ -dimensionalen Matrix  $\mathbf{T}$  werden die Eigenvektoren von  $\mathbf{X}^T \mathbf{X}$  vorgehalten und in der  $n \times n$ -dimensionalen Matrix  $\mathbf{D}^T$  respektive die Eigenvektoren von  $\mathbf{X} \mathbf{X}^T$ .  $\mathbf{S}$  ist die  $m \times n$ -dimensionale Diagonalmatrix mit den Singulärwerten von  $\mathbf{X}^T \mathbf{X}$ . Mittels des Parameters  $k \in \mathbb{N}^+$  kann die Anzahl der Dimensionen von  $\mathbf{S}$  reguliert werden. Bei diesem Ansatz werden ausschließlich die kleinsten Ausprägungen der Eigenwerte entfernt bzw. genullt, da die Dimensionsanzahl unverändert bleibt. Die Informationsdichte wird durch das

Ausmultiplizieren der Matrizen sozusagen erhöht. Dies wiederum bildet einen semantischen Raum ab, in dem sich thematisch ähnliche Konzepte nahe sind (weiterführend dazu Deerwester et al., 1990).

$$X = T \cdot S \cdot D^T. \quad (6)$$

Zieht man bei der Erstellung des LSI-Modells alle Dokumente heran, so erhält man abhängig vom Parameter  $k$  eine bestimmte Anzahl semantisch ähnlicher Konzepte. Neben der Vorgabe der Anzahl der thematischen Cluster kann auch ein Schwellenwert für das Beibehalten der Singulärwerte der Diagonalmatrix  $S$  festgelegt werden. Letzteres bedeutet, dass nur Werte unterhalb eines parametrisierten Schwellenwerts genullt werden, so dass sich die Anzahl der Themen aus dem zugrunde liegenden Korpus ergibt. Für ein optimiertes Ergebnis muss bei dieser Methode die beste Themenanzahl ermittelt werden (Manning et al., 2008).

In der Anwendung können sowohl Dokumente mit anderen Dokumenten aus dem Korpus als auch Terme untereinander verglichen werden (Deerwester et al., 1990). Die Autoren verwenden diesbezüglich die in Kapitel 7.2.1 beschriebene Kosinusähnlichkeit, bei der eine Rangfolge der ähnlichsten Dokumente oder Terme erstellt werden kann.

Deerwester et al. (1990) betonen als besonderen Vorteil, dass Synonymie und Polysemie mit ihrer Methode realisierbar sind. Zwei Synonyme können mittels Link über gemeinsame Kontextwörter und deren Kookkurrenzzuordnung über Dokumentgrenzen hinweg realisiert werden (Mirzal, 2013). Dies setzt jedoch eine ausreichend große Dokumentgröße voraus. Auch bei geringer Kookkurrenz zeigt dieses Modell in der Regel das erwartete Ergebnis (Papadimitriou, Raghavan, Tamaki & Vempala, 2000). Selbst Polysemie, also die Mehrfachbedeutung einer Schreibweise eines Terms, wird in der LSI bedingt berücksichtigt. Dies passiert insofern, als ein polysemantisches Wort in Abhängigkeit von der Bedeutungshäufigkeit des Terms im Korpus ein gewichtetes Mittel der beiden Bedeutungen darstellt (Rosario, 2000). Das Modell überzeugt durch seine mathematisch exakte Abbildung des dimensionsreduzierten semantischen Raums, unabhängig von der Wahl des Parameters für  $k$ , basierend auf dem zugrunde liegenden Korpus.

Dieses Modell hat jedoch auch gravierende Nachteile, so dass die Möglichkeit einer ziel führenden Verwendung als korpusbasierte Wissensbasis fraglich erscheint. Die gravierendste Beeinträchtigung dieses Modells ist die Komplexität. Der rechnerische Aufwand beim Ausmultiplizieren der dichtbesetzten Ergebnismatrix des LSI-Algorithmus ist ungemein hoch (Manning et al., 2008). Deerwester et al. (1990) geben als Komplexitätsgrad  $O((m + n)^2 \times k^3)$  für die Berechnung an, wobei mittlerweile schnelle und skalierbare Implementierungen

erreicht wurden (Bildosola, Martinez-Corral & Basterretxea, 2014; Řehůřek, 2011). Die Berechnungskomplexität, mit der die Anzahl der Terme  $m$  und die Anzahl der Dokumente  $n$  eingehen, wiegt umso schwerer, wenn man bedenkt, dass, anders als bei den direkten Vektorenvergleichen, feingranularere Eingangsdaten auf der Dokumentenseite eine vielfache Komplexitätssteigerung nach sich ziehen.

Als ebenso einschneidend wird der Speicherbedarf gewertet, da zwar die Eingangsmatrix dünn besetzt ist, die Ausgabematrizen aber dicht belegt sind (Rosario, 2000). Als leicht negativ wird außerdem gewertet, dass es für den LSI-Algorithmus wenige Erweiterungen oder Modifikationen gibt (exemplarisch dazu González, Muñoz & Martos, 2016; Hao, S., Xu, Peng, Su & Ke, 2014; Xu, Y., Ke & Su, 2017), da der Algorithmus auf den festdefinierten Verfahren der Singulärwertzerlegung und der Reduktion der Diagonalmatrix basiert und somit kaum Raum für wissenschaftlichen Fortschritt besteht. Die Einflussnahme auf diesen Algorithmus und dessen Ergebnis ist daher eingeschränkt. Mirzal (2013) stellt die Behauptung auf, dass, bezogen auf *Information-Retrieval*-Systeme, die positiven Ergebnisse eher von der Korpuszusammensetzung und den guten Vorverarbeitungsschritten herrühren als von dem LSI-Algorithmus selbst. Da der zugrunde liegende Korpus in diesem Fall jedoch sehr groß sein wird, fällt dies weniger ins Gewicht. Ein viel größerer Nachteil hingegen ist, dass neuhinzugefügte Dokumente und Terme nicht bewertet werden können. Die Methode „*even ignores any new terms [... added documents] contain*“ (Manning et al., 2008, S. 414). Um diese zu berücksichtigen, muss der aufwendige Erstellungsprozess erneut durchgeführt werden.

Trotz der besseren Wissensrepräsentation des Korpus durch den LSI-Algorithmus im Vergleich zu den direkten Vektorvergleichen stellen die Berechnungskomplexität und die fehlende Erweiterbarkeit des Modells um neue Dokumente ein großes Hindernis dar. Auch dass die dichtbesetzten Matrizen bei der Singulärwertzerlegung optimalerweise im Hauptspeicher vorgehalten werden sollten, um eine performante Berechnung zu gewährleisten, spricht bei der zugrunde liegenden Korpusgröße gegen das Modell.

#### 7.2.2.2.2 Probabilistisch prozessierte Dokument-Term-Matrix

Neben der deterministischen Variante der prozessierten Dokument-Term-Matrizen existieren auch zahlreiche probabilistische Verfahren. Dazu zählen unter anderem das *Probabilistic Latent Semantic Indexing* (PLSI) von Hofmann (1999a, 1999b), die *Non-Negative Matrix-Factorization* (NMF) von Lee (1999, 2001), der kombinierte Ansatz der beiden Methoden PLSI und NMF von Ding, Li & Peng (2008), das Gamma-Poisson-Faktorenmodell (GaP) von Canny (2004) oder auch die Latente Dirichlet-Allokation (LDA) von Blei, Ng & Jordan (2003).

Zwischen den Modellen gibt es einige Parallelen, beispielsweise greifen das PLSI- und das NMF-Verfahren ausgehend von den gleichen Ausgangsbedingungen auf unterschiedliche Optimierungsfunktionen zurück (Ding et al., 2008; Gaussier & Goutte, 2005).

Um den Rahmen an dieser Stelle nicht zu sprengen, wird nur kurz auf eines der gelisteten Modelle eingegangen, das aus wissenschaftlicher Sicht vermutlich den größten Nachhall hat. Dabei handelt es sich um das *Topic-Modeling*-Verfahren, in das die LDA einzuordnen ist (Blei et al., 2003; Blei & Lafferty, 2006; 2008; Blei, 2012; Spies & Jungemann-Dorner, 2013). Für einen detaillierten Vergleich zwischen PLSI und LDA wird auf Zhai (2009) verwiesen. *Topic Modeling* ist eine rechnergestützte Methode, um große Mengen an Daten anhand datenspezifischer Eigenschaften zu strukturieren bzw. ein verborgenes Ordnungsschema aufzudecken. Die LDA in Reinform ist einer der einfachsten Vertreter der *Topic Models*, bei denen unter Zuhilfenahme statistischer Modelle abstrakte Themen in einer Sammlung von textuellen Dokumenten voneinander abgegrenzt werden (Blei, 2012). Ein Großteil der LDA-Modelle basiert auf einem generativen Wahrscheinlichkeitsmodell (beispielsweise Griffiths, Thomas & Mark, 2004; Rosen-Zvi, Griffiths, Steyvers & Smyth, 2004; Steyvers, Smyth, Rosen-Zvi & Griffiths, 2004), jedoch gibt es mit der Logic LDA auch einen Vertreter der diskriminativen Modelle (Andrzejewski, Zhu & Craven, 2009; Andrzejewski, Zhu, Craven & Recht, 2011).

Formalisiert wird das LDA-Grundmodell von Blei et al. (2003) oder auch Griffiths et al. (2004) nach folgender Definition: Ein Wort  $w$  entspricht einem Token bzw. einem bestimmten Wortvorkommnis. Es bildet in textbasierten LDA-Modellen die elementarste Einheit und die einzige beobachtete Variable. Jedem Token  $w$  kann ein Term  $v$  zugeordnet werden. Während ein Token  $w$  für das Vorhandensein eines bestimmten Wortes in einem Dokument steht, gibt ein Term  $v$  an, dass dieses spezifische Wort mindestens einmal im Korpus enthalten ist (Manning et al., 2009). Die Menge aller Terme ergibt das indexierte Vokabular  $V = \{v_1, v_2, \dots, v_{|V|}\}$ , dessen gültiger Bereich sich jedoch nur auf diejenigen Wörter beschränkt, die im Trainingskorpus vorhanden waren. Ein Dokument  $d$ , das abhängig vom Modell auch ein Satz, ein Paragraph oder ein anderes Textkonglomerat sein kann, ist eine Sequenz von Wörtern  $W_d$  mit der Länge  $N$ , wobei  $n$  der Position des jeweiligen Tokens  $w$  im Dokument  $d$  entspricht. Somit ist ein Dokument definiert als  $d = \{w_1, w_2, \dots, w_N\}$ . Schließlich gibt es noch die Ansammlung aller Dokumente, die dem Korpus  $D = \{d_1, d_2, \dots, d_{|D|}\}$  entspricht. Dieser begrenzt den Raum, der dem generativen Wahrscheinlichkeitsmodell maximal bekannt ist, da sich daraus die Termliste  $V$  zusammensetzt und das Modell an der Summe der abgegrenzten Dokumente  $d$  mit deren jeweiligen Token  $W_d$  trainiert wird (Blei et al., 2003).

Die Themen  $T$  werden hier zusätzlich zur Verdeutlichung und referenzierend auf das Modell von Steyvers und Griffiths (2004) angegeben. Ein Thema  $t$  ist ein abstraktes Konzept, das in einem generativen Prozess konstruiert wird. Einem spezifischen Thema  $t$  können gleichzeitig sowohl die Wörter  $v$  des Vokabulars  $V$  als auch die Dokumente  $d$  des Korpus  $D$  zu einem gewissen Wahrscheinlichkeitsgrad zugeordnet werden. Es kann somit als Bindeglied betrachtet werden, das sich mit einer probabilistischen Verteilung auf der Dokumentenebene sowie auf der Termebene wiederfindet. Es wird aus der iterativen Ermittlung der Termverteilung und den damit verbundenen wortspezifischen Themen  $z$  innerhalb der Dokumente generiert. Da die LDA-Analyse ein Softclusteringverfahren darstellt, sind die Grenzen fließend und ein Wort kann anteilig mehreren Themen angehören. Die Anzahl der modellimmanenten Themen  $T$  wird als Parameter in das generierte LDA-Modell eingegeben.

Bei dem generativen Wahrscheinlichkeitsmodell der LDA werden sowohl über die beobachteten als auch über die verborgenen Variablen Wahrscheinlichkeitsverteilungen gelegt (Klinger & Tomanek, 2007). Dabei kommt eine Analyse eines verschachtelten Bayes'schen Modells mit drei Ebenen zum Einsatz, das die Themen auf Korpus- und Dokumentenebene sowie auf Wortebene behandelt (Gelman, 2004). Die darauf basierenden Wahrscheinlichkeiten gehen in ein gemeinsames Wahrscheinlichkeitsmodell ein und bilden somit das LDA-Konstrukt, das durch die folgende Gleichung für das Grundmodell beschrieben wird (Andrzejewski et al., 2011; Blei et al., 2003):

$$p(w, z, \phi, \theta | \alpha, \beta) \propto \prod_{t=1}^T p(\phi_t | \beta) \prod_{d=1}^D p(\theta_d | \alpha) \prod_{n=1}^{N_d} p(z_n | \theta) p(w_{d,n} | z_{d,n}, \phi_t), \quad (7)$$

wobei  $\phi_t$  die Termverteilung für das Thema  $t$ ,  $\theta_d$  die Themenverteilung für das Dokument  $d$  und  $z_{n,d}$  das dokumentspezifische Thema für das  $n$ -te Wortvorkommen der Sequenz  $N_d$  im Dokument  $d$  ist. Als Modelleingabe existieren  $\alpha$ , der trainierbare Dirichlet-Hyperparameter der Themenverteilung pro Dokument, und  $\beta$ , der trainierbare Dirichlet-Parameter der Term- bzw. Wortverteilung pro Thema. Diese Gleichung des generativen Modells kann wie folgt verbalisiert werden: Im ersten Teilabschnitt der Funktion wird auf der Korpusebene für jedes Thema entschieden, welche Worte wahrscheinlich sind. Anschließend wird für jedes Dokument entschieden, welche Ansammlung von Themen in einem Dokument wahrscheinlich ist. Und schließlich wird für jedes Wort im zugehörigen Dokument entschieden, zu welchem Thema es zugehörig ist, unter der Bedingung eines im Dokument gegebenen Themas.

Durch die Bayes'sche Inferenzstatistik in der LDA wird der semantische Raum auf der Basis von bedingten Wahrscheinlichkeiten aufgespannt. Die Berechnung der bedingten

Wahrscheinlichkeitsverteilung der verborgenen Variablen unter den gegebenen Daten ist auch als *Posterior Distribution* oder A-posteriori-Wahrscheinlichkeitsverteilung bekannt (Blei, 2012, S. 80). Ein Teil der Ergebnisermittlung im Bayes'schen Ansatz ist die Berechnung der Summe über alle möglichen Fälle der Zufallsgrößen einer sogenannten Randwahrscheinlichkeitsverteilung, so dass die Summe über alle Einzel-a-posteriori-Wahrscheinlichkeiten unter den gegebenen Daten exakt 1 ergibt. Das theoretische Aufsummieren aller möglichen Kombinationen der Themenzuordnungen ist für diese Wahrscheinlichkeit in der Praxis jedoch rechnerisch schwer zu realisieren, da die Anzahl der potentiellen Themenstrukturen mit der Datenmenge, die in das Modell gegeben wird, exponentiell zunimmt (Ponweiser, 2012).

Da die Menge der berechneten Themen schwer zu bewältigen ist, muss die A-posteriori-Wahrscheinlichkeit approximiert werden. Blei (2012) unterscheidet bei den Annäherungen der marginalen Wahrscheinlichkeit oder der Randwahrscheinlichkeit zwischen der Kategorie der stichprobepbasierten Algorithmen und jener der Variationsalgorithmen. Bei Näherungsalgorithmen mittels *Sampling* werden Stichproben nach einer festgelegten Reihenfolge oder Verfahrensweise gesammelt. Dadurch wird eine Reduktion der zu verarbeitenden Datenmenge erzielt. Mit dieser sehr viel geringeren Teilmenge der Daten wird die tatsächliche durch eine empirische Verteilung approximiert. Durch die Annäherung der Daten und damit die Reduktion der Verarbeitungsschritte im LDA-Prozess wird für die Senkung der Rechenoperationen auf ein durchführbares Maß ein geringer Genauigkeitsverlust in Kauf genommen (vgl. Blei, 2012). Meist ist bei LDA-Analysen das Gibbs-Sampling vorzufinden, wobei dieses einen Spezialfall der Monte-Carlo-Markowkette (eng. MCMC) darstellt (Geman & Geman, 1984; Steyvers & Griffiths, 2007).

Die Variationsalgorithmen hingegen, so Blei (2012), stellen die deterministische Alternative dazu dar. Für die LDA-Methode wird diese Alternative verwendet, um eine Annäherung der A-posteriori-Wahrscheinlichkeit einer verborgenen Variable für die inferenzstatistische Analyse bereitzustellen. Bei Variationsmethoden wird eine parametrisierte Gruppe von Verteilungen über die verborgene Struktur des Modells gelegt. Anschließend wird aus dieser Reihe von Verteilungen genau jene ausgewählt, die der A-posteriori-Wahrscheinlichkeit am nächsten ist und ihr somit am besten entspricht. Das Inferenzproblem wird somit in ein Optimierungsproblem umgewandelt, was eine Verbesserung der Modellierung durch Optimierungsverfahren ermöglicht. Variationsmethoden stellen in der Bayes'schen Statistik eine Form der Erwartungswertmaximierung der A-posteriori-Wahrscheinlichkeit dar, wobei der wahrscheinlichste Wert in einer Schätzung sowohl für die beobachteten als auch für die verborgenen Variablen simultan ermittelt wird (ausführlich dazu Blei, 2012).

Bei der Abwägung der Vor- und Nachteile dieses Modells lassen sich viele Parallelen zur LSI-Analyse ziehen, weswegen hier hauptsächlich auf die Unterschiede eingegangen wird. Der vermutlich größte Vorteil gegenüber der Singulärwertzerlegung ist die Vielfältigkeit und Anpassbarkeit des hier vorgestellten Ansatzes. Durch den flexiblen Modellaufbau der LDA sind viele Erweiterungen und Modifikationen möglich. Andrzejewski (2010) gliederte die Modellvariationen in LDA+X-Ansätze sowie Modifikationen der  $\phi$ -Seite bzw. der  $\theta$ -Seite (S. 26 f., 29). Bei Varianten der LDA+X wird die Analyse durch zusätzliche Ziel- oder Eingabedaten angereichert. Modelle mit geänderter  $\phi$ -Seite betreffen Modifikation des „*word generating aspect of LDA in order to capture richer linguistic structure or side information*“ (Andrzejewski, 2010, S. 27). Schließlich gibt es noch die abgeänderte  $\theta$ -Seite, die das Ziel hat, eine „*richer representations of the document-topic associations*“ zu realisieren. Als kleiner Pluspunkt ist zu werten, dass sich bereits unterschiedliche Ansätze des *Topic-Modeling* in der Sentimentanalyse wiederfinden, wie beispielsweise verschiedene Formen der Latenten Dirichlet-Allokation (Li, F., Huang & Zhu, 2010; Liang, Liu, Jianlong & Bai, 2014; Titov & McDonald, 2008; Zhang, Y., Ji, Su & Wu, 2013) oder der *Probabilistic Latent Semantic Analysis* (Lu, Y. & Zhai, 2008; Moghaddam & Ester, 2011).

Die eingangs in diesem Kapitel gelisteten probabilistischen Verfahren der prozessierten Dokument-Term-Matrix sind vergleichbar, was die Punkt-Symmetrie sowie die Polysemie betrifft. Auch bei diesen Ansätzen ist eine Ähnlichkeitsbestimmung zwischen den Termen und zwischen den Dokumenten direkt über einen Vektorvergleich möglich. Ähnlich wie bei der LSI-Analyse gilt es für die LDA-Analyse, die richtige Anzahl an Themen zu finden. Als vorteilhaft kann hier genannt werden, dass es ein Verfahren gibt, das ohne diese Parameterfindung auskommt. Mit dem *Hierarchical Topic-Modeling* wird mittels des chinesischen Restaurant-Prozesses keine im Vorfeld definierte Anzahl an Themen benötigt (Blei, Griffiths, Jordan & Tenenbaum, 2004; Spies & Jungemann-Dorner, 2013).

Ähnlich wie die LSI-Analyse benötigen die probabilistischen Versionen eine substantielle Menge an Text, um die Kookkurrenzen über Dokumentgrenzen hinweg mittels Themenzugehörigkeit aufzulösen. Dies ist zum einen ein Vorteil gegenüber dem direkten Vektorenvergleich, darüber hinaus konnte Spies (2017) zeigen, dass auch mit kleinen Korpora verwendbare Ergebnisse erzielt werden können, was ebenfalls als Vorteil gewertet werden kann. Die LDA-Analyse kommt mit kurzen Texten nur bedingt zurecht (Yan, Guo, Lan & Cheng, 2013). Allerdings berichten beispielsweise Jo & Oh (2011) von guten Ergebnissen bei einer feingranularen Betrachtungsweise auf Satzebene anstelle der üblichen Dokumentebene. Der maschinelle

Aufwand zum Trainieren des Modells für diese Teilaufgabe stellt einen Nachteil dar. Blei (2008) verortet die Berechnungskomplexität des LDA-Algorithmus mit  $O(D \times T \times V)$ , also dem Produkt aus Dokument- und Themenanzahl sowie der Vokabulargröße, im kubischen Raum. Es damit schneller als der originale LSI-Ansatz, bleibt jedoch rechenintensiv. Eine Betrachtung auf Satzebene würde das Modell um ein Vielfaches langsamer machen, weswegen sich auch hier eine gröbere Betrachtung anbietet. Auch eine hohe Anzahl an Themen und damit unterscheidbaren Dimensionen für weiterführende Operationen würde zu einer Verlangsamung führen. Der Rechenaufwand der LDA ist im Vergleich mit den performanteren *Word-Embeddings* deutlich höher (Mikolov, Chen, Corrado & Dean, 2013a).

### 7.2.2.3 Word-Embeddings

In dem Forschungszweig der natürlichen Sprachverarbeitung haben *Word-Embeddings* eine große Bekanntheit. Es handelt sich dabei um Vektorraummodelle, die auf Rumelhart, Hinton & Williams (1986) und Bengio, Ducharme, Vincent & Janvin (2003) zurückzuführen sind. Erst mit einiger Verspätung und vermutlich auch wegen der Beiträge von Collobert & Weston (2008) und Collobert et al. (2011) rückten diese Modelle in den wissenschaftlichen Fokus.

Das ursprüngliche *Word-Embeddings*-Modell von Bengio et al. (2003, S. 1142) basierte auf einem Feedforward-Netzwerk mit einem *Shared-Word-Features-Layer*, einem *Ordinary-Hyperbolic-Tangent-Hidden-Layer* und einem dem *Softmax-Output-Layer*. Der *Shared-Word-Features-Layer* entspricht dabei der *Word-Embeddings*-Schicht. In der *Word-Embeddings*-Schicht werden die *Word-Embeddings* durch eine Multiplikation des Indexvektors eines Worts mit der *Word-Embeddings*-Matrix generiert. In der versteckten Schicht werden die Zwischenrepräsentation der Eingabe erzeugen. Aufgabe des *Softmax-Output-Layers* ist es hingegen Wahrscheinlichkeitsverteilungen aus den Ergebnissen der versteckten Schicht zu erstellen (Bengio et al., 2003; Collobert et al., 2011). Diese Konstellation bildet die Blaupause für nachfolgende neuronale Netze dieser Art.

Auch wenn die Grundfunktion der drei Ebenen bei darauf aufbauenden Forschungsarbeiten prinzipiell gleichbleibt, so sind sie doch das Ziel modularer Anpassungen. In der Ebene der *Word-Embeddings* können unterschiedliche Wahrscheinlichkeitsfunktionen hinterlegt werden, um dieses Verfahren zu schärfen (Mikolov, Sutskever, Chen, Corrado & Dean, 2013b; z.B. Mikolov et al., 2013a; Pennington, Socher & Manning, 2014). Auch die versteckte Ebene wird in neueren Studien beispielsweise durch ein *Long-Short-Term-Memory* (LSTM)-Netzwerk ersetzt (Bojanowski, Grave, Joulin & Mikolov, 2016; Kim, Y., Jernite, Sontag & Rush, 2015; Yaghoobzadeh & Schütze, 2017). Ebenso können anstelle der ursprünglichen SoftMax-

Berechnung andere Verfahren wie das hierarchische SoftMax, die *Noise-Contrastive Estimation*, die *Infrequent Normalization* oder das *Differentiated SoftMax*-Verfahren verwendet werden (weiterführend dazu Chen, W., Grangier & Auli, 2015; Mikolov et al., 2013b; Rong, 2014).

Das neuronale Netz wird anhand eines Textkorpus trainiert, das auf einer Sequenz  $T$  von Wörtern  $w_1, w_2, \dots, w_T$  basiert. Alle Terme  $v$  des Trainingskorpus ergeben das Vokabular  $V$  mit der Mächtigkeit  $|V|$ . Anders als bei den bisherigen Vektorraummodellen, wie der LSI oder der LDA, liegt hier kein *Bag-of-Words*-Ansatz pro Dokument oder Satz zugrunde, sondern ein Kontext von  $n$  Wörtern (Bengio et al., 2003). Dieser Kontext bildet ein sogenanntes Wortfenster, das üblicherweise, ausgehend von dem betrachteten Wort, sowohl rückblickend als auch vorausschauend ist. Ein Fenster mit der Größe  $n = 2$  berücksichtigt beispielsweise neben dem Wort  $w_t$  die vorangegangenen Wörter  $w_{t-1}$  und  $w_{t-2}$  sowie die darauffolgenden Wörter  $w_{t+1}$  und  $w_{t+2}$  als Modelleingabedatum. Während bei der LSI und den probabilistischen Vertretern wie der LDA die Kookkurrenz in Verbindung mit der Dokumentgrenze entscheidend war, schlagen die *Word-Embeddings*-Modelle eine ganz andere Richtung ein. Hier wird das Wort anhand der umgebenden Wörter und jeder Term anhand der im Fenster befindlichen Wörter beschrieben (Altszyler, Sigman & Slezak, 2016). Eine dokumentinterne Kookkurrenz bleibt somit unberücksichtigt, sofern die Distanz zwischen zwei Token größer als die Fenstergröße ist.

Um dies zu erreichen, wird für jeden Term  $v$  des Vokabulars  $V$  ein *Distributed-Feature-Vector* mittels der Wahrscheinlichkeitsfunktion erstellt. Die zugrunde liegende Wahrscheinlichkeitsfunktion der Ergebnisschicht ist dabei abhängig vom Verfahren (weiterführend dazu Chen, W. et al., 2015). Jeder *Distributed-Feature-Vector*  $d_v \in \mathbb{R}^m$  wird in einer  $|V| \times m$ -dimensionalen Nachschlagematrix  $\mathbf{C}$  vorgehalten, wobei  $m$  die parametrisierte Anzahl der Dimensionen darstellt, auf die das Modell die Eingangsdaten reduziert (Bengio et al., 2003, S. 1141). Mittels der Zuordnungsfunktion  $\mathcal{C}(v)$  kann wieder auf den *Distributed-Feature-Vector*  $c_v$  zurückgegriffen werden. Die Nachschlagematrix wird im Training des neuronalen Netzes benötigt, um in Abhängigkeit der Fenstergröße  $h$  aus einer Sequenz von Wörtern  $w_{t-n}, \dots, w_{t-1}, w_{t+1}, \dots, w_{t+n}$  einen gleichbleibende Eingabesequenz für das neuronale Netz zu bilden, der sich aus den konkatenierten Vektoren  $d_{t-n}, \dots, d_{t-1}, d_{t+1}, \dots, d_{t+n}$  zusammensetzt (Collobert & Weston, 2008). Dieser Eingabevektor wird beispielsweise verwendet um ein Wort  $w_t$  bzw. den repräsentativen *Distributed-Feature-Vector*  $d_t$  im Sinnes eines *Language*

*Model* zu bestimmen (Mikolov et al., 2013a). Letzteres variiert jedoch abhängig vom zugrundeliegenden Verfahren, wie im nachfolgenden Kapitel erläutert wird.

Die gemeinsamen Komponenten der *Word-Embeddings* beinhalten eine Zielfunktion und Parameter, die hier kurz eingeleitet und in den nachfolgenden Kapiteln aufgrund der unterschiedlichen Ausprägung detaillierter erläutert werden. Die *Word-Embeddings*-Modelle werden anhand einer Zielfunktion  $J(\theta)$  optimiert, wobei das Optimierungsziel  $\min_{\theta} J(\theta)$  ist und alle Modellparameter zu  $\theta = (\mathbf{C}, \omega)$  zusammengefasst werden.  $\mathbf{C}$  stellt dabei die oben erwähnte Nachschlagematrix dar und  $\omega$  die Parameter des neuronalen Netzwerkes (Bengio et al., 2003), die sich in Abhängigkeit der noch folgenden Implementierungsvarianten unterscheiden. Die zusammengefassten Parameter  $\omega$  sind der Vergleichbarkeit wegen generisch gehalten und werden in den nachfolgenden Kapiteln 7.2.2.3.1 und 7.2.2.3.2 modelspezifisch näher erläutert.

In der Zielfunktion  $J(\theta)$  kann auch eine Regularisierung  $R(\theta)$  addiert werden, beispielsweise die L1- oder die L2-Regulierung (Chen, S. F. & Rosenfeld, 2000), die auf der L1-Norm bzw. der L2-Norm beruhen, oder die WeaknormSQ-Regulierung (Andreas & Klein, 2015; Chen, W. et al., 2015). Der Regularisierung soll ein Überanpassen des Neuronalen Netzwerkes an die eingegeben Trainingsdaten verhindern und eine Generalisierung erreichen (McCaffrey, 2015).

Im Folgenden werden gängige Versionen der *Word-Embeddings* kurz vorgestellt. Im Fokus stehen dabei mit Word2Vec und GloVe die wohl am häufigsten verwendeten Vertreter dieser neuronalen Netze. Der Vollständigkeit halber seien zudem weitere Vertreter wie CW (Collobert & Weston, 2008), *Dependency-Based Word-Embeddings* (Levy & Goldberg, 2014a) *Meta-Embeddings* (Yin & Schütze, 2015), LexVec (Salle, Idiart & Villavicencio, 2016), fast-Text (Joulin, Grave, Bojanowski & Mikolov, 2016) oder der hybride Ansatz lda2vec (Moody, 2016) erwähnt. Die in diesem Kapitel vorgestellte Definition der Parameter wird dabei aufgegriffen und fortgeführt.

#### 7.2.2.3.1 Word2Vec

Word2Vec ist das bekannteste *Word-Embeddings*-Modell. Die aus der Feder von Mikolov et al. (2013a, S. 4) stammende Lösung basiert zusammen mit dem *Continuous-Bag-of-Words* (CBOW)- und dem *Continuous-Skip-gram* (SG)-Modell auf zwei unterschiedlichen Ansätzen desselben Grundgerüsts.

Beim CBOW-Ansatz wird ein Wort  $w_t$  durch die Wörter im Kontext  $c = w_{t-n}, \dots, w_{t-1}, w_{t+1}, \dots, w_{t+n}$  beschrieben bzw. zu bestimmen versucht. Dabei ist es nicht entscheidend, an welcher Stelle der Fenstergröße  $n$  sich ein beschreibendes Wort befindet. Das

CBOW-Modell optimiert in Abhängigkeit von den Modellparametern  $\theta$  folgende Zielfunktion (Le & Mikolov, 2014):

$$J(\theta) = \frac{1}{T} \sum_{t=n}^{T-n} \log p(w_t | c, \theta). \quad (8)$$

Bei den SG-Modellen geht man genau entgegengesetzt zum CBOW vor. Hier wird mit Hilfe des zentralen Worts im Fenster  $w_t$  versucht, die umliegenden Wörter  $w_{t-n}, \dots, w_{t-1}, w_{t+1}, \dots, w_{t+n}$  zu bestimmen (Mikolov et al., 2013a). Die Optimierungsziel-funktion lautet somit (Goldberg & Levy, 2014):

$$J(\theta) = \frac{1}{T} \sum_{t=n}^{T-n} \sum_{\substack{j=-n, \\ j \neq 0}}^n \log p(w_{t+j} | w_t, \theta). \quad (9)$$

Die aktuelle Popularität von *Word-Embeddings* liegt sicherlich auch darin begründet, dass sie unter einem vertretbaren Rechenaufwand erstellbar sind. Sie können aus einem ausreichend großen Korpus errechnet werden. Für das CBOW-Modell wird pro Operation aus dem Trainingskorpus eine Berechnungskomplexität von  $O(N \times E + E \times \log_2(|V|))$  und für die SG-Modelle von  $O(h \times (E + E \times \log_2(|V|)))$  angegeben, wobei  $N$  die Größe der gleichzeitig in das Modell eingegebenen Wörter,  $E$  die Größe der Wortrepräsentationen,  $V$  die Anzahl der Terme im Vokabular und  $h$  die Größe der Wortfenstersequenz ist (Mikolov et al., 2013a). Mit der akzeptablen Rechenzeit geht analog zu den vorhergehenden Methoden eine domänenspezifische Ausrichtung einher, die anhand der Auswahl der Dokumente im Korpus leicht getroffen werden kann. Darüber hinaus müssen nicht wie bei den *Bag-of-Words*-Ansätzen Stoppwörter oder frequente Wörter aus dem Korpus entfernt werden. Diese wirken sich im Gegenteil sogar positiv auf die Berechnung der Vektorrepräsentationen aus (Mikolov et al., 2013b). Im Vergleich zu den vorangegangenen Methoden werden kleinere Wortfenster anstelle ganzer Dokumente betrachtet. Die Herangehensweise unterscheidet sich insofern, als wortfensterweise über das Dokument gegangen wird. Auf Wortfensterebene findet ein Generierungsprozess im Sinne eines *Language-Model* statt, bei dem Sprache basierend auf Wahrscheinlichkeiten erzeugt wird (Manning & Schütze, 2005, S. 71).

Stellt man die beiden Word2Vec-Modelle einander gegenüber, so schneidet das SG-Modell im Vergleich mit dem CBOW-Modell marginal besser ab (Goldberg & Levy, 2014). Baroni et al. (2014) merken an, dass das letztgenannte Modell zudem besser abschneidet als die Verfahren der prozessierten Dokument-Term-Matrix aus Kapitel 7.2.2.2, was jedoch optimierte Parameter voraussetzt (Levy, Goldberg & Dagan, 2015).

Als Nachteil sei hervorgehoben, dass dieses Verfahren bei geringen Textmengen geringfügig schlechter abschneidet als die LSI-Methode (Altszyler et al., 2016). Antoniak & Mimno (2018, S. 118) heben die Sensibilität, bezogen auf die Korpuszusammenstellung, hervor und resümieren, dass „[t]he size of the corpus, the length of individual documents, and the presence or absence of specific documents can all affect the resulting embeddings“. Dokumente können nicht mehr wie bei der LSI- und der LDA-Methode direkt bewertet werden, sondern müssen beispielsweise über dem Umweg der Termaggregation ermittelt werden (Le & Mikolov, 2014; Řehůřek & Sojka, 2010). Im Vergleich zum direkten Wortvektorenvergleich aus Kapitel 7.2.1, bei dem kein Training existiert, bedarf eine Erweiterung des Vokabulars oder die Berücksichtigung neuer Dokumente einer Neuberechnung des Trainingsmodells. Unbekannte Wörter bzw. Terme, die als *Out-of-Vocabulary* (OOV) gekennzeichnet sind (Chu & Kurohashi, 2016, S. 644), stellen ähnlich wie bei Wissensrepräsentationen mittels einer prozessierten Dokument-Term-Matrix ein Problem dar, da mit diesen nicht zielführend umgegangen werden kann. Sprachen mit einer morphologischen Vielfalt stellen das Modell vor eine Herausforderung, weswegen ebenfalls ein Trend in die Richtung der *Character-Embeddings* (Dos Santos & Zadrozny, 2014, S. 1819), also eine Wissensrepräsentation auf Basis von Buchstabenfolgen, erkennbar ist (exemplarisch dazu Kann & Schütze, 2017; Kim, Y. et al., 2015; Yaghoobzadeh & Schütze, 2017).

#### 7.2.2.3.2 GloVe

Die Idee hinter GloVe oder „*Global Vectors for Word Representations*“ besteht darin, die kookkurrenzbasierte Welt im Sinne der LSI und die wortkontextbasierte Welt zu vereinen (Pennington et al., 2014, S. 1532). Um dies zu realisieren, wird zusätzlich der kookkurrenzbasierte Wert  $X_{ij}$  in das Modell gegeben. Dieser gibt an wie oft das Wort  $w_i$  im Kontext von  $w_j$  auftaucht. Im Modell selbst wird über diesen Wert eine Gewichtungsfunktion  $f(X_{ij})$  gelegt. Dadurch werden besonders häufige Kookkurrenzen auf einen maximalen Wert begrenzt und somit eine Verzerrung der Zielfunktion verhindert. Die Gewichtungsfunktion wird angegeben als (Pennington et al., 2014):

$$f(X_{ij}) = \begin{cases} \left(\frac{X_{ij}}{x_{\max}}\right)^\alpha & \text{wenn } X_{ij} < x_{\max}, \\ 1 & \text{andernfalls,} \end{cases} \quad (10)$$

wobei die Autoren für den Exponenten  $\alpha = \frac{3}{4}$  und den Divisor  $x_{\max} = 100$  als Richtwerte angeben. Die Zielfunktion, die in diesem Modell optimiert werden soll, lautet (Pennington et al., 2014):

$$J(\theta) = \sum_{i,j=1}^{|V|} f(X_{ij})(w_i^T \cdot \tilde{w}_j + b_i + \tilde{b}_j - \log X_{ij})^2, \quad (11)$$

wobei  $w$  die Wortvektoren,  $\tilde{w}$  die Kontextwortvektoren und  $b$  respektive  $\tilde{b}$  die Verzerrungen (*Bias*) der Wortvektoren bzw. Kontextwortvektoren darstellen (Pennington et al., 2014, S. 1535). Abschließend finden die logarithmierten Häufigkeiten als Gegenpool zur Kontextbetrachtung Eingang in das Modell. Zusammen mit der Gewichtungsfunktion steht dies für die Kookkurrenzkomponente des Modells. Wie schon bei dem Word2Vec-Modell fasst  $\theta$  alle Modellparameter zusammen.

Die Vorteile dieses Verfahrens schließen sich in großen Teilen den Vorteilen der Word2Vec-Vorgehensweise an. Daher wird hier insbesondere auf modellspezifische Aspekte und Unterschiede eingegangen. Ähnlich wie bei den probabilistischen Ansätzen der prozessierten Dokument-Term-Matrix oder dem Word2Vec-Verfahren können auch hier Modell Anpassungen vorgenommen werden, was als positiv gewertet wird. Beispielsweise kann der kookkurrenzbasierte Wert  $X_{ij}$  durch andere Kookkurrenz- oder Ähnlichkeitsmaße ersetzt werden, die beispielsweise in Kapitel 7.2.1 gelistet wurden (weiterführend dazu auch Rohde, Gonnerman & Plaut, 2006). Das Modell profitiert von der Vereinigung der kookkurrenzbasierten und der kontextbasierten Aspekte. Pennington et al. (2014) führen mehrere Tests an, in denen GloVe durchweg besser abschnitt als die LSI-, SG- und CBOW-Modelle. Außerdem soll dieses Modell mit einer geringen Korpusgröße besonders gut zurechtkommen. Die Autoren des Modells kommen zu dem Schluss, dass *„for the same corpus, vocabulary, window size, and training time, GloVe consistently outperforms word2vec. It achieves better results faster, and also obtains the best results irrespective of speed“* (Pennington et al., 2014, S. 1541).

Neben dem Umstand, dass dieser Ansatz, verglichen mit dem Word2Vec-Verfahren, deutlich seltener verwendet wird, können die bereits genannten Nachteile des Word2Vec-Verfahrens angebracht werden. Dies sind der fehlende direkte Dokumentenvergleich, die Neuberechnung bei Erweiterung des Vokabulars sowie der Umgang mit unbekanntem Wörtern.

#### 7.2.2.4 Auswahl des Modells und Parametrisierung

Als Resümee lässt sich festhalten, dass einfache Wortvektoren mit Häufigkeitszählungen je nach Dokument nicht zielführend sind und dass *Word-Embeddings* einen Vorteil gegenüber Lösungen haben, die auf einer prozessierten Dokument-Term-Matrix basieren (Baroni et al., 2014). Die direkten Vektorenvergleiche aus Kapitel 7.2.1 bleiben jedoch nicht vollkommen unberücksichtigt. Die Kosinusähnlichkeit fungiert als vektorielle Bewertung der Ergebnisse. Des

Weiteren lässt sich auch die Wahl der Methode für die Repräsentation der korpusimmanenten Informationen begründen. Auch wenn im Grunde alle in Kapitel 7.2.2.2 genannten Ansätze denkbar wären, sprechen die Ergebnisse klar für den Einsatz von *Word-Embeddings* (Levy & Goldberg, 2014b). Darüber hinaus steht der maschinelle Lernaufwand einer LDA oder auch einer LSI bei einem großen Textkorpus in keinem Verhältnis zu den deutlich schnelleren *Word-Embeddings* (Mikolov et al., 2013a), weswegen die zuerst genannten Ansätze ausgeklammert werden. Bei der Auswahl der *Word-Embeddings*, die alle hervorragende Ergebnisse beim Abbilden semantischer Ähnlichkeiten erzielen, konzentriert sich die vorliegende Arbeit auf das am häufigsten verwendete *Word-Embeddings*-Verfahren Word2Vec.

Levy et al. (2015) verglichen den Einfluss von Modellparametern und Korpusgröße. Sie kamen zu dem Ergebnis, dass „*larger corpora tend to yield better representations*“, gaben aber gleichzeitig zu bedenken, dass „*training word vectors from larger corpora is more costly in computation time, which could be spent in tuning hyperparameters*“ (ebenda S. 219). Aus diesem Grund wurden mit einem kleinen Teil der Dokumente des Korpus Versuche durchgeführt, um geeignete Einstellungen zu finden. Bezüglich der finalen Parametrisierung für die Word2Vec-Umsetzung nach Mikolov et al. (2013a) in wird auf das SkipGram-Modell gesetzt. Was die Wahl des Algorithmus angeht, wird die Argumentationslinie von Levy et al. (2015) aufgegriffen, in der deutlich gemacht wurde, dass die Wahl der Methodik im Vergleich zu den optimierten Modellparametern zweitrangig ist. Für die vektoriellen Wortrepräsentationen wird aus Geschwindigkeitsgründen eine Größe von 300 Dimensionen festgelegt. Es wird eine variable Fenstergröße von beidseitig acht Wörtern verwendet, um einen ausreichenden großen Kontext zu erfassen. Eine Fenstergröße kleiner als zwei Wörter wäre zu ungenau und würde schlechtere Ergebnisse als ein Verfahren der prozessierten Dokument-Term-Matrix erzielen (Levy et al., 2015). Alle Terme, die weniger als fünfmal vorkommen, werden ignoriert, was die Vokabulargröße auf ca. 31 % oder ca. 914.000 Wörter schrumpfen lässt.

### **7.2.3 Wissensbasis für die Termerweiterung**

Der zweite Aspekt, für den externes Wissen benötigt wird, ist die Erweiterung der *Seed-Words*. Anders als bei der Datengrundlage und -eingabe der methodenbasierten Sentimentanalyse sind bei der Auswahl der *Seed-Words* semantisch ähnliche Wörter unzureichend, da ansonsten die Gefahr besteht, das theoretische Emotionskonstrukt zu verfälschen. Stattdessen wird auf bedeutungsgleiche Wörter, also Synonyme, Hyperonyme und Hyponyme gesetzt.

Nimmt man nochmals Bezug auf die in Abbildung 19 dargestellte Einteilung der Wissensrepräsentationen durch Harispe et al. (2013, 2015), so zeigt sich die Relevanz der strukturierten

Wissensrepräsentation. Dabei ist der konzeptionelle oder semantische Zusammenhang bereits im gespeicherten Wissen inkorporiert. Darunter fallen beispielsweise Taxonomien, Thesauri oder semantische Netzwerke. In Taxonomien werden einzelne Elemente zu übergeordneten Einheiten gruppiert, die wiederum eine Teilmenge einer weiteren Kategorie bilden können. Exemplarisch dazu könnte neben anderen Emotionsmodellen das von Parrott (2001a) herangezogen werden. Ein Thesaurus, der in der Linguistik manchmal auch als kontrolliertes Vokabular betitelt wird, hat den Zweck, Terme inhaltlich in Beziehung zu setzen. Bei Thesauri können sowohl Synonymie und Antonymie als auch die semantischen Ordnungen durch Hyponyme und Hyperonyme abgebildet werden. In semantischen Netzwerken, wie beispielsweise dem englischsprachigen WordNet (Fellbaum, 1999; Miller, 1995), dem deutschsprachigen GermaNet (Hamp & Feldweg, 1997; Henrich, V. & Hinrichs, 2010) für generische Zwecke oder einen dezidierten Anwendungsfall in Bereich Business-Intelligence wie dem MUSING<sup>1</sup>-Projekt der EU (Kenett & Raanan, 2010; Leibold et al., 2010; Spies, Gubser & Schacher, 2010), werden die bisher genannten Relationen der strukturierten Wissensrepräsentationen in einem gerichteten oder ungerichteten Graphennetzwerk gespeichert.

Aus Verfügbarkeitsaspekten wären zum Beispiel *Seed-Words* aus inhaltsgleichen Emotionstheorien, gemeinfreie linguistische Ressourcen wie das Wiktionary (2008a; Zesch, Müller & Gurevych, 2008b), online erreichbare Wörterbücher wie der Duden oder semantische Netzwerke wie das GermaNet (Hamp & Feldweg, 1997; Henrich, V. & Hinrichs, 2010) naheliegender. Zhekova (2013) berichtet jedoch schon im Kontext der Koreferenzauflösung von einem unzureichenden Abdeckungsgrad des englischsprachigen WordNet, welches noch deutlich umfangreicher ist als das deutschsprachige Pendant. Daher konzentriert sich die zuerst gelistete Aufzählung auf alle Wissensquellen mit Ausnahme der semantischen Netzwerke.

## **7.3 Lexikonbasierte Ansätze**

### **7.3.1 Voraussetzungen des lexikonbasierten Ansatzes**

Um die lexikalische Sentimentanalyse durchzuführen, werden im Folgenden zahlreiche Vorverarbeitungsschritte, die in den Kapiteln 7.1.1 bis 7.1.5 beschrieben wurden, angewendet. In erster Instanz wird die Datenqualität auf ein bestmögliches Niveau gehoben, wozu alle Schritte der Datenbereinigung aus Kapitel 7.1.3, die Trennungen innerhalb eines Wortes aus

---

<sup>1</sup> MUlti-Industry, Semantic-based Next Generation Business INtelligence

Kapitel 7.1.2.2 sowie die Tokenisierung aus Kapitel 7.1.2.1 gehören. Für den lexikonbasierten Ansatz liegt ein *Bag-of-Words*-Ansatz zugrunde (Finetti, 1974; Jurafsky & Martin, 2017).

Der lexikalische Ansatz steht und fällt mit der Reichweite. Die Reichweite bzw. der Deckungsgrad beschreibt, welche Wörter eines zu annotierenden Textes auch in dem Meinungslexikon enthalten sind. Da Deutsch eine flexionsreiche und kompositionsfreudige Sprache ist, existieren viele Wortformen, die für den lexikalischen Ansatz kontraproduktiv sind (Gaeta, 2012; Riggert, 2000). Daher wird als zweiter Schritt die Termvielfalt gesenkt. Dies wird durch eine Lemmatisierung erreicht, die in Kapitel 7.1.5.1 angesprochen wurde.

Wie insbesondere bei dem Ansatz von Plutchik in Kapitel 2.3.2.3 beschrieben wurde, kann die Negation für die Sentimentanalyse eine entscheidende Komponente darstellen. Folgerichtig und zur Überprüfung der Hypothese kommt für den lexikalischen Ansatz die regelbasierte Negation aus Kapitel 7.1.5.2 zum Einsatz.

Als Korpus für die kontextspezifische Einbindung des externen Wissens wird das gesamte Nachrichtenkommentarkorpus verwendet. Als Analysedatengrundlage dient der annotierte Datensatz.

### **7.3.2 Emotionswortlistenerstellung mittels Labelpropagationsverfahren**

Für die Erstellung der Emotionswortlisten werden drei unterschiedliche Konfigurationen verwendet. Diese sind eine manuelle erstellte Liste und zwei Listen, die mittels automatischer Verfahren erweitert werden. Die maschinelle Wortselektion erfolgt einerseits auf den ursprünglichen Emotionsbegriffen der Theorie und andererseits auf Basis der erweiterten manuellen Liste in Verbindung mit dem Labelpropagationsverfahren. Letzteres ist deswegen Teil der Hypothesenüberprüfung, da die Emotionstheorie von Izard (1982) bzw. die Übersetzung von Merzen & Krause (1993) nur insgesamt 40 Schlüsselwörter besitzen. Wenn man Kategorien und Ausprägungen zusammenfasst, wäre die Messlatte, die ein lexikalisches Verfahren erreichen kann, das rein auf diesen Schlüsselwörtern beruht, niedrig. Mit Hilfe aktueller Ansätze und eines erweiterten *Seed-Words*-Bestands wird hier versucht, mit diesem Verfahren optimale Ergebnisse zu erzielen. Um das meiste aus den wenigen Emotionswörtern zu machen, wird bei der dritten Konfiguration das Lexikon in erster Instanz handselektierte Emotionswörter und dann in zweiter Instanz um Terme des Labelpropagationsverfahrens erweitert.

Die hier verwendete Methode des Labelpropagationsverfahrens zur Generierung eines feingranularen Meinungslexikons orientiert sich an aktuellen Forschungsarbeiten (Alhothali & Hoey, 2017; Hamilton et al., 2016; Velikovich et al., 2010). Der Erstellungsprozess selbst wird über mehrere Schritte hinweg vollzogen. Zuerst werden die theoriebasierten Emotionswörter

lexikalisch angereichert. Im zweiten Schritt wird eine Affinitätsmatrix erstellt. Schließlich wird das Modell angewendet, bevor es anhand des annotierten Datensatzes evaluiert wird.

### 7.3.2.1 Manuelle Erweiterung der gegebenen Emotionswörter

Wie bereits erwähnt, bilden *Seed-Words* häufig den Dreh-und-Angelpunkt bei der Erstellung eines solchen Meinungslexikons. Ein wichtiges Kriterium in diesem Zusammenhang ist die Güte der Liste. Um diese nicht durch Polysemie zu gefährden, wurde ein Term aus der ursprünglichen Liste herausgenommen. Dabei handelt es sich um das Adjektiv „abgestoßen“ aus dem Partizip Perfekt „abstoßen“, da dieses häufiger in der Bedeutung wegbewegen oder wegstoßen als im Sinne von Abneigung verwendet wird (Dudenredaktion, o. J. a.). Neue Schlüsselwörter werden in drei Stufen gewonnen und angereichert.

Die erste Stufe stellt eine Anreicherung aus anderen Emotionsmodellen dar. Dazu werden nur die beiden Emotionsmodelle von Mayring (2003) und Mees (1991) herangezogen. An dieser Stelle möchte sich die vorliegende Arbeit deutlich von einer Vermengung der Kategorien distanzieren. Das theoretische Konstrukt von Merten & Krause (1993) bleibt erhalten. Es findet auch keine Abwandlung der Emotionsausprägungen statt und ebenso bleibt die Anzahl der Emotionen unverändert. Daher wird, um das Emotionsmodell nicht inhaltlich zu verändern, hier äußerst konservativ vorgegangen und es werden jeweils nur inhaltsgleiche Kategorien ergänzt. Darüber hinaus wird darauf geachtet, dass die Auszüge überschneidungsfrei zu den anderen Emotionsmodellen vonstattengehen, also keine ambivalenten Kategorien im Sinne des zugrunde liegenden Modells aufgenommen werden.

Mayrings (2003) Beitrag zur Emotionsforschung stellt neben den Kategorien auch eine detaillierte Beschreibung der jeweiligen Gefühlsqualitäten unter Berücksichtigung anderer Autoren in diesem Wissenschaftsgebiet dar. Es werden hier jedoch nur die Emotionsausprägungen der vier Kategorien Zuneigungs-, Abneigungs-, Wohlbefindens- und Unbehagensgefühle dargestellt. Die Zuordnung der Emotionen ist der nachfolgenden Tabelle 46 zu entnehmen.

Emotionskategorie	Gruppierte Emotionsausprägungen	Emotionsausprägungen nach Mayring (2003)	Ergänzend zu Merten & Krause (1993)	Quelle bei Mayring (2003)
Zuneigungsgefühle	Liebe, Sympathie, Bindungsgefühl	Liebe	nicht zugeordnet	S. 152–155
		Sympathie	nicht zugeordnet	
		Bindungsgefühl	nicht zugeordnet	
	Stolz, Selbstwertgefühl	Stolz	nicht zugeordnet	S. 155–157
		Selbstwertgefühl	nicht zugeordnet	
		Überraschung, Schreck	Überraschung	
Schreck	nicht zugeordnet			
Abneigungsgefühle	Ekel, Abscheu	Ekel	bereits vorhanden	S. 158–160
		Abscheu	Ekel	
	Ärger, Wut, Zorn	Ärger	Wut	S. 160–162
		Wut	bereits vorhanden	
		Zorn	Wut	
	Angst, Furcht	Angst	bereits vorhanden	S. 163–165
		Furcht	Angst	

	Eifersucht	Eifersucht	nicht zugeordnet	S. 166–167	
	Neid	Neid	nicht zugeordnet	S. 167–170	
Wohlbefindens- gefühle	Lustgefühl, Genussleben	Lustgefühl Genusserleben	nicht zugeordnet nicht zugeordnet	S. 170–171	
	Freude	Freude	bereits vorhanden	S. 172–173	
	Zufriedenheit	Zufriedenheit	nicht zugeordnet	S. 173–175	
	Glück	Glück	Freude	S. 175–177	
Unbehagens-ge- fühle	Niedergeschlagenheit, Missmut	Niedergeschlagenheit Missmut	Trauer nicht zugeordnet	S. 177–180	
	Schamgefühl	Schamgefühl	bereits vorhanden	S. 180–182	
	Schuldgefühl	Schuldgefühl	bereits vorhanden	S. 183–184	
	Langeweile, Müdigkeit, Leere	Langeweile Müdigkeit	nicht zugeordnet nicht zugeordnet	S. 185–186	
	Anspannung, Nervosität, Unruhe, Stress		Leere	nicht zugeordnet	S. 186–188
			Anspannung	nicht zugeordnet	
			Nervosität	nicht zugeordnet	
			Unruhe	nicht zugeordnet	
Einsamkeitsgefühl	Einsamkeitsgefühl	Stress	nicht zugeordnet	S. 188–190	
			nicht zugeordnet		

*Tabelle 46: Ausprägung des Emotionsschemas nach Mayring (2003)*

In ähnlicher Manier wird bei der Ergänzung des Schlüsselworte des zweiten Modells verfahren. Mees (1991) gibt äquivalent zum vergleichbaren englischen Modell von Ortony et al. (1988) exemplarische Ausprägungen der jeweiligen Emotionstypen an. Diese werden in Tabelle 47 gelistet, wobei graugefärbte Emotionen nicht als Anreicherung in die hier erstellte Emotionsliste übernommen werden, da sie in dem Zielemotionsmodell nicht eindeutig wären, bereits vorhanden sind oder eine Ambivalenz besitzen.

Emotionskategorie	Polarisierte Emotionsunterkategorien	Emotionsausprägungen nach Mees (1991)	Ergänzend zu Merten & Krause (1993)	Quelle bei Mees (1991)
Wohlergehensemotion	Freudeemotion	Begeistert, entzückt, erfreut, ekstatisch, euphorisch, Freude, freudig erregt, freudige Überraschung, froh, fröhlich, gerührt, glücklich, wohl, zufrieden	Freude	S. 86
Wohlergehensemotion	Leidemotion	Bedauern, bedrückt, betroffen, bestürzt, betrübt, einsam, elend, entsetzt, erschreckt, erschüttert, Gram, Heimweh, Kummer, Langeweile, Leere, Leid, liebeskrank, niedergeschlagen, Sehnsucht, Schmerz, Schock, Schreck, Trauer, unglücklich, unwohl, unzufrieden, verstört, verzweifelt	Trauer	S. 87
Empathieemotion	Mitfreudeemotion	Bewegt, Mitfreude, Rührung	Freude	S. 91
	Mitleidemotion	Bedauern, Betroffenheit, einem-Leid-tun, Mitgefühl, Mitleid	nicht zugeordnet	S. 92
Erwartungsemotion & Mitleid	Sorge-Verbindungsemotion	Sich Sorgen machen	nicht zugeordnet	S. 93
Empathieemotion	Neidemotion	Missgunst, Neid	nicht zugeordnet	S. 94
	Schadenfreudeemotion	Boshafte Freude, Genugtuung, Häme, Schadenfreude	Verachtung	S. 94
Empathie- & Erwartungs- & Attributionsemotion	Eifersuchtsemotion	Eifersucht	nicht zugeordnet	S. 102
Erwartungsemotion	Hoffnungsemotion	Freudige Erregung, Hoffnung, hoffnungsfroh, hoffnungsvoll (Vorfreude), zuversichtlich	Freude	S. 107
	Furchtemotion	Ängstlich, Befürchtung, besorgt, beunruhigt, Furcht, voller grauen, Hoffnungslosigkeit, Panik, Sorge	Angst	S. 107
	Befriedigungsemotion	Befriedigung, Genugtuung	nicht zugeordnet	S. 110

	Erleichterungs-emotion	Erleichterung	nicht zugeordnet	S. 113
	Enttäuschungs-emotion	Enttäuschung, frustriert	Trauer	S. 113
Internale Attributi-onsemotion	Selbstlobemotion	Stolz	nicht zugeordnet	S. 116
	Selbstvorwurfs-emotion	Scham, sich schuldig fühlen	bereits vorhan-den	S. 116
Externale Attributi-onsemotion	Billigungsemotion	Billigung, Anerkennung, Bewunderung,	nicht zugeordnet	S. 119
	Vorwurfsemotion	Empörung (zu Wut), Entrüstung (zu Wut), Zorn (zu Wut), verachtenswert (zu Verachtung)	Wut / Verach-tung	S. 119
Wohlergehen & Attributionsemo-tion	Selbstzufrieden-heitsemotion	Selbstzufriedenheit, Stolz	nicht zugeordnet	S. 124
	Selbstunzufrieden-heitsemotion	Peinlich (zu Schuld), Scham, Selbstärger (zu Schuld), Verlegenheit (zu Scham)	Schuld / Scham	S. 125
Selbstlob & Mit-freude	Genugtuungsemo-tion	Befriedigung, Genugtuung	nicht zugeordnet	S. 127
Mitleid & Selbst-vorwurf	Schuldemotion	Bekennen, Besserung geloben, Buße tun, eingestehen, sich entschuldigen, sühnen, um Verzeihung bzw. Vergebung bitten, wieder gutmachen	Schuld	S. 131
Wohlergehen / At-tributionsemotion	Dankbarkeitsemo-tion	Dankbarkeit, (gerührt sein), sich jemandem ver-pflichtet fühlen	nicht zugeordnet	S. 133
	Emotion des Är-gers	Ärger, Belästigung, beleidigt, frustriert, empört, entrüstet, erbittert, erobost, ergrimmt, gekränkt, sauer, Unmut, verärgert, Wut, Zorn	Wut	S. 134
Wertschätzungse-motion	Emotion der Be-wunderung	Anbetung, Achtung, Bewunderung, Demut, Ehr-furcht, Hochachtung, Verehrung	nicht zugeordnet	S. 147
	Verachtung	Geringschätzung, Verachtung	Verachtung	S. 147
Attraktivitätsemo-tion	Zuneigungsemo-tion	Liebe, verliebt, vernarrt, Wohlwollen, Zunei-gung	nicht zugeordnet	S. 152
	Abneigungsemo-tion	Abneigung, Abscheu (zu Ekel), Ekel, Feindse-ligkeit (zu Verachtung), Groll, Hass (zu Verach-tung), Widerwille	Ekel / Verach-tung	S. 153

*Tabelle 47: Ausprägungen der Emotionstypen nach Mees (1991)*

In zweiter Instanz wird die Derivation der nun entstandenen Liste an Emotionswörtern verwendet (Donalies, 2011a). Durch die Wortableitung werden ausgehend vom Adjektiv „auf-merksam“ das Verb „aufmerken“ sowie das Nomen „Aufmerksamkeit“ der Liste der Emotionsterme der Emotionskategorie Interesse hinzugefügt. Diese Operation der Schlüsselworterweiterung ist weit weniger kritisch, da eine semantische Bedeutungsverschiebung in eine andere Emotionskategorie kaum stattfindet. Dennoch wurde auch hier sehr konservativ gefiltert, sofern Worte eine polysemantische Bedeutung erfahren oder in einem allgemeinen, nicht emotionsbezogenen Kontext deutlich häufiger vorkommen.

Analog zu den oben genannten Ansätzen zur Worterweiterung (beispielsweise Andreevskaia & Bergler, 2006), wird sich in dritter Instanz auf Synonyme konzentriert. Anders als bei den oben gelisteten Ansätzen wird dabei nicht auf eine semantische Wissensbasis wie WordNet zurückgegriffen, sondern es werden bedeutungsgleiche Wörter aus dem Duden und der gemeinfreien Plattform Wiktionary verwendet. Dabei wird nicht wie bei den ontologischen Ansätzen iterativ die Zuordnungsgrenze der Wortklassen verschoben, sondern es findet nur ein einziger Durchlauf statt. Die so gefundenen Synonyme aller bisher gesammelten Schlüsselwörter und Derivationen wurden nochmals manuell gefiltert. Auch hier wurde streng nach den

oben angedeuteten Kriterien der Polysemie und der unüblichen Wortverwendung des Emotionsterms gefiltert.

Durch die drei hochgradig manuellen Prozessschritte und das minutiöse Filtern der Terme entstand eine Liste von 678 Emotionstermen. Die vollständige Liste findet sich im Anhang in Kapitel 12.2. Die nachfolgende Tabelle stellt eine kumulierte Zusammenfassung der Emotionsliste dar:

	<i>Schlüsselwörter</i>	<i>Derivationen</i>	<i>Synonyme</i>	<i>Summe</i>
<i>Überraschung</i>	3	6	12	21
<i>Interesse</i>	3	4	28	35
<i>Scham</i>	3	5	27	35
<i>Verachtung</i>	3	6	43	52
<i>Schuld</i>	3	6	55	64
<i>Freude</i>	3	4	71	78
<i>Ekel</i>	2	4	80	86
<i>Angst</i>	3	6	83	92
<i>Trauer</i>	3	5	86	94
<i>Wut</i>	3	43	75	121

*Tabelle 48: Übersicht der erweiterten Seed-Words*

### 7.3.2.2 Erstellung der Emotionskategoriezugehörigkeit

Die Erstellung der Emotionskategoriezugehörigkeit ist der Prozess, bei dem die Zugehörigkeit eines beliebigen Terms zu den *Seed-Words* und subsequent zu den Emotionskategorien hinterlegt wird (Alhothali & Hoey, 2017). Um dieses feingranulare Meinungslexikon zu realisieren, sind vier Unterschnitte notwendig. Zum einen muss eine Abbildung der semantischen Beziehungen der Wörter erstellt werden. Zum zweiten muss eine Übergangsmatrix generiert werden, in der die semantischen Beziehungen integriert sind. Drittens wird per Simulation die Relation der Terme zu den *Seed-Words* offen gelegt. Abschließend werden Zugehörigkeiten der Terme zu den Emotionskategorien durch die Vielzahl der *Seed-Word*-Verbindungen ermittelt.

Zur Vorbereitung der Wortvektoren können beispielsweise die Methoden zur Wissensrepräsentation aus Kapitel 7.2.2 herangezogen werden, so wie dies in den Forschungsarbeiten von Hamilton et al. (2016) und Alhothali & Hoey (2017) durchgeführt wurde, auf deren Arbeiten sich diese Untersuchung stützt. Beide Forscherteams untersuchten eine Herangehensweise mittels einer *Singular-Value-Decomposition* (SVD)-zerlegten Matrix, basierend auf dem *Positiv-Pointwise-Mutual-Information* (PPMI)-Ähnlichkeitsmaß, und einer Wissensrepräsentation, basierend auf den *Word2Vec*- und *GloVec-Word-Embeddings*. Hamilton et al. (2016) stellten fest, dass bei kleinem Korpus die „*SVD-based method significantly outperformed word2vec*

[...] and GloVe“. Wohingegen Alhothali & Hoey (2017) den *Word-Embeddings* ein besseres Zeugnis und damit den Vorzug gaben, wengleich anzumerken ist, dass sie diese mittels WordNet überlagerten. Da hier ein ausreichend großer Korpus vorliegt und die *Word-Embeddings* ebenfalls für den maschinellen Lernansatz verwendet werden, stützt sich die Vektorrepräsentation ebenfalls auf diese Grundlage. Somit setzt sich das Vokabular  $V_{\text{Korpus}} = \{v_1, v_2, \dots, v_n\}$  aus der Wissensrepräsentation der *Word2Vec-Word-Embeddings* aus Kapitel 7.2.2.3.1 zusammen. Für spätere Berechnungsschritte wird das Vokabular  $V_{\text{Korpus}}$  in die Teilmenge der *Seed-Words*  $V_{\text{sw}}$  und restlichen Terme  $\bar{V}_{\text{sw}}$  aufgeteilt.

Im zweiten Schritt, bei dem die Terme zueinander in Relation gebracht werden, wird ein gewichtetes Graphennetzwerk verwendet. Hier enden bereits die Gemeinsamkeiten der Ansätze, die hier näher beleuchtet werden sollen. Velikovich et al. (2010) setzen bei der Generierung des Meinungslexikons auf den kürzesten Pfad innerhalb eines Netzwerks, das auf einem riesigen Webkorpus basiert. In iterativen Schritten wird die Pfadlänge erweitert und längere Pfade werden berücksichtigt. Sobald ein Schwellenwert der maximalen Pfadlänge überschritten ist, kann aus den gesammelten Pfaden die Polarität eines Terms zu einem meinungstragenden *Seed-Word* abgelesen werden. Hamilton et al. (2016) hingegen übersetzen das Graphennetzwerk in eine Übergangsmatrix und nutzen einen *Random Walk*, der nachfolgend noch detailliert erklärt wird, um die Polarität über die  $k$ -nächste-Nachbarn-Methode innerhalb des Graphennetzwerkes auszubreiten. Alhothali & Hoey (2017) wiederum verwenden eine analoge Herangehensweise wie Hamilton et al. (2016) und überlagern das Ähnlichkeitsmaß aus den *Word-Embeddings* mit Relationen aus WordNet, indem sie den Mittelwert beider Gewichtungen nutzen. Darüber hinaus unterscheiden sich die beiden letztgenannten Studien darin, dass Hamilton et al. (2016) den Arkuskosinus der Kosinusähnlichkeit als Gewichtung verwenden und Alhothali & Hoey (2017) die unveränderte Kosinusähnlichkeit. Der hier gewählte Ansatz trägt die Signatur von Alhothali & Hoey (2017), denn es wird ebenfalls eine Emotionsdetektion mit mehreren Kategorien gewählt und die zugrunde liegenden Gewichte in den Übergangsteilmatrizen  $\mathbf{Q} \in \mathbb{R}^{|\bar{V}_{\text{sw}}| \times |\bar{V}_{\text{sw}}|}$  und  $\mathbf{R} \in \mathbb{R}^{|\bar{V}_{\text{sw}}| \times |V_{\text{sw}}|}$  basieren auf der Kosinusähnlichkeit, die bereits in Kapitel 7.2.1 vorgestellt wurde. Alle für diese Methode verwendeten Termvektoren werden ebenfalls aus der in Kapitel 7.2.2.3.1 erläuterten Wissensrepräsentation der *Word-Embeddings* entnommen.

In den zugrunde liegenden Studien von Hamilton et al. (2016) und Alhothali & Hoey (2017) wird eine Einschränkung im Sinne einer  $k$ -nächste-Nachbarn-Analyse vorgenommen. Während sich Erstere in ihrer Studie bedeckt halten, was die Wahl von  $k$  angeht, rufen

Althothali & Hoey (2017) einen Wert von  $k = 300$  auf. Davon abweichend werden hier parametrisierte Ähnlichkeitsschwellenwerte  $sim_{\text{Kosinus}}(v_i, v_j) \geq \psi$  für die Inklusion von semantisch ähnlichen Termen verwendet. Die Schwellenwerte  $\psi$  und deren Bedeutung werden in Kapitel 7.3.3.1 näher spezifiziert. In den Übergangsmatrizen  $\mathbf{Q}$  und  $\mathbf{R}$  wird die Übertrittswahrscheinlichkeit dargestellt als:

$$p_{ij} = \frac{|sim_{\text{Kosinus}}(v_i, v_j)|}{\sum_k |sim_{\text{Kosinus}}(v_i, v_j)|}. \quad (12)$$

Die Übergangsmatrix  $\mathbf{P} \in \mathbb{R}^{|\mathcal{V}_{\text{Korpus}}| \times |\mathcal{V}_{\text{Korpus}}|}$  selbst lässt sich schreiben als (Zhu & Ghahramani, 2002):

$$\mathbf{P} = \begin{pmatrix} \mathbf{Q} & \mathbf{R} \\ \mathbf{0} & \mathbf{I}_{V_{\text{sw}}} \end{pmatrix}, \quad (13)$$

wobei  $\mathbf{0}$  eine  $|V_{\text{sw}}| \times |\bar{V}_{\text{sw}}|$ -Nullmatrix und  $\mathbf{I}_{V_{\text{sw}}}$  eine  $|V_{\text{sw}}| \times |V_{\text{sw}}|$ -Identitätsmatrix ist. Die *Seed-Words*, die in der Übergangsteilmatrix  $\mathbf{I}_{V_{\text{sw}}}$  enthalten sind, erhalten einen Sonderstatus, denn sie stellen absorbierende Zustände dar. Ihr Übergangswert wird daher auf sich selbst, also in der Matrixdiagonalen mit 1 angegeben, damit die Markowkette im nächsten Zwischenschritt einen stationären Zustand erreichen kann. Letzteres hat zum Ziel, dass nach Beendigung des folgenden Schrittes nur noch die Zugehörigkeit alle Terme  $\bar{V}_{\text{sw}}$  zu den *Seed-Words*  $V_{\text{sw}}$  in der Zielmatrix  $\hat{\mathbf{P}}$  gegeben ist. Für alle Werte der Matrix gilt  $0 \leq p_{ij} \leq 1 \forall p_{ij} \in \mathbf{P}$ .

Der dritte Schritt nutzt die Übergangsmatrix  $\mathbf{P}$  als Grundlage für einen *Random Walk*. Dies stellt aufgrund der genannten Sonderstellung der *Seed-Words* eine absorbierende Markowkette dar, welche die mathematische Eigenschaft der Konvergenz besitzt. Um die Zielmatrix  $\hat{\mathbf{P}} \in \mathbb{R}^{|\mathcal{V}_{\text{Korpus}}| \times |\mathcal{V}_{\text{Korpus}}|}$  zu erhalten, wird die Übergangsmatrix  $\mathbf{P}$  unendlich oft mit sich selbst multipliziert (Zhu & Ghahramani, 2002). Dies kann unter Verwendung der Neumann-Reihe approximiert werden (Walz, 2017):

$$\hat{\mathbf{P}} = \lim_{t \rightarrow \infty} \mathbf{P}^t = \begin{pmatrix} \mathbf{Q}^\infty & \left( \sum_{n=0}^{\infty} \mathbf{Q}^n \right) \mathbf{R} \\ 0 & \mathbf{I}_{V_{\text{sw}}} \end{pmatrix} \approx \begin{pmatrix} 0 & (\mathbf{I}_{V_{\text{sw}}} - \mathbf{Q})^{-1} \mathbf{R} \\ 0 & \mathbf{I}_{V_{\text{sw}}} \end{pmatrix}. \quad (14)$$

Die Berechnung kann insofern vereinfacht werden, als nur die Wahrscheinlichkeitsverteilung eines Terms zu allen *Seed-Words* und damit indirekt zu den Emotionskategorien abgelesen werden muss. Aus diesem Grund ist es ausreichend, wenn nur  $\hat{\mathbf{R}}$  rechnerisch ermittelt wird:

$$\hat{\mathbf{R}} = (\mathbf{I}_{V_{\text{sw}}} - \mathbf{Q})^{-1} \mathbf{R}. \quad (15)$$

Im vierten Prozessschritt werden die Zugehörigkeiten der Terme aus  $\bar{V}_{\text{sw}}$  zu den Emotionskategorien ermittelt. Hierzu muss der Umweg über die *Seed-Words* gemacht werden. Die

Matrix  $\hat{\mathbf{R}} \in \mathbb{R}^{|\bar{V}_{sw}| \times |V_{sw}|}$  schlüsselt die Zugehörigkeit jedes Wortes aus  $\bar{V}_{sw}$  zu einem *Seed-Word* zu. Die *Seed-Words* wiederum sind entsprechend des theoretischen Unterbaus von Merten & Krause (1993) fest mit einer Emotionskategorie  $y \in Y$  verknüpft. Da es eine unterschiedliche Anzahl  $n_y$  an *Seed-Words* je Emotionskategorie  $y$  gibt, wird für jedes Wort  $v_i$  an der  $i$ -ten Stelle des Vokabulars  $\bar{V}_{sw}$  ein gemittelter Ansatz für jede Einzelkategorie  $y$  herangezogen:

$$\sigma(v_i|y) = \frac{\frac{1}{|S(y)|} \sum_{k \in S(y)} \hat{\mathbf{R}}_{ik}}{\sum_{k \in Y} \frac{1}{|S(y)|} \sum_{k \in S(y)} \hat{\mathbf{R}}_{ik}} \quad (16)$$

Das Ergebnis ist eine auf den Emotionskategorien fußende Verteilung pro Wortvorkommnis der Trainingsdaten, die mit einer Summe von 1 und Einzelwerten je Klasse im Interval von  $[0, 1]$  formal die Kriterien einer Wahrscheinlichkeit erfüllt. Anders als bei Zhu & Ghahramani (2002) bzw. Zhu et al. (2003) wird auf die Übergangsmatrix  $\hat{\mathbf{R}}$  keine harmonische Funktion angewendet. Für die Aufgabenstellung erwies sich ein vereinfachter Ansatz als hinreichend, indem die absorbierende Markovkette berechnet und die Klassenzugehörigkeiten anhand der Übergangswerte entsprechend Formel 16 ermittelt wurden. Somit wäre ein feingranulares Meinungslexikon nach Merten & Krause (1993) im Sinne einer abgeänderten *Label-Propagation* anhand einer vorgegebenen und handgeschöpften *Seed-Word*-Liste und einer Wissensrepräsentation, basierend auf einem kontextrelevanten Korpus, erstellt.

### 7.3.3 Erstellung und Anwendung der Meinungslexika

Um das bestmögliche Ergebnis zu finden, wurden mehrere Konfigurationen des lexikonbasierten Ansatzes ausprobiert, bei dem das Labelpropagationsverfahren Anwendung fand. Erstens wurden bei der Wahl der semantisch ähnlichsten Wörter der Emotionskategoriezugehörigkeit mehrere Schwellenwerte definiert. Dies betrifft zweitens auch die Art der Aggregation der einzelnen Meinungswörter im betrachteten Texthorizont. Drittens wurden mehrere Varianten im Umgang mit der neutralen Klasse getestet. Schließlich wurden die einzelnen Tokens unterschiedlichen Gewichtungsmethoden unterzogen. Nachfolgend sollen alle als Parameter ins Modell eingehenden Möglichkeiten genauer erläutert werden. Da durch die möglichen Parametrisierungen viele Permutationen entstehen, wurden für die finale Analyse unter allen möglichen Kombinationen jeweils zufälligen Stichproben der Einstellungen gezogen, diese wurden einzeln berechnet und als Gesamtheit statistisch bewertet.

### 7.3.3.1 Schwellenwerte zur Inklusion semantischer Beziehungen

Analog zu Hamilton et al. (2016) und zu Alhothali & Hoey (2017) werden nicht alle semantischen Ähnlichkeiten im Labelpropagationsverfahren berücksichtigt. Während, wie oben erwähnt, in beiden soeben genannten Studien auf eine feste Anzahl semantisch ähnlicher Terme berücksichtigt wird, soll hier ein dynamischer Ansatz herangezogen werden.

Zum optimalen Aufbau der Übergangsmatrix wurden die Parameter  $\psi_{\text{Emotinswort}}$ ,  $\psi_{\text{Schlüsselwort}}$  und  $\psi_{\text{Rest}}$  eingeführt. Die jeweiligen Parameter  $\psi$  geben an, ab wann eine Übergangswahrscheinlichkeit, basierend auf der semantischen Ähnlichkeit, in die Matrizen aufgenommen wird. Der Parameter  $\psi_{\text{Emotinswort}}$  beschreibt dabei die semantische Ähnlichkeit zu den Emotionswörtern, also den zehn Kategorien der von Merten & Krause (1993) definierten Emotionen. Der zweite Parameter  $\psi_{\text{Schlüsselwort}}$  beschreibt, ab wann eine Übergangswahrscheinlichkeit mit einer semantischen Ähnlichkeit größer oder gleich als der gegebene Schwellenwert in das Modell einfließt. Unter den Termen, die durch das Raster der semantischen Ähnlichkeit der Emotions- und Schlüsselwörter gefallen sind, wird eine weitere Hürde verwendet. Der Parameter  $\psi_{\text{Rest}}$  beschreibt den semantischer Ähnlichkeitswert zwischen zwei Wörtern, der mindestens erreichen werden muss, damit das Wort berücksichtigt wird. Letztere bilden sozusagen die Grundlage für die Übergangswahrscheinlichkeiten der oben beschriebenen Teilmatrix  $\mathbf{R}$ . Für die Berechnung wurden die Werte  $\psi_{\text{Emotinswort}} = \{1; 0,6; 0,5; 0,4; 0,3; 0,2; 0,1\}$ ,  $\psi_{\text{Schlüsselwort}} = \{1; 0,7; 0,6; 0,5; 0,4; 0,3; 0,2; 0,1\}$  und  $\psi_{\text{Rest}} = \{1; 0,7; 0,6; 0,5; 0,4\}$  definiert. Dabei wurde darauf geachtet, dass die Abhängigkeit  $\psi_{\text{Emotinswort}} \leq \psi_{\text{Schlüsselwort}} \leq \psi_{\text{Rest}}$  eingehalten wurde. Mit dieser Abhängigkeit soll dem Fokus auf das Emotionsmodell Rechnung getragen werden. Mit anderen Worten werden umso mehr semantisch ähnliche Wörter berücksichtigt, je näher ein Term einem emotionsmodellgegebenen *Seed-Word* ist.

