

# Zusammenhang von Twitter-Stimmung und DAX: DAX-Vorhersage mit Twitter?

DISSERTATION

zur Erlangung des Grades eines Doktors

rer. pol.

der Fakultät III – Wirtschaftswissenschaften, Wirtschaftsinformatik  
und Wirtschaftsrecht der Universität Siegen

vorgelegt von

Julian Schröter, M. Sc.

Erstgutachter: Univ.-Prof. Dr. Jan Franke-Viebach

Zweitgutachter: Univ.-Prof. Dr. Ralf Runde

Dekan der Fakultät III: Univ.-Prof. Dr. Volker Wulf

# Inhaltsverzeichnis

<b>Danksagung</b>	<b>III</b>
<b>Abbildungsverzeichnis</b>	<b>IV</b>
<b>Tabellenverzeichnis</b>	<b>V</b>
<b>Symbolverzeichnis</b>	<b>VI</b>
<b>1 Einleitung</b>	<b>1</b>
1.1 Soziale Medien und die Wirtschaft .....	1
1.2 Stand der Forschung .....	1
1.3 Motivation und Vorgehen .....	2
<b>2 Theoretischer Hintergrund</b>	<b>7</b>
2.1 Schwierigkeiten bei der Stimmungsanalyse von Tweets .....	7
2.2 Zusammenhänge mit dem DAX .....	8
2.3 Methoden der Stimmungsanalyse .....	12
2.4 Stimmungslexika .....	15
2.5 Vorhersagekraft von Stimmungsparametern .....	17
2.6 Falschnachrichten und Aktienkurse .....	20
2.7 Untersuchungsmodell und Hypothesen .....	22
<b>3 Methode</b>	<b>25</b>
3.1 Stichprobe und Stimmungsextraktion .....	25
3.2 Unterschiede, Zusammenhänge und Ähnlichkeiten .....	27
3.3 Vorhersagemodell .....	32
3.4 Optimales Verfahren .....	38
3.5 Computerprogramme .....	40
<b>4 Ergebnis</b>	<b>41</b>
4.1 Gesamtstimmungen .....	41
4.2 Themenstimmungen .....	42
4.3 Nutzerstimmungen .....	51
<b>5 Diskussion</b>	<b>57</b>
5.1 Relevanz der Gesamt- und Themenstimmung .....	57
5.2 Optimierung .....	62
5.3 Limitationen .....	68
5.4 Zukünftige Forschung .....	71
<b>Literaturverzeichnis</b>	<b>75</b>
<b>Anhangsverzeichnis</b>	<b>90</b>

## Danksagung

Ich bedanke mich bei Herrn Univ.-Prof. Dr. Jan Franke-Viebach, der es mir ermöglichte, meine Dissertation in seinem Fachgebiet zu erstellen sowie für seine bereichernden Anregungen im Rahmen der Betreuung.

Herrn Univ.-Prof. Dr. Ralf Runde danke ich besonders für die statistische und fachliche Bewertung sowie für seine Tätigkeit als Zweitgutachter.

Ich bedanke mich bei Herrn Univ.-Prof. Dr. Andreas Dutzi für seine konstruktiven Ratschläge und für seine Unterstützung sowie für die Forschungs Kooperation zur sozialen Netzwerkanalyse.

Mein besonderer Dank gilt Herrn Dr. Patrick Winter für seine technischen Anregungen und Hinweise, die mir bei der Erstellung dieser Arbeit eine große Hilfe waren.

Mein ausdrücklicher Dank gilt Frau Dr. Christine Hensoldt für ihre menschliche Unterstützung sowie ihre wertvollen Anregungen, insbesondere während der Endphase dieser Arbeit.

## Abbildungsverzeichnis

Abbildung 1.1: Schritte der Analyse .....	3
Abbildung 3.1: Stimmungszahlen der Stammformen des deutschen Lexikons .....	26
Abbildung 3.2: Überblick der statistischen Methoden .....	27
Abbildung 3.3: Untersuchungsanordnung .....	29
Abbildung 3.4: Vereinfachte Architektur eines neuronalen Netzes .....	33
Abbildung 3.5: Hyperbeltangens .....	35
Abbildung 3.6: Grenzwertoptimierungskurve .....	37
Abbildung 3.7: Serielle Kombination von Algorithmen .....	39
Abbildung 4.1: Anzahl deutscher Tweets der drei Themen nach Uhrzeit .....	43
Abbildung 4.2: Zusammenhang zwischen DAX und deutscher Politikstimmung .....	50
Abbildung 4.3: DAX und deutsche Politikstimmung nach Datum .....	50
Abbildung 4.4: Optimierung der Vorhersagen mit Nutzerstimmungen .....	56
Abbildung 5.1: Kreuzentropiefehler je Modell .....	66

## Tabellenverzeichnis

Tabelle 3.1: Anzahl positiver und negativer Wörter im englischen Lexikon .....	26
Tabelle 3.2: Statistische Methoden zur Datenanalyse .....	28
Tabelle 3.3: Kombinationsmöglichkeiten binärer Variablen .....	31
Tabelle 3.4: Wahrheitsmatrix .....	37
Tabelle 3.5: Richtwerte zur Bewertung des neuronalen Netzes .....	38
Tabelle 4.1: Korrelation DAX und deutsche Stimmung .....	41
Tabelle 4.2: Anzahl Tweets pro Thema .....	42
Tabelle 4.3: Beispiele deutscher Tweets .....	43
Tabelle 4.4 Stimmungen nach Wochentagen .....	45
Tabelle 4.5: Übersicht signifikanter Korrelationen .....	47
Tabelle 4.6: Korrelation deutscher Stimmung und Streuung der Stimmung .....	47
Tabelle 4.7: M-Koeffizienten des DAX und deutsche DAX-Stimmung .....	48
Tabelle 4.8: M-Koeffizienten des DAX und deutsche Wirtschaftsstimmung .....	48
Tabelle 4.9: M-Koeffizienten des DAX und deutsche Politikstimmung .....	49
Tabelle 4.10: Kreuztabelle des DAX und deutscher Stimmungen .....	49
Tabelle 4.11: Chi-Quadrat-Tests deutscher Stimmungen .....	49
Tabelle 4.12: Nutzer mit höchster Aktivität deutscher DAX- und Wirtschafts-Tweets ...	52
Tabelle 4.13: Nutzer mit höchster Aktivität deutscher Politik- und englischer DAX- Tweets .....	53
Tabelle 4.14: Nutzer mit höchster Aktivität mit signifikantem Zusammenhang zum DAX .....	54
Tabelle 4.15: Übersicht möglicher Korrelationen aller Nutzer .....	55
Tabelle 5.1: Wichtigkeit nach Nutzern .....	67
Tabelle 5.2: Quellen der Tweets .....	70
Tabelle 5.3: Weitere erwähnte Themen in der Stichprobe .....	71

## Symbolverzeichnis

$\lambda$	Gewichtungsfaktor
b	Mindestabstand
c	Klasse
d	Aktivierungsfunktion
E	Fehlerfunktion
g	Themenstimmung
h	Tweet
i, j, k	Laufvariablen
l	Klasse
n	Anzahl der Neuronen
p	Soll-Ausgabe
P	Wahrscheinlichkeit
r	Korrelationskoeffizient
S	M-Koeffizient
s	Signifikanz des Korrelationskoeffizienten
t	Zeit
u	Anzahl der täglichen Stimmungen
v, w	Vektoren der synaptischen Gewichte
z	Eigenschaft

# 1 Einleitung

Dieses Kapitel beschreibt die Relevanz sozialer Medien für die Wirtschaft und den DAX. Der Stand der Forschung zur Stimmungsanalyse wird dargestellt und die Ziele sowie das Vorgehen der Arbeit werden erörtert.

## 1.1 Soziale Medien und die Wirtschaft

Das Interesse an Stimmungsanalysen in der internationalen Forschungsgemeinschaft besteht seit etwa 2002 (Martínez-Cámara et al., 2014, S. 2). Twitter ist ein soziales Netzwerk, in dem Kurznachrichten bis 140 Zeichen, den sogenannten Tweets, erstellt und geteilt werden (Meeder et al., 2010, S. 2). Twitter ist mit 40 Millionen Besuchern im Dezember 2014, nach Facebook und Google+, das drittgrößte soziale Netzwerk in Deutschland (Statista GmbH, 2015). Es hatte im 1. Quartal 2018 ca. 336 Millionen aktive Nutzer (Statista GmbH, 2018). Twitter enthält aktuelle Stimmungen, transportiert über Informationen und Ereignisse. Über Twitter verbreitete Informationen können signifikante Auswirkungen auf die Wirtschaft haben. Das Tweet „Eilmeldung: Zwei Explosionen im Weißen Haus und Barack Obama ist verletzt“ wurde von einem gekaperten Twitter-Konto einer Presseagentur veröffentlicht und führte innerhalb von drei Minuten zu einem Kursrückgang des amerikanischen Aktienindexes Standard & Poor's 500 um 140 Punkte (Xu et al., 2014, S. 132).

## 1.2 Stand der Forschung

Bei der Forschung zu Anomalien bei Aktienkursen wurden vielfältige Zusammenhänge, unter anderem zum Wetter (Krämer et al., 1997, S. 637f) und zu Wochentagen untersucht. Es konnte ein Montags- und Wochenendeffekt nachgewiesen werden, allerdings kein Zusammenhang zum Wetter. Mit dem Aufkommen neuer Medien richtet sich der Fokus auf Zusammenhänge mit Daten aus sozialen Netzwerken. Twitter enthält relevante und neue Signale zur Investorenstimmung (Oliveira et al., 2013, S. 5) und hat sich zu einer lebendigen Internetplattform für den Austausch börsenbezogener Informationen entwickelt (Sprenger et al., 2010, S. 949). Die Stimmung aus Tweets enthält Informationen, die im Moment der Veröffentlichung noch nicht im Markt eingepreist sind. Eine Nutzung dieser Informationen könnte erhebliche Wettbewerbsvorteile bedeuten. Das Kaufverhalten und die Dynamik im Markt könnten verändert werden. Verhaltensökonomien bestätigen einen Zusammenhang zwischen der Stimmung der Menschen und

ihrem Kaufverhalten. Bollen et al. (2011b, S. 6) sagten den Verlauf eines amerikanischen Aktienindex durch Twitter-Stimmung mit einer Genauigkeit von 87% voraus. Stimmungsanalysen verbessern die finanziellen Entscheidungen und das Verständnis von Marktbewegungen, indem sie Texte aus dem Internet berücksichtigten (Nassirtoussi et al., 2014, S. 7667f).

Auch Stimmungen in Finanznachrichten wurden extrahiert, die von diversen Nachrichtenquellen zusammengefasst wurden (Nagar et al., 2012, S. 92). So folgte auf ein Maximum des Apple-Kurses nach zwei Tagen ebenfalls ein Maximum der Stimmungen in Apple-Nachrichten (Nagar et al., 2012, S. 94). Folglich ist die Stimmung in den Apple-Nachrichten eine Reaktion auf den sinkenden Aktienkurs, da Nachrichten grundsätzlich Ereignisse im Nachhinein beschreiben. Dementsprechend manifestiert sich die negative Stimmung in den Nachrichten zwei Tage nach Fall des Aktienkurses (Nagar et al. 2012, S. 94). Bei der Analyse von Zusammenhängen wird gemäß dieser Beobachtung in der aktuellen Forschung der Vorlauf in Tagen zwischen dem Ereignis und der darauffolgenden Stimmung bei der Analyse von Zusammenhängen berücksichtigt. Bollen et al. (2011b, S. 6) konnten durch Stimmungen in neun Millionen Tweets die Auf- und Abwärtsbewegung des Schlusskurses eines amerikanischen Aktienindex mit einer Genauigkeit von 87% vorhersagen. Gemäß den Autoren könnten sich Stimmungen signifikant auf die Entscheidungsfindung auswirken. Die beschriebenen Studien konzentrieren sich allerdings auf Stimmungsanalysen von englischen Tweets. So ist die Twitter-Stimmung mit Hilfe von deutschen Stimmungslexika bisher unzureichend analysiert worden (Reuter et al., 2015, S. 35). So hat Nofer (2015) in der bisher umfangreichsten deutschen Twitter-Studie keinen Zusammenhang zwischen dem Deutschen Aktienindex (DAX) und der Stimmung in deutschen Tweets feststellen können. In jener Studie wurde die Gesamtstimmung der Tweets berücksichtigt, ohne sie jedoch aufzuschlüsseln.

### 1.3 Motivation und Vorgehen

Ziel der vorliegenden Arbeit ist die Vorhersage des DAX mit Hilfe von Nutzerstimmungen. Hierfür wird ein neues Modellbildungsverfahren zur Kursvorhersage entwickelt, welches vorausgelagerte Stimmungen auswählt, um die Komplexität für die Vorhersage zu reduzieren. Dies ist erforderlich, da eine Vorhersage mit Gesamt- und Themenstimmung unzureichend ist. Schließlich sollen die Stimmungen aller Nutzer berücksichtigt werden, welches allerdings einer zu hohen Anzahl entspricht und aufgrund technischer Restriktionen nicht möglich ist. Um dieser Problematik zu begegnen, wählt das neue Verfahren geeignete Stimmungen aus.

Die Aussagekraft von Stimmungen für Börsenkurse wurde vielfach untersucht, gezeigt in Tabelle A, Seite 91. Entsprechende Analysen verlaufen grob in 3 Schritten, siehe Abbildung 1.1:

1. Ableitung von (Gesamt-)Stimmungen aus Texten.
2. Ermittlung des Zusammenhangs zwischen Stimmungen und Kursen.
3. Vorhersage des Kurses anhand des gefundenen Zusammenhangs.