Die Einführung der drei Parameter hat zwei Gründe. Zum einen soll die Übergangsmatrix ausgedünnt werden, da nicht jeder geringe Einfluss als Störgröße in das Modell einfließen soll. Zum anderen soll durch die Einführung eines Schwellenwerts der Rechenaufwand bei der Multiplikation der dünn besetzten Matrizen verringert werden.

### 7.3.3.2 Aggregation der Meinungswörter

Die Nutzung des Meinungslexikons erfolgt in der Evaluation auf Satzebene entsprechend dem annotierten Goldstandard. Um das Lexikon auf Satzebene anzuwenden, bedarf es einer Aggregationsstrategie. Die Anwendung des Meinungslexikons wird auf Tokenebene heruntergebrochen, jedoch auf Satzebene aggregiert. Die Reihenfolge wird in diesem Zusammenhang nicht berücksichtigt, womit ein *Bag-of-Words*-Ansatz vorliegt. Jeder Token  $t$  des Satzes  $T =$

$\{t_1, t_2, \dots, t_n\}$  wird im Meinungslexikon nachgeschlagen. Die entsprechenden Wahrscheinlichkeiten zu den Emotionskategorien  $y \in Y$  werden für den gesamten Satz kumuliert. Unabhängig davon, welcher Ansatz zur Bestimmung der Klassenzugehörigkeit  $p(y|T)$  Verwendung findet, wird im Folgenden gleichermaßen vorangeschritten. Dazu wird die zutreffende Klasse  $y_{Klasse}$  eines Satzes anhand folgender Formel bestimmt:

$$y_{Klasse} = \operatorname{argmax}_{y \in Y} p(y|T). \quad (17)$$

In diesem Zusammenhang werden drei unterschiedliche Herangehensweisen geprüft. Erstens eine Summierung und Mittelwertbestimmung der jeweiligen Einzelwahrscheinlichkeiten  $p_{Token}(y|t)$ . Hierbei fällt jedem Wort die gleiche Möglichkeit, das Gesamtergebnis zu beeinflussen, zu. Diese wird formal ausgedrückt als:

$$p_{Summierung}(y|T) = \frac{1}{n} \sum_t^T p_{Token}(y|t). \quad (18)$$

Zweitens wird eine Multiplikation der einzelnen Wahrscheinlichkeiten getestet, um möglichst stark bzw. schwach zutreffende Wahrscheinlichkeiten hervorzuheben bzw. abzuschwächen. Um vergleichbare Werte zu erhalten und vor allem um zu einem späteren Zeitpunkt vergleichbare Schwellenwerte anzuwenden, werden dabei die Werte aller Klassen normiert.

Formal stellt sich dies wie folgt dar:

$$p_{Multiplikation}(y|T) = \frac{\prod_t^T p_{Token}(y|t)}{\sum_{i=0}^Y \prod_t^T p_{Token}(y_i|t)}. \quad (19)$$

Schließlich wird nur die maximale Klassenzugehörigkeit gewertet, also das Wort, das für die jeweilige Klasse  $y$  am einschlägigsten ist. Formal entspricht dies:

$$p_{Klasse}(y|T) = p_{Token}(y_{Klasse}|t). \quad (20)$$

### 7.3.3.3 Umgang mit der neutralen Klasse

Ähnlich wie bei Velikovich et al. (2010) wird zusätzlich ein Schwellenwert  $\gamma$  benötigt, um neutrale Sätze zu kennzeichnen, da in dem Meinungslexikon lediglich eine Verteilung entsprechend den zu den Emotionskategorien zugehörigen Schlüsselwörtern stattgefunden hat und die neutrale Kategorie noch nicht berücksichtigt wurde. Da hier mehrere Emotionskategorien vorliegen und nicht nur eine Einteilung in positiv und negativ, werden unterschiedliche Herangehensweisen geprüft. Die Methoden lassen sich aufteilen in solche, die die neutrale Kategorie nur Sätzen mit einer Nullwahrscheinlichkeit über alle Klassen  $\sum_y p(y|T) = 0$  zuordnen, und solche, die Schwellenwerte vorsehen. Letztere werden differenziert in solche mit einem

minimalen absoluten Schwellenwert  $\gamma_{\min \text{ abs}}$  und solche mit einem minimalen relativen Schwellenwert  $\gamma_{\min \text{ rel}}$ .

Beim minimalen absoluten Schwellenwert  $\gamma_{\min \text{ abs}}$  wird eine Hürde geschaffen, die die Wahrscheinlichkeit für eine Klasse eines bestimmten Textfragments  $p(y|T)$  mindestens erreichen muss. Es wird somit vorher nochmals geprüft, ob es sich tatsächlich um die vorliegende Klasse handelt oder ob ein Term in die neutrale Kategorie einzuordnen ist. Die finale Klassenzuordnung  $y_{\text{final}}$  ist somit:

$$y_{\text{final}} = \begin{cases} y_{\text{max}} & \text{falls } \operatorname{argmax}_{y \in Y} p(y|T) > \gamma_{\min \text{ abs}}, \\ \text{neutral} & \text{andernfalls.} \end{cases} \quad (21)$$

Der minimale relative Schwellenwert  $\gamma_{\min \text{ rel}}$  funktioniert analog wie der minimale absolute Schwellenwert, jedoch bemisst er sich nicht aus der Höhe der Wahrscheinlichkeit  $p(y|T)$ , sondern aus der Differenz zwischen der höchsten zutreffenden Wahrscheinlichkeit  $p(y_i|T)$  und der zweithöchsten zutreffenden Wahrscheinlichkeit  $p(y_j|T)$ . Folglich wird die Klassenzuordnung entsprechend folgender Formel getroffen:

$$y_{\text{final}} = \begin{cases} y_{\text{max}} & \text{falls } p(y_i|T) - p(y_j|T) > \gamma_{\min \text{ rel}}, \\ \text{neutral} & \text{andernfalls.} \end{cases} \quad (22)$$

Um die besten Ergebnisse zu erzielen, wird der Datensatz in einen Trainings- und einen Testdatensatz aufgeteilt, was in Kapitel 8.1 dezidiert erläutert wird. Anhand des Trainingsdatensatzes wird ein optimaler Wert für den Schwellenwert  $\gamma$  gesucht, wohingegen der Testdatensatz zur Evaluierung der Methode nach den Beurteilungskriterien aus Kapitel 8.2 vorgenommen wird.

### 7.3.3.4 Anwendung unterschiedlicher Gewichtungsmethoden

Bei der Gewichtung werden in der Umsetzung die bedingten Wahrscheinlichkeiten der Wörter  $p_{\text{Wort}}(y|t)$  durch gewichtete Pendanten ausgetauscht bzw. im ungewichteten Fall unverändert gelassen. Da dies bei der Multiplikation ohne Ergebnisse wäre und bei der Maximalwertbestimmung zu Verzerrungen hinsichtlich stark gewichteter Wörter führen würde, wird die Gewichtung nur bei der Summierung angewendet.

Manning et al. (2008) weisen auf eine mögliche Gewichtung hin, bei der korpuspezifische Merkmale berücksichtigt werden. Möglich wird dies, indem die dokumentenspezifische Worthäufigkeit als Kehrwert eingeht. Dadurch wird der Wert von selteneren, aber bedeutungstragenden Wörtern vergrößert. Berechnet wird dieser Gewichtungsfaktor der *Inverse-Document-Frequency* (idf) anhand folgender Formel (Manning et al., 2008):

$$idf_{\text{Wort}} = \log \frac{N}{df_{\text{Wort}}}. \quad (23)$$

Bei der zweiten Herangehensweise wird folglich die Gewichtung der einzelnen Wörter anhand der idf vorgenommen. Der Bezugsrahmen für das idf-Maß ist das gesamte Korpus, nicht nur das der annotierten Daten. Formal wird die Wahrscheinlichkeit des Wortes durch folgenden Ausdruck ersetzt:

$$p_{\text{Wort,gewichtet}}(y|t) = idf(t) \cdot p_{\text{Wort}}(y|t). \quad (24)$$

Da sich hier die Gesamtwahrscheinlichkeit bei der Mittelwertbildung verändert, wird in diesem Fall zusätzlich mittels der Summe aller im Satz befindlichen idf-Maße normalisiert, was in folgender Gleichung ausgedrückt wird:

$$p_{\text{gewichteter Satz}}(y|T) = \frac{\sum_{t \in T} (idf(t) \cdot p_{\text{Wort}}(y|t))}{\sum_{t \in T} idf(t)}. \quad (25)$$

Neben einer korpusbasierten Gewichtung kann ebenfalls die Termfrequenz  $tf_{\text{Wort,Dokument}}$ , also die gezählte Häufigkeit eines Terms  $w$  innerhalb eines bestimmten Dokuments  $d$ , verstärkt oder durch Skalierung verringert werden, um Effekte des gehäuft Auftretens eines Terms hervorzuheben oder zu nivelliert (Manning et al., 2008). Aufgrund der kurzen Sätze, in denen relevante Wörter kaum öfter als zweimal vorkommen, wird in dieser Arbeit davon abgesehen. Die davon ausgehende Verzerrung wird als marginal betrachtet.

Gepaart wird das Ganze mit unterschiedlichen Gewichtungen für die einzelnen modellgegebenen Schlüsselwörter und die Wörter mit synonyme Bedeutung, die in Kapitel 7.3.2.1 erstellt wurden. Als Schlüsselwörter wurden ebenso Wortderivationen der Schlüsselwörter betrachtet. Als Gewichtung wurden jegliche Kombinationen der Werte 1, 1,5, 2, 3 oder 4 für die Gewichtungen der Schlüsselwörter und die Gewichtungen der Synonyme zugelassen, bei der die Synonymgewichtung die Schlüsselwortgewichtung nicht übersteigt.

Folglich gehen hinsichtlich der Gewichtungen vier Varianten in das Modell ein. Diese teilen sich auf in eine ungerichtete Betrachtung und eine gewichtete Betrachtung. Letztere besteht aus der idf-Gewichtung, der unterschiedlichen Behandlung von Schlüsselwörtern und Synonymen mit allen möglichen Abstufungen, und der idf-Gewichtung in Kombination mit der Ungleichbehandlung von Schlüsselwörtern und Synonymen mit Abstufungsvarianten.

## 7.4 Modell des maschinellen Lernens

Neben lexikonbasierten Ansätzen gibt es zahlreiche Bestrebungen, die Sentimentanalyse durch den Einsatz von statistischen Methoden oder Verfahren des maschinellen Lernens auf eine völlig neue Ebene zu heben. Der Hauptgrund dafür ist, dass die rein wortbasierten

Verfahren oftmals an ihre Grenzen stoßen – sei es durch metaphorische Umschreibungen wie „da geht mit das Messer in der Tasche auf“, referentielle Äußerungen wie „ich fühle das Gleiche wie du“, Ironie wie „ich freue mich schon auf die unbezahlten Überstunden“, Negation wie „ich habe keine Angst“ oder Emotionen wie die Schadenfreude in „ich freue mich schon auf sein Gesicht, wenn er sieht, was wir getan haben“, um nur einige Gründe zu nennen. Der aktuelle Forschungstrend geht dahin, diese Unzulänglichkeiten der lexikalischen Ansätze mit elaborierten Methoden bestmöglich zu lösen. Um optimal auf Probleme dieser Art reagieren zu können, ist z. B. ein Aufschlüsseln des syntaktischen Abhängigkeitsbaumes eines Satzes notwendig (Socher et al., 2013).

Anders als bei der bisherigen Herangehensweise wird hier kein Vergleich möglicher Methoden vorgenommen, sondern es wird sich direkt auf ein Vorgehen konzentriert, das in jüngster Zeit bemerkenswerte Ergebnisse bei der Sentimentanalyse erzielte (Kalchbrenner et al., 2014; Kim, Y., 2014). Als maschinelles Lernverfahren für die Sentimentanalyse wird hier das *Convolutional Neural Network* (CNN) im Zusammenspiel mit den bereits beschriebenen *Word-Embeddings* verwendet. Der Grund dafür ist, dass dieses Verfahren ohne Aufbau des Abhängigkeitsbaumes syntaktische Informationen im Modell integrieren und somit auch komplexere Phrasen und Satzkonstruktionen bewältigen kann (Kalchbrenner et al., 2014; Socher, 2016). Damit reiht sich dieses Verfahren zu den neuen Ansätzen der Sprachverarbeitung ein, bei der die syntaktische Datenstruktur persistiert wird (beispielsweise Adel, Roth & Schütze, 2016; Adel, Chen & Chen, 2017; Yin, Schütze, Xiang & Zhou, 2016). Alle Token werden durch vektorielle Wortrepräsentationen ausgetauscht. Würde man bei der Beibehaltung der Syntax und einer gleichzeitigen Wortdarstellung bleiben, wäre ein großer Referenzkorpus notwendig, um eine Analyse durchzuführen. Dadurch, dass Wörter jedoch durch angereicherte Vektoren ersetzt werden, die in Kapitel 7.2.2.3 ausführlich beschrieben werden, sind Analysen möglich, die gleichzeitig von den syntaktischen Informationen profitieren. Ein weiterer Vorteil dieses Ansatzes ist, dass Satzzeichen implizit berücksichtigt werden, da sie ein deutliches Merkmal der Subjektiven Sprache sind (Agarwal, A. et al., 2011; Bakliwal et al., 2012).

Im Folgenden wird das Verfahren kurz vorgestellt und die verwendete Konfiguration des Netzwerkes dargelegt.

#### **7.4.1 Voraussetzungen des maschinellen Lernansatzes**

Analog zur Vorgehensweise des lexikalischen Ansatzes werden nun die Voraussetzungen für den maschinellen Lernansatz erläutert. Dabei finden sich viele Parallelen in den Vorverarbeitungsschritten. In gleicher Weise wird als erster Schritt die Datenqualität der Texte

verbessert. Dazu zählen alle Schritte der Datenbereinigung aus Kapitel 7.1.3, die Worttrennungen aus Kapitel 7.1.2.2 und die Tokenisierung aus Kapitel 7.1.2.1. Anders als bei dem lexikalischen Ansatz liegt hier kein *Bag-of-Words*-Modell zugrunde, sondern die Satzstruktur wird persistiert. Wenngleich dabei ebenfalls die Termvielfalt gesenkt wird, so wird dies hier weniger als Feststellung sondern eher als Frage bezüglich des adäquaten Einsatzes der Token formuliert, indem unterschiedliche Konstellationen gegeneinander abgewogen werden. Dabei wird das bereinigte, aber morphologisch nicht veränderte Wort im Vergleich zum bereinigten Lemma untersucht. Bei der Verwendung der lemmatisierten Form werden darüber hinaus noch weitere Varianten geprüft, in denen den Lemmata durch Anhängen von Suffixen zusätzliche wortspezifische Informationen angefügt werden.

Folgende Varianten werden näher betrachtet:

<b>Kurzbezeichnung</b>	<b>Beschreibung eines Tokens und zugehörigem Suffix</b>
<b>Lemma</b>	Lemma ohne Suffix
<b>Lemma Morph.</b>	Lemma mit allen morphologischen Informationen
<b>Lemma Pers.</b>	Lemma mit Person
<b>Lemma Pers. Num.</b>	Lemma mit Person und Numerus
<b>Lemma Pers. Num. Subj.</b>	Lemma mit Person, Numerus und Modus (nur Subjunktiv)
<b>Lemma Pers. Pos.</b>	Lemma mit Person und Wortart
<b>Lemma Pers. Subj.</b>	Lemma mit Person und Modus (nur Subjunktiv)
<b>Word</b>	Wort ohne Suffix

*Tabelle 49: Varianten der Vorverarbeitung der Word2Vec-Modelle*

Darüber hinaus wird das ganze flankiert von der Negation aus Kapitel 7.1.5.2, was ebenfalls in den obigen Varianten als suffigierte oder unveränderte Formen aufgenommen wird. Somit ergeben sich  $8 \times 2$  unterschiedliche Varianten, für die jeweils ein Word2Vec-Modell erzeugt wird, das als Grundlage für den Vergleich der offenen Frage des optimalen Tokeneinsatzes herangezogen wird. Als Korpus für die Wissensrepräsentation wird das gesamte Nachrichtenkommentarkorpus verwendet. Als Analysedatengrundlage dient ebenfalls der annotierte Datensatz.

Ein Wort  $w_n \in \mathbb{R}^k$  an der Stelle  $n$  einer Sequenz von Wörtern  $w_1, w_2, \dots, w_n$  kann somit als  $n \times k$ -Matrix dargestellt werden, wobei die Wörter entsprechend ihrer Reihenfolge untereinander verkettet werden. Zu dem bereits genannten Vorteil der Inklusion der Satzaufbauinformationen kommen noch die positiven Eigenschaften der Wortrepräsentationen, die an späterer Stelle detailliert erläutert werden.

## 7.4.2 Convolutional Neural Networks

Das CNN-Verfahren ist eine Methode aus der Bilderkennung, dessen gedanklicher Ursprung auf neurowissenschaftliche Forschungsarbeiten von Hubel und Wiesel (1959, 1962;

LeCun, Bengio & Hinton, 2015) aber im technischen Bereich auch auf Fukushima (1980, 2013) zurückgeht und unter der Forschungsgruppe um (LeCun et al., 1989; 1990; 1998a) bereits frühzeitig erste Erfolge in der maschinellen Datenverarbeitung verzeichnete. Wenngleich es nennenswerte Unterschiede zwischen der Variante von Fukushima und den heutigen, auf LeCun basierenden neuronalen Netzwerken gibt, soll an dieser Stelle nicht weiter darauf eingegangen werden (weiterführend dazu Schmidhuber, 2015). Bei CNNs handelt es sich um ein Klassifikationsverfahren des überwachten Lernens. Laut Bengio (2009, S. 43) ist es eine Herangehensweise, die bereits vor den *Deep Architectures* erfolgreich war, da letztere angesichts der damaligen Rechenleistung und ohne die Anwendung einer unüberwachten Vortrainingsstufe zu lange Trainingszeiten aufwiesen.

Es ist ein neuronales Netz, das auf der Grundlage zweier neuronaler Netzwerkschichten basiert, dem *Convolutional Layer* inklusive der nichtlinearen Transformation und dem *Pooling-Layer*. Diese beiden Netzwerkebenen werden in der Bildverarbeitung mehrfach hintereinandergeschaltet. Es ist möglich, dass mehrere Faltungsschichten in einer Pooling-Ebene zusammengefasst werden (beispielsweise Kim, Y., 2014; Simonyan & Zisserman, 2014; Szegedy et al., 2014). Diese Konstellation aus *Convolutional* und *Pooling-Layer* kann beliebig oft wiederholt werden, um beispielsweise eine tiefe Architektur im Sinne des *Deep Learning* zu erzeugen. Dai, Dai, Qu, Li & Das (2016) verwendeten beispielsweise 34 Ebenen, He, Zhang, Ren & Sun (2015a) setzten 100 Ebenen ein und Russakovsky et al. (2014) nutzen 152 Ebenen in Verbindung mit einem CNN. Als letzte Ebene dieses Modells wird üblicherweise ein neuronales Netz wie ein *Multi-Layer-Perceptron* (MLP) in Verbindung mit dem SoftMax-Algorithmus verwendet (Roy & Permanente, 2017). Die Anzahl der Neuronen der Ausgabeschicht entsprechen der Anzahl an Klassen. Es gibt aber auch hier Ausnahmen, die z. B. ohne diese Schicht auskommen (beispielsweise Szegedy et al., 2014).

Im Folgenden sollen die Unterschiede zwischen Bild- und Texterkennung genauer herausgearbeitet werden. Diese Erläuterungen sind generisch und in einfacher Sprache gehalten, weswegen im Nachgang dazu die mathematischen Grundlagen dieser Methode dargestellt werden. So werden im zweiten Teil die wichtigsten Komponenten eines CNNs, also die Faltungsschicht, die nichtlineare Aktivierungsfunktion, die Pooling-Schicht und die Klassifikationsschichten näher beleuchtet.

#### **7.4.2.1 Anwendung eines Bilderkennungsverfahrens bei Texten**

Wie aus den oben genannten Quellen ersichtlich wird, hat das CNN-Verfahren bereits gezeigt, dass es sehr gute Dienste bei der Bilderkennung leistet. Seit Kim, Y. (2014) und

Kalchbrenner et al. (2014) ist ebenfalls bekannt, dass dieses Verfahren für die Textklassifikation geeignet ist. In diesem Zusammenhang ergeben sich zwei Fragen: Worin liegen die fundamentalen Unterschiede zwischen der Bild- und der Texterkennung? Und wie kann dieses Verfahren für die Sprachverarbeitung genutzt werden?

Die Eingabematrix bei einer Textklassifikation unterscheidet sich fundamental von der Eingabematrix bei einem Bilderkennungsverfahren. Die Achsenausprägungen sind, anders als bei Bildern, grundverschieden. Doch was bedeutet dies und welche Informationen tragen diese Achsen?

Die erste Achse beinhaltet nebeneinanderliegende Wörter. Dieses Merkmal ist wichtig, denn es stellt die Reihenfolge der Token eines Satzes dar. Informationen auf dieser Achse besitzen eine gewisse Reichweite zueinander. Wenngleich diese meist relativ gering ausfällt, so erstreckt sich der Bezug eines Adjektivs beispielsweise auf ein nachfolgendes Nomen. Eine Konjunktion kann die Referenz auf ein zweites oder weitere gelistete Elemente erweitern. Aber auch größere Bezugsdistanzen sind denkbar, z. B. durch die mögliche Stellung des Verbs am Ende des Satzes im Deutschen. Die Informationen dieser Achsen sind nur in einem gewissen Maße in ihrer Anordnung flexibel. Bedingt ist dies durch die Satztopologie, die in der deutschen Sprache viel grammatikalischen Freiraum hinsichtlich der Kombinatorik bietet. Aber syntaktische Bezüge können nicht gänzlich außer Acht gelassen werden.

Ein weiteres Merkmal, dass die Achse der Token von der Achse der Wortvektoren unterscheidet, ist der Grad der Füllung. Bedingt dadurch, dass Sätze eine unterschiedliche Länge aufweisen, aber ein CNN eine gleichbleibende Eingangsmatrix erwartet, entstehen Lücken. Um die Abmessung der Matrix konstant zu halten, wird sich bei der parametrisierten Dimensionierung an den längsten Sätzen orientiert und kürzere Sätze mit leeren Informationen oder Nullwerten aufgefüllt. Festzuhalten bleibt, dass die erste Achse die Informationen nicht nur durch das Vorkommen bestimmter Worte trägt, sondern auch durch deren Bezüge zueinander. Die zweite Achse der Eingabematrix hingegen repräsentiert die Koordinaten der Wortvektoren. Im Grunde genommen ist jede bedeutungstragende Koordinate hierbei völlig gleichwertig, da alle Koordinaten kodierte Informationen darüber enthalten, wo sich ein Wort im Vergleich zu den anderen Wörtern im semantischen Raum befindet. Dadurch, dass die Reihenfolge der getragenen Informationen bei allen Wortvektoren äquivalent ist, liegt in der Sortierung der Koordinaten, anders als bei der ersten Achse, keine Information vor. Die Elemente der zweiten Achse besitzen keine fehlenden Stellen, die nur bei Bedarf gesetzt werden. Die Informationsdichte ist auf ihr somit vollständig gegeben.

Bei der Textanalyse weicht die Form des Filters, bedingt durch die unterschiedliche Art der Information, von einer Bildanalyse ab. Üblicherweise wird bei der Bildanalyse ein quadratischer Filter oder Kernels verwendet. Dies kann damit begründet werden, dass sowohl horizontal als auch vertikal die gleiche Informationsart und -dichte vorliegt. Wie im vorangegangenen Absatz erläutert, bestehen bei der Textanalyse die Achsen aus grundverschiedenen Informationen. Um diese Informationen zielführend auszulesen, muss auch der Filter entsprechend angepasst werden. Die Filterbreite für die Achse, auf der die Wortreihenfolge gespeichert ist, kann verschiedene Größen annehmen, je nachdem, wie viele Wörter gleichzeitig pro Betrachtung erfasst werden sollen. So entspricht eine Filterbreite von eins einer wortweisen Verarbeitung. Analog dazu liegt eine Betrachtung bei einer Filtergröße von zwei in Bigrammen, bei einer Filtergröße von drei in Trigrammen usw. vor. Alle Filter werden abhängig vom *Stride*-Parameter, der später noch ausführlicher erläutert wird, durch die Matrize geschoben und geben, wie in Kapitel 7.4.2.2 beschrieben, je Position einen Rückgabewert. Durch die gleichzeitige Betrachtung mehrerer Wörter nebeneinander werden so bestimmte syntaktische Informationen inkludiert (Socher, 2016). Diese sind nicht mit einem syntaktischen Abhängigkeitsbaum vergleichbar, umfassen jedoch durch die Satzreihenfolge zusammengehörende Satzteile.

Anders als bei der anfänglichen Herangehensweise der Sentimentanalyse, bei der bei *n*-Grammen tatsächliche Token verwendet wurden (Wiebe, Wilson & Bell, 2001), stützt man sich hier auf *Word-Embeddings*. Durch diesen Kunstgriff müssen nicht exakte Wortfolgen vorliegen; auch semantisch ähnliche Phrasen können durch eine hohe Deckung mit einem Filter vergleichbare Ergebnisse erzielen. Die Verwendung der vektoriellen Informationsträger anstelle der einzelnen Wörter setzt jedoch eine vollständige Betrachtung voraus. Für die Filtergröße bedeutet dies, dass sie auf der zweiten Achse die gleiche Abmessung haben muss wie die *Word-Embeddings*, um ein Versetzen mittels *Stride* zu verhindern. Während bei der ersten Achse wortweise verschoben wird, würden bei der zweiten Achse codierte Bedeutungsdimensionen verschoben werden, die nicht miteinander vergleichbar sind. In diesem Zusammenhang wird ersichtlich, warum für den Parameter *Stride* nur ein Wert von eins zielführend ist, da hier der Filter über jede mögliche Wortfolge iterieren kann. Nur so können alle Informationen abgegriffen werden.

Eine weitere Abweichung zur Bildklassifikation mittels CNN liegt in der Pooling-Schicht und der Anzahl der Wiederholungen von Faltungs- und Pooling-Schichten. Bei der Bildbestimmung können Informationen immer weiter aggregiert und einfache Kanten, Ecken und Flächen auf höheren Schichten zu komplexeren Formen kombiniert werden. Diese Informationsverdichtung ist durch die *Word-Embeddings*-umfassende Filtergröße nur in eine Achsenrichtung

möglich, da die Ausgabe der Faltungsschicht bereits auf ein einzelnes Bit pro Wort und Filter zusammengeschrumpft ist. Es wird argumentiert, dass eine weitere Verdichtung auf Ebene der Wortachse einen ähnlichen Effekt hätte wie die Betrachtung mehrerer nebeneinander liegender Wörter. Aus diesem Grund wird bei der Textanalyse kein mehrere Schichten umspannendes CNN-Netzwerk verwendet, sondern ein einstufiges. Um sich nicht nur auf die Betrachtung bestimmter Wortfolgen zu konzentrieren, werden parallel unterschiedliche Filterbreiten in unterschiedlichen Schichten analysiert. Mit anderen Worten gibt es sowohl für Unigramme, Bigramme und weiterer n-Gramme eigene Faltungsschichten. Diese Informationen werden mittels *Global Pooling* wieder zusammengeführt, bevor sie weiterverarbeitet werden.

In Abbildung 20 ist dieser Sachverhalt nochmals dargestellt. Hier werden zwei Filter für Unigramme und ein Filter für Bigramme auf die *Word-Embeddings*-Satz-Matrix angewendet. An jeder Position wird ein Wert errechnet und transformiert, was im Kapitel 7.4.2.2 sowie 7.4.2.3 detailliert erläutert wird. Jedes Ergebnis einer Filteroperation wird in der Global Pooling auf einen Wert aggregiert. Die Operationen des Aggregationsvorgangs werden in 7.4.2.4 ausführlich behandelt.

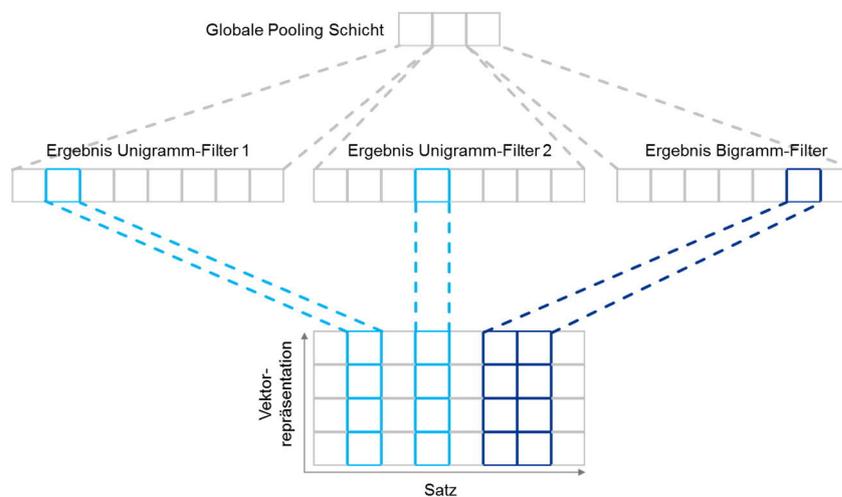


Abbildung 20: Anwendung des CNN-Verfahrens bei Texten

### 7.4.2.2 Faltungsschicht

Im *Convolutional Layer* oder in der Faltungsebene wird ein Kernel, der auch als namensgebende Kernelmatrix bekannt ist, auf eine Eingabematrix angewendet. Dabei ist die Faltung eine mathematische Operation, mittels derer eine Kernelmatrix bzw. Faltungsmatrix mehrfach und schrittweise über eine Eingabematrix gelegt wird (Wang, H., Raj & Xing, 2017). Die Kernelmatrix ist in ihrer Abmessung kleiner oder gleich der Abmessung der Eingabematrix. Die Kernelmatrix wird für jedes Element in der Eingabematrix überlagert, was mathematisch durch das Skalarprodukt realisiert wird. Wie in Abbildung 21 gezeigt, entspricht das Ergebnis

der Multiplikation der partiellen Matrix der Eingabedaten und des Kernels in die zentrale Koordinate der Ausgabematrix. Sofern kein sogenanntes *Padding* verwendet wird, bei dem der Kernel-Überschneidungen mit ungültigen Koordinaten außerhalb der Matrix als Nullwerte behandelt, ist die resultierende Ergebnismatrix entsprechend kleiner (Heaton, 2013).

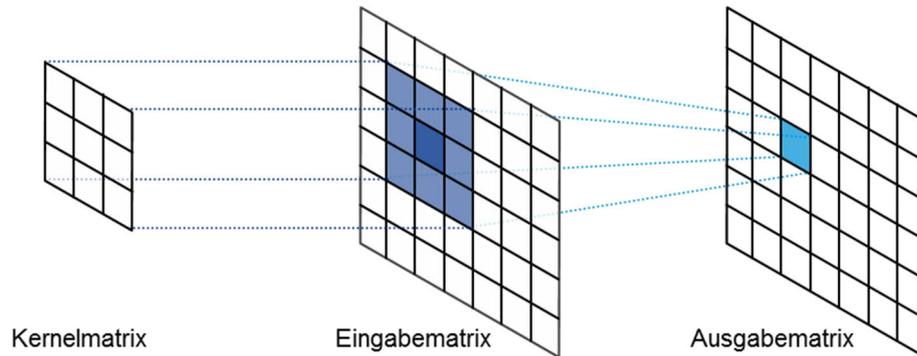


Abbildung 21: Überlagerung der Kernel- und Eingabematrizen mit *Padding*

Die Faltungsoperation wird über eine elementweise Anwendung des Skalarprodukts realisiert, wie Abbildung 22 zeigt. Dabei ist es auch möglich, dass eine Nivellierung der Ergebniswerte in Form eines Divisors, der der Anzahl der Kernelmatrixfelder entspricht, eingesetzt wird (Wang, H. et al., 2017).

8	3	14	15	10	19	*	2	-2	1	=	3	-32	1	18	-6	-1
13	12	3	6	14	11		0	2	0		-1	0	-54	-24	15	-21
14	20	13	18	6	13		-2	-1	0		11	19	-9	-6	-34	-15
3	20	19	12	17	13											
6	14	4	20	10	14											
1	1	6	3	14	17											
18	16	5	9	19	8											
13	10	9	19	20	14											

Abbildung 22: Anwendung des Kernelfilters (Wang, H. et al., 2017)

Während bei Bildgebungsverfahren meist eine quadratische Kernelmatrix verwendet wird, findet bei CNNs in Verbindung mit *Word-Embeddings* eine rechteckige Kernelmatrix Anwendung, deren Länge sich aus der Dimensionalität der Wortvektoren ergibt. Der Termvektor  $x_i \in \mathbb{R}^k$  an der Satzposition  $i$  entspricht einer  $k$ -dimensionalen Wortrepräsentation des Word2Vec-Trainings aus Kapitel 7.2.2.3. Ein Eingabesatz mit der Länge  $n$  entspricht einer mittels des Verkettungsoperators  $\oplus$  zusammengeführten Sequenz, die sich formal wie folgt beschreiben lässt (Kim, Y., 2014):

$$\mathbf{x}_{1:n} = x_1 \oplus x_2 \oplus \dots \oplus x_n. \quad (26)$$

Die Faltungsoperationen über eine Teilsequenz  $\mathbf{x}_{i:i+h} = x_i \oplus x_{i+1} \oplus \dots \oplus x_{i+h-1}$  mit der Wortfensterlänge  $h$  werden mittels eines Kernelfilters  $\mathbf{w} \in \mathbb{R}^{h \times k}$  durchgeführt (Kim, Y., 2014). Neben der schrittweisen Matrixüberlagerung der Eingangsdaten und des Kernels wird

auch eine nichtlineare Aktivierungsfunktion  $f$  in dieser Ebene verwendet, was im folgenden Kapitel näher beleuchtet wird. Durch die nichtlineare Aktivierungsfunktion  $f$  wird das Ausgabemerkmale  $c_i$ , das als Eingangsdatum für nachfolgende Operationen verwendet wird, durch eine Multiplikation der Kernelmatrix  $\mathbf{w}$  mit dem Wortfenster  $\mathbf{x}_{i:i+h-1}$  erzeugt (Kim, Y., 2014):

$$g_i = f(\mathbf{w} \cdot \mathbf{x}_{i:i+h-1} + b), \quad (27)$$

wobei  $b$  ein Verzerrungswert ist. Da der Filter auf jede mögliche Subsequenz des Satzes angewendet wird, entsteht ein Featureset  $g = [g_1, g_2, \dots, g_{n-h+1}]$  (Kim, Y., 2014). Dies bildet wiederum den Ausgangspunkt für die *Pooling*-Schicht.

### 7.4.2.3 Nichtlineare Aktivierungsfunktion

Für neuronale Netzwerke gibt es zahlreiche Aktivierungsfunktionen, die man in intervallbegrenzte und nicht intervallbegrenzte unterscheiden kann (Roy & Permanente, 2017). Gesättigte Aktivierungsfunktionen im Sinne der Sättigungsarithmetik sind Verfahren wie das bereits angesprochene SoftMax (McCullagh & Nelder, 1999), Sigmoid (Han, J. & Moraga, 1995) und *Tangens Hyperbolicus* (Tanh) (Malfliet, 2005) sowie deren Varianten Hard-Sigmoid und Hard-Tanh (Gülçehre, Moczulski, Denil & Bengio, 2016). Daneben existieren die Aktivierungsfunktionen ohne oder mit nur einseitiger Intervallbegrenzung wie Cube (Chen, D. & Manning, 2014), ELU (Clevert, Unterthiner & Hochreiter, 2015), ReLU (Nair & Hinton, 2010) und deren Modifikationen PReLU (He, Zhang, Ren & Sun, 2015b), RReLU oder Leaky ReLU (Xu, B., Wang, Chen & Li, 2015).

Mishkin, Sergievskiy & Matas (2016) verglichen in einer Studie unterschiedliche Aktivierungsfunktionen bei CNNs. Da die Benchmark-Studie in der Bilderkennung stattgefunden hat, kann nicht abschließend gesagt werden, welche Aktivierungsfunktion die geeignetste ist. Aus diesem Grund wird die Wahl der Aktivierungsfunktion hier parametrisiert. Im Rahmen dieser Arbeit werden somit die gängigen Aktivierungsfunktionen ReLU, Leaky ReLU, ELU, Tanh, Sigmoid und SoftMax untersucht und die jeweils am besten geeignete verwendet. Die zuletzt genannten werden nun kurz vorgestellt. In Bezugnahme auf das vorangegangene Kapitel entspricht  $a = \mathbf{w} \cdot \mathbf{x}_{i:i+h-1} + b$  und  $f(a)$  der Aktivierungsfunktion.

Die Aktivierungsfunktion ReLU oder *Rectified Linear Unit* begrenzt alle skalaren Eingabewerte  $a$  einseitig und ist somit formal definiert als (Nair & Hinton, 2010):

$$f_{\text{ReLU}}(a) = \max(0, a). \quad (28)$$

Die modifizierte Version Leaky ReLU schwächt negative Werte um einen Faktor  $\zeta_{\text{Leaky ReLU}}$  ab, der üblicherweise auf  $\zeta = 0,01$  gesetzt wird. Die Funktion ist somit definiert als (Xu, B. et al., 2015):

$$f_{\text{Leaky ReLU}}(a) = \begin{cases} a & \text{wenn } a > 0, \\ \zeta_{\text{Leaky ReLU}} a & \text{andernfalls.} \end{cases} \quad (29)$$

*Exponential Linear Units* oder ELUs verwenden ebenfalls einen Hyperparameter  $\zeta_{\text{ELU}} \in \mathbb{R}^+$ . Im Vergleich zu ReLU oder Leaky ReLU existieren hier negative Werte. Formal ist ELU definiert als (Clevert et al., 2015):

$$f_{\text{ELU}}(a) = \begin{cases} a & \text{wenn } z \geq 0, \\ \zeta_{\text{ELU}}(e^a - 1) & \text{andernfalls.} \end{cases} \quad (30)$$

Tanh ist die Anwendung der Hyperbelfunktionen, die Werte im Intervall  $[-1,1]$  zurückgibt (Malfliet, 2005):

$$f_{\text{tanh}}(a) = \tanh(a). \quad (31)$$

Die Sigmoidfunktion ist eine Aktivierungsfunktion im Wertebereich von  $[0,1]$ . Diese ist definiert als (Han, J. & Moraga, 1995):

$$f_{\text{Sigmoid}}(a) = \frac{1}{1 + e^{-a}}. \quad (32)$$

Schließlich sei noch die SoftMax-Funktion erwähnt, die neben der Einsatzmöglichkeit als Aktivierungsfunktion aus als Klassifikationsfunktion in der abschließenden CNN-Schicht verwendet wird. Als Ergebnis wird ebenfalls ein Wertebereich von  $[0,1]$  abgebildet. Formal drückt sich diese Funktion aus als (McCullagh & Nelder, 1999):

$$f_{\text{SoftMax}}(a_j) = \frac{e^{a_j}}{\sum_{y \in Y} e^{a_y}}, \quad (33)$$

wobei  $a_j$  ein Element der Menge aller Elemente  $a_{y \in Y}$  ist und  $y \in Y$  eine der zu bestimmenden Klassen repräsentiert.

#### 7.4.2.4 Pooling-Schicht

Die *Pooling*-Schicht wird aus dem Ergebnis der Faltungsebene gespeist. Darin werden mehrere Elemente der Eingabematrix anhand einer *Pooling*-Operation zusammengefasst. Das Ziel dieser *Pooling*-Operation ist es, robuster gegenüber Datenrauschen oder unsauberen Daten zu sein (Jarrett, Kavukcuoglu, Ranzato & LeCun, 2009).

Es sind mehrere *Pooling*-Operationen möglich, beispielsweise das *Sum-Pooling*, bei dem die Werte im Pooling-Filter aggregiert werden, das *Max-Pooling*, bei dem der größte Wert im Fokus der *Pooling*-Schicht genommen wird, das *Average-Pooling*, bei der der Durchschnitt aller Werte verwendet wird (Boureau, Ponce & LeCun, 2010), ein kombiniertes *Max/Average-Pooling* (Mishkin et al., 2016), ein geometrisches  $p$ -Norm-Pooling mit dem Parameter  $p$  (Zhang, X., Trmal, Povey & Khudanpur, 2014) oder weitere räumliche Operationen (Avila, Thome, Cord, Valle & Araújo, 2011, 2013; Boureau et al., 2010; Goodfellow, Warde-Farley,

Mirza, Courville & Bengio, 2013; Jarrett et al., 2009). Die parametrisierbare Größe des *Pooling-Layer* bestimmt dabei die residuale Ausgangsmatrix, da hierbei mehrere Felder der Eingabematrix zusammengefasst werden. Der Vorgang ist auch als *Downsampling* oder *Subsampling* bekannt (Bouvré, 2006, S. 3).

Mishkin et al. (2016) erstellte, bezogen auf die Bilderkennung, ein Benchmarking möglicher Pooling-Operationen und zeigte deutliche Unterschiede im Genauigkeitsmaß zwischen den einzelnen Varianten. Anders als bei diesem Vergleich wird in dieser Arbeit jedoch mit Textdaten gearbeitet. Aus diesem Grund wird die Pooling-Variante ebenfalls als Parameter in dieses Modell eingehen und es wird die am besten geeignete Operation gewählt und in der Modellkonfiguration angegeben. Unter den im Fokus der Parameterüberprüfung stehenden Operationen sind das *Max-Pooling*, das *Average-Pooling*, das *Sum-Pooling* und das *p-Norm-Pooling*, wobei für Letzteres eine quadratische Parametrisierung ( $P = 2$ ) verwendet wird. Die Pooling-Varianten sind nachfolgend in Abbildung 23, Abbildung 24, Abbildung 24 und Abbildung 26 dargestellt, wobei das farblich markiert Feld der Ausgangsmatrix das Ergebnis der farblich markierten Elemente der Eingabematrix unter Anwendung der jeweiligen Pooling-Operation darstellt.

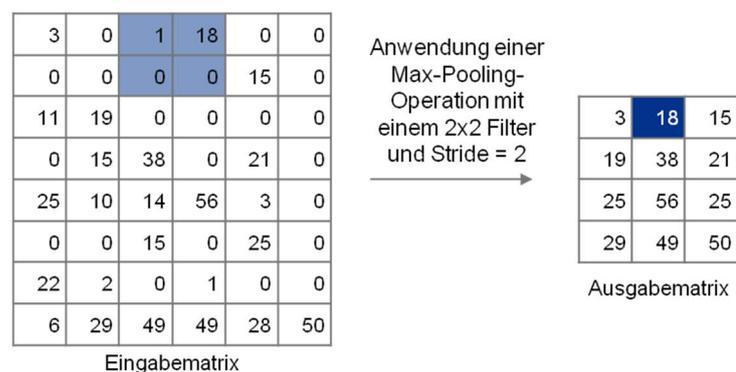


Abbildung 23: Anwendung einer Max-Pooling-Operation

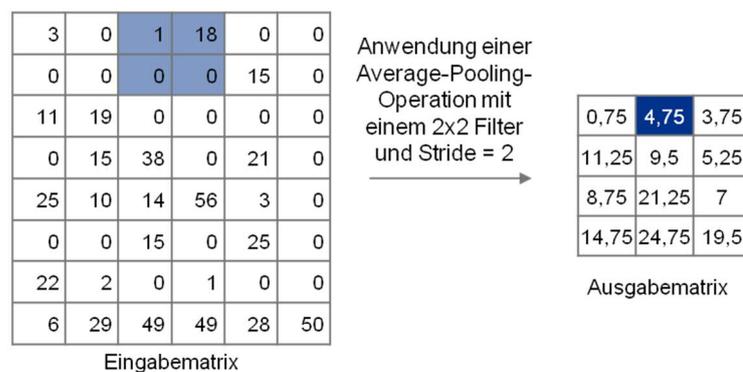


Abbildung 24: Anwendung einer Average-Pooling-Operation

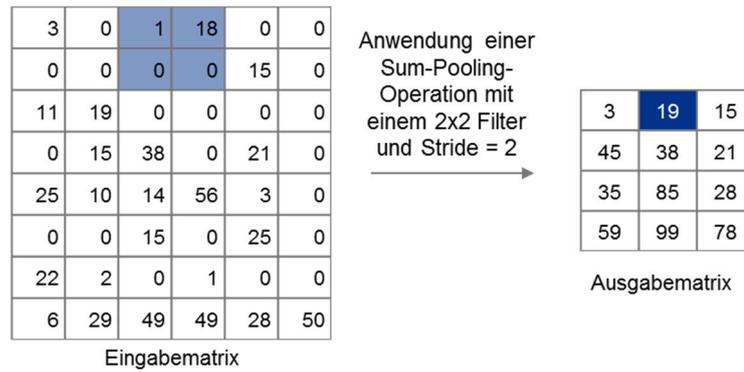


Abbildung 25: Anwendung einer Sum-Pooling-Operation

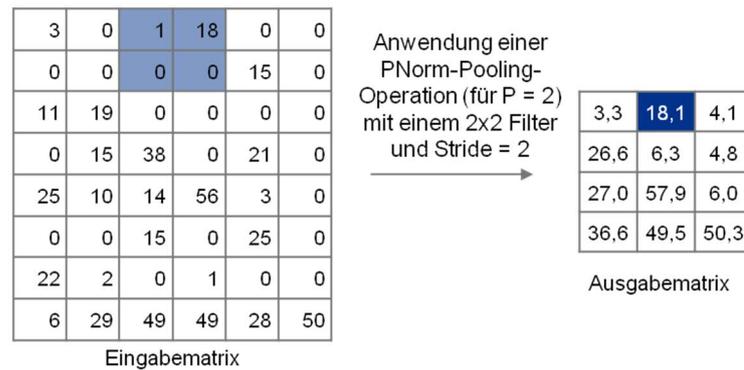


Abbildung 26: Anwendung einer p-Norm-Pooling-Operation

### 7.4.2.5 Klassifikationsschichten

In den bisher beschriebenen Schritten des CNNs wurden die Eingangsdaten unterbrochen, verdichtet und zu Datenmerkmalen aufbereitet (Ren, He, Girshick, Zhang & Sun, 2015). Um die verarbeiteten Informationen aus den vorangegangenen Prozessschritten einer Klasse zuzuordnen, wird ein Klassifikationsverfahren benötigt. Die finalen Klassifikationsschichten bestehen somit aus einem vollständig verbundenen neuronalen Netz und einer Ausgabeschicht, anhand derer die Kategorie eines Eingangsdatums abgelesen werden kann.

Das neuronale Netzwerk zwischen den Convolutional- bzw. Pooling-Schichten und der Ausgabeschicht ist vollständig verbunden. Dies bedeutet, dass jedes Neuron in diesem neuronalen Netz mit jedem Neuron der vorangegangenen und der nachfolgenden Ebene verbunden ist (Roy & Permenter, 2017). Bezogen auf die Bilderkennung, differenzieren Mishkin et al. (2016) die häufigsten Klassifikationsvarianten in ein- bzw. zweistufiges *Multi-Layer-Perceptron* (MLP), ein vor dem MLP gelagertes *Spatial-Pyramid-Matching* (He et al., 2014; Lazebnik, Schmid & Ponce, 2006) und ein *Average-Pooling-Layer* in Verbindung mit einer *Squashing-Spatial-Dimension* (Mishkin et al., 2016, S. 11). Dies ist in Abbildung 27 nochmals schematisch dargestellt.

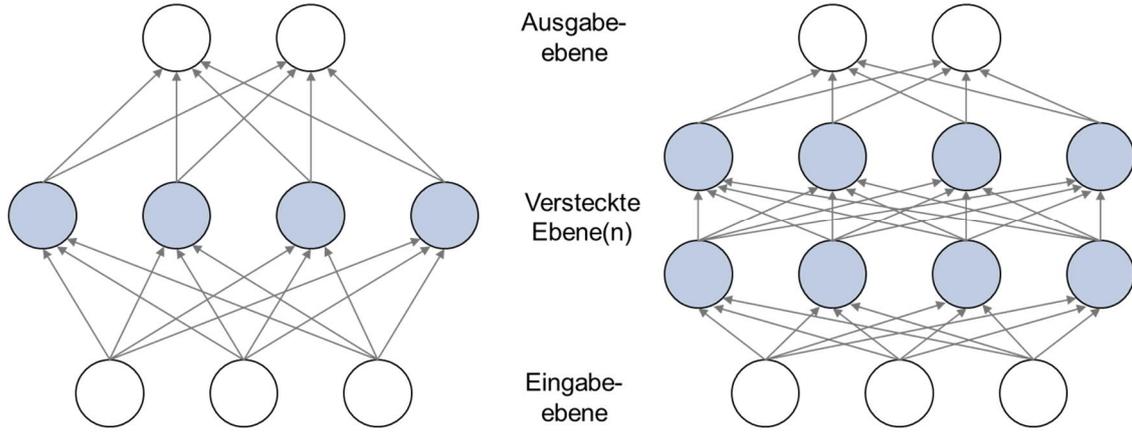


Abbildung 27: Ein- bzw. zweistufiges Multi-Layer-Perceptron

Die Eingabedaten  $x^{j-1} = x_1^{j-1}, \dots, x_i^{j-1}, \dots, x_{n_{j-1}}^{j-1}$  der Ebene  $j$  entsprechen dem Ergebnis der vorangegangenen Netzwerkschicht  $j - 1$  mit insgesamt  $n_{j-1}$  Neuronen. Im Sonderfall der Eingabeebene des MLP kommen die Eingabedaten aus dem Ergebnis der vorangegangenen *Convolutional*- und *Polling*-Operationen. In jedem Neuron an der Position  $i$  in der Ebene  $j$  werden alle Eingabedaten der davor liegenden Schicht  $x_k^{j-1}$  mittels eines Gewichtungsfaktors  $w_i^j$  und eines Verzerrungswerts  $b_i^j$  verarbeitet. Somit ist der erste Aggregationsschritt vorangegangener Daten eines Neurons formal (Nielsen, M., 2015; Spies, 1993):

$$s_i^j = \sum_{k=1}^n w_{ik}^j x_k^{j-1} + b_i^j, \quad (34)$$

wobei  $k$  der Position des Neurons auf der vorangegangenen Ebene  $j$  entspricht. Der zweite Schritt ist die Anwendung der Ausgabe- oder Aktivierungsfunktion  $f(s_i^j)$  im Sinne einer der in Kapitel 7.4.2.3 vorgestellten Verfahren. Oft wird diesbezüglich die Sigmoid-Aktivierungsfunktion verwendet (Nielsen, M., 2015). Das Ausgabedatum  $x_i^j$  der Ebene  $j$  an der Position  $i$  ist definiert als (Spies, 1993):

$$x_i^j = f\left(\sum_{k=1}^n w_{ik}^j x_k^{j-1} + b_i^j\right). \quad (35)$$

Beim Training des Modells werden alle Gewichte sowie Verzerrungswerte maschinell erlernt. Dies wird durch marginale Veränderungen von  $\Delta w_{ik}$  respektive  $\Delta b_i$  je Iterationsschritt erreicht (weiterführend dazu Kapitel 7.4.3.2). Formal kann dies durch folgende Gleichungen beschrieben werden (Nielsen, M., 2015):

$$\Delta w_{ik} = \alpha \cdot x_i^{j-1} (z_i - x_i), \quad (36)$$

$$\Delta b_i = \alpha \cdot (z_i - x_i), \quad (37)$$

wobei  $z_i$  die erwartete Ausgabe des Neurons  $i$  und  $\alpha$  die Lernrate darstellt, welche ein fester oder variabler Parameter ist; abhängig vom verwendeten Modell. Dieser Optimierungsvorgang benötigt eine Bemessungsgrundlage, deren Gradient die Richtung des nächsten maschinellen Lernschrittes vorgibt. Die mathematische Operation, die nach jedem Trainingsschritt des neuronalen Netzwerkes ausgeführt wird, erfolgt anhand der Minimierung einer sogenannten *Cost-Function* bzw. *Loss-Function* (LeCun, Bottou, Orr & Müller, 1998b). In Kapitel 7.4.3.2 wird dezidiert darauf eingegangen.

Als Abschluss des gesamten Konstrukts des neuronalen Netzes ergibt sich eine 11-dimensionale Ergebnisschicht, da 11 die Anzahl der Emotionsausprägungen nach Merten und Krause (1993) inklusive neutraler Kategorie ist. Als Ausgabeebene wird üblicherweise der SoftMax-Algorithmus verwendet (Nielsen, M., 2015). Dieser ordnet die Ergebnisse aller Eingabevektoren  $x$ , also in diesem Fall die Ausgabe des MLP, einer errechneten Klasse  $\hat{y}$  zu. Die Klassenzuordnungswerte sind im Intervall  $[0,1]$  anzusiedeln und die Summe aller Zuordnungswerte entspricht 1. SoftMax erfüllt damit die formalen Kriterien einer Wahrscheinlichkeitszuordnung und wird in den meisten Fällen auch als solche wahrgenommen.

Somit kann für jede vorhergesagte Klasse  $\hat{y}$  unter der Bedingung der im gesamten Modell errechneten Werte  $x$  eine Wahrscheinlichkeit ausgegeben werden:

$$p(y = \hat{y}_f | x) = \frac{e^{x^T w_i}}{\sum_{l=1}^{11} e^{x^T w_l}}. \quad (38)$$

Ist der Ergebniswert  $\hat{y}$  eines Neurons  $i$  am stärksten ausgeprägt, spricht dies im Kontext dieser Arbeit für das Erkennen der jeweiligen Emotion durch das neuronale Netzwerk. Stimmt der maximale Wahrscheinlichkeitswert von  $\hat{y}$  mit der tatsächlichen Klasse  $y$  überein, dann gilt dies hier als korrekt klassifiziert.

### 7.4.3 Konfiguration des neuronalen Netzwerkes

Bevor die Parametrisierung des Modells angegangen werden kann, müssen noch zwei wichtige Aspekte geklärt werden, die bisher unerwähnt blieben bzw. nur angedeutet wurden. Dies sind zwei Parametereinstellungen, die beim Training eines Modells angegeben werden können, um ein optimales Erlernen der Daten zu gewährleisten. Zum einen betrifft das den initialen Zustand des Netzwerkes, bevor der maschinelle Lernvorgang beginnt, zum anderen die Regulierung des neuronalen Netzwerkes, um ein Überlernen zu verhindern. Diese relevanten Aspekte sollen in den nächsten beiden Kapiteln erläutert werden, bevor die Konfiguration des CNNs vorgestellt wird.

### 7.4.3.1 Initialisierung

Die Initialisierung bezeichnet den Startpunkt, von dem aus das neuronale Netzwerk graduelle Anpassungen in iterativer Weise vornimmt. Eine gute Anfangsgewichtung bedeutet, dass der maschinelle Lernalgorithmus schneller in einem Optimum konvergiert bzw. bei einer festgelegten Anzahl an Trainingsepochen ein besseres Ergebnis generieren kann als ein vergleichsweise schlecht initialisiertes neuronales Netzwerk. Saxe, McClelland & Ganguli (2013) weisen auf die Bedeutung einer guten Initialisierung hin, wenngleich sie ein vorausgegangenes Training einem randomisierten Ansatz vorziehen. In dieser Arbeit wird jedoch kein vorausgelagertes Training durchgeführt. Im Folgenden sollen auszugswise die null- und die zufallsverteilte Initialisierung unter die Lupe genommen werden, wobei die ReLU-, Xavier-, und Sigmoid-Initialisierungen Vertreter der letztgenannten Kategorie sind.

Die Nullinitialisierung belässt alle netzwerkimmanenten Gewichte auf der numerischen Null. Sie ist gleichzusetzen mit einer Nicht-Initialisierung. Dies ist ein Beispiel für eine schlechte Initialisierung, da in dem Modell alle Gewichte von Grund auf erlernt werden müssen und somit deutlich mehr Trainingsiterationen notwendig sind, um in den Bereich einer brauchbaren Klassifikation zu kommen.

Bei der Zufallsinitialisierung werden die Gewichte anhand einer Verteilung festgelegt. Um eine Symmetrie zu wahren, kann unabhängig von der Verteilungskurve die numerische Null als zentraler Wert gewählt werden. Als Verteilung liegt meist eine Gleich- oder Normalverteilung zugrunde. Es sei an dieser Stelle anzumerken, dass zu einer Methode, auch wenn sie hier als gleich- oder normalverteilt beschrieben wird, häufig auch das andersartige Pendant existiert (vergleiche dazu z.B. Gibson, 2015).

Bei einer Normalverteilung liegt die Gauß'sche Glockenkurve zugrunde, weswegen neben dem Mittelwert auch ein Varianzwert für das Abweichungsverhalten hin zur Mitte angegeben werden muss. Als Mittelwert wird meist die numerische Null gewählt. Bezüglich der Varianz gibt es bei der Normalverteilungsmethode keine Vorgaben zu deren Größe. In dem CNN des ImageNet wurde dafür mit 0,01 jedoch ein sehr kleiner Wert gewählt (Krizhevsky, Sutskever & Hinton, 2012). Bei der ReLU-Initialisierung schlagen He et al. (2015b) bei einer zugrunde liegenden Gauß'schen Normalverteilung einen Mittelwert von null und eine Standardverteilung von  $\sqrt{\frac{2}{n}}$  vor, wobei  $n$  die Anzahl der Neuronen in der vorherigen Netzwerkschicht darstellt. Die Autoren empfehlen diese Methode für vielschichtige Modelle, beispielsweise ab acht Ebenen (He et al., 2015b). Weiter führen sie aus, dass diese Initialisierungsmethode auch bei tiefen neuronalen Netzwerken geeignet sei. Diese Art der Initialisierung wird in dieser Arbeit als

ReLU-Initialisierung bezeichnet (Gibson, 2015), entsprechend ihrer Benennung im zugrunde liegenden Deeplearning4j-Framework (Deeplearning4j Development Team, o. J.). Das gleichverteilte Pendant dazu wird als RELU UNIFORM geführt.

Die Gleichverteilung hingegen lässt alle Werte innerhalb einer Intervallgrenze zu, ohne dass Werte nahe der Mitte eine höhere Wahrscheinlichkeit aufweisen. Die Intervallgrenzen können jedoch an Bedingungen geknüpft werden. Eine uniforme oder gleichverteilte Initialisierung im Sinne von Glorot & Bengio (2010) setzt in jeder Ebene des neuronalen Netzwerkes die Gewichte auf einen ebenenabhängigen Standardwert. Die Intervallgrenzen hängen dabei mit der Position zusammen, an der sich ein Neuron im Netzwerk befindet, da diese von der Anzahl der Neuronen in der vorangegangenen Schicht beeinflusst werden. So wird beispielsweise eine gleichverteilte Zufallsvariable im Intervall  $\left[-\frac{1}{\sqrt{n}}, \frac{1}{\sqrt{n}}\right]$  als initialer Gewichtungswert gewählt, wobei  $n$  ebenfalls die Anzahl der Neuronen in der vorangegangenen Netzwerkschicht darstellt (Glorot & Bengio, 2010). Diese Art der Initialisierung wird später als UNIFORM bezeichnet (Gibson, 2015).

Auch die Xavier-Initialisierung verfolgt den Gedanken einer gleichverteilten Initialisierung, wobei als Intervall  $\left[-\sqrt{\frac{6}{n_l+n_{l+1}}}, \sqrt{\frac{6}{n_l+n_{l+1}}}\right]$  angegeben wird, während  $n_l$  und  $n_{l+1}$  für die Anzahl der Neuronen in der vorangegangenen bzw. der nachfolgenden Ebene stehen. Im Nachfolgenden wird diese Initialisierungsvariante als XAVIER-UNIFORM bezeichnet, da es auch eine normalverteilte Xavier-Verteilung gibt, die hier als XAVIER geführt wird (Gibson, 2015). Für Letztere empfehlen Glorot & Bengio (2010), ebenfalls unter Berücksichtigung der vorangegangenen und der nachfolgenden Neuronenanzahl, eine Varianz von  $\frac{2}{n_l+n_{l+1}}$ . Die Sigmoid-Initialisierung ist hingegen wieder gleichverteilt und stellt eine Variante der Xavier-Initialisierung dar, bei der Gewichtungswerte aus dem Intervall  $\left[-4\sqrt{\frac{6}{n_l+n_{l+1}}}, 4\sqrt{\frac{6}{n_l+n_{l+1}}}\right]$  zufällig gezogen werden (Gibson, 2015). Diese wird als SIGMIOD-UNIFORM geführt.

Im hier verwendeten Deeplearning4j-Framework stehen noch weitere initiale Gewichtsverfahren zur Verfügung (Deeplearning4j Development Team, o. J.). Es wird sich aber auf die oben genannten RELU, RELU-UNIFORM, XAVIER, XAVIER-UNIFORM, SIGMIOD-UNIFORM und UNIFORM konzentriert. Diese Wahloptionen werden als Parameter-einstellung in die Netzwerkkonfiguration einfließen, sie werden als solche verglichen und das geeignetste Initialisierungsverfahren wird ausgewählt.

### 7.4.3.2 Verlustfunktion und Optimierungsvorgang

Ein Optimierungsvorgang im Sinne des maschinellen Lernens ist eine iterative Verbesserung. Dazu sind zwei Komponenten notwendig, nämlich eine zu optimierende Funktion und ein dazugehöriges Optimierungsverfahren, das abhängig von einer Lernrate die modellimmanenten Parameter schrittweise optimiert. Die zu optimierende Funktion ist, wie oben bereits erwähnt, die Verlustfunktion, die dann einen minimalen Wert annimmt, wenn das neuronale Netz mit den Trainingsdaten in einem lokalen oder im günstigsten Fall einem globalen Optimum gelandet ist. Gängige Optimierungsverfahren für das maschinelle Lernen sind beispielsweise die mittlere quadratische Abweichung, die mittlere absolute Abweichung, die negative *Log-Likelihood*-Funktion oder die Kreuzentropie. Darüber hinaus existieren Verfahren wie *Hinge-Loss*, *Logistic Loss* oder *Square Loss* (Pei-Xia, Hui-Ting & Tao, 2016; Rosasco, Vito, Caponnetto, Piana & Verri, 2004) sowie *Histogram-Loss* (Ustinova & Lempitsky, 2016), um nur einige zu nennen. Allen Verlustfunktionen oder *Loss-Functions* ist gleich, dass sie eine umso kleinere reelle Kennzahl als Ergebniswert zurückliefern, je besser ein vorhergesagtes Modell mit den Trainingsdaten übereinstimmt.

Aus Gesichtspunkten der Fokussierung konzentriert sich die Arbeit auf die mittlere quadratische Abweichung (engl. „*Mean Squared Error (MSE)*“) (LeCun et al., 1998a, S. 9) und die Kreuzentropie als Verlustfunktion (Nielsen, M., 2015). Erstere wurde im ursprünglichen CNN verwendet und ist bei vielen neuronalen Netzwerken als Standard gesetzt. In der Verlustfunktion  $L_{\text{MSE}}$  werden die vom Klassifikator errechneten Klassen  $\hat{y}$  den tatsächlichen Klassen  $y$  gegenübergestellt. Die daraus resultierende reelle Zahl gibt Aufschluss über die Genauigkeit, mit der das neuronale Netz unter den modellimmanenten Einstellungen die aktuellen Trainingsdaten abbilden kann.

Aus formaler Sicht entspricht die mittlere quadratische Abweichung:

$$L_{\text{MSE}} = \frac{1}{N} \sum_{n=1}^N (\hat{y}_n - y_n)^2, \quad (39)$$

wobei  $N$  die Anzahl der bewerteten Daten ist. Problematisch kann hier die MSE-Verlustfunktion sein, da diese, anders als beim nachfolgenden Verfahren, leichter in einem lokalen Optimum hängenbleibt (Golik, Doetsch & Ney, 2013).

Bei der Bewertung von Wahrscheinlichkeitsverteilungen, in die sich eine Klassifikation einreihen lässt, wie am Ende des Kapitels 7.4.2.5 gezeigt wurde, kann die Kreuzentropie herangezogen werden. Die Verlustfunktion  $L_{\text{MCXENT}}$  der Kreuzentropie oder *Cross-Entropy* ist ähnlich wie die MSE-Verlustfunktion ein häufig anzutreffendes Verfahren. Die daraus

resultierende reale Kennzahl sagt aus, dass sich die zugrunde liegenden Werte der Vorhersage  $\hat{y}$  und die tatsächlichen Klassifikationswerte  $y$  (Reichel, 2010) umso ähnlicher sind, je kleiner ein Wert ist. Formal lässt sich die Kreuzentropie-Verlustfunktion ausdrücken als:

$$L_{\text{MCXENT}} = -\frac{1}{N} \sum_{n=1}^N y_n \log \hat{y}_n + (1 - y_n) \log(1 - \hat{y}_n). \quad (40)$$

Die Kreuzentropie hat zwei positive Eigenschaften, die sie für die Klassifikation besonders geeignet machen. Zum einen ist die soeben gezeigte Verlustfunktion stets positiv  $L_{\text{CE}} > 0$ . Zum anderen tendiert die Funktion gegen null, sofern die vorhergesagten Werte den Trainingsdaten entsprechen. Darüber hinaus hat die Kreuzentropie im Gegensatz zur mittleren quadratischen Abweichung den Vorteil, dass „it avoids the problem of learning slowing down“ (Nielsen, M., 2015). Sowohl Golik et al. (2013) als auch Kline & Berardi (2005) sprechen sich nach empirischen Versuchen für die Nutzung der Kreuzentropie und gegen die Verwendung der MSE-Verlustfunktion aus. Um unterschiedliche Herangehensweisen zu testen, werden in dieser Arbeit beide Methoden verwendet, also die Kreuzentropie, bezogen auf mehrere Klasseneinteilungen, sowie die mittlere quadratische Abweichung, die in der späteren Analyse unter den Bezeichnungen MCXENT bzw. MSE geführt wird.

Verlustfunktionen besitzen generell, wie oben angedeutet, die positive Eigenschaft, dass sie mit zunehmender Realitätsabbildung des Modells genauer werden. Dies wird dadurch erreicht, dass sie auf Ebene eines einzelnen Neurons eines neuronalen Netzwerkes ein berechenbarer Zustand und eine zuverlässige Annäherung an ein lokales Optimum entsprechend der Optimierungsfunktion herbeizuführen suchen. Bei jedem Iterationsschritt, bei dem eine Anpassung der modellimmanenten Gewichtungen vorgenommen wird, wird anhand der Ableitung der Verlustfunktion versucht, das lokale Minimum zu erreichen. Mathematisch ergibt sich damit ein Optimierungsproblem, das auf der rechnerischen Ebene der jeweiligen Neuronen eine Annäherung an ein lokales Optimum herbeizuführen sucht.

Diesbezüglich gibt es unterschiedliche Methoden oder Näherungsverfahren (ausführlich dazu Boyd & Vandenberghe, 2004; Papageorgiou, Leibold & Buss, 2015). In Verbindung mit CNNs werden Optimierungsaufgaben beispielsweise mittels *Hessian-free Optimization* (Cho, Dhir & Lee, 2015; Martens, 2010), *Limited-Memory-BFGS*, *Conjugate Gradient*, *Gradient-Descent* oder dessen approximiertem Pendant *Stochastic Gradient-Descent* realisiert (Le et al., 2011). Andere Varianten sind der Pseudo-Newton-Algorithmus (Becker & LeCun, 1989), die *Saddle-Free-Newton-Methode* (Dauphin et al., 2014), der *Stochastic-Average-Gradient-Ansatz*

(Schmidt, Le Roux & Bach, 2013) oder ein kombinierter *Sum-of-Functions-Optimizer* (Sohl-Dickstein, Poole & Ganguli, 2013), die hier jedoch alle nur erwähnt bleiben.

Ebenfalls aus Gründen der Fokussierung wird hier das *Stochastic-Gradient-Decent* (SGD)-Verfahren angewendet, das eines der am häufigsten verwendeten Verfahren in maschinellen Lernen darstellt. Die Verlustfunktion bzw. die damit einhergehenden Gewichtungsfaktoren und die Verzerrungswerte werden anhand der Trainingsdaten und des SGD-Verfahrens, das hier nicht detaillierter ausgeführt wird, iterativ optimiert (weiterführend dazu Bottou, 2010; LeCun et al., 1998a). Zahlreiche Erweiterungen können das Optimierungsverfahren zur Auffindung des globalen Optimums verbessern, beschleunigen bzw. die Lernrate des Modells dynamisch anpassen. Für den iterativen Parameteraktualisierungsschritt des SDG stehen beispielsweise durch Momentum (Sutskever, Martens, Dahl & Hinton, 2013), AdaGrad (Duchi, Hazan & Singer, 2011), AdaDelta (Zeiler, 2012), RPROP (Riedmiller & Braun, 1993), RMSPROB (Hinton, Srivastava & Swersky, 2016) oder ADAM (Kingma & Ba, 2014) Erweiterungen zur Verfügung.

Beim Momentum wird beim Optimierungsvorgang das Wissen über die Richtungen aus vorangegangenen Schritt berücksichtigt und mit der im aktuellen Schritt errechneten Steigung kombiniert (Polyak, 1964; Sutskever et al., 2013). Bei AdaGrad wird der SDG durch zusätzliche adaptive Lernraten je Parameter erweitert, wobei die drastische Lernrate unterdrückt und Parameter mit wenigen Aktualisierungen vergrößert werden (Duchi et al., 2011). Neben einer trägeren Verringerung der Lernrate berücksichtigt AdaDelta (Zeiler, 2012) im Gegensatz zu AdaGrad nicht alle bisher gesehen Trainingsdaten, sondern nur einen kleineren Ausschnitt davon. Außerdem verhindert eine Regulierung, dass extreme Werte zu ungewünscht starken Veränderungen der Lernrate führen. Die Methoden RPROP (Riedmiller & Braun, 1993) und RMSPROP (Hinton et al., 2016) passen die Lernraten, ähnlich wie AdaDelta, auf Basis der Übereinstimmung der beiden Vorzeichen des aktuellen und des letzten Gradienten an. Im Gegensatz zur RPROP kann RMSPROB mit einer *Batch*-Regularisierung kombiniert werden (Ioffe & Szegedy, 2015). ADAM sowie AdaMax, eine Spezialform von ADAM, erweitern RMSPROB derart, dass das Momentum bereits inkludiert ist und darüber hinaus das Momentum erster und zweiter Ordnung berücksichtigt wird. Zusätzlich findet, im Vergleich zum RMSPROB, ein Verzerrungswert Eingang in die Erweiterung des statistischen Optimierungsverfahrens (Kingma & Ba, 2014).

### 7.4.3.3 Regularisierung

Ein neuronales Netzwerk wie das CNN stellt ein nichtlineares Verfahren dar und kann beliebige Kurvenverläufe einer Funktion approximieren (Nielsen, M., 2015). Die nahezu identische Abbildung einer zu erlernenden Funktion ist jedoch nur bedingt erfolgversprechend, da dies zwar für die Trainingsdaten zu exzellenten Ergebnissen führt, aber mit neuen Datensätzen problematisch ist. Im diesem Zusammenhang wird auch von *Overfitting* oder dem Überanpassen des Trainingsalgorithmus gesprochen (Goodfellow, Bengio & Courville, 2016). Eine entsprechende Regularisierung ist ein entscheidender Schritt, um diesem Problem zu begegnen. Damit ein maschineller Lernalgorithmus generalisiert, statt optimal auf die Trainingsdaten angepasst zu sein, gibt es verschiedene Ansätze. Erreicht wird dies beispielsweise durch die Begrenzung der Verlustfunktion oder durch *Noise-Injection* (Poole, Sohl-Dickstein & Ganguli, 2014).

Zwei häufig verwendete Verfahren sollen hier vorgestellt werden, da diese Anwendung im Modell finden. Das erste Verfahren der Regularisierung setzt direkt beim Optimierungsvorgang an. Die zweite Regularisierung arbeitet durch das Einfügen von Datenrauschen.

Mittels einer L1- und L2-Regularisierung wird direkt beim Optimierungsverfahren eingegriffen. Dies wird dadurch erreicht, dass in der oben genannten Verlustfunktion ein zusätzlicher Regularisierungswert addiert wird (Goodfellow et al., 2016). Dieser Regularisierungsterm ist abhängig von den im neuronalen Netzwerk verwendeten Gewichten und entspricht  $\frac{1}{2} \lambda |w|$  bei der L1-Regularisierung bzw.  $\frac{1}{2} \lambda w^2$  bei der L2-Regularisierung, wobei  $\lambda$  der Parameter für die Gewichtungintensität und  $w$  die jeweilige Gewichtung im Modell ist. Die Regularisierung bestraft Gewichte innerhalb eines neuronalen Netzwerkes, indem sie die Summe der absoluten bzw. quadrierten Fehlerwerte hinzufügt (McCaffrey, 2015). Beide Regularisierungen können unabhängig voneinander verwendet oder auch kombiniert werden (Zou & Hastie, 2005). In dieser Arbeit wird jedoch nur die L2-Regularisierung genutzt.

Die zweite Möglichkeit der Regulierung, die Anwendung findet, ergibt sich durch das Einfügen von Datenrauschen. Der hier für das Training verwendete Ansatz ist *Dropout* (Srivastava, Hinton, Krizhevsky, Sutskever & Salakhutdinov, 2014). Dabei wird mittels eines Modellparameters  $p$  eine Wahrscheinlichkeit angegeben, mit der ein Neuron während eines Trainingsschrittes aktiv ist. Diese Methode verhindert, dass das neuronale Netz Entscheidungen nur aufgrund weniger starker Neuronen trifft. Da diese bei der Trainingsphase nur mit einer bestimmten Wahrscheinlichkeit zugeschaltet sind, lernt der Algorithmus länger und damit weniger dominante Merkmale.

Andere Regularisierungsverfahren, die in eine ähnliche Richtung gehen, seien hier auszugswise erwähnt, werden aber nicht verwendet. Dazu gehören z. B. *Whiteout* (Li, Y. & Liu, 2016), eine Regularisierung der Bild- und Mustererkennung, bei der weißes Rauschen eingefügt wird, oder auch *shakout* (Kang, Li & Tao, 2016), das die Gewichtungen wahrscheinlichkeitsabhängig leicht verstärkt oder als Bruchteil ins Gegenteil verkehrt. Weitere Vertreter dieser Kategorie sind *DropConnect* (Wan, Zeiler, Zhang, LeCun & Fergus, 2013), bei dem Aktivierungen während des Trainings wahrscheinlichkeitsbedingt ignoriert werden, oder andere, häufig verwendete Methoden wie die *Batch-Normalization* (Ioffe & Szegedy, 2015), *Stochastic Pooling* (Zeiler & Fergus, 2013), die *Max-Norm-Regularisierung* (Lee, J., Recht, Salakhutdinov, Srebro & Tropp, 2010; Rennie & Srebro, 2005; Srebro & Shraibman, 2005) oder *Early Stopping* (Yao, Rosasco & Caponnetto, 2007).

#### **7.4.3.4 Parametrisierung**

Bei der Parameterfindung wird analog zu dem CNN-basierten Versuchsaufbau von Tripathi et al. (2017) anhand mehrerer durchgeführter Testläufe die optimale Konfiguration des neuronalen Netzes gesucht. Die Grundlage dafür bilden die Trainings- und Validierungsdatensätze, deren Unterscheidung in Kapitel 8.1 näher erläutert wird. Konfigurationseinstellungen, die noch nicht Teil der Hypothesenüberprüfung waren, werden ebenfalls für den optimalen Bestimmungsprozess der Parameter herangezogen. Die Konfiguration orientiert sich an Empfehlungen von Srinivas et al. (2016) sowie mehrere tausend im Vorfeld durchgeführte Testläufe zur Eingrenzung zielführender Wertintervalle für eine Parameterwahl.

## 8 Evaluation

Um unterschiedliche Herangehensweisen und Modelle zu vergleichen, sind sowohl ein Referenzdatensatz notwendig, auf dem das Modell angewendet wird, als auch eine einheitliche Metrik. Im Folgenden soll zuerst auf den Umgang mit dem annotierten Datensatz unter Berücksichtigung der unterschiedlichen Methoden eingegangen werden. Anschließend werden die hier verwendeten Beurteilungskriterien vorgestellt.

### 8.1 Referenzdatensatz

#### 8.1.1 Ansätze der Evaluierungsverfahren

Als Referenz wird der von Menschen annotierte Datensatz oder Goldstandard herangezogen. Die beiden hier verwendeten Ansätze unterscheiden sich bezüglich der Menge der in die Evaluation einfließenden Daten. Bei der lexikonbasierten Herangehensweise und beim maschinellen Lernvorgang werden Daten zum Optimieren des Schwellenwerts bzw. zum Trainieren des neuronalen Netzwerkes benötigt. Dies schränkt die Grundgesamtheit der zur Verfügung stehenden Daten im Evaluationsprozess ein, da die Datensätze aufgeteilt werden müssen. Han und Kamber (Han, J. & Kamber, 2006) unterscheiden bei der Klassifikation mit der *Holdout*-, der *Cross-Validation*- und der *Bootstrap*-Methode drei gängige Evaluierungsverfahren.

Bei der *Holdout*-Methode werden die Datensätze zufällig auf zwei bzw. drei Gruppen aufgeteilt. Üblicherweise wird eine Partitionierung in Trainings- und Testdaten vorgeschlagen (Han, J. & Kamber, 2006, 2006; Witten, Frank & Hall, 2011). Dabei wird das Modell anhand der Trainingsdaten optimiert. Am Ende des Trainings und mit Fixierung aller Parameter und Einstellungen wird der Testdatensatz zur finalen Bewertung herangezogen. Andere Autoren wie Ripley (2005, S. 354) gehen noch einen Schritt weiter und unterteilen alle Datensätze, die nicht für die Evaluierung gedacht sind, in Trainings- und Validierungsdaten. Zwar stehen für das Training weniger Beispiele zur Verfügung, doch der Vorteil ist, dass die Parameter des neuronalen Netzwerkes einer Feintuning unterzogen werden können.

Die *k-Fold-Cross-Validation* separiert die Datensätze zufallsbedingt in  $k$  gleich große Gruppen. Beim Evaluationsvorgang wird jeweils einer dieser partitionierten Datensätze herausgelassen, um ähnlich wie bei der *Holdout*-Methode als Testdatensatz zu fungieren (Han, J. & Kamber, 2006, S. 364). Dieser Vorgang wird  $k$  Mal wiederholt, so dass jede Teilmenge des annotierten Datensatz einmal anhand der verbleibenden Trainingsdaten bewertet wurde. Aus den Ergebnissen der Einzelbewertungen wird ein Mittelwert erstellt, mit dem Ziel, alle Datensätze

für den Evaluationsvorgang zu berücksichtigen und so mit dem Modell näher an der Realität zu sein (Forman & Scholz, 2010).

Die *Bootstrap*-Methode unterscheidet sich von den vorangegangenen Methoden darin, dass ihr eine andere Zufallsauswahl zugrunde liegt und Daten mehrfach für den Trainingsvorgang ausgewählt werden können. Der Trainingsdatensatz wird aus allen annotierten Daten in  $n$  Schritten zufällig und anhand einer Gleichverteilung von  $p = \frac{1}{n}$  gezogen, wobei  $n$  üblicherweise auch der Anzahl an annotierten Beispielen entspricht. Damit eine Partitionierung stattfindet, liegt als Wahrscheinlichkeitsmodell ein Ziehen mit Zurücklegen zugrunde (Han, J. & Kamber, 2006).

### 8.1.2 Festlegung des Evaluierungsverfahrens

Aufgrund der relativ geringen Anzahl annotierter Datensätze bietet sich das Kreuzvalidierungsverfahren an, da es extreme Ausschläge einzelner Evaluierungsschritte nivelliert (Forman & Scholz, 2010). In dieser Studie wird sich jedoch aus praktischen Gesichtspunkten nur für die erstgenannte Methode der Partitionierung in Trainings-, Validierungs- und Testdaten entscheiden. Der Grund dafür liegt in der statistischen Überprüfung der Hypothesen und der Ermittlung der optimalen Konfiguration. Durch die Erfüllung unterschiedlicher Anforderungen und die Variation mehrerer Parameterkonstellationen wird exzessiv vom Validierungsdatensatz Gebrauch gemacht. Die *Holdout*-Methode erlaubt in diesem Zusammenhang eine flexible und zielführende Aufteilung der Daten.

Für den lexikalischen Ansatz muss nur ein parametrisierter Schwellenwert optimiert werden. Aus diesem Grund ist es ausreichend, wenn die annotierten Texte in Trainings- und Testdatensätze aufgeteilt werden. Der Grenzwert, der festlegt, ab welchem aggregierten Meinungswert kein neutraler, sondern ein emotiver Satz vorliegt, wird anhand der Hälfte der Daten bestimmt. Dies bedeutet, dass Datensätze jeder Meinungskategorie für sich genommen zufällig und gleichverteilt dem Trainings- und Testdatensatz zugeordnet werden.

Es wurde bereits erwähnt, dass der Validierungsdatensatz eine entscheidende Rolle in der Parameteroptimierung für das neuronale Netzwerk spielt. Aus diesem Grund wird hier eine Aufteilung des Datensatzes in 50 % Trainingsdaten, 20 % Validierungsdaten und die restlichen 30 % für den Testdatensatz als zielführend erachtet.

## 8.2 Beurteilungskriterien der Klassifikation

### 8.2.1 Bewertungsmetriken

Wie bereits erwähnt, wird bei einer Klassifikation jedem der  $n$  Datensätze  $x \in X$  eine der  $m$  Klassen  $y \in Y$  zugeordnet. Wird dem Klassifikator ein Datensatz übergeben, so nimmt dieser eine Zuordnung  $\hat{y} \in Y$  vor. Abhängig davon, ob die tatsächliche Kategoriezugehörigkeit der Zuordnung durch den Klassifikator entspricht, also ob  $y = \hat{y}$  oder  $y \neq \hat{y}$  ist, wird dies entsprechend in die *Confusion-Matrix* oder Konfusionsmatrix einsortiert (Ting, 2017, S. 260).

Diese setzt sich wie folgt zusammen (Manning et al., 2008):

	Kategorie $y$ zugehörig	Kategorie $y$ nicht zugehörig
richtig klassifiziert	richtigerweise als zugehörig klassifiziert ( $tp$ )	fälschlicherweise als zugehörig klassifiziert ( $fp$ )
falsch klassifiziert	fälschlicherweise als nicht zugehörig klassifiziert ( $fn$ )	richtigerweise als nicht zugehörig klassifiziert ( $tn$ )

Tabelle 50: Konfusionsmatrix der Klassifikationsergebnisbewertung

Anhand eines Abgleichs der durch das Verfahren klassifizierten Datensätze und der manuell annotierten Zuordnungen werden die jeweils zutreffenden Fälle  $tp$ ,  $tn$ ,  $fp$  und  $fn$  entsprechend Tabelle 50 zugeordnet. Über eine Vielzahl von bewerteten Bewertungsvorgängen kann eine Aussage über die Güte des Klassifikators getroffen werden. Dazu werden die Klassifikationsergebnisse einer Bewertungsfunktion übergeben. Es sei an dieser Stelle erwähnt, dass es zahlreiche Bewertungsfunktionen für Klassifikatoren gibt, beispielsweise *Accuracy*, *Confidence*, *Fallout*, *F-Measure*, *Jaccard*, *Miss Rate*, *Specificity*, *Sensitivity*, *Precision*, *Recall* oder Kombinationen davon (Powers, 2011, S. 38f.). Die vorliegende Arbeit stützt sich jedoch nur auf die gängigen Beurteilungskriterien *Accuracy*, *Precision*, *Recall* und das  $F_1$ -Maß. Diese definieren sich wie folgt (Manning et al., 2008):

$$\text{Accuracy} = \frac{1}{n} \sum_{i=1}^n \frac{tp_i + tn_i}{tp_i + tn_i + fp_i + fn_i} \quad (41)$$

$$\text{Precision} = \frac{1}{n} \sum_{i=1}^n \frac{tp_i}{tp_i + fp_i} \quad (42)$$

$$\text{Recall} = \frac{1}{n} \sum_{i=1}^n \frac{tp_i}{tp_i + fn_i} \quad (43)$$

$$F1 = \frac{(2 \cdot \text{Precision} \cdot \text{Recall})}{\text{Precision} + \text{Recall}} \quad (44)$$

In dieser Arbeit liegt keine binäre Zuordnung vor, sondern es wird eine Klassifikation zwischen allen Emotionen inklusive der neutralen Klasse vorgenommen. Somit erweitert sich die Konfusionsmatrix um alle möglichen Zuordnungs- und Klassifikationskombinationen zu einer Kontingenztabelle. Um die Beurteilungsmaße auf einen Bewertungsvorgang mit multiplen Klassen anzuwenden, wird entweder der *Micro-Average* oder der *Macro-Average* der Bewertungsfunktion benötigt (Yang, Y., 1999, S. 70). Beim *Micro-Average* wird zuerst der Durchschnitt aller Ausprägungen der jeweils zutreffenden Fälle  $tp$ ,  $tn$ ,  $fp$  und  $fn$  gebildet, um dann die Bewertungsfunktion zu ermitteln. Beim *Macro-Average* wird das Beurteilungskriterium zuerst berechnet und anschließend wird gemittelt, so dass alle  $m$  Emotionsklassen sowie die neutrale Klasse gleichgewichtet werden. Anhand der *Precision* soll der Vorgang formal erläutert werden (Tsoumakas, Katakis & Vlahavas, 2010):

$$\text{Precision}_{\text{micro}} = \frac{1}{n} \sum_{i=1}^n \frac{\frac{1}{m} \sum_{j=1}^m tp_{i,j}}{\frac{1}{m} \sum_{j=1}^m tp_{i,j} + \frac{1}{m} \sum_{j=1}^m fp_{i,j}}, \quad (45)$$

$$\text{Precision}_{\text{macro}} = \frac{1}{m} \sum_{j=1}^m \frac{1}{n_j} \sum_{i=1}^{n_j} \frac{tp_{i,j}}{tp_{i,j} + fp_{i,j}}. \quad (46)$$

## 8.2.2 Festlegung der Beurteilungskriterien und des Evaluationsframeworks

Die Auswahl an Bewertungsfunktionen wurde bereits auf *Accuracy*, *Precision*, *Recall* und das  $F_1$ -Maß eingegrenzt. Im Folgenden soll begründet werden, warum der  $F_1$ -Wert als das zu optimierende Gütekriterium herangezogen wird. *Accuracy* kann durch das große Ungleichgewicht der Klassenaufteilungen zu Verzerrungen führen. Auch *Precision* und *Recall* bilden einzeln betrachtet nur einen kleinen Teil der Wahrheit ab, da sie entweder falsche Klassifizierungen außer Acht lassen oder nicht die Gesamtheit der relevanten Datensätze berücksichtigen. Daher bietet das  $F_1$ -Maß, das aus dem harmonischen Mittel von *Precision* und *Recall* gebildet wird, das entscheidende Kriterium. Es kann nur dann maximal werden, wenn sowohl *Precision* als auch *Recall* gleichzeitig einen hohen Wert annehmen.

Zur Evaluation wurde der integrierte Evaluierungsmechanismus von Deeplearning4j verwendet (Gibson, 2018) bzw. für das Labelpropagationsverfahren entsprechend nachgebildet. Bei der Betrachtung mehrerer Klassen können Sonderfälle auftreten, die unter Verwendung des *Macro-Average* bei dieser Implementierung die Beurteilungsmaße verzerren. Dies tritt dann ein, wenn während des gesamten Bewertungsvorgangs eine oder mehrere Klassen überhaupt nicht klassifiziert wurden. In diesem Fall ist für diese Klassen aufgrund der Division durch null keine Berechnung des *Precision*-Werts möglich. Dieser wird nicht durch die numerische Null

ersetzt, sondern unter Ausgabe eines Hinweises aus der Berechnung des *Macro-Average* herausgenommen. Folglich kann der *Precision*-Wert höher erscheinen, was eine Verzerrung darstellt.

Die Berechnung der *Recall*- und der *F1*-Klassenwerte wird in diesem Evaluationsframework trotzdem durchgeführt und für den jeweiligen Evaluationsvorgang dieser Emotion wird jeweils der numerische Wert null errechnet bzw. angegeben. Somit betrifft die Verzerrung nur *Precision*-Werte, findet jedoch nicht auf Basis der *Macro-Average*-Werte des zuvor als ausschlaggebend definierten F1-Maßes statt.

### 8.3 Statistische Überprüfung der Ergebnisse auf Signifikanz

Im Rahmen der Hypothesenbestimmung wurden zahlreiche Testreihen mit unterschiedlichen Konfigurationen durchgeführt. Die gewählten Parameter bezogen sich auf die oben genannten Aspekte bzw. auf modellimmanente Schwellwerte. Alle Einstellungen wurden zwischen den verfügbaren Auswahloptionen und bei numerischer Parametrisierung innerhalb der gesteckten Grenzen variiert. Eine Übersicht dazu findet sich in Kapitel 9. Jede Konfiguration wurde zufällig aus den Kombinationen aller möglichen Parameterkonstellationen ausgewählt und zusammen mit den Ergebniswerten gespeichert. Somit steht für die Überprüfung der jeweiligen Hypothesen eine Vielzahl an Versuchsergebnissen für das CNN sowie für das Labelpropagationsverfahren zur Verfügung.

Um eine verlässliche Aussage über den Einfluss von Einstellungen oder unterschiedlichen Verarbeitungsschritten zu erhalten, wird ein Signifikanztest durchgeführt. Das Ziel dabei ist es nicht, im Einzelfall das beste Ergebnis zu erzielen, sondern den Einfluss von Eingabevariablen für die Emotionsbestimmung zu messen. Damit die Signifikanzüberprüfung im Kontext der Textklassifikation angewendet werden kann, wird auf die Ergebniswerte und deren zugehörige Konfigurationen zurückgegriffen, wobei je nach Fragestellung der Hypothese andere Einstellungsmerkmale gegenübergestellt werden. Alle Einstellungen, die nicht wegen der Überprüfung von Hypothesen gezielt festgelegt wurden, sind das Ergebnis einer Zufallsstichprobe und somit uniform verteilt. Alle Signifikanztests werden ausschließlich auf die F1-Maße der Modellergebnisse der jeweiligen Konfiguration angewendet.

Zur Berechnung der Signifikanzwerte werden gängige Testverfahren zur Signifikanzüberprüfung verwendet. In der aktuellen Forschung sind bei dieser Art der Überprüfung auch Methoden wie verallgemeinerte lineare Modelle (Nelder & Wedderburn, 1972) oder auf Entscheidungsbäumen basierende Random-Forest (Ho, 1995) mit Bezugnahme auf die *Variable-Importance* (Greenwell, Boehmke & McCarthy, 2018; Strobl, Boulesteix, Kneib, Augustin &

Zeileis, 2008) denkbar, ohne dass *a priori* eine Hypothesenaufstellung durchgeführt wird. Da in dieser Arbeit explizit Fragestellungen herausgearbeitet und dafür Hypothesen aufgestellt wurden, werden gängige und im Forschungsfeld der Psychologie akzeptierte Standardmethoden herangezogen. In Betracht gezogen wurden ein Zweistichproben-t-Test bzw. ein Wilcoxon-Rangsummentest für die Gegenüberstellung zweier Verteilungen und eine Varianzanalyse sowie ein Kruskal-Wallis-Test für die Differenzierung mehrerer Verteilungen (Bortz & Schuster, 2010). Um zu überprüfen, ob ein parametrischer Test verwendet werden darf, wurde für alle zu überprüfenden Datensätze ein Shapiro-Wilk-Test durchgeführt (Shapiro & Wilk, 1965). Letzterer zeigt an, ob eine Normalverteilung angenommen werden kann. Für alle Teildatensätze, die für die Hypothesenüberprüfung verwendet wurden, ergab der Shapiro-Wilk-Test ein signifikantes Ergebnis, was bedeutet, dass die zugrunde liegende Verteilung nicht normalverteilt ist. Der Varianzanalyse wird eine gewisse Robustheit hinsichtlich der Verletzung der Nicht-Normalverteilung zugeschrieben (Field, 2011), dennoch wird hier gänzlich auf die nichtparametrischen Signifikanzüberprüfungen gesetzt. Der Wilcoxon-Rangsummentest und der Kruskal-Wallis-Test basieren auf einem ähnlichen Prinzip, bei dem die intervallskalierten Ergebnisse in eine Rangfolge umgewandelt und dann verarbeitet werden (Kruskal & Wallis, 1952; Wilcoxon, 1945). Als Post-hoc-Analyse wird durchgehend der Dunn-Test mit Bonferroni-Korrektur verwendet (Dunn, 1964; Haynes, 2013). Die hier genannten Tests gehören in der Psychologie zum Standardrepertoire. Daher wird an dieser Stelle weiterführend auf die einschlägige Standardliteratur verwiesen (Bortz & Schuster, 2010; Field, 2011).

Die zufällige Auswahl der Parameter und die Vielzahl der durchgeführten Tests erzeugen eine hohe Validität. Die statistische Überprüfung mittels Signifikanztests stellt eine probate und wissenschaftlich akzeptierte Herangehensweise dar. Aufgrund der Permutation aller möglichen Konfigurationen ist es nicht möglich, alle Einstellungen zu testen. Durch das Randomisieren der Konfigurationen soll sichergestellt werden, dass keine Stichprobenverzerrung vorliegt (Cortes, Mohri, Riley & Rostamizadeh, 2008).

Für die Signifikanztests wurden aufgrund der Vielzahl der benötigten Analyseergebnisse keine konvergierten Modelle verwendet. Für alle CNN-Analysen wurden insgesamt zehn Epochen berechnet und danach gestoppt. Bei der Näherung des *Label-Propagation*-Verfahrens wurde nach fünf Matrixmultiplikationen bzw. Durchläufen gestoppt.

## 9 Prozessuale Zusammenfassung der Datenverarbeitung

In diesem Kapitel werden alle genannten Verarbeitungsschritte übersichtlichshalber in eine prozessuale Darstellung gebracht. Rechtecke symbolisieren Prozessschritte, Parallelogramme entsprechen berechneter Modelle, Datenbank- und Dokumentsymbole stehen für gespeicherte Daten bzw. für manuell erstellte Listen.

Oberhalb der Prozesskette befinden sich die Eingangsdaten und darunter die Ausgangsdaten. In Abbildung 28 wird der Grundstein mit der Akquise der Links für die Nachrichtenkommentare gelegt, wobei pro Nachrichtenportal ein eigens dafür konzipierter Web-Crawler verwendet wurde.

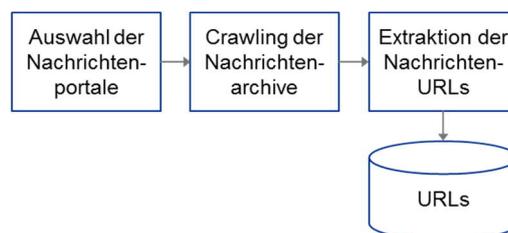


Abbildung 28: Prozess der Linksammlung

Die gesammelten URLs werden ebenfalls in einen speziell konstruierten Web-Scraper eingegeben. Dieser liest nur Kommentare und Metadaten. Als Ergebnis werden nur vereinzelte Snippets gespeichert, wie in Abbildung 29 dargestellt.

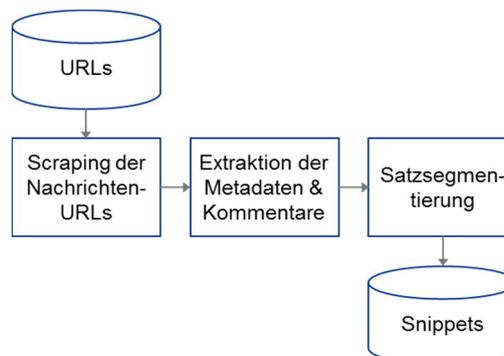


Abbildung 29: Prozess des Herunterladens der Datenbasis

Abbildung 30 skizziert den Auswahl- und Annotationsprozess der Daten. Dieser Vorgang ist in Kapitel 4 ausführlich beschrieben.

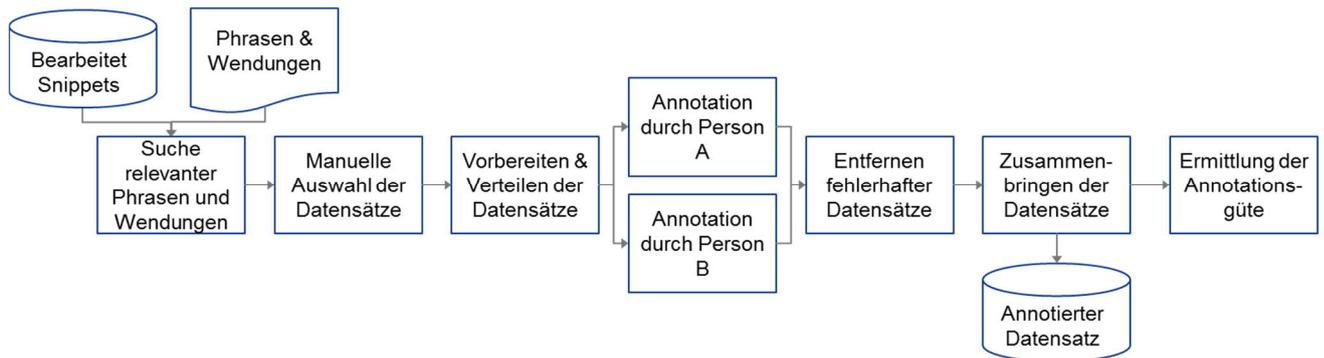


Abbildung 30: Prozess der Datenannotation

Die Snippets und das zuvor genannte zusätzliche Korpus aus Büchern und Wikipediaartikeln werden anhand der Verarbeitungsschritte in Abbildung 31 bearbeitet. Abstrahiert sind darin enthalten die Datenexklusion aus Kapitel 7.1.1 sowie vereinzelte stringbasierte Datenbereinigungsmethoden wie die Entfernung von Zeichendopplungen aus Kapitel 7.1.3.1 und die Datenharmonisierung aus Kapitel 7.1.4, darüber hinaus die Datentrennungen der Tokenisierung aus Kapitel 7.1.2.1 und die Datentrennungen innerhalb eines Wortes aus Kapitel 7.1.2.2. Auf Tokenebene werden die restlichen genannten Datenbereinigungsschritte aus Kapitel 7.1.3 durchgeführt. Schließlich wird abhängig von der Art des zu überprüfenden Datensatzes die Merkmalsanreicherung bzw. die Merkmalsreduktion in Form einer Wort- oder Wortstammverwendung aus Kapitel 7.1.5 angewendet. Das Ergebnis ist ein aggregierter Korpus, der sowohl die Snippets als auch das zusätzliche, bearbeitete Textmaterial beinhaltet. Dasselbe Verfahren wird auch für die Teilmenge der annotierten Snippets durchgeführt, die dann am Ende dieses Vorgangs als bearbeiteter, annotierter Datensatz vorliegen.

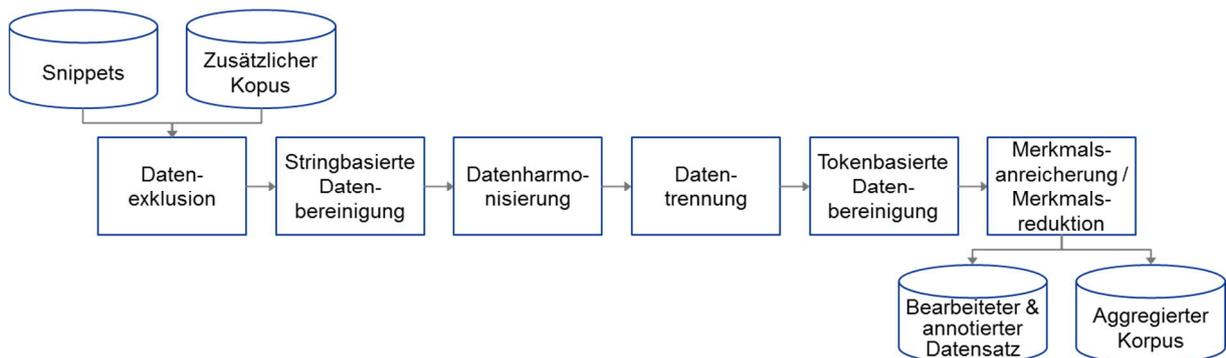


Abbildung 31: Prozess der Datenvorverarbeitung

Die Ansammlung an unterschiedlich reduzierten und angereicherten Korpusen wird als externe Wissensrepräsentation in Form eines *Word-Embedding* berechnet. Dieser einfache Vorgang mit den Word2Vec-Modellen als Ergebnis ist in Abbildung 32 dargestellt.

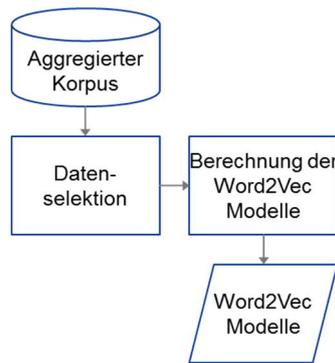


Abbildung 32: Prozess der Erstellung der externen Wissensrepräsentation

Mit Hilfe des semiüberwachten Lernvorgangs des Labelpropagationsverfahrens werden erweiterte Wortlisten erstellt. Wie in Abbildung 33 dargestellt, werden dazu die Schlüsselwörter der verwendeten Emotionstheorie sowie die Informationen über die semantischen Ähnlichkeiten aus der externen Wissensrepräsentation benötigt.

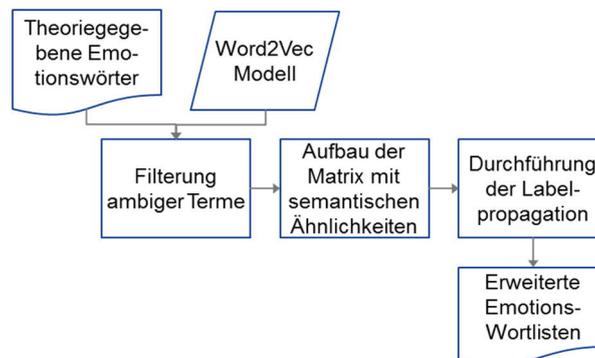


Abbildung 33: Prozess der Wortlistenerstellung mittels Labelpropagationsverfahren

Die manuell erstellte sowie die maschinell generierten Wortlisten aus dem Labelpropagationsverfahren werden dann unter Auswahl unterschiedlicher Konfigurationen auf den annotierten Datensatz angewendet, wie Abbildung 34 darstellt. Alle verwendeten Konfigurationen, die im Kapitel 7.3 erläutert wurden, werden in Tabelle 51 gelistet. Dabei werden stets nur Wortlisten und bearbeitete annotierte Datensätze zusammengebracht, die die gleiche Vorverarbeitungskonfiguration haben. Alle Berechnungen werden mehrfach durchgeführt und die Ergebnisse fließen in die statistische Signifikanzüberprüfung ein.

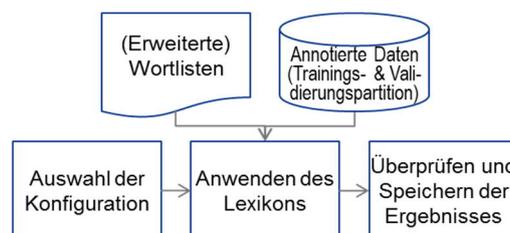


Abbildung 34: Prozess der Anwendung des lexikonbasierten Ansatzes

Einstellung	Wert
<b>Kontext</b>	LEFT_CENTER, CENTER, CENTER_RIGHT, LEFT_CENTER_RIGHT
<b>Datenreduktion</b>	LEMMA, UNCHANGED, WORD
<b>Datenanreicherung</b>	NEGATION, NORMAL
<b>Synonymgewichtungen</b>	1; 1,5; 2; 3; 4
<b>Schlüsselwortgewichtungen</b>	1; 1,5; 2; 3; 4
<b>Wortgewichtung</b>	IDF, IDF AND SEEDWORDS, SEEDWORD WEIGHTED, UNWEIGHTED
<b>Aggregationstyp</b>	MAX, SUM, PRODUCT
<b>Schwellenwerte der semantischen Ähnlichkeiten</b>	0,1 0,1 0,4; 0,1 0,1 0,4; 0,1 0,2 0,4; 0,1 0,2 0,5; 0,1 0,3 0,4; 0,1 0,3 0,5; 0,1 0,4 0,5; 0,2 0,2 0,4; 0,2 0,2 0,5; 0,2 0,2 0,6; 0,2 0,3 0,4; 0,2 0,3 0,5; 0,2 0,3 0,6; 0,2 0,4 0,4; 0,2 0,4 0,5; 0,2 0,4 0,6; 0,2 0,5 0,5; 0,2 0,5 0,6; 0,2 0,5 0,7; 0,2 0,6 0,6; 0,2 0,6 0,7; 0,2 0,7 0,7; 0,3 0,3 0,4; 0,3 0,3 0,5; 0,3 0,3 0,6; 0,3 0,4 0,5; 0,3 0,4 0,6; 0,3 0,5 0,5; 0,3 0,5 0,6; 0,3 0,5 0,7; 0,3 0,6 0,6; 0,3 0,6 0,7; 0,3 0,7 0,7; 0,4 0,4 0,4; 0,4 0,4 0,5; 0,4 0,4 0,6; 0,4 0,4 0,7; 0,4 0,5 0,5; 0,4 0,5 0,6; 0,4 0,5 0,7; 0,4 0,6 0,7; 0,4 0,7 0,7; 0,5 0,5 0,5; 0,5 0,5 0,7; 0,5 0,6 0,6; 0,5 0,6 0,7; 0,5 0,7 0,7; 0,6 0,6 0,6; 0,6 0,6 0,7; 0,6 0,7 0,7; 0,7 0,7 0,7; MANUAL
<b>Umgang mit der neutralen Klasse</b>	DELTA THRESHOLD, MIN THRESHOLD, ONLY ZEROS
<b>Schwellenwert beim Umgang mit Neutral</b>	0,05; 0,1; 0,15; 0,2; 0,25; 0,3; 0,35; 0,4; 0,45; 0,5; 0,55; 0,6; 0,65; 0,7; 0,75; 0,8; 0,85; 0,9; 0,95

Tabelle 51: Listung aller Konfigurationen beim Labelpropagationsverfahren

In Abbildung 35 wird der überwachte maschinelle Lernansatz dargestellt. Auch hier werden nur annotierte Daten und Word2Vec-Modelle verwendet, die durch die gleiche Vorverarbeitung gingen. Die Ergebnisse werden analog zum Labelpropagationsverfahren in Verbindung mit der verwendeten Konfiguration gesammelt und für die Hypothesenüberprüfung genutzt. Alle in Kapitel 7.4 erläuterten und hier verwendeten Konfigurationen sind in Tabelle 52 zusammengefasst.

Als Framework für das maschinelle Lernen dient das Java-basierte Deeplearning4j in der Version 0.9.0 (Deeplearning4j Development Team, o. J.).

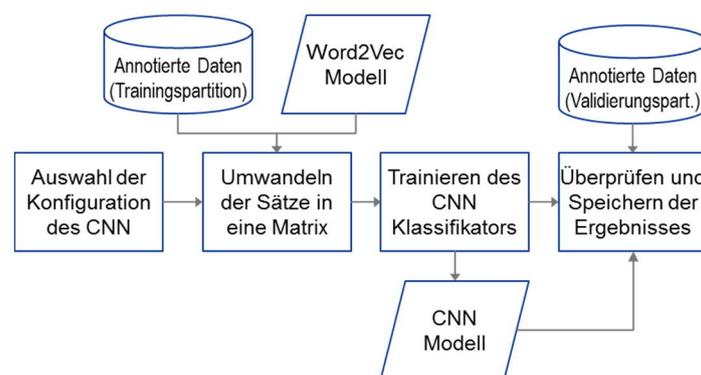


Abbildung 35: Prozess des Trainings und der Anwendung der CNN Methode

<b>Einstellung</b>	<b>Wert</b>
<b>Kontext</b>	LEFT_CENTER, CENTER, CENTER_RIGHT, LEFT_CENTER_RIGHT
<b>Datenreduktion &amp; -anreicherung (nur LEMMA)</b>	LEMMA, LEMMA PERS, LEMMA PERS NUM, LEMMA PERS SUBJ, LEMMA PERS, LEMMA PERS NUM, LEMMA PERS SUBJ, UNCHANGED, WORD
<b>Gewichtsinitialisierungen</b>	RELU, RELU UNIFORM, SIGMOID UNIFORM, XAVIER, XAVIER UNIFORM
<b>Nichtlineare Aktivierungsfunktion</b>	ELU, LEAKYRELU, RELU, RRELU, SELU, TANH
<b>Adaptive Lernrate</b>	ADADELTA, ADAGRAD, ADAM, ADAMAX, NADAM, NESTEROVS, RMSPROP, SGD
<b>Pooling</b>	MAX
<b>Anzahl der Filter pro Faltungsschicht</b>	15, 30, 50, 70, 100, 200, 300
<b>Verlustfunktion</b>	MCXENT, MSE
<b>Datenanreicherung</b>	NEGATION, NORMAL
<b>L2-Regularisierung</b>	0,00033; 0,0001; 0,001
<b>Dropout</b>	0; 0,7

*Tabelle 52: Listung aller Konfigurationen bei der CNN Methode*

Die Prozessschritte aus Abbildung 34 und Abbildung 35 werden in gleicher Weise für die Bestimmung des bestmöglichen Ergebnisses durchgeführt, wobei zur Überprüfung ein noch nicht verwendeter Testdatensatz herangezogen wird. Letzteres wird im folgenden Kapitel näher erläutert.

## 10 Ergebnisse

Sofern nicht anders angegeben, werden zur Überprüfung der Hypothesen und zur Ermittlung der Ergebnisse nur die Trainings- und Validierungsdatensätze verwendet. Im Rahmen der hier durchgeführten Analysen fanden im Vorfeld Überprüfungen statt, um die optimalen Intervalle der Parameterkonfigurationen zu finden. Diese Voranalysen unterlagen ebenfalls der Einschränkung der Nichtverwendung des Testdatensatzes

Für die statistische Überprüfung wurden, wie in Kapitel 9 erläutert, mehrere Konfigurationen verwendet. Die Ergebnisse aller ermittelten F1-Werte werden in Abbildung 36 und Abbildung 37 als Histogramm dargestellt. Zur besseren Lesbarkeit aller Werte wurde in der Darstellung eine logarithmische Skala verwendet, da insbesondere bei der CNN-Methode häufig nur eine Klasse vorhergesagt wurde.

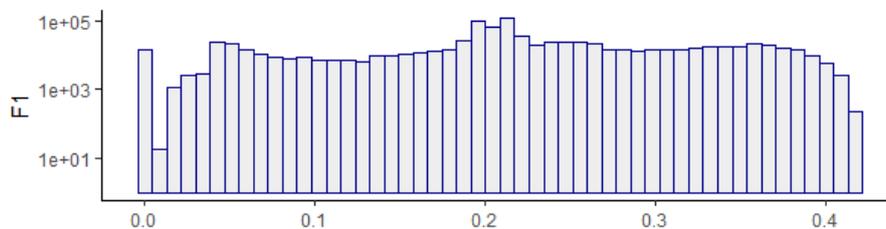


Abbildung 36: Übersicht aller errechneten F1 Werte mittels Labelpropagationsverfahren

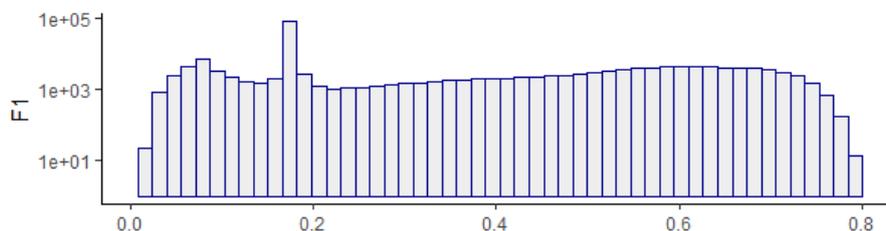


Abbildung 37: Übersicht aller errechneten F1 Werte mittels CNN-Verfahren

Wie aus der Grafik zu entnehmen ist, tritt der F1-Wert von 0,167 beim CNN-Verfahren um ein Vielfaches häufiger auf als andere Werte. In diesem Fall, wird lediglich eine einzige Klasse vorhergesagt, die in den meisten Fällen der Zuordnung der prädominanten Klasse der Trainingsdaten entspricht. Dieses Problem, dass das neuronale Netz in eine Sackgasse gerät und unabhängig von den Eingangsdaten nur eine Klasse vorhersagt, ist in den meisten Fällen systematischer Natur und konnte in einer extra dafür ausgelegten Voranalyse mehrere hundert Male reproduziert werden. Die Testreihen mit dieser ungünstigen Initialisierung werden explizit nicht aus der Signifikanzanalyse ausgeschlossen, da auch diese fehlerhaften Analysen Auskünfte über mögliche Fallstricke geben. Diese Aussage gilt durchgehend für alle hier vorgenommenen Tests, sofern nichts anderes angegeben wurde.

Die Anwendung der Ergebnisse des Labelpropagationsverfahrens, also der errechneten Emotionskategoriezuordnung je Wort, ist deterministisch. Anders verhält es sich mit der CNN-Methode. Da sie ein lernendes Modell ist und somit durch einen *Random Seed* beeinflusst wird, wird für beide Ansätze die Verwendung der Ergebnisse bei der Signifikanzprüfung unterschiedlich gehandhabt. Die Anwendung des Labelpropagationsverfahrens gibt wegen der deterministischen Natur der Emotionsaggregationsmethode aller Wörter des Textfragments bei gleicher Konfiguration und Eingabe auch wiederkehrend die gleiche Emotionseinstufung zurück, weshalb für dieses Verfahren nur diese berechneten F1-Werte herangezogen. Bei der CNN-Methode könnte auch der F1-Wert für die statistische Wertung herangezogen werden, der nach mehreren Epochen errechnet wurde. Dies entspricht jedoch nur zum Teil der Wahrheit, denn zwei unterschiedliche Konfigurationen können nach vielen Iterationsstufen auf ein vergleichbares Klassifikationsergebnis kommen. Jedoch wurde dieses mit der ersten Konfiguration bereits nach wenigen Epochen erlernt, während die zweite Konfiguration viele Dutzend Durchläufe benötigte, um eine vergleichbare Modellgüte zu erreichen. Daher werden in diesem Kapitel bei den angewendeten Signifikanztests grundsätzlich alle Klassifikationsergebnisse von der ersten bis zur zehnten Epoche herangezogen, um die Spreu, also die Konfigurationen, die sich nur langsam einer asymptotischen Klassifikationsgüte nähern, vom Weizen, also den Konfigurationen, die sehr schnell und zuverlässig lernen, zu trennen. Die Inklusion aller Epochen gilt jedoch nur, sofern nichts anderes angegeben wurde.

Bezüglich der Signifikanztests wurde darauf geachtet, dass unter den gezogenen Stichproben der errechneten F1-Werte alle einander gegenübergestellten Kategorien die gleiche Anzahl haben. Erreicht wurde dies, indem bei allen durchgeführten Signifikanztests 1.000 Messergebnisse je Merkmal genommen wurden. Aus der Gesamtheit der ermittelten F1-Werte wurden für jede Fragestellung der Hypothesenüberprüfung stets Zufallsstichproben gezogen. Wurde beispielsweise ein Signifikanztest zur Unterscheidung dreier Ausprägungen durchgeführt, dann war die Stichprobengesamtheit für diesen Test  $n = 3.000$  bei gleich großer Aufteilung.

Eine finale Anmerkung betrifft die Wahl der *Pooling*-Konfiguration beim CNN-Algorithmus. Sofern nichts anderes angegeben wurde, wird das *Max-Pooling* für die Berechnung aller Ergebnisse herangezogen. Aus der Voranalyse wurde deutlich, dass dies mit großem Abstand die deutlichste Parametereinstellung ist, die über eine hohe bzw. niedrige Güte des Modells entscheidet. Um keine Verzerrungen durch nichtssagende Analysen einzuführen, wurde diese

Parameterwahl, bis auf die eigentliche Überprüfung der *Pooling*-Konfiguration, auf das *Max-Pooling* vordefiniert.

## 10.1 Einfluss des Kontexts auf das Analyseergebnis

Die Differenzierung des Einflusses des Kontexts auf das Ergebnis fand auf den Granularitätsebenen des zentralen, emotionstragenden Satzes (C), des zentralen und vorangegangenen Satzes (LC), des zentralen und nachfolgenden Satzes (CR) und beider angrenzenden Sätze in Verbindung mit dem zentralen Satz (LCR) statt. Die oben aufgestellte Nullhypothese, die es zu falsifizieren gilt, war:

H1: Die Granularitätsebene, ob ein Emotionsatz mit oder ohne Kontext in die Analyse eingeht, hat keinen Einfluss auf die Ergebnisse.

Die Signifikanzüberprüfung fand sowohl für die wortbasierten Ansätze als auch für den maschinellen Lernvorgang statt. Für die Emotionsklassifikation wurden je Kontextebene 1.000 zufällige Stichproben aller berechneten F1-Ergebniswerte gezogen. Somit flossen in den Signifikanztest sowohl für die lexikonbasierte als auch für die CNN-basierte Methode jeweils  $n = 4.000$  randomisierte Stichproben ein.

Beim Labelpropagationsverfahren zeigte der Kruskal-Wallis-Test eine hochsignifikante gemittelte Rangabweichung der F1-Werte mit geringer Effektstärke ( $\chi^2(3) = 51,2; p < 0,001; \eta^2 = 0.012$ ). Die Post-hoc-Analyse mittels Dunn-Test ergab eine hochsignifikante Abweichung ( $p < 0,001$ ) zwischen den Kontexteinstufungen C zu LCR, C zu LC und CR zu LCR, eine signifikante Abweichung ( $p = 0,02$ ) bei LC zu LCR. Für das Labelpropagationsverfahren ergab die Reihenfolge C, CR, LC und LCR die zielführendste Reihenfolge für die Emotionsbestimmung. Zur besseren Übersichtlichkeit werden alle mittleren Ränge, sortiert nach Wertigkeit, in der nachfolgenden Tabelle dargestellt.

Kontext	Mittlerer Rang
C	2.154
CR	2.078
LC	1.961
LCR	1.808

Tabelle 53: Ergebniswerte der Hypothese H1 beim Labelpropagationsverfahren

In Abbildung 38 ist dieser Sachverhalt zusätzlich als Boxplot abgebildet. Dieser und folgende Boxplots unterscheiden sich darin, dass zusätzlich der Mittelwert in blau eingezeichnet wurde. Von der in der Forschung üblichen Darstellung der Boxplots, die als Mittelstrich den Median verwenden, wird dabei nicht abgewichen. Da keine Normalverteilung zugrunde liegt,

kann der Median irreführend sein und es wird stattdessen die Betrachtung des Mittelwerts nahegelegt.

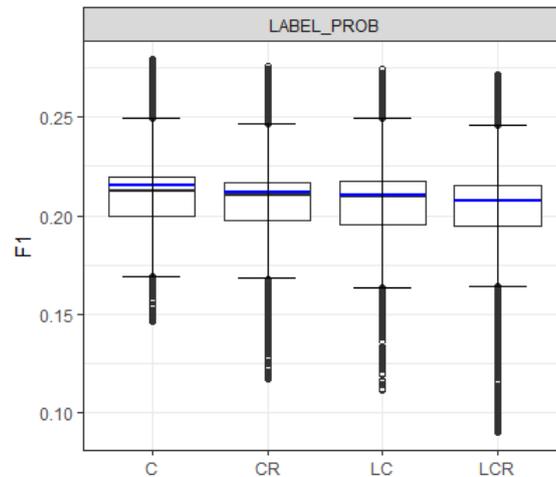


Abbildung 38: Überprüfung der Hypothese H1 beim Labelpropagationsverfahren

Bei den Methoden des maschinellen Lernens zeigte der durchgeführte Kruskal-Wallis-Test ein hochsignifikantes Ergebnis mit ebenfalls geringer Effektstärke ( $\chi^2(3) = 19,7; p < 0,001, \eta^2 = 0,004$ ). Die Post-hoc-Analyse mittels Dunn-Test ergab nur bei LC als bester Fokusbetrachtung eine hochsignifikante Rangabweichung der Mittelwerte bei LC zu CR von 226,3 ( $p < 0,001$ ), bei LC zu LCR eine signifikante Rangabweichung von 132,5 ( $p = 0,05$ ) und bei LC zu C eine Tendenz von 123,8 ( $p = 0,08$ ). In der nachfolgenden Abbildung sind diese Differenzen nochmals als Boxplot mit Blaufärbung der Mittelwerte dargestellt.

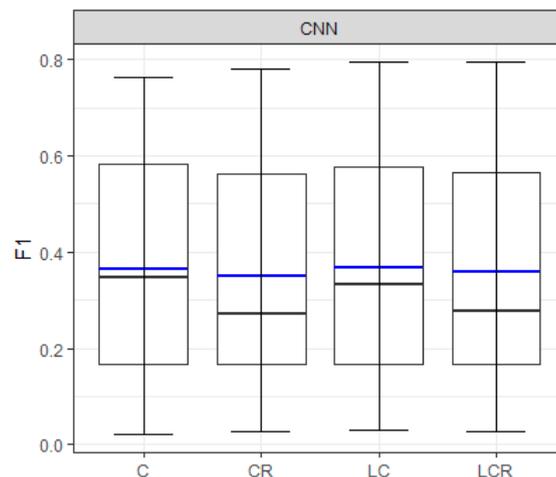


Abbildung 39: Überprüfung der Hypothese H1 bei der CNN-Methode

Um einen noch tieferen Einblick in das Lernverhalten des neuronalen Netzwerkes zu erhalten, wird eine weitere visuelle Analyse durchgeführt. Die Mittelwerte des F1-Beurteilungsmaßes aller erfolgreichen Berechnungen, also Durchläufe, bei denen nicht nur die am häufigsten vorkommende Klasse vorhergesagt wurde, werden zusätzlich in einem Liniendiagramm

dargestellt. Die epochenweise Betrachtung der Ergebnisentwicklung gibt Auskunft über die Kontinuität bzw. den abnehmenden oder zunehmenden Einfluss von Variablen über die Dauer des Trainings hinweg.

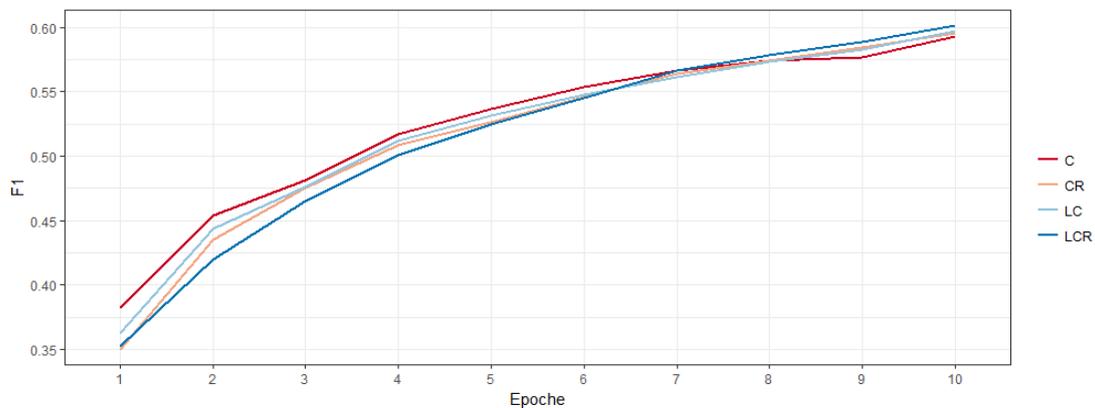


Abbildung 40: Entwicklung der Ergebniswerte bei H1 pro Epoche

## 10.2 Vergleich des manuellen und semi-überwachten lexikonbasierten Ansatzes

In der Signifikanzüberprüfung der lexikonbasierten Emotionsklassifikation wird eine handsortierte Liste mehreren Ergebnissen des Labelpropagationsverfahrens gegenübergestellt. Zum optimalen Vergleich werden mehrere Einstellungen der Parameter  $\psi_{Emotinswort}$ ,  $\psi_{Schlüsselwort}$  und  $\psi_{Rest}$  herangezogen. Darunter sind die folgenden Konfigurationen:

$\psi_{Emotinswort}$	$\psi_{Schlüsselwort}$	$\psi_{Rest}$	Bezeichnungssuffix
0,4	0,5	0,7	0.4 0.5 0.7
0,4	0,6	0,7	0.4 0.6 0.7
0,4	0,7	0,7	0.4 0.7 0.7
0,5	0,5	0,7	0.5 0.5 0.7
0,5	0,6	0,7	0.5 0.6 0.7
0,5	0,7	0,7	0.5 0.7 0.7
0,6	0,7	0,7	0.6 0.7 0.7

Tabelle 54: Eingangskonfigurationen der Schwellwerte bei Hypothese H2

Das *Label-Propagation*-Verfahren wurde ebenfalls auf die manuell erstellte Emotionsliste angewendet. Dabei wurden Synonyme so behandelt, als wären sie Schlüsselwörter. Somit werden in der Signifikanzwertbestimmung die Herangehensweisen ausschließlich manuell (MANUAL), mit dem Labelpropagationsverfahren (LABEL\_PROB) und dem kombinierten Verfahren (MANUAL+LABEL\_PROB) durchgeführt. Die dazugehörige Nullhypothese wurde oben angegeben als:

H2: Unter Verwendung eines lexikonbasierten Ansatzes liefert eine manuell erstellte Emotionsliste keine besseren Ergebnisse als eine maschinell generierte.

Für den Signifikanztest wurden pro genannter Konfiguration 1.000 zufällige Stichproben der berechneten Ergebniswerte gezogen. Somit stützt sich die Signifikanzbestimmung auf eine Gesamtzahl von  $n = 3.000$  berechneten F1-Werte. Die unterschiedlichen Konfigurationen wurden gleichzeitig in die statistische Analyse gegeben, um das entsprechende Signifikanzniveau zu berücksichtigen. Nichtsdestotrotz werden nur gruppenübergreifende Signifikanzen dargestellt.

Das Ergebnis des Kruskal-Wallis-Tests zeigte eine hochsignifikante, gemittelte Rangabweichung der F1-Werte ( $\chi^2(2) = 182,7; p < 0,001; \eta^2 = 0,06$ ).

Die Post-hoc-Analyse mittels Dunn-Test zeigt bei den Konfigurationspaaren MANUAL zu LABEL\_PROB sowie MANUAL zu LABEL\_PROB+MANUAL ein hochsignifikantes Niveau von 497,5 ( $p < 0,001$ ) bzw. 390 ( $p < 0,001$ ). Bei der Gegenüberstellung der Konfigurationen LABEL\_PROB zu MANUAL+LABEL\_PROB ergab sich ein signifikanter Unterschied von 107,5 ( $p = 0,02$ ). Alle Analysen entsprechen der aufgestellten Hypothese, so dass die Nullhypothese verworfen werden kann.

Darüber hinaus werden die F1-Werte aller Konfigurationen als Boxplot dargestellt. In Abbildung 41 werden die Ergebnisse nach der Methode der lexikonbasierten Herangehensweise gruppiert.

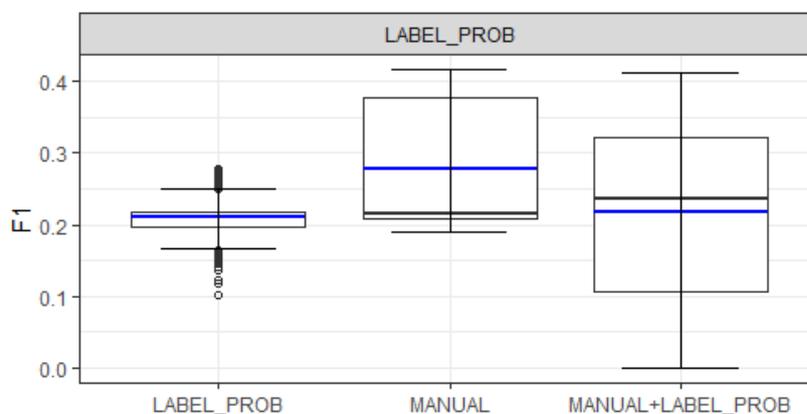


Abbildung 41: Überprüfung der Hypothese H2 beim Labelpropagationsverfahren

### 10.3 Lexikonbasierter und maschineller Lernansatzes im Vergleich

Bei diesem Signifikanztest wird das CNN-basierte Modell dem lexikonbasierten Ansatz unter Verwendung der manuell erstellten und der mittels Labelpropagationsverfahren generierten Listen gegenübergestellt. Zur fairen Beurteilung wird das CNN-basierte Modell sowohl mit

ungünstiger Initialisierung (CNN\_INITS\_ALL) als auch unter Ausschluss dieser Testreihen (CNN) dem Vergleich unterzogen. Auf der anderen Seite stehen die ausschließlich manuell (MANUAL) und mittels Labelpropagationsverfahren (LABEL\_PROB) erstellten Emotionslexika für den lexikonbasierten Ansatz. Bei der Gruppe des LABEL\_PROB wurden die Parameter  $\psi_{\text{Emotinswort}} = 0,4$ ,  $\psi_{\text{Schlüsselwort}} = 0,5$  und  $\psi_{\text{Rest}} = 0,7$  gesetzt. Die oben postulierte Nullhypothese lautet:

H3: Ein lexikonbasierter Ansatz erzielt keine schlechteren Ergebnisse als ein maschineller Lernansatz.

Für die Überprüfung der Signifikanz wurden pro Konfiguration 1.000 zufällig gezogene Stichproben der berechneten F1-Ergebnisse verwendet. Abweichend von anderen Hypothesentests, wird hier nur die letzte trainierte Epoche verwendet. Die Signifikanzbestimmung stützt sich somit auf eine Gesamtzahl von  $n = 4.000$  Berechnungen. Dies ist der einzige Test, bei dem F1-Ergebnisse aus beiden Herangehensweisen gleichzeitig in einer Analyse verarbeitet werden.

Der Kruskal-Wallis-Test zeigt eine hochsignifikante Abweichung des mittleren Rangs aller eingegebenen F1-Ergebniswerte ( $H(3) = 1.681; p < 0,001; \eta^2 = 0,42$ ). Der gemittelte Rang war für CNN 3.109, für CNN\_INITS\_ALL 1.802, für MANUAL 2.072 und für LABEL\_PROB 1.017. Eine nachgelagerte Analyse mittels Dunn-Test ergab zwischen allen Kategorien eine hochsignifikante Abweichung der Rangdifferenz. Zur besseren Darstellung sind die Abweichungen in der nachfolgenden Tabelle in sortierter Reihenfolge gelistet, wobei die zuerst genannten jeweils einen höheren mittleren Rang bekleiden.

Höherwertiger Kontext	Niedrigwertiger Kontext	Mittlere Rangabweichung	Grad der Signifikanz
CNN	LABEL_PROB	2.092	$p < 0,001$
CNN	CNN_INITS_ALL	1.307	$p < 0,001$
MANUAL	LABEL_PROB	1.054	$p < 0,001$
CNN	MANUAL	1.037	$p < 0,001$
CNN_INITS_ALL	LABEL_PROB	784	$p < 0,001$
MANUAL	CNN_INITS_ALL	269	$p < 0,001$

*Tabelle 55: Mittlere Rangabweichung bei Hypothese H3*

Wird das neuronale Netz korrekt initialisiert, was der Verwendung der CNN-Werte entspricht, so kann die Nullhypothese zugunsten der Alternativhypothese, dass ein maschineller Lernansatz bessere Ergebnisse erzielt als ein lexikonbasierter Ansatz, verworfen werden. Andernfalls trifft dieser Hypothesenbestätigung nur auf CNN\_INITS\_ALL und das nicht manuell angereicherte Labelpropagationsverfahren LABEL\_PROB zu. In Abbildung 42 werden die gebündelten F1-Ergebniswerte nochmals als Boxplot dargestellt.

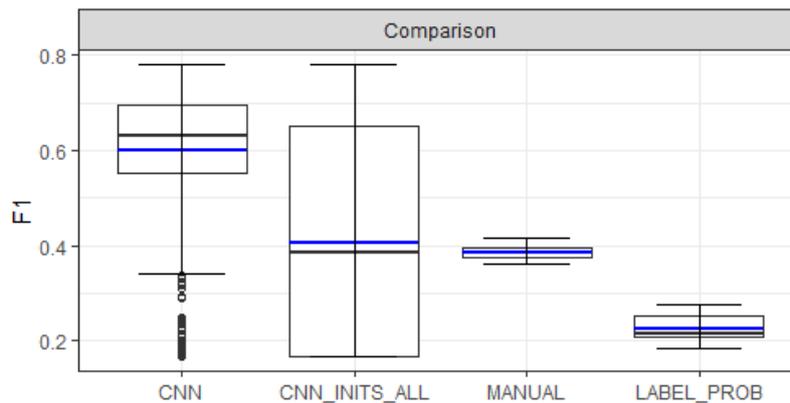


Abbildung 42: Überprüfung der Hypothese H3

## 10.4 Harmonisierung, Reinigung und Wortstammreduktion

Unveränderte Benutzerschreibweisen und nicht auf den Wortstamm zurückgeführte Wörter stellen einem zusätzlichen Komplexitätsgrad dar. Texte, die in unveränderter Form aus Nachrichtenkommentaren genommen werden (UNCHANGED), werden Wörtern gegenübergestellt, bei denen alle oben beschriebenen Harmonisierungs- und Datenbereinigungsmaßnahmen durchgeführt wurden (WORD), bzw. Wörtern, bei denen zusätzlich eine Wortstammreduktion durchgeführt wurde (LEMMA). Die dazugehörigen Nullhypothesen lauten:

H4a: Die Datenbereinigungsschritte haben weder bei dem lexikonbasierten noch bei dem maschinellen Lernansatz eine positive Wirkung auf die Emotionsklassifikation.

H4b: Bei der Emotionsklassifikation mittels lexikonbasierter Herangehensweise hat die Verwendung des Wortstamms weder im Vergleich zu den bereinigten Wörtern noch im Vergleich zu den unveränderten Wörtern einen positiven Effekt.

H4c: Bei der Emotionsklassifikation mittels CNN schneiden Modelle mit Eingabe wortstammreduzierter Wörter nicht schlechter ab als Modelle mit unbearbeiteten Texten als Eingabe.

Sowohl für die wortbasierten Ansätze als auch für die des maschinellen Lernvorgangs fanden Signifikanzüberprüfungen statt. Für die Klassifikation mittels lexikonbasierter Methode und CNN wurden pro Gruppe 3.000 Berechnungsergebnisse zufällig aus einer Stichprobe gezogen, so dass sich die Gesamtzahl der Observationen auf jeweils  $n = 3.000$  beläuft.

Sowohl die Methode CNN ( $\chi^2(2) = 19,3; p < 0,001; \eta^2 = 0,01$ ) als auch für die Methode LABEL\_PROB ( $\chi^2(2) = 33,9; p < 0,001; \eta^2 = 0,01$ ) zeigt der Kruskal-Wallis-Test ein signifikantes Ergebnis. Die gemittelten Ränge betragen bei der Gruppe CNN für UNCHANGED 1.421, für WORD 1.589 und für LEMMA 1.491. Analog dazu waren die

mittleren Ränge für die Gruppe LABEL\_PROB für UNCHANGED 1.389, für WORD 1.496 und für LEMMA 1.615.

Die Post-hoc-Analyse zeigte, dass das erwartete Ergebnis von H4a hochsignifikant bei CNN und signifikant bei LABEL\_PROB eintrifft. Bei der Gruppe CNN als auch bei der Gruppe LABEL\_PROB zeigte sich eine mittlere Rangabweichung bei WORD zu UNCHANGED von 167,8 ( $p < 0,001$ ) bzw. 106,5 ( $p < 0,001$ ). Auch die Nullhypothese H4b konnte hochsignifikant widerlegt werden. Die mittlere Rangabweichung zwischen LEMMA und WORD beträgt 119,1 ( $p = 0,006$ ) und zwischen LEMMA und UNCHANGED 225,6 ( $p < 0,001$ ). Die Sachverhalte der Hypothesen H4a und H4b, bezogen auf das Labelpropagationsverfahren, werden im nachfolgenden Boxplot nochmals visualisiert.

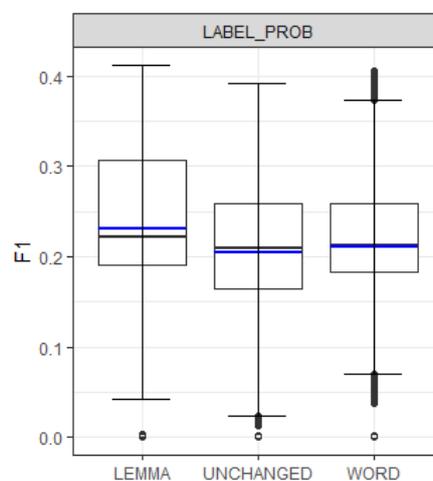


Abbildung 43: Überprüfung der Hypothesen H4a und H4b

Die Hypothese H4c konnte unter Berücksichtigung aller Epochen (CNN\_EVERY\_EPOCH) nicht falsifiziert werden. Zieht man jedoch nur die letzte Trainings-epoche (CNN\_LAST\_EPOCH\_ONLY) heran, dann zeigt sich ein signifikanter Unterschied ( $p = 0,007$ ). Nachfolgend werden die beiden Gruppen mit den jeweiligen Überprüfungsgegenständen in Abbildung 44 dargestellt.

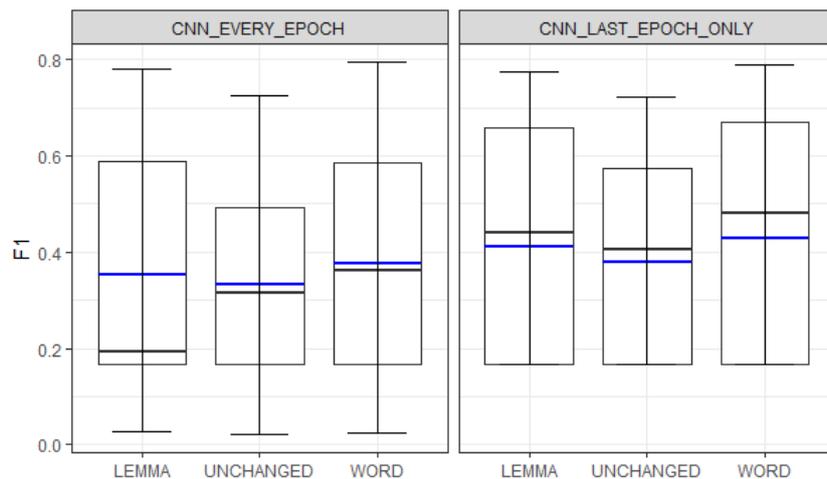


Abbildung 44: Überprüfung der Hypothese H4a und H4c

Zum besseren Verständnis wird hier auf eine epochenweise Darstellung der Wertentwicklungen zurückgegriffen. Im Vergleich zur Hypothesenüberprüfung wurden für das nachfolgende Liniendiagramm fehlerhafte Initialisierungen mit nur einer Klassenvorhersage ausgenommen. Das häufige Festhängen in einem lokalen Optimum und damit eine Unfähigkeit, zu lernen, tritt besonders häufig bei der Kategorie LEMMA auf, was auch die konträren Ergebnisbeschreibungen zwischen dem Boxplot und der nachfolgenden Grafik erklärt.

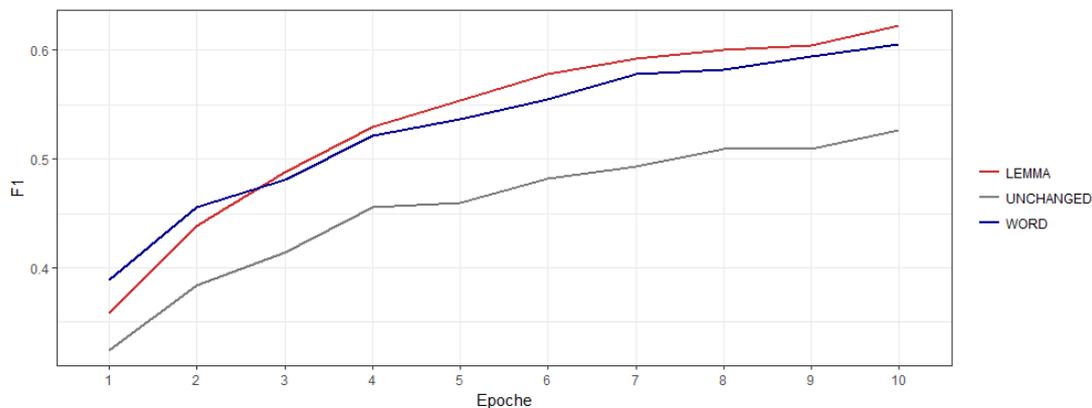


Abbildung 45: Entwicklung der Ergebniswerte bei H4a und H4c pro Epoche

## 10.5 Anreicherung

Die Signifikanzwertbestimmung der grammatischen Person wird nicht mit dem lexikonbasierten Ansatz durchgeführt. In dieser Analyse wird das Modell des nichtangereicherten Wortstamms (LEMMA) mit dem Modell des Wortstamms und der Wortarten, die um die grammatische Person angereichert wurde (LEMMA\_PERS), die zusätzlich um den grammatikalischen Numerus ergänzt wurde (LEMMA\_PERS\_NUM) und die zusätzlich um die Möglichkeitsform angereichert wurde (LEMMA\_PERS\_SUBJ), verglichen. Folgende Nullhypothesen wurden dazu aufgestellt:

H5a: Das Hinzunehmen der wortbedingten Information der Person hat keinen positiven Einfluss auf die Klassifikation.

H5b: Die zusätzliche Verwendung des Numerus zur grammatikalischen Person als Eingabemerkmale hat keine positive Auswirkung auf die Modellgüte.

H5c: Die zusätzliche Verwendung der Möglichkeitsform zur grammatikalischen Person als Eingabemerkmale hat keine positive Auswirkung auf die Modellgüte.

Die Gesamtzahl der F1-Observationen belaufen sich auf  $n = 4.000$ . Diese teilen sich gleichmäßig auf in die Kategorien LEMMA, LEMMA\_PERS, LEMMA\_PERS\_NUM und LEMMA\_PERS\_SUBJ. Die Überprüfung der Hypothesen wurde, wie schon zuvor, mittels eines Berechnungsdurchgangs mit entsprechendem Signifikanzniveau durchgeführt.

Der Kruskal-Wallis-Test zeigt eine hochsignifikante Abweichung der F1-Ergebniswerte ( $\chi^2(3) = 32,7; p < 0,001, \eta^2 = 0,01$ ). Die gemittelten Ränge der vier Kategorien sind LEMMA 2.177, LEMMA\_PERS 1.926, LEMMA\_PERS\_NUM 1.939 und LEMMA\_PERS\_SUBJ 1.959. Die Post-hoc-Analyse ergab jedoch, dass alle Anreicherungen signifikant schlechter abschnitten als die Kategorie LEMMA. Dies steht jedoch entgegen den formulierten Hypothesen, so dass keine der in diesem Unterkapitel angeführten Nullhypothesen verworfen werden kann. Der Sachverhalt wird im nachfolgenden Boxplot dokumentiert.

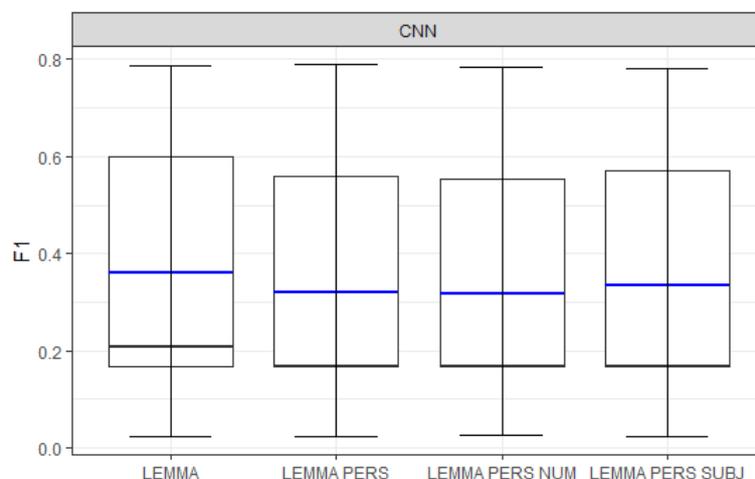


Abbildung 46: Fehlgeschlagene Überprüfung der Hypothesen H5a, H5b und H5c

Wie auch bei den CNN-basierten Methoden wird auch hier die Ergebnisentwicklung pro Epoche als Liniendiagramm dargestellt. Dies zeugt ebenfalls von der konstant schlechteren Performanz der Anreicherung. Bei allen Testgruppen wurden fehlerhafte Initialisierungen ausgeklammert.

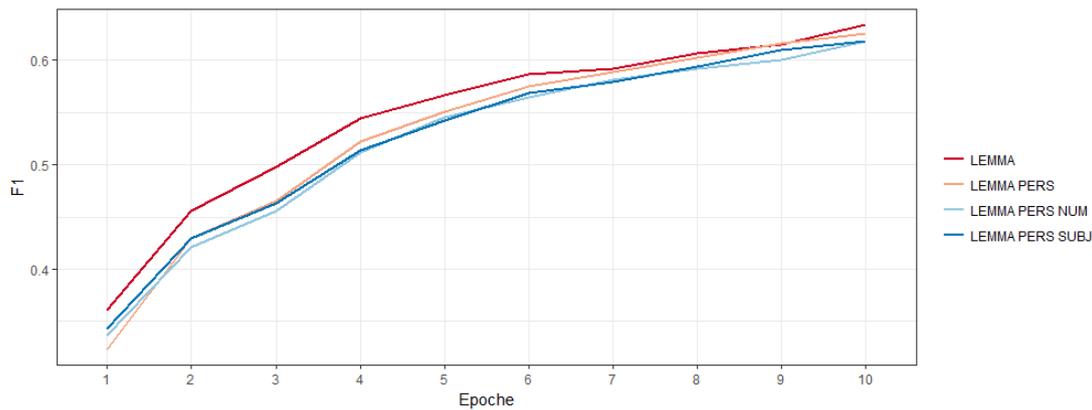


Abbildung 47: Entwicklung der Ergebniswerte bei H5 pro Epoche

## 10.6 Negation

Sowohl für den lexikalischen Ansatz als auch für das CNN-Modell wird die Anwendung der Negation überprüft. Dabei wird getestet, inwieweit sich ein unveränderter Datensatz (NORMAL) und ein Datensatz unter Anwendung der oben beschriebenen Negation (NEG) unterscheiden. Die dazugehörige Nullhypothese lautet:

H6: Die Anwendung einer Negation hat keinen positiven Einfluss auf das Klassifikationsergebnis.

Insgesamt werden für die Negation  $n_{Label\_Prob}$  4.000 Datensätze mit den lexikonbasierten Herangehensweisen überprüft, was 1.000 zufällige Beobachtungen pro Negationsgruppe NORMAL und NEG und pro Art der Schlüsselwortgewinnung darstellt. Letztere Gruppierung teilt sich auf in das Labelpropagationsverfahren (LABEL\_PROB) und die manuell sortierte Emotionsliste (MANUAL). Für die CNN-basierte Analyse werden  $n_{CNN} = 2.000$  Datensätze verwendet, die sich gleichmäßig auf die Kategorien NORMAL und NEG aufteilen. Alle F1-Ergebnisse wurden mittels einer zufälligen Stichprobe aus allen berechneten F1-Werten entnommen.

Die Überprüfung des MANUAL Labelpropagationsverfahrens und der CNN-basierten Analyse mittels Wilcoxon-Rangsummentest ergaben einen hochsignifikanten bzw. signifikanten Unterschied. Die Kategorie MANUAL ( $U = 569.600$ ;  $Z = 5.39$ ;  $p < 0,001$ ;  $r = 0,12$ ) und die Kategorie LABEL\_PROB ( $U = 508.570$ ;  $Z = 0,66$ ;  $p = 0,5$ ; nicht signifikant) wurden einer einseitigen Hypothesenüberprüfung unterzogen. Diese Sachverhalte, die bei MANUAL zum Verwerfen der Gegenhypothese führen bzw. die bei LABEL\_PROB keine signifikante Auswirkung haben, sind im nachfolgenden Boxplot dargestellt.

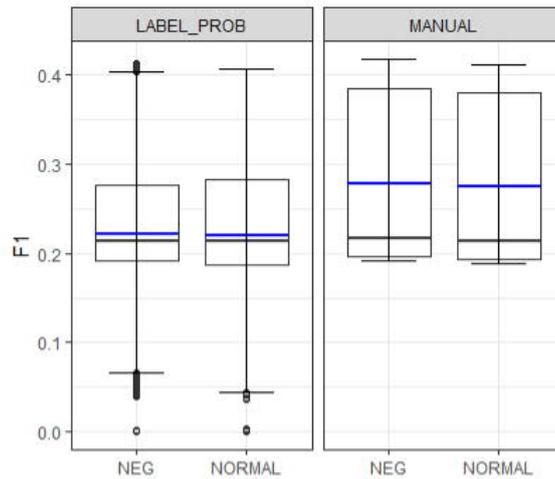


Abbildung 48: Überprüfung von  $H_6$  beim Labelpropagationsverfahren

Der nichtparametrische Signifikanztest lieferte auch in der Kategorie CNN ein hochsignifikantes Ergebnis ( $U = 531.530$ ;  $Z = 2,48$ ;  $p = 0,01$ ;  $r = 0,05$ ). Aus diesem Grund kann die Alternativhypothese auch hier verworfen werden. In der nachfolgenden Abbildung 49 werden die Ergebnisse nochmals als Boxplot dargestellt.

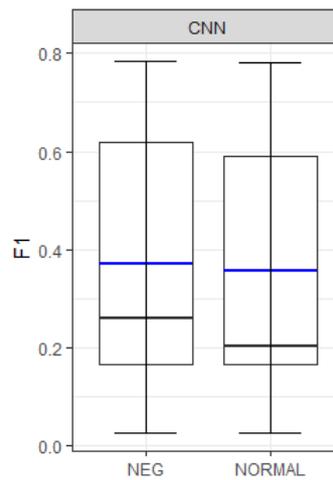


Abbildung 49: Überprüfung der Hypothese  $H_6$  bei der CNN-Analyse

Die weiterführende visuelle Analyse pro Epoche untermauert beim CNN-Verfahren die Hypothese  $H_6$  auf ganzer Linie. Die Anreicherung um Negationssuffixe zeigt epochenübergreifend bessere Ergebnisse, wie das nachfolgende Liniendiagramm darstellt.

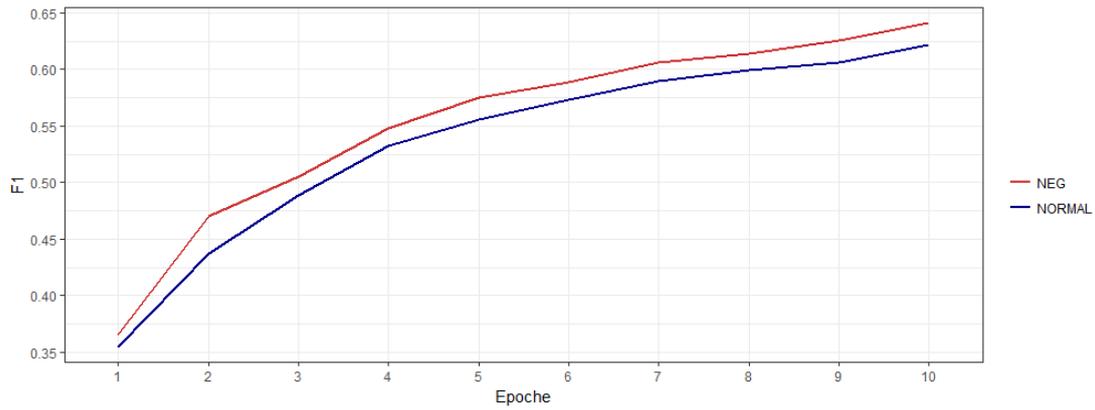


Abbildung 50: Entwicklung der Ergebniswerte bei H6 pro Epoche

## 10.7 Optimierte Ergebnisse

### 10.7.1 Manueller lexikonbasierter Ansatz

Bei der handannotierten Emotionsliste zeigt ein niedriger Wert für die Gewichtung der Synonyme als etwas erfolgversprechender. Ein Vergleich von  $n = 2.593$  Ergebniswerten zeigt in dies in Abbildung 51, bezogen auf den Vergleich der Mittelwerte.

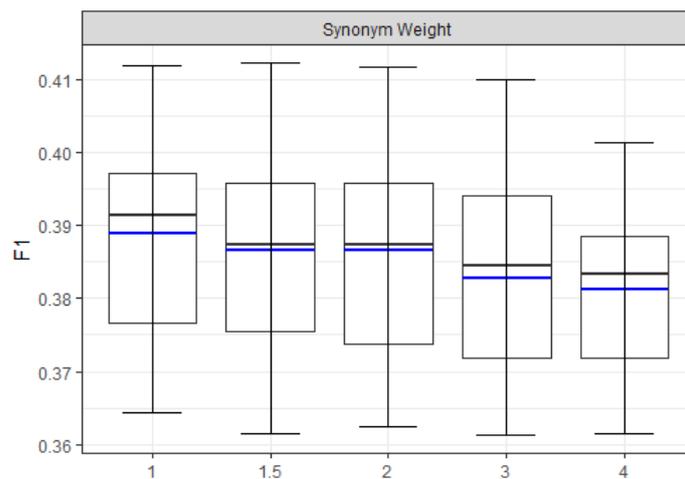


Abbildung 51: Boxplot der Werte der Synonymgewichtungen bei der manuellen Lexikonerstellung

Dahingegen zeigt Abbildung 52, dass ein höherer Wert für die Schlüsselwörter bessere Ergebniswerte erzeugt. Die Unterschiede sind jedoch marginal. Es liegt eine unveränderte Anzahl an Ergebnisberechnungen von  $n = 2.593$  vor.

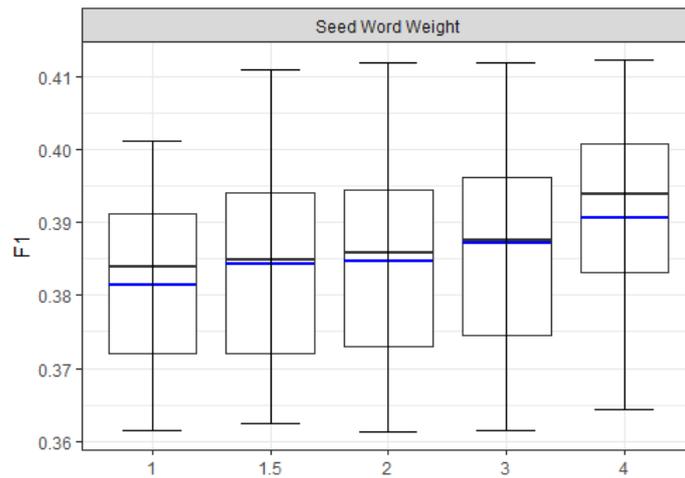


Abbildung 52: Boxplot der Werte der Schlüsselwortgewichtungen bei der manuellen Lexikonerstellung

Bei der Auswahl des Aggregationstyps liegt die Konfiguration MAX hinter den beiden anderen Typen SUM und PRODUCT. Auch hier sind die Unterschiede so gering, dass der Konfiguration SUM der Vorzug gegeben wird, da für diese Konfiguration mittels Wortgewichtung weitere Einstellungen vorgenommen werden können. Die nachfolgende Abbildung 53 macht dies deutlich. Die Bewertung basiert auf  $n = 2.593$  Ergebnisberechnungen.

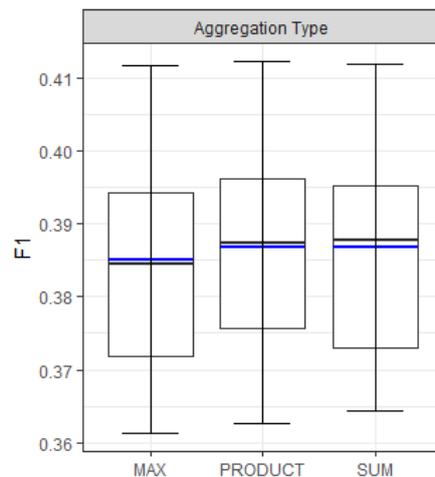


Abbildung 53: Boxplot der Aggregationstypen bei der manuellen Lexikonerstellung

Wie in Kapitel 7.3.3.4 erläutert, hat die Anwendung einer unterschiedlichen Gewichtung nur bei dem Aggregationstyp SUM einen Effekt. Abbildung 54 spricht für eine leichte Tendenz der Inklusion der idf-Werte anstelle der bloßen Verwendung der Schlüsselwortgewichtungen. Der Entscheidung liegen  $n = 2.593$  Analyseergebnisse zugrunde.

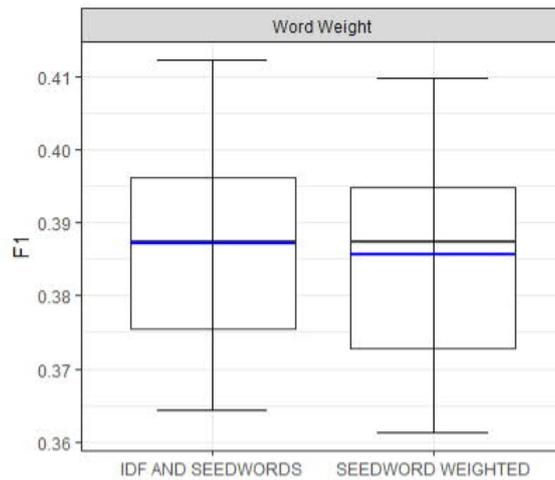


Abbildung 54: Boxplot der Wortgewichte bei der manuellen Lexikonerstellung

Der Umgang mit der neutralen Klasse bringt im Gegensatz zur bipolaren Sentimentanalyse einen Komplexitätsgrad ins Spiel. Bei Verwendung des hier vorliegenden Datensatzes und Modells schnitt der Ansatz MIN\_THRESHOLD besser ab als DELTA\_THRESHOLD. Dies wird in Abbildung 55, basierend auf  $n = 2.593$  Analyseergebnissen, ersichtlich.