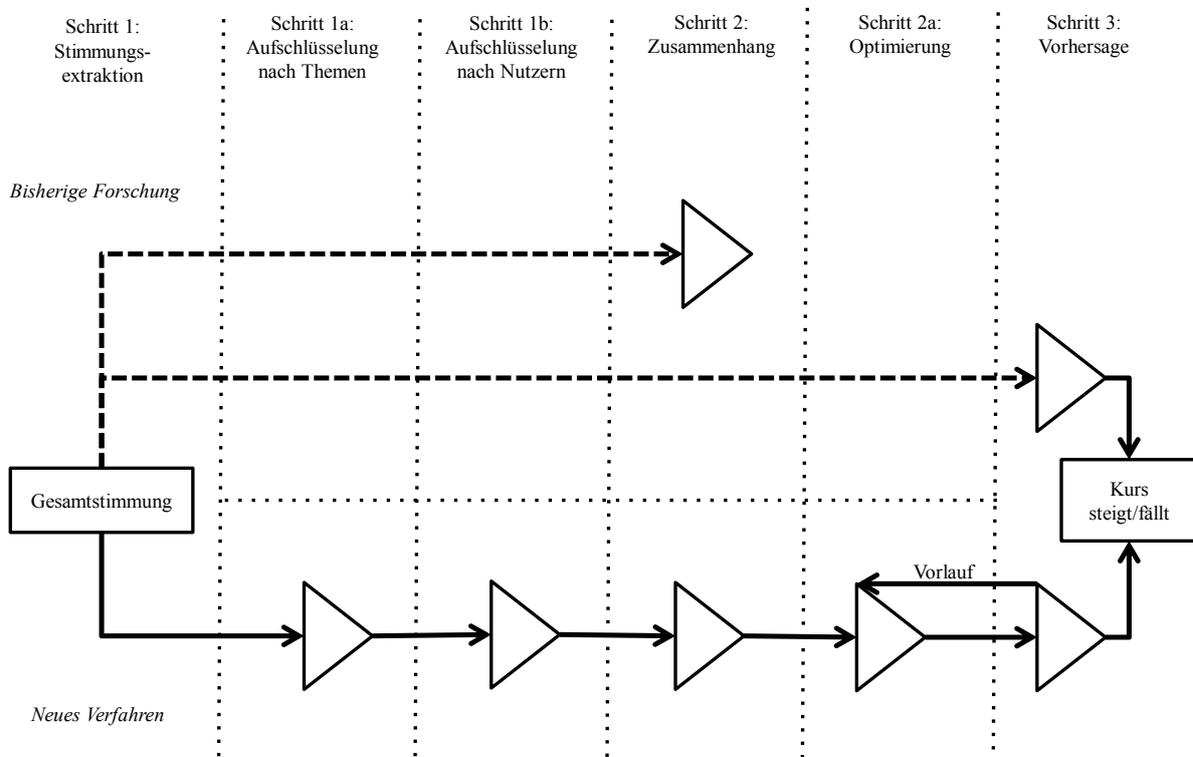


Abbildung 1.1: Schritte der Analyse

Quelle: Eigene Darstellung

Bei allen drei Schritten wurden diverse Methoden erprobt. Bei Schritt 1 werden die vorliegenden Texte in der Regel schlicht segmentiert und Worthäufigkeiten berechnet. Bei Schritt 2 reicht das Methodenspektrum von einfachen Kennzahlen wie Distanzmaßen über Korrelations- und Regressionsanalysen bis hin zu fortgeschrittenen Methoden wie die vektorautoregressiven Modelle und die Monte-Carlo-Simulation. Auch für Schritt 3 wurden häufig fortgeschrittene Methoden verwendet, unter anderem die Stützvektormaschine und die Bayes-Klassifikation, teilweise aber auch eine subjektive Klassifikation durch Menschen. Die Klassifikation wurde sowohl bei der Stimmungsextraktion verwendet (das heißt, es wurde danach unterschieden, ob ein Wort oder Satz positiv oder negativ ist – dies entspricht zwei Klassen) als auch bei der Vorhersage eines steigenden oder fallenden Kurses (dies entspricht ebenfalls zwei Klassen). Eine Klassifikation von Stimmungswörtern ist nicht notwendig, da auf bereits bestehende Stimmungsexikla zurückgegriffen wird. Die eigentliche Klassifikation bezieht sich auf die Vorhersage der beiden Klassen des DAX in Steigen und Fallen.

Dem ersten Schritt wurde im Vergleich zu den folgenden bislang geringe Aufmerksamkeit geschenkt. Ein Grund mag sein, dass bei der Ableitung von Stimmungen aus Texten kaum bessere

Methoden als die genannten existieren, da es – im Gegensatz zu den folgenden Schritten – kein eindeutiges „richtig“ oder „falsch“, ja, kaum ein objektives „besser“ oder „schlechter“ gibt. Jedoch ist der erste Schritt von größter Bedeutung, denn nachgelagerte Methoden können nur so gute Ergebnisse erzielen, wie ihre Datengrundlage es erlaubt.

Zur Verbesserung der Vorhersagekraft bietet es sich demgemäß am ehesten an, bei Schritt 1 anzusetzen. Es wird vorgeschlagen, zwischen Schritt 1 und 2 weitere Schritte einzuführen: In Zwischenschritt 1a wird die ermittelte Gesamtstimmung nach Themen aufgeschlüsselt. In Zwischenschritt 1b wird die aufgeschlüsselte Themenstimmung nach Nutzern aufgeschlüsselt. Dies ist erforderlich, da ein und derselbe Nutzer zu unterschiedlichen Themen Tweets schreiben und demgemäß auch zu unterschiedlichen Themen potentiell unterschiedliche Stimmungen verbreiten kann. So wird ein thematischer Zusammenhang hergestellt. Dieser Ansatz verfolgt drei Ziele: Die Stimmungsreinheit innerhalb jedes Themas soll erhöht werden. Die nachgelagerten Methoden aus Schritt 2 und 3 sollen auf die einzelnen Nutzer, nicht auf die Gesamtstimmung angewandt werden, was zu detaillierteren Ergebnissen führt. Die Nutzerstimmungen können miteinander verglichen werden und schließlich in unterschiedlicher Kombination zu einem Gesamtergebnis zusammengesetzt werden, je nachdem, wie aussagekräftig sie sind. Aus dem letzteren Punkt wird ersichtlich, dass die Einführung der Zwischenschritte 1a und 1b die Einführung eines – entgegengesetzt gerichteten – neuen Schrittes 2a notwendig machen: Nachdem die Schritte 1 bis 2 für die Nutzer angewendet worden sind, muss eine Vorhersage dieser Nutzerstimmungen erfolgen, jedoch nicht auf Stimmungs-, sondern auf Ergebnisebene. Ein neuronales Netz sagt die beiden Klassen Steigen und Fallen des DAX voraus. Anhand der Stimmungen und deren komplexer Kombination wird ein Muster erkannt, welches entweder als Steigen (Klasse 1) oder als Fallen (Klasse 2) gedeutet wird.

Die Vorhersage des DAX-Kurses wird mit Hilfe von Stimmungsaufschlüsselungen auf Nutzerebene verbessert. Somit ist der Beitrag dieser Arbeit, die Nutzerstimmungen als Eingangsvariablen für das neuronale Netz zu optimieren. Die bisherige Forschung berücksichtigte lediglich die Gesamtstimmung zur Kursvorhersage. Der hier vorgeschlagene Ansatz hingegen hat die Aufschlüsselung nach Themen und anschließend nach Nutzern zum Ziel. Wenn die Nutzerstimmungen aufgeschlüsselt sind, werden sie durch eine vorgelagerte Methode ausgewählt und an das Vorhersagemodell weitergeleitet. Deshalb werden die relevanten Signale herausgefiltert. Dies setzt allerdings voraus, dass die richtigen Signale zunächst gefunden werden müssen. Demgemäß werden in allen Tweets durch Themen- und Nutzeraufschlüsselung nach glaubwürdigen Nutzern gesucht. Anschließend werden die Einzelstimmungen zusammengefügt, um eine

Gesamtaussage zu erhalten. Die Arbeit konzentriert und damit beschränkt sich auf Aufschlüsselung und auf die anschließende Vorhersage der daraus abgeleiteten Stimmungen. Dies bedeutet, es werden zwei hierarchisch aufgebaute Aufschlüsselungen durchgeführt, zum einen bezogen auf die Thematik und anschließend bezogen auf die Nutzer.

Zunächst ist festzustellen, ob sich eine Aussage, die eine Stimmung enthält, direkt auf den betrachteten Börsentitel bezieht. Ob die Aussage eine Kursveränderung ankündigt, oder auf Themen Bezug nimmt, welche die Kursentwicklung indirekt betreffen können. Themen, wie Politik und Wirtschaft. Für diese Themen wurden Zusammenhänge mit Börsenkursen nachgewiesen. Dies wird in Kapitel 2.2 beschrieben. Die Vermutung liegt nahe, dass dies auch für entsprechende Stimmungen gilt. Fraglich ist aber, ob solche Stimmungen tatsächlich zwischen den unterschiedlichen Themen vermischt werden können. Aus diesem Grund werden die Analysen dieser Arbeit für jedes Thema separat durchgeführt und die Ergebnisse miteinander verglichen. Diese Themenstimmungen werden im Anschluss weiter aufgeschlüsselt. Es wird geprüft, ob entsprechende Aussagen in der Sprache des betrachteten Titels – im vorliegenden Fall Deutsch – oder in einer anderen Sprache – hier Englisch – verfasst worden sind. Dieses Vorgehen wird begründet mit der Tatsache, dass die Auswertung von Stimmungen in Abhängigkeit von der Sprache zu unterschiedlichen Ergebnissen führt, weil englische Tweets mit Hilfe eines anderen Stimmungslexikons gemessen werden als deutsche.

Die zweite Aufschlüsselung findet auf der Ebene der einzelnen Marktteilnehmer statt. Sie besteht in der Messung der Zuverlässigkeit des potenziellen Investors, von dem eine Stimmung stammt. Diese ist eine Funktion davon, wie realistisch – und damit aussagekräftig für eine Analyse – die Einschätzungen des Investors sind. Obwohl diese Information eine hohe Relevanz besitzt, wurde sie in bisherigen Studien kaum verwertet. Der wesentliche Grund könnte sein, dass es technisch nicht einfach ist, die aufgeschlüsselten Daten am Ende wieder so zu zusammenzufügen, dass die Informationen, abgeleitet aus den aufgeschlüsselten Stimmungen, enthalten sind. Diese Aufgabe der Vorhersage stellt den dritten Kern der vorliegenden Arbeit dar. Für das neue Verfahren mit vorheriger Aufschlüsselung ist es erforderlich, Zusammenhänge auf Nutzerebene zwischen Stimmungen in Tweets und dem DAX zu prüfen. Hierbei werden die Themen Politik, Wirtschaft und DAX mit den entsprechenden Nutzern berücksichtigt. Um Verzerrungen durch Tagesereignisse zu vermeiden, werden Stimmungen eines halben Jahres analysiert. Fraglich ist, ob es zeitlich differenzierte Zusammenhänge zwischen den Tweets und dem DAX gibt. Hierfür werden Zusammenhänge mit einem Vorlauf von bis zu sieben Tagen in die Vergangenheit untersucht. Die Stimmungen werden mit validierten Stimmungslexika extrahiert. Hiermit können die Eigenheiten der Sprache berücksichtigt werden.

Problematisch ist, dass ohne Aufschlüsselung der Gesamtstimmung kein Zusammenhang zwischen Twitter-Stimmung und dem DAX-Kurs feststellbar ist (Nofer, 2015, S. 63). Dementsprechend ist die Gesamtstimmung sinnvoll nach Themen und anschließend nach Nutzern aufzuschlüsseln. Eine Zusammenhanganalyse mit Hilfe statistischer Methoden wie Ermitteln von Gruppenunterschieden, der Korrelation und der Ähnlichkeit, soll zunächst den Informationszuwachs der Aufschlüsselung nach Thema der gesamten Tweets belegen. Ferner soll die Analyse ebenfalls relevante Themen und Nutzer aufzeigen. Hierbei werden zusammenhängende Variablen identifiziert und diese anschließend in einem neuronalen Netz zur Vorhersage verwendet. Die Eingangsvariablen des neuronalen Netzes werden auf Zusammenhänge aller Nutzerstimmungen mit dem DAX-Kurs überprüft, da das neuronale Netz nicht alle Nutzer gleichzeitig aufgrund der damit einhergehenden Komplexität berücksichtigen kann. Somit schlägt diese Arbeit Mechanismen zur Auswahl von Nutzern vor, die eine DAX-Vorhersage verbessern könnten.

Zunächst ist zu klären, ob es einen signifikanten Zusammenhang zwischen der Stimmung in deutschen und englischen Tweets und dem DAX gibt. Fraglich ist, welche Nutzermeinungen aus den Themen DAX, Wirtschaft oder Politik am stärksten mit dem DAX-Kurs zusammenhängen und in welchem zeitlichen Abstand der Zusammenhang am größten ist. Anhand der Ergebnisse sollen die Stimmungen für die Vorhersage des DAX nutzbar gemacht werden. Handlungsempfehlungen für die Praxis sollen abgeleitet werden.

Diese Überlegungen bestimmen den Aufbau der Arbeit: Kapitel 2 beschreibt den Stand der Forschung bei den Zusammenhängen zum DAX und bei der Stimmungsanalyse. Kapitel 3 beschreibt die Untersuchungsanordnung und definiert die Stichprobe sowie die Methodik der Stimmungsanalyse. Kapitel 4 enthält die Ergebnisse der Aufschlüsselung, ferner die sich anschließende Vorhersage. In Kapitel 5 werden die Ergebnisse diskutiert. Limitationen der Vorhersage werden aufgezeigt, Erkenntnisse verdichtet und zukünftige Forschungsansätze vorgeschlagen.

## 2 Theoretischer Hintergrund

Dieses Kapitel fasst die relevante Literatur zur DAX-Vorhersage und Stimmungsanalyse zusammen. Die wichtigsten Studien werden erläutert. Das Untersuchungsmodell und die Hypothesen werden aufgestellt.

### 2.1 Schwierigkeiten bei der Stimmungsanalyse von Tweets

Die Datenstruktur sozialer Medien stellt die Wissenschaft vor Herausforderungen. Soziale Medien enthalten unstrukturierte Daten (Gundecha et al., 2012, S. 4). Des Weiteren enthalten Tweets Werbung und unpräzise sowie mehrdeutige Ausdrücke. Beides erschwert die computerbasierte Verarbeitung natürlicher Sprache (Han et al., 2011, S. 372). Die Techniken der textuellen Informationsverarbeitung sind unter anderem die Einteilung eines Satzes in einzelne Worteinheiten (Zinsmeister et al., 2006, S. 64), die Klassifikation, das Erkennen von Sätzen und das Ermitteln von Zusammenhängen (Reese, 2015, S. 1).

Eine weitere Schwierigkeit ist, dass Algorithmen zur Stimmungsanalyse keine profanen Aussagen in Texten erkennen. Dieses Problem kann in Ansätzen dadurch gelöst werden, dass die Nachrichtenhistorie eines Nutzers mitberücksichtigt wird (Rajadesingan et al., 2015, S. 104). So konnten die Forscher Sarkasmus in Texten erkennen. Daher ist es ratsam, einen Text nicht isoliert durch Algorithmen zu analysieren, sondern auch andere Tweets desselben Nutzers sowie die Anzahl seiner Abonnenten zu berücksichtigen.

Zudem hat Twitter eine eigene Syntax (Zhang et al., 2011b, S. 4). Daher komplizieren die hieraus folgenden Eigenschaften die Textanalyse von Tweets (Martínez-Cámara et al., 2014, S. 20): Kürze, Grammatikfehler, Jargon und Mehrsprachigkeit. Es ist zu fragen, ob die Einordnung eines Wortes nach Subjekt, Prädikat und Objekt in einem Text zu besseren Ergebnissen führt. Es hat sich herausgestellt, dass bei Twitter die differenzierte Einordnung von Wortart und Redeteil nicht nützlich ist (Kouloumpis et al., 2011, S. 541). Jedoch wirkt ein Wort mit subjektiver Bewertung, das in die Länge gezogen wird, wie z. B. das Wort „Cooooool“ stimmungsverstärkend (Brody et al., 2011, S. 569). Somit sollten solche Eigenheiten besonders berücksichtigt werden. Jedoch ist festzustellen, dass diese in die Länge gezogenen Wörter in keinem Stimmungslexikon enthalten sind. Stimmungslexika sind Wortlisten, welche die in einzelnen Worten enthaltenen Stimmungen bewerten und einordnen. Die Gesamtstimmung eines Satzes errechnet sich schließlich über die einzelnen Stimmungsworte.

Twitter selbst besteht aus öffentlichen und geschützten Tweets. Öffentliche Tweets sind für alle lesbar, geschützte Tweets ausschließlich für genehmigte Abonnenten (Makice, 2009, S. 182).

Unter Abonnenten sind Personen zu verstehen, welche die Tweets anderer Nutzer abonnieren und diese regelmäßig lesen (Twitter Inc., 2016a).