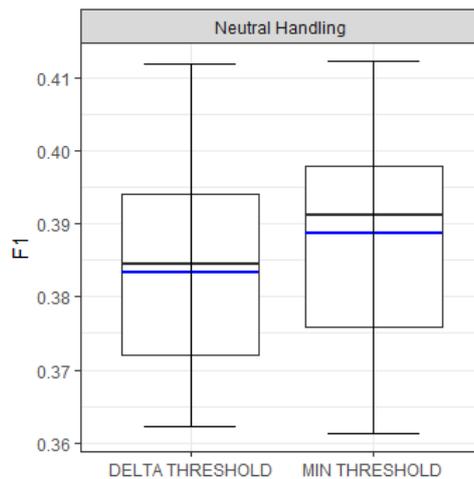


Abbildung 55: Boxplot des Umgangs mit der neutralen Klasse

Als Schwellwert für den Umgang mit der neutralen Klasse in der Emotionserkennung erweist sich ein niedriger Wert als besser als ein höherer. Dies ist der visuellen Analyse der  $n = 2.593$  Analyseergebnisse in Abbildung 56 entnehmbar.

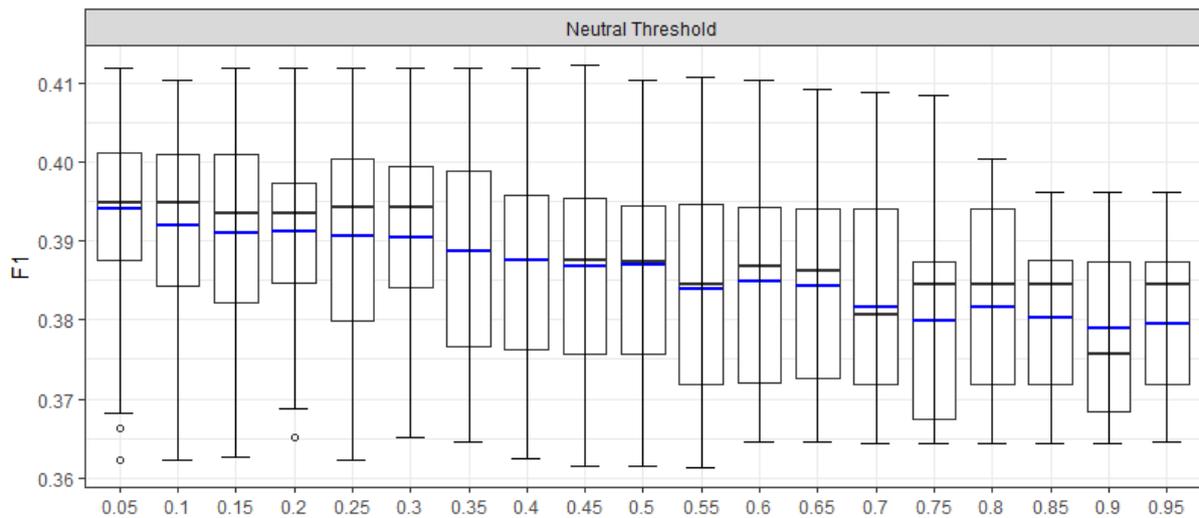


Abbildung 56: Boxplot der Schwellenwerte im Umgang mit der neutralen Klasse

Die Konfiguration zur Berechnung des optimalen Ergebnisses für den manuellen lexikonbasierten Ansatz ist folglich:

Einstellung	Wert
Kontext	LC
Datenreduktion	LEMMA
Datenanreicherung	NEGATION
Synonymgewichtungen	1
Schlüsselwortgewichtungen	4
Aggregationstyp	SUM
Wortgewichtung	IDF AND SEEDWORDS
Umgang mit der neutralen Klasse	MIN_THRESHOLD
Schwellenwert $\gamma$ beim Umgang mit Neutral	0,05

Tabelle 56: Optimale Konfiguration bei manueller Lexikonerstellung

### 10.7.2 Lexikonbasierter Ansatz mit Labelpropagationsverfahren

Bei der maschinell erstellten Emotionsliste ist kein Unterschied hinsichtlich der Synonymgewichtung auszumachen. Ein Vergleich von  $n = 47.024$  Ergebniswerten zeigt in Abbildung 57 keinen Unterschied der Mittel- und Medianwerte. Deswegen wird auf die exakt gleiche Synonymgewichtung wie im vorangegangenen Kapitel bei dem manuellen Ansatz zurückgegriffen.

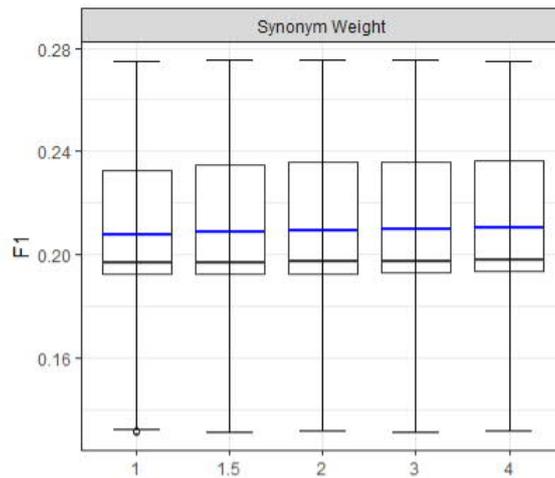


Abbildung 57: Boxplot der Werte der Synonymgewichtungen bei der manuellen Lexikonerstellung

Ähnlich wie bei der manuellen Erstellung des Emotionslexikons zeigt Abbildung 58, dass ein höherer Gewichtungsfaktor für die Schlüsselwörter marginal bessere Ergebnisse liefert. Dies geht auch mit der Einstellung des manuell erstellten Lexikons einher. Es liegen  $n = 50.000$  Ergebnisberechnungen vor.

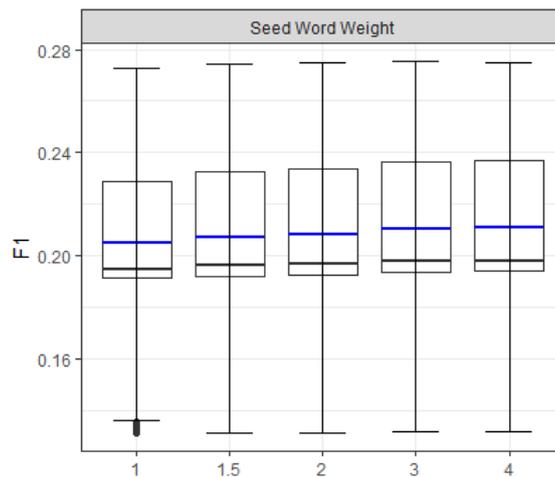


Abbildung 58: Boxplot der Werte der Schlüsselwortgewichtungen bei der manuellen Lexikonerstellung

Da bei der Auswahl der Aggregationstypen nur ein marginaler Unterschied auszumachen ist, wird sich hier, wie bereits im vorangegangenen Kapitel, auf die Konfiguration SUM konzentriert. Bei dieser Aggregation können mittels Wortgewichtung noch weitere Konfigurationseinstellungen getroffen werden. Die Bewertung basiert auf  $n = 30.000$  Ergebnisberechnungen und ist in Abbildung 59 visualisiert.

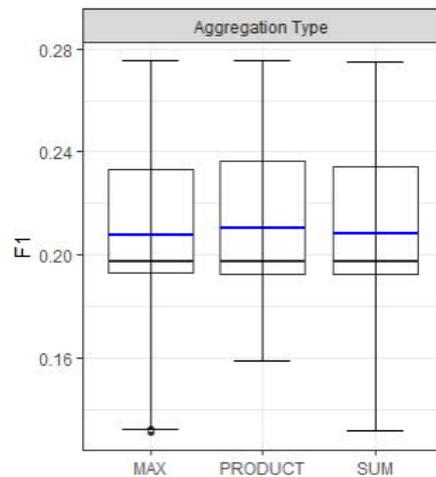


Abbildung 59: Boxplot der Aggregationstypen bei der manuellen Lexikonerstellung

Bei der Nutzung des Labelpropagationsverfahrens ist die Schlüsselwortgewichtung mit und ohne IDF-Faktor leicht im Vorteil, wie Abbildung 60 zeigt. Aus Gründen der Vergleichbarkeit wird hier die gleiche Konfiguration wie bei der manuellen Lexikonerstellung verwendet. Es liegen  $n = 23.560$  Analyseergebnisse vor.

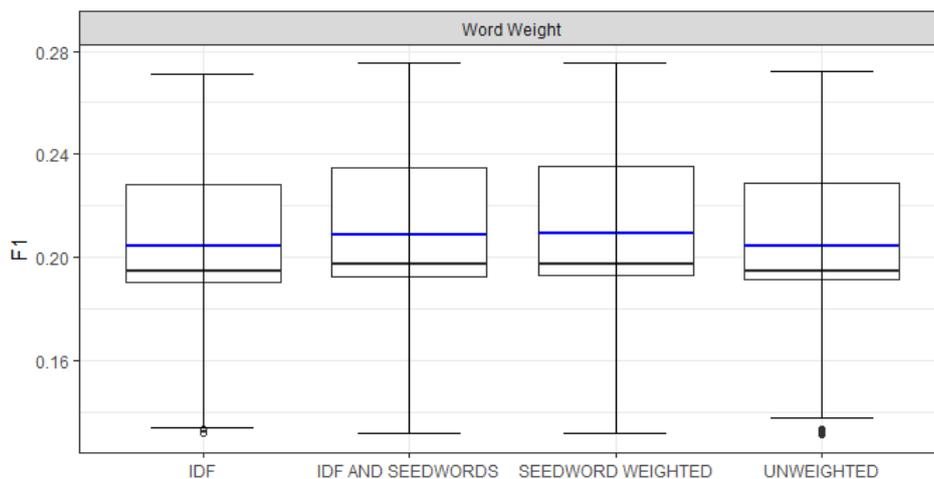


Abbildung 60: Boxplot der Wortgewichte bei der manuellen Lexikonerstellung

Darüber hinaus können bei der Lexikonerstellung mittels Labelpropagationsverfahren die Schwellenwerte der semantischen Ähnlichkeiten variiert werden. Beide nachfolgenden Grafiken basieren auf  $n = 71.919$  F1-Ergebnissen. Abbildung 61 zeigt Werte mit niedriger Streuung und wenig vielversprechenden Ergebnissen, die nahe einer Klassifikation der am häufigsten vorkommenden Klasse sind.

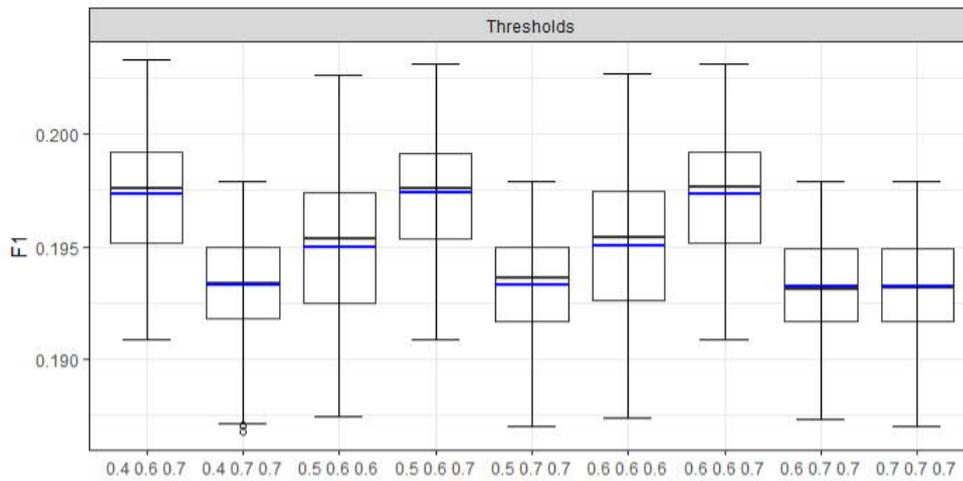


Abbildung 61: Übersicht der Schwellwerte mit geringer Ergebnisvarianz

Die nachfolgende Abbildung 62 zeigt einerseits Werte mit hoher Streubreite in niedrigen Regionen des Schwellenwerts der semantischen Ähnlichkeit, andererseits lässt sich anhand der Konfigurationen 0.4 0.5 0.5, 0.4 0.5 0.6, 0.4 0.5 0.7, 0.5 0.5 0.5 und 0.5 0.5 0.7 eine Annäherung an eine optimale Konfiguration ablesen.

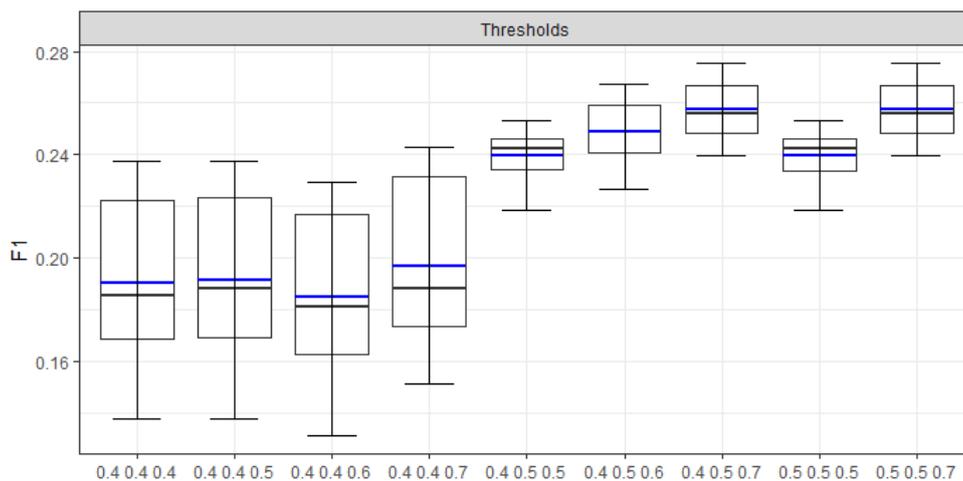


Abbildung 62: Übersicht der Schwellwerte mit größerer Varianz und besserer Werteinstufung

Um die Klasse Neutral zu erzeugen, wurden drei Ansätze überprüft. Wenngleich der Ansatz ONLY\_ZEROS hier den größten Mittelwert aufwies, konnte damit bei diesem Ansatz nicht das beste Ergebnis erzielt werden. Somit wird, wie bereits bei der neutralen Herangehensweise, auf MIN\_THRESHOLD zurückgegriffen. In Abbildung 63 sind die Unterschiede dargestellt.

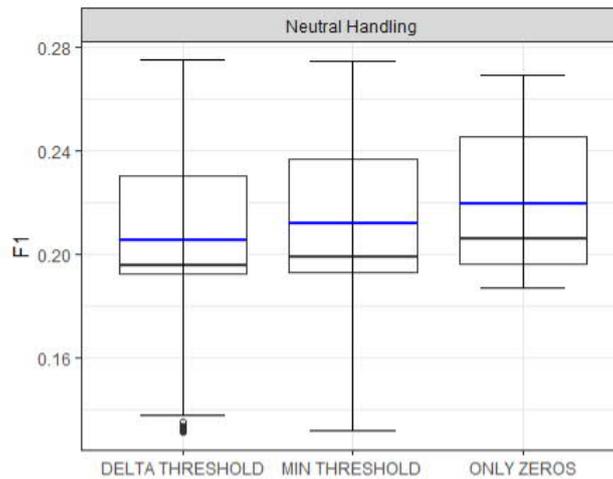


Abbildung 63: Boxplot im Umgang mit der Klasse Neutral

Ähnlich wie bei der manuellen Erstellung des Lexikons zeigt sich ein geringerer Wert im Umgang mit der Klasse Neutral, als vorteilhaft wäre. Dies wird aus Abbildung 64 ersichtlich.

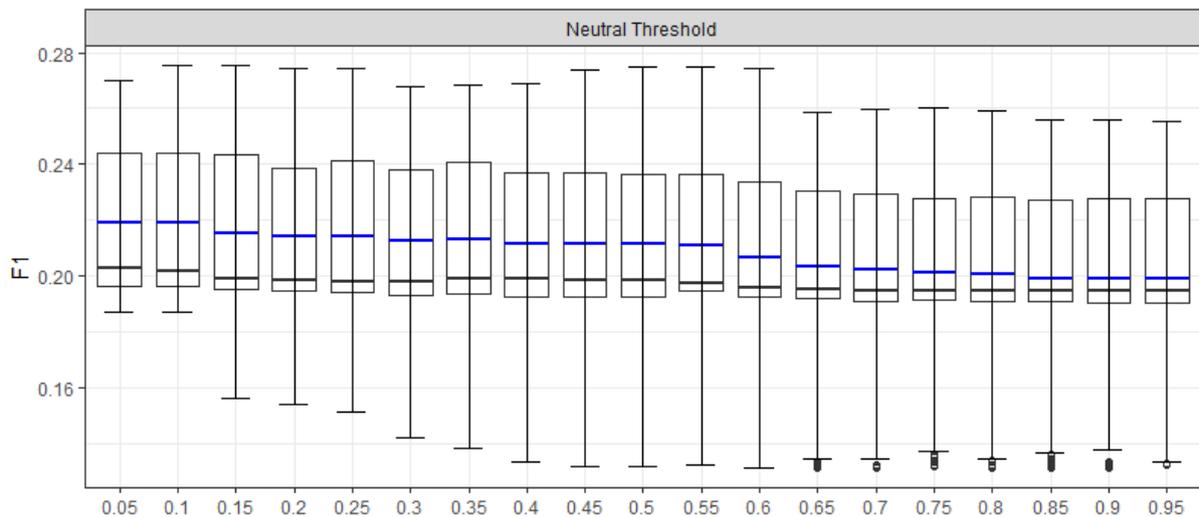


Abbildung 64: Schwellenwerte im Umgang mit der Klasse Neutral

Die Konfiguration zur Berechnung des optimalen Ergebnisses für die Erstellung und Anwendung des maschinell generierten Lexikons ist in Abbildung 60 dargestellt.

Einstellung	Wert
Kontext	LC
Datenreduktion	LEMMA
Datenanreicherung	NEGATION
Synonymgewichtungen	1
Schlüsselwortgewichtungen	4
Aggregationstyp	SUM
Wortgewichtung	IDF AND SEEDWORDS
Schwellenwerte der semantischen Ähnlichkeiten	$\psi_{\text{Emotivswort}} = 0,5$ $\psi_{\text{Schlüsselwort}} = 0,5$ $\psi_{\text{Rest}} = 0,7$
Umgang mit der neutralen Klasse	MIN_THRESHOLD
Schwellenwert $\gamma$ beim Umgang mit Neutral	0,05

Abbildung 65: Optimale Konfiguration bei der maschinellen Lexikonerstellung

### 10.7.3 Maschinelles Lernansatz

Im Rahmen von  $n = 14.732$  durchgeführten Testläufen zeigte die Gewichtsinitialisierung XAVIER im Mittel die besten F1-Werte, wenngleich die Vorteile gegenüber XAVIER UNIFORM, RELU und RELU UNIFORM nur marginal sind. Abweichend von den bisherigen Ergebnisvergleichen, wurde hier bewusst nur auf die Ergebniswerte nach der Initialisierung, also der ersten Iteration geachtet. In Abbildung 66 ist dieser knappe Vorsprung dargestellt.

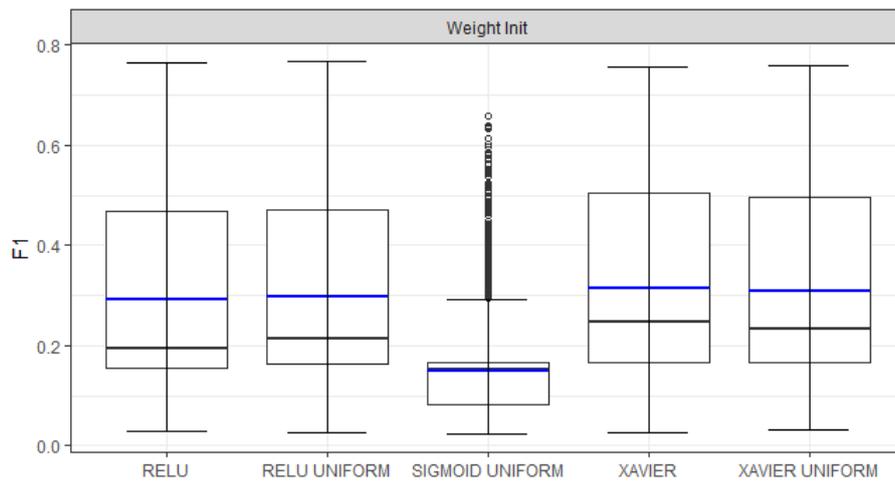


Abbildung 66: Boxplot der Gewichtsinitialisierungen

Unter den adaptiven Lernraten stach für die Textverarbeitung von Nachrichtenkommentaren ADADELTA heraus. Dieses Verfahren hat nicht nur einen höheren Mittelwert, sondern generell weniger niedrigere Werte und ist ausschließlich bei den höchsten Werten vertreten, wie aus Abbildung 67 hervorgeht. Die Gegenüberstellung beruht auf  $n = 34.490$  Ergebniswerten.

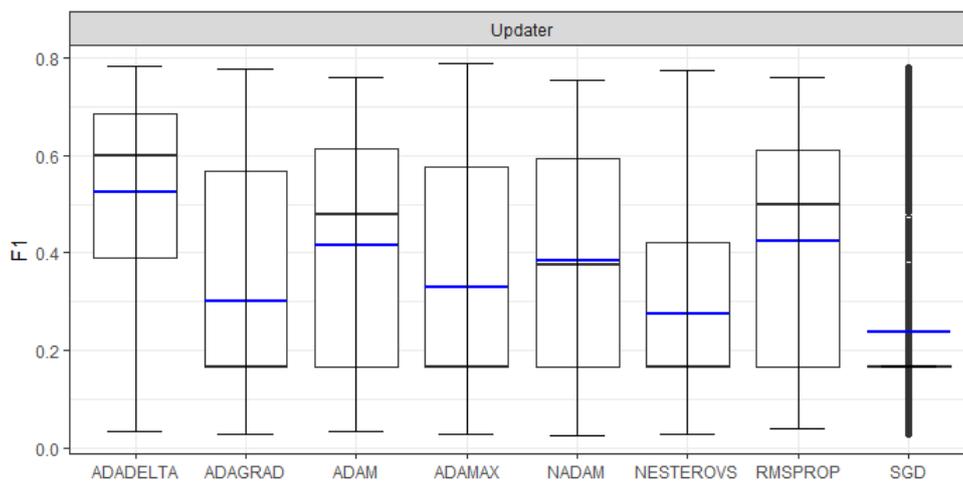


Abbildung 67: Boxplot der Erweiterungen der Lernrate

Das Liniendiagramm in Abbildung 68 führt die Überlegenheit dieser Lernrate, bezogen auf den speziellen Datensatz, fort. Es ist anzumerken, dass bei dem SGD und weiteren

Verfahren äußerst viele fehlerhaft initialisierte Werte vorhanden sind, die in der Grafik in Abbildung 63 ebenfalls herausgenommen wurden.

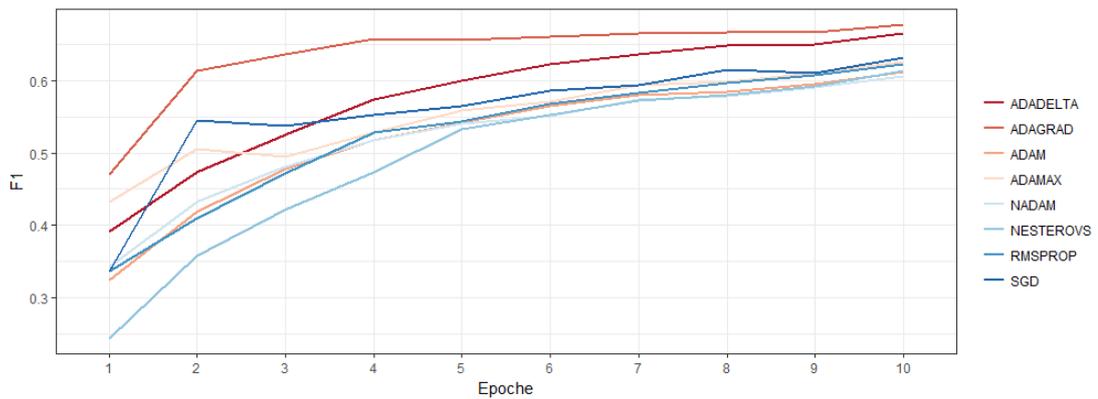


Abbildung 68: Entwicklung der F1-Werte pro adaptiver Lernrate und Epoche

Der Wechsel der nichtlinearen Aktivierungsfunktion führt nur zu marginal unterschiedlichen Werten. Dies wird aus Abbildung 69 ersichtlich, deren Boxplot auf einer Analyse von  $n = 34.490$  Ergebnissen fußt. Wegen der besten Medianausprägung wird dabei LEAKYRELU der Vorzug gegeben.

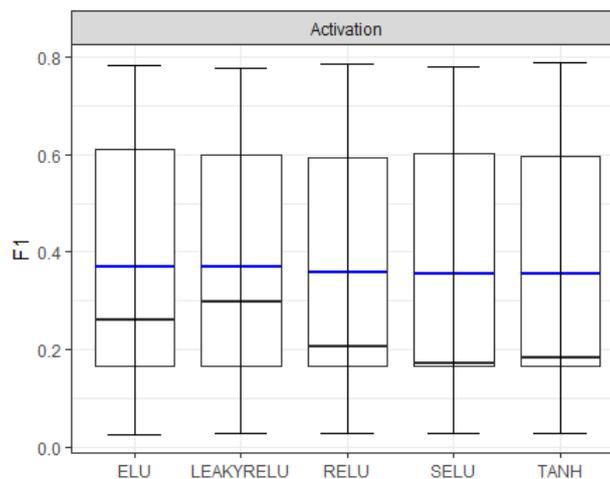


Abbildung 69: Boxplot der nichtlinearen Aktivierung

Wie in Abbildung 70 zu sehen ist, beginnt der hyperbolische Tangens zwar mit dem geringsten Wert, jedoch erzielt dieser mit voranschreitender Trainingsdauer bessere Ergebnisse. Aus diesen Grund und der marginalen Abweichung der Werte wird sich für TANH entschieden.

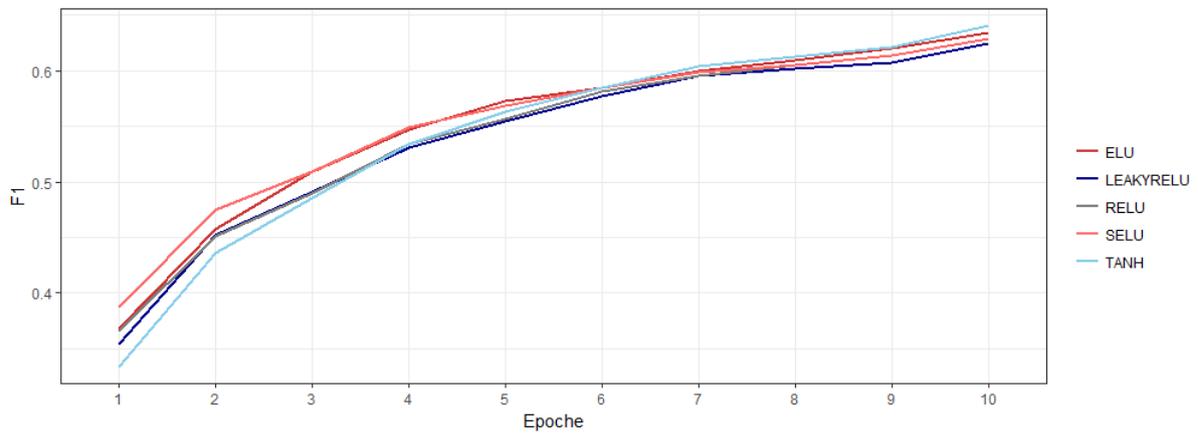


Abbildung 70: Entwicklung der F1-Werte pro Aktivierungsfunktion und Epoche

Das *Max-Pooling* stellt das vielversprechendste Verfahren dar. Dies zeigt sich auch durch den großen Abstand der Mittel- und Medianwerte auf dem Boxplot in Abbildung 71. Als Grundlage dienen in diesem Fall  $n = 40.000$  F1-Werte.

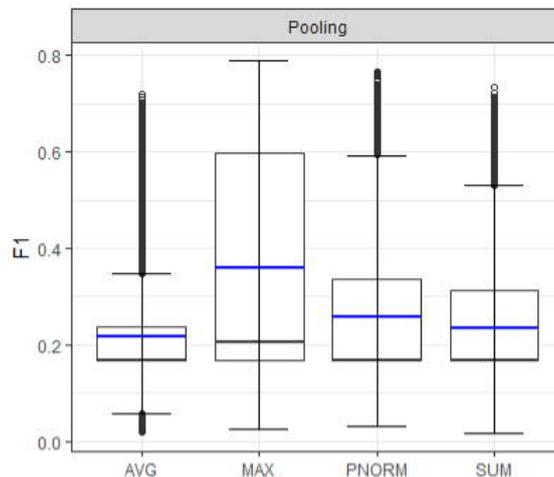


Abbildung 71: Boxplot der Pooling-Varianten

Diese Information findet sich auch in Abbildung 72. Trotz der vielen Exklusionen fehlerhaft initialisierter Werte der *Pooling*-Konfigurationen AVG, PNORM und SUM zeigt sich die Methode MAX den anderen überlegen.

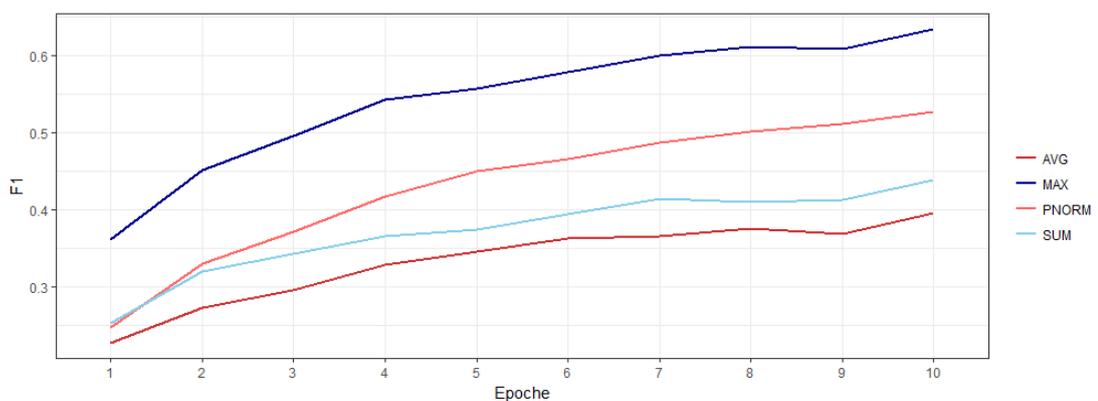


Abbildung 72: Entwicklung der F1-Werte pro Pooling-Konfiguration und Epoche

Bei der Anzahl der Filter zeigten sich die Einstellungen mit 70 bzw. 200 Filtern pro Faltungsschicht die vielversprechendsten Werte. Der Median- und Mittelwertvergleich aus Abbildung 73 basiert auf  $n = 34.490$  Berechnungsergebnissen.

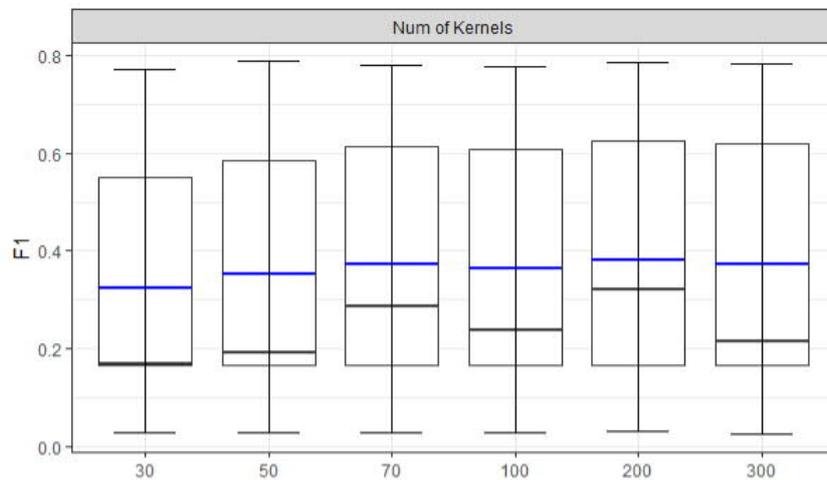


Abbildung 73: Boxplot der Anzahl der Filter pro Faltungsschicht

Aufgrund der Ergebnisse der hier durchgeführten Analyse wird sich hier auf 200 Filter je Faltungsschicht konzentriert. Wie bei den vorangegangenen Analysen soll das Liniendiagramm in Abbildung 74 zusätzliche Einblicke gewähren.

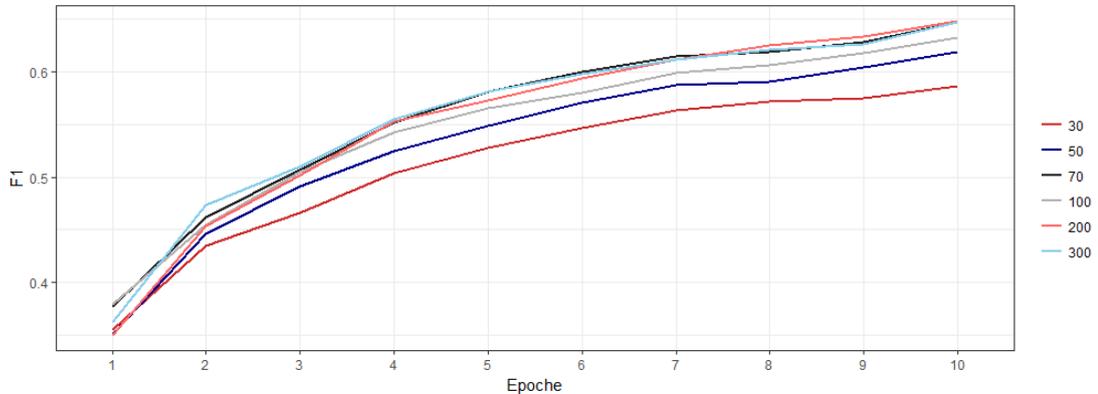


Abbildung 74: Entwicklung der F1-Werte pro Filteranzahl und Epoche

Unter den beiden Verlustfunktionen wird der Kreuzentropie im Vergleich zum mittleren quadratischen Fehler der Vorzug gegeben. Die Analyse der  $n = 20.000$  Ergebnisberechnungen zeigt zwar eine höhere Streuung der Werte, jedoch auch einen im Mittel höheren F1-Wert. Zu sehen ist dies in Abbildung 75.

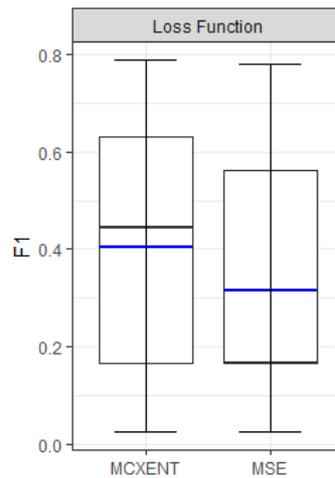


Abbildung 75: Boxplot der Verlustfunktion

Gleiches ist in der epochenweisen Betrachtung der Verlustfunktion zu beobachten. In dem Liniendiagramm in Abbildung 76 wird dies ersichtlich.

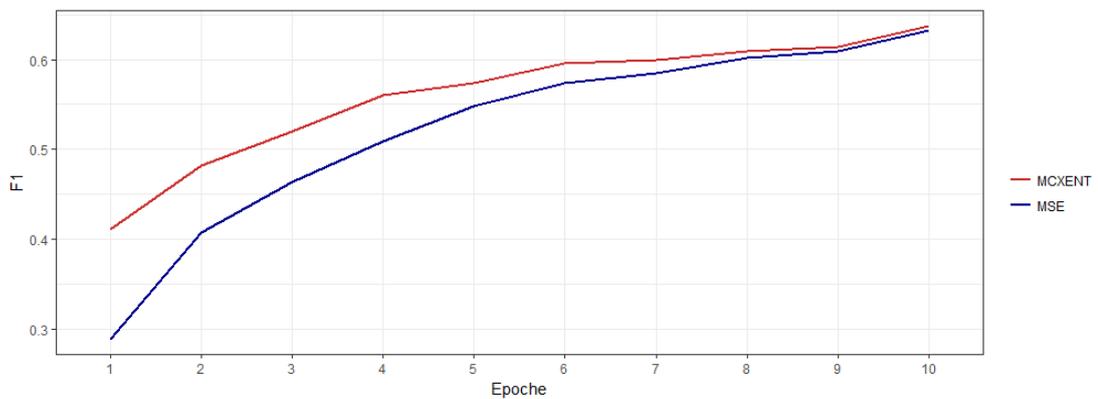


Abbildung 76: Entwicklung der F1-Werte pro Verlustfunktion und Epoche

Als Regularisierungswert wird 0,00033 der Vorzug gegeben, wengleich auch der nächstkleinere Wert ein valides Ergebnis liefern würde. Die marginalen Abstände der Medianwerte können Abbildung 77 entnommen werden. Diese Analyse fußt ebenfalls auf einer Menge von  $n = 30.000$  Ergebnisberechnungen.

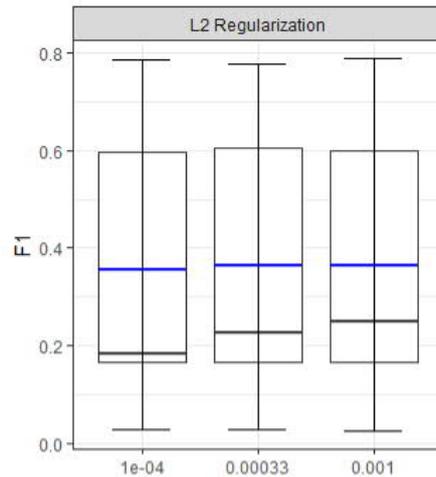


Abbildung 77: Boxplot der unterschiedlichen Werte der L2-Regularisierung

Abbildung 78 führt die Unterschiede als Liniendiagramm fort. Hier ist nur eine marginale Überlegenheit auszumachen.

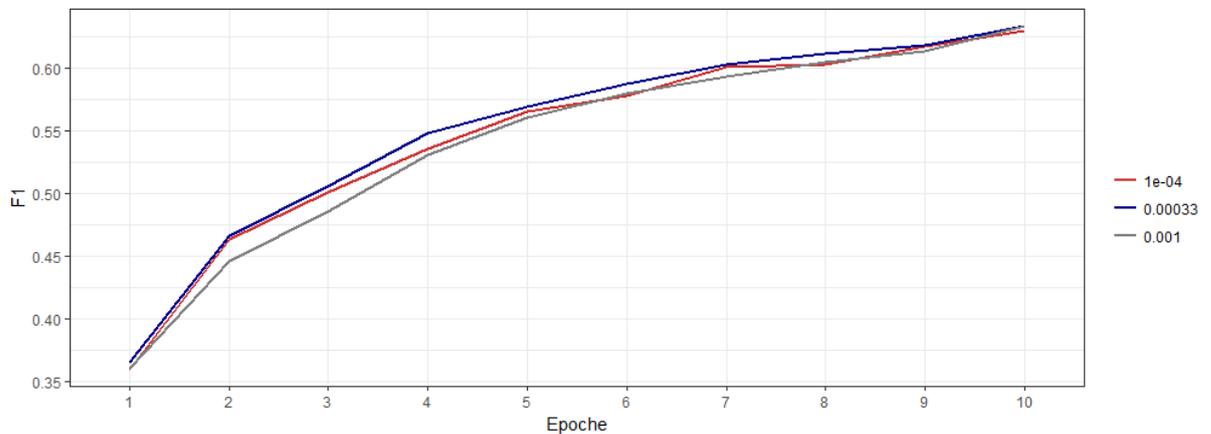


Abbildung 78: Entwicklung der F1-Werte pro Regularisierungswert und Epoche

In einer vorgelagerten Analyse erwies sich ein Dropout-Wert von 0,7 als die vielversprechendste Parametereinstellung mit Dropout. Eine Analyse, basierend auf  $n = 20.000$ , zeigt jedoch im Mittel ein besseres Ergebnis ohne Dropout für die textuelle Klassifikation von Nachrichtencommentaren, wie aus Abbildung 79 ersichtlich wird.

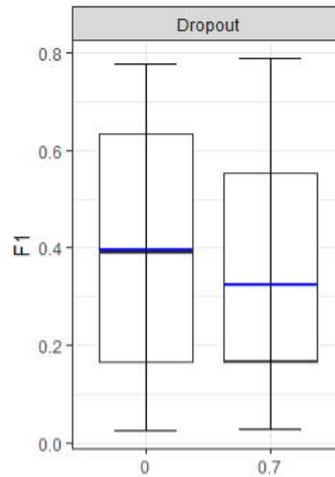


Abbildung 79: Boxplot der Ergebniswerte mit und ohne Dropout

Diese Einschätzung wird in einer epochenweisen Darstellung durchgehen bestätigt. Zu sehen ist dies in Abbildung 80.

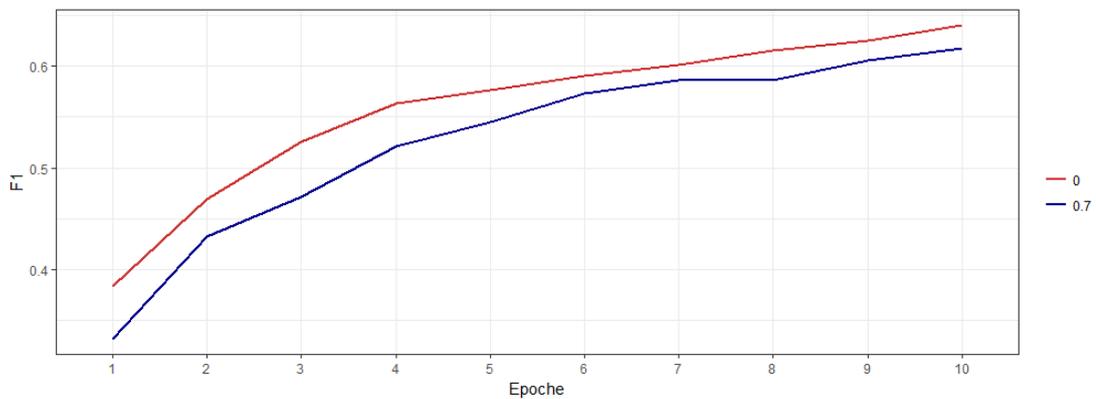


Abbildung 80: Entwicklung der F1-Werte pro Dropout-Konfiguration und Epoche

Für die Ermittlung des optimierten Ergebnisses wird folgende Konfiguration verwendet:

Einstellung	Wert
Gewichtsinitialisierungen	XAVIER_UNIFORM
Nichtlineare Aktivierungsfunktion	LEAKYRELU
Adaptive Lernrate	ADADELTA
Pooling	MAX
Anzahl der Filter pro Faltungsschicht	200
Verlustfunktion	MCXENT
L2-Regularisierung	0,00033
Dropout	0

Tabelle 57: Optimale Konfiguration beim CNN-Verfahren

### 10.7.4 Gegenüberstellung der optimierten Ergebnisse

In der bisherigen Überprüfung wurden nur Hypothesen verifiziert bzw. falsifiziert oder die beste Konfiguration ausfindig gemacht. Die optimalen Ergebnisse wurden dabei noch nicht ermittelt. Bis dato wurde nur der Trainings- und Validierungsdatensatz verwendet. Um ein aussagekräftiges Ergebnis zu erhalten, blieb der Testdatensatz bisher unangetastet.

Für diese letzte Überprüfung sollen nun sowohl die Erkenntnisse aus den vorangegangenen Hypothesen als auch die darin verwendeten Konfigurationen in die Parametergestaltung einfließen. Alle in Tabelle 58 dargestellten Werte beziehen sich auf Berechnungen des *Macro-Average* mit gleichmäßiger Gewichtung aller Klassen. Alle CNN Modelle wurden bis zur Konvergenz berechnet.

Methode	Kontext	Reduktion & Anreicherung	Accuracy	Precision	Recall	F1
Manuelle Lexikonerstellung	LC	LEMMA_NEG	0,46	0,4	0,47	0,41
Maschinelle Lexikonerstellung	LC	LEMMA_NEG	0,3	0,26	0,3	0,26
CNN	LC	UNCHANGED	0,69	0,75	0,69	0,70
CNN	LC	LEMMA	<b>0,77</b>	0,80	<b>0,77</b>	0,77
CNN	LC	LEMMA_NEG	<b>0,77</b>	0,81	<b>0,77</b>	<b>0,78</b>
CNN	LC	WORD	<b>0,77</b>	0,82	<b>0,77</b>	<b>0,78</b>
CNN	LC	WORD_NEG	<b>0,77</b>	0,81	<b>0,77</b>	<b>0,78</b>
CNN	C	WORD_NEG	0,75	<b>0,83</b>	0,75	0,77
CNN	CR	WORD_NEG	0,75	<b>0,83</b>	0,75	0,77
CNN	LCR	WORD_NEG	0,74	<b>0,83</b>	0,75	0,77

Tabelle 58: Ergebniswerte der Emotionserkennung bei Nachrichtenkommentaren

In Abbildung 81 und Abbildung 82 wurden die Entwicklungen der F1 Werte während der Ermittlung der optimierten Ergebnisse aus der Exploration der Designalternativen für die ersten 20 Epochen abgebildet. Wie in beiden Abbildungen ersichtlich ist, wird bereits nach wenigen Epochen ein Wert erreicht, der in ähnlichen Größenordnungen ist wie der konvergierte Wert der jeweiligen Konfiguration. Zu beachten ist in Abbildung 81, dass bei der Konfiguration C | WORD NEG in Epoche 5 ein Einbruch ist. Dieser Einbruch entsteht durch die nicht vollständige Klassifizierung aller Emotionen und führt zu den Komplikationen der *Precision*-Berechnung, die in Kapitel 8.2.2 näher beschrieben wurden.

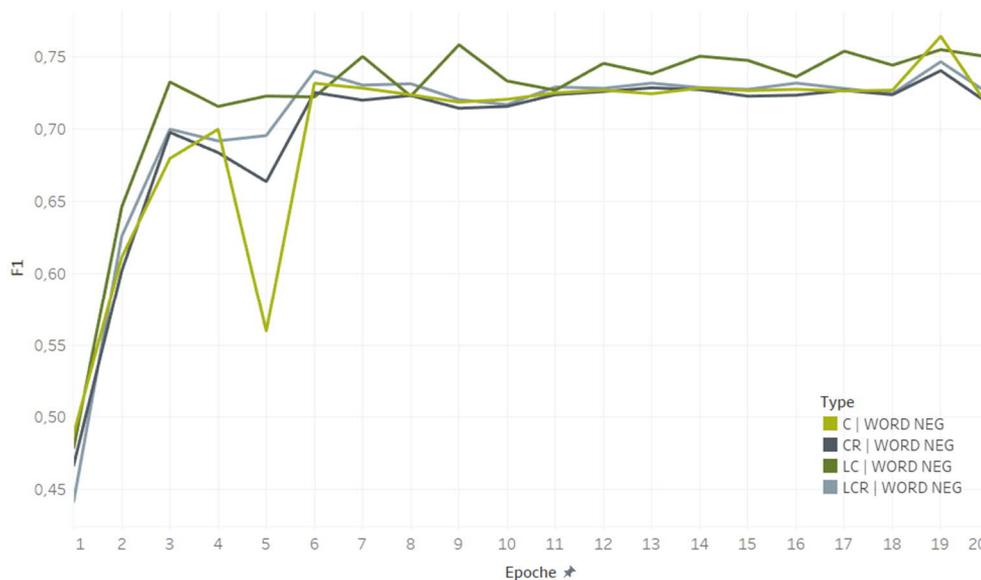


Abbildung 81: Entwicklung der F1 Werte für die Konfiguration WORD NEG

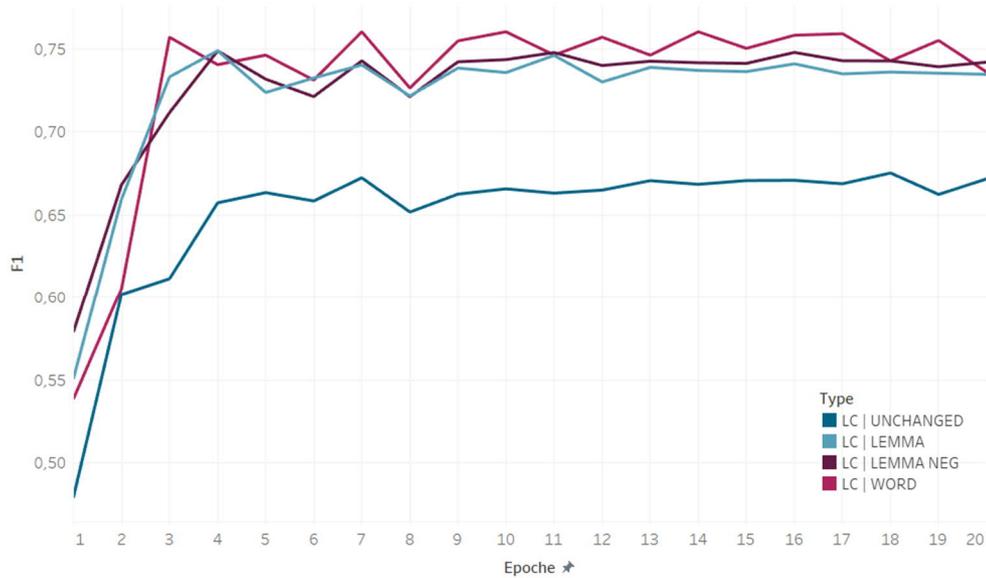


Abbildung 82: Entwicklung der F1 Werte für die restlichen CNN Konfigurationen

Darüber hinaus wird für den Ansatz des maschinellen Lernens der Trainingsfehler bezogen auf die MCXENT Zielfunktion angegeben, um die Stabilität des Modells transparent zu machen. Die nachfolgenden Abbildungen beziehen sich ebenfalls auf die ersten zwanzig Epochen, wobei jeweils nach 100 Lerniterationen Datenpunkte erhoben wurden, was ca. 6,2 Datenpunkten je Epoche entspricht. Zum Vergleich wurden sowohl die Werte der MCXENT Zielfunktion des Trainingsvorgangs (Train) mit den Validierungsdaten, als auch des finalen Tests (Test) durchgeführt.

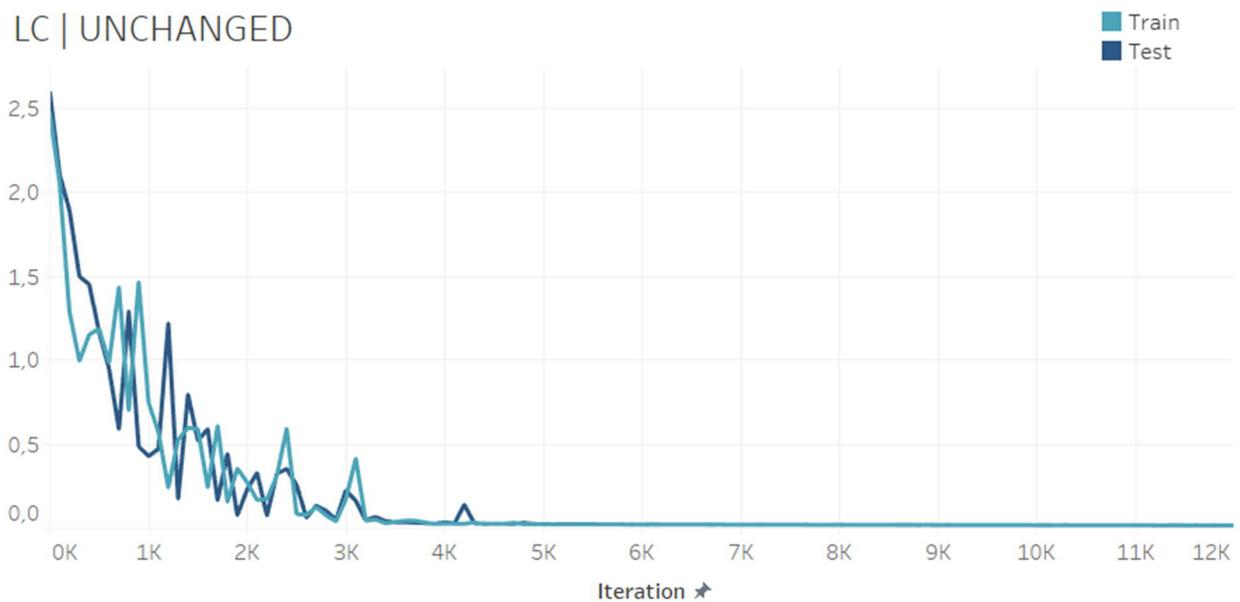


Abbildung 83: Entwicklung der Zielfunktionswerte der Konfiguration LC | UNCHANGED

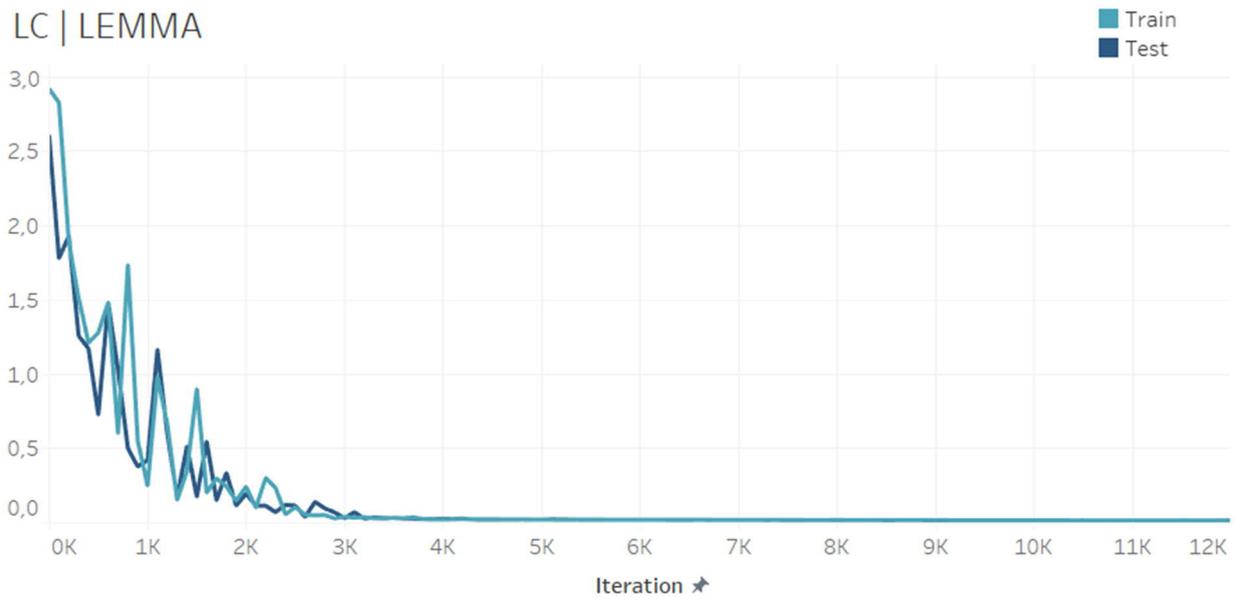


Abbildung 84: Entwicklung der Zielfunktionswerte der Konfiguration LC | LEMMA

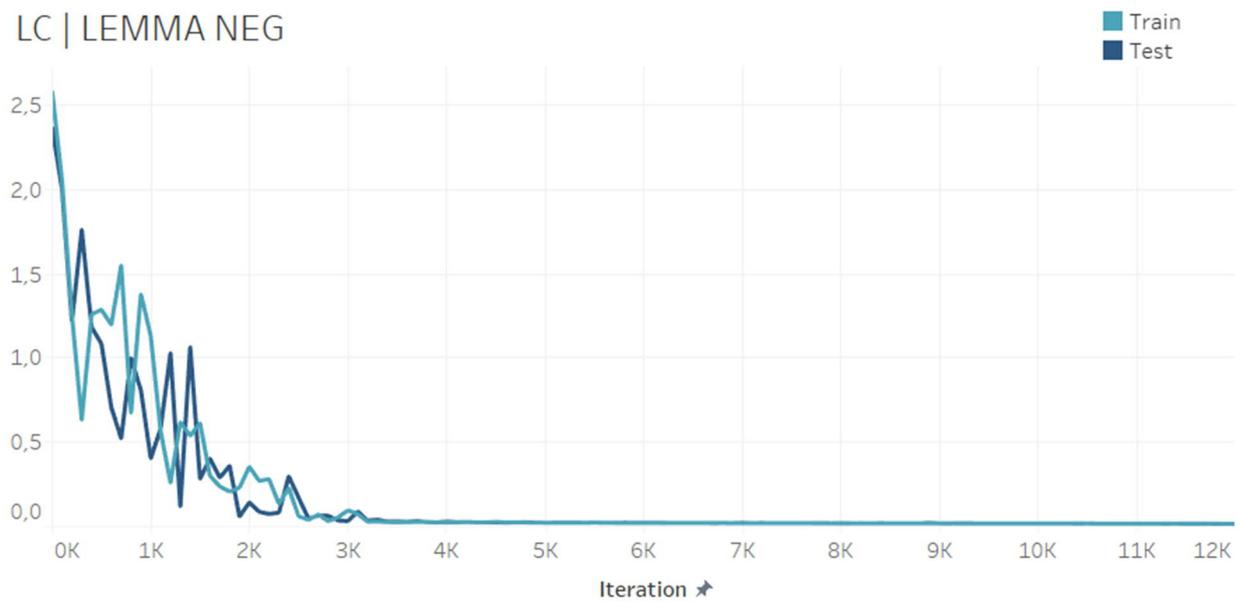


Abbildung 85: Entwicklung der Zielfunktionswerte der Konfiguration LC | LEMMA NEG

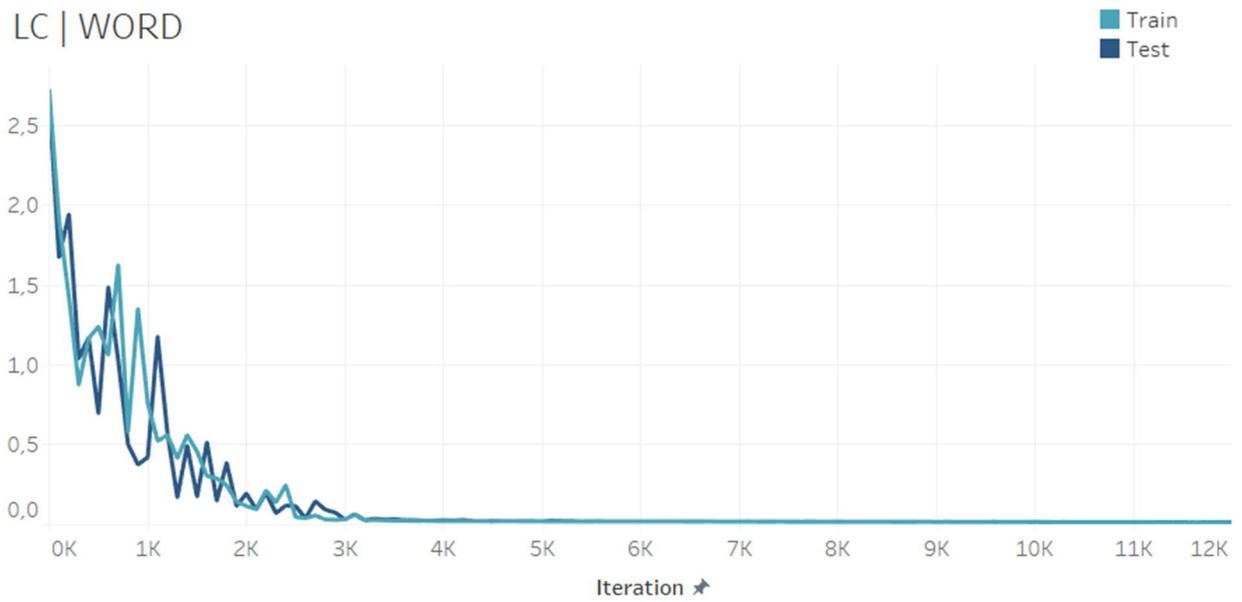


Abbildung 86: Entwicklung der Zielfunktionswerte der Konfiguration LC | WORD

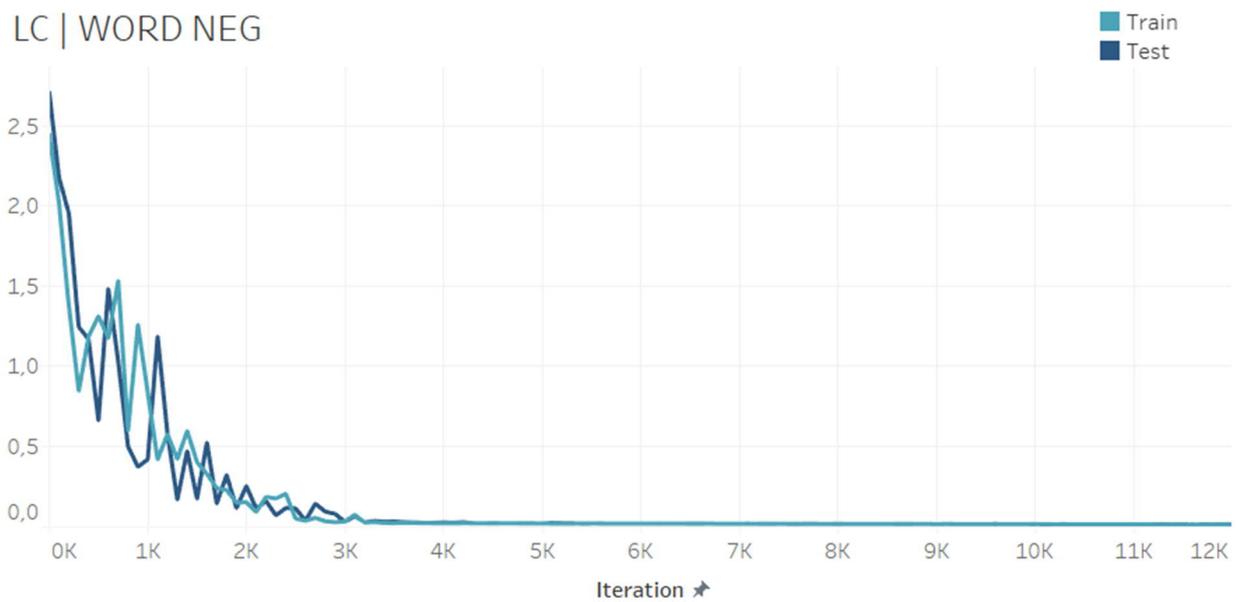


Abbildung 87: Entwicklung der Zielfunktionswerte der Konfiguration LC | WORD NEG

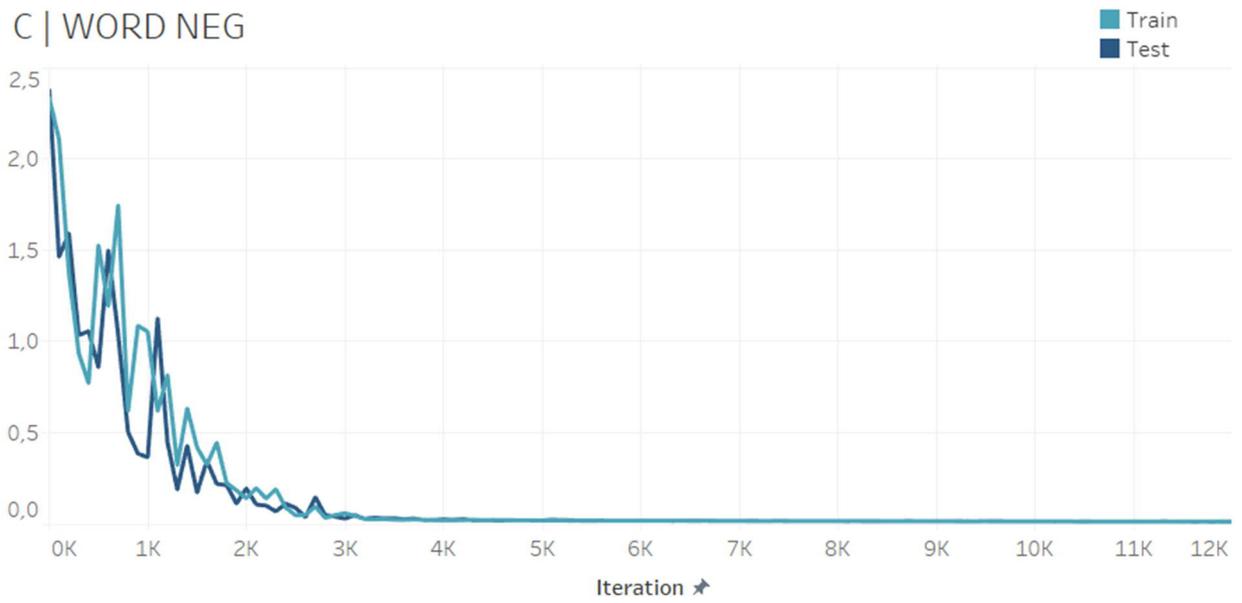


Abbildung 88: Entwicklung der Zielfunktionswerte der Konfiguration C | WORD NEG

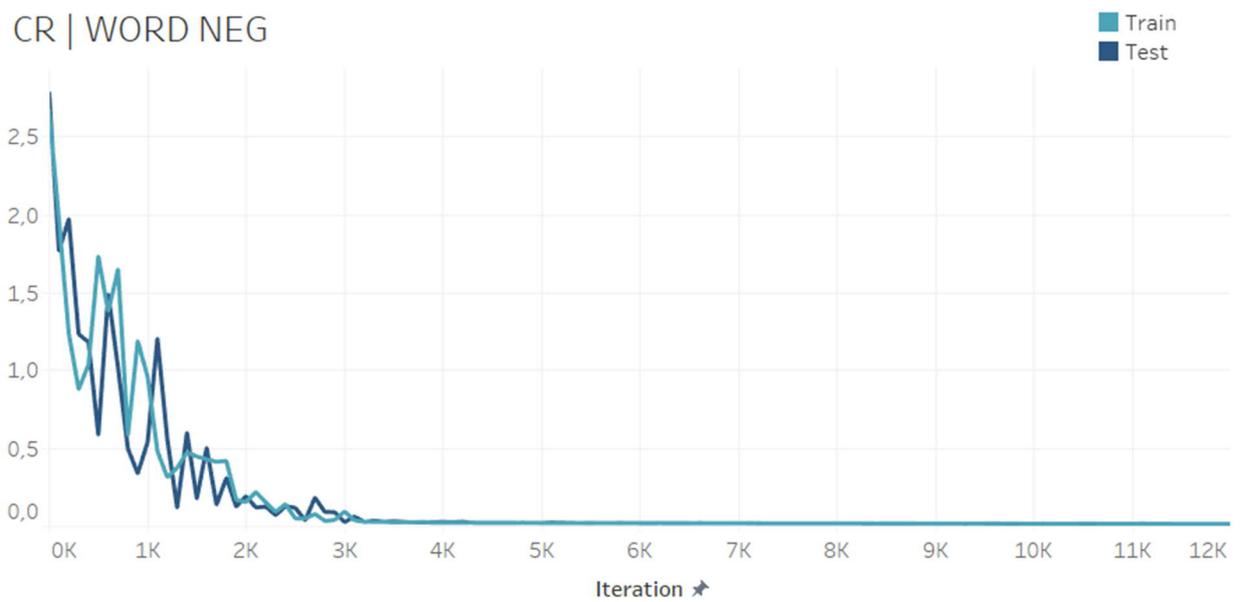


Abbildung 89: Entwicklung der Zielfunktionswerte der Konfiguration CR | WORD NEG

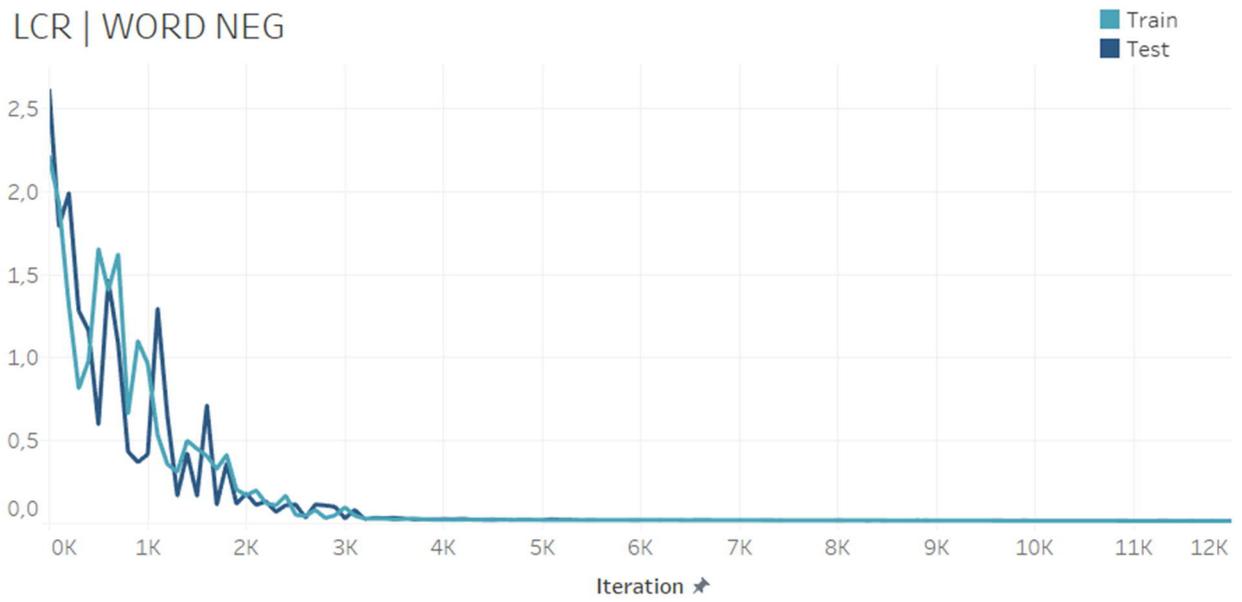


Abbildung 90: Entwicklung der Zielfunktionswerte der Konfiguration LCR | WORD NEG

# 11 Diskussion

## 11.1 Bewertung der Ergebnisse aus emotionstheoretischer Sicht

In Kapitel 2.4 wurden mehrere Fragestellungen aufgeworfen, für die im Folgenden ein Beantwortungsversuch erarbeitet werden soll. Die Fragen waren: Wie strukturieren sich Emotionen? Wie kann man Emotionen bestimmen? Welche Emotionen gibt es?

In den Kapiteln 11.1.1 und 11.1.2 soll ergründet werden, was durch diese Herangehensweise über den Charakter von Emotionen hinsichtlich Unter- und Sekundäremotionen preisgegeben wird. Anschließend soll geklärt werden, ob mit diesem Ansatz beantwortet werden kann, welche Emotionen es gibt, und ob dieser forschungsfeldübergreifende Ansatz zur näheren Bestimmung von Emotionen geeignet ist.

### 11.1.1 Struktur von Emotionen

Der zweite Vorteil, der sich durch die Verknüpfung der beiden Forschungsfelder ergibt, ist die Möglichkeit einer noch spezifischeren Bestimmung von Emotionen. Betrachtet man eine Emotion nicht als Atom in der Demokrit'schen Auslegung, also als etwas unteilbares, sondern als eine sprachliche Zusammenfassung unterschiedlicher Facettierungen einer Gefühlsqualität, lässt dies Raum für weitere Untersuchungen. Anhand annotierter oder klassifizierter Datensätze kann eine dezidiertere Unterteilung der Emotionen vorgenommen werden. Um diese Vorgehensweise zu unterstreichen, wurde dies für den annotierten Datensatz auszugsweise vorgenommen. Es sei an dieser Stelle eindringlich darauf hingewiesen, dass diese Gruppierung keine Allgemeingültigkeit besitzt, da sie nur von dem Autor dieser Arbeit vorgenommen wurde. Somit weist dieses Ordnungsschema einen deutlichen subjektiven Charakter auf. Zudem sei gesagt, dass es deutlich zielführender wäre, eine weiterführende Gruppierung durch mehrere Versuchsteilnehmer vornehmen zu lassen. So wäre beispielsweise eine Vorgehensweise mittels Sortierung analog zu dem Versuchsaufbau von Schmidt-Atzert & Ströhm (1983) denkbar. Nichtsdestotrotz lässt sich durch diesen exemplarischen Gliederungsversuch bereits die Behauptung untermauern, dass durch diese Herangehensweise eine detailliertere Betrachtung der Emotionen möglich ist und die Emotionspsychologie von annotierten bzw. klassifizierten Datensätzen aus dem angrenzenden Wissenschaftszweig profitiert.

Bei der hier durchgeführten Differenzierung wurden zwei manuelle Gruppierungsverfahren angewendet. In erster Instanz wurden die annotierten Kommentarabschnitte abstrahiert. Die generischen Textbausteine wurden dann entsprechend ihrer Bedeutung gruppiert, so dass sich individuelle sprachliche Ausprägungen nivellierten, jedoch markante Merkmale erhalten

blieben. An einem Beispiel soll dies illustriert werden. So können die Aussagen „ich habe Angst vor diesen langbeinigen Viechern“ und „wenn ich Spinnen sehe, dann läuft es mir eiskalt den Rücken runter“ zu einer Angst vor Spinnen zusammengefasst werden. Kommt dann noch der Satz „bei Mäusen stehe ich immer kreischend auf dem Stuhl“ dazu, dann ergibt sich eine allgemeine Angst vor Tieren. Sammelt man noch mehr Beispiele, wie „ich fürchte mich vor engen Räumen“, können dies Angstaussprägungen zu einer generellen Phobie zusammengefasst werden. Diese Abstraktionsebene ist eine Gratwanderung, denn einerseits soll sie trennscharf sein, andererseits durch ausreichend Beispiele belegt werden können, und unterliegt persönlichen Ansichten.

Zur besseren Gliederung wurden im zweiten Schritt Gliederungsdimensionen erarbeitet, so dass jedem oben entstandenen Muster eine individuelle Ausprägung zugeordnet werden kann. Dabei handelt es sich nicht um einen dimensionalen Ansatz, sondern um eine Entscheidungshilfe zum Zusammenführen ähnlicher Emotionsausprägungen. Es wurde darauf geachtet, dass die Unterscheidungskriterien möglichst emotionsübergreifend angewendet werden können. Durch das Dimensionsraster lässt sich jeweils eine ordinale bzw. nominale Unterscheidung vornehmen, die als Unterstützungshilfe herangezogen wurde, um gleichartige Emotionsausprägungen zu gruppieren.

Die Dimensionen Horizont, Perspektive, Erwartung, Anwesenheit, Attribution, Bewertung durch Dritte und Bezug wurden hier als zielführend erachtet. Der Horizont differenziert reale Begebenheiten von hypothetischen oder zukünftigen Ereignissen. Die Perspektive betrachtet den Referenzpunkt, von der aus eine Person fühlt bzw. sich hineinversetzt. Die Erwartungshaltung bezüglich eines Ereignisses ist eine Dimension, die ausschließlich für die Emotion der positiven Überraschung notwendig ist, da die anderen Kriterien dies nur unzureichend abgrenzen. Die Anwesenheit beschreibt, ob ein Gefühl durch die Anwesenheit oder Abwesenheit von etwas entsteht. Die Attribution definiert, ob ein Gefühl internal oder external zugeschrieben wird. Die Bewertung durch Dritte fügt die Komponente der sozialen Erwünschtheit hinzu. Schließlich komplettiert der Bezug die schematische Trennung, indem der Gegenstand, auf den sich die Emotion bezieht, aufgeschlüsselt wird. Auch hier sei darauf hingewiesen, dass dieses Gliederungsschema und deren Ausprägungen nicht vollständig sind, da es nur wenige annotierte Datensätze abdeckt und eine deutliche subjektive Färbung bei der Einordnung aufweist, da es abermals nur aus der Feder einer einzelnen Person stammt.

Durch eine Vielzahl an emotionstragenden Sätzen entsteht durch die Zusammenfassung peu à peu ein deutlicheres Mosaik der jeweiligen Unteremotionen, in der sich häufig vorkommende Muster deutlich herausbilden und sich seltenere Verwendungen dieser Emotion

abzeichnen. An dieser Stelle sei sich nochmals unmissverständlich von einer Beweisführung zur Existenz von Primär- und Sekundäremotionen abgegrenzt. Es wird hier vielmehr die Ansicht vertreten, dass Emotionen durch ein existentes Emotionsmodell vorgegeben sind und sich genauer differenzieren lassen. Im Anhang in Kapitel 12.3 wird der Großteil der im annotierten Datensatz erkannten Unteremotionen tabellarisch dargestellt. Sofern einer Dimensionsausprägung einer Unteremotion keine Einordnung zugrunde liegt, kann dies zweierlei Gründe haben: Einerseits kann dies bedeuten, dass sie anhand des zugrunde liegenden Datensatzes nicht zuordenbar war, oder andererseits, dass nicht ausreichend Datensätze vorhanden waren, um sie feiner aufzuteilen, jedoch eine genauere Gliederung vermutet wurde. Angesichts der relativ geringen Anzahl der vorliegenden Emotionsannotationen stellt dies jedoch nur einen ersten Schritt in der dezidierten Differenzierung der Emotionen dar.

Zahlreiche Vorteile sprechen für die hier exemplarisch angewendete Herangehensweise der Emotionsinduktion. Zum einen reiht sich diese Methode nicht in die Fülle an deduktiven Emotionsbestimmungsverfahren ein, sondern bietet eine Grundlage zur Steigerung des semantischen Informationsgehalts mittels Schlussfolgerung (Johnson-Laird, 1993; Sternberg, 1998). Durch diesen empirischen Ansatz werden Emotionen in der natürlichen Umgebung bzw. im unverfälschten Kontext verwendet, da die Verfasser eines Kommentars nicht explizit zum Generieren eines emotionsgeladenen Textes aufgefordert werden. Ein weiterer Vorteil dieser Herangehensweise ist, dass sie mit nahezu beliebig vielen Daten durchgeführt werden kann. Dieser Punkt wird umso stärker gewichtet, wenn man bedenkt, dass sehr viele frei verfügbare Datensätze vorhanden sind und unaufhörlich neue Texte hinzukommen. Grundsätzlich kann davon ausgegangen werden, dass sich ein größerer Datenpool positiv auf die Genauigkeit des Modells auswirkt. Man darf jedoch nicht vergessen, dass dieser Methodik, zumindest für den hier examinierten Datensatz, eine domänenspezifische Betrachtung anhaftet und somit keine Allgemeingültigkeit gegeben ist. Darüber hinaus kann als nachteilig eingestuft werden, dass nicht alle Emotionen in gleicher Menge vorkommen, wie die divergierende Anzahl der Datenannotationen zeigt. Ferner ist diese Vorgehensweise arbeitsaufwendig, da zahlreiche manuelle Prüfungen und Bewertungen vorgenommen werden müssen, womit eine nicht normative Kategorisierung und eine Prägung der Emotionseingliederung einhergehen. Wenngleich der subjektiven Verzerrung durch eine konsolidierte Fassung mehrerer Betrachter entgegengewirkt werden kann, so erhöht dies den Aufwand doch um ein Vielfaches. Abschließend kann gesagt werden, dass diese Methodik mühsam ist, sie den Unteremotionen jedoch ohne Heerscharen von Versuchspersonen sowie vor allem durch Anstrengung und Fleiß auf die Spur kommen kann.

An dieser Stelle ist nicht geklärt, ob eine Feineinteilung der Emotionen in einer Taxonomie mündet oder ob es losgelöste, voneinander unabhängige Unteremotionen sind. Dies sowie eine detailliertere Betrachtung der Emotionen sind in zukünftigen Forschungen zu klären.

### **11.1.2 Sekundäremotionen**

Wie im Theorieteil gezeigt wurde, sind Sekundäremotionen, die sich ähnlich einer Farbpalette aus dem Mischen mehrerer Primäremotionen zusammensetzen, umstritten. Wenngleich es nicht das primäre Ziel dieser Arbeit war, ihre Existenz zu beweisen bzw. zu falsifizieren, so ergeben sich durch diese Art der Emotionsbestimmung dennoch relevante Einblicke. Formuliert man die Frage dahingehend, ob sich mehrere Emotionen zu einer Sekundäremotion formen oder ob sie diskret zueinander koexistieren, lassen sich anhand des annotierten Datensatzes Aussagen dazu treffen.

Als Voraussetzung für die Existenz von Sekundäremotionen müssen zwei unterschiedliche Emotionen vorliegen, die von den Annotatoren jedoch unterschiedlich gekennzeichnet wurden. Sowohl in den aussortierten Datensätzen, die als nicht bestimmbar oder als Doppelemotionen gekennzeichnet wurden, als auch in der zusätzlich vorgenommenen feineren Schematisierung der Emotionskategorien konnte keine Vermengung der Emotionen festgestellt werden. Dies wurde daran ausgemacht, dass eine Sekundäremotion, die dann auszumachen wäre, wenn sich zwei Primäremotionen zu einer resultierenden Emotion verbinden und dabei die beiden ursprünglichen Emotionen verloren gehen, kein einziges Mal erkannt wurde. Diese deskriptive Herangehensweise kann als Indiz dafür genommen werden, dass aus der Vermengung von Primäremotionen keine resultierenden Emotionen erwachsen.

Der Umkehrschluss, also die Nichtexistenz von Sekundäremotionen, legt nahe, dass Emotionen nur koexistieren. Zumindest im gewählten Emotionsmodell spricht vieles für diese Aussage, denn in den aussortierten Annotationsdatensätzen wurden mehrere gleichzeitig vorkommenden Emotionen festgestellt, die nicht selten und in nahezu allen Kombinationen auftauchten. Bezogen auf die nicht ausgeschlossenen Datensätze wird dies auch bei den Emotionen Verachtung in Verbindung mit Wut erkennbar. Diese blieben aufgrund ihrer großen Häufigkeit in dem annotierten Datensatz verankert und wurden von den Annotatoren als Wut deklariert, da dies von ihnen als dominante Emotion erkannt wurde. Die ist in Übereinstimmung mit den Beobachtungen anderer Emotionsforscher. Wie Reisenzein & Hofmann (1993) anführen, ist eine Bewertungssituation nicht selten eine Zusammensetzung mehrerer Emotionen, da die Gesamtsituation bewertet wird und nicht einzelne Aspekte. Dies hat zur Folge, dass es zu Überlagerungen zwischen den einzelnen Emotionsclustern kommt.

Sowohl die Beobachtung der fehlenden Vermengung zweier Emotionen als auch die Koexistenz mehrerer Emotionen deuten darauf hin, dass die Kritik an den Sekundäremotionen nicht unbegründet ist. Für einen eindeutigen Gegenbeweis gegen die Existenz von Sekundäremotionen wird an dieser Stelle auf zukünftige Forschung verwiesen.

### **11.1.3 Forschungsfeldübergreifender Ansatz der Emotionsbestimmung**

Das übergeordnete Ziel dieser Arbeit ist es, die beiden Forschungsfelder Psychologie und Computerlinguistik näher zusammenzubringen. Aus emotionstheoretischer Perspektive soll erläutert werden, ob dieser forschungsfeldübergreifende Ansatz für eine nähere Bestimmung von Emotionen geeignet ist. Im Nachfolgenden soll zunächst aus psychologischer Sicht argumentiert werden, ob und inwiefern dadurch profitiert werden kann.

Der Schulterschluss zwischen Psychologie und Computerlinguistik eröffnet neue Möglichkeiten in der Emotionsforschung. Wie gezeigt wurde, können mit Hilfe der angewendeten Methodik relativ zielsicher Textdaten in großer Menge automatisiert klassifiziert werden. Durch die Vielzahl der Datensätze lassen sich Emotionen und deren spezifische Ausprägungen noch besser untersuchen. Dies wurde bereits an den Unter- und Sekundäremotionen unter Beweis gestellt. Es wird hier argumentiert, dass eine theoretische Auseinandersetzung mit den Emotionen zu einem gewissen Grad zielführend ist, jedoch muss sich dieses theoretische Konstrukt auch in der Praxis bewähren. Die über hundert Jahre alte Emotionsforschung und der fehlende Konsens untermauern dies. Wie im Theorieteil der Emotionsmodelle angedeutet wurde, zeigen sich besonders jene Modelle am vielversprechendsten und aussagekräftigsten, die auf Sortierverfahren oder Emotionsgruppierungen basieren, da gerade an diesen Methoden der Schritt in die Empirie gewagt wurde. Auch die hier vorgestellte Arbeitsweise eröffnet den Weg zur praktischen Validierung von Emotionsmodellen und zur Überprüfung theoriebasierter Annahmen an realitätsbezogenen Situationen. Bekräftigt wird dieses Argument von Meiselman (2016) wenn er zur Messung von Emotionen sagt, dass *„[t]hose looking for affective data without interrupting the daily flow of life should be interested in sentiment analysis, or the textual material including social media messages“*. Durch die relative Anonymität im Internet und die laborfernen Rahmenbedingungen entsteht zudem ein geringer Beobachtungsfehler (Wirtz, 2017).

Für eine explorative Bestimmung der Emotionen eignet sich dieser Ansatz jedoch nur bedingt. Die Annotation der Datensätze war nur deshalb möglich, da nach vorgegebenen Emotionskategorien gesucht wurde. Eine explorative Emotionsfindung ist jedoch nicht ausgeschlossen. Denkbar wäre dies beispielsweise mittels einer dreistufigen Herangehensweise. In erster

Instanz würden subjektive bzw. meinungsgeladene Texte annotiert. Im zweiten Schritt könnten dann von weiteren Annotatoren Emotionsbegriffe hinzugefügt werden. Im dritten Schritt müssten die gefundenen Emotionsbegriffe konsolidiert werden. Sind genügend Emotionen des gleichen Typs vorhanden, dann könnte dies als Indiz dafür gewertet werden, dass es sich um eine benennbare Emotion handelt. Das resultierende Emotionsschema würde nicht nur alle im Text vorkommenden Emotionen unter einen Hut bringen, sondern ein zugrunde liegendes Ordnungsschema in Form einer Hierarchie schaffen. Der Grund, warum dies jedoch nur bedingt für eine explorative Bestimmung geeignet ist, liegt darin, dass nicht alle Emotionen freizügig preisgegeben werden bzw. textuell vorhanden sind.

Mit der annotationsbasierten Herangehensweise lassen sich diffizile Unterscheidungsverfahren und offene Fragestellungen der Emotionsforschung näher ergründen. Auch ohne Erkennung der Referenzmarker ist eine Differenzierung der Emotionen maschinell möglich. Die Emotionsklassen Ekel vor Objekten bzw. Verhaltensweisen und Abscheu bzw. Verachtung von Menschen wiesen in den Ergebnissen keine nennenswerten Unterscheidungsprobleme auf. Vergleicht man die Kategorien untereinander, so zeigt sich in der Annotation kein merklicher Unterschied zu den anderen Kategorien. Ekel und Verachtung wurden von 764 bzw. 974 manuellen Annotationen nur 54 Mal falsch klassifiziert und somit verwechselt. Diese Herangehensweise liefert auch eine Möglichkeit zur Auseinandersetzung mit der offenen Fragestellung der Emotion Überraschung, die von einigen Forschern als zweifelhaft angesehen wird (Ortony & Turner, 1990). Die Emotion der positiven Überraschung war mit 287 Vorkommnissen im Annotationsdatensatz deutlich unterrepräsentiert. Dies ist nicht damit begründet, dass so wenig Datensätze ausgewählt wurden, sondern dass so wenig vorhanden waren. Aufgrund der geringen Anzahl wurden bei dieser Emotion explizite Anstrengungen unternommen, um noch mehr Textpassagen für die Analyse zu inkludieren. Es wurde eine nachgelagerte Annotation möglicher Textstellen vorgenommen, die Überraschung enthalten können, um überhaupt auf die nun gegebene Anzahl von annotierten Datensätzen zu kommen. Dies war jedoch trotz exzessiver Verwendung von Suchworten nur bedingt von Erfolg gekrönt. Da dies keine Emotion darstellt, die man zurückhält oder bei der wie bei Schuld oder Scham persönliche Hürden existieren, kann dies damit begründet werden, dass die Überraschungskurve zu schnell abflaut, textuell nicht geäußert wird oder die Emotion tatsächlich einen zweifelhaften Status hat.

## **11.2 Bewertung der Ergebnisse aus computerlinguistischer Sicht**

Aus computerlinguistischer Perspektive werden nicht nur die bloßen mathematischen Ergebnisse betrachtet. In erster Instanz wird der Auswahlprozess unter die Lupe genommen.

Nach der detaillierten Auseinandersetzung mit dem Ergebnis werden die beiden angewendeten Methoden einander gegenübergestellt. Da im Rahmen dieser Arbeit eine regelbasierte Negation für deutschsprachige Texte entstanden ist, soll auch diese abschließend und mit Hinblick auf die Emotionserkennung bewertet werden. In der zuletzt genannten Überprüfung soll die Betrachtung nochmals auf Emotionsmodelle mit geregelter Emotionsbehandlung ausgeweitet werden.

### **11.2.1 Bewertung der Kontextrelevanz**

Sowohl das lexikonbasierte Verfahren mittels Labelpropagation als auch die CNN-basierte Methode weisen einen hochsignifikanten Einfluss des Kontexts auf die Ergebnishöhe auf, in beiden Fällen jedoch mit einer geringen Effektgröße. Nichtsdestotrotz kann anhand der statistischen Auswertung konstatiert werden, dass ein vorangehender Kontext für eine Emotionserkennung förderlich ist bzw. der nachgehende Satz eine zusätzliche Komplexität schafft.

Der optimale Kontextbezug kann zwar das Zünglein an der Waage der Ergebniswerte darstellen, doch die Ergebnisse in Verbindung mit der Annotation sprechen trotzdem für die Verwendung kleinerer Textfragmente anstelle verketteter Sätze. Als Trainingsdaten gingen ausschließlich angrenzende Sätze ohne Emotionsmerkmal ein, da diese von den Annotatoren gefiltert wurden. Der Mehrwert, der durch einen zusätzlichen Satz geschaffen wird, wiegt nicht die Gefahr auf, dass zwei angrenzende Sätze mit unterschiedlichen Emotionen geladen sind und es somit zu Verzerrungen kommt. Dies ist von praktischer Relevanz bei der Klärung der Frage nach der notwendigen Textmenge. Wie bereits argumentiert wurde, ist ein gesamtes Dokument meist zu ungenau. Gleichsam ist, zumindest bei der Emotionserkennung, die Wortebene nicht ausreichend, wie aus dem Vergleich des lexikalischen Ansatzes und des maschinellen Lernansatzes mit Berücksichtigung der Syntax ersichtlich wird. Fügt man die hier statistisch erworbenen Erkenntnisse den bisherigen Argumentationslinien der in Kapitel 5.2 angeführten Forschungsarbeiten hinzu, stellt man fest, dass das Optimum näher bei geringeren Textmengen liegt. Während diese Arbeit nur Auskunft darüber gibt, ob angrenzende Sätze einen Einfluss auf die Klassifikation haben, bleibt offen, ob die Satzebene das Optimum darstellt oder ob Satzfragmente Störeinflüsse noch besser ausblenden können. Letzteres stellt an zukünftige Forschungsarbeiten in dieser Richtung natürlich die Fragen der sinnvollen Satzaufteilung, der nachgelagerten Betrachtung von Nebensätzen oder auch des Umgangs mit Einschüben.

### 11.2.2 Handverlesene und maschinell erstellte Emotionslisten im Vergleich

Der manuelle Aufwand bei der Erstellung eines Emotionslexikons lohnt sich. Diese Schlussfolgerung lässt sich zumindest für das Labelpropagationsverfahren angesichts der Überprüfung der zweiten Hypothese ziehen. Die handverlesene Liste zeigt mit signifikantem Abstand die besten Ergebnisse unter den lexikonbasierten Ansätzen. Die Kombination des Labelpropagationsverfahrens mit der manuell erweiterten Liste ist maladaptiv. Zwar sind die Ergebnisse des Labelpropagationsverfahrens ohne Anreicherung im Mittel schlechter als die Ergebnisse mit Anreicherung, bemerkenswert ist jedoch, dass diese immer besser werden, je höher die Parameter ausfallen. Die Vergrößerung des Schwellenwerts wiederum bedeutet, dass der Einfluss der über das Labelpropagationsverfahren errechneten semantischen Ähnlichkeiten abnimmt. Die Analyse erreicht statistisch dann das beste Ergebnis, wenn der Einfluss vollkommen negiert wird, was ausschließlich der manuell erstellten Liste bzw. der Bezeichnung MANUAL entspricht.

Für den negativen Einfluss des Labelpropagationsverfahrens bei den lexikonbasierten Modellen werden hier überwiegend drei Gründe vermutet. Erstens ist eine Emotionserkennung deutlich schwieriger als eine Sentimentanalyse. Das Labelpropagationsverfahren wurde erfolgreich im Kontext der bipolaren Sentimentanalyse angewendet (Hamilton et al., 2016). Durch die Verwendung von positiven und negativen Vorzeichen heben sich entgegengesetzte Meinungsgewichtungen auf. Somit entsteht in einem solchen semantischen Netzwerk ohne Zutun eine neutrale Kategorie. Die hier verwendeten Ansätze sind Versuche, eine neutrale Kategorie ohne diesen Aufhebungseffekt herzustellen. Auch die Vielzahl der Emotionskategorien schafft Komplexität, die sich nachweislich negativ auf die Ergebnisse dieses Modells auswirken. Zweitens wurde bereits argumentiert, dass bei der manuellen>Listenerstellung psychologische Konzepte und Sprachfeinheiten besser berücksichtigt werden können. Ein maschineller Ansatz, wenngleich vielfach schneller, wird auf Hindernisse stoßen wie Polysemie oder Verzerrungen, die sich durch das Zusammenstellen des Korpus ergeben können. Drittens ist dieses Verfahren stark von den trainierten Wissensrepräsentationen abhängig. Da die Internetsprache so vielschichtig ist, ist nicht auszuschließen, dass die *Word-Embeddings* relevante semantische Ähnlichkeiten nicht ausreichend auflösen konnten. Zwar wurde ein kombinierter Wikipedia-, Buch- und Nachrichtenkommentarkorpus für das Training verwendet, dennoch kommen viele der mannigfaltigen Schreibweisen in Nutzerkommentare nur selten vor, so dass es zu Verzerrungen kommen kann. So können beispielsweise tatsächlich ähnliche Wörter des Netzjargons nicht erkannt oder, im ungünstigsten Fall, fehlerhafte Wortpaare einander zugeordnet werden.

Auch hier ergeben sich Möglichkeiten, weiter in diese Forschungsrichtung zu investieren. Was kann getan werden, damit das Labelpropagationsverfahren auch im Kontext einer Textanalyse mit mehreren Ergebnisklassen zielführend angewendet werden kann? Darüber hinaus wurden hier im Grunde nur zwei Varianten überprüft; ein Ansatz mit minimaler Schlüsselwortliste und eine sehr ausführliche, handverlesene Liste. Von Interesse wäre es definitiv, zu wissen, wie viele *Seed-Words* aus einer Theorie benötigt werden, um eine Klassifikation mit geringem überwachtem Lernaufwand zu erreichen. Zudem bleibt es in der zukünftigen Forschung zu klären, ob ein kleinerer, aber einschlägigerer Trainingskorpus der *Word-Embeddings* besser für diese Art der Klassifikation geeignet wäre.

### **11.2.3 Der wortbasierte und der maschinelle Lernansatz im Vergleich**

Der Vergleich des maschinellen Lernansatzes mit dem lexikonbasierten Ansatz bietet eines der deutlichsten Abweichungen der F1-Werte. Das CNN-Verfahren weist zum Labelpropagationsverfahren und zur manuell erstellten Liste ein signifikant besseres Ergebnis auf. Dies ist jedoch nur der Fall, wenn die CNN-Methode richtig initialisiert und wenn extreme Parameterkonfigurationen vermieden werden. Eine zielführende Initialisierung kann, wie bereits erwähnt, durch eine sorgsame Wahl der Parameter oder eine geänderte Sortierung der Eingangsdaten erreicht werden. Es ist auch zu klären, ob eine bessere Aufteilung der Trainings- und Testpartitionen zu besseren Ergebnissen oder geringeren Fehlinitialisierungen führt.

Die Vielzahl der ungünstig initialisierten CNN-Berechnungen stellen ein Problem dar. Dadurch, dass die Fehlinitialisierungen so häufig vorhanden sind, werden die errechnete Effektgrößen  $\eta^2$  im Sinne einer geringen Wertausprägung negativ beeinflusst. Das Festfahren auf eine Klasse kann zahlreiche Gründe haben. Erstens besteht die Möglichkeit, dass der CNN-basierte Ansatz wegen der ungleichmäßig verteilten Klassen der Trainingsdaten in einem lokalen Minimum startet. Die neutrale Klasse ist mit 2.707 Zählern nahezu dreimal so häufig vertreten wie Ärger mit 1.009 Vorkommnissen bzw. fast zehnmal so frequent wie Überraschung mit 287 Datensätzen. Zweitens können durch die Merkmalsreduktion entscheidende Differenzierungsmerkmale verloren gehen. Für Letzteres spricht die überdurchschnittliche Häufigkeit der Fehlinitialisierung bei den Einstellungen LEMMA mit und ohne Anreicherungen. Drittens können von vorneherein ungünstige Intervallgrenzen der CNN-Einstellungen definiert worden sein, so dass sich das Zusammenspiel der zahlreichen Parameter als nicht zielführend herausstellte. Werden zu extreme Parameterkonstellationen gewählt, dann kann dies einen negativen Klassifikationseffekt haben. Doch wie der nachfolgende Abschnitt zeigt, ist das Festfahren auf ein lokales Optimum nicht ausschließlich auf ungünstige Konfigurationen beschränkt.

Als sensibel wird die Anfälligkeit bei Parameterkonfigurationen wahrgenommen, so dass auch Einstellungen innerhalb vielversprechender Grenzen sich als nicht zielführend herausstellen können und es zu Fehlinitialisierungen kommen kann. Die Parameterkonfigurationen des neuronalen Netzwerkes stellt sich sensibel heraus. Diese Beobachtung ist analog zu beispielsweise Baroni et al. (2014), die der Parameterkonfigurationen eine entscheidende Rolle zusprechen. In dieser Hinsicht ist eine Voranalyse zielführend. Eine Voranalyse zur Bestimmung möglicher Parametergrenzen kann bereits vor der Durchführung der langwierigen Ergebnisgenerierung mögliche Schwachstellen aufzeigen. Somit können extreme oder nicht zielführende Werte vermieden werden. Darüber hinaus können viele valide Parametereinstellungen mit hoher Güte der oben angeführten Konfigurationsüberprüfungen aus Kapitel 10.7.3 zu einer Festsetzung in lokalen Optima führen. Es handelt sich dabei um eine Gratwanderung, um einerseits das frühzeitige Erreichen eines lokalen Extrempunkts zu vermeiden und andererseits genügend Differenzierungspotential nach mehreren Iterationsschritten herauszustellen.

Die Tatsache, dass der maschinelle Lernansatz, unter Ausschluss der Fehlinitialisierungen, besser als der lexikonbasierte Ansatz ist, hat viele Ursachen. Erstens ist die Anwendung der lexikonbasierten Herangehensweise deterministisch; sie basiert einzig auf bestimmten Parametereinstellungen und den eingegebenen Schlüsselwörtern. Die gewählte Methode bleibt daher von der Vielzahl der Trainingsdaten unberührt und kann nicht davon profitieren. Anders gesagt, wird hier ein überwachter Lernvorgang mit einem nur schwach überwachten Lernvorgang verglichen. Zweitens umfasst der maschinelle Lernansatz auch syntaktische Informationen. Wie Socher et al. (2013) herausstellten, ist dies bereits bei einer bipolaren Sentimentanalyse ein entscheidender Erfolgsfaktor. Ähnlich wie positive und negative Meinungen werden Emotionen durch Phrasen zum Ausdruck gebracht. Die Verwendung von größeren Filtern bei der CNN-Herangehensweise, die der Benutzung von n-Grammen nahekkommt, hat zur Bewältigung dieser längeren Textpassagen beigetragen. In diesem Zusammenhang muss jedoch auch eine mögliche Verzerrung genannt werden, nämlich die Zusammenstellung der Phrasen. Viele emotionsgeladene Annotationen haben einen ähnlichen oder gleichklingenden Wortlaut, so dass Dopplungen oder ein Überlernen nicht ausgeschlossen sind. Drittens sind Emotionen in Texten komplexe Gebilde, die, wie die Annotation zeigte, auch für den Menschen nicht zweifelsfrei realisiert werden können. Ein Aspekt, der sie schwierig zu bestimmen macht, ist die häufig fehlende Nennung eines Emotionsworts. Das Ausbleiben eines solchen hat insbesondere für die lexikonbasierten Methoden Nachteile. Und wie die vorangegangene Hypothese H2 zeigte, ist ein Labelpropagationsverfahren nur bedingt in der Lage, dies über semantische Ähnlichkeiten,

bezogen auf im Text vorkommende Wörter, aufzulösen. Viertens stellt die neutrale Kategorie für die lexikonbasierte Textklassifikation ein nicht zu vernachlässigendes Hindernis dar. Während dies beim CNN erlernt wird und womöglich durch Zugabe von per Definition neutral gehaltenen Nachrichten-Texten als Trainingsdaten noch verbessert werden könnte, wartet die neutrale Kategorie beim Labelpropagationsverfahren mit vielen Schwierigkeiten auf. Dazu zählen nicht nur die im vorangegangenen Kapitel genannten, sondern vor allem auch die Nennung von Emotionswörtern im neutralen Kontext.

Der CNN-basierte Ansatz ist vielversprechend und meistert nicht nur die bipolare Satzklassifikation (Kim, Y., 2014), sondern auch die mehrdimensionale Emotionserkennung mit Bravour. Die minutiöse Optimierung der Parameter, die hier auf Signifikanzniveau vorgenommen wurde, kann in der zukünftigen Forschung durch eine noch genauere Bestimmung der Einflussvariablen vertieft werden, um die Frage zu untersuchen, welche Komponente, welche Vorverarbeitung oder welche im vorangegangenen Absatz erwähnten Schritte den größten bzw. einen zu vernachlässigenden Einfluss haben.

#### **11.2.4 Bewertung der Vorverarbeitung**

In dieser Arbeit wurden mit der Merkmalsreduktion und der Merkmalsanreicherung zwei Methoden der Vorverarbeitung durchgeführt. Die Bewertung stützt sich ausschließlich auf die CNN-basierte Methode, da diese mit beiden Verarbeitungsprozessen durchgeführt wurde und auch bei der Merkmalsreduktion eine große Effektgröße aufwies. Beide Schritte werden im Folgenden gesondert behandelt.

Die Merkmalsreduktion bezieht sich auf die Bereinigung der Daten einerseits und die Reduktion der Wortvielfalt andererseits. Durch die Inklusion des unbearbeiteten Datensatzes wurde die Beantwortung der Fragestellung angestrebt, ob die zeitaufwendige Vorverarbeitung der Daten zielführend ist. Die Ergebnisse des maschinellen Lernansatzes sprechen klar für die Reinigung und Anreicherung der Datensätze. Begründet werden die positiven Ergebnisse mit zwei Argumenten. Der erste Aspekt wird in der Qualität der Wissensrepräsentationen, also der Reinheit der *Word-Embeddings* gesehen. Die Datenqualität von Nutzerkommentaren stellt ein gravierendes Problem dar, das auch menschliche Leser Schwierigkeiten bereitet. Dies muss vor dem Hintergrund gesehen werden, dass es fast nur lesbare Textfragmente in die annotierten Datensätze geschafft haben. Die Annotatoren haben viele kryptisch anmutenden Texte aufgrund der unverständlichen Schreibweise oder der fehlenden Kontextinformation nicht begreifen bzw. klassifizieren konnten. Außerdem kamen viele Wörter aufgrund ungewöhnlicher Rechtschreibung und netzjargonspezifischer Schreibweise nur vereinzelt vor. Die soeben

genannten Faktoren treten insbesondere bei dem Schritt vom UNCHANGED- zum WORD-Datensatz zutage. Die fehlenden Wörter und Schreibweisen führten bei der Anwendung der *Word-Embeddings* zu zahlreichen *Out-of-Vocabulary*-Situationen, so dass keine vektorielle Entsprechung gefunden werden konnte. Somit war die positive Eigenschaft der Syntaxberücksichtigung des CNNs beeinträchtigt, was folglich zu signifikant schlechteren F1-Werten führte.

Die Reduktion auf die lexikalische Form von WORD zu LEMMA ist beim CNN-Ansatz nicht empfehlenswert. Erstens bringt sie keine Steigerung der Beurteilungskriterien. Zweitens ist sie rechenintensiver als die Verwendung des bloßen Wortvorkommnisses. Drittens sind die Fehlinitialisierungen, bei dem nur eine Klasse vorhergesagt wird, bei der Einstellung LEMMA deutlich höher als bei der Dateneingabe WORD.

Die Merkmalsanreicherung der morphologischen Informationen hingegen hatte weder einen signifikant positiven noch negativen Einfluss. Dies stand entgegen der Hypothese und wird damit begründet, dass die Bedeutung dieser Information nicht so deutlich ist wie ursprünglich angenommen. Zumindest bezogen auf die Informationsanreicherung von LEMMA zu LEMMA\_PERS ist eine Tendenz in die erwartete Richtung erkennbar, doch die weitere Anreicherung zu LEMMA\_PERS\_SUBJ und LEMMA\_PERS\_NUM straft die Vermutung Lügen. Trotz der nicht verifizierten Hypothese wird dieser Fehlschlag in der Arbeit gelassen, damit zukünftigen Forschergenerationen dieser Schritt erspart bleibt.

Um die Vorverarbeitungsschritte noch besser einschätzen zu können, wäre es für die zukünftige Forschung ebenfalls zielführend, die jeweiligen Schritte zu trennen und den Effekt der Einzelprozessverarbeitungsschritte zu quantifizieren. Dies wurde zwar für die Negation und die morphologischen Informationen durchgeführt, blieb jedoch bei der automatisierten Rechtschreibkorrektur und der Datenharmonisierung, also der Abkürzungersersetzung, Netzjargonbehandlung und Sonderzeichenentfernung, offen. Darüber hinaus wird auch die Merkmalsanreicherung als zielführend erachtet. Aber auch hier wird auf zukünftige Forschung verwiesen, um weitere geeignete und zielführende Merkmale zu finden.

### **11.2.5 Praktische und theoretische Implikationen der Negation**

Ebenso wie in der bipolaren Sentimentanalyse ist die Negation für die Emotionserkennung von Bedeutung, doch der Effekt fällt im Vergleich zur Nachbardisziplin gering aus. In der regulären Sentimentanalyse wurde der Negation ein entscheidender Faktor attestiert (Carrillo de Albornoz & Plaza, 2013; Socher et al., 2013; Tromp, 2012). Wie aus der methodischen Überprüfung hervorgeht, hat die Negation bei allen hier angewendeten Ansätzen einen signifikanten Einfluss. Der Grad der Ergebnisbeeinflussung auf die Emotionserkennung ist jedoch nicht sehr

ausgeprägt. Dies kann mehrere Gründe haben. Ersten kann das Negationsmodul falsch und somit ungenau sein. Zweitens ist eine Emotionserkennung qualitativ anders als eine bipolare Sentimentanalyse. Begründet wird Letzteres damit, dass Emotionen, anders als positive bzw. negative Bewertungen, selten durch Verneinung ausgedrückt werden. Deutlich wird dies mit dem Versuch, die Emotion Angst durch das Gegenteil auszudrücken. Die verneinte Aussage „in diesem Moment war ich nicht mutig“ ist sehr generisch und kann losgelöst nicht zweifelsfrei als Angst, Scham oder Schuld eingeordnet werden. Wohingegen die Aussage „mir fehlte in der Situation der Mut“ auf Angst hinweist, diese jedoch ohne Negation auskommt. Verneinungen von Emotionen können jedoch in feststehenden Ausdrücken oder Umschreibungen vorkommen, wie „gestern waren wir keine Kinder der Traurigkeit“ für das Gefühl der Freude. Drittens kommen verneinte Emotionen in Nachrichtenkommentaren selten vor. Die Vorauswahl emotionsgeladener Passagen durch definierte Wendungen, die in Kapitel 12.1 gelistet sind, ergab, dass Wendungen nur begrenzt eingesetzt werden. Noch seltener sind sie in einer Verneinung anzutreffen. Somit wird argumentiert, dass die Verneinung nur marginal zur Bestimmung einer Emotion beiträgt.

Sofern die Negation einen Vorteil für die Emotionsdetektion hat, ist dieser in der neutralen Klasse anzusiedeln. Die meisten verneinten Bekundungen der Verfasser der Nachrichtenkommentare wurden von den Annotatoren im emotionsneutralen Bereich verortet. Dies geht aus einer qualitativen Betrachtung des Goldstandard-Datensatzes hervor. So lassen Aussagen wie „ich bin nicht traurig“ oder „ich bin nicht interessiert“ keinen Schluss auf andere Emotionen zu. Letzteres ist in Übereinstimmung mit dem Emotionsmodell von Merten & Krause (1993), dass keine Vorgehensweise mit bzw. Gegenpaare von negierten Emotionen vorschreibt. Unter den vorgestellten diskreten Emotionsmodellen gibt es nur wenige, die eine Negation im theoretischen Konstrukt verankern (Plutchik, 1984; Robinson, 2008). Anhand der qualitativen Betrachtung kann diesbezüglich eine Tendenz angedeutet werden, da bestimmte Emotionspaare wie Freude zu Trauer bzw. Kummer bei Plutchik (1984) bzw. Robinson (2008) oder Überraschung zu Interesse und Angst zu Wut bei Plutchik (1984) sowie Einzelemotionen bei Merten & Krause (1993) auftraten. Examiniert man die Einordnungen der Annotatoren beim vorliegenden Datensatz, so konnten die oben genannten, negierten Emotionspaare in keiner Emotionskategorie gefunden werden. Vielmehr zeigt sich die im vorangegangenen Absatz beschriebene Einordnung in die emotionsneutrale Kategorie. Um diese Aussage zu validieren, wird jedoch auf zukünftige Forschung verwiesen.

Auf die komplikationsbehaftete Anwendung der Verneinung bei dimensional Ansätzen wurde in Kapitel 2.3.1 hingewiesen. Die hier deutlich werdenden Muster haben keine

Aussagekraft für dimensionale Emotionsmodelle. Diese Frage kann mit dem hier eingeschlagenen Weg nicht beantwortet werden und es wird auch dabei auf zukünftige Forschung verwiesen. Diesbezüglich ist ebenfalls zu klären, ob die Verneinung nur auf die psychologische Valenzdimension angewendet werden kann oder ob sie auch auf die anderen Dimensionen ausgeweitet werden darf. Dies ist eine Frage, die an zukünftige Forschungsgenerationen übergeben wird.

### **11.2.6 Bewertung des Auswahlprozesses**

In dieser Studie wurden sowohl die gängigen dimensional als auch die diskreten Emotionstheorien theoretisch und argumentativ beleuchtet. Für beide Ansätze wurden Bewertungskriterien herausgearbeitet und auf alle vorgestellten Emotionsmodelle angewendet. Darüber hinaus wurden die emotionstheoretischen Ansätze einander gegenübergestellt und bezüglich einer Anwendung der Sentimentanalyse bewertet. Dabei wurde ein großer theoretischer Aufwand betrieben, von dem nur ein Bruchteil Eingang in diese Arbeit gefunden hat. Unter diesen Gesichtspunkten stellt sich unweigerlich die Frage, ob der breitangelegte Auswahlprozess zielführend und ob der Aufwand, der hier unternommen wurde, gerechtfertigt ist. Die drei folgenden Argumente sollen dies untermauern.

Erstens sind in der maschinellen Textverarbeitung bereits viele der vorgestellten Ansätze in Anwendung. Es wurde herausgearbeitet, dass nicht alle Emotionstheorien in gleicher Weise für die Sentimentanalyse geeignet sind. Nur in wenigen Fällen wurde nachvollziehbar an die Selektion des Emotionsmodells herangegangen. Wie dargelegt, wurden dabei nicht selten emotionstheoretische Grenzen aufgeweicht, übertreten oder sich gänzlich von emotionstheoretischen Grundlagen gelöst. Diese Studie stellt eine kritische Stimme im Diskurs der Sentimentanalyseforschung dar, in der eine wenig fundierte Auswahl eines Emotionsmodells oder eine willkürliche Kombination mehrerer emotionstheoretischer Ansätze angeprangert werden. Begründet wird dies damit, dass theoretische Unstimmigkeiten im Emotionsmodell zu Schwierigkeiten bei der Ausführung einer computerlinguistischen Sentimentanalyse führen können und somit das Ergebnis negativ beeinflussen.

Zweitens ist die Emotionsforschung kein abgeschlossenes Feld. Es ist nicht ausgeschlossen, dass in Zukunft weitere Emotionsmodelle hinzukommen. Die hier erarbeiteten Bewertungskriterien bilden eine Grundlage für die Bewertung weiterer, zukünftiger Emotionstheorien mit Hinblick auf die Anwendung der Sentimentanalyse. Der wissenschaftliche Beitrag besteht darin, dass Praktizierenden der Computerlinguistik Anhaltspunkte zur Auswahl des Emotionsansatzes dargelegt werden. Da weder der dimensionale noch der diskrete Ansatz

ausgeschlossen, sondern die Vor- und Nachteile sowie Anwendungsfelder herausgearbeitet wurden, stellt dies weniger ein Gebot, sondern eher eine Einladung dar, beide Ansätze anzuprobieren und das geeignete Modell für die jeweilige Anwendung zu finden. Festzuhalten bleibt jedoch, dass der diskrete Emotionsansatz für das erklärte Ziel der Emotionsdetektion die dimensionale Herangehensweise aufgrund der eingangs theoretisch erarbeiteten Vor- und Nachteile überflügelt. Aus diesem und den oben genannten Gründen wurde lediglich eine weiterführende Untersuchung anhand dieses Ansatzes vorgenommen. Nichtsdestotrotz hat auch der dimensionale Ansatz seine Daseinsberechtigung und es bleibt folgenden Forschergenerationen offen, ein adäquates Emotionsmodell auszuwählen und in ähnlicher Weise zu prüfen.

Für beide Emotionsansätze wurde ein Bewertungsschema erarbeitet, das es einem Anwender ohne einschlägigen emotionstheoretischen Hintergrund erlaubt, einen Überblick über die Materie zu gewinnen und Modelle zu evaluieren. So können nicht nur bestehende Ansätze mit Hinblick auf die Sentimentanalyse eingesehen und verglichen werden, sondern auch zukünftige, neue Ansätze aufgenommen und einander gegenübergestellt werden. Mit Hinblick auf weiterführende Forschungsfelder lassen sich die definierten Kategorien noch schärfen oder erweitern, um ein noch genaueres Bild der unterschiedlichen Emotionsmodelle zu erzeugen.

Drittens können durch den Schulterschluss der beiden Disziplinen Computerlinguistik und Psychologie Synergien gehoben werden. So könnten beispielsweise in der Psychologie Annotationsschema erarbeitet werden. Datensätze und Testreihen sind in der humanwissenschaftlichen Disziplin deutlich dünner gesät, als dies in der Computerlinguistik der Fall ist. Ein Rückgriff auf vorsortierte Texte, wie dies hier der Fall war, kann für Emotionsforscher ein großer Pluspunkt sein. Diese können theoriekonform analysiert und im gleichen Zug annotiert werden. Somit könnten für die Computerlinguisten zahlreiche Klassifikationsdatensätze erzeugt und ein zukünftiger Emotionsmodellvergleich angestrebt werden.

Viertens kann die Computerlinguistik von der Emotionsforschung profitieren, sofern sie sich an den bereits erarbeiteten Forschungsergebnissen orientiert. Durch die enge Auseinandersetzung mit Rahmenbedingungen, die Berücksichtigung der Abgrenzung von anderen affektiven Zuständen, unterschiedlichen Bestimmungsmethoden und empirischen Untersuchungen sind Emotionen trotz des fehlenden Konsenses über ihre Menge klar definiert. Überträgt man dieses Wissen durch das Akquirieren emotionsspezifischer Kontextinformationen in die maschinelle Emotionsbestimmung, dann lassen sich beispielsweise frühzeitig theoretische Diskrepanzen zur Datengrundlage erkennen oder zusätzliche Eingabemerkmale generieren, um noch genauere Ergebnisse zu erzielen. Letzteres betrifft sowohl den Kontext von Emotionen als auch die detaillierte Beschreibung, die in die Annotation einfließen kann. Auch wurde bereits die

*Named-Entity-Recognition* erwähnt, um Referenzmarker zielgerichteter Emotionen näher zu bestimmen. Aber auch das Einbinden von morphologischen Informationen oder eine vorgeschaltete Klassifikation des internen bzw. externen Bezugsrahmens könnten einen Mehrwert für die Sentimentanalyse liefern. Es bleibt der zukünftigen Forschung überlassen, welche emotionsspezifischen Kontextinformationen darüber hinaus nutzbar gemacht werden können und welchen Einfluss diese auf die Klassifikationsergebnisse haben.

## **11.3 Einschränkungen**

### **11.3.1 Einschränkungen hinsichtlich der Emotionstheorie**

#### **11.3.1.1 Einschränkungen des gewählten Emotionsmodells**

In Kapitel 2.5 wurden mehrere geeignete Emotionsmodelle ausgewählt, wobei man sich aus praktischen Gesichtspunkten für das Modell von Merten & Krause (1993) entschied. Unter Berücksichtigung der neuen Erkenntnisse durch die Umsetzung kann die Frage gestellt werden, ob für die Anwendung in der Computerlinguistik das richtige Emotionsmodell ausgewählt wurde. Diese Frage kann nur zum Teil bejaht werden.

Für das Modell sprechen seine Einfachheit und die geringe Anzahl an Emotionen. Die unkomplizierten Rahmenbedingungen, die an die einzelnen diskreten Emotionen gestellt werden, und die kaum vorhandenen Überschneidungen erlaubten eine direkte Bestimmung der Emotionen. Diese Aussage wird durch das erreichte Ergebnis unterstrichen, das Zeuge einer realisierbaren Klassifikation unter Verwendung dieses Modells ist. Die reduzierte Anzahl an Emotionen im Vergleich zu den anderen Modellen in der engeren Auswahl machte sich bei der Annotation doppelt bemerkbar. Einerseits gab es durch die deutliche Abgrenzung der Emotionen zueinander und die überschaubaren Emotionskategorien wenig Erklärungsbedarf und kaum Rückfragen durch die Annotatoren. Dies macht sich auch durch die ausgezeichneten Ergebnisse des *Inter-Annotator-Agreement* der manuellen Satzkategorisierung bemerkbar. Andererseits blieb durch die vergleichsweise geringe Anzahl an Emotionen der Annotationsaufwand in einem machbaren Rahmen. Aggregiert man die benötigte Zeit, die von den Annotatoren zurückgespiegelt wurde, und berücksichtigt man die Dauer für die Vorauswahl und das anschließende Zusammenfassen der Datensätze, dann ergeben sich mehrere Monate in Vollzeittätigkeit. Bei komplexeren Modellen wie den weiteren herauskristallisierten Ansätzen empfiehlt es sich, den Aufwand auf ein Forscherteam aufzuteilen oder mit bezahlten Annotatoren zu arbeiten.

Gegen das Modell spricht die geringe Anzahl an positiven Emotionen, die Schwierigkeiten rund um die Emotionen Überraschung und Interesse sowie die deutliche Unterrepräsentation bestimmter Emotionen im Text. Unter den Modellen, die als adäquat für eine feingranulare Sentimentanalyse befunden wurden, ist der gewählte Ansatz derjenige mit der geringsten Menge an positiven Emotionen. Da sich dieser Ansatz an der unteren Grenze des definierten Schwellenwerts befindet, konnten viele eindeutig emotionale Textpassagen nicht oder nur ungenau benannt werden. So wurde von mehreren Annotatoren die Rückfrage gestellt, inwieweit eine positiv bewertete Emotion zu klassifizieren ist, die im Modell von Mees (1991) beispielsweise in die Kategorien Dankbarkeit oder Bewunderung gefallen wäre.

Der zweite Aspekt, der gegen dieses Modell spricht, ist die schwierige Abgrenzung zwischen positiver und negativer Überraschung. Gleiches gilt für die Emotion Interesse, bei der sarkastische Aussagen wie „mich würde jetzt schon mal interessieren, wie du das besser hinbekommen hättest“ auftraten. Die Anzahl der nicht zuordenbaren oder abweichenden Emotionen bei der Annotation zeugt von der Schwierigkeit der Abgrenzung. Für die Erweiterbarkeit des Modells stellt dies einen Einschnitt dar. Für den Fall, dass ein weiteres Emotionsmodell auf Basis dieses Datensatzes annotiert werden sollte, müssten alle ungenauen Emotionen nochmals unter die Lupe genommen werden. Während beispielsweise die negativen Emotionen Wut, Angst und Trauer auch in anderen Modellen in gleicher Abstufung existieren, hat das Modell von Merten & Krause (1993) bei den positiven deutliche Differenzierungs-ungenauigkeiten.

Die dritte Schwierigkeit bestand darin, dass es sehr wenig Vorkommnisse von Überraschung, Schuld und Scham im textuellen Rahmen gab. Doch wie bereits in der Realisierbarkeit der Emotionsmodelle angeführt wurde, sind dies Emotionen, die durch das Niederschreiben an ihrem Überraschungsmoment einbüßen, die textuell nicht freizügig preisgegeben werden oder denen eine gewisse Hemmschwelle obliegt. Dies kann ein Effekt sein, der im Speziellen für die Textsorte der Nachrichtenkommentare gilt. Es kann aber auch mit der Art der Emotionserfassung, basierend auf schriftlicher Kommunikation, zusammenhängen. Andererseits wird angezweifelt, ob es mit der Aktualität und des kollektiv relevanten Bezugsrahmens von Nachrichtenmeldungen sowie dem Deckmantel der Anonymität im Internet einen besseren Nährboden für das gleichzeitige Auftreten von Emotionen jener Art gibt.

Da der oben aufgeworfenen Auswahl nur teilweise zugestimmt werden kann, drängt sich die Frage auf, was in zukünftigen Forschungen verbessert werden kann? Zum einen kann ein Vergleich angestrebt werden, bei dem mehrere der anfangs selektierten Emotionsmodelle einander gegenübergestellt werden können. Andererseits können die im Auswahlprozess

verwendeten Kriterien noch besser auf den auszuwertenden Datensatz angeglichen und der minimale Schwellenwert von drei positiven Emotionen angehoben werden.

Im Nachhinein zeigt sich, dass der Emotionsansatz von Mees (1991) in manchen Aspekten zielführender gewesen wäre. Dies wird an folgenden Punkten ausgemacht: Erstens ist das Modell differenzierter und würde insbesondere die positiven Emotionen von Merten & Krause (1993) besser aufschlüsseln. Darüber hinaus konnten viele subjektive Textpassagen, die mehrere der genannten Textmarker wie Zeichenverlängerung, exzessiven Gebrauch von Ausrufe- oder Fragezeichen, Großschreibung oder Emoticons aufwiesen (Liu, B., 2015a), aber nicht gewertet werden konnten, da Emotionen wie Hoffnung, Schadenfreude, Bewunderung oder Mitleid in dem gewählten Modell nicht vorhanden waren. Die Ausprägungen der Emotionen Ärger und Verachtung scheinen entweder nicht differenziert genug oder kommen in Nachrichtenkommentaren überdurchschnittlich häufig vor. Zieht man erneut das Modell von Mees (1991) heran, so ist dieses mit den Emotionen Leid, Selbstzufriedenheit, Zorn und Ärger sowie Verachtung und Hass präziser als das hier gewählte Modell von Merten & Krause (1993).

### **11.3.1.2 Ungleiche Aufteilung der Emotionen**

Die ungleiche Aufteilung der Emotionen ist kein Problem, dass auf das gewählte Modell von Merten & Krause (1993) beschränkt ist. Die Annotationen zeigen ein Bild der sozialen Netzgemeinde, die sich gerne empört, verächtlich über andere äußert bzw. ihre Abneigung gegen Situationen oder Objekte zeigt. Erst an vierter Stelle wird sich mit oder über etwas gefreut. Die oben gelistete Reihenfolge der Emotionshäufigkeiten wurde nicht systematisch kreiert, sondern entstand mit der Absicht, modellgegebene Emotionen im gleichen Maße darzustellen. Dass bestimmte Emotionen deutlich unterrepräsentiert sind, liegt an den fehlenden Vorkommnissen bzw. an der Schwierigkeit, bestimmte Emotionen zu erkennen.

Die ungleiche Verteilung der Emotionen ist ein Problem, dass vor allem den annotierten Datensatz betrifft. Einerseits können durch das Ungleichgewicht nicht alle Emotionen gleichermaßen genau bestimmt werden. Andererseits stellt dies eine Verzerrung dar, die, wie das hier angewendete CNN-Modell, von einer gleichmäßigen Verteilung der Anzahl der Trainingsdaten über alle Klassen hinweg profitieren. Zukünftigen Unterfangen, die ebenfalls ein Emotionsmodell annotieren, sei mit auf dem Weg gegeben, dass eine gleiche Aufteilung der Emotionen für maschinelle Lernalgorithmen vorteilhaft sein kann und eine deutliche Unterrepräsentation von einzelnen Emotionen zu Schwierigkeiten führen kann. Es bleibt der nachfolgenden Forschergeneration überlassen, zu entscheiden, inwieweit ein maschineller Lernansatz von einer Gleichverteilung profitiert.

Hinsichtlich der Repräsentativität des Datensatzes kann ins Feld geführt werden, dass in Nachrichtenkommentaren nicht alle Emotionen vorhanden sind bzw. bestimmte Emotionen deutlich häufiger vorkommen, als dies im normalen Alltag der Fall ist. Diesbezüglich wird eingeräumt, dass hier keine Allgemeingültigkeit der Schematisierung und der Emotionsbestimmung gegeben ist. Die Aussagekraft dieser Arbeit ist nur für den Nachrichtenkommentarsektor gegeben. Darüber hinaus kann diese Studie nicht als Indikator für die Häufigkeit bestimmter Emotionen herangezogen werden.

### **11.3.2 Einschränkungen der methodischen Herangehensweise**

#### **11.3.2.1 Feineinteilung der Unteremotionen**

In Kapitel 11.1.1 wurde eine detailliertere Eingliederung der Emotionen in Unteremotionen vorgenommen. Dies ist nicht unproblematisch. Es wird an dieser Stelle nachdrücklich darauf hingewiesen, dass kein neues Emotionsmodell geschaffen wurde, sondern lediglich ein bestehendes untermauert und ein neuer gangbarer Weg aufgezeigt wurde, um das Phänomen Emotion noch näher zu bestimmen. Nachfolgend werden die Hauptgründe für die Einschränkung dieser Methode und Vorgehensweise dargestellt.

Erstens entstehen bei der Feineinteilung der Emotionen Ambivalenzen. Auch wenn eine genauere Bestimmung der Emotionen in den allermeisten Fällen möglich ist, da zahlreiche Anhaltspunkte gegeben sind, so ist eine Schematisierung nicht immer mit Gewissheit möglich. Dies liegt daran, dass unterhalb der Emotionsebene Doppeleingliederungen bzw. Vermengungen möglich sind. Am Beispiel der ungenauen Ausdrucksweise „ich ekel mich vor Spinnen“ wird dies deutlich. Denn einerseits kann es in die Emotionskategorie Ekel eingeordnet werden, andererseits kann in diesem Fall auch Arachnophobie vorliegen, also die Angst vor Spinnen. Solche Einordnungskonflikte können nicht zweifelsfrei aufgelöst werden.

#### **11.3.2.2 Beschränkung auf einzelne Emotionen**

Die Betrachtung von Emotionskombinationen als eigenständige Emotionskategorien wird insbesondere bei der Ergründung der Beweisführung für oder gegen Sekundäremotionen als sinnvoll erachtet. Aufgrund der Permutation der zehn Emotionskategorien dieses Modells wären jedoch sehr viele Datensätze entstanden. Folglich wäre eine deutlich größere annotierte Datenmenge und gleichzeitig deutlich mehr Rohdaten vonnöten gewesen, da diverse Kombinationen nur selten auftreten.

Diese exklusive Betrachtungsweise singulärer und somit losgelöster Emotionen ist eine Einschränkung hinsichtlich des theoretischen Unterbaus (Reisenzein & Hofmann, 1993).

Deswegen kann in dieser Arbeit keine fundierte Aussage über die Überlagerung und die Art und Weise der Koexistenz getroffen werden.

Die hier vorgenommene Untersuchung konzentriert sich fast ausschließlich auf singular auftretende oder situativ dominante Emotionen. Dieser Umstand ist gewollt, um den Datensatz möglichst breitflächig und auch für dimensionale Bestimmungen nutzen zu können. Außerdem lässt sich der Datensatz so ebenfalls für die Mehrfachklassifikation von diskreten Emotionen nutzen, sofern anstelle des hier gewählten Ansatzes mehrere binäre Klassifikatoren berechnet werden (Bishop, 2006). Die Nutzung dieses Datensatzes unter Verwendung der Ein-gegen-Rest Variante bleibt zukünftigen Forschergenerationen vorbehalten.

### **11.3.2.3 Vorgelagerte Suche**

Die vorgelagerte Auswahl der Textstellen anhand bestimmter Schlüsselwörter erfasst nur einen Teil der Realität. Es wurde zwar mittels Stichproben darauf geachtet, dass die gewählten Textpassagen in Kongruenz mit den erwarteten Emotionen sind und dass der Datensatz nicht ausschließlich auf vorgefertigten Daten basiert. Doch ist die vorgelagerte Suche zweifelsohne als Einschränkung zu nennen, da sich im Datensatz viele wiederkehrende Phrasen befinden. Einerseits war dies eine Notwendigkeit, da eine wahllose und zufällige Satzannotation um ein Vielfaches aufwendiger geworden wäre. Andererseits liegt in der Vorauswahl auch eine Verzerrung. Durch die Herangehensweise, die mit einer booleschen Suche verglichen werden kann, wurden viele gleichartige Textstrukturen ausgewählt. Viele unterschwellige oder anders formulierte Textpassagen, die eine Emotion im Sinne des Emotionsmodells von Merten & Krause (1993) liefern, können dabei durchs Raster gefallen sein. Letzteres führt dazu, dass eine Generalisierbarkeit des Modells und folglich der Ergebnisse nicht absolut gegeben ist.

### **11.3.2.4 Annotation mit Hindernissen**

Zwei Gründe führten dazu, dass sich die Annotation als schwierig herausstellte. Zum einen ist die Satzebene nicht immer zielführend. Viele Emotionen entstehen fernab jeglicher Nennung von Schlüsselwörtern und sind nur aus dem Kontext zu entnehmen. Jene ergeben sich beispielsweise nur als Schlussfolgerung einer längeren Textpassage. Es ist auch möglich, auf Emotionen anderer Autoren zu verweisen, wenn z. B. eine Person „mir geht es wie dem vorangegangenen Autor“ schreibt, ohne selbst den Emotionszustand zu benennen. Ebenso können Allusionen und Metaphern vielfältige Formen annehmen, die sich einer breit angelegten Textanalyse entziehen. Diese und weitere Emotionen konnten im Rahmen dieser Arbeit nicht oder nur unvollständig annotiert werden.

Zum anderen wurde von den Annotatoren angemerkt, dass es oft nicht klar ist, ob die Bewertung der Situation oder die zugrunde liegende Emotion annotiert werden soll. An einem Beispiel soll dies deutlich werden. Unter der Prämisse, dass beispielsweise Stolz und Verachtung in einen zu annotierenden Emotionsmodell sind, würde der Satz „ich bin stolz, schlauer zu sein als der Großteil der Bevölkerung“ abhängig von der Perspektive unterschiedliche Ergebnisse liefern. Betrachtet man die einzelne Person, könnte der Satz tatsächlich auf Stolz zurückzuführen sein. Bewertet man hingegen die Situation, dann zeigt sich hier Verachtung. Dies ist ein generelles methodisches Problem der Annotation von Emotionsdaten, vor dem auch andere Forscher stehen, die ein ähnliches Unterfangen unternehmen. Einige Emotionstheorien liefern zwar eine generelle Richtlinie, zeigen aber nicht für jeden situationsbedingten Fall eine Lösung auf. Die hier vorgenommene Empfehlung, das Naheliegendste zu annotieren und die Entscheidung somit dem *Inter-Annotator-Agreement* zu überlassen bzw. die Emotion als nicht zuordenbar zu kennzeichnen, wenn sie zweifelhaft ist, stellt nur einen unzufriedenstellenden Kompromiss dar. Für die zukünftige Forschung kann definitiv empfohlen werden, das Bewertungskriterium aufzunehmen, ob oben genannte Zweifelsfälle theoretisch erläutert bzw. aufgelöst sind, oder sich zusätzliche Richtlinien für die Annotation zu überlegen.

### **11.3.2.5 Angewendete Methodik**

Die angewendete Methodik in Verbindung mit dem speziellen Datensatz kann ebenfalls als Einschränkung angeführt werden. In Kapitel 3.3 wurde bereits auf die Qualität der Datensätze aufmerksam gemacht. Ohne vorgreifend auf das folgende Kapitel und die Qualität des Korpus einzugehen, seien hier einige methodische Einschränkungen erwähnt.

Das größte Problem bei der Verwendung des unveränderten Word2Vec-Verfahrens ist das häufige Auftreten von *Out-of-Vocabulary*-Situationen. Diese entstehen dann, wenn Terme, seien es Neologismen, stilistische Zeichenfolgen oder falsch geschriebene Wörter, zu selten auftreten, so dass sie unterhalb des Schwellenwerts der zu berücksichtigenden Wörter liegen.

Je weniger Vorverarbeitungsschritte und Datenbereinigungsverfahren angewendet werden, desto deutlicher ist dieser Umstand gewichtet. Insbesondere die unveränderte Herangehensweise ist davon betroffen. Durch das Erstellen eines Word2Vec-Modells auf Basis einer deutlich größeren Nachrichtenkommentarsammlung wurde zwar versucht, dem entgegenzuwirken. Jedoch stellt dies eine nennenswerte Einschränkung dar, da keine abschließende Aussage darüber gemacht werden kann, ob die positiv erzielten Ergebnisse dadurch zustande kamen, dass störende Einflüsse durch leere Vektoren, bedingt durch die *Out-of-Vocabulary*-Situation,

ausgeblendet wurden, oder ob die Strahlkraft der *Word-Embeddings* in Verbindung mit dem CNN-Verfahren tatsächlich so hervorragend ist.

Es gibt bereits zahlreiche Herangehensweisen, die sich dieser Herausforderung stellen. Denkbar wäre beispielsweise die Verwendung von Character-Aware Language-Models (Hwang & Sung, 2016, 2017; Kim, Y. et al., 2015) oder eines *Bag-of-gram-Model* (Schütze, 2017), um die *Out-of-Vocabulary*-Situation zu verhindern oder zu minimieren. Für die Klärung dieser Frage wird auf zukünftige Forschungen verwiesen.

### **11.3.3 Einschränkungen, bezogen auf den Korpus**

#### **11.3.3.1 Datenqualität und Problematik der Echtdaten**

Eines der größten Probleme bei der Bearbeitung dieses Datensatzes hängt mit der mangelnden Datenqualität und der Verwendung von realitätsbezogenen Daten zusammen. Durch die uneinheitliche Groß- und Kleinschreibung sowie die orthografischen und grammatikalischen Übertretungen mussten viele Korrekturmechanismen eingesetzt werden, um beispielsweise die morphologische Bestimmung, die Wortartenerkennung oder Negation durchzuführen. Einerseits ist dies positiv, da zahlreiche Methoden für die deutsche Sprache entwickelt werden konnten, die in dieser Form vorher noch nicht existierten. Außerdem spiegelt die Arbeit mit solchen Datensätzen die ungeschminkte Realität wider, in der verfasste Texte nicht im Rahmen eines Lektorats auf Richtigkeit geprüft werden und unterschiedliche Schreibweisen zusammenkommen. Andererseits sind Korrekturmaßnahmen wie die Rechtschreibkorrektur oder die Textharmonisierung wiederum selbst nicht vor Fehlern gefeit und es ist nicht ausgeschlossen, dass dadurch weitere Verzerrungen oder Folgefehler entstanden. Durch Neologismen, *Code-Switching* oder selten auftretende Wortschreibweisen, aber auch durch Feinheiten der deutschen Sprache wie die Kompositabildung gelangen Methoden wie das verwendete Word2Vec und Datenbereinigungsansätze an ihre Grenzen.

#### **11.3.3.2 Einschlägiger Datensatz**

Der Umstand, dass sich der annotierte Datensatz nur aus Textfragmenten von Nachrichtenkommentaren speist, sollte ebenfalls als Einschränkung erwähnt werden. Es wurde bereits argumentiert, warum sich Nachrichtenkommentare besonders gut für die Erfassung von Emotionen eignen. Ebenso wurde darauf hingewiesen, dass durch die Anonymität eine gewisse textuelle Freizügigkeit hinsichtlich des Zeigens eigener Emotionen an den Tag gelegt wird. Andererseits lassen sich, wie bereits verlautet wurde, die oben genannten Argumente auch auf andere Textformen wie Mikroblockdienste, Forenbeiträge oder Produktbeschreibungen

anwenden. Es ist somit nicht von der Hand zu weisen, dass die resultierenden Aussagen nur eine Gültigkeit für Nachrichtenkommentare haben und dass durch diesen Umstand gängige Formulierungen oder Äußerungen außen vor gelassen wurden. Die Ergebnisse und die damit verbundene Aussage gelten nur für den ausgewiesenen, annotierten Datensatz.

Mit den Erkenntnissen der durchgeführten Analyse wäre es eine Empfehlung für zukünftige Forschungen in ähnlicher Manier oder für zukünftige Annotationsunternehmungen, sich nicht nur auf Datensätze aus einem Genre zu fokussieren. Zielführend wären in diesem Zusammenhang auch Texte aus ausgewählten Foren, beispielsweise das von GoFeminin<sup>2</sup>, das von Parship<sup>3</sup> oder das Psychologieforum<sup>4</sup>, um nur einige zu nennen. Diese Texte bieten eine hohe Dichte an dargelegten Emotionen, in denen auch Gefühlszustände wie z. B. Stolz zum Ausdruck kommen, die oben in der Abhandlung und in der Literatur als nicht unkompliziert eingestuft wurden (Schirmer, 2015).

### **11.3.3.3 Sarkasmus und Ironie**

Sarkasmus und Ironie wurden explizit aus dem Datensatz entfernt. Durch die Anweisung, die an die Annotatoren erging, wurden Datensätze, die entweder Sarkasmus oder Ironie beinhalteten sowie per Netzjargon als solche gekennzeichneten Textpassagen aus dem Datensatz ausgeschlossen. Durch die Einordnung nicht zuordenbar konnten diese Störeinflüsse separiert werden. Die Einordnung und der Umgang mit Sarkasmus und Ironie wurden als nicht trivial eingestuft (Fariás, Patti & Rosso, 2016; Hartung, 1998; van Hee, 2017; Wiegand et al., 2010). Dies hätte den Fokus dieser Arbeit über die Maßen ausgedehnt.

Dieser Ausschluss stellt eine Verzerrung dar, die einer absoluten Generalisierung des Datensatzes entgegensteht. Es sei an dieser Stelle darauf hingewiesen, dass es trotz des Hinweises der Exklusion von entsprechenden Textstellen einige sarkastische bzw. ironische Bemerkungen in Verbindung mit der Emotion Verachtung in den Datensatz geschafft haben. Dies wird bei der Durchsicht der annotierten Daten ersichtlich.

---

<sup>2</sup> <http://forum.gofeminin.de/forum/>

<sup>3</sup> <https://www.parship.de/forum/>

<sup>4</sup> <https://www.psychologieforum.de/>

## 11.4 Weitere wissenschaftliche Anknüpfungspunkte

### 11.4.1 Nutzung der speziellen Eigenschaften von Nachrichtenkommentaren

Nachrichtentexte besitzen strukturelle Merkmale, die sie von anderen textuellen Daten unterscheiden. Dies betrifft den inhaltlichen Aspekt der Nachricht, bei dem innerhalb einer Meldung sowie bei redaktionsübergreifenden ähnlichen Texten vergleichbare Kommentare vermutet werden. Des Weiteren lässt sich auch der Zeitbezug der Presseartikel als Gleichrichtungsmerkmal nutzen, um so noch mehr emotionale Reaktion in einem vergleichbaren Schema zu akquirieren.

Kommentare zu einer einzelnen Nachrichtenmeldung besitzen eine starke thematische Kohärenz und somit kann bei den dazugehörigen Nutzertexten von einem ähnlichen Set an Emotionen ausgegangen werden. Wie an dem annotierten Datensatz offensichtlich wurde, sind Nachrichtentexte ein geeignetes Mittel, um eine emotionale Reaktion bei Lesern hervorzurufen. Mit der starken thematischen Konsistenz wird die Annahme aufgeworfen, dass durch eine einzelne Pressemeldung nicht akzidentelle emotionale Zustände ausgelöst werden, sondern Kommentare in einer vergleichbaren emotionalen Orientierung verfasst werden. Es wird somit angenommen, dass Kommentare innerhalb einer Nachrichtenseite eine stärkere analoge Entsprechung besitzen, als dies bei Kommentaren, übergreifend zu anderen Zeitungen, zum selben Thema der Fall ist. Diese spezielle Eigenschaft von Nachrichtenkommentaren kann zukünftig für die Annotation oder die Klassifikation genutzt werden.

Eine ähnliche, aber schwächere thematische Kohärenz wird auch bei Kommentaren angenommen, die zu Nachrichtenmeldungen unterschiedlicher Zeitungen geschrieben wurden, aber das gleiche Thema abhandeln. Es wird daher argumentiert, dass Benutzertexte vergleichbarer Nachrichtenartikel analoge Emotionen hervorrufen und somit gebündelt betrachtet werden können. Begründet wird dies damit, dass Nachrichtenredaktionen generell versuchen, lokale und globale Ereignisse einzufangen, die für die ihre spezielle Zielgruppe relevant sind. Um für eine breite Leserschaft interessant zu sein, versuchen universelle Nachrichtenverlage, möglichst viele Themen in ihren Nachrichtenressorts abzudecken. Während dies auf lokaler Ebene noch realisierbar ist, wäre es auf globaler Ebene für eine einzelne Nachrichtenredaktion finanziell undenkbar, wenn an jedem Ort Journalisten aufwarten müssten, die das aktuelle Geschehen erfassen.

Die Korrespondenz weltumspannender Ereignisse wird daher in vielen Fällen von einem darauf spezialisierten Unternehmen übernommen. Einzelne Pressedienste, beispielsweise die Deutsche Presse-Agentur (dpa), kaufen von diesen Anbietern gesammeltes Text-, Bild- oder

Tonmaterial und formulieren daraus ihre Nachrichtenmeldungen. Mehrere Nachrichtenagenturen greifen dann auf diese Quelle zurück. Eine Konsequenz daraus ist, dass Meldungsüberschneidungen zwischen den einzelnen Nachrichtenredaktionen zustande kommen. Doch selbst wenn mehrere Nachrichtenagenturen über ein und dasselbe Ereignis schreiben, unterscheiden sich die Pressemitteilungen durch den persönlichen Schreibstil des Redakteurs, wobei zusätzlich ideologische Färbungen zum Tragen kommen können. Zudem richtet sich die Inhaltsdarstellung auch nach den internen Vorgaben einer Nachrichtenagentur. Auch der Schwerpunkt, welche Information in den Mittelpunkt gerückt werden soll, wird von den einzelnen Autoren festgelegt. Durch das Hinzufügen von weiteren Ausführungen, Erklärungen oder Hintergrundinformationen bzw. das Weglassen bestimmter Angaben aus der ursprünglichen Quelle differenzieren sich die Mitteilungstexte inhaltlich voneinander. Die Vorgaben bezüglich des Textumfangs unterscheiden sich auch von Agentur zu Agentur. Dadurch kann von gewissen Abweichungen der verschiedenen Meldungen über ein bestimmtes Ereignis ausgegangen werden.

Es kann somit festgehalten werden, dass Nachrichtentexte unterschiedlicher Agenturen über denselben Sachverhalt einander ähnlich sind, aber sich durch kleine Inhaltsnuancen unterscheiden. Diese spezifische Eigenschaft kann zukünftig ebenso wie das zuvor genannte Merkmal der schwachen thematischen Kohärenz zum Nutzen der Annotation oder Klassifikation eingesetzt werden.

Was für nachrichtenportalübergreifende Kommentare gilt, kann auch auf den zeitlichen Bezug ausgeweitet werden. Viele Begebenheiten haben einen längeren Zeitbezug und sind nicht mit einer Einmalmeldung abgetan. In diesem Fall können auch mehrere Artikel zu einem Vorfall erscheinen. Hier wird angenommen, dass sich die schriftlich ausgedrückten Emotionen zu einer Meldung über die Zeit hinweg stark ähneln. Wie Kim, D. & Oh (2011) zeigten, können auch innerhalb eines Nachrichtenblattes chronologisch zusammenhängend mehrere Texte zu einem Thema veröffentlicht und diese inhaltlich wieder übereinandergelegt werden. Inhaltliche Überschneidungen existieren folglich sowohl redaktionsübergreifend als auch zeitversetzt innerhalb der Veröffentlichungen einer Onlineredaktion. Auch diese Art der emotionalen Gleichrichtung der Kommentare stellt einen Vorteil für die zukünftige Forschung dar.

Eine weitere Eigenschaft von Nutzerkommentaren ist die chronologische Abfolge, was zu einer Dialogstruktur führt. Dadurch ist es möglich, dass emotionale Zustände durch die verfassten Kommentare anderer Autoren beeinflusst werden. Ferner existiert die Möglichkeit, dass Autoren, mehrfach kommentieren und ihren Standpunkt aufgrund der Entwicklung des Gesprächsverlaufs erneut deutlich machen, bzw. konträre Standpunkte anderer Autoren kritisieren. Speziell Letzteres führt nicht selten zu den Emotionen Wut oder Verachtung. Aber auch

die Dialogstruktur kann bei wiederkehrenden Mustern für die Emotionsdetektion als Merkmal in eine Analyse einfließen.

Nachdem dieser Mehrwert nun bereits mehrfach nebulös beschrieben wurde, stellt sich die Frage, wie er genutzt werden kann. Durch die starke und die schwache thematische Kohärenz können Emotionsformulierungen gezielt akquiriert oder in einer semiüberwachten Lernumgebung mit Rückgabeschleife annotiert werden. Wird sich beispielsweise über einen Skandal echauffert oder in Trauer über das Verscheiden einer berühmten Persönlichkeit geäußert, dann können mehrere Textfragmente zu dieser Meldung mittels des bestehenden Modells maschinell annotiert werden. Erreichen die Häufungen einer einzelnen Emotion eine kritische Masse und liegen gleichzeitig nicht mehrere andere Klassifikationen in den Textpassagen der jeweiligen Kommentare vor, so könnten gesicherte Textpassagen als quasiannotierte Datensätze behandelt werden. Dieser automatisch annotierte Datensatz könnte dann in die Erstellung eines verbesserten Modells einfließen. Die vergleichbaren Emotionsreaktionen sind ein naheliegender Aufsattpunkt, durch den erleichterte Annotationen oder darauf aufsetzende Herangehensweisen einen Mehrwert für zukünftige Forschungsunternehmungen bieten können.

#### **11.4.2 Nivellierung der Emotionen**

Auch wenn dieser Umstand in vielen Emotionsmodellen nicht beachtet wird, so sind in realitätsnahen Datensätzen unterschiedlich starke Ausprägungen der Emotionen anzutreffen. In einer Verfeinerung der Emotionserkennung wäre dies zielführend, da so beispielsweise auch Doppelemotionen mit einer dominanten Emotion abgedeckt werden können. Außerdem wäre es mit einer Abstufung möglich, verschieden starke Aussagen zu differenzieren, um das Emotionsmodell noch anwendungsorientierter zu gestalten. Um dies zu erreichen, wären für die zukünftige Forschung mehrere Ansatzpunkte denkbar.

Erstens könnte der annotierte Datensatz nochmals überarbeitet und um einen zusätzlichen Wert angereichert werden. Annotatoren können angehalten werden, die bereits bestehenden Emotionsphrasen in ihrer Intensität einzuschätzen. Mittels einer Mehrfacheinschätzung und einer folgenden Mittelwertbildung der jeweiligen Annotatorenbewertungen könnten ein intervallskalierter Intensitätswert errechnet werden.

Zweitens wäre eine Integration der Wertigkeitsnivellierung in einer weiterführenden Analyse möglich. Die kontextbedingte Wertigkeitsnivellierung oder *Contextual Valence-Shifter*, wie sie in der einschlägigen Sentimentanalyteliteratur auch genannt wird (Polanyi & Zaenen, 2006), beeinflussen, ähnlich wie die Negation, die Wertigkeit einer meinungsgeladenen Aussage. Eine Wertigkeitsnivellierung in Anwendung erfüllt im Wesentlichen zwei Funktionen.

Zum einen soll die Stärke der Polarität einer Meinungsäußerung nach oben oder unten korrigiert werden. Betroffene Textpassagen oder einzelne Adjektive können per *Intensifiers* in ihrer Polarität gesteigert oder per *Diminishers* gesenkt werden (Kennedy & Inkpen, 2006). Jedoch gibt es für die Terminologie der Wertigkeitsnivellierungen keine einheitlichen Bezeichnungen, weswegen an anderer Stelle auch *Amplifiers* für verstärkte bzw. *Attenuators* für abgeschwächte Aussagen verwendet werden (Tromp, 2012, S. 13). Exemplarisch soll hier ein praktikabler Ansatz von Mendel (2002) erwähnt werden, der Häufigkeitsangaben auf einer 10-Punkte-Intervallskala verortet. Diese Richtlinie für die Wertigkeitsklassifikation war beim Projekt FIRST im Einsatz (Klein et al., 2013). Die generelle Problematik besteht jedoch darin, dass ein Meinungswort nicht losgelöst betrachtet wird, sondern der in Merkmalen abstrahierte Kontext ebenfalls in die Analyse miteinfließt. Generell hängen emotionale Aussagen nicht nur an einem Wort, weswegen eine Integration dieser Wertigkeitsnivellierung nicht trivial ist und der zukünftigen Forschung überantwortet wird.

### 11.4.3 Voraufteilung der Daten

Anknüpfend zur Emotionsdetektion, kann auch eine inhaltliche Gruppierung durchgeführt werden. Damit lassen sich Themen ermitteln, die häufig mit den jeweiligen Emotionen in Verbindung gebracht werden. Diese Informationen wiederum ließen sich als mögliches Eingabemerkmal in die Analyse zurückführen bzw. nutzen, um sich bei der Textauswahl einer weiterführenden Annotation auf bestimmte Themen zu konzentrieren, in denen die Dichte der zu suchenden Emotion erhöht ist.

Um ein noch genaueres Bild der Emotionen zu erhalten, kann der hier genannte Modellauf auf eine größere Datenmenge angewendet und die so annotierten Daten ebenfalls dem Clustervorgang zugeführt werden. Zielführend wäre in diesem Zusammenhang eine Analyse, bei der die Anzahl der Themen in Abhängigkeit von den Daten automatisch ermittelt wird, beispielsweise der *Hierarchical Dirichlet-Process* (Spies & Jungemann-Dorner, 2013; Teh, Jordan, Beal & Blei, 2006)

Alternativ kann abermals auf die immanenten Eigenschaften der Nachrichtenkommentare zurückgegriffen und die Nachrichtenkategorie als Gruppierungsmerkmal verwendet werden. So könnten Meldungen zu Politik, Wirtschaft, Kultur, Sport etc. getrennt voneinander betrachtet werden. Die Nachrichtenkategorien können ebenfalls dazu verwendet werden, den gesamten Datensatz zu partitionieren, um domänenspezifische Emotionseinschätzungen bzw. -modelle zu erhalten. Popescu & Etzioni (2005) zeigten bereits bei der Sentimentanalyse, dass durch die Nachrichtengliederung zusätzliche Domänen in das Modell einfließen können. Durch die

getrennte Betrachtung des Nachrichtenressorts ist eine Partitionierung der Daten leichter zu realisieren und kann durch die Wahl des Gliederungsmerkmals in ihrer inhaltlichen Ausrichtung genauer dosiert werden. Ob sich dies oder ein maschinelles Clusterverfahren verwenden lassen und besseren Analyseergebnissen führt, bleibt zukünftigen Forschungsgenerationen überlassen.