Es besteht aber auch die Möglichkeit, dass geschützte Tweets an die Öffentlichkeit gelangen. Hierzu eine kurze Statistik: Im Jahr 2009 hatten 1% aller Twitter-Nutzer geschützte Tweets weitergeleitet und 4% aller Weiterleitungen enthielten den Inhalt eines geschützten Tweets (Meeder et al., 2010, S. 5). Eine Weiterleitung ist ein Tweet, den ein Nutzer aktiv an seine Abonnenten übermittelt (Twitter Inc., 2016b). Im Jahr 2012 hatten 11% aller Twitter-Nutzer einen geschützten Account und im Durchschnitt 47 Abonnenten (Udani, 2012).

Fraglich ist, ob sich geschützte und öffentliche Tweets von ihren Inhalten her unterscheiden, ob die Inhalte geschützter Tweets wichtiger sind und eine bessere Vorhersagekraft haben als die Inhalte von öffentlichen Tweets. Dies wäre der Fall, wenn in diesen geschützten Tweets Insiderinformationen enthalten wären, die auf eine direkte Kaufentscheidung abzielten. Geschützte Tweets sind jedoch leider nicht zugänglich und konnten daher nicht berücksichtigt werden.

## 2.2 Zusammenhänge mit dem DAX

### **Zufallsprozess**

Nach herrschender Meinung folgt der Aktienkurs einem Zufallsprozess (Fama, 1970, S. 388). Demnach ist bis heute kein Verfahren gefunden worden, das eine Vorhersage in vollends befriedigender Weise ermöglicht. Viele Forscher führen dies auf eine bestehende Effizienz der Märkte zurück. Die Markteffizienzhypothese von Fama (1970, S. 413) besagt, dass alle relevanten und aktuellen Informationen im Aktienkurs eingepreist sind. Dies würde bedeuten, dass alle Informationen, die im Kursverlauf zum Zeitpunkt  $t$  verfügbar sind, auch im Kurs zum Zeitpunkt  $t$  enthalten sind. Substanzielle Kursveränderungen würden sich daher nur durch *neue* Informationen ergeben; diese sind aber im Prinzip nicht vorhersagbar und können daher von der öffentlichen Meinung nicht antizipiert werden (Bollen et al., 2011b, S. 5). Diese neuen Informationen entstehen zufällig und unabhängig von den bereits bestehenden Informationen und überführen die Aktienkurse wiederum in eine Zufallsbewegung (Qian et al., 2007, S. 25). Diese Arbeit verfolgt den Ansatz, dass jedoch die aufgeschlüsselten Stimmungen aus Tweets nicht bereits in Kursen enthalten sind. Somit liegt keine Effizienz vor und daher ist die Kursbewegung nicht rein zufällig. Folglich lassen sich neue Informationen aus Stimmungen extrahieren.

Zusätzlich hängen Aktiennachrichten mit Marktvolatilitäten zusammen; dies ist jedoch von geringer ökonomischen Bedeutung (Antweiler et al., 2004, S. 1281).

### **Politik und Wirtschaft**

Der Zusammenhang zwischen Politik, Wirtschaft und dem Aktienmarkt konnte in Studien nachgewiesen werden. Wisniewski (2016), Santa-Clara et al. (2003) und Stevenson (2001) bewiesen die folgenden Zusammenhänge zwischen Politik und Wirtschaft für die USA: Bei Kriegen und bei terroristischen Anschlägen sinken die Börsenkurse (Wisniewski, 2016, S. 21). Gemäß dem Autor steigen Aktienrenditen hingegen in intakten Demokratien sowie während der zweiten Amtszeit eines amerikanischen Präsidenten. Kontrahiert jedoch die Wirtschaft, verstärkt dies rechtsgerichtete politische Präferenzen (Stevenson, 2001, S. 627). Eine politische Analyse bei kleineren deutschen Unternehmen ergab, dass die Wertentwicklung auf dem Aktienmarkt bei rechtsgerichteter Politik besser ist als bei linksgerichteter Politik (Füss et al., 2007, S. 147). In den USA haben Aktienmärkte jedoch unter demokratischen Regierungen höhere Renditen als unter republikanischen (Santa-Clara et al., 2003, S. 1869). Zusammenfassend können politische Ereignisse nachweislich mit der wirtschaftlichen Entwicklung eines Landes sowie mit den Aktienkursen zusammenhängen.

Nicht nur Politik und Wirtschaft, sondern auch klassische sowie neue Medien könnten mit den Aktienmärkten zusammenhängen. Dieser Zusammenhang, insbesondere in Bezug auf neue Medien, ist daher in folgendem Absatz beschrieben.

### **Neue Medien**

Die neuen Medien, dazu gehört insbesondere das Internet, sind den klassischen Medien aufgrund von Aktualität und Informationsdichte überlegen. Zunächst erhielten Investoren ihre Informationen aus klassischen Medien. Später konnten Nutzer im Internet selbst Inhalte verfassen und erhielten ihre Nachrichten über Internetforen, auf denen zum Thema Börse diskutiert wird (Wu et al., 2014, S. 1078). Nach Watkins (2003, S. 200) besteht ein Zusammenhang zwischen den Inhalten der Foren und den Aktienmärkten. Auch private Investoren sind in diesen Internetforen besser beraten als durch ihren eigenen Bankanalysten (Nofer et al., 2014, S. 324). Dieses Ergebnis folgt dem Narrativ der kollektiven Intelligenz. Hierbei ist die Kaufempfehlung einer Gruppe, ist diese auch von Amateuren besetzt, gewinnbringender als die Kaufempfehlung eines einzelnen Experten. Dies ist darin begründet, dass viele Menschen durch ihr Wissen, ihre Erfahrung und Insiderinformationen die Märkte besser voraussagen als einzelne Experten (Segaran, 2007, S. 2). In diesem Sinn können in den neuen Medien kollektiv wiedergegebene Aussagen durchaus neue Informationen darstellen, oder auch eine Neubewertung vorhandener

Informationen implizieren. Es ist unklar, ob bzw. wie schnell solche Informationen in den Kurs eingepreist werden, sodass die o.g. Markteffizienzhypothese nicht ohne weitere Forschung als gültig und Kursänderungen damit als zufällig angenommen werden sollten.

Die Meinung, dass die kollektive Intelligenz aller Forennutzer zusammen der individuellen Intelligenz eines einzelnen Bankberaters überlegen ist, teilen auch Nofer et al. (2014). Sie rechtfertigen mit diesem Argument ihre eigene Vorgehensweise, nämlich die Extraktion von Stimmungen aus Twitter. Die Forscher konnten nachweisen, dass es einen Zusammenhang zwischen Meinungsverschiedenheiten bei Twitter und einem verminderten Handelsvolumen gibt. Viele Tweets treten gleichzeitig mit einem erhöhten Handelsvolumen und einer erhöhten Volatilität der Börsenkurse auf (Oliveira et al., 2013, S. 8). Alle diese Faktoren zusammen machen Twitter zu einer Plattform, auf der diese kollektive Intelligenz genutzt werden kann.

Zunächst einmal ist Twitter ein soziales Netzwerk. In Deutschland werden soziale Netzwerke zu 7% beruflich genutzt (Budde et al., 2013, S. 22). Berufliche Nutzung bezieht sich darauf, dass Twitter auch zur Kommunikation unter Geschäftspartnern oder zur Informationsbeschaffung und Recherche verwendet wird. Diese berufliche Nutzung findet auch bei Investoren statt. Hierzu sind folgende Studien beschrieben, die Empfehlungen für Handelsalgorithmen geben: Die Anzahl der Abonnenten aus sozialen Netzwerken, also wieviel Nutzer die Nachrichten anderer Nutzer verfolgen, kann den Eigenkapitalwert von Unternehmen besser vorhersagen als die Anzahl von Suchanfragen oder Analysen zum Internetverkehr (Luo et al., 2013, S. 157). Gemäß Yu et al. (2013, S. 925) haben soziale Medien eine schnellere Vorhersagekraft als klassische Internetmedien, weil sie stärker mit dem Aktienkurs korrelieren. Laut Schniederjans et al. (2013, S. 916) hängen soziale Medien mit der Ertragslage eines Unternehmens zusammen. Wenn Unternehmen eigene Tweets schreiben und somit die Kommunikation zum Verbraucher suchen, kann dies zu geringeren Geld-Brief-Spannen führen (Blankespoor et al., 2013, S. 109). Soziale Medien werden in diesem Kontext analysiert, um eine Kaufentscheidung zu generieren. Finanzentscheidungen dieser Art werden einigen Verhaltensökonomern zufolge auch anhand von Stimmungen getroffen (Nofsinger, 2005, S. 145). Solche Stimmungen können, gleichermaßen wie traditionelle Nachrichten, mit Aktienkursen zusammenhängen (Bollen et al., 2011b, S. 7). Gilbert et al. (2010, S. 61) unterstützen diese These und wenden Stimmungsanalysen auf einen amerikanischen Aktienindex an. Hierbei zeigt sich das folgende Bild: Pessimismus in Medien erzeugt Abwärtsbewegungen der Aktienmärkte, wobei extremer Pessimismus, gleichwie extremer Optimismus, zu hohen Handelsvolumina führt (Tetlock, 2007, S. 1166). Grundsätzlich werten Menschen Verluste höher als Gewinne (Tversky et al., 1991, S. 1057). Dieses Phänomen ist auch als Risikoaversion bekannt. Die Risikoaversion ist individuell verschieden

und es gibt es beim Aktienkauf einen Zusammenhang zwischen Risikoaversion und Ermüdungserscheinung bzw. Erschöpfung eines Investors (Hockey et al., 2000, S. 848). Den Autoren zufolge gibt es einen positiven Zusammenhang zwischen der Ermüdung einer Person und dem Risiko seiner Finanzentscheidung. Auch verhaltenspsychologische Effekte sind zu berücksichtigen. So haben Menschen, die sich auf positive Informationen fokussieren, eine bessere Stimmung nach der Entscheidung und insgesamt eine größere Entscheidungszufriedenheit (English et al., 2015, S. 354).

Auch wird die Stimmung zunehmend in Verbindung mit weiteren Indikatoren gesehen. So ist eine geringe Rendite trotz positiver Stimmung bei den Aktien zu erwarten, bei denen Arbitrage und die Bewertung schwierig sind (Baker et al., 2011, S. 285). Die Evaluation von Finanzinstrumenten bedingt folglich eine gewisse Zurückhaltung. Die positive Stimmung hängt jedoch nicht signifikant mit der Aktienrendite der schwierig zu bewertenden Unternehmen zusammen. Dementsprechend überwiegt die Unsicherheit über die Wirkung der positiven Stimmung. Weiterhin besteht nach Ranco et al. (2015, S. 20) ein Zusammenhang zwischen der Twitter-Stimmung und den abnormalen Renditen. So hängt eine hohe Anzahl Tweets mit starken Schwankungen der Renditen zusammen. Gemäß den Autoren bestimmt die Anzahl der Tweets bei einem Drittel der in einem amerikanischen Aktienindex befindlichen Unternehmen den Kurs. Sie weisen dies mit der Methode der Granger-Kausalität nach. Diese Methode ist ein verbreitetes ökonometrisches Modell zur Bestimmung von Zeitreihenkorrelationen (Granger, 1969, S. 428). Hier ist  $x$  Granger-kausal zu  $y$ , wenn zukünftige Werte von  $y$  mit Hilfe vergangener Werte von  $x$  mit geringerer Fehlervarianz vorhergesagt werden können (Kirchgässner et al., 2006, S. 85). Zusammengefasst reagiert der Börsenmarkt auf Stimmungen, basierend besonders auf sich schnell verbreitenden Gerüchten und Neuigkeiten (Lugmayr et al., 2013, S. 69). Ein weiteres Merkmal ist die Anzahl der Abonnenten. So gibt es bei kleineren Firmen und Firmen mit geringerer medialer Aufmerksamkeit einen Zusammenhang zwischen der Anzahl der Abonnenten und dem künftigen Unternehmenswert (Bartov et al., 2017, S. 25f).

Bollen et al. (2011b, S. 6) extrahierten Frühindikatoren aus sozialen Netzwerken, um Änderungen im Aktienkurs vorherzusagen. Die Stimmung in Tweets ist ein solcher Indikator für eine Kaufentscheidung. Die Stimmungsanalyse wird auch im Hochfrequenzhandel genutzt. Dort werden Tweets auf einen eingeschränkten Kontext mit Hilfe von genetischen Algorithmen analysiert (Vincent et al., 2010, S. 9). Hierbei werden Änderungen der Handelsstrategien nach entsprechen Eilmeldungen bei gesellschaftspolitischen Themen berücksichtigt (Vincent et al., 2010, S. 8). Bei genetischen Algorithmen werden vorteilhafte Eigenschaften, die durch zufällige Variation entstehen, durch natürliche Auslese ausgewählt (Kruse et al., 2011, S. 155). Ein

genetischer Algorithmus besteht nach Gerdes et al. (2004, S. 35) aus vier Schritten: Zunächst wird eine Startpopulation geschaffen und die Fitness berechnet. Im Anschluss wird selektiert und genetische Operatoren wie die Rekombination oder Mutation ausgewählt (Gerdes et al., 2004, S. 35).

Nachdem die Relevanz zur Untersuchung neuer Medien insbesondere sozialer Netzwerke erläutert wurde, wird im nächsten Kapitel ein Überblick über die verwendeten Methoden gegeben.

### 2.3 Methoden der Stimmungsanalyse

Stimmungsanalysen unterstützen bei Investitionsentscheidungen (Brown, 2012, S. 40). Stimmungsindikatoren sind kein neues Phänomen. So gibt es traditionelle Stimmungsindikatoren wie unter anderem den Börse Frankfurt Sentiment Index, den Economic Sentiment Index, den Indikator des Zentrums für Europäische Wirtschaftsforschung und den ifo-Geschäftsklimaindex (Lugmayr, 2013, S. 574). Letzterer ist der bekannteste und wird häufig in den Medien zitiert.

Die Stimmungsanalyse umfasst unterschiedlichen Disziplinen der Wissenschaft. Nassirtoussi et al. (2014, S. 7654) haben die Disziplinen der Stimmungsanalyse zur Marktvorhersage systematisiert: So verwenden Algorithmen des maschinellen Lernens die Texterkennung aus der Computerlinguistik, um diese mit verhaltensökonomischen Modellen zu verknüpfen. Stimmungen werden extrahiert, gewichtet und bewertet, um schließlich Zusammenhänge mit ökonomischen Indikatoren nachzuweisen.

Einen umfassenden Überblick gibt die sich im Anhang befindliche Tabelle A auf Seite 91. Sie fasst die aktuellen Studien zur Stimmungsanalyse zusammen und zeigt die Methoden sowie die Ergebnisse auf. Die meisten Studien beziehen sich auf englische Tweets. Hierbei gibt es zwei gängige Methoden der Stimmungsextraktion: Die Stimmungen werden entweder von Menschen analysiert oder mit maschinellem Lernen extrahiert. Während bei der ersten Methode Menschen selbstständig durch Lesen eines Tweets dessen Stimmung auf einer Skala bewerten, so lernen die Algorithmen des maschinellen Lernens, wie eine Aufgabe aus der Erfahrung zu lösen ist, ohne explizit darauf programmiert worden zu sein (Brandewinder, 2015, S. 2). Diese Methodik steht im Gegensatz zu gängigen Algorithmen, die im Vorfeld speziell für eine besondere Aufgabe entworfen worden sind.