## 12 Anhang

### 12.1 Suchbegriffe für die Vorselektion der Datensätze

Mögliche Kategorie	Boolesche Suchanfrage
Angst	Zittern ODER zittern
Angst	Zähneklappern
Angst	Torschlusspanik
Angst	Teufel UND Weihwasser
Angst	tausend UND Tode
Angst	Tantalusqualen ODER Tantalusqual
Angst	Schwanz UND einziehen ODER einkreifen
Angst	Schneid UND abkaufen
Angst	Schiss ODER Schiß ODER schiss UND haben
Angst	Panik ODER Horror ODER Angst
Angst	Ofen UND verkriechen ODER kriechen
Angst	nass UND machen
Angst	Nacken ODER Genick UND sitzen ODER lauern
Angst	Mutter UND Schürze ODER Schürzenband ODER Schürzenzipfel ODER Rockzipfel
Angst	mulmig
Angst	Muffe ODER Muffensausen
Angst	Mauseloch UND kriechen
Angst	Manschetten ODER Gamaschen UND haben
Angst	Lampenfieber ODER Flattermann
Angst	Kopf UND verlieren
Angst	Koller
Angst	Knochen UND fahren
Angst	Knie ODER Knien UND weich ODER wackeln ODER wackelig ODER schlottern ODER schlottrig
Angst	kneifen
Angst	Ketten UND rasseln
Angst	Kaninchen ODER Kanikel UND Schlange
Angst	kalt ODER kalte UND Füße ODER Fuss ODER Fuß
Angst	Hose ODER Hemd ODER Höschen ODER Hemdchen UND voll ODER flattern ODER machen
Angst	Himmelangst
Angst	Herz UND still
Angst	Herz UND Hose
Angst	Hals ODER Kopf UND Kloß ODER Kloss ODER Frosch ODER Schlinge ODER zuschnüren ODER schnüren ODER schnürt
Angst	Haare ODER Haar UND Berge ODER Berg ODER sträuben
Angst	Gurgel UND schnürt ODER schnüren
Angst	Gesicht UND geschrieben
Angst	Gänsehaut
Angst	Fürchten
Angst	Fracksausen ODER Höllenangst ODER Heidenangst
Angst	feige ODER feig
Angst	Espenlaub
Angst	eiskalt ODER kalt UND Buckel ODER Rücken
Angst	Düse UND gehen
Angst	Blut UND Wasser

<b>Angst</b>	Bange ODER bängen ODER Bangen
<b>Angst</b>	Bammel
<b>Angst</b>	Atem UND verschlagen
<b>Angst</b>	Arsch UND Grundeis
<b>Angst</b>	Angsthase
<b>Angst</b>	Angst
<b>Ekel</b>	würgen ODER würg ODER runterwürg ODER kotz ODER kotzen ODER Kotze O- DER Würgereflex ODER Würg
<b>Ekel</b>	Schnute UND ziehen
<b>Ekel</b>	Scheiße ODER Scheiß ODER Pisse
<b>Ekel</b>	pfui
<b>Ekel</b>	kalte ODER kalt UND Grausen ODER grausen
<b>Ekel</b>	hoch UND kommen
<b>Ekel</b>	Haare ODER Nackenhaare ODER Haar UND sträuben ODER aufstellen ODER stel- len ODER richten ODER auf
<b>Ekel</b>	Ekelpaket
<b>Ekel</b>	bäh ODER bah ODER pah
<b>Freude</b>	Wonne
<b>Freude</b>	Vorfreude
<b>Freude</b>	Tollerei
<b>Freude</b>	Tanzbein
<b>Freude</b>	Streich ODER Streiche
<b>Freude</b>	Stimmung
<b>Freude</b>	steppt ODER tanzt UND Bär
<b>Freude</b>	Spaß
<b>Freude</b>	siebter ODER siebten ODER schweben ODER fühlen ODER sieben UND Himmel ODER Wolke
<b>Freude</b>	Sektlaune
<b>Freude</b>	Schalk UND Augen ODER Auge
<b>Freude</b>	rockt ODER Leben UND Bude
<b>Freude</b>	Ringelpiez
<b>Freude</b>	Post UND ab
<b>Freude</b>	Pabst UND boxt ODER boxen
<b>Freude</b>	Luftsprung ODER Luftsprünge
<b>Freude</b>	Liebe UND Magen
<b>Freude</b>	Lebens ODER Leben UND froh
<b>Freude</b>	Laune
<b>Freude</b>	Kuh UND fliegen
<b>Freude</b>	jux
<b>Freude</b>	Juhu ODER juhu
<b>Freude</b>	juchhei
<b>Freude</b>	juchhe
<b>Freude</b>	hurra ODER hurra
<b>Freude</b>	Höhenflug
<b>Freude</b>	Hochstimmung
<b>Freude</b>	hipp UND hurra
<b>Freude</b>	Highlife
<b>Freude</b>	Herzenslust
<b>Freude</b>	Hallotria
<b>Freude</b>	Gaudi
<b>Freude</b>	fun
<b>Freude</b>	Friede UND Freude UND Eierkuchen
<b>Freude</b>	Fisimatenten ODER Fisimatent
<b>Freude</b>	Firlefanzen

<b>Freude</b>	Fez UND machen
<b>Freude</b>	Faxen
<b>Freude</b>	Fahrt UND kommen ODER geraten
<b>Freude</b>	Bombenstimmung
<b>Freude</b>	bespaßen
<b>Freude</b>	Begeisterung
<b>Freude</b>	Backen UND grinsen
<b>Freude</b>	Arm UND nehmen
<b>Freude</b>	Allotria
<b>Freude</b>	Albernheiten
<b>Scham</b>	versaubeuteln
<b>Scham</b>	verlegen
<b>Scham</b>	schämen
<b>Scham</b>	rot UND anlaufen
<b>Scham</b>	puterrot
<b>Scham</b>	peinlichsten UND mir
<b>Scham</b>	Ofen UND krichen ODER verkriechen
<b>Scham</b>	Not UND Tugend
<b>Scham</b>	nicht UND in UND Augen UND sehen
<b>Scham</b>	nackt UND Erbsen ODER erbsen
<b>Scham</b>	nackt ODER Nackt ODER Nacktheit
<b>Scham</b>	Mund UND nehmen
<b>Scham</b>	Mauseloch UND kriechen
<b>Scham</b>	Leisetreter
<b>Scham</b>	Kopf ODER kopf UND kratzen
<b>Scham</b>	klein UND mit UND Hut
<b>Scham</b>	Grund UND Boden
<b>Scham</b>	Gesicht UND sehen
<b>Scham</b>	Erdboden UND versinken
<b>Scham</b>	blöd ODER vorkommen
<b>Scham</b>	Augen UND treten
<b>Schuld</b>	Zähne UND ausbeißen
<b>Schuld</b>	Wicken UND gehen
<b>Schuld</b>	verkacken ODER verkackt
<b>Schuld</b>	Sündenbock
<b>Schuld</b>	Seifenblase UND zerplatzen
<b>Schuld</b>	schwarzer UND Peter
<b>Schuld</b>	Schuld UND Schuhe
<b>Schuld</b>	schmutzige UND Wäsche
<b>Schuld</b>	schlechtes UND Gewissen
<b>Schuld</b>	Schiffbruch UND erleiden
<b>Schuld</b>	Scheitern ODER scheitern
<b>Schuld</b>	Ritter UND trauriger UND Gestalt
<b>Schuld</b>	reinreiten
<b>Schuld</b>	reines ODER rein UND Gewissen
<b>Schuld</b>	Persilschein
<b>Schuld</b>	Ohren UND fliegen
<b>Schuld</b>	Nieren UND gehen
<b>Schuld</b>	Nase ODER Bauch ODER Schnauze ODER Fresse ODER Hintern ODER Arsch UND fallen ODER fliegen
<b>Schuld</b>	Misserfolg
<b>Schuld</b>	Mea UND Culpa
<b>Schuld</b>	madig UND gemacht ODER machen
<b>Schuld</b>	leise UND Töne

<b>Schuld</b>	Leichen UND Keller
<b>Schuld</b>	Last UND legen
<b>Schuld</b>	Klinge UND springen
<b>Schuld</b>	Karren UND Wand ODER Dreck
<b>Schuld</b>	Kainsmal ODER Kainszeichen
<b>Schuld</b>	Hände UND Unschuld
<b>Schuld</b>	Granit ODER beißen
<b>Schuld</b>	Grab UND bringen
<b>Schuld</b>	Gewissensbisse
<b>Schuld</b>	Gewissen
<b>Schuld</b>	Finger UND verbrennen
<b>Schuld</b>	Fiasko
<b>Schuld</b>	Fall UND kommen
<b>Schuld</b>	Fahne UND streichen
<b>Schuld</b>	das UND kommt UND davon
<b>Schuld</b>	Brust UND nehmen
<b>Schuld</b>	Bruchlandung
<b>Schuld</b>	böse ODER böß UND Bube ODER bube
<b>Schuld</b>	Blinde UND Lahmen
<b>Schuld</b>	Binsen UND gehen
<b>Schuld</b>	Affenschande
<b>Schuld</b>	Abbitte
<b>Trauer</b>	Zähne UND zusammenbeißen
<b>Trauer</b>	Wermutstropfen
<b>Trauer</b>	unter UND Haut
<b>Trauer</b>	Trübsal
<b>Trauer</b>	Trauerweide
<b>Trauer</b>	Tränen ODER Träne ODER tränen ODER träne ODER Krokodilstränen ODER Tränen-drüse
<b>Trauer</b>	seelisches ODER seelisch ODER seelisch UND Wrack
<b>Trauer</b>	Seele UND leidtun ODER wehtun ODER weh
<b>Trauer</b>	Schotten UND dichtmachen ODER dicht
<b>Trauer</b>	Schmerz
<b>Trauer</b>	Ohren UND hängen
<b>Trauer</b>	nahe ODER nah UND gehen ODER geht
<b>Trauer</b>	Leichenbitter ODER Leichenbittermiene
<b>Trauer</b>	lange ODER langes ODER lang UND Gesicht ODER Gesichter
<b>Trauer</b>	Kopf UND sinken ODER hängen
<b>Trauer</b>	Kopf UND hängen
<b>Trauer</b>	Joch
<b>Trauer</b>	Herzschmerz
<b>Trauer</b>	Herz UND greifen
<b>Trauer</b>	Häufchen ODER Haufen UND Elend
<b>Trauer</b>	geknickt
<b>Trauer</b>	Fluppe ODER Flappe ODER Fleppe UND ziehen
<b>Trauer</b>	fertig UND mit UND Welt
<b>Trauer</b>	Fahne UND halbmast
<b>Trauer</b>	down UND sein
<b>Trauer</b>	blutendes ODER bluten ODER blutend ODER brechen ODER brechend ODER schwer ODER schweren UND Herz ODER Herzen ODER Herzens
<b>Trauer</b>	Blues UND haben
<b>Trauer</b>	bestürzt ODER Bestürzung
<b>Trauer</b>	bedröppelt
<b>Trauer</b>	angefressen

<b>Überraschung</b>	Widerhall
<b>Überraschung</b>	Wagen ODER Karren UND spannen
<b>Überraschung</b>	Visier UND Lüften
<b>Überraschung</b>	Speck UND Mund
<b>Überraschung</b>	offene ODER rennen ODER einrennen UND Türen
<b>Überraschung</b>	Neugier ODER neugier ODER neugierig
<b>Überraschung</b>	Hund UND Jagen ODER jagen
<b>Überraschung</b>	Hummeln UND Hintern ODER Arsch
<b>Überraschung</b>	daran UND liegen ODER liegt
<b>Überraschung</b>	Bude UND einrennen
<b>Überraschung</b>	Avancen
<b>Überraschung</b>	auf UND Hut UND sein
<b>Überraschung</b>	Aktien UND drin
<b>Verachtung</b>	Verachtung ODER verachten
<b>Verachtung</b>	Trottel
<b>Verachtung</b>	Tratschtante
<b>Verachtung</b>	Trantüte
<b>Verachtung</b>	Tassen UND Schrank
<b>Verachtung</b>	Stinkstiefel
<b>Verachtung</b>	Spott
<b>Verachtung</b>	Spießruten ODER Spießrute UND laufen ODER Lauf
<b>Verachtung</b>	Spargeltarzan
<b>Verachtung</b>	Schlappschwanz
<b>Verachtung</b>	schäbig
<b>Verachtung</b>	Rotzlöffel
<b>Verachtung</b>	Respektlosigkeit
<b>Verachtung</b>	Pissnelke
<b>Verachtung</b>	nichts UND wert
<b>Verachtung</b>	Nichtbeachtung
<b>Verachtung</b>	Missachtung ODER missachtung
<b>Verachtung</b>	minderwertig
<b>Verachtung</b>	Lustmolch
<b>Verachtung</b>	Labertasche
<b>Verachtung</b>	Korn UND nehmen
<b>Verachtung</b>	Hosenscheisser
<b>Verachtung</b>	Hohn
<b>Verachtung</b>	Herabwürdigung
<b>Verachtung</b>	Herabsetzung
<b>Verachtung</b>	Hackfresse
<b>Verachtung</b>	grau UND Maus
<b>Verachtung</b>	Geringschätzung ODER geringschätzen
<b>Verachtung</b>	Geringschätzung
<b>Verachtung</b>	Geringachtung
<b>Verachtung</b>	Fraß UND vorwerfen
<b>Verachtung</b>	Flachwichser
<b>Verachtung</b>	Fickfehler
<b>Verachtung</b>	Entwürdigung
<b>Verachtung</b>	dumm ODER doof
<b>Verachtung</b>	Despektierlichkeit
<b>Verachtung</b>	Demütigung
<b>Verachtung</b>	Arschgeige
<b>Verachtung</b>	Arsch
<b>Verachtung</b>	Armleuchter
<b>Wut</b>	zum UND Kuckuck ODER Teufel

<b>Wut</b>	Zores
<b>Wut</b>	Zoff
<b>Wut</b>	Zinne UND bringen ODER sein
<b>Wut</b>	Zeichen UND Wunder
<b>Wut</b>	Zeichen UND Sturm
<b>Wut</b>	Zähneknirschen
<b>Wut</b>	Wut ODER Ärger ODER Unmut UND steigern ODER hineinsteigern
<b>Wut</b>	Wut ODER Ärger ODER Unmut UND schäumen ODER platzen ODER kochen
<b>Wut</b>	Wut ODER Ärger ODER Unmut UND reinfressen ODER runterspülen
<b>Wut</b>	Wut ODER Ärger ODER Unmut UND Luft UND gehen
<b>Wut</b>	Wut ODER Ärger ODER Unmut UND herunterschlucken ODER hinunterschlucken schlucken
<b>Wut</b>	Wut ODER Ärger ODER Unmut UND Bauch
<b>Wut</b>	wow ODER Wow
<b>Wut</b>	werd ODER werde UND Hirsch
<b>Wut</b>	Weißglut
<b>Wut</b>	was UND du UND nicht UND sagst
<b>Wut</b>	Wände ODER Wand ODER Decke UND durch ODER hochgehen ODER gehen ODER schießen
<b>Wut</b>	Wallung UND geraten
<b>Wut</b>	Verstand ODER verstand UND rauben
<b>Wut</b>	verflucht UND nochmal ODER noch
<b>Wut</b>	verflixt ODER verdammt
<b>Wut</b>	Überraschung
<b>Wut</b>	Trabbel
<b>Wut</b>	tiefgreifend ODER unheimlich ODER sehr ODER äußerst ODER ausergewöhnlich ODER echt ODER tatsächlich ODER positiv ODER immer ODER besonders ODER tiefst ODER angenehm ODER wirklich ODER tatsächlich ODER zutiefst ODER wahnsinnig ODER ausgesprochen ODER außergewöhnlich ODER erstaunlich ODER höchst ODER überaus ODER voll ODER wunderbar ODER wundervoll UND überrascht ODER beeindruckt
<b>Wut</b>	Terz
<b>Wut</b>	Stunk
<b>Wut</b>	streift UND Bus
<b>Wut</b>	Stirn UND runzeln
<b>Wut</b>	Stimmung UND geladen
<b>Wut</b>	Stein UND Anstoß
<b>Wut</b>	staunen
<b>Wut</b>	sprachlos
<b>Wut</b>	Sicherung ODER Sicherungen UND durchbrennen ODER durchgebrannt
<b>Wut</b>	Selbstbeherrschung UND verlieren
<b>Wut</b>	schwellen ODER schwillt UND Hals ODER Adern ODER Ader ODER Zornesader
<b>Wut</b>	Schwein UND pfeift ODER pfeifen
<b>Wut</b>	Schwein UND pfeifen ODER pfeift
<b>Wut</b>	Schuh ODER Schuhe ODER Trunschuh ODER Turnschuhe ODER Hobel UND aufblasen ODER blasen
<b>Wut</b>	schöne UND Bescherung ODER bescherung
<b>Wut</b>	Schockschwerenot
<b>Wut</b>	schieß ODER schießen UND Wand
<b>Wut</b>	Scheibenkleister ODER Scheibenhonig
<b>Wut</b>	Schaum UND Mund
<b>Wut</b>	Sapperlot
<b>Wut</b>	Sakra
<b>Wut</b>	rotes ODER rot UND Tuch

<b>Wut</b>	rot ODER schwarz UND sehen
<b>Wut</b>	Rochus
<b>Wut</b>	rauscht UND Karton
<b>Wut</b>	Rage UND geraten
<b>Wut</b>	potz UND Blitz ODER blitz
<b>Wut</b>	Post UND ab
<b>Wut</b>	positiv UND überrascht ODER überraschen
<b>Wut</b>	platzen ODER platzt UND Kragen
<b>Wut</b>	Pfui UND Spinne ODER Teufel
<b>Wut</b>	Pardauz
<b>Wut</b>	Palme UND hoch ODER bringen ODER treiben
<b>Wut</b>	Ohne UND Worte ODER Wort
<b>Wut</b>	oha
<b>Wut</b>	Oh UND leck
<b>Wut</b>	Ogotogott ODER Himmelherrgott ODER himmelherrgott ODER Allmächtiger O- DER allmächtiger
<b>Wut</b>	ODER kochen ODER koche ODER Kochen ODER Wallung UND Blut
<b>Wut</b>	O ODER Oh UND Graus
<b>Wut</b>	noch UND Worte
<b>Wut</b>	neugierig UND gemacht
<b>Wut</b>	Neugier UND geweckt
<b>Wut</b>	Nerven
<b>Wut</b>	Mütchen UND kühlen
<b>Wut</b>	Mock UND hoch
<b>Wut</b>	Mistding ODER Mistkram ODER Mist
<b>Wut</b>	Messer ODER Faust UND Tasche
<b>Wut</b>	Menschkind ODER Menschskinder
<b>Wut</b>	Mensch UND Meier ODER Meyer ODER Maier
<b>Wut</b>	Mensch UND Maier ODER Meier ODER Mayer ODER Meyer
<b>Wut</b>	meine UND Güte
<b>Wut</b>	meine ODER mein UND Fresse
<b>Wut</b>	Manometer ODER Manomann ODER Mannometer
<b>Wut</b>	Mann-o-Mann
<b>Wut</b>	Mamma UND mia
<b>Wut</b>	Luft UND gehen
<b>Wut</b>	Luft ODER luft UND machen
<b>Wut</b>	Luft ODER Spucke UND wegbleiben ODER bleiben ODER weg
<b>Wut</b>	liebes UND Lottchen ODER Lieschen
<b>Wut</b>	lieber heiliger ODER gütiger UND Himmel ODER Gott ODER Schwan ODER Scholli ODER Blechle ODER Blech ODER Zeit
<b>Wut</b>	Leckomio ODER leckomio
<b>Wut</b>	Leber UND Laus ODER laus ODER fressen ODER frisst
<b>Wut</b>	laust ODER lausen UND Affe
<b>Wut</b>	laust ODER lausen ODER Laust ODER Lausen UND Affe
<b>Wut</b>	Latschen ODER Socken ODER Pantoffeln ODER Pantinen UND kippen ODER kipp
<b>Wut</b>	lange ODER lang UND gärt
<b>Wut</b>	küsst ODER küssen ODER knutscht ODER knutschen ODER tritt ODER treten O- DER treten UND Pferd ODER Elch
<b>Wut</b>	kriegen ODER krieg UND Motten ODER Motte
<b>Wut</b>	kriegen ODER krieg UND Hörner
<b>Wut</b>	kreuzweise
<b>Wut</b>	kreist UND Hammer
<b>Wut</b>	Koller ODER Rappel ODER Raster ODER Ausraster UND haben ODER bekommen ODER kriegen

<b>Wut</b>	Kokoschinski
<b>Wut</b>	knierschen ODER knirschende ODER zusammengebissenen UND Zähne ODER Zahn
<b>Wut</b>	Knatsch
<b>Wut</b>	Kladderadatsch
<b>Wut</b>	Keks ODER Senkel ODER Kette ODER Zeiger ODER Wecker ODER Docht ODER Geist ODER Geister ODER Eier ODER Sack ODER Nüsse UND gehen ODER geht
<b>Wut</b>	kaum ODER nicht UND glauben
<b>Wut</b>	Kasalla
<b>Wut</b>	Kacke UND Dampfen
<b>Wut</b>	Juchhe ODER Juchhei
<b>Wut</b>	ist UND Hammer
<b>Wut</b>	ist UND ein UND Ding
<b>Wut</b>	Hut ODER hut ODER hutschnur ODER Hutschnur UND hoch
<b>Wut</b>	hundertachtzig
<b>Wut</b>	Hund UND Pfanne
<b>Wut</b>	Huhu
<b>Wut</b>	Huch
<b>Wut</b>	hoppla ODER uff
<b>Wut</b>	Hol's ODER holen ODER hol UND Geier ODER Henker ODER Kuckuck ODER Teufel
<b>Wut</b>	Holla ODER holla UND Waldfee ODER waldfee
<b>Wut</b>	Höhe UND gehen
<b>Wut</b>	hochgehen UND Rakete
<b>Wut</b>	Hirn UND Himmel
<b>Wut</b>	Himmel ODER Himmels UND Dank ODER dank ODER danken ODER Willen ODER willen ODER Wille
<b>Wut</b>	Herrschaftszeiten
<b>Wut</b>	Herrschaft UND Zeiten ODER Zeit
<b>Wut</b>	herrjemine ODER oje ODER ojemine
<b>Wut</b>	Herr UND meiner UND selbst
<b>Wut</b>	Herr UND Gesangsverein
<b>Wut</b>	heilig ODER heiliger UND strohsack ODER Strohsack ODER Kanonenrohr ODER kanonenrohr ODER bimbam ODER Bimbam
<b>Wut</b>	Heidewitzka ODER heidewitzka
<b>Wut</b>	Heidenei ODER heidenei
<b>Wut</b>	Haut UND fahren
<b>Wut</b>	hätte UND gedacht
<b>Wut</b>	handgreiflich
<b>Wut</b>	Hand UND gegen UND erheben
<b>Wut</b>	Hamster UND bohnerm ODER bohner
<b>Wut</b>	Halt UND Stop
<b>Wut</b>	Hals UND umdrehen ODER voll ODER kriegen
<b>Wut</b>	haben UND wir UND Salat
<b>Wut</b>	Haare ODER Haar UND raufen
<b>Wut</b>	guten ODER gute UND Geister
<b>Wut</b>	gute UND Miene UND Spiel
<b>Wut</b>	Groll
<b>Wut</b>	Gottverdammich
<b>Wut</b>	glaub UND hackt
<b>Wut</b>	Gewitter UND Anzug
<b>Wut</b>	geladen UND sein
<b>Wut</b>	Geduldsfaden
<b>Wut</b>	gedacht UND nicht

Wut	Galle
Wut	fuchsteufelswild
Wut	fresse ODER fressen UND Besen
Wut	fick UND Knie
Wut	fick UND Henne
Wut	Fehdehandschuh UND Fehde
Wut	Faust ODER hauen ODER schlagen UND Tisch
Wut	erhitze ODER erhitzen UND Gemüter
Wut	Ei UND Daus
Wut	Du ODER du UND bist UND einer
Wut	Dreieck ODER Karree UND springen ODER spring
Wut	Draht UND Mütze
Wut	Donnerwetter ODER Donnerkeil
Wut	Donnerlittchen
Wut	Donner UND Doria
Wut	dickes UND Ei ODER ei
Wut	Decke ODER decke UND gehen
Wut	Dampf UND ablassen ODER lassen
Wut	brennt ODER brennen UND Luft
Wut	braten ODER brat UND Storch
Wut	Brass UND haben
Wut	böses ODER böse UND Blut
Wut	biegen ODER krepeln ODER rollen ODER krümmen ODER kräuseln UND Nägel ODER Zehennägel ODER Fingernägel
Wut	Beherrschung UND verlieren
Wut	beeindrucken
Wut	Barometer UND Sturm
Wut	auskotzen
Wut	aus UND heiterem UND Himmel
Wut	Au ODER au UNZD Backe
Wut	alter UND Schwede
Wut	alter UND Falter
Wut	aggressiv
Wut	aggro ODER aggromäßig
Wut	ach UND Schande ODER Scheiße

*Tabelle 59: Suchwörter für die Auswahl emotionaler Phrasen*

## 12.2 Emotionslexikon nach Merten & Krause (1993)

Emotion nach Merten & Krause (1993)	Schlüsselwörter	Modell gegebener Term	Erzeugt durch Derivationen	Erzeugt durch Synonymie
Ekel	Abgunst	Nein	nein	ja
Ekel	abhorrieren	nein	nein	ja
Ekel	abneigend	nein	nein	ja
Ekel	Abneigung	nein	nein	ja
Ekel	abominabel	nein	nein	ja
Ekel	Abscheu	nein	nein	ja
Ekel	abscheuerregend	nein	nein	ja
Ekel	abscheulich	nein	nein	ja
Trauer	Abschiedsschmerz	nein	nein	ja
Ekel	abschreckend	nein	nein	ja
Ekel	abstoßend	nein	ja	nein
Interesse	achtsam	nein	nein	ja

<b>Interesse</b>	Achtsamkeit	nein	nein	ja
<b>Wut</b>	Affront	nein	ja	nein
<b>Ekel</b>	affrös	nein	nein	ja
<b>Angst</b>	Aftersausen	nein	nein	ja
<b>Wut</b>	Aggression	nein	nein	ja
<b>Freude</b>	amüsan	nein	nein	ja
<b>Freude</b>	Amusement	nein	nein	ja
<b>Schuld</b>	anbrüllen	nein	nein	ja
<b>Interesse</b>	Andacht	nein	nein	ja
<b>Interesse</b>	andächtig	nein	nein	ja
<b>Interesse</b>	andachtsvoll	nein	nein	ja
<b>Ekel</b>	anekeln	nein	nein	ja
<b>Schuld</b>	anfauen	nein	nein	ja
<b>Wut</b>	ärgerlich	ja	nein	nein
<b>Wut</b>	angefressen	nein	ja	nein
<b>Freude</b>	angenehm	nein	nein	ja
<b>Wut</b>	wütend	ja	nein	nein
<b>Angst</b>	Angst	nein	ja	nein
<b>Angst</b>	angsterfüllt	nein	nein	ja
<b>Angst</b>	Angstgefühl	nein	nein	ja
<b>Angst</b>	ängstigen	nein	ja	nein
<b>Angst</b>	Ängstlich	nein	nein	ja
<b>Wut</b>	zornig	ja	nein	nein
<b>Angst</b>	Ängstlichkeit	nein	nein	ja
<b>Angst</b>	angstverzerrt	nein	nein	ja
<b>Angst</b>	angstvoll	nein	nein	ja
<b>Angst</b>	Angstzustand	nein	nein	ja
<b>Wut</b>	Animosität	nein	nein	ja
<b>Ekel</b>	ankotzen	nein	nein	ja
<b>Schuld</b>	anmeckern	nein	nein	ja
<b>Wut</b>	anpflaumen	nein	nein	ja
<b>Wut</b>	anpissen	nein	nein	ja
<b>Schuld</b>	anranzen	nein	nein	ja
<b>Schuld</b>	Anranzer	nein	nein	ja
<b>Schuld</b>	anschießen	nein	nein	ja
<b>Schuld</b>	Anschiss	nein	nein	ja
<b>Schuld</b>	anschnauzen	nein	nein	ja
<b>Schuld</b>	Anschnauzer	nein	nein	ja
<b>Schuld</b>	anschreien	nein	nein	ja
<b>Schuld</b>	anschuldigen	nein	nein	ja
<b>Wut</b>	anstinken	nein	nein	ja
<b>Interesse</b>	Anteilnahme	nein	nein	ja
<b>Ekel</b>	anwidern	nein	ja	nein
<b>Wut</b>	Ärger	nein	ja	nein
<b>Verachtung</b>	geringschätzend	ja	nein	nein
<b>Wut</b>	ärgern	nein	ja	nein
<b>Wut</b>	Ärgernis	nein	ja	nein
<b>Interesse</b>	argusäugig	nein	nein	ja
<b>Angst</b>	argwöhnen	nein	nein	ja
<b>Ekel</b>	ätzend	nein	nein	ja
<b>Wut</b>	aufbrausen	nein	nein	ja
<b>Wut</b>	aufbrausend	nein	nein	ja

<b>Wut</b>	aufgebracht	nein	nein	ja
<b>Wut</b>	Aufgebrachtheit	nein	nein	ja
<b>Interesse</b>	aufmerken	nein	ja	nein
<b>Verachtung</b>	spöttisch	ja	nein	nein
<b>Interesse</b>	Aufmerksamkeit	nein	ja	nein
<b>Interesse</b>	Augenmerk	nein	nein	ja
<b>Freude</b>	Augenweide	nein	nein	ja
<b>Wut</b>	ausflippen	nein	nein	ja
<b>Freude</b>	Ausgelassenheit	nein	nein	ja
<b>Schuld</b>	ausschimpfen	nein	nein	ja
<b>Angst</b>	aussichtslos	nein	nein	ja
<b>Angst</b>	Aussichtslosigkeit	nein	nein	ja
<b>Verachtung</b>	ausspotten	nein	nein	ja
<b>Angst</b>	ausweglos	nein	nein	ja
<b>Angst</b>	Ausweglosigkeit	nein	nein	ja
<b>Ekel</b>	Aversion	nein	nein	ja
<b>Überraschung</b>	baff	nein	nein	ja
<b>Angst</b>	Bammel	nein	nein	ja
<b>Angst</b>	Bange	nein	nein	ja
<b>Angst</b>	bange	nein	nein	ja
<b>Angst</b>	bangen	nein	nein	ja
<b>Angst</b>	Bangigkeit	nein	nein	ja
<b>Angst</b>	bänglich	nein	nein	ja
<b>Angst</b>	Bangnis	nein	nein	ja
<b>Ekel</b>	beachtlich	nein	nein	ja
<b>Angst</b>	beängstigen	nein	nein	ja
<b>Angst</b>	beängstigend	nein	nein	ja
<b>Schuld</b>	beanstanden	nein	nein	ja
<b>Schuld</b>	Beanstandung	nein	nein	ja
<b>Schuld</b>	beckmessern	nein	nein	ja
<b>Trauer</b>	bedauerlich	nein	nein	ja
<b>Trauer</b>	Bedauern	nein	nein	ja
<b>Scham</b>	bedripst	nein	nein	ja
<b>Trauer</b>	bedröppelt	nein	nein	ja
<b>Trauer</b>	bedrückt	nein	nein	ja
<b>Angst</b>	befürchten	nein	nein	ja
<b>Angst</b>	Befürchtung	nein	nein	ja
<b>Freude</b>	begeistert	nein	nein	ja
<b>Freude</b>	Begeisterung	nein	nein	ja
<b>Freude</b>	beglückend	nein	nein	ja
<b>Freude</b>	Beglückung	nein	nein	ja
<b>Wut</b>	Behelligung	nein	ja	nein
<b>Trauer</b>	bejammern	nein	nein	ja
<b>Trauer</b>	beklagenswert	nein	nein	ja
<b>Scham</b>	Beklemmung	nein	nein	ja
<b>Scham</b>	beklommen	nein	nein	ja
<b>Angst</b>	Beklommenheit	nein	nein	ja
<b>Wut</b>	beknackt	nein	nein	ja
<b>Trauer</b>	bekümmert	nein	nein	ja
<b>Verachtung</b>	belachen	nein	nein	ja
<b>Wut</b>	beleidigt	nein	ja	nein
<b>Wut</b>	Beleidigung	nein	ja	nein

<b>Verachtung</b>	belustigen	nein	nein	ja
<b>Schuld</b>	bemäkeln	nein	nein	ja
<b>Schuld</b>	bemängeln	nein	nein	ja
<b>Schuld</b>	Bemängelung	nein	nein	ja
<b>Schuld</b>	bereuen	nein	ja	nein
<b>Scham</b>	beschämt	nein	nein	ja
<b>Scham</b>	Beschämung	nein	nein	ja
<b>Wut</b>	bescheuert	nein	nein	ja
<b>Wut</b>	Beschimpfung	nein	ja	nein
<b>Schuld</b>	beschuldigen	nein	ja	nein
<b>Freude</b>	Beschwingtheit	nein	nein	ja
<b>Angst</b>	besorglich	nein	nein	ja
<b>Angst</b>	besorgt	nein	nein	ja
<b>Trauer</b>	bestürzen	nein	nein	ja
<b>Trauer</b>	bestürzt	nein	nein	ja
<b>Trauer</b>	betrauern	nein	nein	ja
<b>Scham</b>	Betretenheit	nein	nein	ja
<b>Trauer</b>	betrüben	nein	nein	ja
<b>Trauer</b>	Betrübnis	nein	nein	ja
<b>Trauer</b>	betrübt	nein	nein	ja
<b>Angst</b>	beunruhigt	nein	nein	ja
<b>Angst</b>	Beunruhigung	nein	nein	ja
<b>Trauer</b>	beweinen	nein	nein	ja
<b>Verachtung</b>	bewitzeln	nein	nein	ja
<b>Schuld</b>	bezichtigen	nein	nein	ja
<b>Angst</b>	bibbern	nein	nein	ja
<b>Wut</b>	blöd	nein	nein	ja
<b>Scham</b>	Blöße	nein	nein	ja
<b>Wut</b>	böse	nein	nein	ja
<b>Verachtung</b>	boshaft	nein	nein	ja
<b>Verachtung</b>	Boshaftigkeit	nein	nein	ja
<b>Scham</b>	Bredouille	nein	nein	ja
<b>Trauer</b>	brummig	nein	nein	ja
<b>Wut</b>	bullerig	nein	nein	ja
<b>Freude</b>	bumsfidel	nein	nein	ja
<b>Schuld</b>	Buße	nein	nein	ja
<b>Trauer</b>	decouragieren	nein	nein	ja
<b>Trauer</b>	decouragiert	nein	nein	ja
<b>Trauer</b>	defätistisch	nein	nein	ja
<b>Ekel</b>	Degout	nein	nein	ja
<b>Ekel</b>	degoutant	nein	nein	ja
<b>Ekel</b>	degoutieren	nein	nein	ja
<b>Trauer</b>	demoralisieren	nein	nein	ja
<b>Trauer</b>	Demoralisierung	nein	nein	ja
<b>Trauer</b>	deplorabel	nein	nein	ja
<b>Trauer</b>	Depression	nein	nein	ja
<b>Trauer</b>	depressiv	nein	nein	ja
<b>Trauer</b>	depri	nein	nein	ja
<b>Trauer</b>	deprimieren	nein	nein	ja
<b>Angst</b>	deprimierend	nein	nein	ja
<b>Trauer</b>	deprimiert	nein	nein	ja
<b>Trauer</b>	desolat	nein	nein	ja

<b>Verachtung</b>	despektieren	nein	nein	ja
<b>Verachtung</b>	Despektion	nein	nein	ja
<b>Angst</b>	desperat	nein	nein	ja
<b>Angst</b>	Desperation	nein	nein	ja
<b>Ekel</b>	detestieren	nein	nein	ja
<b>Wut</b>	Diffamierung	nein	ja	nein
<b>Verachtung</b>	Diskriminierung	nein	nein	ja
<b>Wut</b>	dumm	nein	nein	ja
<b>Wut</b>	durchdrehen	nein	ja	nein
<b>Wut</b>	Ehrenkränkung	nein	ja	nein
<b>Wut</b>	Ehrverletzung	nein	ja	nein
<b>Freude</b>	Eifer	nein	nein	ja
<b>Wut</b>	eingeschnappt	nein	ja	nein
<b>Schuld</b>	eingestehen	nein	nein	ja
<b>Angst</b>	einschüchtern	nein	nein	ja
<b>Ekel</b>	Ekel	nein	ja	nein
<b>Ekel</b>	ekelerregend	nein	nein	ja
<b>Ekel</b>	ekelhaft	nein	nein	ja
<b>Ekel</b>	ekelig	nein	nein	ja
<b>Ekel</b>	ekeln	nein	ja	nein
<b>Ekel</b>	Ekelpaket	nein	nein	ja
<b>Ekel</b>	eklig	nein	nein	ja
<b>Freude</b>	ekstatisch	nein	nein	ja
<b>Trauer</b>	elegisch	nein	nein	ja
<b>Wut</b>	empören	nein	nein	ja
<b>Wut</b>	empört	nein	nein	ja
<b>Wut</b>	Empörung	nein	nein	ja
<b>Wut</b>	enervieren	nein	nein	ja
<b>Trauer</b>	entmutigen	nein	ja	nein
<b>Angst</b>	entmutigend	nein	nein	ja
<b>Verachtung</b>	verachtungsvoll	ja	nein	nein
<b>Trauer</b>	Entmutigung	nein	ja	nein
<b>Wut</b>	entnerven	nein	nein	ja
<b>Wut</b>	entrüsten	nein	nein	ja
<b>Wut</b>	entrüstet	nein	nein	ja
<b>Wut</b>	Entrüstung	nein	nein	ja
<b>Schuld</b>	entschuldigen	nein	nein	ja
<b>Angst</b>	entsetzen	nein	nein	ja
<b>Ekel</b>	entsetzlich	nein	nein	ja
<b>Trauer</b>	Enttäuschung	nein	nein	ja
<b>Freude</b>	Entzücken	nein	nein	ja
<b>Freude</b>	entzückt	nein	nein	ja
<b>Freude</b>	Entzückung	nein	nein	ja
<b>Ekel</b>	erbärmlich	nein	nein	ja
<b>Wut</b>	erbittern	nein	nein	ja
<b>Wut</b>	erbittert	nein	ja	nein
<b>Wut</b>	Erbitterung	nein	ja	nein
<b>Wut</b>	erbosen	nein	nein	ja
<b>Wut</b>	erbost	nein	ja	nein
<b>Ekel</b>	erbrechen	nein	nein	ja
<b>Ekel</b>	erbrochen	nein	nein	ja
<b>Ekel</b>	Erbrochenes	nein	nein	ja

<b>Freude</b>	erfreulich	nein	nein	ja
<b>Überraschung</b>	erstaunt	ja	nein	nein
<b>Freude</b>	ergötzlich	nein	nein	ja
<b>Freude</b>	Ergötzung	nein	nein	ja
<b>Wut</b>	ergrimmen	nein	nein	ja
<b>Wut</b>	ergrimmt	nein	ja	nein
<b>Freude</b>	erquicklich	nein	nein	ja
<b>Wut</b>	erregt	nein	nein	ja
<b>Wut</b>	Erregung	nein	nein	ja
<b>Scham</b>	erröten	nein	nein	ja
<b>Angst</b>	erschauern	nein	nein	ja
<b>Angst</b>	erschrecken	nein	ja	nein
<b>Angst</b>	erschreckend	nein	ja	nein
<b>Überraschung</b>	überrascht	ja	nein	nein
<b>Angst</b>	erschüttern	nein	nein	ja
<b>Überraschung</b>	erstaunen	nein	ja	nein
<b>Überraschung</b>	Erstaunen	nein	ja	nein
<b>Überraschung</b>	verblüfft	ja	nein	nein
<b>Wut</b>	erzürnen	nein	ja	nein
<b>Wut</b>	Erzürnung	nein	ja	nein
<b>Freude</b>	euphorisch	nein	nein	ja
<b>Freude</b>	Euthymie	nein	nein	ja
<b>Wut</b>	exaltieren	nein	nein	ja
<b>Ekel</b>	fabelhaft	nein	nein	ja
<b>Schuld</b>	Fehltritt	nein	nein	ja
<b>Angst</b>	feige	nein	nein	ja
<b>Verachtung</b>	Feindseligkeit	nein	nein	ja
<b>Freude</b>	feuchtfröhlich	nein	nein	ja
<b>Freude</b>	fidel	nein	nein	ja
<b>Ekel</b>	fies	nein	nein	ja
<b>Ekel</b>	Fiesling	nein	nein	ja
<b>Interesse</b>	Flow	nein	nein	ja
<b>Wut</b>	foppen	nein	nein	ja
<b>Angst</b>	Fracksausen	nein	nein	ja
<b>Freude</b>	Freude	nein	ja	nein
<b>Trauer</b>	freudelos	nein	nein	ja
<b>Freude</b>	Freudenausbruch	nein	nein	ja
<b>Trauer</b>	freudenlos	nein	nein	ja
<b>Freude</b>	freudenreich	nein	nein	ja
<b>Freude</b>	freudestrahlend	nein	nein	ja
<b>Freude</b>	freudig	nein	ja	nein
<b>Freude</b>	Freudigkeit	nein	nein	ja
<b>Trauer</b>	freudlos	nein	nein	ja
<b>Freude</b>	freudvoll	nein	nein	ja
<b>Freude</b>	froh	nein	nein	ja
<b>Freude</b>	Frohheit	nein	nein	ja
<b>Trauer</b>	entmutigt	ja	nein	nein
<b>Freude</b>	Frohmut	nein	nein	ja
<b>Freude</b>	frohmutig	nein	nein	ja
<b>Freude</b>	Frohnatur	nein	nein	ja
<b>Freude</b>	Frohsinn	nein	ja	nein
<b>Trauer</b>	frusten	nein	nein	ja

<b>Trauer</b>	Frustration	nein	nein	ja
<b>Trauer</b>	frustrieren	nein	nein	ja
<b>Trauer</b>	frustriert	nein	nein	ja
<b>Wut</b>	fuchsig	nein	nein	ja
<b>Wut</b>	fuchsteufelswild	nein	nein	ja
<b>Wut</b>	fuchtig	nein	nein	ja
<b>Angst</b>	Furcht	nein	ja	nein
<b>Angst</b>	furchtbar	nein	nein	ja
<b>Angst</b>	furchteinflößend	nein	nein	ja
<b>Angst</b>	fürchten	nein	ja	nein
<b>Ekel</b>	fürchterlich	nein	nein	ja
<b>Angst</b>	furchterregend	nein	nein	ja
<b>Trauer</b>	niedergeschlagen	ja	nein	nein
<b>Angst</b>	Furchtsamkeit	nein	nein	ja
<b>Wut</b>	furibund	nein	nein	ja
<b>Wut</b>	furios	nein	ja	nein
<b>Wut</b>	Furor	nein	ja	nein
<b>Freude</b>	gaiment	nein	nein	ja
<b>Verachtung</b>	gallig	nein	nein	ja
<b>Freude</b>	Gaudi	nein	nein	ja
<b>Trauer</b>	gedeftet	nein	nein	ja
<b>Interesse</b>	gefitzt	nein	nein	ja
<b>Wut</b>	Gefrett	nein	nein	ja
<b>Freude</b>	gefreet	nein	nein	ja
<b>Trauer</b>	gefrustet	nein	nein	ja
<b>Trauer</b>	traurig	ja	nein	nein
<b>Interesse</b>	Geistesgegenwart	nein	nein	ja
<b>Interesse</b>	geistesgegenwärtig	nein	nein	ja
<b>Trauer</b>	geknickt	nein	nein	ja
<b>Wut</b>	gekränkt	nein	ja	nein
<b>Wut</b>	Gekränktheit	nein	ja	nein
<b>Wut</b>	Gemeinheit	nein	ja	nein
<b>Freude</b>	gemütlich	nein	nein	ja
<b>Scham</b>	genieren	nein	nein	ja
<b>Scham</b>	genierlich	nein	nein	ja
<b>Wut</b>	gereizt	nein	nein	ja
<b>Wut</b>	Gereiztheit	nein	nein	ja
<b>Verachtung</b>	Geringachtung	nein	nein	ja
<b>Verachtung</b>	geringschätzen	nein	ja	nein
<b>Schuld</b>	reumütig	ja	nein	nein
<b>Verachtung</b>	Geringschätzigkeit	nein	nein	ja
<b>Verachtung</b>	Geringschätzung	nein	ja	nein
<b>Angst</b>	gespenstig	nein	nein	ja
<b>Angst</b>	gespenstisch	nein	nein	ja
<b>Verachtung</b>	Gespött	nein	nein	ja
<b>Ekel</b>	Gewürge	nein	nein	ja
<b>Ekel</b>	gewürzt	nein	nein	ja
<b>Ekel</b>	Gewürgte	nein	nein	ja
<b>Schuld</b>	geziemend	nein	nein	ja
<b>Wut</b>	Gfrett	nein	nein	ja
<b>Freude</b>	Glück	nein	nein	ja
<b>Freude</b>	glücklich	nein	nein	ja

<b>Freude</b>	glücklich	nein	nein	ja
<b>Freude</b>	Glückseligkeit	nein	nein	ja
<b>Freude</b>	glückstrahlend	nein	nein	ja
<b>Wut</b>	gnatzig	nein	nein	ja
<b>Trauer</b>	Gram	nein	nein	ja
<b>Trauer</b>	grämen	nein	nein	ja
<b>Trauer</b>	grämlich	nein	nein	ja
<b>Wut</b>	grantig	nein	nein	ja
<b>Ekel</b>	grässlich	nein	nein	ja
<b>Ekel</b>	Gräuel	nein	nein	ja
<b>Angst</b>	Grauen	nein	nein	ja
<b>Angst</b>	grauen	nein	nein	ja
<b>Ekel</b>	grauenhaft	nein	nein	ja
<b>Ekel</b>	grauenvoll	nein	nein	ja
<b>Ekel</b>	graulen	nein	nein	ja
<b>Angst</b>	graus	nein	nein	ja
<b>Ekel</b>	grausam	nein	nein	ja
<b>Angst</b>	Grausen	nein	nein	ja
<b>Ekel</b>	grausig	nein	nein	ja
<b>Ekel</b>	grauslich	nein	nein	ja
<b>Ekel</b>	greislich	nein	nein	ja
<b>Wut</b>	griesgrämig	nein	nein	ja
<b>Wut</b>	grimmig	nein	nein	ja
<b>Wut</b>	grollen	nein	nein	ja
<b>Scham</b>	gschamig	nein	nein	ja
<b>Interesse</b>	Gunstbezeigung	nein	nein	ja
<b>Schuld</b>	gutmachen	nein	nein	ja
<b>Wut</b>	haarsträubend	nein	nein	ja
<b>Verachtung</b>	Häme	nein	nein	ja
<b>Wut</b>	hänseln	nein	ja	nein
<b>Trauer</b>	härmen	nein	nein	ja
<b>Angst</b>	hasenfüßig	nein	nein	ja
<b>Angst</b>	hasenherzig	nein	nein	ja
<b>Verachtung</b>	Hass	nein	nein	ja
<b>Wut</b>	hassen	nein	nein	ja
<b>Ekel</b>	Hassgefühl	nein	nein	ja
<b>Ekel</b>	hässlich	nein	nein	ja
<b>Angst</b>	Heidenangst	nein	nein	ja
<b>Freude</b>	heilfroh	nein	nein	ja
<b>Schuld</b>	heimgeigen	nein	nein	ja
<b>Trauer</b>	Heimweh	nein	nein	ja
<b>Freude</b>	Heiterkeit	nein	nein	ja
<b>Interesse</b>	hellwach	nein	nein	ja
<b>Scham</b>	hemmen	nein	ja	nein
<b>Scham</b>	Hemmung	nein	ja	nein
<b>Schuld</b>	heruntermachen	nein	nein	ja
<b>Schuld</b>	herunterputzen	nein	nein	ja
<b>Angst</b>	Herzensangst	nein	nein	ja
<b>Freude</b>	Herzensfreude	nein	nein	ja
<b>Freude</b>	Hilarität	nein	nein	ja
<b>Trauer</b>	himmeltraurig	nein	nein	ja
<b>Wut</b>	hitzig	nein	ja	nein

<b>Freude</b>	hochgemut	nein	nein	ja
<b>Freude</b>	hochgestimmt	nein	nein	ja
<b>Freude</b>	Hochstimmung	nein	nein	ja
<b>Angst</b>	hoffnungslos	nein	nein	ja
<b>Angst</b>	Hoffnungslosigkeit	nein	nein	ja
<b>Interesse</b>	Höflichkeit	nein	nein	ja
<b>Verachtung</b>	Hohn	nein	nein	ja
<b>Wut</b>	höhnern	nein	ja	nein
<b>Verachtung</b>	Hohngelächter	nein	nein	ja
<b>Verachtung</b>	Hohngeschrei	nein	nein	ja
<b>Verachtung</b>	höhnisch	nein	nein	ja
<b>Angst</b>	Höllenangst	nein	nein	ja
<b>Ekel</b>	Horror	nein	nein	ja
<b>Verachtung</b>	Humor	nein	nein	ja
<b>Freude</b>	humoristisch	nein	nein	ja
<b>Freude</b>	humorvoll	nein	nein	ja
<b>Ekel</b>	Idiosynkrasie	nein	nein	ja
<b>Angst</b>	Impasse	nein	nein	ja
<b>Wut</b>	Indignation	nein	ja	nein
<b>Wut</b>	indigniert	nein	ja	nein
<b>Ekel</b>	infam	nein	nein	ja
<b>Wut</b>	Ingrimm	nein	nein	ja
<b>Scham</b>	inhibieren	nein	nein	ja
<b>Schuld</b>	inkriminieren	nein	nein	ja
<b>Wut</b>	Insult	nein	ja	nein
<b>Wut</b>	Insultierung	nein	ja	nein
<b>Interesse</b>	intensiv	nein	nein	ja
<b>Interesse</b>	interessant	nein	nein	ja
<b>Interesse</b>	Interesse	nein	nein	ja
<b>Interesse</b>	interessiert	nein	nein	ja
<b>Wut</b>	Invektive	nein	ja	nein
<b>Ekel</b>	irr	nein	nein	ja
<b>Ekel</b>	irre	nein	nein	ja
<b>Ekel</b>	irrsinnig	nein	nein	ja
<b>Wut</b>	Jähzorn	nein	nein	ja
<b>Trauer</b>	jammern	nein	nein	ja
<b>Freude</b>	Jubel	nein	nein	ja
<b>Freude</b>	Juchzer	nein	nein	ja
<b>Interesse</b>	kaprizieren	nein	nein	ja
<b>Trauer</b>	Katzenjammer	nein	nein	ja
<b>Verachtung</b>	kaustisch	nein	nein	ja
<b>Trauer</b>	klagen	nein	nein	ja
<b>Angst</b>	kleinmütig	nein	nein	ja
<b>Wut</b>	Knatsch	nein	nein	ja
<b>Freude</b>	Konvivialität	nein	nein	ja
<b>Interesse</b>	Konzentration	nein	ja	nein
<b>Interesse</b>	konzentrationsfähig	nein	nein	ja
<b>Interesse</b>	Konzentrationsfähigkeit	nein	nein	ja
<b>Interesse</b>	konzentrieren	nein	ja	nein
<b>Schuld</b>	schuldig	ja	nein	nein
<b>Ekel</b>	Kotze	nein	nein	ja

<b>Ekel</b>	kotzen	nein	nein	ja
<b>Schuld</b>	kritisieren	nein	nein	ja
<b>Trauer</b>	Kummer	nein	nein	ja
<b>Angst</b>	Lampenfieber	nein	nein	ja
<b>Freude</b>	lebenslustig	nein	nein	ja
<b>Trauer</b>	lebensverneinend	nein	nein	ja
<b>Trauer</b>	lebenverneinend	nein	nein	ja
<b>Freude</b>	Leidenschaft	nein	nein	ja
<b>Trauer</b>	Leidensweg	nein	nein	ja
<b>Trauer</b>	leidvoll	nein	nein	ja
<b>Freude</b>	lustig	nein	nein	ja
<b>Trauer</b>	Malaise	nein	nein	ja
<b>Wut</b>	Malesche	nein	nein	ja
<b>Verachtung</b>	maliziös	nein	nein	ja
<b>Wut</b>	Manie	nein	nein	ja
<b>Trauer</b>	maßleidig	nein	nein	ja
<b>Schuld</b>	maßregeln	nein	nein	ja
<b>Schuld</b>	Maßregelung	nein	nein	ja
<b>Trauer</b>	mauserig	nein	nein	ja
<b>Verachtung</b>	medisant	nein	nein	ja
<b>Trauer</b>	Melancholie	nein	nein	ja
<b>Trauer</b>	melancholisch	nein	nein	ja
<b>Ekel</b>	mies	nein	nein	ja
<b>Trauer</b>	miesepeinig	nein	nein	ja
<b>Ekel</b>	miserabel	nein	nein	ja
<b>Verachtung</b>	Missachtung	nein	nein	ja
<b>Schuld</b>	missbilligen	nein	nein	ja
<b>Ekel</b>	Missbilligung	nein	nein	ja
<b>Ekel</b>	missfallen	nein	nein	ja
<b>Trauer</b>	missgelaunt	nein	nein	ja
<b>Trauer</b>	missgestimmt	nein	nein	ja
<b>Trauer</b>	mislaunig	nein	nein	ja
<b>Trauer</b>	Missmut	nein	nein	ja
<b>Trauer</b>	missmutig	nein	nein	ja
<b>Wut</b>	Missstimmung	nein	nein	ja
<b>Wut</b>	Missvergnügen	nein	nein	ja
<b>Freude</b>	Mitfreude	nein	nein	ja
<b>Wut</b>	mobben	nein	nein	ja
<b>Verachtung</b>	mokant	nein	nein	ja
<b>Verachtung</b>	mokieren	nein	nein	ja
<b>Schuld</b>	monieren	nein	nein	ja
<b>Angst</b>	Muffe	nein	nein	ja
<b>Angst</b>	Muffensausen	nein	nein	ja
<b>Freude</b>	Munterkeit	nein	nein	ja
<b>Trauer</b>	mürrisch	nein	nein	ja
<b>Angst</b>	mutlos	nein	nein	ja
<b>Verachtung</b>	Naserümpfen	nein	nein	ja
<b>Verachtung</b>	necken	nein	nein	ja
<b>Verachtung</b>	Neckerei	nein	nein	ja
<b>Wut</b>	nerven	nein	ja	nein
<b>Wut</b>	nervig	nein	ja	nein
<b>Verachtung</b>	Nichtachtung	nein	nein	ja

<b>Trauer</b>	niederdrücken	nein	nein	ja
<b>Trauer</b>	niedergedrückt	nein	nein	ja
<b>Schuld</b>	tadelnswert	ja	nein	nein
<b>Trauer</b>	Niedergeschlagenheit	nein	ja	nein
<b>Angst</b>	Panik	nein	nein	ja
<b>Angst</b>	panikerregend	nein	nein	ja
<b>Angst</b>	paranoid	nein	nein	ja
<b>Trauer</b>	parterre	nein	nein	ja
<b>Schuld</b>	peinlich	nein	nein	ja
<b>Überraschung</b>	perplex	nein	nein	ja
<b>Überraschung</b>	Perplexität	nein	nein	ja
<b>Angst</b>	pessimistisch	nein	nein	ja
<b>Ekel</b>	Pestfetzen	nein	nein	ja
<b>Angst</b>	phobisch	nein	nein	ja
<b>Wut</b>	pikiert	nein	ja	nein
<b>Freude</b>	Pläsier	nein	nein	ja
<b>Freude</b>	pläsierlich	nein	nein	ja
<b>Scham</b>	prüde	nein	nein	ja
<b>Trauer</b>	Qual	nein	nein	ja
<b>Freude</b>	quietschfidel	nein	nein	ja
<b>Wut</b>	rabiart	nein	nein	ja
<b>Wut</b>	Rage	nein	nein	ja
<b>Wut</b>	rasen	nein	nein	ja
<b>Wut</b>	rasend	nein	nein	ja
<b>Wut</b>	Raserei	nein	nein	ja
<b>Ekel</b>	rausekeln	nein	nein	ja
<b>Schuld</b>	Rechtswidrigkeit	nein	nein	ja
<b>Scham</b>	reprimieren	nein	nein	ja
<b>Trauer</b>	resigniert	nein	nein	ja
<b>Verachtung</b>	Respektlosigkeit	nein	nein	ja
<b>Schuld</b>	Reue	nein	ja	nein
<b>Schuld</b>	reuevoll	nein	nein	ja
<b>Schuld</b>	reuig	nein	nein	ja
<b>Scham</b>	gehemmt	ja	nein	nein
<b>Interesse</b>	Rezeptivität	nein	nein	ja
<b>Schuld</b>	Rüffel	nein	nein	ja
<b>Schuld</b>	rüffeln	nein	nein	ja
<b>Schuld</b>	Rüge	nein	nein	ja
<b>Schuld</b>	rügen	nein	nein	ja
<b>Verachtung</b>	sardonisch	nein	nein	ja
<b>Wut</b>	Säuernis	nein	nein	ja
<b>Verachtung</b>	Schadenfreude	nein	nein	ja
<b>Scham</b>	Scham	nein	ja	nein
<b>Scham</b>	schämen	nein	ja	nein
<b>Scham</b>	Schamgegend	nein	nein	ja
<b>Scham</b>	schamhaft	nein	nein	ja
<b>Scham</b>	Schamhaftigkeit	nein	nein	ja
<b>Scham</b>	schämig	nein	nein	ja
<b>Scham</b>	Schamröte	nein	nein	ja
<b>Scham</b>	schamvoll	nein	nein	ja
<b>Ekel</b>	schändlich	nein	nein	ja
<b>Interesse</b>	scharfsinnig	nein	nein	ja

<b>Verachtung</b>	scharfzüngig	nein	nein	ja
<b>Angst</b>	Schauer	nein	nein	ja
<b>Ekel</b>	schauerbar	nein	nein	ja
<b>Ekel</b>	schauerhaft	nein	nein	ja
<b>Ekel</b>	schauerlich	nein	nein	ja
<b>Wut</b>	schäumen	nein	nein	ja
<b>Ekel</b>	schaurig	nein	nein	ja
<b>Angst</b>	Scheißangst	nein	nein	ja
<b>Schuld</b>	Schelte	nein	nein	ja
<b>Wut</b>	Schererei	nein	nein	ja
<b>Scham</b>	scheu	nein	nein	ja
<b>Scham</b>	Scheu	nein	nein	ja
<b>Ekel</b>	Scheusal	nein	nein	ja
<b>Ekel</b>	scheußlich	nein	nein	ja
<b>Ekel</b>	schiech	nein	nein	ja
<b>Schuld</b>	Schimpfe	nein	nein	ja
<b>Schuld</b>	schimpfen	nein	nein	ja
<b>Angst</b>	Schiss	nein	nein	ja
<b>Trauer</b>	schlimm	nein	nein	ja
<b>Wut</b>	Schmähung	nein	ja	nein
<b>Trauer</b>	schmerzlich	nein	nein	ja
<b>Ekel</b>	schnöd	nein	nein	ja
<b>Ekel</b>	schnöde	nein	nein	ja
<b>Verachtung</b>	schnöden	nein	nein	ja
<b>Angst</b>	schockieren	nein	nein	ja
<b>Ekel</b>	schofelig	nein	nein	ja
<b>Ekel</b>	schoflig	nein	nein	ja
<b>Angst</b>	schreckhaft	nein	nein	ja
<b>Ekel</b>	schrecklich	nein	nein	ja
<b>Scham</b>	schüchtern	nein	nein	ja
<b>Schuld</b>	Schuld	nein	ja	nein
<b>Schuld</b>	schuldbeladen	nein	nein	ja
<b>Schuld</b>	schuldbewusst	nein	nein	ja
<b>Scham</b>	verlegen	ja	nein	nein
<b>Schuld</b>	schuldringend	nein	nein	ja
<b>Angst</b>	schwanen	nein	nein	ja
<b>Angst</b>	schwarzseherisch	nein	nein	ja
<b>Trauer</b>	Schwermut	nein	nein	ja
<b>Trauer</b>	schwermütig	nein	nein	ja
<b>Trauer</b>	Seelenschmerz	nein	nein	ja
<b>Trauer</b>	Seelenschmetter	nein	nein	ja
<b>Wut</b>	sekkieren	nein	ja	nein
<b>Schuld</b>	Selbstärger	nein	nein	ja
<b>Freude</b>	Serenität	nein	nein	ja
<b>Scham</b>	sittsam	nein	nein	ja
<b>Verachtung</b>	skoptisch	nein	nein	ja
<b>Verachtung</b>	skoptisieren	nein	nein	ja
<b>Angst</b>	Sorge	nein	nein	ja
<b>Angst</b>	sorgenvoll	nein	nein	ja
<b>Interesse</b>	sorgfältig	nein	nein	ja
<b>Angst</b>	sorglich	nein	nein	ja
<b>Interesse</b>	sorgsam	nein	nein	ja

<b>Freude</b>	Spaß	nein	nein	ja
<b>Wut</b>	Sperenzchen	nein	nein	ja
<b>Wut</b>	Sperenzien	nein	nein	ja
<b>Verachtung</b>	spitzzünftig	nein	nein	ja
<b>Verachtung</b>	Spott	nein	ja	nein
<b>Verachtung</b>	Spöttelei	nein	nein	ja
<b>Verachtung</b>	spötteln	nein	nein	ja
<b>Verachtung</b>	spotten	nein	ja	nein
<b>Verachtung</b>	Spöttere	nein	nein	ja
<b>Scham</b>	verschämt	ja	nein	nein
<b>Überraschung</b>	sprachlos	nein	nein	ja
<b>Überraschung</b>	Sprachlosigkeit	nein	nein	ja
<b>Scham</b>	spröd	nein	nein	ja
<b>Schuld</b>	stauchen	nein	nein	ja
<b>Schuld</b>	Stauher	nein	nein	ja
<b>Freude</b>	stillvergnügt	nein	nein	ja
<b>Wut</b>	stinkig	nein	nein	ja
<b>Wut</b>	stinksauer	nein	nein	ja
<b>Ekel</b>	Stinktief	nein	nein	ja
<b>Wut</b>	Stinkwut	nein	nein	ja
<b>Schuld</b>	Strafpredigt	nein	nein	ja
<b>Schuld</b>	sühnen	nein	nein	ja
<b>Schuld</b>	Tadel	nein	ja	nein
<b>Schuld</b>	tadeln	nein	ja	nein
<b>Interesse</b>	aufmerksam	ja	nein	nein
<b>Angst</b>	terrorisieren	nein	nein	ja
<b>Scham</b>	timid	nein	nein	ja
<b>Angst</b>	timide	nein	nein	ja
<b>Wut</b>	Tobsucht	nein	nein	ja
<b>Wut</b>	tobsüchtig	nein	nein	ja
<b>Angst</b>	Todesangst	nein	nein	ja
<b>Angst</b>	Todesfurcht	nein	nein	ja
<b>Trauer</b>	tragisch	nein	nein	ja
<b>Überraschung</b>	Trara	nein	nein	ja
<b>Trauer</b>	Trauer	nein	ja	nein
<b>Trauer</b>	trauern	nein	ja	nein
<b>Interesse</b>	konzentriert	ja	nein	nein
<b>Trauer</b>	Traurigkeit	nein	nein	ja
<b>Wut</b>	trischakeln	nein	nein	ja
<b>Trauer</b>	trist	nein	nein	ja
<b>Freude</b>	Triumph	nein	nein	ja
<b>Trauer</b>	trostlos	nein	nein	ja
<b>Trauer</b>	Trübsal	nein	nein	ja
<b>Trauer</b>	trübselig	nein	nein	ja
<b>Trauer</b>	Trübsinn	nein	nein	ja
<b>Trauer</b>	trübsinnig	nein	nein	ja
<b>Ekel</b>	übel	nein	nein	ja
<b>Wut</b>	übellaunig	nein	nein	ja
<b>Angst</b>	überängstlich	nein	nein	ja
<b>Freude</b>	übergücklich	nein	nein	ja
<b>Überraschung</b>	überraschen	nein	ja	nein
<b>Freude</b>	erfreut	ja	nein	nein

<b>Überraschung</b>	Überraschung	nein	ja	nein
<b>Wut</b>	überschnappen	nein	nein	ja
<b>Freude</b>	Überschwang	nein	nein	ja
<b>Überraschung</b>	überwältigt	nein	nein	ja
<b>Ekel</b>	unappetitlich	nein	nein	ja
<b>Ekel</b>	unaussprechlich	nein	nein	ja
<b>Freude</b>	unbeschwert	nein	nein	ja
<b>Wut</b>	unerfreulich	nein	ja	nein
<b>Wut</b>	Ungehaltenheit	nein	nein	ja
<b>Wut</b>	Unmut	nein	nein	ja
<b>Ekel</b>	verabscheuen	nein	nein	ja
<b>Verachtung</b>	verachtend	nein	ja	nein
<b>Verachtung</b>	verachtenswert	nein	nein	ja
<b>Verachtung</b>	Verachtung	nein	ja	nein
<b>Freude</b>	fröhlich	ja	nein	nein
<b>Wut</b>	verärgert	nein	nein	ja
<b>Überraschung</b>	verblüffen	nein	ja	nein
<b>Freude</b>	vergnügt	ja	nein	nein
<b>Überraschung</b>	Verblüffung	nein	ja	nein
<b>Überraschung</b>	verdutzen	nein	nein	ja
<b>Überraschung</b>	verdutzt	nein	nein	ja
<b>Schuld</b>	Vergebung	nein	nein	ja
<b>Freude</b>	Vergnügen	nein	ja	nein
<b>Ekel</b>	angeekelt	ja	nein	nein
<b>Ekel</b>	angewidert	ja	nein	nein
<b>Scham</b>	Verlegenheit	nein	ja	nein
<b>Angst</b>	ängstlich	ja	nein	nein
<b>Überraschung</b>	verwundern	nein	nein	ja
<b>Überraschung</b>	verwundert	nein	nein	ja
<b>Überraschung</b>	Verwunderung	nein	nein	ja
<b>Schuld</b>	Verzeihung	nein	nein	ja
<b>Trauer</b>	verzweifelt	nein	nein	ja
<b>Freude</b>	Vorfreude	nein	nein	ja
<b>Interesse</b>	wachsam	nein	nein	ja
<b>Interesse</b>	Wachsamkeit	nein	nein	ja
<b>Ekel</b>	würgen	nein	nein	ja
<b>Wut</b>	Wut	nein	ja	nein
<b>Wut</b>	wüten	nein	ja	nein
<b>Angst</b>	erschreckt	ja	nein	nein
<b>Wut</b>	Zorn	nein	ja	nein
<b>Angst</b>	furchtsam	ja	nein	nein
<b>Wut</b>	zürnen	nein	ja	nein
<b>Interesse</b>	wach	ja	nein	nein

*Tabelle 60: Theoriebasiertes Anreichern der Emotionsterme*















## 13 Literaturverzeichnis

- § 10 Telemediengesetz. Speicherung von Informationen. TMG.
- § 51 UrhG. (1965). Urheberrechtsgesetz (BGBl. I S. 1273), das durch Artikel 13 des Gesetzes vom 17. Juli 2017 (BGBl. I S. 2541) geändert worden ist.
- § 63 UrhG. (1965). Urheberrechtsgesetz (BGBl. I S. 1273), das durch Artikel 13 des Gesetzes vom 17. Juli 2017 (BGBl. I S. 2541) geändert worden ist.
- § 87f Absatz 1 UrhG. (1965). Urheberrechtsgesetz (BGBl. I S. 1273), das durch Artikel 13 des Gesetzes vom 17. Juli 2017 (BGBl. I S. 2541) geändert worden ist.
- § 87g Absatz 4 UrhG. (1965). Urheberrechtsgesetz (BGBl. I S. 1273), das durch Artikel 13 des Gesetzes vom 17. Juli 2017 (BGBl. I S. 2541) geändert worden ist.
- §§ 39 und 62 UrhG. (1965). Urheberrechtsgesetz (BGBl. I S. 1273), das durch Artikel 13 des Gesetzes vom 17. Juli 2017 (BGBl. I S. 2541) geändert worden ist.
- Abdel-Wahab, M. & Busso, C. (2018). Domain Adversarial for Acoustic Emotion Recognition. *IEEE/ACM Trans. Audio, Speech & Language Processing*, 26 (12), 2423–2435.  
<https://doi.org/10.1109/TASLP.2018.2867099>
- Abelson, Robert & Sermat, V. (1962). Multidimensional scaling of facial expressions. *Journal of experimental psychology*, 63, 546–554.
- Adel, H., Chen, F. & Chen, Y.-Y. (2017). Ranking Convolutional Recurrent Neural Networks for Purchase Stage Identification on Imbalanced Twitter Data. In *Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics: Volume 2, Short Papers* (S. 592–598). Valencia, Spain: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/E17-2094>
- Adel, H., Roth, B. & Schütze, H. (2016). Comparing Convolutional Neural Networks to Traditional Models for Slot Filling. In *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies* (S. 828–838). San Diego, California: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/N16-1097>
- Agarwal, A., Xie, B., Vovsha, I., Rambow, O. & Passonneau, R. (2011). Sentiment Analysis of Twitter Data. In *Proceedings of the Workshop on Languages in Social Media (LSM '11)*, S. 30–38). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=2021109.2021114>
- Agarwal, S. & Yu, H. (2010). Biomedical negation scope detection with conditional random fields. *Journal of the American Medical Informatics Association*, 17 (6), 696–701.  
<https://doi.org/10.1136/jamia.2010.003228>

- Ahmad, K. (2011). Introduction. Affect Computing and Sentiment Analysis. In K. Ahmad (Ed.), *Affective Computing and Sentiment Analysis. Emotion, Metaphor and Terminology ; [Workshop on Emotion, Metaphor, Ontology, and Terminology (EMOT) in August 2008 ... Selected papers from the Workshop]* (Text, Speech and Language Technology, vol. 45, pp. vii–x). Dordrecht: Springer.
- Alali, M., Sharef, N. M., Hamdan, H., Murad, M. A. A. & Husin, N. A. (2018). Multi-layers Convolutional Neural Network for Twitter Sentiment Ordinal Scale Classification. In *Proceedings of the 3rd International Conference on Soft Computing and Data Mining* (S. 446–454).
- Alhothali, A. & Hoey, J. (2017). Semi-Supervised Affective Meaning Lexicon Expansion Using Semantic and Distributed Word Representations. *CoRR*, *abs/1703.09825*.
- Alm, C. O. (2009). *Affect in Text and Speech*: VDM Verlag Dr. Müller.
- Alm, C. O. & Sproat, R. (2005). Emotional Sequencing and Development in Fairy Tales. In J. Tao, T. Tan & R. Picard (Hrsg.), *Affective Computing and Intelligent Interaction* (Lecture Notes in Computer Science, Bd. 3784, S. 668–674). Springer.  
[https://doi.org/10.1007/11573548\\_86](https://doi.org/10.1007/11573548_86)
- Al-Smadi, M., Qawasmeh, O., Al-Ayyoub, M., Jararweh, Y. & Gupta, B. (2018). Deep Recurrent neural network vs. support vector machine for aspect-based sentiment analysis of Arabic hotels' reviews. *J. Comput. Science*, *27*, 386–393.  
<https://doi.org/10.1016/j.jocs.2017.11.006>
- Altszyler, E., Sigman, M. & Slezak, D. F. (2016). Comparative study of LSA vs Word2vec embeddings in small corpora. A case study in dreams database. *CoRR*, *abs/1610.01520*.
- Alvarado, N. (1998). A Reconsideration of the Structure of the Emotion Lexicon. *Motivation and Emotion*, *22* (4), 329–344. <https://doi.org/10.1023/A:1021356424065>
- Aman, S. & Szpakowicz, S. (2007). Identifying Expressions of Emotion in Text. In V. Matoušek & P. Mautner (Hrsg.), *Text, Speech and Dialogue* (Lecture Notes in Computer Science, Bd. 4629, S. 196–205). Springer. [https://doi.org/10.1007/978-3-540-74628-7\\_27](https://doi.org/10.1007/978-3-540-74628-7_27)
- Anderson, A. & Phelps, E. (2002). Is the human amygdala critical for the subjective experience of emotion? Evidence of intact dispositional affect in patients with amygdala lesions. *Journal of cognitive neuroscience*, *14* (5), 709–720.  
<https://doi.org/10.1162/08989290260138618>
- Andreas, J. & Klein, D. (2015). When and why are log-linear models self-normalizing? In *NAACL* (S. 244–249).
- Andreevskaia, A. & Bergler, S. (2006). Mining WordNet for a Fuzzy Sentiment: Sentiment Tag Extraction from WordNet Glosses. *EACL*, *6*, 209–215.
- Andrzejewski, D. (2010). *Incorporating Domain Knowledge in Latent Topic Models*. Madison, WI, USA.

- Andrzejewski, D., Zhu, X. & Craven, M. (2009). Incorporating Domain Knowledge into Topic Modeling via Dirichlet Forest Priors. In *Proceedings of the 26th Annual International Conference on Machine Learning (ICML '09, S. 25–32)*. New York, NY, USA: ACM. Verfügbar unter <http://doi.acm.org/10.1145/1553374.1553378>
- Andrzejewski, D., Zhu, X., Craven, M. & Recht, B. (University of Wisconsin-Madison, Hrsg.). (2011). *A Framework for Incorporating General Domain Knowledge into Latent Dirichlet Allocation using First-Order Logic*, Lawrence Livermore National Laboratory. Zugriff am 10.09.2014. Verfügbar unter <http://pages.cs.wisc.edu/~andrzejewski/publications/ijcai-2011-poster.pdf>
- Antoniak, M. & Mimno, D. (2018). Evaluating the Stability of Embedding-based Word Similarities. *Transactions of the Association for Computational Linguistics*, 6, 107–119. Verfügbar unter <http://aclweb.org/anthology/Q18-1008>
- Ardakani, M. S. & Arbabi, E. (2017). A Categorical Approach for Recognizing Emotional Effects of Music. *CoRR*, *abs/1709.05684*.
- Arnold, M. (1960a). *Emotion and Personality* (Emotion and Personality): Columbia University Press.
- Arnold, M. (1960b). *Neurological and physiological aspects* (Emotion and Personality): Columbia University Press.
- Ashimura, K., Baggia, P., Oltramari, A., Peter, C. & Zovato, E. (2014). *Vocabularies for EmotionML*, W3C. Zugriff am 08.08.2014. Verfügbar unter <http://www.w3.org/TR/emotion-voc/#frijda-action-tendencies>
- Assange, J., Appelbaum, J., Müller-Maguhn, A. & Zimmermann, J. (2013). Cypherpunks. *Unsere Freiheit und die Zukunft des Internets. Cypherpunks*.
- Auer, P. (Ed.). (2003). *Code-switching in conversation. Language, interaction and identity* (Transferred to Digital Printing). London: Routledge.
- Avila, S., Thome, N., Cord, M., Valle, E. & Araújo, A. de. (2011). BOSSA. Extended bow formalism for image classification. In *18th IEEE International Conference on Image Processing* (S. 2909–2912). IEEE.
- Avila, S., Thome, N., Cord, M., Valle, E. & Araújo, A. de. (2013). Pooling in image representation. The visual codeword point of view. *Computer Vision and Image Understanding*, 117 (5), 453–465. <https://doi.org/10.1016/j.cviu.2012.09.007>
- Baccianella, S., Esuli, A. & Sebastiani, F. (2010). SentiWordNet 3.0: An Enhanced Lexical Resource for Sentiment Analysis and Opinion Mining. In *Proceedings of the 7th Conference on International Language Resources and Evaluation (LREC'10)*. Valletta, Malta: European Language Resources Association (ELRA). Verfügbar unter [http://www.lrec-conf.org/proceedings/lrec2010/pdf/769\\_Paper.pdf](http://www.lrec-conf.org/proceedings/lrec2010/pdf/769_Paper.pdf)

- Bai, J., Luo, K., Peng, J., Shi, J., Wu, Y., Feng, L. et al. (2017). Music emotions recognition by cognitive classification methodologies. In *16th IEEE International Conference on Cognitive Informatics & Cognitive Computing, ICCI\*CC 2017, Oxford, United Kingdom, July 26-28, 2017* (S. 121–129). Verfügbar unter <http://doi.ieeecomputer-society.org/10.1109/ICCI-CC.2017.8109740>
- Bakliwal, A., Arora, P., Madhappan, S., Kapre, N., Singh, M. & Varma, V. (2012). Mining Sentiments from Tweets. In *Proceedings of the 3rd Workshop in Computational Approaches to Subjectivity and Sentiment Analysis* (S. 11–18). Jeju, Korea: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology-new/W/W12/W12-3704.bib>
- Balahur, A., Hermida, J. & Montoyo, A. (2012). Building and Exploiting EmotiNet, a Knowledge Base for Emotion Detection Based on the Appraisal Theory Model. *IEEE Trans. Affect. Comput.*, 3 (1), 88–101. <https://doi.org/10.1109/T-AFFC.2011.33>
- Balahur, A., van der Goot, E., Vossen, P. & Montoyo, A. (Hrsg.). (2016). *Proceedings of the 7th Workshop on Computational Approaches to Subjectivity, Sentiment and Social Media Analysis*. Stroudsburg, PA, USA: Association for Computational Linguistics.
- Balnat, V. (2011). *Kurzwortbildung im Gegenwartsdeutschen* (Germanistische Linguistik): Olms Verlag.
- Baroni, M., Dinu, G. & Kruszewski, G. (2014). Don't count, predict! A systematic comparison of context-counting vs. context-predicting semantic vectors. In *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)* (S. 238–247). Baltimore, Maryland: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/P14-1023>
- Barrett, L. F. (2006). Are Emotions Natural Kinds? *Perspectives on psychological science : a journal of the Association for Psychological Science*, 1 (1), 28–58. <https://doi.org/10.1111/j.1745-6916.2006.00003.x>
- Barrett, L. F. (2011). Constructing Emotion. *Psychological topics*, 20 (3), 359–380.
- Barrett, L. F. (2017). *How emotions are made. The secret life of the brain*: Pan Macmillan.
- Barrett, L. F., Lindquist, K., Bliss-Moreau, E., Duncan, S., Gendron, M., Mize, J. et al. (2007). Of Mice and Men. Natural Kinds of Emotions in the Mammalian Brain? A Response to Panksepp and Izard. *Perspectives on psychological science : a journal of the Association for Psychological Science*, 2 (3), 297–312. <https://doi.org/10.1111/j.1745-6916.2007.00046.x>
- Barros, P. V. A., Churamani, N., Lakomkin, E., Siqueira, H., Sutherland, A. & Wermter, S. (2018). The OMG-Emotion Behavior Dataset. In *International Joint Conference on Neural Networks* (S. 1–7).

- Barry, J. (2017). Sentiment Analysis of Online Reviews Using Bag-of-Words and LSTM Approaches. In *Proceedings of the 25th Irish Conference on Artificial Intelligence and Cognitive Science, Dublin, Ireland, December 7 - 8, 2017* (S. 272–274). Verfügbar unter [http://ceur-ws.org/Vol-2086/AICS2017\\_paper\\_21.pdf](http://ceur-ws.org/Vol-2086/AICS2017_paper_21.pdf)
- Bartsch, A. & Hübner, S. *Emotionale Kommunikation - ein integratives Modell*. @Halle, Univ., FB Sprach- u. Literaturwiss., Diss. Göttingen, Halle, Saale. Verfügbar unter <http://nbn-resolving.de/urn:nbn:de:gbv:3-000011479>
- Becker, S. & LeCun, Y. (1989). Improving the Convergence of Back-Propagation Learning with Second-Order Methods. In D. S. Touretzky, G. Hinton & T. Sejnowski (Hrsg.), *Proc. of the 1988 Connectionist Models Summer School* (S. 29–37). San Mateo: Morgan Kaufmann.
- Bengio, Y. (2009). Learning Deep Architectures for AI. *Foundations and Trends® in Machine Learning*, 2 (1), 1–127. <https://doi.org/10.1561/2200000006>
- Bengio, Y., Delalleau, O. & Le Roux, N. (2006). Label Propagation and Quadratic Criterion. In *Semi-Supervised Learning* (S. 193–216). MIT Press. Verfügbar unter <https://www.microsoft.com/en-us/research/publication/label-propagation-and-quadratic-criterion/>
- Bengio, Y., Ducharme, R., Vincent, P. & Janvin, C. (2003). A Neural Probabilistic Language Model. *J. Mach. Learn. Res.*, 3, 1137–1155. Verfügbar unter <http://dl.acm.org/citation.cfm?id=944919.944966>
- Bensch, N. & Stetter, M. (2007). *Die Negation / Verneinung*. Zugriff am 22.07.2014. Verfügbar unter [http://www.mein-deutschbuch.de/lernen.php?menu\\_id=17](http://www.mein-deutschbuch.de/lernen.php?menu_id=17)
- Bergknapp, A. (2002). Strukturmodell der Emotionen. In *Ärger in Organisationen: Eine systemische Strukturanalyse* (S. 58–124). Wiesbaden: VS Verlag für Sozialwissenschaften. [https://doi.org/10.1007/978-3-322-90199-6\\_3](https://doi.org/10.1007/978-3-322-90199-6_3)
- Berry, N. (2012). *Emoticon Analysis in Twitter. The top emoticons*, Data Genetics. Zugriff am 26.12.2017. Verfügbar unter <http://www.datagenetics.com/blog/october52012/index.html>
- Biagioni, R. (2016). *The sentinet sentiment lexicon. Exploring semantic richness in multi-word concepts* (Briefs in cognitive computation, Bd. 4). Switzerland: Springer.
- Bildosola, I., Martinez-Corral, U. & Basterretxea, K. (2014). Adaptive scalable SVD unit for fast processing of large LSE problems. In *2014 IEEE 25th International Conference on Application-Specific Systems, Architectures and Processors* (S. 17–24). IEEE.
- Bishop, C. (2006). *Pattern recognition and machine learning* (Information Science and Statistics). New York, NY: Springer.
- Blanchard, C. & Blanchard, R. (2003). What can animal aggression research tell us about human aggression? *Hormones and Behavior*, 44 (3), 171–177. [https://doi.org/10.1016/S0018-506X\(03\)00133-8](https://doi.org/10.1016/S0018-506X(03)00133-8)

- Blei, D. (2008). *Topic-models. The computational complexity of LDA*. Zugriff am 25.07.2017. Verfügbar unter <https://lists.cs.princeton.edu/pipermail/topic-models/2008-April/000211.html>
- Blei, D. (2012). Probabilistic topic models. *Communications of the ACM*, 55 (4), 77. Zugriff am 01.07.2013.
- Blei, D., Griffiths, T., Jordan, M. & Tenenbaum, J. (2004). Hierarchical Topic Models and the Nested Chinese Restaurant Process. In *Advances in Neural Information Processing Systems* (S. 2003). MIT Press.
- Blei, D. & Lafferty, J. (2006). Dynamic topic models. In *Proceedings of the 23rd international conference on Machine learning (ICML '06, S. 113–120)*. New York, NY, USA: ACM.
- Blei, D., Ng, A. & Jordan, M. (2003). Latent dirichlet allocation. *J. Mach. Learn. Res.*, 3, 993–1022.
- Block, J. (1957). A study of affective responsiveness in a lie-detection situation. *The Journal of Abnormal and Social Psychology*, 55 (1), 11–15. <https://doi.org/10.1037/h0046624>
- Blühdom, H. (2008). *Negation im Deutschen. Syntax, Prosodie, Semantik* (Studien zur deutschen Sprache, Bd. 48, 1. Aufl.). Tübingen: Narr.
- Bojanowski, P., Grave, E., Joulin, A. & Mikolov, T. (2016). Enriching Word Vectors with Subword Information. *CoRR*, [abs/1607.04606](https://arxiv.org/abs/1607.04606).
- Boniwell, I. (2012). *Positive psychology in a nutshell. The science of happiness* (3rd ed.).
- Bortz, J. (1993). *Statistik. Für Sozialwissenschaftler* (Springer-Lehrbuch, 4. Aufl.).
- Bortz, J. & Schuster, C. (2010). *Statistik für Human- und Sozialwissenschaftler*. Berlin, Heidelberg: Springer. <https://doi.org/10.1007/978-3-642-12770-0>
- Bottenberg, E. (1972). *Emotionspsychologie. Ein Beitrag zur empirischen Dimensionierung emotionaler Vorgänge ; mit Tabellen* (Das wissenschaftliche Taschenbuch Abteilung Geisteswissenschaften, Bd. 4). München: Goldmann.
- Bottou, L. (2010). Large-Scale Machine Learning with Stochastic Gradient Descent. In Y. Lechevallier & G. Saporta (Hrsg.), *Proceedings of COMPSTAT'2010: 19th International Conference on Computational Statistics Paris France, August 22-27, 2010 Keynote, Invited and Contributed Papers* (S. 177–186). Heidelberg: Physica-Verlag HD. [https://doi.org/10.1007/978-3-7908-2604-3\\_16](https://doi.org/10.1007/978-3-7908-2604-3_16)
- Bouma, G. (2009). Normalized (Pointwise) Mutual Information in Collocation Extraction. In *Proceedings of the International Conference of the German Society for Computational Linguistics and Language Technology (GSCL '09)*. Potsdam, Germany.
- Boureau, Y.-L., Ponce, J. & LeCun, Y. (2010). A Theoretical Analysis of Feature Pooling in Visual Recognition. In *27th International Conference on Machine Learning, Haifa, Israel*.
- Bouvier, J. (2006). *Notes on Convolutional Neural Networks*. Zugriff am 13.08.2017. Verfügbar unter [http://people.csail.mit.edu/jvb/papers/cnn\\_tutorial.pdf](http://people.csail.mit.edu/jvb/papers/cnn_tutorial.pdf)



- Burkitt, I. (2014). *Emotions and social relations*. Los Angeles: SAGE Publications.
- Calin, E. (o.J.). *List of positive words*. Zugriff am 31.10.2015. Verfügbar unter <http://positive-wordsresearch.com/list-of-positive-words/>
- Calvo, R. (2010). Latent and Emergent Models in Affective Computing. *Emotion review : journal of the International Society for Research on Emotion*, 2 (3), 288–289.  
<https://doi.org/10.1177/1754073910368735>
- Cambria, E. (2013). An Introduction to Concept-Level Sentiment Analysis. In F. Castro, A. Gelbukh & M. González (Hrsg.), *Advances in Soft Computing and Its Applications* (Lecture Notes in Computer Science, Bd. 8266, S. 478–483). Springer.  
[https://doi.org/10.1007/978-3-642-45111-9\\_41](https://doi.org/10.1007/978-3-642-45111-9_41)
- Cambria, E., Havasi, C. & Hussain, A. (2012a). SenticNet 2: A semantic and affective resource for opinion mining and sentiment analysis. In *Proceedings of FLAIRS, Marco Island* (S. 202–207).
- Cambria, E. & Hussain, A. (2012). *Sentic Computing. Techniques, tools, and applications* (Briefs in cognitive computation). Dordrecht: Springer.
- Cambria, E. & Hussain, A. (2015). *Sentic Computing. A Common-Sense-Based Framework for Concept-Level Sentiment Analysis* (Socio-Affective Computing, vol. 1). Cham: Springer. <https://doi.org/10.1007/978-3-319-23654-4>
- Cambria, E., Livingstone, A. & Hussain, A. (2012b). The Hourglass of Emotions. In A. Esposito, A. Esposito, A. Vinciarelli, R. Hoffmann & V. Müller (Hrsg.), *Cognitive Behavioural Systems* (Lecture Notes in Computer Science, Bd. 7403, S. 144–157). Springer.  
[https://doi.org/10.1007/978-3-642-34584-5\\_11](https://doi.org/10.1007/978-3-642-34584-5_11)
- Cambria, E., Olsher, D. J. & Rajagopal, D. (2014a). SenticNet 3: A common and common-sense knowledge base for cognition-driven sentiment analysis. In *Proceedings of AAAI, Quebec City*.
- Cambria, E., Poria, S., Bajpai, R. & Schuller, B. (2016). SenticNet 4. A Semantic Resource for Sentiment Analysis Based on Conceptual Primitives. In *Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers* (S. 2666–2677). The COLING 2016 Organizing Committee. Verfügbar unter <http://aclanthology.coli.uni-saarland.de/pdf/C/C16/C16-1251.pdf>
- Cambria, E., Schuller, B., Xia, Y. & Havasi, C. (2013). New Avenues in Opinion Mining and Sentiment Analysis. *Intelligent Systems, IEEE*, 28 (2), 15–21.  
<https://doi.org/10.1109/MIS.2013.30>
- Cambria, E., Song, Y., Wang, H. & Newton, H. (2014b). Semantic Multidimensional Scaling for Open-Domain Sentiment Analysis. *Intelligent Systems, IEEE*, 29 (2), 44–51.  
<https://doi.org/10.1109/MIS.2012.118>

- Cambria, E., Speer, R., Havasi, C. & Hussain, A. (2010). SenticNet: A publicly available semantic resource for opinion mining. In *Proceedings of AAAI CSK, Arlington* (S. 14–18).
- Campos, J. & Barrett, K. (1990). Toward a new understanding of emotions and their development. In C. E. Izard, J. Kagan & R. Zajonc (Eds.), *Emotions, cognition, and behavior* (pp. 229–263). Cambridge: Cambridge University Press.
- Cannon, W. (1927). The James-Lange Theory of Emotions. A Critical Examination and an Alternative Theory. *The American Journal of Psychology*, 39 (1/4), 106.  
<https://doi.org/10.2307/1415404>
- Canny, J. (2004). GaP. In M. Sanderson, K. Järvelin, J. Allan & P. Bruza (Hrsg.), *Proceedings of the 27th annual international conference on Research and development in information retrieval - SIGIR '04* (S. 122). New York, New York, USA: ACM.
- Carrillo de Albornoz, J. & Plaza, L. (2013). An emotion-based model of negation, intensifiers, and modality for polarity and intensity classification. *Journal of the American Society for Information Science and Technology*, 64 (8), 1618–1633.  
<https://doi.org/10.1002/asi.22859>
- Carrillo de Albornoz, J., Plaza, L. & Gervás, P. (2012). SentiSense: An easily scalable concept-based affective lexicon for sentiment analysis. In N. Calzolari, K. Choukri, T. Declerck, U. Doğan, B. Maegaard, J. Mariani et al. (Hrsg.), *Proceedings of the Eighth International Conference on Language Resources and Evaluation (LREC-2012)* (S. 3562–3567). Istanbul, Turkey: European Language Resources Association (ELRA). Verfügbar unter [http://www.lrec-conf.org/proceedings/lrec2012/pdf/236\\_Paper.pdf](http://www.lrec-conf.org/proceedings/lrec2012/pdf/236_Paper.pdf)
- Chapman, W., Bridewell, W., Hanbury, P., Cooper, G. & Buchanan, B. (2001). A Simple Algorithm for Identifying Negated Findings and Diseases in Discharge Summaries. *Journal of Biomedical Informatics*, 301–310.
- Chapman, W., Hilert, D., Velupillai, S., Kvist, M., Skeppstedt, M., Chapman, B. et al. (2013). Extending the NegEx Lexicon for Multiple Languages. *Studies in health technology and informatics*, 192, 677–681.
- Chaspari, T., Dimitriadis, D. & Maragos, P. (2014). Emotion classification of speech using modulation features. In *2014 22nd European Signal Processing Conference (EUSIPCO)* (S. 1552–1556).
- Chen, D. & Manning, C. (2014). A Fast and Accurate Dependency Parser using Neural Networks. In *Emnlp* (S. 740–750).
- Chen, S. F. & Rosenfeld, R. (2000). A survey of smoothing techniques for ME models. *IEEE Transactions on Speech and Audio Processing*, 8 (1), 37–50.  
<https://doi.org/10.1109/89.817452>

- Chen, W., Grangier, D. & Auli, M. (2015). Strategies for Training Large Vocabulary Neural Language Models. *ArXiv e-prints*. Zugriff am 25.07.2017. Verfügbar unter <https://arxiv.org/abs/1512.04906>
- Chen, Y., Hou, W. & Cheng, X. (2018). Hierarchical Convolution Neural Network for Emotion Cause Detection on Microblogs. In *Proceedings of the Artificial Neural Networks and Machine Learning* (S. 115–122).
- Cheng, J., Li, P., Ding, Z., Zhang, S. & Wang, H. (2016). Sentiment Classification of Chinese Microblogging Texts with Global RNN. In *IEEE First International Conference on Data Science in Cyberspace* (S. 653–657). Verfügbar unter <http://doi.ieeecomputer-society.org/10.1109/DSC.2016.65>
- Chernykh, V., Sterling, G. & Prihodko, P. (2017). Emotion Recognition From Speech With Recurrent Neural Networks. *CoRR*, *abs/1701.08071*.
- Cho, M., Dhir, C. S. & Lee, J. (2015). Hessian-Free Optimization For Learning Deep Multidimensional Recurrent Neural Networks. *CoRR*, *abs/1509.03475*.
- Chu, C. & Kurohashi, S. (2016). Paraphrasing Out-of-Vocabulary Words with Word Embeddings and Semantic Lexicons for Low Resource Statistical Machine Translation. In *LREC* (S. 644–648).
- Clevert, D.-A., Unterthiner, T. & Hochreiter, S. (2015). Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs). *ArXiv e-prints*.
- Cohen, J. (2016). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, *20* (1), 37–46. <https://doi.org/10.1177/001316446002000104>
- Collobert, R. & Weston, J. (2008). A Unified Architecture for Natural Language Processing. Deep Neural Networks with Multitask Learning. In *Proceedings of the 25th International Conference on Machine Learning* (ICML '08, S. 160–167). New York, NY, USA: ACM. Verfügbar unter <http://doi.acm.org/10.1145/1390156.1390177>
- Collobert, R., Weston, J., Bottou, L., Karlen, M., Kavukcuoglu, K. & Kuksa, P. (2011). Natural Language Processing (almost) from Scratch. *CoRR*, *abs/1103.0398*.
- Corr, P. & McNaughton, N. (2015). Neural mechanisms of low trait anxiety and risk for externalizing behavior. In S. Hinshaw & T. Beauchaine (Eds.), *The Oxford handbook of externalizing spectrum disorders* (Oxford library of psychology, pp. 220–238). Oxford: Oxford University Press.
- Cortes, C., Mohri, M., Riley, M. & Rostamizadeh, A. (2008). Sample Selection Bias Correction Theory. In *Proceedings of the 19th International Conference on Algorithmic Learning Theory* (ALT '08, S. 38–53). Berlin, Heidelberg: Springer. Verfügbar unter [http://dx.doi.org/10.1007/978-3-540-87987-9\\_8](http://dx.doi.org/10.1007/978-3-540-87987-9_8)
- Councill, I., McDonald, R. & Velikovich, L. (2010). What's Great and What's Not: Learning to Classify the Scope of Negation for Improved Sentiment Analysis. In *Proceedings of the*

- Workshop on Negation and Speculation in Natural Language Processing (NeSp-NLP '10*, S. 51–59). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1858959.1858969>
- Cowen, A. & Keltner, D. (2017). Self-report captures 27 distinct categories of emotion bridged by continuous gradients. *Proceedings of the National Academy of Sciences of the United States of America*, 114 (38), E7900-E7909. <https://doi.org/10.1073/pnas.1702247114>
- CrowdFlower. (2015). *Primary emotions of statements*. Zugriff am 07.12.2017. Verfügbar unter <https://www.figure-eight.com/wp-content/uploads/2016/03/primary-plutchik-wheel-DFE.csv>
- CrowdFlower. (2016). *Sentiment Analysis. Emotion in Text*. Zugriff am 07.12.2017. Verfügbar unter [https://www.figure-eight.com/wp-content/uploads/2016/07/text\\_emotion.csv](https://www.figure-eight.com/wp-content/uploads/2016/07/text_emotion.csv)
- Crystal, D., Parrott, G., Okazaki, Y. & Watanabe, H. (2016). Examining relations between shame and personality among university students in the United States and Japan. A developmental perspective. *International Journal of Behavioral Development*, 25 (2), 113–123. <https://doi.org/10.1080/01650250042000177>
- Cunha, R. G. (2007). *How to Write a Spelling Corrector*. Zugriff am 24.11.2015. Verfügbar unter <http://raelcunha.com/spell-correct/>
- Cunningham, H. (2002). GATE, a General Architecture for Text Engineering. *Computers and the Humanities*, 36 (2), 223–254. <https://doi.org/10.1023/A:1014348124664>
- Daelemans, W. & Bosch, A. (2005). *Memory-based language processing* (Studies in natural language processing). Cambridge, UK: Cambridge University Press.
- Daelemans, W., Zavrel, J., Berck, P. & Gillis, S. (1996). MBT: A Memory-Based Part of Speech Tagger-Generator. In E. Ejerhed & I. Dagan (Hrsg.), *Proceedings of the Fourth Workshop on Very Large Corpora* (S. 14–27).
- Dagan, I., Lee, L. & Pereira, F. (1999). Similarity-Based Models of Word Cooccurrence Probabilities. *Machine Learning*, 34 (1), 43–69. <https://doi.org/10.1023/A:1007537716579>
- Dagan, I., Pereira, F. & Lee, L. (1994). Similarity-Based Estimation of Word Cooccurrence Probabilities. In *Proceedings of the 32nd Annual Meeting of the Association for Computational Linguistics* (272-278).
- Dai, W., Dai, C., Qu, S., Li, J. & Das, S. (2016). Very Deep Convolutional Neural Networks for Raw Waveforms. *CoRR*, *abs/1610.00087*.
- Dalal, M. & Zaveri, M. (2014). Opinion Mining from Online User Reviews Using Fuzzy Linguistic Hedges. *Applied Computational Intelligence and Soft Computing*, 2014 (4, part 3), 1–9. <https://doi.org/10.1155/2014/735942>
- Das, S. R. & Chen, M. (2001). Yahoo! for Amazon: Sentiment Parsing from Small Talk on the Web. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.276189>

- Dauphin, Y., Pascanu, R., Gülçehre, Ç., Cho, K., Ganguli, S. & Bengio, Y. (2014). Identifying and attacking the saddle point problem in high-dimensional non-convex optimization. *CoRR*, *abs/1406.2572*.
- Davidov, D., Tsur, O. & Rappoport, A. (2010). Enhanced Sentiment Learning Using Twitter Hashtags and Smileys. In *Proceedings of the 23rd International Conference on Computational Linguistics: Posters (COLING '10)*, S. 241–249. Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1944566.1944594>
- Davidson, R. & Ekman, P. (1994). Afterword. In P. Ekman & R. Davidson (Hrsg.), *The nature of emotion. Fundamental questions* (Series in affective science, S. 232–233). New York: Oxford University Press.
- Davidson, R., Ekman, P., Saron, C. D., Senulis, J. A. & Friesen, W. V. (1990). Approach-withdrawal and cerebral asymmetry. Emotional expression and brain physiology. I. *Journal of personality and social psychology*, *58* (2), 330–341.
- Davidson, R., Scherer, K. & Goldsmith, H. (Hrsg.). (2009). *Handbook of affective sciences* (Series in affective science). New York: Oxford University Press.
- Deb, S. & Dandapat, S. (2019). Multiscale Amplitude Feature and Significance of Enhanced Vocal Tract Information for Emotion Classification. *IEEE Trans. Cybernetics*, *49* (3), 802–815. <https://doi.org/10.1109/TCYB.2017.2787717>
- Deeplearning4j Development Team. (o. J.). *Deeplearning4j. Open-source distributed deep learning for the JVM* (Apache Software Foundation License 2.0). Zugriff am 01.08.2017. Verfügbar unter <http://deeplearning4j.org>
- Deerwester, S., Dumais, S., Furnas, G., Landauer, T. & Harshman, R. (1990). Indexing by latent semantic analysis. *Journal of the American Society for Information Science*, *41* (6), 391–407. [https://doi.org/10.1002/\(SICI\)1097-4571\(199009\)41:6<391::AID-ASI1>3.0.CO;2-9](https://doi.org/10.1002/(SICI)1097-4571(199009)41:6<391::AID-ASI1>3.0.CO;2-9)
- Demos, J. (1982). The changing faces of fatherhood. In S. Cath, A. Gurwitt & J. Ross (Eds.), *Father and Child. Developmental and Clinical Perspectives* (1<sup>st</sup> ed., pp. 425–445). Routledge.
- Denton, D. (2006). *The primordial emotions. The dawning of consciousness*. Oxford: Oxford University Press.
- Deriu, J. & Cieliebak, M. (2016). Sentiment Detection using Convolutional Neural Networks with Multi-Task Training and Distant Supervision (CLiC-it 2016) & Fifth Evaluation Campaign of Natural Language Processing and Speech Tools for Italian. Final Workshop (EVALITA 2016), Napoli, Italy, December 5-7, 2016. In P. Basile, A. Corazza, F. Cutugno, S. Montemagni, M. Nissim, V. Patti et al. (Hrsg.), *Proceedings of Third Italian Conference on Computational Linguistics (CLiC-it 2016) & Fifth Evaluation Campaign of Natural*

- Language Processing and Speech Tools for Italian. Final Workshop (EVALITA 2016), Napoli, Italy, December 5-7, 2016* (CEUR Workshop Proceedings, Bd. 1749). CEUR-WS.org. Verfügbar unter [http://ceur-ws.org/Vol-1749/paper\\_032.pdf](http://ceur-ws.org/Vol-1749/paper_032.pdf)
- DeRose, S. (2005). *The Compass DeRose Guide to Emotion Words*. Zugriff am 31.10.2015. Verfügbar unter <http://www.derose.net/steve/resources/emotionwords/ewords.html>
- Desmet, P. (2012). *Faces of Product Pleasure. 25 Positive Emotions in Human-Product Interactions*. Verfügbar unter <http://www.ijdesign.org/ojs/index.php/IJDesign/article/view/1190/459>
- Deutscher Bundestag (Hrsg.). (2017). *Bundestag beschließt Gesetz gegen strafbare Inhalte im Internet*. Zugriff am 30.05.2018. Verfügbar unter <https://www.bundestag.de/dokumente/textarchiv/2017/kw20-de-soziale-netzwerke/505074>
- Devitt, A. & Ahmad, K. (2013). Is there a language of sentiment? An analysis of lexical resources for sentiment analysis. *Language Resources and Evaluation*, 47 (2), 475–511. Verfügbar unter <http://dblp.uni-trier.de/db/journals/lre/lre47.html#DevittA13>
- Dey, L., Chakraborty, S., Biswas, A., Bose, B. & Tiwari, S. (2016). Sentiment Analysis of Review Datasets Using Naive Bayes and K-NN Classifier. *CoRR*, *abs/1610.09982*.
- Ding, C., Li, T. & Peng, W. (2008). On the equivalence between Non-negative Matrix Factorization and Probabilistic Latent Semantic Indexing. *Computational Statistics & Data Analysis*, 52 (8), 3913–3927. <https://doi.org/10.1016/j.csda.2008.01.011>
- Dittenbach, M. (2010). *Scoring and Ranking Techniques. tf-idf term weighting and cosine similarity*, Information Retrieval Facility. Zugriff am 03.10.2014. Verfügbar unter <http://www.ir-facility.org/scoring-and-ranking-techniques-tf-idf-term-weighting-and-cosine-similarity>
- Dodds, P. S., Harris, K. D., Kloumann, I., Bliss, C. & Danforth, C. (2011). Temporal Patterns of Happiness and Information in a Global Social Network: Hedonometrics and Twitter. *PLoS ONE*, 6 (12), e26752. <https://doi.org/10.1371/journal.pone.0026752>
- Donalies, E. (2011a). *Derivation*. Zugriff am 21.11.2016. Verfügbar unter [http://hypermedia.ids-mannheim.de/call/public/sysgram.ansicht?v\\_typ=d&v\\_id=631](http://hypermedia.ids-mannheim.de/call/public/sysgram.ansicht?v_typ=d&v_id=631)
- Donalies, E. (2011b). *Komposition*. Zugriff am 24.11.2016. Verfügbar unter [http://hypermedia.ids-mannheim.de/call/public/sysgram.ansicht?v\\_typ=d&v\\_id=585](http://hypermedia.ids-mannheim.de/call/public/sysgram.ansicht?v_typ=d&v_id=585)
- Donalies, E. (2012). *Fugenelement*. Zugriff am 21.11.2016. Verfügbar unter [http://hypermedia.ids-mannheim.de/call/public/sysgram.ansicht?v\\_typ=d&v\\_id=547&v\\_wort=fugen](http://hypermedia.ids-mannheim.de/call/public/sysgram.ansicht?v_typ=d&v_id=547&v_wort=fugen)
- Dong, L., Wei, F., Tan, C., Tang, D., Zhou, M. & Xu, K. (2014). Adaptive Recursive Neural Network for Target-dependent Twitter Sentiment Classification. In *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics* (S. 49–54). Verfügbar unter <http://aclweb.org/anthology/P/P14/P14-2009.pdf>

- Dorsch, F., Wirtz, M. A. & Strohmer, J. (Hrsg.). (2013). *Dorsch - Lexikon der Psychologie* (16., vollst. überarb. Aufl.). Bern: Huber.
- Dos Santos, C. N. & Zadrozny, B. (2014). Learning Character-level Representations for Part-of-speech Tagging. In *Proceedings of the 31st International Conference on International Conference on Machine Learning - Volume 32* (ICML '14, 1818-1826). JMLR.org. Verfügbar unter <http://dl.acm.org/citation.cfm?id=3044805.3045095>
- Duchi, J., Hazan, E. & Singer, Y. (2011). Adaptive Subgradient Methods for Online Learning and Stochastic Optimization. *J. Mach. Learn. Res.*, 12, 2121–2159. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1953048.2021068>
- Dudenredaktion. (o. J. a.). "abstoßend" auf Duden online. Zugriff am 21.07.2017. Verfügbar unter <http://www.duden.de/rechtschreibung/abstoszen>
- Dudenredaktion. (o. J. b.). "Affekt" auf Duden online. Zugriff am 20.07.2017. Verfügbar unter <http://www.duden.de/rechtschreibung/Affekt>
- Dudenredaktion. (o. J. d.). "fröhlich" auf Duden online. Zugriff am 26.12.2017. Verfügbar unter <http://www.duden.de/rechtschreibung/froehlich>
- Dudenredaktion. (o. J. e.). "Trauer" auf Duden online. Zugriff am 26.12.2017. Verfügbar unter <https://www.duden.de/rechtschreibung/Trauer>
- Dudenredaktion. (o. J. f.). "vergnügt " auf Duden online. Zugriff am 26.12.2017. Verfügbar unter <http://www.duden.de/rechtschreibung/vergnuegt>
- Dudenredaktion. (o. J. c.). *Bindestrich als Ergänzungsstrich*. Zugriff am 27.11.2016. Verfügbar unter <http://www.duden.de/sprachwissen/sprachratgeber/bindestrich-als-ergaenzungsstrich>
- Dunn, O. (1964). Multiple Comparisons Using Rank Sums. *Technometrics*, 6 (3), 241–252. <https://doi.org/10.1080/00401706.1964.10490181>
- Ebert, S., Vu, N. T. & Schütze, H. (2015). CIS-positive: A Combination of Convolutional Neural Networks and Support Vector Machines for Sentiment Analysis in Twitter. In *Proceedings of the 9th International Workshop on Semantic Evaluation* (S. 527–532). Verfügbar unter <http://aclweb.org/anthology/S/S15/S15-2088.pdf>
- Ekman, P. (1992). An argument for basic emotions. *Cognition and Emotion*, 6 (3), 169–200. <https://doi.org/10.1080/02699939208411068>
- Ekman, P. (2005). Basic Emotions. In T. Dalgleish & M. Power (Hrsg.), *Handbook of Cognition and Emotion* (S. 45–60). John Wiley & Sons, Ltd. <https://doi.org/10.1002/0470013494.ch3>
- Ekman, P. & Friesen, W. V. (1971). Constants across cultures in the face and emotion. *Journal of personality and social psychology*, 17 (2), 124–129.
- Esuli, A. & Sebastiani, F. (2006). SentiWordNet: A publicly available lexical resource for opinion mining. In *In Proceedings of the 5th Conference on Language Resources and*

- Evaluation (LREC'06* (S. 417–422). Verfügbar unter SentiWordNet: A publicly available lexical resource for opinion mining
- Euler, H. (2000). Evolutionstheoretische Ansätze. In J. Otto, H. Euler & H. Mandl (Hrsg.), *Emotionspsychologie. Ein Handbuch* (S. 45–63). Weinheim: Beltz Psychologie Verlagsunion.
- Fariás, D. I. H., Patti, V. & Rosso, P. (2016). Irony Detection in Twitter. *ACM Transactions on Internet Technology*, 16 (3), 1–24. <https://doi.org/10.1145/2930663>
- Feinerer, I. (2017). *Introduction to the tm Package. Text Mining in R*. Zugriff am 26.06.2017. Verfügbar unter <http://cran.r-project.org/web/packages/tm/vignettes/tm.pdf>
- Fellbaum, C. (1999). Review of "WordNet. An Electronic Lexical Database" by Christiane Fellbaum. The MIT Press 1998. *Computational Linguistics*, 25 (2), 292–296. Verfügbar unter <http://dl.acm.org/citation.cfm?id=973306.973316>
- Feng, H., Golshan, H. M. & Mahoor, M. H. (2018). A wavelet-based approach to emotion classification using EDA signals. *Expert Syst. Appl.*, 112, 77–86. <https://doi.org/10.1016/j.eswa.2018.06.014>
- Feng, S., Wang, Y., Liu, L., Wang, D. & Yu, G. (2019). Attention based hierarchical LSTM network for context-aware microblog sentiment classification. *World Wide Web*, 22 (1), 59–81. <https://doi.org/10.1007/s11280-018-0529-6>
- Field, A. (2011). *Discovering statistics using SPSS. (and sex and drugs and rock 'n' roll)* (3. ed.). Los Angeles, Calif.: SAGE Publications.
- Finetti, B. d. (1974). *Theory of probability. A critical introductory treatment*.
- Fink, C., Chou, D., Kopecky, J. & Llorens, A. (2011). Coarse- and Fine-Grained Sentiment Analysis of Social Media Text. *Johns Hopkins APL Technical Digest*, 30 (1), 22–30.
- Forman, G. & Scholz, M. (2010). Apples-to-apples in Cross-validation Studies. Pitfalls in Classifier Performance Measurement. *SIGKDD Explor. Newsl.*, 12 (1), 49–57. <https://doi.org/10.1145/1882471.1882479>
- Fourati, N. & Pelachaud, C. (2018). Perception of Emotions and Body Movement in the Emilya Database. *IEEE Trans. Affective Computing*, 9 (1), 90–101. <https://doi.org/10.1109/TAFFC.2016.2591039>
- Fredrickson, B. & Levenson, R. (1998). Positive Emotions Speed Recovery from the Cardiovascular Sequelae of Negative Emotions. *Cognition & emotion*, 12 (2), 191–220. <https://doi.org/10.1080/026999398379718>
- Fredrickson, B., Mancuso, R., Branigan, C. & Tugade, M. (2000). The Undoing Effect of Positive Emotions. *Motivation and Emotion*, 24 (4), 237–258.
- Freitag, D., Blume, M., Byrnes, J., Chow, E., Kapadia, S., Rohwer, R. et al. (2005). New Experiments in Distributional Representations of Synonymy. In *Proceedings of the Ninth Conference on Computational Natural Language Learning (CONLL '05, S. 25–32)*.

- Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1706543.1706548>
- Frijda, N. (1986). *The emotions* (Studies in emotion and social interaction). Cambridge: Cambridge University Press.
- Frijda, N. (1994). Varieties of affect. Emotions and episodes, moods, and sentiments. In P. Ekman & R. Davidson (Hrsg.), *The nature of emotion. Fundamental questions* (Series in affective science, S. 59–67). New York: Oxford University Press.
- Frijda, N. (2007). Klaus Scherer's article on "What are emotions?" Comments. *Social Science Information*, 46 (3), 381–383. <https://doi.org/10.1177/0539018407079694>
- Frijda, N., Robinson, J. & Parrott, G. (2009). Ur-Emotions and Your Emotions. Reconceptualizing Basic Emotion. *Emotion review : journal of the International Society for Research on Emotion*, 2 (1), 14–21. <https://doi.org/10.1177/1754073909345547>
- Frijda, N. & Swagerman, J. (2008). Can computers feel? Theory and design of an emotional system. *Cognition and Emotion*, 1 (3), 235–257. <https://doi.org/10.1080/02699938708408050>
- Fukushima, K. (1980). Neocognitron. A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36 (4), 193–202. <https://doi.org/10.1007/BF00344251>
- Fukushima, K. (2013). Artificial vision by multi-layered neural networks. Neocognitron and its advances. *Neural networks : the official journal of the International Neural Network Society*, 37, 103–119. <https://doi.org/10.1016/j.neunet.2012.09.016>
- Gaeta, L. (Hrsg.). (2012). *Das Deutsche als kompositionsfreudige Sprache. Strukturelle Eigenschaften und systembezogene Aspekte* (Linguistik, Impulse & Tendenzen, Bd. 46). Berlin u.a.: De Gruyter.
- Gaeta, L. & Schlücker, B. (Hrsg.). (2012). *Das Deutsche als kompositionsfreudige Sprache. Strukturelle Eigenschaften und systembezogene Aspekte* (Linguistik, Impulse & Tendenzen, Bd. 46, 1. Aufl.). s.l.: Walter de Gruyter. <https://doi.org/10.1515/9783110278439>
- Gaind, B., Syal, V. & Padgalwar, S. (2019). Emotion Detection and Analysis on Social Media. *CoRR*, [abs/1901.08458](https://arxiv.org/abs/1901.08458).
- Galliker, M. (2009). *Psychologie der Gefühle und Bedürfnisse. Theorien, Erfahrungen, Kompetenzen* (Einführungen und Allgemeine Psychologie, 1. Aufl.). Stuttgart: Kohlhammer.
- Gaussier, E. & Goutte, C. (2005). Relation between PLSA and NMF and implications. In R. Baeza-Yates, N. Ziviani, G. Marchionini, A. Moffat & J. Tait (Hrsg.), *Proceedings of the 28th annual international ACM SIGIR conference on Research and development in information retrieval - SIGIR '05* (S. 601). New York, New York, USA: ACM.
- Gelman, A. (2004). *Bayesian data analysis* (Texts in statistical science, 2nd ed.). Boca Raton, Fla: Chapman & Hall.

- Geman, S. & Geman, D. (1984). Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. *IEEE Trans. Pattern Anal. Mach. Intell.*, 6 (6), 721–741.
- Gervasi, O., Franzoni, V., Riganelli, M. & Tasso, S. (2019). Automating facial emotion recognition. *Web Intelligence*, 17 (1), 17–27. <https://doi.org/10.3233/WEB-190397>
- Gibson, A. (2015). *Enum WeightInit*. Zugriff am 16.08.2017. Verfügbar unter <https://github.com/deeplearning4j/deeplearning4j/blob/master/deeplearning4j-nn/src/main/java/org/deeplearning4j/nn/weights/WeightInit.java>
- Gibson, A. (2018). *Class Evaluation*, Skymind. Zugriff am 22.07.2018. Verfügbar unter <https://deeplearning4j.org/doc/org/deeplearning4j/eval/Evaluation.html>
- Glorot, X. & Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. In Y. W. Teh & M. Titterton (Hrsg.), *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics* (Proceedings of Machine Learning Research, Bd. 9, S. 249–256). Chia Laguna Resort, Sardinia, Italy: PMLR. Verfügbar unter <http://proceedings.mlr.press/v9/glorot10a.html>
- Go, A., Bhayani, R. & Huang, L. (2009). Twitter Sentiment Classification using Distant Supervision. *Processing*, 1–6. Verfügbar unter <http://www.stanford.edu/~alecmgo/papers/Twitter-DistantSupervision09.pdf>
- Godbole, N., Srinivasaiah, M. & Skiena, S. (2007). Large-Scale Sentiment Analysis for News and Blogs. In *Proceedings of the International Conference on Weblogs and Social Media (ICWSM)*.
- Goldberg, Y. & Levy, O. (2014). word2vec Explained. Deriving Mikolov et al.'s negative-sampling word-embedding method. *CoRR*, *abs/1402.3722*.
- Golik, P., Doetsch, P. & Ney, H. (2013). Cross-entropy vs. squared error training. A theoretical and experimental comparison. In *INTERSPEECH*.
- González, J., Muñoz, A. & Martos, G. (2016). Asymmetric latent semantic indexing for gene expression experiments visualization. *J. Bioinformatics and Computational Biology*, 14 (4), 1–18. <https://doi.org/10.1142/S0219720016500232>
- Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep Learning*: MIT Press.
- Goodfellow, I., Warde-Farley, D., Mirza, M., Courville, A. & Bengio, Y. (2013). Maxout Networks. *ArXiv e-prints*.
- Gordon, S. L. (1981). The Sociology of Sentiments and Emotion. In M. Rosenberg & R. H. Turner (Hrsg.), *Social Psychology. Sociological Perspectives* (S. 562–592). Transaction Publishers.
- Goshvarpour, A., Abbasi, A. & Goshvarpour, A. (2017). Multi-aspects of emotional electrocardiogram classification in combination with musical stimuli and composite features. *I-JAPR*, 4 (1), 64–88. <https://doi.org/10.1504/IJAPR.2017.10003563>

- Gray, J. A. (1982). Précis of The neuropsychology of anxiety. An enquiry into the functions of the septo-hippocampal system. *Behavioral and Brain Sciences*, 5 (03), 469.  
<https://doi.org/10.1017/S0140525X00013066>
- Gray, J. A. (1990). Brain Systems that Mediate both Emotion and Cognition. *Cognition and Emotion*, 4 (3), 269–288. <https://doi.org/10.1080/02699939008410799>
- Gray, J. A. & MacNaughton, N. (2003). *The neuropsychology of anxiety. An enquiry into the functions of the septo-hippocampal system* (Oxford psychology series, vol. 33, 2nd ed.). Oxford: Oxford University Press.
- Greenwell, B. M., Boehmke, B. C. & McCarthy, A. J. (2018, 12. Mai). *A Simple and Effective Model-Based Variable Importance Measure*. Verfügbar unter <http://arxiv.org/pdf/1805.04755v1>
- Grekow, J. (2018). *From Content-based Music Emotion Recognition to Emotion Maps of Musical Pieces* (Studies in Computational Intelligence, Bd. 747): Springer.  
<https://doi.org/10.1007/978-3-319-70609-2>
- Griffiths, T., Thomas, S. & Mark. (2004). Finding scientific topics. *Proceedings of the National Academy of Sciences*, 101 (suppl\_1), 5228–5235.
- Gross, J. & Barrett, L. F. (2011). Emotion Generation and Emotion Regulation: One or Two Depends on Your Point of View. *Emotion Review*, 3 (1), 8–16.  
<https://doi.org/10.1177/1754073910380974>
- Grühn, D. (2016). An English Word Database of EMOTional TErms (EMOTE). *Psychological reports*, 119 (1), 290–308. <https://doi.org/10.1177/0033294116658474>
- Gui, L., Zhou, Y., Xu, R., He, Y. & Lu, Q. (2017). Learning representations from heterogeneous network for sentiment classification of product reviews. *Knowledge-Based Systems*, 124, 34–45. <https://doi.org/10.1016/j.knosys.2017.02.030>
- Gülçehre, Ç., Moczulski, M., Denil, M. & Bengio, Y. (2016). Noisy Activation Functions. *CoRR*, abs/1603.00391.
- Gundermann, S. (2001). *Wortwahl, Grammatik und Aussage. Eine strukturelle Analyse der Dramen Три сестры, Вишневый сад und Власть тьмы*. Universität Trier, Trier. Verfügbar unter [http://ubt.opus.hbz-nrw.de/volltexte/2004/286/pdf/003\\_Gundermann\\_Diss.pdf](http://ubt.opus.hbz-nrw.de/volltexte/2004/286/pdf/003_Gundermann_Diss.pdf)
- Hahn, U. & Buechel, S. (2017). EmoBank. Studying the Impact of Annotation Perspective and Representation Format on Dimensional Emotion Analysis. In *Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics, EACL 2017, Valencia, Spain, April 3-7, 2017, Volume 2: Short Papers* (S. 578–585).
- Hamada, M., Zaidan, B. B. & Zaidan, A. A. (2018). A Systematic Review for Human EEG Brain Signals Based Emotion Classification, Feature Extraction, Brain Condition, Group Comparison. *J. Medical Systems*, 42 (9), 162:1-162:25. <https://doi.org/10.1007/s10916-018-1020-8>

- Hambridge, S. (1995). *Netiquette Guidelines*. United States: RFC Editor.
- Hamdi, E., Rady, S. & Aref, M. (2018). A Convolutional Neural Network Model for Emotion Detection from Tweets. In *Proceedings of the International Conference on Advanced Intelligent Systems and Informatics, AISI 2018, Cairo, Egypt, September 3-5, 2018* (S. 337–346).
- Hamilton, W., Clark, K., Leskovec, J. & Jurafsky, D. (2016). Inducing Domain-Specific Sentiment Lexicons from Unlabeled Corpora. *Proceedings of the Conference on Empirical Methods in Natural Language Processing. Conference on Empirical Methods in Natural Language Processing, 2016*, 595–605. <https://doi.org/10.18653/v1/D16-1057>
- Hamp, B. & Feldweg, H. (1997). GermaNet - a Lexical-Semantic Net for German. In *Automatic Information Extraction and Building of Lexical Semantic Resources for NLP Applications* (S. 9–15). Verfügbar unter <http://www.aclweb.org/anthology/W97-0802>
- Han, J. & Kamber, M. (2006). *Data mining. Concepts and techniques* (The Morgan Kaufmann series in data management systems, 2nd ed.). Amsterdam: Elsevier; Morgan Kaufmann.
- Han, J. & Moraga, C. (1995). The influence of the sigmoid function parameters on the speed of backpropagation learning. In G. Goos, J. Hartmanis, J. Leeuwen, J. Mira & F. Sandoval (Hrsg.), *From Natural to Artificial Neural Computation* (Lecture Notes in Computer Science, Bd. 930, S. 195–201). Berlin, Heidelberg: Springer. [https://doi.org/10.1007/3-540-59497-3\\_175](https://doi.org/10.1007/3-540-59497-3_175)
- Han, K. M., Zin, T. & Tun, H. M. (2016). Extraction Of Audio Features For Emotion Recognition System Based On Music. In *International Journal of Scientific & Technology Research* (Volume 5, Issue 06, S. 53–56).
- Han, K., Yu, D. & Tashev, I. *Speech Emotion Recognition Using Deep Neural Network and Extreme Learning Machine*. Verfügbar unter <https://www.microsoft.com/en-us/research/publication/speech-emotion-recognition-using-deep-neural-network-and-extreme-learning-machine/>
- Hanseatisches Oberlandesgericht Hamburg. (2006). Störerhaftung des Betreibers eines Internetforums für im Forum eingestellte Beiträge mit rechtsverletzendem Inhalt. *JurPC* (98), 2. Urteil vom 22.08.2006. <https://doi.org/10.7328/jurpcb/200621996>
- Hao, S., Xu, Y., Peng, H., Su, K. & Ke, D. (2014). Automated Chinese Essay Scoring from Topic Perspective Using Regularized Latent Semantic Indexing. In *2014 22nd International Conference on Pattern Recognition* (S. 3092–3097). IEEE.
- Hao, Z., Cai, R., Yang, Y., Wen, W. & Liang, L. (2017). A Dynamic Conditional Random Field Based Framework for Sentence-Level Sentiment Analysis of Chinese Microblog. In *IEEE International Conference on Computational Science and Engineering* (S. 135–142). Verfügbar unter <http://doi.ieeecomputersociety.org/10.1109/CSE-EUC.2017.33>

- Harispe, S., Ranwez, S., Janaqi, S. & Montmain, J. (2013). Semantic Measures for the Comparison of Units of Language, Concepts or Entities from Text and Knowledge Base Analysis. *CoRR*, *abs/1310.1285*.
- Harispe, S., Ranwez, S., Janaqi, S. & Montmain, J. (2015). Semantic Similarity from Natural Language and Ontology Analysis. *Synthesis Lectures on Human Language Technologies*, 8 (1), 1–254. <https://doi.org/10.2200/S00639ED1V01Y201504HLT027>
- Hartung, M. (1998). *Ironie in der Alltagssprache. Eine gesprächsanalytische Untersuchung*.
- Hatzivassiloglou, V. & McKeown, K. (1997). Predicting the semantic orientation of adjectives. In P. Cohen & W. Wahlster (Hrsg.), *the eighth conference* (S. 174–181).
- Hatzivassiloglou, V. & Wiebe, J. (2000). Effects of adjective orientation and gradability on sentence subjectivity, 299–305. <https://doi.org/10.3115/990820.990864>
- Häusel, H.-G. (2010). *Die wissenschaftliche Fundierung des Limbic® Ansatzes*. Zugriff am 15.03.2014. Verfügbar unter [http://www.nymphenburg.de/tl\\_files/pdf/LimbicScience101120.pdf](http://www.nymphenburg.de/tl_files/pdf/LimbicScience101120.pdf)
- Haynes, W. (2013). Bonferroni Correction. In W. Dubitzky, O. Wolkenhauer, K.-H. Cho & H. Yokota (Hrsg.), *Encyclopedia of Systems Biology* (S. 154). New York, NY: Springer. [https://doi.org/10.1007/978-1-4419-9863-7\\_1213](https://doi.org/10.1007/978-1-4419-9863-7_1213)
- He, K., Zhang, X., Ren, S. & Sun, J. (2014). Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition. *CoRR*, *abs/1406.4729*.
- He, K., Zhang, X., Ren, S. & Sun, J. (2015a). Deep Residual Learning for Image Recognition. *CoRR*, *abs/1512.03385*.
- He, K., Zhang, X., Ren, S. & Sun, J. (2015b). Delving Deep into Rectifiers. Surpassing Human-Level Performance on ImageNet Classification. *CoRR*, *abs/1502.01852*.
- Heaton, J. (2013). *Deep learning and neural networks* (Artificial intelligence for humans, Bd. 3). St. Louis, MO: Heaton Research Inc.
- Heck, F. (2007). *Morphologie. Komposition*, Universität Leipzig. Zugriff am 20.05.2016. Verfügbar unter <http://home.uni-leipzig.de/heck/morph07/webkomp.pdf>
- Heise, D. (1977). The Semantic Differential and Attitude Research. In G. Summers (Ed.), *Attitude measurement* (pp. 235–253). London: Kershaw.
- Helbig, G. & Albrecht, H. (1993). *Die Negation* (Zur Theorie und Praxis des Deutschunterrichts für Ausländer, 6. Aufl.). Leipzig: Langenscheidt, Verl. Enzyklopädie.
- Henrich, J., Heine, S. & Norenzayan, A. (2010). The weirdest people in the world? *Behavioral and Brain Sciences*, 33 (2-3), 61-83; discussion 83-135. <https://doi.org/10.1017/S0140525X0999152X>
- Henrich, V. & Hinrichs, E. (2010). GernEdiT - The GermaNet Editing Tool. In *In Proceedings of the ACL 2010 System Demonstrations* .

- Hewson, C., Vogel, C. & Laurent, D. (2016). *Internet research methods* (2. ed.). Los Angeles: SAGE Publications.
- Hinton, G., Srivastava, N. & Swersky, K. (2016). *Overview of mini-batch gradient descent*. Zugriff am 14.08.2017. Verfügbar unter [http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture\\_slides\\_lec6.pdf](http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture_slides_lec6.pdf)
- Ho, T. K. (1995). Random decision forests. In *Proceedings of 3rd International Conference on Document Analysis and Recognition* (S. 278–282). IEEE Comput. Soc. Press.
- Hobbs, J. & Gordon, A. (2011). The Deep Lexical Semantics of Emotions. In K. Ahmad (Ed.), *Affective Computing and Sentiment Analysis. Emotion, Metaphor and Terminology ; [Workshop on Emotion, Metaphor, Ontology, and Terminology (EMOT) in August 2008 ... Selected papers from the Workshop]* (Text, Speech and Language Technology, vol. 45, pp. 27–34). Dordrecht: Springer.
- Hochschild, A. R. (1979). Emotion Work, Feeling Rules, and Social Structure. *American Journal of Sociology*, 85 (3), 551–575. Verfügbar unter <http://www.jstor.org/stable/2778583>
- Hoffman, M. (1982). Development of prosocial motivation. Empathy and guilt. In N. Eisenberg (Hrsg.), *The development of prosocial behavior* (Developmental Psychology, United Kingdom edition, S. 281–313). New York, New York: Academic Press.
- Hofmann, T. (1999a). Probabilistic Latent Semantic Analysis. In *Proceedings of the Fifteenth Conference on Uncertainty in Artificial Intelligence (UAI'99, S. 289–296)*. San Francisco, CA, USA: Morgan Kaufmann. Verfügbar unter <http://dl.acm.org/citation.cfm?id=2073796.2073829>
- Hofmann, T. (1999b). Probabilistic Latent Semantic Indexing. In *Proceedings of the 22nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR '99, S. 50–57)*. New York, NY, USA: ACM. Verfügbar unter <http://doi.acm.org/10.1145/312624.312649>
- Hogenboom, A., Bal, D., Frasinca, F., Bal, M., Jong, F. de & Kaymak, U. (2013). Exploiting Emoticons in Sentiment Analysis. In *Proceedings of the 28th Annual ACM Symposium on Applied Computing (SAC '13, S. 703–710)*. New York, NY, USA: ACM. Verfügbar unter <http://doi.acm.org/10.1145/2480362.2480498>
- Hogenboom, A., van Iterson, P., Heerschop, B., Frasinca, F. & Kaymak, U. (2011). Determining negation scope and strength in sentiment analysis. In *IEEE International Conference on Systems, Man, and Cybernetics* (S. 2589–2594).
- Höhle, B. (2010). *Psycholinguistik* (Akademie Studienbücher - Sprachwissenschaft). München: Oldenbourg Akademieverlag.
- Hu, M. & Liu, B. (2004). Mining and Summarizing Customer Reviews. In *Proceedings of the 10th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*

- (KDD '04, S. 168–177). New York, NY, USA: ACM. Verfügbar unter <http://doi.acm.org/10.1145/1014052.1014073>
- Hu, X. & Liu, H. (2012). Text Analytics in Social Media. In C. Aggarwal & C. Zhai (Hrsg.), *Mining Text Data* (S. 385–414). Springer. [https://doi.org/10.1007/978-1-4614-3223-4\\_12](https://doi.org/10.1007/978-1-4614-3223-4_12)
- Huang, A. (2008). Similarity measures for text document clustering.
- Huang, F. & Yates, A. (2009). Distributional Representations for Handling Sparsity in Supervised Sequence-Labeling. In *Proceedings of the Joint Conference of the 47th Annual Meeting of the ACL and the 4th International Joint Conference on Natural Language Processing of the AFNLP* (S. 495–503). Suntec, Singapore: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/P09-1056>
- Hubel, D. H. & Wiesel, T. N. (1959). Receptive fields of single neurones in the cat's striate cortex. *The Journal of Physiology*, 148 (3), 574–591.
- Hubel, D. H. & Wiesel, T. N. (1962). Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. *The Journal of Physiology*, 160 (1), 106-154.2.
- Hupka, R. & Otto, J. (2000). Neid und Eifersucht. In J. Otto, H. Euler & H. Mandl (Hrsg.), *Emotionspsychologie. Ein Handbuch* (S. 272–283). Weinheim: Beltz Psychologie Verlagsunion.
- Hurtado-de-Mendoza, A., Molina, C. & Fernández-Dols, J.-M. (2012). The Archeology of Emotion Concepts. *Journal of Language and Social Psychology*, 32 (3), 272–290. <https://doi.org/10.1177/0261927X12465610>
- Hwang, K. & Sung, W. (2016). Character-level incremental speech recognition with recurrent neural networks. In *2016 IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP 2016, Shanghai, China, March 20-25, 2016* (S. 5335–5339).
- Hwang, K. & Sung, W. (2017). Character-level language modeling with hierarchical recurrent neural networks. In *2017 IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP 2017, New Orleans, LA, USA, March 5-9, 2017* (S. 5720–5724).
- Imhasly, B., Marfurt, B. & Portmann, P. (1982). *Konzepte der Linguistik. Eine Einführung* (Studienbücher zur Linguistik und Literaturwissenschaft, Bd. 9, 2., unveränd. Aufl.). Wiesbaden: Athenaion.
- Ioffe, S. & Szegedy, C. (2015). Batch Normalization. Accelerating Deep Network Training by Reducing Internal Covariate Shift. *CoRR*, [abs/1502.03167](https://arxiv.org/abs/1502.03167).
- Ivanova, S. & Kuebler, S. POS Tagging for German: how important is the Right Context?. Verfügbar unter <http://dblp.uni-trier.de/db/conf/lrec/lrec2008.html#IvanovaK08>
- Izard, C. E. (1982). *The face of emotion* (Century psychology series). New York: Irvington.
- Izard, C. E. (1990). Emotion-cognition relationships and human development. In C. E. Izard, J. Kagan & R. Zajonc (Eds.), *Emotions, cognition, and behavior* (pp. 17–37). Cambridge: Cambridge University Press.

- Izard, C. E. (1991). *The psychology of emotions* (Emotions, personality, and psychotherapy). New York, NY: Plenum Press.
- Izard, C. E. (1993). *The Differential Emotions Scale. DES IV-A; [a Method of Measuring the Meaning of Subjective Experience of Discrete Emotions]*: University of Delaware.
- Izard, C. E. (1994). *Die Emotionen des Menschen. Eine Einführung in die Grundlagen der Emotionspsychologie* (3. Aufl.). Weinheim: Beltz Psychologie Verlagsunion.
- Jacob-Dazarola, R., Ortíz Nicolás, J. C. & Cárdenas Bayona, L. (2016). Behavioral Measures of Emotion. In H. Meiselman (Ed.), *Emotion measurement* (pp. 101–118). Duxford: Woodhead Publishing.
- Jahr, S. (2000). *Emotionen und Emotionsstrukturen in Sachtexten. Ein interdisziplinärer Ansatz zur qualitativen und quantitativen Beschreibung der Emotionalität von Texten*. Berlin: De Gruyter.
- Jakobovits, L. (1966). Comparative Psycholinguistics in the Study of Cultures. *International Journal of Psychology*, 1 (1), 15–37. <https://doi.org/10.1080/00207596608247042>
- James, W. (1884). What is an Emotion? *Mind*, 9 (34), 188–205.
- Jarrett, K., Kavukcuoglu, K., Ranzato, M.' A. & LeCun, Y. (2009). What is the best multi-stage architecture for object recognition? In *2009 IEEE 12th International Conference on Computer Vision* (S. 2146–2153). IEEE.
- Jimeno-Yepes, A., Jiménez-Ruiz, E., Berlanga Llavori, R. & Rebholz-Schuhmann, D. (2009). Reuse of terminological resources for efficient ontological engineering in Life Sciences. *BMC Bioinformatics*, 10 (S-10), 4. <https://doi.org/10.1186/1471-2105-10-S10-S4>
- Jo, Y. & Oh, A. (2011). Aspect and sentiment unification model for online review analysis. In I. King, W. Nejdl & H. Li (Hrsg.), *the fourth ACM international conference* (S. 815).
- Johnson-Laird, P. (1993). *Human and Machine Thinking*. Hillsdale, NJ, USA: Lawrence Erlbaum Associates.
- Joulin, A., Grave, E., Bojanowski, P. & Mikolov, T. (2016). Bag of Tricks for Efficient Text Classification. *CoRR*, [abs/1607.01759](https://arxiv.org/abs/1607.01759).
- Jurafsky, D. & Martin, J. (2017). *Speech and Language Processing* (3. Aufl.). Upper Saddle River, NJ, USA: Prentice Hall.
- Kagal, L. (2002). *Rei. A Policy Language for the Me-Centric Project*. HP Labs.
- Kalchbrenner, N., Grefenstette, E. & Blunsom, P. (2014). A Convolutional Neural Network for Modelling Sentences. *CoRR*, [abs/1404.2188](https://arxiv.org/abs/1404.2188).
- Kamps, J., Marx, M., Mokken, R. & Rijke, M. de. (2004). Using WordNet to measure semantic orientation of adjectives. In *LREC*.
- Kanayama, H. & Nasukawa, T. (2006). Fully Automatic Lexicon Expansion for Domain-oriented Sentiment Analysis. In *Proceedings of the 2006 Conference on Empirical Methods in Natural Language Processing* (EMNLP '06, S. 355–363). Stroudsburg, PA, USA:

- Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1610075.1610125>
- Kang, G., Li, J. & Tao, D. (2016). *Shakeout. A New Regularized Deep Neural Network Training Scheme*. Verfügbar unter <https://www.aaai.org/ocs/index.php/AAAI/AAAI16/paper/view/11840>
- Kann, K. & Schütze, H. (2017). Unlabeled Data for Morphological Generation With Character-Based Sequence-to-Sequence Models. *CoRR*, *abs/1705.06106*.
- Katsigiannis, S. & Ramzan, N. (2018). DREAMER: A Database for Emotion Recognition Through EEG and ECG Signals From Wireless Low-cost Off-the-Shelf Devices. *IEEE J. Biomedical and Health Informatics*, *22* (1), 98–107. <https://doi.org/10.1109/JBHI.2017.2688239>
- Kaur, J. & Jatinderkumar, S. (2014). Emotion Detection and Sentiment Analysis in Text Corpus. A Differential Study with Informal and Formal Writing Styles. *International Journal of Computer Applications*, *101* (9), 1–9. <https://doi.org/10.5120/17712-8078>
- Kaya, H. & Karpov, A. A. (2018). Efficient and effective strategies for cross-corpus acoustic emotion recognition. *Neurocomputing*, *275*, 1028–1034. <https://doi.org/10.1016/j.neucom.2017.09.049>
- Kenett, R. & Raanan, Y. (Hrsg.). (2010). *Operational Risk Management*. Chichester, UK: John Wiley & Sons, Ltd. <https://doi.org/10.1002/9780470972571>
- Kennedy, A. & Inkpen, D. (2006). Sentiment Classification of Movie Reviews Using Contextual Valence Shifters. *Computational Intelligence*, *22* (2), 110–125. <https://doi.org/10.1111/j.1467-8640.2006.00277.x>
- Khan, G., Siddiqi, A., Khan, M. U. G., Wahla, S. Q. & Samyan, S. (2019). Geometric positions and optical flow based emotion detection using MLP and reduced dimensions. *IET Image Processing*, *13* (4), 634–643. <https://doi.org/10.1049/iet-ipr.2018.5728>
- Khanpour, H. & Caragea, C. (2018). Fine-Grained Emotion Detection in Health-Related Online Posts. In *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing* (S. 1160–1166). Verfügbar unter <https://aclanthology.info/papers/D18-1147/d18-1147>
- Kiela, D., Hill, F. & Clark, S. (2015). Specializing Word Embeddings for Similarity or Relatedness. In L. Màrquez, C. Callison-Burch & J. Su (Hrsg.), *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing* (S. 2044–2048). Stroudsburg, PA, USA: Association for Computational Linguistics.
- Kim, D. & Oh, A. (2011). Topic chains for understanding a news corpus. In *Proceedings of the 12th international conference on Computational linguistics and intelligent text processing - Volume Part II* (CICLing'11, S. 163–176). Berlin, Heidelberg: Springer.

- Kim, S.-M. & Hovy, E. (2006a). Extracting Opinions, Opinion Holders, and Topics Expressed in Online News Media Text. In *Proceedings of the Workshop on Sentiment and Subjectivity in Text* (SST '06, S. 1–8). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1654641.1654642>
- Kim, S.-M. & Hovy, E. (2006b). Identifying and Analyzing Judgment Opinions. In *Proceedings of the Main Conference on Human Language Technology Conference of the North American Chapter of the Association of Computational Linguistics* (HLT-NAACL '06, S. 200–207). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dx.doi.org/10.3115/1220835.1220861>
- Kim, Y. (2014). Convolutional Neural Networks for Sentence Classification. *ArXiv e-prints*.
- Kim, Y., Jernite, Y., Sontag, D. & Rush, A. (2015). Character-Aware Neural Language Models. *CoRR*, *abs/1508.06615*.
- Kim, Y. & Lee, H. (2018). DMCB at SemEval-2018 Task 1. Transfer Learning of Sentiment Classification Using Group LSTM for Emotion Intensity prediction. In *Proceedings of The 12th International Workshop on Semantic Evaluation* (S. 300–304). Verfügbar unter <https://aclanthology.info/papers/S18-1044/s18-1044>
- Kingma, D. & Ba, J. (2014). Adam. A Method for Stochastic Optimization. *CoRR*, *abs/1412.6980*.
- Kiritchenko, S., Zhu, X., Cherry, C. & Mohammad, S. (2014). NRC-Canada-2014. Detecting Aspects and Sentiment in Customer Reviews. In *Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014)* (S. 437–442). Dublin, Ireland: Association for Computational Linguistics and Dublin City University. Verfügbar unter <http://www.aclweb.org/anthology/S14-2076>
- Klein, A., Altuntas, O., Riekert, M., Dinev, V., Grcar, M., Sluban, B. et al. (2012). *D4.2 Semantic information extraction components, addressing noise and uncertainty*. Zugriff am 15.08.2014. Verfügbar unter [http://project-first.eu/sites/project-first.eu/files/content-uploads/http://project-first.eu/sites/project-first.eu/files/content-uploads/publications/FIRST\\_D4\\_2\\_Semantic\\_Information\\_Extraction\\_Components\\_Addressing\\_Noise\\_and\\_Uncertainty\\_v1.0.pdf](http://project-first.eu/sites/project-first.eu/files/content-uploads/http://project-first.eu/sites/project-first.eu/files/content-uploads/publications/FIRST_D4_2_Semantic_Information_Extraction_Components_Addressing_Noise_and_Uncertainty_v1.0.pdf)
- Klein, A., Dinev, V., Altuntas, O., Riekert, M., Gredel, L. & Kralj Novak, P. (2013). *D4.3 Large-scale Semantic Information Extraction Components*. Zugriff am 25.07.2014. Verfügbar unter [http://project-first.eu/sites/project-first.eu/files/content-uploads/publications/FIRST\\_D4.3\\_Large-scale\\_semantic\\_information\\_extraction\\_components\\_v1.0.pdf](http://project-first.eu/sites/project-first.eu/files/content-uploads/publications/FIRST_D4.3_Large-scale_semantic_information_extraction_components_v1.0.pdf)
- Kleinginna, P. & Kleinginna, A. (1981). A categorized list of motivation definitions, with a suggestion for a consensual definition. *Motivation and Emotion*, 5 (3), 263–291. <https://doi.org/10.1007/BF00993889>

- Kline, D. & Berardi, V. (2005). Revisiting squared-error and cross-entropy functions for training neural network classifiers. *Neural Computing & Applications*, 14 (4), 310–318. <https://doi.org/10.1007/s00521-005-0467-y>
- Klinger, R. & Tomanek, K. (2007). *Classical Probabilistic Models and Conditional Random Fields*.
- Ko, B. (2018). A Brief Review of Facial Emotion Recognition Based on Visual Information. *Sensors*, 18 (2), 401. <https://doi.org/10.3390/s18020401>
- Koller, D. & Sahami, M. (1996). Toward Optimal Feature Selection. In *Proceedings of the Thirteenth International Conference on International Conference on Machine Learning (ICML '96, S. 284–292)*. San Francisco, CA, USA: Morgan Kaufmann. Verfügbar unter <http://dl.acm.org/citation.cfm?id=3091696.3091731>
- Kraut, R. & Johnston, R. (1979). Social and emotional messages of smiling. An ethological approach. *Journal of personality and social psychology* (37), 1539–1553.
- Kreibig, S., Wilhelm, F., Roth, W. & Gross, J. (2007). Cardiovascular, electrodermal, and respiratory response patterns to fear- and sadness-inducing films. *Psychophysiology*, 44 (5), 787–806. <https://doi.org/10.1111/j.1469-8986.2007.00550.x>
- Krishnan, V. & Ganapathy, V. (2005). Named Entity Recognition.
- Krizhevsky, A., Sutskever, I. & Hinton, G. (2012). ImageNet Classification with Deep Convolutional Neural Networks. In F. Pereira, C. J. C. Burges, L. Bottou & K. Q. Weinberger (Hrsg.), *Advances in Neural Information Processing Systems 25* (S. 1097–1105). Curran Associates Inc. Verfügbar unter <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>
- Kruskal, W. & Wallis, W. A. (1952). Use of Ranks in One-Criterion Variance Analysis. *Journal of the American Statistical Association*, 47 (260), 583. <https://doi.org/10.2307/2280779>
- Kumar, N. & Shivakumar, G. (2018). A Real Time Human Emotion Recognition System Using Respiration Parameters and ECG. In *Intelligent Human Computer Interaction* (S. 36–45).
- Kunkel-Razum, K. & Eisenberg, P. (2009). *Der Duden. Die Grammatik* (Bd. 4, 8., überarb. Aufl., 12 Bände). Mannheim: Dudenverlag.
- Lapponi, E., Read, J. & Øvrelid, L. (2012). Representing and Resolving Negation for Sentiment Analysis. In *Data Mining Workshops (ICDMW), 2012 IEEE 12th International Conference on* (S. 687–692).
- Lazarus, R. (1984). On the primacy of cognition. *American Psychologist*, 39 (2), 124–129. <https://doi.org/10.1037//0003-066X.39.2.124>
- Lazarus, R. (1994). *Emotion and Adaptation*. Oxford: Oxford University Press.

- Lazarus, R. (2001). Relational Meaning and discrete Emotions. In K. Scherer, A. Schorr & T. Johnstone (Eds.), *Appraisal processes in emotion. Theory, methods, research* (Series in affective science, pp. 37–67). Oxford: Oxford University Press.
- Lazebnik, S., Schmid, C. & Ponce, J. (2006). Beyond Bags of Features. Spatial Pyramid Matching for Recognizing Natural Scene Categories. In *Computer Society Conference on Computer Vision and Pattern Recognition - Volume 2 (CVPR'06)* (S. 2169–2178). IEEE.
- Le, Q. & Mikolov, T. (2014). Distributed Representations of Sentences and Documents. *CoRR*, *abs/1405.4053*.
- Le, Q., Ngiam, J., Coates, A., Lahiri, A., Prochnow, B. & Ng, A. (2011). On Optimization Methods for Deep Learning. In *Proceedings of the 28th International Conference on International Conference on Machine Learning (ICML '11)*, S. 265–272). USA: Omnipress. Verfügbar unter <http://dl.acm.org/citation.cfm?id=3104482.3104516>
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning, *521* (7553), 436–444. <https://doi.org/10.1038/nature14539>
- LeCun, Y., Boser, B., Denker, J., Henderson, D., Howard, R. E., Hubbard, W. et al. (1989). Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Comput*, *1* (4), 541–551. <https://doi.org/10.1162/neco.1989.1.4.541>
- LeCun, Y., Boser, B., Denker, J., Henderson, D., Howard, R. E., Hubbard, W. et al. (1990). Handwritten Digit Recognition with a Back-Propagation Network. In D. S. Touretzky (Hrsg.), *Advances in Neural Information Processing Systems 2* (S. 396–404). Morgan Kaufmann. Verfügbar unter <http://papers.nips.cc/paper/293-handwritten-digit-recognition-with-a-back-propagation-network.pdf>
- LeCun, Y., Bottou, L., Bengio, Y. & Haffner, P. (1998a). Gradient-based learning applied to document recognition. In *Proceedings of the IEEE* (S. 2278–2324).
- LeCun, Y., Bottou, L., Orr, G. & Müller, K.-R. (1998b). Efficient BackProp. In G. Orr & K.-R. Müller (Hrsg.), *Neural Networks: Tricks of the Trade* (S. 9–50). Berlin, Heidelberg: Springer. [https://doi.org/10.1007/3-540-49430-8\\_2](https://doi.org/10.1007/3-540-49430-8_2)
- Lee, D. & Seung, S. (1999). Learning the parts of objects by non-negative matrix factorization, *401* (6755), 788–791. <https://doi.org/10.1038/44565>
- Lee, D. & Seung, S. (2001). Algorithms for Non-negative Matrix Factorization. In T. K. Leen, T. G. Dietterich & V. Tresp (Hrsg.), *Advances in Neural Information Processing Systems 13* (S. 556–562). MIT Press. Verfügbar unter <http://papers.nips.cc/paper/1861-algorithms-for-non-negative-matrix-factorization.pdf>
- Lee, J., Recht, B., Salakhutdinov, R., Srebro, N. & Tropp, J. (2010). Practical Large-scale Optimization for Max-norm Regularization. In *Proceedings of the 23rd International Conference on Neural Information Processing Systems (NIPS'10)*, S. 1297–1305). USA: Curran Associates Inc. Verfügbar unter <http://dl.acm.org/citation.cfm?id=2997189.2997334>

- Lee, J. & Tashev, I. (2015). High-level Feature Representation using Recurrent Neural Network for Speech Emotion Recognition. In *Interspeech 2015*. ISCA - International Speech Communication Association. Verfügbar unter <https://www.microsoft.com/en-us/research/publication/high-level-feature-representation-using-recurrent-neural-network-for-speech-emotion-recognition/>
- Lee, M. (2004). *Stanford Manual Annotation Tool*, Stanford University. Zugriff am 16.05.2017. Verfügbar unter <http://nlp.stanford.edu/software/stanford-manual-annotation-tool-2004-05-16.tar.gz>
- Legerstee, M. T. & Hart, S. (Eds.). (2010). *Handbook of jealousy. Theory, research, and multidisciplinary approaches*. Chichester, West Sussex: Wiley-Blackwell.
- Leibold, C., Krieger, H.-U. & Spies, M. (2010). Ontology-Based Modelling and Reasoning in Operational Risks. In R. Kenett & Y. Raanan (Hrsg.), *Operational Risk Management* (S. 39–59). Chichester, UK: John Wiley & Sons, Ltd.
- Lerot, J. (1972). Zum Aufbau einer wissenschaftlich-pädagogischen Grammatik für den Fremdsprachenunterricht. In H. Moser (Hrsg.), *Neue Grammatiktheorien und ihre Anwendung auf das heutige Deutsch*.
- Levenson, R. (2011). Basic Emotion Questions. *Emotion review : journal of the International Society for Research on Emotion*, 3 (4), 379–386.  
<https://doi.org/10.1177/1754073911410743>
- Levy, O. & Goldberg, Y. (2014a). Dependency-Based Word Embeddings. In *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers)* (S. 302–308). Baltimore, Maryland: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/P14-2050>
- Levy, O. & Goldberg, Y. (2014b). Neural Word Embedding as Implicit Matrix Factorization. In Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence & K. Q. Weinberger (Hrsg.), *Advances in Neural Information Processing Systems 27* (S. 2177–2185). Curran Associates Inc. Verfügbar unter <http://papers.nips.cc/paper/5477-neural-word-embedding-as-implicit-matrix-factorization.pdf>
- Levy, O., Goldberg, Y. & Dagan, I. (2015). Improving Distributional Similarity with Lessons Learned from Word Embeddings. *TACL*, 3, 211–225. Verfügbar unter <https://tacl2013.cs.columbia.edu/ojs/index.php/tacl/article/view/570>
- Li, F., Huang, M. & Zhu, X. (2010). Sentiment Analysis with Global Topics and Local Dependency. In *Proceedings of the 24th AAAI Conference on Artificial Intelligence*. AAAI Press. Verfügbar unter <http://dblp.uni-trier.de/db/conf/aaai/aaai2010.html#LiHZ10>
- Li, Y. & Liu, F. (2016). Whiteout. Gaussian Adaptive Noise Regularization in FeedForward Neural Networks. *ArXiv e-prints*.

- Liang, J., Liu, P., Jianlong, T. & Bai, S. (2014). Sentiment Classification Based on AS-LDA Model. *Procedia Computer Science*, 31 (0), 511–516.  
<https://doi.org/10.1016/j.procs.2014.05.296>
- Liew, J. S. Y., Turtle, H. & Liddy, E. (2016). EmoTweet-28. A Fine-Grained Emotion Corpus for Sentiment Analysis. In N. Calzolari, K. Choukri, T. Declerck, S. Goggi, M. Grobelnik, B. Maegaard et al. (Hrsg.), *Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC 2016)*. Paris, France: European Language Resources Association (ELRA).
- Lin, C. & He, Y. (2009). Joint Sentiment/Topic Model for Sentiment Analysis. In *Proceedings of the 18th ACM Conference on Information and Knowledge Management (CIKM '09*, S. 375–384). New York, NY, USA: ACM. Verfügbar unter <http://doi.acm.org/10.1145/1645953.1646003>
- Lin, C., He, Y. & Everson, R. (2011). Sentence subjectivity detection with weakly-supervised learning. In *Proceedings of the 5th International Joint Conference on Natural Language Processing* (S. 1153–1161). Verfügbar unter <http://oro.open.ac.uk/29609/>
- Lin, C., He, Y., Everson, R. & Ruger, S. (2012). Weakly Supervised Joint Sentiment-Topic Detection from Text. *Knowledge and Data Engineering, IEEE Transactions on*, 24 (6), 1134–1145. <https://doi.org/10.1109/TKDE.2011.48>
- Lindquist, K. (2017). The role of language in emotion. Existing evidence and future directions. *Current opinion in psychology*, 17, 135–139. <https://doi.org/10.1016/j.copsyc.2017.07.006>
- Lindquist, K., MacCormack, J. & Shablack, H. (2015). The role of language in emotion: predictions from psychological constructionism. *Frontiers in psychology*, 6, 444.  
<https://doi.org/10.3389/fpsyg.2015.00444>
- Liu, B. (Hrsg.). (2011). *Web Data Mining*. Berlin, Heidelberg: Springer.
- Liu, B. (2012). *Sentiment analysis and opinion mining* (Synthesis lectures on human language technologies). San Rafael, Calif.: Morgan & Claypool.
- Liu, B. (2015a). The Problem of Sentiment Analysis. In B. Liu (Hrsg.), *Sentiment Analysis* (S. 16–46). Cambridge: Cambridge University Press.  
<https://doi.org/10.1017/CBO9781139084789.003>
- Liu, B. (2015b). *Sentiment analysis. Mining opinions, sentiments, and emotions*. Cambridge: Cambridge University Press.
- Liu, B. (2015c). Sentiment Lexicon Generation. In B. Liu (Hrsg.), *Sentiment Analysis* (S. 189–201). Cambridge: Cambridge University Press.  
<https://doi.org/10.1017/CBO9781139084789.008>

- Liu, B., Dai, Y., Li, X., Lee, W. S. & Yu, P. (2003). Building text classifiers using positive and unlabeled examples. In *Third IEEE International Conference on Data Mining* (S. 179–186). IEEE Comput. Soc.
- Liu, B., Hu, M. & Cheng, J. (2005). Opinion Observer: Analyzing and Comparing Opinions on the Web. In *Proceedings of the 14th International Conference on World Wide Web* (WWW '05, S. 342–351). New York, NY, USA: ACM. Verfügbar unter <http://doi.acm.org/10.1145/1060745.1060797>
- Liu, B. & Menczer, F. (2011). Web Crawling. In B. Liu (Hrsg.), *Web Data Mining* (S. 311–362). Berlin, Heidelberg: Springer.
- Liu, B. & Zhang, L. (2012). A survey of opinion mining and sentiment analysis. *Mining Text Data*, 415–463. Verfügbar unter [http://scholar.google.de/scholar.bib?q=info:CEE7xsbkW6cJ:scholar.google.com/&output=citation&hl=de&as\\_sdt=0&as\\_ylo=2012&ct=citation&cd=1](http://scholar.google.de/scholar.bib?q=info:CEE7xsbkW6cJ:scholar.google.com/&output=citation&hl=de&as_sdt=0&as_ylo=2012&ct=citation&cd=1)
- Liu, K.-L., Li, W.-J. L. & Guo, M. (2012). Emoticon Smoothed Language Models for Twitter Sentiment Analysis. In *Proceedings of AACL* (S. 1).
- Liu, N., Fang, Y., Li, L., Hou, L., Yang, F. & Guo, Y. (2018). Multiple Feature Fusion for Automatic Emotion Recognition Using EEG Signals. In *IEEE International Conference on Acoustics, Speech and Signal Processing* (S. 896–900).
- Lopez, S. (Ed.). (2009). *Encyclopedia of positive psychology*. Malden, MA: Wiley-Blackwell. <https://doi.org/10.1002/9781444306002>
- Lövheim, H. (2012). A new three-dimensional model for emotions and monoamine neurotransmitters. *Medical hypotheses*, 78 (2), 341–348. <https://doi.org/10.1016/j.mehy.2011.11.016>
- Lu, B., Ott, M., Cardie, C. & Tsou, B. (2011). Multi-aspect Sentiment Analysis with Topic Models. In *11th International Conference on Data Mining Workshops* (S. 81–88). IEEE.
- Lu, Y. & Zhai, C. (2008). Opinion integration through semi-supervised topic modeling. In J. Huai, R. Chen, H.-W. Hon, Y. Liu, W.-Y. Ma, A. Tomkins et al. (Hrsg.), *Proceeding of the 17th international conference* (S. 121).
- Lv, C., Li, S. & Huang, L. (2018). Music Emotions Recognition Based on Feature Analysis. In *11th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics, CISP-BMEI 2018, Beijing, China, October 13-15, 2018* (S. 1–5).
- Maas, A., Ng, A. & Potts, C. (2011). *Multi-Dimensional Sentiment Analysis with Learned Representations*, Stanford University. Zugriff am 09.08.2014. Verfügbar unter <http://ai.stanford.edu/~amaas/papers/multisent-techreport-2011.pdf>
- Majumder, N., Poria, S., Hazarika, D., Mihalcea, R., Gelbukh, A. F. & Cambria, E. (2018). DialogueRNN: An Attentive RNN for Emotion Detection in Conversations. *CoRR*, *abs/1811.00405*.