Auch beim maschinellen Lernen ist es hilfreich, weitere Merkmale zur Stimmungsanalyse hinzuzufügen. Ein weiteres Merkmal sind Emoticons. Emoticons werden besonders berücksichtigt, um mit ihrer Hilfe Algorithmen für maschinelles Lernen zu trainieren (Go et al., 2009,

S. 6). Ein Emoticon ist die Darstellung eines meist lachenden oder traurigen Gesichtes zur Gefühlsäußerung, erstellt mit den Standardzeichen einer Computertastatur (Bibliographisches Institut GmbH – Dudenverlag, 2016).

Go et al. (2009) trainierten drei Typen des maschinellen Lernens mit Emoticons: Die naive Bayes-Klassifikation, die Maximum-Entropie-Methode und die Stützvektormaschine.

Bei der naiven Bayes-Klassifikation ist die Wahrscheinlichkeit

$$p(l|x) = \frac{p(l) \cdot p(x|l)}{\sum_{j=1}^c p(p(j)) \cdot x|j} \quad (2.1)$$

mit  $x$  als Vektor der nicht überlappenden Eigenschaften und  $l$  als Klasse (Runkler, 2015, S. 94). Mit Hilfe der Maximum-Entropie-Methode können Vorhersagen oder Schlussfolgerungen bei unvollständiger Information gemacht werden (Phillips et al., 2006, S. 234). Die Maximum-Entropie-Methode berücksichtigt hingegen die Eigenschaftsüberlappung besser als die naive Bayes-Klassifikation; ihr Wahrscheinlichkeitsmaß ist

$$P_{ME}(c|h, \lambda) = \frac{e^{[\sum_i \lambda_i z_i(c,h)]}}{\sum_{c'} e^{[\sum_i \lambda_i z_i(c',h)]}} \quad (2.2)$$

wobei  $c$  die Klasse,  $h$  das Tweet,  $\lambda$  ein Gewichtungsvektor und  $z$  eine Eigenschaft ist, beispielsweise die Berücksichtigung zweier Worte oder einer Phrase (Go et al., 2009, S. 3). Die Entropie ist somit ein quantitatives Maß der Unsicherheit über eine Verteilung (Kapur, 1989, S. 1). Folglich führt ein höherer Informationsgehalt zur Abnahme der Entropie (Ihara, 1993, S. 98) und zu einem höheren Ordnungszustand. Die Autoren trainierten die Gewichte  $\lambda$  mit der Methode der konjugierten Gradienten, einer effektiven Methode zur Lösung linearer Gleichungssysteme der Form  $Ax = b$  (Hanke-Bourgeois, 2002, S. 85). Die oben erwähnte Stützvektormaschine benutzt lineare Klassengrenzen, wobei die Daten einen Mindestabstand  $b > 0$  zu den Grenzen haben müssen, das heißt bei naheliegenden Klassen oder Überlappungen kann unter Umständen keine Klassengrenze gefunden werden, ohne zuvor die Bedingungen gelockert zu haben (Runkler, 2015, S. 98). Nichtlineare Klassengrenzen können jedoch durch die Erweiterung mit einem Kerndichteschätzer ermittelt werden (Runkler, 2015, S. 99). Go et al. (2009, S. 3) verwendeten in ihrer Studie einen linearen Kerndichteschätzer.

Fraglich ist, wie hoch die Genauigkeit solcher Algorithmen ist. Bei den bisher vorgestellten Studien waren die Algorithmen bei der Vorhersage von Aktien bzw. Aktienindices durch Stimmungen bis zu 80% präzise. Vereinzelt werden auch neuronale Netze zur Simulation des komplexen Marktverhaltens eingesetzt. Eine weitere Methode sind Stimmungskarten, die Stimmungsunterschiede in verschiedenen geographischen Regionen aufzeigen (Godbole et al.,

2007, S. 222). Sie sind vergleichbar mit Wetterkarten. Statt der Temperatur wird die regionale Stimmung dargestellt.

In der Wissenschaft werden Nachrichtenströme besonders beachtet. Dies steht im Gegensatz zur isolierten Nachrichtenbetrachtung. Zur Berücksichtigung solcher Nachrichtenströme werden Methoden aus der Ingenieurwissenschaft verwendet, um Einzelnachrichten im Kontext zu analysieren. Negi et al. (2014, S. 3763) haben ein soziales Netzwerk zur Nachbarschaftsanalyse vorgeschaltet. Sie verwendeten ein Modell aus der Physik zur Berechnung von Nachbarschaftswechselwirkungen beim Ferromagnetismus (Brenig, 2013, S. 323). Der Vorteil dieses Modells ist die Reduktion der Fehlerrate, indem Kommunikationswege durch die oben genannten Nachbarschaftswechselwirkungen von Nachrichten berücksichtigt werden. Larsson et al. (2012, S. 738ff) visualisieren sogar die Beziehungen der Nutzer untereinander mit Hilfe gerichteter Graphen.

Bei kontextbezogener Betrachtung von Tweets könnte sich eine andere Stimmung ergeben als bei isolierter Betrachtung. Netzwerkstrukturen beschreiben solche Beziehungen zwischen den Nachrichten. Indem Nachrichtenbeziehungen berücksichtigt werden, kann eine latente Stimmung ermittelt werden. Diese latente Stimmung ist relativ zu der Stimmung eines Tweets eines anderen Nutzers. Es werden hier nicht die individuellen Stimmungen isoliert betrachtet, sondern wie Stimmungen von Tweets zueinander stehen. Dies führt zu einer Erhöhung des Kontextbezugs: Die Stimmung eines Tweets hängt von der Stimmung eines mit ihm verbundenen Tweets ab. Diese Nachbarschaftsbetrachtung stellt die Erweiterung der einfachen Stimmungsanalyse dar. Sie berücksichtigt den jeweiligen Abonnenten eines Tweets. In diesem Zusammenhang werden auch semantische Netzwerke eingesetzt. Diese Netzwerke verbessern die Vorhersage für eine Aktie (Si et al., 2014, S. 1140), da die Algorithmen berücksichtigen, welche Nutzer welchen anderen Nutzern folgen und welche anderen Tweets ein Nutzer verbreitet.

Bisher wurde die Stimmung als eindimensionales Objekt beschrieben. Ein Wort kann eine Stimmung haben, diese entspricht entweder einem Wert auf einer Skala oder sie wird bewertet nach positiv oder negativ. Für ganze Sätze ließe sich demzufolge eine Gesamtstimmung ermitteln. Gesamtstimmungen werden unter anderem mit Hilfe arithmetischer Mittel, Mediane, Summe der Maxima oder spezielle Indizes als Punktwertung gebildet (Basiri et al., 2014, S 9). Letztendlich ist auch die akkumulierte Stimmung eindimensional. Im Gegensatz hierzu gibt es Studien, die Stimmung mehrdimensional betrachten. Arvidsson (2011, S. 52) misst die Stimmung in drei Dimensionen: der affektiven Stärke einer Nachricht, der Netzwerkzentralität und der Häufigkeit der Erscheinung.

Grundsätzlich können mit Hilfe der Methoden der Stimmungsanalyse Stimmungswörter gefunden werden, die in ihrer Eigenschaft entweder positiv oder negativ sind. Für die Klassifikation von Wörtern in positive oder negative Stimmungswörter werden in der aktuellen Forschung verschiedene Methoden angewandt. Die naive Bayes-Klassifikation wird besonders bei der Erkennung bestimmter Sprach- und Begriffsmuster eingesetzt. Hierbei handelt es sich um eine wahrscheinlichkeitsbasierte Klassifikation, die auf dem Satz von Bayes basiert (Runkler, 2015, S. 93). Bei der Einordnung ist auch die Stützvektormaschine ein effektiver Algorithmus (Joachims, 2002, S. 4). Zusammenfassend ist festzuhalten: Entweder müssen Wörter bezüglich ihrer Stimmung erst klassifiziert werden, oder die Wörter wurden bereits klassifiziert und werden anschließend in Form eines Stimmungslexikons zur Verfügung gestellt. Mittlerweile haben sich solche Stimmungslexika etabliert. Sie sind das Ergebnis umfangreicher Stimmungsanalysen und daher universell einsetzbar. Das folgende Kapitel beschreibt nun die verwendeten Stimmungslexika.

## 2.4 Stimmungslexika

Grundsätzlich beinhaltet die Methode des Stimmungslexikons Wortlisten mit deren Grundform und deren Flexionen. Flexionen sind unter anderem die konjugierten Formen eines Verbs oder die deklinierten Formen eines Nomens, Substantivs oder Adjektivs (Behrens, 2013, S. 95). Wörter erhalten entweder eine Stimmung als Zahlenwert, oder sie werden in positive oder negative Stimmungswörter unterteilt. Für die Extraktion von Stimmungen aus deutschen Texten wird ein Stimmungswörterbuch mit Stimmungswerten verwendet. Das englische Stimmungslexikon enthält hingegen positive und negative Stimmungswortlisten (Hu et al., 2004, S. 757). Es enthält allerdings doppelt so viele negative wie positive Stimmungswörter. Das englische Lexikon ist demgemäß nicht so ausgeglichen wie das deutsche, was die Stimmung ins Negative verzerren könnte.

Im Folgenden werden bekannte Probleme von Stimmungslexika beschrieben. Nach Declerck et al. (2014, S. 3875) sollten Stimmungslexika auch die Grundform eines Wortes enthalten. Dies ist bei den deutschen Worten im Lexikon gegeben. Empfehlenswert ist es jedoch auch, Texte in anderen Sprachen zu analysieren. So kann ein ganzheitliches Stimmungsbild erhalten werden.

Das für diese Arbeit verwendete Stimmungswörterbuch mit Stimmungswerten enthält deutsche Wörter. So ist zu fragen, wie ein einsprachiges Wörterbuch auch für andere Sprachen eingesetzt werden kann. Für eine mehrsprachige Stimmungsanalyse empfiehlt es sich, das Wort zunächst zu übersetzen und die Stimmungszahl auf die Übersetzung zu übertragen (Denecke, 2008,

S. 509). Nach dem Autor ist der Vorgang automatisierbar, nicht berücksichtigt würden dabei jedoch die Eigenheiten einer Sprache. Aus diesem Grund wird auf eine maschinelle Wörterbuchkonvertierung verzichtet.

Jain et al., (2010, S. 21) legen dar, dass die Berücksichtigung des Kontextes im Gegensatz zur individuellen Wortbetrachtung die Stimmungsanalyse verbessern könnte. Eine hierfür eingesetzte Methode ist die Stützvektormaschine. Diese kann jedoch Sätze mit wenigen Meinungsäußerungen oder Sätze mit multiplen Meinungsäußerungen zu einem Thema nicht klassifizieren (Kim et al., 2004, S. 7). In Bezug auf Tweets und deren besonderer Syntax ist diese Form der Kontextberücksichtigung zumindest problematisch. Eine weitere Möglichkeit zur Verbesserung lexikalischer Stimmungsextraktion ist das Kategorisieren von Tweets. Sriram et al. (2010, S. 842) kategorisieren kurze Texte nach den folgenden Kriterien: Nachrichten, Ereignisse, Meinungen, geschäftliche Nachrichten und private Nachrichten. Diese Kategorisierung im Vorhinein erfordert aber in diesem Zusammenhang das Lesen und manuelle Verarbeiten eines jeden einzelnen Tweets.

Ein weiteres Problem lexikalischer Analysen ist die Stimmungserkennung einer Verneinung. So hat der Satz „der Film war nicht schlecht“ eine negative Stimmung, obwohl er eine positive Aussage hat. Der Satz enthält das Stimmungswort „schlecht“ mit einer Stimmungszahl von -0.0048. Dies könnte bei vielen Verneinungen in Tweets zu einer Verzerrung führen. Schließlich verstärkt eine Verneinung trotz positiver Textaussage die negative Stimmung (Potts, 2011, S. 650). Der Autor hat auch hier Stimmungszahlen einzelner Wörter ohne Kontextbezug mit Hilfe eines Lexikons extrahiert.

Dem Kontextbezug ist auch folgende Studie zuzuordnen: Agarwal et al. (2011, S. 34) untersuchen vorhergehende Wörter. Hierbei werden sogar einzelne Satzteile berücksichtigt. Auch Barbosa et al. (2010, S. 42) untersuchen die Semantik, um ein abstraktes Abbild eines Tweets zu erstellen, denn die Berücksichtigung der Semantik präzisiert die Stimmungsanalyse (Xie et al., 2013, S. 876). Die zuletzt genannten Autoren überprüften den Zusammenhang von Aktienkursen und Finanznachrichten. Hier erstellten sie Szenarien anhand spezifischer Sätze zum Training einer Stützvektormaschine.

Zusammenfassend bieten Stimmungslexika eine standardisierte Stimmungsextraktion. Feinheiten wie Verneinungen und Kontextbezüge werden mit Lexika jedoch vernachlässigt. Um die Ergebnisse zu verbessern, besteht die Möglichkeit, weitere Methoden ergänzend einzusetzen. Im folgenden Kapitel wird die eigentliche Vorhersagekraft von Parametern erläutert, die aus Stimmungen extrahiert wurden.

## 2.5 Vorhersagekraft von Stimmungsparametern

Kern dieses Kapitels ist eine Übersicht der Vorhersagekraft von Stimmungsparametern, die aus der Extraktion von Nachrichten aus Twitter und anderen Internetplattformen extrahiert worden sind. Festzuhalten ist, dass die Ergebnisse von Stimmungsanalysen bei Twitter in ihrer Wertigkeit durchaus als ambivalent zu bezeichnen sind (Brown, 2012, S. 40). Grundsätzlich ist die Vorhersage mit Hilfe sozialer Medien umso besser, je mehr Nutzer ihre Meinung äußern (Ceron et al., 2014, S. 353). Dies bedeutet, dass sich mit zunehmender Stichprobengröße die Tendenz einer Stimmung deutlich besser ermitteln lässt. Es wird auch empfohlen, Stimmungen bekannter Nutzer besonders zu berücksichtigen. Ein Ergebnis dieser differenzierten Betrachtung ist, dass die Stimmung bekannter, vor allem beliebter Nutzer mit der Stimmung der Abonnenten stärker zusammenhängt, als die Stimmung unbekannter respektive unpopulärer Nutzer (Bae et al., 2012, S. 2534). Ein beliebter Nutzer ist ein Nutzer mit vielen Abonnenten, die seine Tweets regelmäßig lesen. Diese Abonnenten können somit die Stimmung ihres Vorbildes übernehmen. Sie werden dementsprechend polarisiert.

Zu fragen ist jedoch, wie nachhaltig diese Polarisierung durch einen Nutzer wirkt, ob es sich hierbei um kurzfristige oder langfristige Zusammenhänge handelt. So wirken Stimmungen umso nachhaltiger, je mehr Nutzer einem Tweet an einem Tag folgen (Dennis et al., 2014, S. 811). Die Anzahl dieser Abonnenten ist auch ein Indikator für die Vertraulichkeit oder Seriosität eines Tweets. Auch Tweets mit wenigen Abonnenten wurden untersucht. Das unerwartete Ergebnis war gemäß den Autoren, dass Stimmungen in Tweets mit wenigen Abonnenten mit späteren Aktienrenditen stärker zusammenhängen als Stimmungen in Tweets mit vielen Nutzern.

Auf dieser Grundlage, nämlich der differenzierten Berücksichtigung und damit unterschiedlicher Vorhersagekraft der Anzahl von Abonnenten eines Tweets, haben die oben genannten Forscher ein Vorhersagemodell erstellt. Dieses Modell gewichtet die jeweilige Stimmung in den Tweets mit der Anzahl der Abonnenten. Die Anzahl der Abonnenten ist somit ein zentrales Element.

Zur Frage, wie ein Nutzer zu Börsenthemen an seine Abonnenten kommt, gibt es verschiedene Untersuchungen. Sprenger et al. (2010, S. 950) bewiesen, dass Investitionsratschläge die Anzahl der Abonnenten eines Nutzers erhöhen. So werden die Nachrichten derjenigen Nutzer auch öfters weitergeleitet, die viele Ratschläge geben. Es gibt dementsprechend ein primäres Interesse an Investitionsratschlägen von Seiten der Twitter-Nutzer.

Auch Dennis et al. (2014, S. 811f) stellen fest, dass Tweets mit wenigen Abonnenten sich stärker auf die Aktienrenditen auswirken als Tweets hoher Relevanz und mit vielen Abonnenten.

Hingegen hängt die Anzahl von Investitionsratschlägen mit dem Aktienkurs nicht zusammen. Demzufolge hängen nach Sprenger et al. (2010, S. 950) die Nutzer mit vielen Investitionsratschlägen und mit vielen Abonnenten weniger mit Aktienkursen zusammen, als bisher angenommen.

Bisher verliefen Bemühungen, Zusammenhänge zwischen Stimmungen in deutschen Tweets und den Entwicklungen auf dem deutschen Aktienmarkt herauszufinden erfolglos. Gemäß Nofer (2015) gab es zwischen 2011 und 2013 keinen Zusammenhang zwischen der akkumulierten Stimmung aller öffentlichen deutschen Tweets aller Nutzer und dem DAX.

Der Frage, ob diese akkumulierte Stimmung nicht auch die Stimmung der Investoren enthält, sind mehrere Autoren nachgegangen. So konnte die akkumulierte Stimmung erfolgreich durch folgende Indikatoren ermittelt werden: Zum Beispiel über die Auswertung von Suchanfragen auf Google, wie Rezession, Arbeitslosigkeit und Insolvenz (Da et al., 2015, S. 29). Hier wird die Häufigkeit derjenigen Suchbegriffe untersucht, die einen direkten ökonomischen Bezug zur Realwirtschaft haben.

Die Investorenstimmung kann im englischsprachigen Raum präziser ermittelt werden. So bestehen nach Brown et al. (2004, S. 13) Korrelationen zwischen zeitgleichen Stimmungen und Aktienrenditen, jedoch haben die Stimmungen für in naher Zukunft liegenden Aktienrenditen geringe Vorhersagekraft. Die aktuelle Stimmung ist demzufolge eine Momentaufnahme des aktuellen Aktienmarktes. Im Gegensatz zu Nofer (2015) entdeckten Bollen et al. (2011b) und Sprenger et al. (2010) bei englischen Tweets signifikante Korrelationen. Eine grundlegende Studie zur Vorhersage mit Hilfe von Stimmungsanalyse bezieht sich auf Filmverkäufe in den USA. So besteht nach Mishne et al. (2006, S. 158) ein Zusammenhang zwischen Stimmung und Filmverkäufen, werden Genre und Spielzeit mitberücksichtigt. Den Forschern zufolge ist die positive Stimmung präziser nachzuweisen, wenn sie auf einen limitierten Kontext angewendet wird. In diesem Fall werden  $k$  Worte als Kontextgröße vor und nach elektronischen Verweisen (Internet-Verknüpfungen auf Amazons Filmdatenbank) berücksichtigt. Auch hier zeigt sich, dass die Kontextbeschränkung die Vorhersage verbessert.

Im Folgenden ist festzustellen, wie sich der Aktienmarkt bei abrupten Stimmungsausbrüchen verhält. So gibt es einen Zusammenhang zwischen solchen emotionalen Ausbrüchen auf Twitter und dem Wert eines Aktienindex (Zhang et al., 2011a, S. 61): Der amerikanische Aktienindex Dow Jones fiel am folgenden Tag signifikant, wenn die Menschen am vorhergehenden Tag viel Hoffnung, Angst oder Sorge über Tweets verbreitet hatten (Zhang et al., 2011a, S. 58).

Auch hier wurde die Stimmung wie bei Arvidsson (2011) mehrdimensional betrachtet. Die zuvor genannten Schlüsselworte, wie Angst oder Hoffnung, scheinen den Menschen zum Kauf- oder Verkauf von Aktien zu bewegen.

Bisher wurde ein Zusammenhang zwischen Stimmung und Aktienindices untersucht, wie dem Dow Jones oder dem DAX. Der Frage, ob es auch Zusammenhänge bei einzelnen Aktien gibt, sind Smailović et al. (2012, S. 173) mit Hilfe der Granger-Kausalität nachgegangen. Sie konnten zeitversetzte Korrelationen zwischen Twitter-Stimmungen und dem Aktienkurs von Apple nachweisen. Hierbei wurde die Auf- und Abwärtsbewegung des Kurses durch die Tweets mit einem Zeitabstand von zwei Tagen vorhergesagt. Auffällig in ihrer Studie ist, dass bei einer hohen Anzahl positiver Tweets auch eine hohe Anzahl negativer Tweets zu beobachten ist. Dies wird unter anderem damit begründet, dass die trainierte Stützvektormaschine nur bis zu 81% genau ist (Smailović et al. 2012, S. 171). Eine weitere Erklärung für die gleichzeitige Zunahme positiver und negativer Tweets ist, dass auf Twitter kontrovers diskutiert wird. Dies führt dazu, dass positiven Tweets negative Kommentare oder Antworten folgen können und einer positiven Aussage widersprochen wird. Zusammenfassend besteht gemäß den Autoren eine Granger-Kausalität zwischen der positiven Stimmung und dem um zwei Tage verschobenen Aktienkurs. Dieser zeitliche Vorlauf ist somit ausreichend für ein Vorhersagemodell.

Neben der Vorhersage von Aktienmärkten wird die Stimmungsanalyse auch bei der Vorhersage von Wahlen angewandt. So gibt es einen Zusammenhang zwischen sozialen, politischen, kulturellen und ökonomischen Ereignissen mit der Twitter-Stimmung bei politischen Wahlen (Bollen et al., 2011a, S. 453). Prechter et al. (2012, S. 11) bestätigen, dass die Stimmung an Aktienmärkten ein Indikator für die Ergebnisse bei Wiederwahlen ist. Den Autoren zufolge tendieren bei optimistischer Stimmung die Wähler zur Wiederwahl einer Person oder Partei, bei pessimistischer Stimmung zu einem Wechsel (Prechter et al., 2012, S. 3). Die oben aufgeführten Studien haben ergeben, dass die Stimmung ein aussagekräftigerer Indikator für Märkte sein kann als die klassischen ökonomischen Indikatoren, wie das Bruttoinlandsprodukt, die Inflation oder die Arbeitslosigkeit.

Einen anderen Ansatz verfolgt die Evidenztheorie. Es ist eine Methode zur Kombination von Einzelsignalen von Dempster (1967) und Shafer (1976). Basiri et al. (2014) berechnen mit dieser Methode die Gesamtstimmung eines Satzes aus der Kombination von Einzelstimmungen von Wörtern. So haben die Autoren zunächst die Stimmung der Tweets ermittelt und das Ergebnis daraus auf Satzebene als Evidenz bestimmt (Basiri et al., 2014, S. 5). Diese Methode setzt allerdings voraus, dass zum einen die Einzelstimmungen unabhängig voneinander sind und zum anderen, dass die jeweilige Zuverlässigkeit der Einzelstimmungen bekannt ist.

Schließlich müssten die Stimmungen in dichotome Daten transformiert werden, aber dies führt zum Verlust von Information. Diese Restriktionen hat das neuronale Netz jedoch nicht.

Bisher wurden Stimmungen als Gesamtheit untersucht. Die Deutung von einzelnen Stimmungen und deren Kombination ist für diese Arbeit von zentraler Bedeutung. Da die Stimmung einen Zusammenhang mit den Märkten hat, wird diese durch Manipulation gezielt verbreitet. Das Verbreiten von Stimmung kann mit Hilfe von Falschnachrichten erfolgen. Welche Bedeutung derartige Falschnachrichten haben können, zeigt der folgende Abschnitt.

## 2.6 Falschnachrichten und Aktienkurse

Besonders nach den Präsidentschaftswahlen von 2016 wurde behauptet, dass Falschnachrichten sogar ausschlaggebend für den Wahlausgang gewesen sind (Allcott et al., 2017, S. 232). Die Autoren definieren eine Falschnachricht als eine Nachricht, die absichtlich und nachweislich falsch ist und damit den Leser irreführt (Allcott et al., 2017, S. 213). Die Verbreitung solcher Falschnachrichten wird unter anderem dadurch gefördert, dass Reglementierungen fehlen. Eine fehlende Reglementierung ist, dass Falschnachrichten ohne Personenbezug oder Personengruppenbezug in Deutschland nicht strafbar sind (Deutscher Bundestag, 2016, S. 5).

Algorithmen zur Identifikation von Falschnachrichten werden zurzeit erforscht. Anhand der Art, wie sich eine Nachricht durch Twitter verbreitet, kann eine Nachricht als Falschnachricht mit einer Genauigkeit von bis zu 80% erkannt werden (Castillo et al., 2011, S. 682). Nach dieser Studie sind Nachrichten glaubwürdig, die auch von glaubwürdigen Nutzern weitergeleitet wurden. So ist ein glaubwürdiger Nutzer daran zu erkennen, dass er viele Verbindungen zu anderen Nutzern hat. Gemäß den Autoren bedeutet dies, dass die Twitter-Nutzer die Funktion eines sozialen Filters haben. Zu fragen ist, ob ein Nutzer durch gezielte Platzierung einer Falschnachricht in Twitter Profit machen könnte. Welchen Effekt eine Falschmeldung haben kann, ist in der Einleitung zu dieser Arbeit aufgezeigt worden. Ein weiteres Beispiel für eine Falschnachricht ist die Ankündigung der Firmenübernahme von Twitter in 2015. Diese Falschnachricht wurde auf einer nachgemachten Internetseite veröffentlicht, die wie das Nachrichtenportal Bloomberg ausgesehen hatte – die Folge war ein Anstieg des Twitter-Börsenkurses um fast 8% (Brigida et al., 2017, S. 565).

Bisherige Studien haben gezeigt, dass Menschen auf Falschnachrichten und deren Stimmungsänderungen reagieren. Ein gezieltes Verbreiten einer gewissen Stimmung kann auch im Jahresreport eines Unternehmens erfolgen. So neigen Unternehmen in Bezug auf Umwelt und Nachhaltigkeit zu übermäßig positiven Aussagen, um die Stimmung zu ändern. Dies geschieht beispielsweise, um negative Ereignisse zu überdecken. So ist die Varianz des Aktienkurses im

Folgejahr größer, wenn sich die Stimmung im Jahresreport geändert hat (Hájek et al., 2013, S. 303). Dies bedeutet, dass der Markt auf Wechselhaftigkeit im Jahresreport mit Volatilität reagiert. Ein Teil der Personen glaubt an die Übertreibungen. Der andere Teil hingegen erkennt die Übertreibung und reagiert dementsprechend am Markt.

Schließlich stellt sich die Frage nach der Glaubwürdigkeit von Informationen, die, wenn isoliert analysiert, nicht unmittelbar als Falschnachricht erkannt werden kann. In solchen Fällen wird auf die Kombination von Indikatoren zurückgegriffen. Somit wird die textuelle Information anhand zusätzlicher Daten validiert. Ziel dieser Validierung ist die Bestimmung einer Wahrscheinlichkeit, ob es sich bei der untersuchten Meldung um eine Falschnachricht handelt. Dieses Vorgehen ist vergleichbar mit der Erweiterung des Kontextbezugs durch Hinzunahme weiterer Merkmale.

Das neuronale Netz eignet sich besonders gut dafür, aus Stimmungen und weiteren Merkmalen Vorhersagen zu treffen. So wurde durch Kombination von Finanzindikatoren und Stimmungen ein Vorhersagemodell auf Basis eines einfachen neuronalen Netzes entworfen (Hájek et al., 2013, S. 297). Diese einfache Form wurde 1962 von Frank Rosenblatt entwickelt (Sivanandam et al., 2006, S. 60). Es ist das Modell eines hypothetischen Nervensystems mit den grundlegenden Eigenschaften eines intelligenten Systems (Rosenblatt, 1962, S. 387). Es verwendet gewichtete Eingänge und hat eine Aktivierungsfunktion (Ponce-Cruz et al. 2009, S. 57).

Gahirwal et al. (2018, S. 819) überprüfen die Glaubwürdigkeit eines Tweets, indem sie die Internetverknüpfung (Verweise auf andere Internetseiten) eines Nutzers mit einer Datenbank mit faktengeprüften Internetverknüpfungen vergleichen. Letzteses bedeutet, dass diese Internetseiten auf Richtigkeit geprüft wurden. Yamaguchi et al. (2010, S. 246f) berechneten die Glaubwürdigkeit von Nutzern anhand eines Graphen, bei dem die Nutzer und die Tweets zur Analyse des Informationsflusses modelliert werden.

Chen et al. (2017, S. 4) haben Volatilitäten von Aktienkursen mit rekurrierenden neuronalen Netzen vorhergesagt. Ein rekurrierendes neuronales Netz hat Rückkopplungen zwischen den Neuronen, welche eine Erinnerung der Eingänge ermöglicht (Graves, 2012, S. 22). Durch die Erinnerung wird der sequenzielle Kontext der Daten berücksichtigt (Medsker, 1999, S. 3). Chen et al. (2017) verwendeten zusätzlich Mechanismen mit beständigem Speicher, die auch längerfristige Abhängigkeiten der Elemente einer Sequenz berücksichtigen (Jabreel et al., 2018, S. 44).

In sozialen Netzwerken können Falschnachrichten identifiziert werden, indem Algorithmen die Fakten einer Falschnachricht mit den Fakten, die über traditionelle Suchmaschinen gefunden

werden, vergleichen (Figueira et al., 2017, S. 821). Zusammenfassend beziehen sich die meisten Studien zur Glaubwürdigkeit eines Tweets auf Algorithmen (Shariff et al., 2017, S. 794). Zu fragen ist, ob diese Falschnachrichten zur DAX-Vorhersage herausgefiltert werden sollten. Falschnachrichten sind aufgrund ihres Zusammenhangs mit den Märkten nicht zu ignorieren. Sie können signifikante, allerdings kurzfristige Änderungen an Märkten verursachen. Folglich werden die Falschnachrichten nicht herausgefiltert. Da die Falschnachrichten auch von allen Nutzern gelesen und diskutiert werden, sind sie somit Teil der Gesamtinformation.

## 2.7 Untersuchungsmodell und Hypothesen

Die in Kapitel 2 beschriebenen Forschungsergebnisse zeigen die Forschungslücken auf, die ein Hauptthema dieser Arbeit sind. Eine Vorhersage des Aktienmarktes mit Hilfe deutscher Tweets sollte folgendes beinhalten:

- Aufschlüsselung der Gesamtstimmung nach Themen
- Anschließende Aufschlüsselung der Themenstimmungen nach Nutzern
- Vorhersage zur Empfehlung einer Kauf- oder Verkaufsentscheidung

Da zu Beginn der Untersuchung nicht bekannt ist, ob die Stimmungen positiv oder negativ mit dem DAX zusammenhängen, ist bei der Korrelation ein zweiseitiger Signifikanztest anzuwenden (Brosius, 2013, S. 524).