- Maks, I. & Vossen, P. (2010). Modeling attitude, polarity and subjectivity in Wordnet. In *Proceedings of Fifth Global Wordnet Conference*. Mumbai, India. Zugriff am 03.08.2014. Verfügbar unter [http://www.cfilt.iitb.ac.in/gwc2010/pdfs/34\\_Modeling\\_Attitude\\_\\_maks.pdf](http://www.cfilt.iitb.ac.in/gwc2010/pdfs/34_Modeling_Attitude__maks.pdf)
- Maks, I. & Vossen, P. (2012). A lexicon model for deep sentiment analysis and opinion mining applications. *Decision Support Systems*, 53 (4), 680–688.  
<https://doi.org/10.1016/j.dss.2012.05.025>
- Malfliet, W. (2005). The tanh method. A tool for solving certain classes of non-linear PDEs. *Mathematical Methods in the Applied Sciences*, 28 (17), 2031–2035.  
<https://doi.org/10.1002/mma.650>
- Mandl, H. & Reiserer, M. (2000). Kognitionstheoretische Ansätze. In J. Otto, H. Euler & H. Mandl (Hrsg.), *Emotionspsychologie. Ein Handbuch* (S. 95–104). Weinheim: Beltz Psychologie Verlagsunion.
- Manning, C. (2014). *Statistical natural language processing and corpus-based computational linguistics: An annotated list of resources*, Stanford University Department of Linguistics. Zugriff am 19.08.2014. Verfügbar unter <http://www-nlp.stanford.edu/links/statnlp.html>
- Manning, C., Grow, T., Grenager, T., Finkel, J. & Bauer, J. (o.J.). *Stanford Tokenizer*. Verfügbar unter <https://nlp.stanford.edu/software/tokenizer.shtml>
- Manning, C., Raghavan, P. & Schütze, H. (2008). *Introduction to information retrieval*. New York: Cambridge University Press.
- Manning, C. & Schütze, H. (2005). *Foundations of statistical natural language processing*. Cambridge, Mass.: MIT Press.
- Manstead, A. & Tetlock, P. (1989). Cognitive appraisals and emotional experience. Further evidence, 3, 225–239.
- Marcic, R. (1957). *Vom Gesetzesstaat zum Richterstaat. Recht als Maß der Macht / Gedanken über den demokratischen Rechts- und Sozialstaat*. Wien: Springer.
- Mark, G., Iqbal, S., Czerwinski, M., Johns, P., Sano, A. & Lutchyn, Y. (2016). Email Duration, Batching and Self-interruption. In J. Kaye, A. Druin, C. Lampe, D. Morris & J. P. Hourcade (Hrsg.), *Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems - CHI '16* (S. 1717–1728). New York, New York, USA: ACM.
- Marsella, S., Gratch, J. & Petta, P. (2010). Computational Models of Emotion. In K. Scherer, T. Bänziger & E. Roesch (Eds.), *Blueprint for affective computing. A sourcebook* (Series in affective science, pp. 21–46). Oxford: Oxford University Press.
- Martens, J. (2010). Deep Learning via Hessian-free Optimization. In *Proceedings of the 27th International Conference on International Conference on Machine Learning (ICML '10*, S. 735–742). USA: Omnipress. Verfügbar unter <http://dl.acm.org/citation.cfm?id=3104322.3104416>

- Matsumoto, D. & Willingham, B. (2009). Spontaneous facial expressions of emotion of congenitally and noncongenitally blind individuals. *Journal of personality and social psychology*, 96 (1), 1–10. <https://doi.org/10.1037/a0014037>
- Mauro, R., Sato, K. & Tucker, J. (1992). The role of appraisal in human emotions. A cross-cultural study. *Journal of personality and social psychology*, 62 (2), 301–317.
- Mayring, P. (2003). Klassifikation und Beschreibung einzelner Emotionen. In D. Ulich & P. Mayring (Hrsg.), *Psychologie der Emotionen* (Grundriss der Psychologie, Bd. 5, 2., überarb. u. erw. Aufl., S. 144–190). Stuttgart: Kohlhammer.
- McCaffrey, J. (2015). L1 and L2 Regularization for Machine Learning. *MSDN Magazine*, 30 (2), 64–69. Verfügbar unter [http://download.microsoft.com/download/E/2/A/E2ACA573-591D-4DC9-AFB9-E6260D3C6046/MDN\\_0215DG.pdf](http://download.microsoft.com/download/E/2/A/E2ACA573-591D-4DC9-AFB9-E6260D3C6046/MDN_0215DG.pdf)
- McCullagh, P. & Nelder, J. A. (1999). *Generalized linear models* (Monographs on Statistics and Applied Probability, vol. 37, 2nd ed.). London: Chapman & Hall.
- McDonald, R., Hannan, K., Neylon, T., Wells, M. & Reynar, J. (2007). Structured Models for Fine-to-Coarse Sentiment Analysis. In *Proceedings of the Association for Computational Linguistics (ACL)* (S. 432–439). Prague, Czech Republic: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/P/P07/P07-1055>
- McDougall, W. (1926). The Principal Instincts and the Primary Emotions. In W. McDougall (Hrsg.), *An Introduction to Social Psychology* (Revised Edition, S. 47–92). Boston: John W. Luce & Co.
- McEachrane, M. (2009). Emotion, Meaning, and Appraisal Theory. *Theory & Psychology*, 19 (1), 33–53. <https://doi.org/10.1177/0959354308101418>
- McEnery, T., Xiao, R. & Tono, Y. (2008). *Corpus-based language studies. An advanced resource book* (Routledge applied linguistics). London: Routledge.
- Meckel, M. (2009). *Zukunft der Medien in 50 Zitaten. Journalismus ohne Zeitung*. Zugriff am 11.09.2017. Verfügbar unter <http://www.foerderland.de/digitale-wirtschaft/netzwerk/news/artikel/zukunft-der-medien-journalismus-ohne-zeitung/>
- Medhat, W., Hassan, A. & Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams Engineering Journal* (0), -. <https://doi.org/10.1016/j.asej.2014.04.011>
- Mees, U. (1991). *Die Struktur der Emotionen*. Göttingen: Hogrefe Verl. für Psychologie.
- Meiselman, H. (2016). Emotion Measurement. In *Emotion Measurement* (S. 645–697). Elsevier. <https://doi.org/10.1016/B978-0-08-100508-8.00026-6>
- Mendel, J. (2002). An architecture for making judgments using computing with words. *International Journal of Applied Mathematics and Computer Science*, 12 (3), 325–335. Verfügbar unter <http://eudml.org/doc/207590>

- Mert, A. & Akan, A. (2018). Emotion recognition based on time-frequency distribution of EEG signals using multivariate synchrosqueezing transform. *Digital Signal Processing*, 81, 106–115. <https://doi.org/10.1016/j.dsp.2018.07.003>
- Merten, J. & Krause, R. (1993). *Differentielle Affekt-Skala DAS*. Verfügbar unter [http://www.prof-rkrause.de/data/Differentielle\\_Affekt-Skala\\_DAS.pdf](http://www.prof-rkrause.de/data/Differentielle_Affekt-Skala_DAS.pdf)
- Meyer, W.-U., Reisenzein, R. & Schützwohl, A. (2001). *Einführung in die Emotionspsychologie* (Aus dem Programm Huber, 2., überarb. Aufl.).
- Meyer, W.-U., Schützwohl, A. & Reisenzein, R. (2003). *Evolutionspsychologische Emotionstheorien* (Einführung in die Emotionspsychologie, Bd. 2, 3., korr. Aufl.). Bern: Huber.
- Miestamo, M. (2007). Negation – An Overview of Typological Research. *Language and Linguistics Compass*, 1 (5), 552–570. <https://doi.org/10.1111/j.1749-818X.2007.00026.x>
- Mikolov, T., Chen, K., Corrado, G. & Dean, J. (2013a). Efficient Estimation of Word Representations in Vector Space. *CoRR*, *abs/1301.3781*.
- Mikolov, T., Sutskever, I., Chen, K., Corrado, G. & Dean, J. (2013b). Distributed Representations of Words and Phrases and their Compositionality. In C. J. C. Burges, L. Bottou, M. Welling, Z. Ghahramani & K. Q. Weinberger (Hrsg.), *Advances in Neural Information Processing Systems 26* (S. 3111–3119). Curran Associates Inc. Verfügbar unter <http://papers.nips.cc/paper/5021-distributed-representations-of-words-and-phrases-and-their-compositionality.pdf>
- Miller, G. (1956). The magical number seven plus or minus two. Some limits on our capacity for processing information. *Psychological review*, 63 (2), 81–97.
- Miller, G. (1995). WordNet. A lexical database for English. *Commun. ACM*, 38 (11), 39–41. <https://doi.org/10.1145/219717.219748>
- Mirzal, A. (2013). The limitation of the SVD for latent semantic indexing and Engineering. In *2013 IEEE International Conference on Control System, Computing and Engineering, ICCSCE 2013, Penang, Malaysia, November 29 - Dec. 1, 2013* (S. 413–416). IEEE. Verfügbar unter <https://doi.org/10.1109/ICCSCE.2013.6720000>
- Mishkin, D., Sergievskiy, N. & Matas, J. (2016). Systematic evaluation of CNN advances on the ImageNet. *CoRR*, *abs/1606.02228*.
- Mishne, G. (2005). Experiments with mood classification in blog posts. In *Proceedings of the 1st Workshop on Stylistic Analysis Of Text For Information Access*. Verfügbar unter <http://staff.science.uva.nl/gilad/pubs/style2005-blogmoods.pdf>
- Mishne, G. & Rijke, M. de. (2006). Capturing Global Mood Levels Using Blog Posts. In *Proceedings of the AAAI Spring Symposia on Computational Approaches to Analyzing Weblogs*. Stanford, US. Verfügbar unter <https://www.microsoft.com/en-us/research/publication/capturing-global-mood-levels-using-blog-posts/>

- Mitesser, O. (2008). Latente Semantische Analyse zur Messung der Diversität von Forschungsgebieten. *Berliner Handreichungen zur Bibliotheks- und Informationswissenschaft* (240), IX - 81. Zugriff am 28.07.2016. Verfügbar unter <http://www.ib.hu-berlin.de/~kum-lau/handreichungen/h240/>
- Moffat, D., Frijda, N. & Phaf, R. H. (1993). *Analysis of a computer model of emotions* (Slo-man, A., Hogg, D., Humphreys, G. & Ramsay, A., Hrsg.): IOS Press, Amsterdam. *Prospects for artificial intelligence*. Verfügbar unter <http://cogprints.org/469/>
- Moghaddam, S. & Ester, M. (2011). ILDA. In W.-Y. Ma, J.-Y. Nie, R. Baeza-Yates, T.-S. Chua & B. Croft (Hrsg.), *the 34th international ACM SIGIR conference* (S. 665).
- Moghaddam, S. & Ester, M. (2013). The FLDA Model for Aspect-based Opinion Mining. Addressing the Cold Start Problem. In *Proceedings of the 22nd International Conference on World Wide Web (WWW '13)*, S. 909–918. New York, NY, USA: ACM. Verfügbar unter <http://doi.acm.org/10.1145/2488388.2488467>
- Mohammad, S. (2012). #Emotional Tweets. In *SEM. The First Joint Conference on Lexical and Computational Semantics* (S. 246–255). Montréal, Canada: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/S12-1033>
- Mohammad, S. & Bravo-Márquez, F. (2017). WASSA-2017 Shared Task on Emotion Intensity. In *Proceedings of the 8th Workshop on Computational Approaches to Subjectivity, Sentiment and Social Media Analysis, WASSA@EMNLP 2017, Copenhagen, Denmark, September 8, 2017* (S. 34–49).
- Mohammad, S., Dunne, C. & Dorr, B. (2009). Generating High-coverage Semantic Orientation Lexicons from Overtly Marked Words and a Thesaurus. In *Proceedings of the 2009 Conference on Empirical Methods in Natural Language Processing: Volume 2 - Volume 2 (EMNLP '09)*, S. 599–608. Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1699571.1699591>
- Mohammad, S. & Hirst, G. (2012). Distributional Measures as Proxies for Semantic Relatedness. *CoRR*, *abs/1203.1889*.
- Mohammad, S. & Kiritchenko, S. (2015). Using Hashtags to Capture Fine Emotion Categories from Tweets. *Computational Intelligence*, *31* (2), 301–326. <https://doi.org/10.1111/coin.12024>
- Mohammad, S., Sobhani, P. & Kiritchenko, S. (2017). Stance and Sentiment in Tweets. *ACM Trans. Internet Techn.*, *17* (3), 26:1-26:23. <https://doi.org/10.1145/3003433>
- Mohammad, S. & Turney, P. (2010). Emotions Evoked by Common Words and Phrases: Using Mechanical Turk to Create an Emotion Lexicon. In *Proceedings of the NAACL HLT 2010 Workshop on Computational Approaches to Analysis and Generation of Emotion in Text (CAAGET '10)*, S. 26–34. Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1860631.1860635>

- Mohammad, S., Zhu, X., Kiritchenko, S. & Martin, J. (2015). Sentiment, emotion, purpose, and style in electoral tweets. *Inf. Process. Manage.*, 51 (4), 480–499.  
<https://doi.org/10.1016/j.ipm.2014.09.003>
- Moilanen, K. & Pulman, S. (2008). The Good, the Bad, and the Unknown: Morphosyllabic Sentiment Tagging of Unseen Words. In *Proceedings of the 46th Annual Meeting of the Association for Computational Linguistics on Human Language Technologies: Short Papers* (HLT-Short '08, S. 109–112). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1557690.1557719>
- Moody, C. (2016). Mixing Dirichlet Topic Models and Word Embeddings to Make lda2vec. *CoRR*, *abs/1605.02019*.
- Moraes, R., Valiati, J. F. & Gavião Neto, W. (2013). Document-level sentiment classification. An empirical comparison between SVM and ANN. *Expert Systems with Applications*, 40 (2), 621–633. <https://doi.org/10.1016/j.eswa.2012.07.059>
- Morton, T. & LaCivita, J. (2003). WordFreak. An Open Tool for Linguistic Annotation. In *Proceedings of the 2003 Conference of the North American Chapter of the Association for Computational Linguistics on Human Language Technology: Demonstrations - Volume 4* (NAACL '03, S. 17–18). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dx.doi.org/10.3115/1073427.1073436>
- Müller, C. & Strube, M. (2006). Multi-level annotation of linguistic data with MMAX2. In *Corpus Technology and Language Pedagogy. New Resources, New Tools, New Methods*.
- Müller von Blumencron, M. (2015). *Unsere tägliche Desinformation. Propagandaschlacht im Internet*. Zugriff am 11.09.2017. Verfügbar unter <http://www.faz.net/aktuell/politik/das-internet-als-propagandavehikel-obskurer-theorien-13364530.html>
- Müller-Neuhof, J. (Der Tagesspiegel, Hrsg.). (2017). *Selbst die Regierung weiß nicht, welche Inhalte strafbar sind. Geplantes Gesetz gegen Hasskommentare*. Zugriff am 11.09.2017. Verfügbar unter <http://www.tagesspiegel.de/politik/geplantes-gesetz-gegen-hasskommentare-selbst-die-regierung-weiss-nicht-welche-inhalte-straftbar-sind/19824788.html>
- Musacchio, M. T. (2011). Metaphors and Metaphor-Like Processes Across Languages. Notes on English and Italian Language of Economics. In K. Ahmad (Ed.), *Affective Computing and Sentiment Analysis. Emotion, Metaphor and Terminology ; [Workshop on Emotion, Metaphor, Ontology, and Terminology (EMOT) in August 2008 ... Selected papers from the Workshop]* (Text, Speech and Language Technology, vol. 45, pp. 79–88). Dordrecht: Springer.
- Naber, D. (2015). *Komposita-Zerlegung mit Java*. Zugriff am 21.11.2016.
- Nair, V. & Hinton, G. (2010). Rectified Linear Units Improve Restricted Boltzmann Machines. In J. Fürnkranz & T. Joachims (Hrsg.), *Proceedings of the 27th International Conference*

- on *Machine Learning (ICML-10)* (S. 807–814). Omnipress. Verfügbar unter <http://www.icml2010.org/papers/432.pdf>
- NDR/ARD-aktuell. (o.J.). *Faktenfinder*. Zugriff am 11.09.2017. Verfügbar unter <http://faktenfinder.tagesschau.de/>
- Nelder, J. A. & Wedderburn, R. W. M. (1972). Generalized Linear Models. *Journal of the Royal Statistical Society. Series A (General)*, 135 (3), 370. <https://doi.org/10.2307/2344614>
- Neviarouskaya, A., Prendinger, H. & Ishizuka, M. (2007). Analysis of affect expressed through the evolving language of online communication. In *IUI '07: Proceedings of the 12th international conference on Intelligent user interfaces* (S. 278–281). New York, NY, USA: ACM. Verfügbar unter <http://portal.acm.org/citation.cfm?id=1216295.1216346&coll=GUIDE&dl=GUIDE&CFID=14426045&CFTOKEN=24753528>
- Nielsen, F. A. (2011). *AFINN*. Richard Petersens Plads, Building 321, DK-2800 Kgs. Lyngby: Informatics and Mathematical Modelling, Technical University of Denmark. Zugriff am 28.07.2014. Verfügbar unter <http://www2.imm.dtu.dk/pubdb/p.php?6010>
- Nielsen, M. (2015). *Neural Networks and Deep Learning*.
- Nigam, K., Lafferty, J. & McCallum, A. (1999). *Using maximum entropy for text classification*. Verfügbar unter <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.48.1073>
- Niwa, Y. & Nitta, Y. (1994). Co-occurrence Vectors from Corpora vs. Distance Vectors from Dictionaries. In *Proceedings of the 15th Conference on Computational Linguistics - Volume 1 (COLING '94)*, S. 304–309. Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dx.doi.org/10.3115/991886.991938>
- Noroozi, F., Corneanu, C. A., Kaminska, D., Sapinski, T., Escalera, S. & Anbarjafari, G. (2018a). Survey on Emotional Body Gesture Recognition. *CoRR*, *abs/1801.07481*.
- Noroozi, F., Marjanovic, M., Njegus, A., Escalera, S. & Anbarjafari, G. (2018b). A Study of Language and Classifier-independent Feature Analysis for Vocal Emotion Recognition. *CoRR*, *abs/1811.08935*. Zugriff am 30.05.2019. Verfügbar unter <https://arxiv.org/abs/1811.08935>
- Norvig, P. (2007). *How to Write a Spelling Corrector*. Zugriff am 29.11.2015. Verfügbar unter <http://norvig.com/spell-correct.html>
- Ogren, P. (2006). Knowtator. A Protégé plug-in for annotated corpus construction. In *Proceedings of the Human Language Technology Conference of the NAACL* (S. 273–275). New York City, USA: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/N/N06/N06-4006>
- Oleszkiewicz, A., Frackowiak, T., Sorokowska, A. & Sorokowski, P. (2017). Children can accurately recognize facial emotions from emoticons. *Computers in Human Behavior*, 76, 372–377. <https://doi.org/10.1016/j.chb.2017.07.040>

- Olsher, D. J. (2012). Full spectrum opinion mining: integrating domain, syntactic and lexical knowledge. In *Data Mining Workshops (ICDMW), 2012 IEEE 12th International Conference on* (S. 693–700).
- Omdahl, B. L. (2014). *Cognitive Appraisal, Emotion, and Empathy*. Hoboken: Taylor and Francis.
- Ong, R. (2019). Offensive Language Analysis using Deep Learning Architecture. *CoRR*, *abs/1903.05280*.
- Ortner, H. (2014). *Text und Emotion. Theorie, Methode und Anwendungsbeispiele emotions-linguistischer Textanalyse* (Europäische Studien zur Textlinguistik, Bd. 15). Teilw. zugl.: Innsbruck, Univ., Diss., 2011. Tübingen: Narr.
- Ortony, A., Clore, G. & Collins, A. (1988). *The cognitive structure of emotions*. Cambridge: Cambridge University Press.
- Ortony, A. & Turner, T. J. (1990). What's basic about basic emotions? *Psychological review*, *97* (3), 315–331.
- Osgood, C. E. (1964). Semantic Differential Technique in the Comparative Study of Cultures<sup>1</sup>. *American Anthropologist*, *66* (3), 171–200.  
<https://doi.org/10.1525/aa.1964.66.3.02a00880>
- Osgood, C. E., Suci, G. & Tannenbaum, P. (1957). *The measurement of meaning*. Urbana: University of Illinois Press.
- Otto, J., Euler, H. & Mandl, H. (2000a). Begriffsbestimmungen. In J. Otto, H. Euler & H. Mandl (Hrsg.), *Emotionspsychologie. Ein Handbuch* (S. 11–18). Weinheim: Beltz Psychologie Verlagsunion.
- Otto, J., Euler, H. & Mandl, H. (Hrsg.). (2000b). *Emotionspsychologie. Ein Handbuch*. Weinheim: Beltz Psychologie Verlagsunion.
- Ouss, L., Carton, S., Jouvent, R. & Widlöcher, D. (1990). Traduction et validation de l'échelle d'émotions différentielles d'Izard. Exploration de la qualification verbale des émotions. *L'Encephale*, *16* (6), 453–458.
- Ouyang, X., Zhou, P., Li, C. H. & Liu, L. (2015). Sentiment Analysis Using Convolutional Neural Network. In *2015 IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communications; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing* (S. 2359–2364). IEEE.
- Pang, B. & Lee, L. (2008). *Opinion mining and sentiment analysis*. Hanover, MA: Now Publishers.
- Pang, B., Lee, L. & Vaithyanathan, S. (2002). Thumbs up?, 79–86.
- Panksepp, J. (1998). *Affective neuroscience. The foundations of human and animal emotions* (Series in affective science). Oxford: Oxford University Press.

- Panksepp, J. (2007). Can PLAY Diminish ADHD and Facilitate the Construction of the Social Brain? *Journal of the Canadian Academy of Child and Adolescent Psychiatry*, 16 (2), 57–66.
- Panksepp, J. & Panksepp, J. (2013). Toward a cross-species understanding of empathy. *Trends in neurosciences*, 36 (8), 489–496. <https://doi.org/10.1016/j.tins.2013.04.009>
- Papadimitriou, C., Raghavan, P., Tamaki, H. & Vempala, S. (2000). Latent Semantic Indexing. A Probabilistic Analysis. *Journal of Computer and System Sciences*, 61 (2), 217–235. <https://doi.org/10.1006/jcss.2000.1711>
- Papageorgiou, M., Leibold, M. & Buss, M. (2015). *Optimierung. Statische, dynamische, stochastische Verfahren für die Anwendung* (4., korr. Aufl.).
- Parrott, G. (2001a). *Emotions in social psychology: Essential readings*: Psychology Press.
- Parrott, G. (2001b). The Nature of Emotion. In A. Tesser & N. Schwarz (Hrsg.), *Blackwell Handbook of Social Psychology. Intraindividual Processes* (S. 375–390). Malden, Massachusetts, USA: Blackwell Publishers.
- Parrott, G. (2007). Components and the definition of emotion. *Social Science Information*, 46 (3), 419–423. <https://doi.org/10.1177/05390184070460030109>
- Pecchinenda, A. (2001). The psychophysiology of appraisals. In K. Scherer, A. Schorr & T. Johnstone (Eds.), *Appraisal processes in emotion. Theory, methods, research* (Series in affective science, pp. 301–315). Oxford: Oxford University Press.
- Pei-Xia, S., Hui-Ting, L. & Tao, L. (2016). Learning discriminative CNN features and similarity metrics for image retrieval. In *2016 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC)* (S. 1–5). IEEE.
- Pekrun, R. (2000). Persönlichkeit und Emotion. In J. Otto, H. Euler & H. Mandl (Hrsg.), *Emotionspsychologie. Ein Handbuch* (S. 334–348). Weinheim: Beltz Psychologie Verlagsunion.
- Pennebaker, J., Francis, M. & Booth, R. (2001). *Linguistic Inquiry and Word Count: A computerized text analysis program*.
- Pennington, J., Socher, R. & Manning, C. (2014). GloVe. Global Vectors for Word Representation. In *Empirical Methods in Natural Language Processing (EMNLP)* (S. 1532–1543). Verfügbar unter <http://www.aclweb.org/anthology/D14-1162>
- Picard, R. (1995). Affective Computing-MIT Media Laboratory Perceptual Computing Section Technical Report No. 321. *Cambridge, MA*, 2139.
- Pickering, A. & Corr, P. (2008). J.A. Gray's Reinforcement Sensitivity Theory (RST) of Personality. In D. Saklofske, G. Boyle & G. Matthews (Eds.), *The SAGE handbook of personality theory and assessment. Vol. 2: Personality measurement and testing* (pp. 239–256). Los Angeles, Calif.: SAGE Publications.

- Plutchik, R. (1962). *The Emotions. Facts, Theories, and a New Model* (Studies in psychology, PP24): Random House.
- Plutchik, R. (1980). *Emotion. A psychoevolutionary synthesis*. New York: Harper & Row.
- Plutchik, R. (1984). Emotions. A general psychoevolutionary theory. In K. Scherer & P. Ekman (Eds.), *Approaches To Emotion* (pp. 197–219). Hoboken: Taylor and Francis.
- Plutchik, R. (2001). The Nature of Emotions. *American Scientist*, 89 (4), 344.  
<https://doi.org/10.1511/2001.4.344>
- Poirier, D., Bothorel, C. & Neef, É. G. d. (2011). Automating Opinion Analysis in Film Reviews. The Case of Statistic Versus Linguistic Approach. In K. Ahmad (Ed.), *Affective Computing and Sentiment Analysis. Emotion, Metaphor and Terminology ; [Workshop on Emotion, Metaphor, Ontology, and Terminology (EMOT) in August 2008 ... Selected papers from the Workshop]* (Text, Speech and Language Technology, vol. 45, pp. 125–140). Dordrecht: Springer.
- Polanyi, L. & Zaenen, A. (2006). Contextual valence shifters. In *Computing attitude and affect in text. Theory and applications* (S. 1–10). Springer.
- Polyak, B. T. (1964). Some methods of speeding up the convergence of iteration methods. *USSR Computational Mathematics and Mathematical Physics*, 4 (5), 1–17.  
[https://doi.org/10.1016/0041-5553\(64\)90137-5](https://doi.org/10.1016/0041-5553(64)90137-5)
- Ponweiser, M. (2012). *Latent Dirichlet Allocation in R*. Diplomarbeit. Wirtschaftsuniversität Wien, Wien.
- Poole, B., Sohl-Dickstein, J. & Ganguli, S. (2014). Analyzing noise in autoencoders and deep networks. *CoRR*, *abs/1406.1831*.
- Popescu, A.-M. & Etzioni, O. (2005). Extracting product features and opinions from reviews. In R. Mooney (Hrsg.), *the conference* (S. 339–346).
- Poria, S., Cambria, E., Winterstein, G. & Huang, G.-B. (2014). Sentic patterns. Dependency-based rules for concept-level sentiment analysis. *Knowledge-Based Systems*, 69, 45–63.  
<https://doi.org/10.1016/j.knosys.2014.05.005>
- Porter, M. F. (1980). An algorithm for suffix stripping. *Program*, 14 (3), 130–137.  
<https://doi.org/10.1108/eb046814>
- Pöttker, H. (2005). The News Pyramid and its Origin from the American Journalism in the 19th Century. A Professional Approach and an Empirical Inquiry. In S. Høyer & H. Pöttker (Hrsg.), *Diffusion of the news paradigm, 1850-2000*. Göteborg, Sweden: Nordicom.
- Potts, C. (2011a). *Sentiment Symposium Tutorial: Lexicons. Relationships*, Stanford University Department of Linguistics. Zugriff am 29.07.2014. Verfügbar unter <http://sentiment.christopherpotts.net/lexicons.html>

- Potts, C. (2011b). *Simple WordNet Propagation*, Stanford University Department of Linguistics. Zugriff am 03.08.2014. Verfügbar unter <http://sentiment.christopherpotts.net/wnpropagate/>
- Powers, D. (2011). Evaluation. From precision, recall and f-measure to roc., informedness, markedness & correlation. *Journal of Machine Learning Technologies*, 2 (1), 37–63.
- Prasad, S. (2010). *Micro - blogging Sentiment Analysis Using Bayesian Classification Methods*. Zugriff am 21.07.2014. Verfügbar unter <http://nlp.stanford.edu/courses/cs224n/2010/reports/suhaasp.pdf>
- Pritzel, M., Brand, M. & Markowitsch, H. (2003). *Gehirn und Verhalten. Ein Grundkurs der physiologischen Psychologie*. Heidelberg: Spektrum Akademischer Verlag.  
<https://doi.org/10.1007/978-3-8274-2340-5>
- Quigley, K., Lindquist, K. & Barrett, L. F. (2014). Inducing and measuring emotion and affect: Tips, tricks, and secrets. In *Handbook of research methods in social and personality psychology* (2nd Edition, S. 220–252). New York, NY, US: Cambridge University Press.
- Quinlan, J. R. (1986). Induction of Decision Trees. *Mach. Learn.*, 1 (1), 81–106.  
<https://doi.org/10.1023/A:1022643204877>
- Quirk, R. (1985). *A Comprehensive grammar of the English language*. London: Longman.
- Rajaraman, A. (2008). *More data usually beats better algorithms*. Zugriff am 11.08.2014. Verfügbar unter <http://anand.typepad.com/datawocky/2008/03/more-data-usual.html>
- Rao, Y., Li, Q., Mao, X. & Wenyin, L. (2014). Sentiment Topic Models for Social Emotion Mining. *Inf. Sci.*, 266, 90–100. <https://doi.org/10.1016/j.ins.2013.12.059>
- Ravi, K. & Ravi, V. (2015). A survey on opinion mining and sentiment analysis. Tasks, approaches and applications. *Knowledge-Based Systems*, 89, 14–46.  
<https://doi.org/10.1016/j.knosys.2015.06.015>
- Rehbein, I. (2013). Fine-Grained POS Tagging of German Tweets. In I. Gurevych, C. Biemann & T. Zesch (Hrsg.), *Language Processing and Knowledge in the Web* (Lecture Notes in Computer Science, Bd. 8105, S. 162–175). Springer. [https://doi.org/10.1007/978-3-642-40722-2\\_17](https://doi.org/10.1007/978-3-642-40722-2_17)
- Řehůřek, R. (2011). *Scalability of Semantic Analysis in Natural Language Processing*. Dissertation. Masaryk University, Brunn. Zugriff am 08.09.2017. Verfügbar unter [https://radimrehurek.com/phd\\_rehurek.pdf](https://radimrehurek.com/phd_rehurek.pdf)
- Řehůřek, R. & Sojka, P. (2010). Software Framework for Topic Modelling with Large Corpora. In *Proceedings of the LREC 2010 Workshop on New Challenges for NLP Frameworks* (S. 45–50). Valletta, Malta: ELRA.
- Reichel, U. (2010). *Statistische Sprachmodelle*, Ludwig-Maximilians-Universität München. Zugriff am 22.06.2013. Verfügbar unter [http://www.phonetik.uni-muenchen.de/~reichelu/kurse/stat\\_lm/script\\_reichel\\_stat\\_lm.pdf](http://www.phonetik.uni-muenchen.de/~reichelu/kurse/stat_lm/script_reichel_stat_lm.pdf)

- Reisenzein, R. (1994). Pleasure-arousal theory and the intensity of emotions. *Journal of personality and social psychology*, 67 (3), 525–539. <https://doi.org/10.1037/0022-3514.67.3.525>
- Reisenzein, R. (2000a). Einschätzungstheoretische Ansätze. In J. Otto, H. Euler & H. Mandl (Hrsg.), *Emotionspsychologie. Ein Handbuch* (S. 117–138). Weinheim: Beltz Psychologie Verlagsunion.
- Reisenzein, R. (2000b). Worum geht es in der Debatte um die Basisemotionen? In F. Försterling, J. Stiensmeier-Pelster & L.-M. Silny (Hrsg.), *Kognitive und emotionale Aspekte der Motivation* (S. 205–237). Göttingen: Hogrefe Verl. für Psychologie.
- Reisenzein, R. (2006). Arnold's theory of emotion in historical perspective. *Cognition and Emotion*, 20 (7), 920–951. <https://doi.org/10.1080/02699930600616445>
- Reisenzein, R. & Hofmann, T. (1993). Discriminating emotions from appraisal-relevant situational information. Baseline data for structural models of cognitive appraisals. *Cognition and Emotion*, 7 (3-4), 271–293. <https://doi.org/10.1080/02699939308409190>
- Remus, R. (2013). Modeling and Representing Negation in Data-driven Machine Learning-based Sentiment Analysis. In *ESSEM@ AI\* IA* (S. 22–33).
- Ren, S., He, K., Girshick, R., Zhang, X. & Sun, J. (2015). Object Detection Networks on Convolutional Feature Maps. *CoRR*, *abs/1504.06066*.
- Rennie, J. & Srebro, N. (2005). Fast maximum margin matrix factorization for collaborative prediction. In S. Dzeroski (Hrsg.), *Proceedings of the 22nd international conference on Machine learning - ICML '05* (S. 713–719). New York, New York, USA: ACM.
- Reynar, J. (1998). *Topic Segmentation. Algorithms and Applications*. Dissertation. University of Pennsylvania, Pennsylvania. Zugriff am 12.12.2016. Verfügbar unter [https://repository.upenn.edu/cgi/viewcontent.cgi?article=1068&context=ircs\\_reports](https://repository.upenn.edu/cgi/viewcontent.cgi?article=1068&context=ircs_reports)
- Riedl, M. & Biemann, C. (2012). TopicTiling: A Text Segmentation Algorithm Based on LDA. In *Proceedings of ACL 2012 Student Research Workshop (ACL '12)*, S. 37–42). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=2390331.2390338>
- Riedmiller, M. & Braun, H. (1993). A direct adaptive method for faster backpropagation learning. The RPROP algorithm. In *IEEE International Conference on Neural Networks* (S. 586–591). IEEE.
- Riggert, W. (2000). *Betriebliche Informationskonzepte. Von Hypertext zu Groupware* (2., überarb. Aufl.). Wiesbaden: Vieweg+Teubner Verlag. <https://doi.org/10.1007/978-3-322-89195-2>
- Rill, S., Adolph, S., Drescher, J., Reinel, D., Scheidt, J., Schütz, O. et al. (2012a). A phrase-based opinion list for the German language. In Jeremy Jancsary (Hrsg.), *Proceedings of*

- KONVENS 2012 (S. 305–313). ÖGAI. Verfügbar unter [http://www.oegai.at/konvens2012/proceedings/46\\_rill12w/](http://www.oegai.at/konvens2012/proceedings/46_rill12w/)
- Rill, S., Scheidt, J., Drescher, J., Schütz, O., Reinel, D. & Wogenstein, F. (2012b). A Generic Approach to Generate Opinion Lists of Phrases for Opinion Mining Applications. In *Proceedings of the First International Workshop on Issues of Sentiment Discovery and Opinion Mining* (WISDOM '12, S. 7). New York, NY, USA: ACM. Verfügbar unter <http://doi.acm.org/10.1145/2346676.2346683>
- Ripley, B. (2005). *Pattern recognition and neural networks* (8. print). Cambridge: Cambridge University Press.
- Robinson, D. (2008). Brain function, emotional experience and personality. *Netherlands Journal of Psychology*, 64 (4), 152–168. <https://doi.org/10.1007/BF03076418>
- Rohde, D., Gonnerman, L. & Plaut, D. (2006). An improved model of semantic similarity based on lexical co-occurrence. *Communications of the ACM*, 8, 627–633.
- Rojas, S. L., Kirschenmann, U. & Wolpers, M. (2012). We Have No Feelings, We Have Emoticons ;-). In *Proceedings of the 2012 IEEE 12th International Conference on Advanced Learning Technologies* (ICALT '12, S. 642–646). Washington, DC, USA: IEEE Computer Society. Verfügbar unter <http://dx.doi.org/10.1109/ICALT.2012.180>
- Rong, X. (2014). word2vec Parameter Learning Explained. *CoRR*, *abs/1411.2738*.
- Rosario, B. (2000). *Latent Semantic Indexing. An overview* (INFOSYS 240, Hrsg.). Zugriff am 28.07.2016. Verfügbar unter <http://www.cse.msu.edu/~cse960/Papers/LSI/LSI.pdf>
- Rosasco, L., Vito, E. de, Caponnetto, A., Piana, M. & Verri, A. (2004). Are loss functions all the same? *Neural Comput*, 16 (5), 1063–1076. <https://doi.org/10.1162/089976604773135104>
- Roseman, I. (1979). Cognitive aspects of emotion and emotional behavior. In *Proceedings of the 87th Annual Convention of the American Psychological Association* (Bd. 58). New York.
- Roseman, I. (2001). A model of appraisal in the emotion system. Integrating theory, research, and applications. In K. Scherer, A. Schorr & T. Johnstone (Eds.), *Appraisal processes in emotion. Theory, methods, research* (Series in affective science, pp. 68–91). Oxford: Oxford University Press.
- Roseman, I. & Evdokas, A. (2004). Appraisals cause experienced emotions. Experimental evidence. *Cognition and Emotion*, 18 (1), 1–28. <https://doi.org/10.1080/02699930244000390>
- Rosenthal, S., Nakov, P., Kiritchenko, S., Mohammad, S., Ritter, A. & Stoyanov, V. (2015). SemEval-2015 Task 10. Sentiment Analysis in Twitter. In *Proceedings of the 9th International Workshop on Semantic Evaluation (SemEval 2015)* (S. 451–463). Denver,

- Colorado: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/S15-2078>
- Rosen-Zvi, M., Griffiths, T., Steyvers, M. & Smyth, P. (2004). The author-topic model for authors and documents. In *Proceedings of the 20th conference on Uncertainty in artificial intelligence* (UAI '04, S. 487–494). Arlington, Virginia, United States: AUAI Press.
- Roth, G. (2003). *Fühlen, Denken, Handeln. Wie das Gehirn unser Verhalten steuert*. Frankfurt am Main: Suhrkamp.
- Rouse, M. (2005). *Crawler*. Zugriff am 25.06.2014. Verfügbar unter <http://searchsoa.techtarget.com/definition/crawler>
- Roy, T. & Permanente, K. (2017). *Medical Image Analysis with Deep Learning, Part 2*. Verfügbar unter <http://www.kdnuggets.com/2017/04/medical-image-analysis-deep-learning-part-2.html>
- Rübenstrunk, H.-G. (1998). *Emotionale Computer. Computermodelle von Emotionen und ihre Bedeutung für die emotionspsychologische Forschung*. Diplomarbeit. Universität Bielefeld, Bielefeld.
- Rumelhart, D., Hinton, G. & Williams, R. (1986). Learning representations by back-propagating errors, *323* (6088), 533–536. <https://doi.org/10.1038/323533a0>
- Rummer, R. & Engelkamp, J. (2000). Sprache und Emotion. In J. Otto, H. Euler & H. Mandl (Hrsg.), *Emotionspsychologie. Ein Handbuch* (325-333). Weinheim: Beltz Psychologie Verlagsunion.
- Runkehl, J., Schlobinski, P. & Siever, T. (1998). *Sprache und Kommunikation im Internet. Ueberblick und Analysen*. Opladen: Westdeutscher Verlag.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S. et al. (2014). ImageNet Large Scale Visual Recognition Challenge. *CoRR*, *abs/1409.0575*.
- Russell, J. (1980). A circumplex model of affect. *Journal of personality and social psychology*, *39* (6), 1161–1178. <https://doi.org/10.1037/h0077714>
- Russell, J. (1983). Pancultural aspects of the human conceptual organization of emotions, *45*, 1281–1288.
- Russell, J. (1991). Culture and the categorization of emotions. *Psychological bulletin*, *110* (3), 426–450.
- Russell, J. (1997). Reading emotions from and into faces. Resurrecting a dimensional-contextual perspective. In J. Russell, J.-M. Fernández-Dols & G. Mandler (Hrsg.), *The psychology of facial expression* (S. 295–320). Cambridge: Cambridge University Press. <https://doi.org/10.1017/CBO9780511659911.015>
- Russell, J. & Fernández-Dols, J.-M. (1997). What does a facial expression mean? In J. Russell (Hrsg.), *The psychology of facial expression* (Studies in emotion and social interaction, 1. publ, S. 3–30). Cambridge u.a.: Cambridge University Press.

- Russell, J. A. & Mehrabian, A. (1977). Evidence for a three-factor theory of emotions. *Journal of Research in Personality*, 11 (3), 273–294. [https://doi.org/10.1016/0092-6566\(77\)90037-X](https://doi.org/10.1016/0092-6566(77)90037-X)
- Sadamitsu, K., Sekine, S. & Yamamoto, M. (2008). Sentiment analysis based on probabilistic models using inter-sentence information. In *In Proceedings of the International Conference on Language Resources and Evaluation* (S. 2892–2896).
- Salle, A., Idiart, M. & Villavicencio, A. (2016). Enhancing the LexVec Distributed Word Representation Model Using Positional Contexts and External Memory. *CoRR*, *abs/1606.01283*.
- Samha, A., Li, Y. & Zhang, J. (2015). Aspect-Based Opinion Mining from Product Reviews Using Conditional Random Fields. In *13th Australasian Data Mining Conference* (S. 119–128).
- Santamaria-Granados, L., Organero, M. M., González, G. R., Abdulhay, E. & N., A. (2019). Using Deep Convolutional Neural Network for Emotion Detection on a Physiological Signals Dataset (AMIGOS). *IEEE Access*, 7, 57–67. <https://doi.org/10.1109/ACCESS.2018.2883213>
- Sauter, D., Eisner, F., Ekman, P. & Scott, S. (2010). Cross-cultural recognition of basic emotions through nonverbal emotional vocalizations. *Proceedings of the National Academy of Sciences of the United States of America*, 107 (6), 2408–2412. <https://doi.org/10.1073/pnas.0908239106>
- Saxe, A., McClelland, J. & Ganguli, S. (2013). Exact solutions to the nonlinear dynamics of learning in deep linear neural networks. *CoRR*, *abs/1312.6120*.
- Scheible, C. & Schütze, H. (2013). Sentiment Relevance. In *Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)* (S. 954–963). Sofia, Bulgaria: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/P13-1094>
- Scherer, K. (1982). Emotion as a process. Function, origin and regulation. *Social Science Information*, 21 (4-5), 555–570. <https://doi.org/10.1177/053901882021004004>
- Scherer, K. (1999). Appraisal Theory. In T. Dalgleish & M. Power (Hrsg.), *Handbook of Cognition and Emotion* (S. 637–663). Chichester, UK: John Wiley & Sons, Ltd. <https://doi.org/10.1002/0470013494.ch30>
- Scherer, K. (2001). Appraisal Considered as a Process of Multi-Level Sequential Checking. In K. Scherer, A. Schorr & T. Johnstone (Eds.), *Appraisal processes in emotion. Theory, methods, research* (Series in affective science, pp. 92–120). Oxford: Oxford University Press.
- Scherer, K. (2005). What are emotions? And how can they be measured? *Social Science Information*, 44 (4), 695–729. <https://doi.org/10.1177/0539018405058216>

- Scherer, K. & Wallbott, H. G. (1994). Evidence for universality and cultural variation of differential emotion response patterning. *Journal of personality and social psychology*, 66 (2), 310–328.
- Scherer, K. & Wallbott, H. (2006). *ISEAR Databank*. Zugriff am 07.12.2017. Verfügbar unter <http://emotion-research.net/toolbox/toolboxdatabase.2006-10-13.2581092615>
- Schiller, A., Teufel, S., Stöckert, C. & Thielen, C. (1995). *Vorläufige Guidelines für das Tagging deutscher Textcorpora mit STTS*. Universität Stuttgart, Universität Tübingen. Zugriff am 19.08.2014. Verfügbar unter [ftp://ftp.ims.uni-stuttgart.de/pub/corpora/stts\\_guide.pdf](ftp://ftp.ims.uni-stuttgart.de/pub/corpora/stts_guide.pdf)
- Schirmer, A. (2015). *Emotion*. Thousand Oaks, CA: SAGE Publications.
- Schlobinski, P. (2001). \*knuddel zurueckknuddel dich ganzdollknuddel\*. Inflektive und Inflektivkonstruktionen im Deutschen [Inflection and Inflectional Constructions in German]. *Zeitschrift für Germanistische Linguistik*, 29 (2). <https://doi.org/10.1515/zfgl.2001.013>
- Schmid, H. (1994). Probabilistic Part-of-Speech Tagging Using Decision Trees. In *Proceedings of the International Conference on New Methods in Language Processing*. Manchester, UK.
- Schmid, H. (1999). Improvements in Part-of-Speech Tagging with an Application to German. In S. Armstrong, K. Church, P. Isabelle, S. Manzi, E. Tzoukermann & D. Yarowsky (Hrsg.), *Natural Language Processing Using Very Large Corpora* (Text, Speech and Language Technology, Bd. 11, S. 13–25). Springer. [https://doi.org/10.1007/978-94-017-2390-9\\_2](https://doi.org/10.1007/978-94-017-2390-9_2)
- Schmid, H. & Laws, F. (2008). Estimation of Conditional Probabilities with Decision Trees and an Application to Fine-grained POS Tagging. In *Proceedings of the 22nd International Conference on Computational Linguistics - Volume 1 (COLING '08, S. 777–784)*. Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1599081.1599179>
- Schmidhuber, J. (2015). Deep learning in neural networks. An overview. *Neural networks : the official journal of the International Neural Network Society*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Schmidt, M., Le Roux, N. & Bach, F. (2013). Minimizing Finite Sums with the Stochastic Average Gradient. *ArXiv e-prints*.
- Schmidt-Atzert, L. (1980). *Die verbale Kommunikation von Emotionen. Eine Bedingungsanalyse unter besonderer Berücksichtigung physiologischer Prozesse*: Universität Giessen.
- Schmidt-Atzert, L. (1981). *Emotionspsychologie* (Kohlhammer-Studienbücher Psychologie). Stuttgart: Kohlhammer.
- Schmidt-Atzert, L. (1996). *Lehrbuch der Emotionspsychologie*. Stuttgart: Kohlhammer.
- Schmidt-Atzert, L. & Ströhm, W. (1983). Ein Beitrag zur Taxonomie der Emotionswörter. *Psychologische Beiträge*, 25, 126–141.

- Schneiderman, I., Zilberstein-Kra, Y., Leckman, J. & Feldman, R. (2011). Love alters autonomic reactivity to emotions. *Emotion (Washington, D.C.)*, 11 (6), 1314–1321.  
<https://doi.org/10.1037/a0024090>
- Schofield, A., Magnusson, M. & Mimno, D. (2017). Pulling Out the Stops. Rethinking Stopword Removal for Topic Models. In *Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics: Volume 2, Short Papers* (S. 432–436). Valencia, Spain: Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/E17-2069>
- Schütze, H. (2017). Nonsymbolic Text Representation. In *Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics, EACL 2017, Valencia, Spain, April 3-7, 2017, Volume 1: Long Papers* (S. 785–796).
- Schwartz, S. (2009). *LSAT Words. "Except" "unless" "until" and "without" mean...* Zugriff am 23.07.2014. Verfügbar unter <http://lsatblog.blogspot.de/2009/11/words-except-unless-until-without-mean.html>
- Schweiger, W. (2017). *Der (des)informierte Bürger im Netz. Wie soziale Medien die Meinungsbildung verändern.*
- Sedgewick, R. & Wayne, K. D. (2011). *Algorithms* (4th ed.). Upper Saddle River, NJ: Addison-Wesley.
- Segura-Bedmar, I., Quirós, A. & Martínez, P. (2017). Exploring Convolutional Neural Networks for Sentiment Analysis of Spanish tweets. In *Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics, EACL 2017, Valencia, Spain, April 3-7, 2017, Volume 1: Long Papers* (S. 1014–1022). Verfügbar unter <https://aclanthology.info/papers/E17-1095/e17-1095>
- Semantria, L. L.C. (2013). *Capitalization, Exclamation Marks, and Negation Phrases Affect on Sentiment Score.* Zugriff am 25.07.2014. Verfügbar unter <http://support.semantria.com/customer/portal/articles/1019655-capitalization-exclamation-marks-and-negation-phrases-affect-on-sentiment-score>
- Shaheen, S., El-Hajj, W., Hajj, H. & Elbassuoni, S. (2014). Emotion Recognition from Text Based on Automatically Generated Rules. In *2014 IEEE International Conference on Data Mining Workshop* (S. 383–392).
- Shapiro, S. S. & Wilk, M. B. (1965). An Analysis of Variance Test for Normality (Complete Samples). *Biometrika*, 52 (3/4), 591–611. <https://doi.org/10.2307/2333709>
- Shaver, P., Schwartz, J., Kirson, D. & O'Connor, C. (1987). Emotion knowledge. Further exploration of a prototype approach. *Journal of personality and social psychology*, 52 (6), 1061–1086.
- Shen, Q., Wang, Z. & Sun, Y. (2017). Sentiment Analysis of Movie Reviews Based on CNN-BLSTM. In *2nd IFIP TC 12 International Conference* (S. 164–171).

- Shepard, R. (1962a). The analysis of proximities. Multidimensional scaling with an unknown distance function. I. *Psychometrika*, 27 (2), 125–140. <https://doi.org/10.1007/BF02289630>
- Shepard, R. (1962b). The analysis of proximities. Multidimensional scaling with an unknown distance function. II. *Psychometrika*, 27 (3), 219–246. <https://doi.org/10.1007/BF02289621>
- Shepstone, S. E., Tan, Z.-H. & Jensen, S. H. (2018). Audio-Based Granularity-Adapted Emotion Classification. *IEEE Trans. Affective Computing*, 9 (2), 176–190. <https://doi.org/10.1109/TAFFC.2016.2598741>
- Shi, Z. (2012). *Intelligence science* (Series on intelligence science, vol. 2). Singapore: World Scientific Pub. Co.
- Shuman, V., Schlegel, K. & Scherer, K. (2015). *Geneva Emotion Wheel Rating Study*.
- Simonyan, K. & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *CoRR*, *abs/1409.1556*.
- Skomoroch, P. (2008). *Some Datasets Available on the Web*. Zugriff am 26.06.2014. Verfügbar unter <http://www.datawrangling.com/some-datasets-available-on-the-web>
- Smith, C. & Ellsworth, P. (1985). Patterns of cognitive appraisal in emotion. *Journal of personality and social psychology*, 48 (4), 813–838.
- Snyder, C. (Hrsg.). (2009). *Oxford handbook of positive psychology* (Oxford library of psychology, 2. ed.). Oxford u.a.: Oxford University Press.
- Socher, R. (2016). *Convolutional Neural Networks (for NLP)*. Zugriff am 07.12.2017. Verfügbar unter <http://cs224d.stanford.edu/lectures/CS224d-Lecture13.pdf>
- Socher, R., Perelygin, A., Wu, J., Chuang, J., Manning, C., Ng, A. et al. (2013). Recursive deep models for semantic compositionality over a sentiment treebank. *Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1631–1642.
- Sohl-Dickstein, J., Poole, B. & Ganguli, S. (2013). An adaptive low dimensional quasi-Newton sum of functions optimizer. *CoRR*, *abs/1311.2115*.
- Song, T., Zheng, W., Lu, C., Zong, Y., Zhang, X. & Cui, Z. (2019). MPED: A Multi-Modal Physiological Emotion Database for Discrete Emotion Recognition. *IEEE Access*, 7, 12177–12191. <https://doi.org/10.1109/ACCESS.2019.2891579>
- Sosa, P. (2017). *Twitter Sentiment Analysis using combined LSTM-CNN Models*. Zugriff am 10.06.2019. Verfügbar unter [https://www.academia.edu/35947062/Twitter\\_Sentiment\\_Analysis\\_using\\_combined\\_LSTM-CNN\\_Models](https://www.academia.edu/35947062/Twitter_Sentiment_Analysis_using_combined_LSTM-CNN_Models)
- Sousa, R. d. (2007). Defining emotional space. *Social Science Information*, 46 (3), 383–387. <https://doi.org/10.1177/05390184070460030102>
- Spies, M. (1993). *Unsicheres Wissen. Wahrscheinlichkeit, Fuzzy-Logik, neuronale Netze und menschliches Denken*. Heidelberg u.a.: Spektrum Akad. Verl.
- Spies, M. (2010). An ontology modelling perspective on business reporting. *Information Systems*, 35 (4), 404–416. <https://doi.org/10.1016/j.is.2008.12.003>

- Spies, M. (2017). Probabilistic topic models for small corpora. An empirical study. In C. Roche (Hrsg.), *Terminologie & Ontologie. Théories et Applications* (Terminologica ). Chambéry: Éditions de l'Université Savoie Mont Blanc.
- Spies, M., Gubser, R. & Schacher, M. (2010). Intelligent Regulatory Compliance. In R. Kenett & Y. Raanan (Hrsg.), *Operational Risk Management* (S. 215–238). Chichester, UK: John Wiley & Sons, Ltd.
- Spies, M. & Jungemann-Dorner, M. (2013). Big Textual Data Analytics and Knowledge Management. In *Big data computing*. [S.I.]: Chapman & Hall.
- Spies, M. & Roche, C. (2008). Aristotelian Ontologies and OWL Modeling. In P. Rittgen (Hrsg.), *Handbook of Ontologies for Business Interaction* (S. 21–33). IGI Global. <https://doi.org/10.4018/978-1-59904-660-0.ch002>
- Spyrou, E., Vernikos, I., Nikopoulou, R. & Mylonas, P. (2018). A Non-Linguistic Approach for Human Emotion Recognition from Speech. In *9th International Conference on Information, Intelligence, Systems and Applications* (S. 1–5). Verfügbar unter <http://doi.ieeecomputersociety.org/10.1109/IISA.2018.8633644>
- Srebro, N. & Shraibman, A. (2005). Rank, Trace-Norm and Max-Norm. In D. Hutchison, T. Kanade, J. Kittler, J. Kleinberg, F. Mattern, J. Mitchell et al. (Hrsg.), *Learning Theory* (Lecture Notes in Computer Science, Bd. 3559, S. 545–560). Berlin, Heidelberg: Springer. [https://doi.org/10.1007/11503415\\_37](https://doi.org/10.1007/11503415_37)
- Srinivas, S., Sarvadevabhatla, R. K., Mopuri, K. R., Prabhu, N., Kruthiventi, S. & Babu, R. V. (2016). A Taxonomy of Deep Convolutional Neural Nets for Computer Vision. *Frontiers in Robotics and AI*, 2, 2654. <https://doi.org/10.3389/frobt.2015.00036>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. & Salakhutdinov, R. (2014). Dropout. A Simple Way to Prevent Neural Networks from Overfitting. *J. Mach. Learn. Res.*, 15 (1), 1929–1958. Verfügbar unter <http://dl.acm.org/citation.cfm?id=2627435.2670313>
- Städtler, T. (2003). *Lexikon der Psychologie. Wörterbuch, Handbuch, Studienbuch* (Sonderausg.). Stuttgart: Kröner.
- Statista. (2011). *Umfrage zur Nutzung der Kommentarfunktion bei Onlinemedien durch die Leser. Wie häufig wird die Kommentarfunktion genutzt?* Zugriff am 11.08.2014. Verfügbar unter <http://de.statista.com/statistik/daten/studie/209517/umfrage/nutzung-der-kommentarfunktion-bei-onlinemedien-durch-die-leser/>
- Stemmler, G., Schmidt-Atzert, L. & Peper, M. (2014). *Emotionspsychologie. Ein Lehrbuch* (2., überarb. Aufl.). s.l.: Kohlhammer.
- Stenetorp, P., Pyysalo, S., Topić, G., Ohta, T., Ananiadou, S. & Tsujii, J.'i. (2012). BRAT. A Web-based Tool for NLP-assisted Text Annotation. In *Proceedings of the Demonstrations at the 13th Conference of the European Chapter of the Association for Computational*

- Linguistics* (EACL '12, S. 102–107). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=2380921.2380942>
- Sternberg, R. (1998). *Thinking and Problem Solving* (Handbook Of Perception And Cognition). Burlington: Elsevier Science.
- Stevens, R. (o.J.). *Stevens Family Ontology*. Zugriff am 08.08.2014. Verfügbar unter [www.cs.man.ac.uk/~stevensr/ontology/family.rdf.owl](http://www.cs.man.ac.uk/~stevensr/ontology/family.rdf.owl)
- Steyvers, M. & Griffiths, T. (2007). Probabilistic Topic Models. In T. Landauer, D. Mcnamara, S. Dennis & W. Kintsch (Hrsg.), *Handbook of Latent Semantic Analysis*. Lawrence Erlbaum Associates.
- Steyvers, M., Smyth, P., Rosen-Zvi, M. & Griffiths, T. (2004). Probabilistic author-topic models for information discovery. In *Proceedings of the 10th ACM SIGKDD international conference on Knowledge discovery and data mining* (KDD '04, S. 306–315). New York, NY, USA: ACM.
- Stojanovski, D., Strezoski, G., Madjarov, G. & Dimitrovski, I. (2015). Twitter Sentiment Analysis Using Deep Convolutional Neural Network. In E. Onieva, I. Santos, E. Osaba, H. Quintián & E. Corchado (Hrsg.), *Hybrid Artificial Intelligent Systems: 10th International Conference, HAIS 2015, Bilbao, Spain, June 22-24, 2015, Proceedings* (S. 726–737). Cham: Springer. [https://doi.org/10.1007/978-3-319-19644-2\\_60](https://doi.org/10.1007/978-3-319-19644-2_60)
- Stone, P. (o.J.). *How the General Inquirer is used and a comparison of General Inquirer with other text-analysis procedures*, Harvard University. Zugriff am 28.07.2014. Verfügbar unter <http://www.wjh.harvard.edu/~inquirer/homecat.htm>
- Stone, P. (1997). Thematic text analysis: new agendas for analyzing text content. In C. Roberts (Hrsg.), *Text Analysis for the Social Sciences*. Mahwah, NJ: Lawrence Erlbaum Associates.
- Stone, P., Dunphy, D., Smith, M. & Ogilvie, D. (1966). *The General Inquirer: A Computer Approach to Content Analysis*: MIT Press.
- Strapparava, C. & Mihalcea, R. (2007a). SemEval-2007 Task 14. Affective Text. In *Proceedings of the 4th International Workshop on Semantic Evaluations* (SemEval '07, S. 70–74). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1621474.1621487>
- Strapparava, C. & Mihalcea, R. (2007b). SemEval-2007 Task 14: Affective Text. In *Proceedings of the 4th International Workshop on Semantic Evaluations* (SemEval '07, S. 70–74). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1621474.1621487>
- Strapparava, C. & Valitutti, A. (2004). WordNet-Affect: an Affective Extension of WordNet. In *Proceedings of the 4th International Conference on Language Resources and Evaluation* (S. 1083–1086).

- Strapparava, C., Valitutti, A. & Stock, O. (2006). The affective weight of lexicon. *Proceedings of the Fifth International Conference on Language Resources and Evaluation*, 423–426.
- Strobl, C., Boulesteix, A.-L., Kneib, T., Augustin, T. & Zeileis, A. (2008). Conditional variable importance for random forests. *BMC Bioinformatics*, 9, 307. <https://doi.org/10.1186/1471-2105-9-307>
- Sutskever, I., Martens, J., Dahl, G. & Hinton, G. (2013). On the Importance of Initialization and Momentum in Deep Learning. In *Proceedings of the 30th International Conference on International Conference on Machine Learning - Volume 28 (ICML '13, III-1139-III-1147)*. JMLR.org. Verfügbar unter <http://dl.acm.org/citation.cfm?id=3042817.3043064>
- Syed, A. Z., Aslam, M. & Martinez-Enriquez, A. M. (2011). Sentiment Analysis of Urdu Language: Handling Phrase-level Negation. In *Proceedings of the 10th Mexican International Conference on Advances in Artificial Intelligence - Volume Part I (MICAI'11, S. 382–393)*. Berlin, Heidelberg: Springer. Verfügbar unter [http://dx.doi.org/10.1007/978-3-642-25324-9\\_33](http://dx.doi.org/10.1007/978-3-642-25324-9_33)
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D. et al. (2014). Going Deeper with Convolutions. *CoRR*, *abs/1409.4842*.
- 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)
- Tangney, J. P., Miller, R. S., Flicker, L. & Barlow, D. H. (1996). Are shame, guilt, and embarrassment distinct emotions? *Journal of personality and social psychology*, 70 (6), 1256–1269.
- Teh, Y. W., Jordan, M. I., Beal, M. J. & Blei, D. M. (2006). Hierarchical Dirichlet Processes. *Journal of the American Statistical Association*, 101 (476), 1566–1581. <https://doi.org/10.1198/016214506000000302>
- Teuber, O. (1998). fasel beschreib erwähn – Der Inflektiv als Wortform des Deutschen. *Germanistische Linguistik* (141-142), 7–26.
- Ting, K. M. (2017). Confusion Matrix. In C. Sammut & G. Webb (Hrsg.), *Encyclopedia of Machine Learning and Data Mining* (S. 260). Boston, MA: Springer. [https://doi.org/10.1007/978-1-4899-7687-1\\_50](https://doi.org/10.1007/978-1-4899-7687-1_50)
- Titov, I. & McDonald, R. (2008). Modeling online reviews with multi-grain topic models. In J. Huai, R. Chen, H.-W. Hon, Y. Liu, W.-Y. Ma, A. Tomkins et al. (Hrsg.), *Proceeding of the 17th international conference* (S. 111).
- Tiwari, A. & Falk, T. H. (2019). Fusion of Motif- and Spectrum-Related Features for Improved EEG-Based Emotion Recognition. *Comp. Int. and Neurosc.*, 2019, 3076324:1-3076324:14. <https://doi.org/10.1155/2019/3076324>

- Tomkins, S. (1962). *Affect, imagery, consciousness. The Positive Affects* (Bd. 1). New York: Springer.
- Tomkins, S. (1963). *Affect, imagery, consciousness. The Negative Affects* (Bd. 2). New York: Springer.
- Tomkins, S. (1970). Affect as the primary motivational system. In M. Arnold (Ed.), *Feelings and Emotions. The Loyola Symposium* (pp. 101–110). Academic Press.
- Tomkins, S. (1984). Affect theory. In K. Scherer & P. Ekman (Eds.), *Approaches To Emotion* (pp. 163–195). Hoboken: Taylor and Francis.
- Tomkins, S. & Demos, V. (1995). *Exploring affect. The selected writings of Silvan S. Tomkins* (Studies in emotion and social interaction). Cambridge: Cambridge University Press; Editions de la Maison des Sciences de l'homme.
- Tong, E., Bishop, G., Enkelmann, H. C., Why, Y. P., Diong, S. M., Khader, M. et al. (2005). The use of ecological momentary assessment to test appraisal theories of emotion. *Emotion (Washington, D.C.)*, 5 (4), 508–512. <https://doi.org/10.1037/1528-3542.5.4.508>
- Traxel, W. & Heide, H. J. (1961). Dimensionen der Gefühle. *Psychologische Forschung*, 26 (3), 179–204. <https://doi.org/10.1007/BF00424647>
- Tripathi, S., Acharya, S., Sharma, R., Mittal, S. & Bhattacharya, S. (2017). *Using Deep and Convolutional Neural Networks for Accurate Emotion Classification on DEAP Dataset*. Verfügbar unter <https://aaai.org/ocs/index.php/IAAI/IAAI17/paper/view/15007>
- Tromp, E. (2012). *Multilingual Sentiment Analysis on Social Media. An Extensive Study on Multilingual Sentiment Analysis Performed on Three Different Social Media*. Saarbrücken: LAP LAMBERT Academic Publishing.
- Tsoumakas, G., Katakis, I. & Vlahavas, I. (2010). Mining Multi-label Data. In O. Maimon & L. Rokach (Hrsg.), *Data Mining and Knowledge Discovery Handbook* (S. 667–685). Boston, MA: Springer. [https://doi.org/10.1007/978-0-387-09823-4\\_34](https://doi.org/10.1007/978-0-387-09823-4_34)
- Tugade, M., Shiota, M. & Kirby, L. (2014). *Handbook of Positive Emotions*. New York: Guilford Publications.
- Turney, P. (2002). Thumbs up or thumbs down? In P. Isabelle (Hrsg.), *the 40th Annual Meeting* (S. 417).
- Turney, P. & Littman, M. (2002). *Unsupervised Learning of Semantic Orientation from a Hundred-Billion-Word Corpus*. Institute for Information Technology; National Research Council Canada.
- Turney, P. & Littman, M. (2003). Measuring praise and criticism. *ACM Transactions on Information Systems*, 21 (4), 315–346. <https://doi.org/10.1145/944012.944013>
- Turney, P. & Pantel, P. (2010). From Frequency to Meaning. Vector Space Models of Semantics. *CoRR*, *abs/1003.1141*.

- Ulich, D. (1982). *Das Gefühl. Eine Einführung in die Emotionspsychologie* (U & S Psychologie). München: Urban u. Schwarzenberg.
- Ulich, D. (2003). Ein persönlichkeitspsychologisches Modell der Entstehung von Gefühlszuständen. In D. Ulich & P. Mayring (Hrsg.), *Psychologie der Emotionen* (Grundriss der Psychologie, Bd. 5, 2., überarb. u. erw. Aufl., S. 84–117). Stuttgart: Kohlhammer.
- Ulich, D. & Mayring, P. (Hrsg.). (1992). *Psychologie der Emotionen*: Kohlhammer.
- Ulich, D. & Mayring, P. (Hrsg.). (2003). *Psychologie der Emotionen* (Grundriss der Psychologie, Bd. 5, 2., überarb. u. erw. Aufl.). Stuttgart: Kohlhammer.
- Unicode Consortium. (2017). *Unicode 10.0.0*. Zugriff am 30.09.2017. Verfügbar unter <http://unicode.org/versions/Unicode10.0.0/>
- Ustinova, E. & Lempitsky, V. (2016). Learning Deep Embeddings with Histogram Loss. *CoRR*, *abs/1611.00822*.
- Vaas, R. (2000). *Emotionen*. Zugriff am 20.07.2017. Verfügbar unter <http://www.spektrum.de/lexikon/neurowissenschaft/emotionen/3405>
- Valitutti, A., Strapparava, C. & Stock, O. (2004). Developing Affective Lexical Resources. *PsychNology Journal*, 2 (1), 61–83.
- Van Hee, C. (2017). *Can machines sense irony? Exploring automatic irony detection on social media*. Ghent University.
- Vashisht, G. & Thakur, S. (2014). Facebook as a Corpus for Emoticons-Based Sentiment Analysis. *International Journal of Emerging Technology and Advanced Engineering*, 2014 (Volume 4, Issue 5), 904–908. Verfügbar unter [http://www.ijetae.com/files/Volume4Issue5/IJETAE\\_0514\\_142.pdf](http://www.ijetae.com/files/Volume4Issue5/IJETAE_0514_142.pdf)
- Velikovich, L., Blair-Goldensohn, S., Hannan, K. & McDonald, R. (2010). The viability of web-derived polarity lexicons of the Association of Computational Linguistics, Proceedings, June 2-4, 2010, Los Angeles, California, USA. In *Human Language Technologies. Conference of the North American Chapter of the Association of Computational Linguistics, Proceedings, June 2-4, 2010, Los Angeles, California, USA* (S. 777–785). Association for Computational Linguistics. Verfügbar unter <http://www.aclweb.org/anthology/N10-1119>
- Vinodhini, G. & Chandrasekaran, R. M. (2012). Sentiment analysis and opinion mining: a survey. *International Journal*, 2 (6).
- Waltinger, U. (2010). GermanPolarityClues: A Lexical Resource for German Sentiment Analysis. In *Proceedings of the 7th International Conference on Language Resources and Evaluation (LREC)*. Valletta, Malta: electronic proceedings.
- Walz, G. (Hrsg.). (2017). *Lexikon der Mathematik. Sed bis Zyl* (Bd. 5, 2. Auflage, 5 Bände). Berlin: Springer Spektrum. <https://doi.org/10.1007/978-3-662-53506-6>
- Wan, L., Zeiler, M., Zhang, S., LeCun, Y. & Fergus, R. (2013). Regularization of Neural Networks Using Dropconnect. In *Proceedings of the 30th International Conference on*

- International Conference on Machine Learning - Volume 28 (ICML '13, III-1058-III-1066)*.  
JMLR.org. Verfügbar unter <http://dl.acm.org/citation.cfm?id=3042817.3043055>
- Wang, H., Raj, B. & Xing, E. (2017). On the Origin of Deep Learning. *CoRR*,  
*abs/1702.07800*.
- Wang, S. & Manning, C. (2012). Baselines and Bigrams: Simple, Good Sentiment and Topic Classification. In *Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics: Short Papers - Volume 2 (ACL '12, S. 90–94)*. Stroudsburg, PA, USA: Association for Computational Linguistics.
- Wang, Y., Feng, S., Wang, D., Yu, G. & Zhang, Y. (2016). Multi-label Chinese Microblog Emotion Classification via Convolutional Neural Network. In *Proceedings of the 18th Asia-Pacific Web Conference (S. 567–580)*.
- Wang, Y. & Pal, A. (2015). Detecting Emotions in Social Media. A Constrained Optimization Approach. In *Proceedings of the 24th International Conference on Artificial Intelligence (IJCAI '15, S. 996–1002)*. AAAI Press. Verfügbar unter <http://dl.acm.org/citation.cfm?id=2832249.2832387>
- Wang, Z., Chong, C. S., Lan, L., Yang, Y., Beng Ho, S. & Tong, J. C. (2016). Fine-grained sentiment analysis of social media with emotion sensing. In *2016 Future Technologies Conference (FTC) (S. 1361–1364)*. IEEE.
- Warriner, A. B., Kuperman, V. & Brysbaert, M. (2013). Norms of valence, arousal, and dominance for 13,915 English lemmas. *Behavior research methods*, 45 (4), 1191–1207.  
<https://doi.org/10.3758/s13428-012-0314-x>
- Watson, D., Clark, L. A. & Tellegen, A. (1988). Development and validation of brief measures of positive and negative affect. The PANAS scales. *Journal of personality and social psychology*, 54 (6), 1063–1070.
- Watson, D. & Tellegen, A. (1985). Toward a consensual structure of mood. *Psychological bulletin*, 98 (2), 219–235.
- Weitz, F. (2013). *Die acht elementaren Gefühle nach Plutchik*. Zugriff am 07.08.2014.
- Weller, S. & Romney, A. K. (1988). *Systematic data collection (Qualitative research methods, Bd. 10)*. Newbury Park Calif. u.a.: SAGE Publications.
- Whissell, C. (1989). The dictionary of affect in language. In *The Measurement of Emotions (S. 113–131)*. Elsevier. <https://doi.org/10.1016/B978-0-12-558704-4.50011-6>
- Whissell, C. (2009). Using the Revised Dictionary of Affect in Language to quantify the emotional undertones of samples of natural language. *Psychological reports*, 105 (2), 509–521.  
<https://doi.org/10.2466/PRO.105.2.509-521>
- Wiebe, J. (2000). Learning Subjective Adjectives from Corpora. In *Proceedings of the 17th National Conference on Artificial Intelligence and Twelfth Conference on Innovative*

- Applications of Artificial Intelligence* (S. 735–740). AAAI Press. Verfügbar unter <http://dl.acm.org/citation.cfm?id=647288.721121>
- Wiebe, J., Bruce, R. & O'Hara, T. (1999). Development and Use of a Gold-standard Data Set for Subjectivity Classifications. In *Proceedings of the 37th Annual Meeting of the Association for Computational Linguistics on Computational Linguistics* (ACL '99, S. 246–253). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dx.doi.org/10.3115/1034678.1034721>
- Wiebe, J., Wilson, T. & Bell, M. (2001). Identifying Collocations for Recognizing Opinions. In *Proceedings of the ACL/EACL Workshop on Collocation: Computational Extraction, Analysis, and Exploitation* .
- Wiebe, J., Wilson, T. & Cardie, C. (2005). Annotating Expressions of Opinions and Emotions in Language. *Language Resources and Evaluation*, 39 (2-3), 165–210. <https://doi.org/10.1007/s10579-005-7880-9>
- Wiegand, M., Balahur, A., Roth, B., Klakow, D. & Montoyo, A. (2010). A Survey on the Role of Negation in Sentiment Analysis. In *Proceedings of the Workshop on Negation and Speculation in Natural Language Processing* (NeSp-NLP '10, S. 60–68). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dl.acm.org/citation.cfm?id=1858959.1858970>
- Wilcoxon, F. (1945). Individual Comparisons by Ranking Methods. *Biometrics Bulletin*, 1 (6), 80. <https://doi.org/10.2307/3001968>
- Wilson, T., Wiebe, J. & Hoffmann, P. (2005). Recognizing Contextual Polarity in Phrase-level Sentiment Analysis. In *Proceedings of the Conference on Human Language Technology and Empirical Methods in Natural Language Processing* (HLT '05, S. 347–354). Stroudsburg, PA, USA: Association for Computational Linguistics. Verfügbar unter <http://dx.doi.org/10.3115/1220575.1220619>
- Wilson, T., Wiebe, J. & Hoffmann, P. (2009). Recognizing Contextual Polarity: An Exploration of Features for Phrase-Level Sentiment Analysis. *Computational Linguistics*, 35 (3), 399–433. <https://doi.org/10.1162/coli.08-012-R1-06-90>
- Wirtz, M. A. (Hrsg.). (2017). *Dorsch - Lexikon der Psychologie* (18., überarbeitete Auflage). Bern: Hogrefe.
- Witten, I., Frank, E. & Hall, M. (2011). *Data mining. Practical machine learning tools and techniques* (3rd ed.).
- Xia, R., Zong, C., Hu, X. & Cambria, E. (2013). Feature Ensemble Plus Sample Selection: Domain Adaptation for Sentiment Classification. *Intelligent Systems, IEEE*, 28 (3), 10–18. <https://doi.org/10.1109/MIS.2013.27>
- Xu, B., Wang, N., Chen, T. & Li, M. (2015). Empirical Evaluation of Rectified Activations in Convolutional Network. *CoRR*, [abs/1505.00853](https://arxiv.org/abs/1505.00853).

- Xu, Y., Ke, D. & Su, K. (2017). Contextualized Latent Semantic Indexing. A New Approach to Automated Chinese Essay Scoring. *Journal of Intelligent Systems*, 26 (2), 359.  
<https://doi.org/10.1515/jisys-2015-0048>
- Yaghoobzadeh, Y. & Schütze, H. (2017). Multi-level Representations for Fine-Grained Typing of Knowledge Base Entities. *CoRR*, *abs/1701.02025*.
- Yan, X., Guo, J., Lan, Y. & Cheng, X. (2013). A biterm topic model for short texts. In D. Schwabe, V. Almeida, H. Glaser, R. Baeza-Yates & S. Moon (Hrsg.), *Proceedings of the 22nd international conference on World Wide Web - WWW '13* (S. 1445–1456). New York, New York, USA: ACM.
- Yang, J. (2017). *SUTDAnnotator. An efficient human annotation tool for text*, Singapore University of Technology and Design. Zugriff am 30.07.2017. Verfügbar unter <https://github.com/jiesutd/SUTDAnnotator>
- Yang, Y. (1999). An Evaluation of Statistical Approaches to Text Categorization. *Information Retrieval*, 1 (1), 69–90. <https://doi.org/10.1023/A:1009982220290>
- Yao, Y., Rosasco, L. & Caponnetto, A. (2007). On Early Stopping in Gradient Descent Learning. *Constructive Approximation*, 26 (2), 289–315. <https://doi.org/10.1007/s00365-006-0663-2>
- Yenigalla, P., Kumar, A., Tripathi, S., Singh, C., Kar, S. & Vepa, J. (2018). Speech Emotion Recognition Using Spectrogram & Phoneme Embedding. In *Interspeech. 19th Annual Conference of the International Speech Communication Association* (S. 3688–3692).
- Yi, J., Nasukawa, T., Bunescu, R. & Niblack, W. (2003). Sentiment analyzer: extracting sentiments about a given topic using natural language processing techniques. In *Proceedings of the 3rd IEEE International Conference on Data Mining* (S. 427–434).
- Yin, W. & Schütze, H. (2015). Learning Word Meta-Embeddings by Using Ensembles of Embedding Sets. *CoRR*, *abs/1508.04257*.
- Yin, W., Schütze, H., Xiang, B. & Zhou, B. (2016). ABCNN. Attention-Based Convolutional Neural Network for Modeling Sentence Pairs. *Transactions of the Association for Computational Linguistics*, 4, 259–272. Verfügbar unter <https://tacl2013.cs.columbia.edu/ojs/index.php/tacl/article/view/831>
- Yoon, S.-a., Son, G. & Kwon, S. (2019). Fear emotion classification in speech by acoustic and behavioral cues. *Multimedia Tools Appl*, 78 (2), 2345–2366.  
<https://doi.org/10.1007/s11042-018-6329-2>
- You, Y.-D. (2001). *Das flow-Erlebnis und seine empirischen Implikationen für die Psychotherapie*: Herbert Utz Verlag.
- Yu, H. & Hatzivassiloglou, V. (2003). Towards answering opinion questions, 129–136.  
<https://doi.org/10.3115/1119355.1119372>

- Zagibalov, T. & Carroll, J. (2008). Automatic Seed Word Selection for Unsupervised Sentiment Classification of Chinese Text. In *Proceedings of the 22nd International Conference on Computational Linguistics (Coling 2008)* (S. 1073–1080). Manchester, UK: Coling 2008 Organizing Committee. Verfügbar unter <http://www.aclweb.org/anthology/C08-1135>
- Zajonc, R. (1980). Feeling and thinking. Preferences need no inferences. *American Psychologist*, 35 (2), 151–175. <https://doi.org/10.1037/0003-066X.35.2.151>
- Zajonc, R. (1984). On the primacy of affect. *American Psychologist*, 39 (2), 117–123. <https://doi.org/10.1037/0003-066X.39.2.117>
- Zeiler, M. (2012). ADADELTA. An Adaptive Learning Rate Method. *CoRR*, *abs/1212.5701*.
- Zeiler, M. & Fergus, R. (2013). Stochastic Pooling for Regularization of Deep Convolutional Neural Networks. *CoRR*, *abs/1301.3557*.
- Zesch, T., Müller, C. & Gurevych, I. (2008a). Extracting Lexical Semantic Knowledge from Wikipedia and Wiktionary. In *Proceedings of the International Conference on Language Resources and Evaluation, LREC 2008, 26 May - 1 June 2008, Marrakech, Morocco*.
- Zesch, T., Müller, C. & Gurevych, I. (2008b). Using Wiktionary for Computing Semantic Relatedness. In *Proceedings of the Twenty-Third AAAI Conference on Artificial Intelligence, AAAI 2008, Chicago, Illinois, USA, July 13-17, 2008* (S. 861–866).
- Zhai, C. (2009). *Statistical Language Models for Information Retrieval* (Synthesis lectures on human language technologies, #1). San Rafael: Morgan & Claypool.
- Zhang, B., Provost, E. M. & Essl, G. (2019). Cross-Corpus Acoustic Emotion Recognition with Multi-Task Learning: Seeking Common Ground While Preserving Differences. *IEEE Trans. Affective Computing*, 10 (1), 85–99. <https://doi.org/10.1109/TAFFC.2017.2684799>
- Zhang, F., Meng, H. & Li, M. (2016). Emotion extraction and recognition from music. In *2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)* (S. 1728–1733). IEEE.
- Zhang, K., Zhang, H., Li, S., Yang, C.-y. & Sun, L. (2018). The PMEmo Dataset for Music Emotion Recognition. In *Proceedings of the 2018 ACM on International Conference on Multimedia Retrieval* (S. 135–142).
- Zhang, X., Trmal, J., Povey, D. & Khudanpur, S. (2014). Improving deep neural network acoustic models using generalized maxout networks. In *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (S. 215–219). IEEE.
- Zhang, Y. & Wallace, B. (2015). A Sensitivity Analysis of (and Practitioners' Guide to) Convolutional Neural Networks for Sentence Classification. *CoRR*.
- Zhang, Y., Ji, D.-H., Su, Y. & Wu, H. (2013). Joint Naïve Bayes and LDA for Unsupervised Sentiment Analysis. In J. Pei, V. Tseng, L. Cao, H. Motoda & G. Xu (Hrsg.), *Advances in Knowledge Discovery and Data Mining* (Lecture Notes in Computer Science, Bd. 7818, S. 402–413). Springer. [https://doi.org/10.1007/978-3-642-37453-1\\_33](https://doi.org/10.1007/978-3-642-37453-1_33)

- Zhao, S., Gholaminejad, A., Ding, G., Gao, Y., Han, J. & Keutzer, K. (2019). Personalized Emotion Recognition by Personality-Aware High-Order Learning of Physiological Signals. *TOMCCAP*, 15 (1s), 14:1-14:18. <https://doi.org/10.1145/3233184>
- Zhekova, D. (2013). *Towards Multilingual Coreference Resolution*. Dissertation. Universität Bremen, Bremen. Zugriff am 24.05.2016. Verfügbar unter <http://elib.suub.uni-bremen.de/edocs/00103541-1.pdf>
- Zhou, D., Bousquet, O., Lal, T. N., Weston, J. & Schölkopf, B. (2004). Learning with Local and Global Consistency Processing Systems, NIPS 2003, December 8-13, 2003, Vancouver and Whistler, British Columbia, Canada]. In S. Thrun, L. Saul & B. Schölkopf (Hrsg.), *Advances in Neural Information Processing Systems 16 [Neural Information Processing Systems, NIPS 2003, December 8-13, 2003, Vancouver and Whistler, British Columbia, Canada]* (S. 321–328). MIT Press. Verfügbar unter <http://papers.nips.cc/paper/2506-learning-with-local-and-global-consistency>
- Zhu, X. & Ghahramani, Z. (2002). Learning from labeled and unlabeled data with label propagation.
- Zhu, X., Ghahramani, Z. & Lafferty, J. (2003). Semi-supervised Learning Using Gaussian Fields and Harmonic Functions. In *Proceedings of the Twentieth International Conference on International Conference on Machine Learning (ICML '03, S. 912–919)*. AAAI Press. Verfügbar unter <http://dl.acm.org/citation.cfm?id=3041838.3041953>
- Ziai, R. & Ott, N. (2014). *RFTagger Java Interface*. Zugriff am 25.12.2017. Verfügbar unter <http://sifnos.sfs.uni-tuebingen.de/resource/A4/rftj/>
- Zou, H. & Hastie, T. (2005). Regularization and Variable Selection via the Elastic Net. *Journal of the Royal Statistical Society. Series B (Statistical Methodology)*, 67 (2), 301–320. Verfügbar unter <http://www.jstor.org/stable/3647580>

## **Eidesstattliche Erklärung**

Hiermit versichere ich an Eides statt, dass ich die vorliegende Dissertation „Emotionserkennung bei Nachrichtencommentaren mittels Convolutional Neural Networks und Label Propagationsverfahren“ selbstständig angefertigt habe, mich außer der angegebenen keiner weiteren Hilfsmittel bedient und alle Erkenntnisse, die aus dem Schrifttum ganz oder annähernd übernommen sind, als solche kenntlich gemacht und nach ihrer Herkunft unter Bezeichnung der Fundstelle einzeln nachgewiesen habe.

München, den 10.12.2019

Andreas Aschenbrenner

---

Unterschrift