### **Gesamtstimmung**

Für die Gesamtstimmung lässt sich folgende Hypothese ableiten:

H0 Hypothese: Es besteht kein Zusammenhang zwischen deutschen Tweets und dem DAX  
gegen Alternative: Es besteht ein Zusammenhang zwischen deutschen Tweets und dem DAX.

### **Aufschlüsselung nach Thema**

Es wird für eine differenzierte Betrachtung die Gesamtheit aller Tweets thematisch aufgeschlüsselt. Der Zusammenhang der Twitter-Stimmung mit dem DAX soll in verschiedenen, allerdings DAX-relevanten Themen wie DAX, Wirtschaft oder Politik gesondert betrachtet werden. Zu fragen ist hier, ob ein zeitlicher Vorlauf der Stimmung mit dem DAX zusammenhängt. So ist es erforderlich, Stimmungszeitreihen in die Vergangenheit zu verschieben.

Zu fragen ist, ob die themenbezogenen Tweets mit dem DAX zusammenhängen. Des Weiteren lassen sich die folgenden Hypothesen ableiten, die den Zusammenhang zwischen Themenstimmung und dem DAX untersuchen:

- H1 Hypothese: Es besteht kein Zusammenhang zwischen deutschen DAX-Tweets und dem DAX *gegen* Alternative: Es besteht ein Zusammenhang zwischen deutschen DAX-Tweets und dem DAX.
- H2 Hypothese: Es besteht kein Zusammenhang zwischen deutschen Wirtschafts-Tweets und dem DAX *gegen* Alternative: Es besteht ein Zusammenhang zwischen deutschen Wirtschafts-Tweets und dem DAX.
- H3 Hypothese: Es besteht kein Zusammenhang zwischen deutschen Politik-Tweets und dem DAX *gegen* Alternative: Es besteht ein Zusammenhang zwischen deutschen Politik-Tweets und dem DAX.
- H4 Hypothese: Es besteht kein Zusammenhang zwischen englischen DAX-Tweets und dem DAX *gegen* Alternative: Es besteht ein Zusammenhang zwischen englischen DAX-Tweets und dem DAX.

Sollten sich die Stimmungen in den drei deutschen Themen bei ihren Lageparametern unterscheiden, so gibt es unterschiedliche Stimmungsniveaus. Darüber hinaus ist zu fragen, ob die Stimmungen auch untereinander korrelieren. Bestünde eine Korrelation unter den deutschen Stimmungen, so könnte dies die Notwendigkeit einer Aufschlüsselung reduzieren. Die folgenden Hypothesen testen die Unabhängigkeit der nach Themen aufgeschlüsselten Stimmungen:

- H5 Hypothese: Es besteht kein Zusammenhang zwischen deutschen DAX-Tweets und deutschen Wirtschafts-Tweets *gegen* Alternative: Es besteht ein Zusammenhang zwischen deutschen Wirtschafts-Tweets und deutschen DAX-Tweets.
- H6 Hypothese: Es besteht kein Zusammenhang zwischen deutschen DAX-Tweets und deutschen Politik-Tweets *gegen* Alternative: Es besteht ein Zusammenhang zwischen deutschen Politik-Tweets und deutschen DAX-Tweets.
- H7 Hypothese: Es besteht kein Zusammenhang zwischen deutschen Wirtschafts-Tweets und deutschen Politik-Tweets *gegen* Alternative: Es besteht ein Zusammenhang zwischen deutschen Wirtschafts-Tweets und deutschen Politik-Tweets.

Die folgenden drei Hypothesen beziehen sich auf den Zusammenhang der Themenstimmungen, die mit unterschiedlichen deutschen und englischen Lexika extrahiert wurden:

- H8 Hypothese: Es besteht kein Zusammenhang zwischen deutschen DAX-Tweets und englischen DAX-Tweets *gegen* Alternative: Es besteht ein Zusammenhang zwischen deutschen DAX-Tweets und englischen DAX-Tweets.
- H9 Hypothese: Es besteht kein Zusammenhang zwischen deutschen Wirtschafts-Tweets und englischen DAX-Tweets *gegen* Alternative: Es besteht ein Zusammenhang zwischen deutschen Wirtschafts-Tweets und englischen DAX-Tweets.

H10 Hypothese: Es besteht kein Zusammenhang zwischen deutschen Politik-Tweets und englischen DAX-Tweets *gegen* Alternative: Es besteht ein Zusammenhang zwischen deutschen Politik-Tweets und englischen DAX-Tweets.

### **Aufschlüsselung nach Nutzern**

Die Aufschlüsselung nach Nutzern erfolgt nach der Aufschlüsselung nach Themen. Dass nicht die Gesamtstimmung direkt nach Nutzern aufgeschlüsselt wird, wird damit begründet, dass Nutzer zu vielfältigen Themen unterschiedliche Stimmungen haben, somit wird ein gewisser Themenbezug bei der Nutzerstimmung hergestellt. Die Aufschlüsselung nach Nutzern ist somit die Suche nach Experten in den einzelnen Themen. So wird nach diesen Experten gefiltert, um die Vorhersage des DAX zu verbessern. Anschließend werden aus den Themen die Nutzer ausgewählt. Hier wird auf Nutzerebene nach Zusammenhängen von Einzelstimmungen und dem DAX gesucht. Die folgenden Hypothesen werden für jeden einzelnen Nutzer individuell geprüft:

H11 Hypothese: Es besteht kein Zusammenhang zwischen dem deutschen DAX-Tweet-Nutzer Nr. i und dem DAX *gegen* Alternative: Es besteht ein Zusammenhang zwischen dem deutschen DAX-Tweet-Nutzer Nr. i und dem DAX.

H12 Hypothese: Es besteht kein Zusammenhang zwischen dem deutschen Wirtschafts-Tweet-Nutzer Nr. i und dem DAX *gegen* Alternative: Es besteht ein Zusammenhang zwischen dem deutschen Wirtschafts-Tweet-Nutzer Nr. i und dem DAX.

H13 Hypothese: Es besteht kein Zusammenhang zwischen dem deutschen Politik-Tweet-Nutzer Nr. i und dem DAX *gegen* Alternative: Es besteht ein Zusammenhang zwischen dem deutschen Politik-Tweet-Nutzer Nr. i und dem DAX.

H14 Hypothese: Es besteht kein Zusammenhang zwischen dem englischen DAX-Tweet-Nutzer Nr. i und dem DAX *gegen* Alternative: Es besteht ein Zusammenhang zwischen dem englischen DAX-Tweet-Nutzer Nr. i und dem DAX.

### **Vorhersage**

Wurden die Stimmungen ausgewählt, werden sie zu einer Kaufentscheidung zusammengesetzt. Eine Optimierung der Vorläufe wird berücksichtigt. Hier wird die Güte der jeweiligen Modelle miteinander verglichen. Es wird die Frage untersucht, ob die Vorhersagekraft eines Modells auf Ebene der Nutzerstimmungen höher ist als die der Vorhersagemodelle auf Gesamt- oder Themenstimmungsebene.

## 3 Methode

Dieses Kapitel beschreibt die Stichprobe, die Stimmungsextraktion, die statistischen Methoden und das neue Verfahren.

### 3.1 Stichprobe und Stimmungsextraktion

#### **DAX und Tweets**

Die täglichen Schlusskurse des Deutschen Aktienindex werden über die Webseite Yahoo Finanzen geladen. Diese sind mit dem Reuters Instrument Code  $\wedge$ GDAXI zu identifizieren.

Da es keinen bereits verfügbaren Datensatz mit Twitter-Nachrichten gibt, müssen eigene Daten gesammelt werden. Für diese Arbeit sind öffentliche Tweets der drei Themen DAX, Wirtschaft und Politik in zunächst allen Sprachen (nicht nur Englisch und Deutsch) in dem Zeitraum vom 02.09.2014 bis zum 07.03.2015 über einen Dienst mitgeschnitten worden. Die jeweilige Sprache eines Tweets wird von Twitter maschinell festgestellt (Twitter Inc., 2016c). Das #-Symbol kennzeichnet Schlagwörter oder Themen in einem Tweet und dient somit zur Kategorisierung von Nachrichten (Twitter Inc., 2016d). Die Stimmung wird täglich zwischen 0 bis 23:59 Uhr mitteleuropäischer Zeit gemessen. Doppelte Tweets wurden nicht aussortiert.

#### **Deutsches Lexikon**

Die Stimmung deutscher Tweets wird als Stimmungszahl mit dem Stimmungslexikon *SentiWS* Version 1.8c vom 21.03.2011 extrahiert. Das Lexikon wurde von der Universität Leipzig entwickelt und validiert. Es enthält 15.649 positive und 15.632 negative Wortformen inklusive ihrer Flexionsformen (Remus et al., 2018). Die 3.468 Stammformen von Wörtern, inklusive ihrer Flexionsformen, nehmen 1.215 diskrete Stimmungszahlen an. Hiervon liegen 774 negative Stimmungszahlen in dem Intervall  $[-1; -0,0042]$  und 441 positive Stimmungszahlen in dem Intervall  $[0,004; +1]$ . Die Ergebnismatrix enthält Datum, Anzahl, Stimmung und Anzahl erkannter Stimmungswörter. Adjektive und Adverbien deuten Stimmung explizit, Nomen und Verben deuten Stimmung implizit (Remus et al., 2010, S. 1168). Die Stimmungszahl ist diskret und ordinal. Die 3.468 Stammformen des deutschen Lexikons sind im Intervall  $[-1, 1]$ . Die Verteilung der Stimmungszahlen einzelner Wörter ist in Abbildung 3.1 dargestellt.

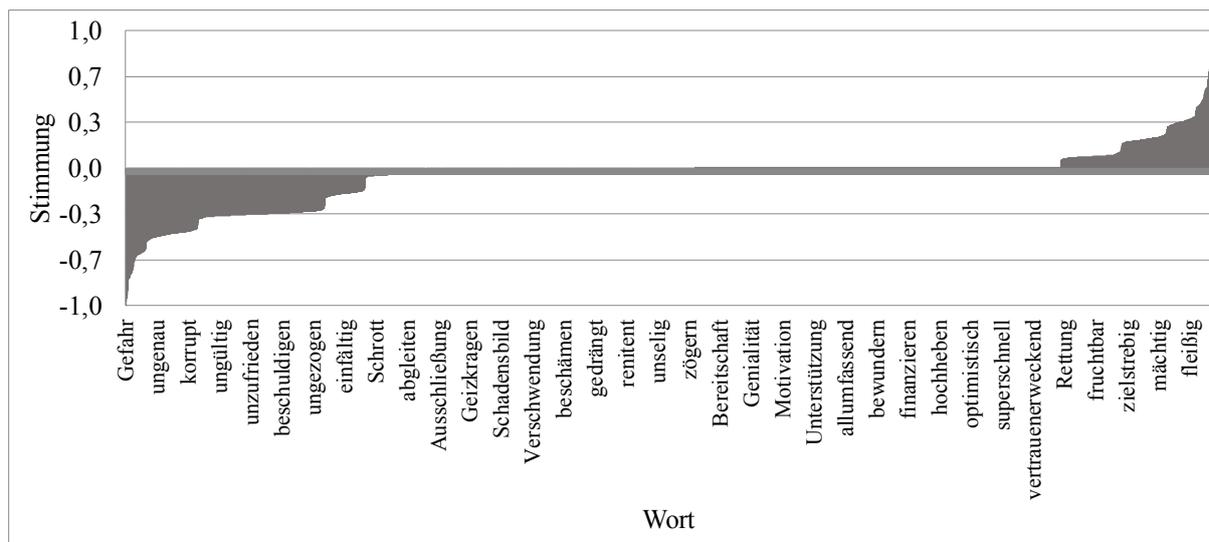


Abbildung 3.1: Stimmungszahlen der Stammformen des deutschen Lexikons

Quelle: Eigene Darstellung

Die Beschriftung der Abszisse enthält jede 87. Stammform. 859 Wörter haben den Median -0,048 als Stimmungszahl. Das Wort mit der schlechtesten Stimmung ist „Gefahr“ (-1). Das Wort mit der besten Stimmung ist „gelungen“ (+1). Die Flexionen eines Wortes haben dieselbe Stimmungszahl. 75% der Wörter haben eine neutrale Stimmungszahl. Ausreißer bzw. deutlich ausgeprägte Stimmungswörter bestimmen maßgeblich die Stimmung in Texten.

### Englisches Lexikon

Die Stimmung englischer Tweets wird mit dem *Opinion Lexicon* (Hu et al., 2004, S. 757) extrahiert. Das englische Lexikon besteht im Gegensatz zum deutschen Lexikon aus positiven und negativen Wörtern, siehe Tabelle 3.1. Es enthält keine Stimmungszahlen.

Tabelle 3.1: Anzahl positiver und negativer Wörter im englischen Lexikon

Wörter	Anzahl	%
Positive	2.006	30%
Negative	4.738	70%
SUMME	6.744	100%

Quelle: Eigene Darstellung

### Normalisierung

Ein Skript extrahiert die Stimmung aus den Tweets. Die Tweets werden in folgender Reihenfolge normalisiert, damit sie mit den regulären Ausdrücken der Lexika verglichen werden können:

1. Umwandlung in Kleinbuchstaben
2. Entfernen von Internet-Verknüpfungen, gekennzeichnet mit `http://`

3. Entfernen von Satzzeichen, wie Punkt und Ausrufungszeichen
4. Entfernen von Steuerzeichen, wie Tabulatoren
5. Zusammenführen mehrfacher Leerzeichen zu einem
6. Entfernen von Leerzeichen am Anfang und Ende eines Tweets

Das Ergebnis der deutschen Stimmungsextraktion ist eine Textdatei, deren Spalten durch Kommata getrennt sind. Diese Spalten sind: ID, normalisierter Text, Anzahl der Wörter eines Tweets ohne Links und Tags, Anzahl positiver Wörter, Anzahl negativer Wörter und Stimmungszahlen. Das Ergebnis der englischen Stimmungsextraktion ist ebenfalls eine Textdatei und enthält unter anderem die folgenden Spalten: Normalisierter Text, Anzahl der Wörter eines Tweets ohne Internetverknüpfungen, Anzahl positiver Wörter und Anzahl negativer Wörter.

### 3.2 Unterschiede, Zusammenhänge und Ähnlichkeiten

Die Untersuchung zur Verbesserung der Vorhersage des DAX bedarf einer Abfolge von statistischen Methoden. Diese werden in diesem und im nächsten Kapitel erläutert.

#### Gesamtüberblick der Methoden

Abbildung 3.2 gibt einen Gesamtüberblick der Methoden auf den jeweiligen Ebenen.

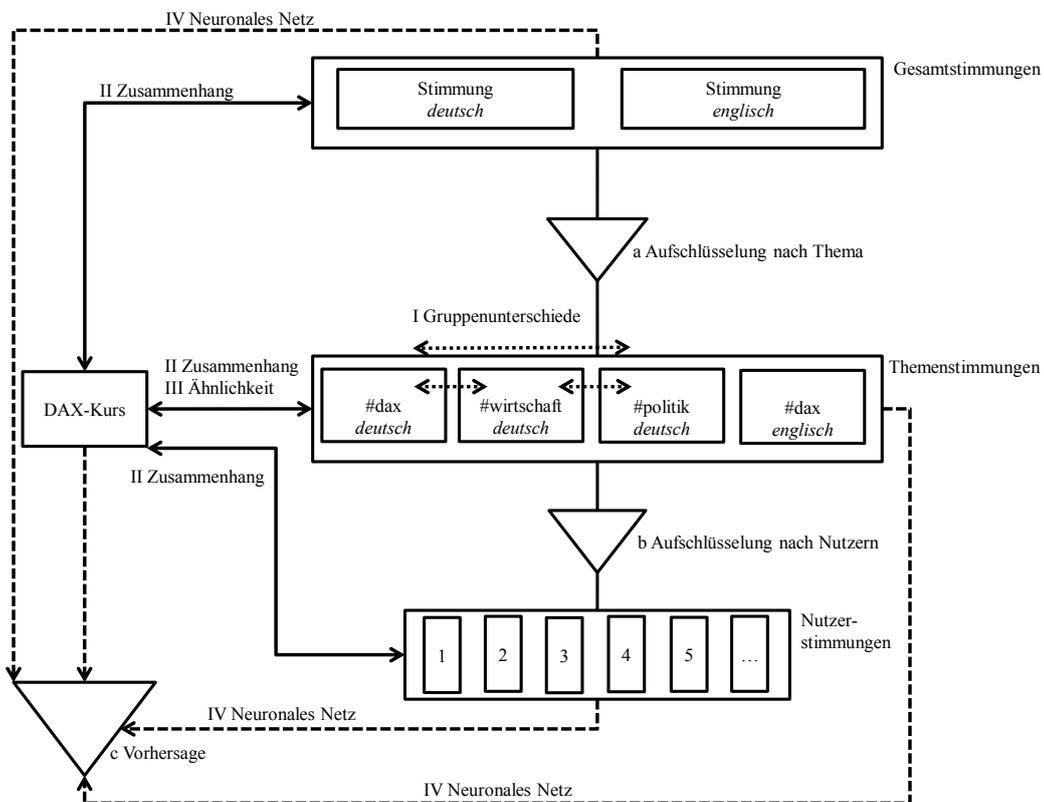


Abbildung 3.2: Überblick der statistischen Methoden

Quelle: Eigene Darstellung.

Zur verbesserten Übersicht sind die statistischen Methoden mit I-IV und die Schritte mit a-c beschriftet. Zunächst wird festgestellt, ob die (zeitversetzte) Gesamtstimmung mit dem DAX zusammenhängt (II). Sollte kein Zusammenhang bestehen, rechtfertigt dies die Aufschlüsselung nach Themen. Zeitversetzt bedeutet in diesem Zusammenhang, dass die Twitter-Stimmungen bis zu sieben Tage in die Vergangenheit verschoben werden (die gestrige Wirtschaftsstimmung, die vorgestrige Wirtschaftsstimmung, usw.).

Die Einzelstimmungen werden für jeden Nutzer themenspezifisch betrachtet, da ein Nutzer zu unterschiedlichen Themen auch eine andere Stimmung haben kann. Daher wird zunächst die Gesamtstimmung nach Themen aufgeschlüsselt (a). Bei der thematischen Aufschlüsselung werden die Themen aus den deutschen und den englischen Tweets ausgewählt. Aus den jeweiligen Gesamtstimmungen entstehen so vier Themenstimmungen. Die unterschiedlichen Stimmungsniveaus zwischen den Themen werden herausgestellt (I) um die thematische Abgrenzung zu rechtfertigen. Sollten sich die Stimmungen nicht gemäß ihren Lageparametern unterscheiden, so wäre eine andere Themenwahl notwendig. Die Themenstimmungen werden ebenfalls auf einen Zusammenhang mit dem DAX hin untersucht (II). Fehlende Zusammenhänge der Themenstimmung rechtfertigen eine weitere Aufschlüsselung nach Nutzern. Zusätzlich wird eine Ähnlichkeitsanalyse zwischen Themenstimmungen und dem DAX durchgeführt (III), um auf einem niedrigeren Skalenniveau (die Stimmungen sind hier binär) die Notwendigkeit einer weiteren Aufschlüsselung nach Nutzern zu verdeutlichen. Auf Gesamt-, Themen- und Nutzer-ebene werden DAX-Vorhersagen mit einem neuronalen Netz geprüft (IV). Verbesserungen der DAX-Vorhersagen durch Aufschlüsselungen sind mit der Modellgüte des neuronalen Netzes festzustellen. Die Methoden sind in Tabelle 3.2 zusammengefasst.

Tabelle 3.2: Statistische Methoden zur Datenanalyse

Statistische Methode(n)	Ebene(n)	Prüfung
Kruskal-Wallis-Test, Mann-Whitney-U-Test	Thema	Gruppenunterschiede
Spearman's Rangkorrelationskoeffizient	Gesamt, Thema, Nutzer	Zusammenhänge
M-Koeffizient	Thema	Zusammenhänge
Neuronales Netz	Gesamt, Thema, Nutzer	Vorhersage

Quelle: Eigene Darstellung

Abbildung 3.3 zeigt die Methoden auf Datenebene bei der Normalisierung, der Stimmungsextraktion mit Lexika und der Zusammenhangsanalyse zwischen den Twitter-Stimmungen nach Themen und dem DAX.

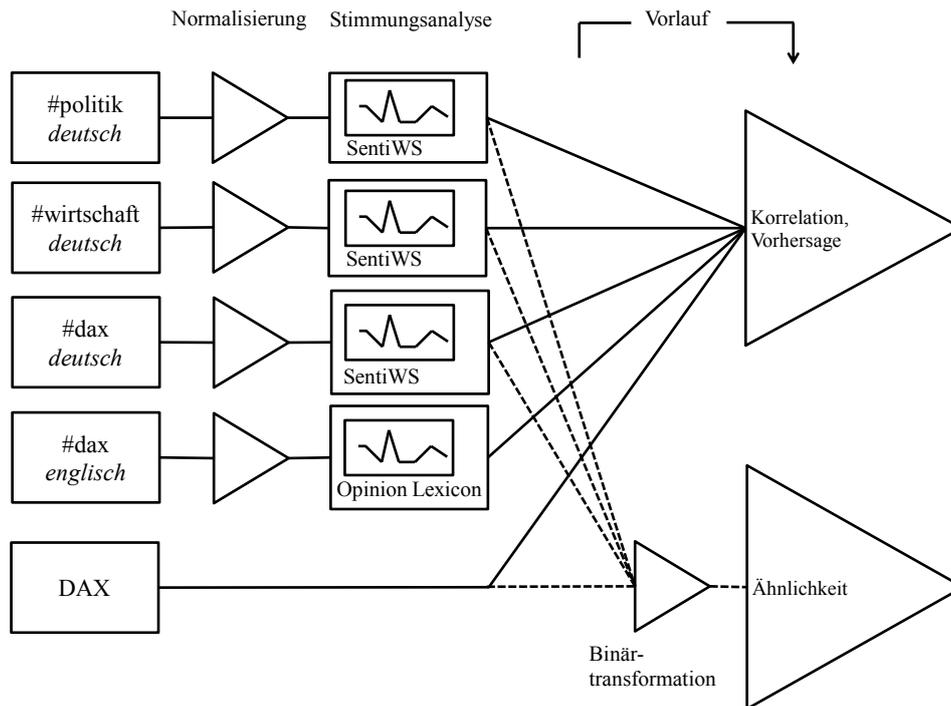


Abbildung 3.3: Untersuchungsanordnung

Quelle: Eigene Darstellung

Die deutschen DAX-, Wirtschafts-, Politik- und die englischen DAX-Tweets werden zunächst normalisiert, wie in Kapitel 3.1 beschrieben. Die Stimmung wird aus jedem Wort mit den jeweiligen Lexika individuell extrahiert, damit ein Zusammenhang der Stimmungen mit dem DAX untersucht werden kann. Hierbei ergab sich das Problem, dass viele dieser Nutzer mehrere Tweets pro Tag verfasst hatten. In diesen Fällen wurde der Median der Stimmung aller ihrer Tweets pro Tag verwendet. Ziel dieser Arbeit ist die Verbesserung der DAX-Vorhersage durch Optimierung der Nutzerstimmungen. Bei diesem neuen Verfahren müssen vorgelagert Tagesstimmungen ausgewählt werden. Dies ist erforderlich, weil das neuronale Netz nur mit einer begrenzten Anzahl von Eingangsneuronen funktioniert.

### Gruppenunterschiede

Unterschiede zwischen den Lageparametern der Themenstimmungen rechtfertigen deren Abgrenzung. Dies bedeutet, dass zwischen den Themen ein unterschiedliches Stimmungsniveau herrscht. Es wird erst nach der Themenaufschlüsselung nach Nutzern aufgeschlüsselt. Zu fragen ist, ob die Tweets mit politischen Inhalten die gleiche Stimmung enthalten wie Tweets zur Wirtschaft oder zum DAX. Hierzu werden Lageunterschiede zwischen den Medianen der drei deutschen Gruppen mit dem Kruskal-Wallis-Test und dem Mann-Whitney-U-Test ermittelt. Sollten Gruppenunterschiede festgestellt werden, wird im nächsten Schritt nach Zusammenhängen zwischen den Themenstimmungen und dem DAX gesucht.

### **Zusammenhangsanalyse bei Themenstimmungen**

Hierbei soll der negative Median der täglichen Nutzerstimmungen auf Korrelation mit dem DAX geprüft werden. Dies ist der tägliche Median aus den negativen Stimmungswerten. Die positiven Stimmungswerte werden ignoriert. Dies ist damit begründet, dass das deutsche Lexikon Stimmungen durch negative Worte differenzierter abbildet als durch positive, obwohl das deutsche Lexikon gleich viele positive wie negative Wörter umfasst. Ein Zusammenhang zwischen Themenstimmungen soll nun für jedes Thema gesondert geprüft werden. Spearmans Rangkorrelationskoeffizient eignet sich für ordinale Daten, kleine Stichproben oder bei Ausreißern (Elliott et al., 2007, S. 193). Die Zusammenhänge mit dem täglichen DAX werden jeweils gesondert ermittelt. Die Korrelationen werden für alle Themen der deutschen und englischen Tweets berechnet. Da die Stimmungen nicht auf ein niedrigeres Skalenniveau transformiert werden müssen, geht keine Information verloren. Ist hier kein Zusammenhang feststellbar, so kann zusätzlich die Ähnlichkeit des Steigens und Fallens von Stimmung und DAX ermittelt werden, beschrieben im nächsten Absatz.

### **Zusammenhangsanalyse bei Nutzerstimmungen**

Die Vorhersage mit Nutzerstimmungen wird aufgrund der großen Anzahl an Nutzern als problematisch angesehen. Deshalb wird die Zuverlässigkeit jedes einzelnen Nutzers mit Hilfe der Korrelation untersucht. Zunächst wird nach den Nutzern mit den meisten Abonnenten aufgeschlüsselt, da deren Stimmung viele Nutzer erreicht. Das Resultat ist eine Tabelle absoluter und relativer Häufigkeiten von Tweets. Darauf wird nach den zehn Nutzern gemäß Anzahl geschriebener Tweets aufgeschlüsselt. Das Resultat ist ebenfalls eine Tabelle absoluter und relativer Häufigkeiten der Tweets. Im Anschluss werden die Nutzer aufgeschlüsselt, deren Stimmung mit dem DAX zusammenhängt. Diese Zusammenhänge werden ebenfalls mit Hilfe des Rangkorrelationskoeffizienten berechnet. Das Ergebnis ist eine Liste derjenigen Nutzer, deren Stimmung signifikant mit dem DAX zusammenhängt.

### **Ähnlichkeitsanalyse**

Außer der Korrelation wird die Ähnlichkeit untersucht, um eine andere Sichtweise auf die Daten zu erhalten und eine eventuelle Transformation auf ein niedrigeres Skalenniveau zu rechtfertigen. Im Kontext dieser Arbeit ist der M-Koeffizient das geeignete Ähnlichkeitsmaß. Die Methode des M-Koeffizienten wird angewendet, wenn die Variablen symmetrisch und die beiden zu messenden Größen gleich wichtig sind. Das gleichzeitige Vorhandensein und die gleichzeitige Abwesenheit, in diesem Fall gleichzeitiges Steigen und Fallen von sowohl DAX als

auch Twitter-Stimmung, hätten dieselbe Bedeutung und dieselbe Auswirkung auf das Ähnlichkeitsmaß (Dunn et al., 2004, S. 26). Die Ähnlichkeitsanalyse, in diesem Fall für binäre Daten, wird bei den deutschen Tweets angewendet, um Übereinstimmung der täglichen Auf- und Abwärtsbewegung von Stimmung und DAX zu ermitteln. Es wird demzufolge das gleichzeitige Steigen und Fallen zweier Variablen mit dem M-Koeffizienten als Ähnlichkeitsmaß untersucht, nachdem die Variablen in binäre Form transformiert worden sind. Beim M-Koeffizienten sind im Zähler alle übereinstimmenden Fälle enthalten (Backhaus et al., 2016, S. 463). Hierbei bedeutet 1 Anstieg und 0 Fall von DAX und Twitter-Stimmung. Die Koeffizienten der Ähnlichkeitsmessung liegen zwischen 0 bei vollkommener Unähnlichkeit und 1 bei vollkommener Ähnlichkeit (Backhaus et al., 2016, S. 462). Die Variablen Twitter-Stimmung und DAX sind in binäre Form transformiert. Nach Bildung der Punktepaare werden deren absolute Häufigkeiten bestimmt. Tabelle 3.3 enthält die Kombinationsmöglichkeiten binärer Variablen.

Tabelle 3.3: Kombinationsmöglichkeiten binärer Variablen

DAX	Twitter-Stimmung		Zeilensumme
	Steigt (1)	Fällt (0)	
Steigt (1)	a	c	a + c
Fällt (0)	b	d	b + d
Spaltensumme	a + b	c + d	M

Quelle: Übernommen aus Backhaus et al. (2016, S. 460)

In Tabelle 3.3 sind die Fälle gleichzeitiger Übereinstimmung die Felder a bzw. d. b und c sind die Fälle für die Nichtübereinstimmung.  $M$  ist die Gesamtsumme aller Fälle (Übereinstimmungen und Nichtübereinstimmungen). Der M-Koeffizient  $S_{ij}$  ist demnach die Ähnlichkeit zwischen den Objekten  $i$  und  $j$ :

$$S_{ij} = \frac{a + d}{M} \quad (3.1)$$

Die Ähnlichkeitsanalyse ist jedoch mit Informationsverlust verbunden, da die Stimmung auf ein nominales Skalenniveau transformiert werden muss.

### Nichtparametrische Regression

Während lineare Zusammenhänge durch eine lineare Regression veranschaulicht werden, ist für einen nichtlinearen Zusammenhang die nichtparametrische Regression geeignet. Sie kommt zur Anwendung, wenn die Voraussetzungen für eine lineare Regression nicht gegeben sind. Als nichtparametrische Regression wird die Glättungskurve als additive Quantilregression nach Koenker et al. (1994) sowie Koenker et al. (2004) erstellt. Während die klassische Regression nur Informationen über einen bedingten Erwartungswert gibt, erweitert die Quantilregression den Blickwinkel auf die gesamte bedingte Verteilung der Antwortvariablen (Davino et al.,

2013, S. 20). Die Glättungskurve hat lokale Gewichte (Cleveland, 1979, S. 831). Im anschließenden Kapitel wird die Methode der Nutzerbasierten Aufschlüsselung von Stimmungen erläutert.

### 3.3 Vorhersagemodell

#### **Neuronales Netz für die nichtlineare Klassifikation**

Märkte sind komplexe adaptive Systeme, in denen sich die heterogenen Investoren interaktiv organisieren (Mauboussin, 2002, S. 12f). Komplexe adaptive Systeme bestehen aus mehreren, miteinander zusammenhängenden Elementen. Adaptiv sind sie, weil sie sich an ihre Umwelt anpassen und aus Erfahrung lernen können (Holland, 1992, S. 19). Neuronale Netze reduzieren die Komplexität für eine Klassifikation (Hinton et al., 2006, S. 507). Komplexe Systeme sind auch nichtlinear und dynamisch (Lansing, 2003, S. 183). Folglich bedarf es für die Vorhersage eines Marktes einer nichtlinearen Methode, hier eines neuronalen Netzes. Lee et al. (1993, S. 289) bestätigen, dass das neuronale Netz für nichtlineare ökonomische Zeitreihen gleich oder sogar besser geeignet ist als statistische Standardtests.

Auf jeder Ebene wird die Modellgüte einer DAX-Vorhersage getestet. Gesamt-, Thema und Nutzerstimmungen werden mit Hilfe eines neuronalen Netzes wieder zusammengesetzt. Zur Generierung einer Kaufentscheidung wird als letzte Instanz eine Klassifikation benötigt. Lineare Klassifikationsmodelle sind unter anderem die logistische Regression, die lineare Trennfunktion oder das Log-lineare Modell (Adler, 2009, S. 435ff). Sollten Zusammenhänge nichtlinear sein, werden Algorithmen für maschinelles Lernen benötigt. Hier sind die Nächster-Nachbar-Klassifikation, die Entscheidungsbäume, die Stützvektormaschine und das neuronale Netz zu nennen (Adler, 2009, S. 445ff). Das autoregressive Modell mit integriertem gleitendem Durchschnitt nach Box-Jenkins ist bei Zeitreihenvorhersagen verbreitet, jedoch dem neuronalen Netz unterlegen (Adebisi et al., 2014, S. 6). Neuronale Netze können zusätzlich zu den klassischen statistischen Methoden eingesetzt werden, um nichtlineare und komplexe Zusammenhänge zu modellieren (Backhaus et al., 2016, S. 22). So empfehlen die Autoren diese Methode insbesondere für die Vorhersage von Aktienkursen (Backhaus et al., 2016, S. 23). Ein neuronales Netz eignet sich ebenfalls für die Klassifikation, wenn die Zeitreihen der Stimmungen unvollständig sind, d. h. wenn es eine begrenzte Zahl fehlender Werte gibt (Hawley et al., 2008, S. 68). Dies rechtfertigt die Methode besonders auf der Ebene der Nutzerstimmungen, da nicht jeder Nutzer auch jeden Tag einen Tweet veröffentlicht.

### Architektur eines neuronalen Netzes

Künstliche Neuronale Netze, als eine Simulation echter neuronaler Netze im Zentralnervensystem, haben Synapsen. Das sind die Stellen, an denen Informationen von Nervenzelle zu Nervenzelle oder von einer Nervenzelle auf andere Zellen übertragen werden. Es handelt sich dementsprechend um einen Verbund von Nervenzellen, den sogenannten Neuronen (Donahoe, 1997, S. 11). Das neuronale Netz hat die Stimmungen als Eingangsvariablen. Die Zusammenhänge zwischen den Variablen werden durch Lernen ermittelt (Backhaus et al., 2016, S. 603). Die Modellierung mit einem neuronalen Netz hat gemäß den Autoren die folgenden Vorteile:

- Es muss keine kausale Verknüpfung zwischen Variablen postuliert werden
- Die Verknüpfungen müssen nicht linear sein
- Variablen unterschiedlichster Skalenniveaus werden berücksichtigt
- Das neuronale Netz kann klassische Methoden ersetzen

Abbildung 3.4 zeigt den Aufbau eines einfachen neuronalen Netzes.

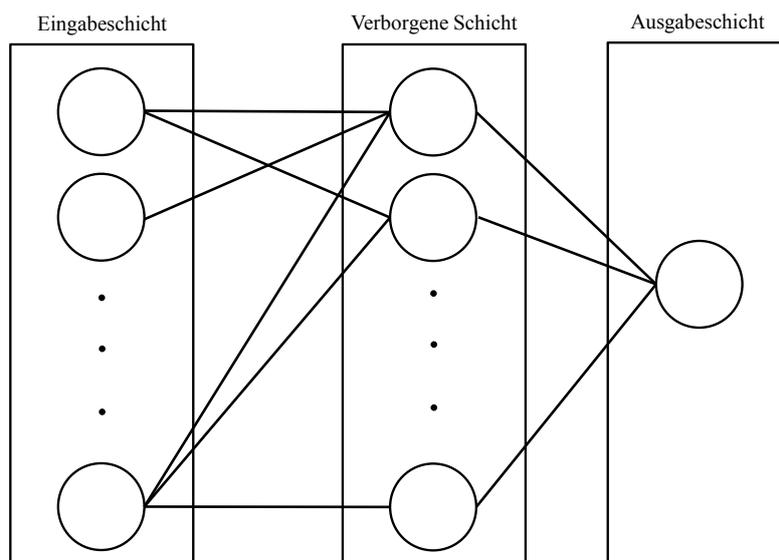


Abbildung 3.4: Vereinfachte Architektur eines neuronalen Netzes

Quelle: Übersetzt von Hafezi et al. (2015, S. 204)

Die Architektur des neuronalen Netzes ist die Struktur der Verbindungen der Neuronen (Fausett, 1994, S. 3). Die Stimmungen befinden sich auf der linken Eingabeschicht und sind die Eingänge. Die mittlere Schicht besteht aus den Funktionseinheiten in Form der Neuronen. Die Linien symbolisieren die synaptischen Verbindungen zwischen den Einheiten in den jeweiligen Schichten. Die Einheiten der mittleren Schicht wirken auf die dichotome Variable DAX auf der rechten Ausgabeschicht, nämlich den beiden Ausgaben „DAX steigt“ oder „Dax fällt“. Bei einem rückgekoppelten Neuronales Netzwerk wären die Neuronen in der verborgenen Schicht

zusätzlich untereinander verbunden (Graves, 2012, S. 22), welches hier nicht zur Anwendung kommt.

Aufgabe eines neuronalen Netzes ist die Ermittlung einer Kombination von Parametern, die eine Zielfunktion als Fehlerfunktion  $E(f)$  minimiert (Matignon, 2005, S. 77). Als Vorhersage wird hier der DAX in Bezug auf Steigen und Fallen betrachtet. In diesem Kontext ist das neuronale Netz eine Funktion von Twitter-Stimmungen. Das Vorhersagemodell erhält die Tagesstimmungen sowie den DAX als binäre abhängige Variable. Das Modell beinhaltet überwachtes Lernen, und die Informationsverarbeitung ist vorwärtsgerichtet (Backhaus et al., 2016, S. 608). Neuronale Netze transformieren eine  $n$ -dimensionale Eingabe in eine  $m$ -dimensionale Ausgabe und modellieren die Funktion  $F: \mathbb{R}^n \rightarrow \mathbb{R}^m$  (Rojas, 2013, S. 29). Sie haben die folgende Form (Hájek et al., 2013, S. 297):

$$y = \sum_{k=1}^K v_k \left( d \left( \sum_{j=1}^J w_{j,k} x_{j,k}^t \right) \right) \quad (3.2)$$

Gemäß den Autoren ist  $v_k$  der Vektor der synaptischen Gewichte zwischen den Neuronen der verborgenen Schicht und der Ausgangsschicht,  $w_{j,k}$  ist der Vektor der synaptischen Gewichte zwischen Eingangsneuronen und der verborgenen Schicht,  $k$  ist der Index der Neuronen in der verborgenen Schicht,  $j$  ist der Index der Eingangsneuronen,  $d$  ist die Aktivierungsfunktion und  $x_{j,k}^t$  ist der Eingangsvektor des neuronalen Netzes. Eine Aktivierungsfunktion bestimmt, welchen Wert ein Neuron an ein anderes Neuron weitergibt (Schmidt et al., 2010, S. 150), ob es dieses aktiviert. Die Aktivierungsfunktion dient in diesem Kontext der DAX-Vorhersage als der eigentlichen Klassifizierung (Alder, 2009, S. 424).

### **Trainieren der Klassifikation**

Ein neuronales Netz modelliert die Architektur anhand der erlernten Zusammenhänge. Es passt sich den gegebenen Daten an. Dies setzt voraus, dass das neuronale Netz zunächst mit Hilfe eines Datensatzes trainiert werden muss. Somit muss die Stichprobe zunächst in eine Trainings- und in eine Testmenge aufgeteilt werden. Das Training wird bei den verschiedenen Modellen mit 66-82% der Stichprobe durchgeführt. Beim Training werden schließlich die synaptischen Gewichte zwischen den Neuronen geschätzt (Zhang, 2004, S. 5). Dies bedeutet, dass die anfangs gesetzten Gewichte (Zufallswerte) durch das Training verbessert werden.

Das neuronale Netz benötigt keine Annahme eines Modelles, da es sich bestmöglich an die Trainingsdaten anpasst und daher geringe Verzerrung aufweist (Zhang, 2004, S. 5). In vorliegendem Fall geht es bei der Vorhersage des DAX um eine richtige Klassifikation in einen steigenden oder in einen fallenden DAX. Das Klassifikationsproblem in diesem Kontext besteht

darin, dass das Objekt DAX durch beobachtbare Eigenschaften, die sich auf das Objekt beziehen, in die beiden vordefinierten Kategorien Steigen und Fallen eingeteilt werden soll (Volna et al., 2016, S. 31). Die Eigenschaften, die sich auf den DAX beziehen, sind die Eingangsneuronen des neuronalen Netzes. Sollen jedoch alle Einzelstimmungen eines jeden Nutzers betrachtet werden, so muss die Anzahl der Stimmungen aufgrund der damit einhergehenden Komplexität reduziert werden (Armstrong, 2001, S. 251). Dementsprechend müssen Stimmungen auf Nutzerebene ausgewählt werden.

### Hyperbeltangens als Aktivierungsfunktion der verborgenen Schicht

Eine Aktivierungsfunktion bestimmt für jedes Neuron in der verborgenen Schicht, bei welchen Werten es aktiviert wird, die es von der Eingabeschicht erhält. Die Aktivierungsfunktion für die Neuronen in der verborgenen Schicht ist der Hyperbeltangens  $\tanh x$  (Umkehrfunktion der Hyperbelfunktion) (Brauch et al., 1995, S. 269). Hierbei ist

$$y = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.3)$$

(Matignon, 2005, S. 137), wobei  $-1 < y < 1$ . Die Funktion hat einen S-förmigen Graphen, siehe Abbildung 3.5:

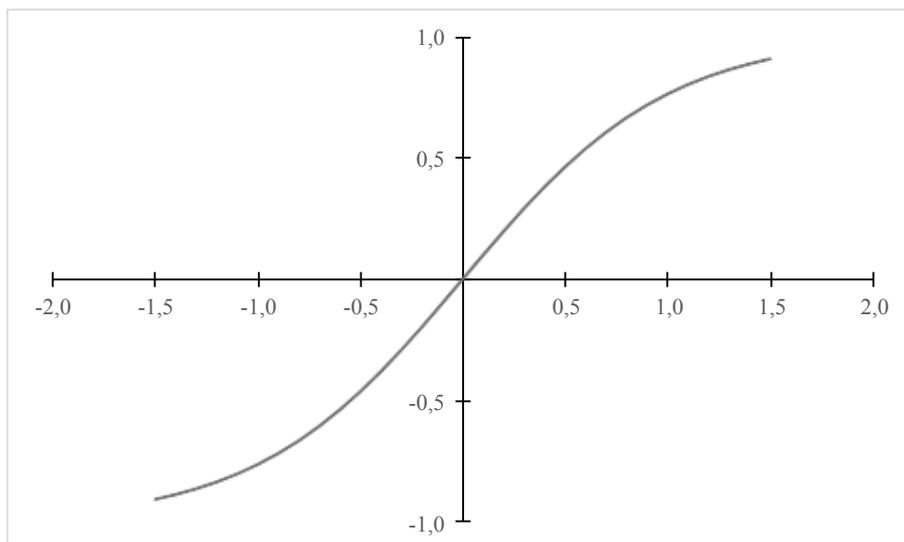


Abbildung 3.5: Hyperbeltangens

Quelle: Eigene Darstellung

### Aktivierungsfunktion der Ausgabeschicht

Das Neuron auf der Ausgabeschicht wird ebenfalls durch eine Funktion aktiviert. Diese bestimmt, bei welchen Werten es aktiviert wird, die es von den Neuronen der verborgenen Schicht

erhält. Die Aktivierungsfunktion der Ausgabeschicht ist eine normalisierte Exponentialfunktion (Bishop et al., 1995, S. 238) und transformiert die ungleich verteilten Daten in eine akzeptable Spannweite (Swingler, 1996, S. 32). Als Aktivierungsfunktion für die Ausgabeschicht ist

$$y(c_k) = \frac{e^{(c_k)}}{\sum_j e^{(c_j)}} \quad (3.4)$$

mit  $0 < y(c_k) < 1$  und  $\sum_j e^{(c_j)} = 1$  (Bishop et al., 1995, S. 225). Im Folgenden wird die Straffunktion der Aktivierungsfunktion beschrieben.

### **Fehlerfunktion bzw. Straffunktion auf der Ausgabeschicht**

Bei einem Klassifikationsproblem wird eine a-posteriori-Wahrscheinlichkeit für eine Klassenzugehörigkeit modelliert (Bishop et al., 1995, S. 194). Der Kreuzentropiefehler ähnelt in seiner Funktion der Residuenquadratsumme einer Regression und ist

$$E = - \sum_n \{ p^n \ln y^n + (1 - p^n) \ln(1 - y^n) \} \quad (3.5)$$

für binäre Zielvariablen mit  $p^n = 1$  eines Eingangsvektors mit einem einzigen Ausgang  $y^n$  von Klasse 1 (DAX steigt) und  $p^n = 0$  von Klasse 2 (DAX fällt) (Bishop et al., 1995, S. 230f).  $n$  ist die Anzahl der Neuronen.  $p^n$  ist die Soll-Ausgabe des n-ten Neurons.  $y^n$  ist die berechnete Ausgabe des n-ten Neurons (Ist). Die berechnete Ausgabe wurde mit der Aktivierungsfunktion der Ausgabeschicht ermittelt. Die Fehlerfunktion summiert alle Abweichungen aller Neuronen von der Ist- zur Soll-Klassenzugehörigkeit. Die Kreuzentropie ist folglich die Straffunktion der Aktivierungsfunktion der Ausgabeschicht (Dunne, 2007, S. 47) und somit auch ein Maßstab der Vorhersagequalität der Klassifikation. Zur Bewertung eines Vorhersagemodelles und zum Vergleich verschiedener Vorhersagemodelle wird die Modellgüte verwendet, beschrieben im nächsten Absatz.

### **Modellgüte als bestimmtes Integral der Grenzwertoptimierungskurve**

Das neuronale Netz soll anhand der trainierten Daten in der Lage sein, die Vorhersage des DAX zu generalisieren, um somit anhand von neuen Daten eine richtige Entscheidung treffen zu können (Menshaw, 2018, S. 65). Je besser die Qualität der Vorhersage, umso höher die Modellgüte, dargestellt mit der Grenzwertoptimierungskurve. Die Grenzwertoptimierungskurve zeigt die Sensitivitäts- und Spezifitätswahrscheinlichkeiten, basierend auf einer binären Zielvariablen (Matignon, 2005, S. 399). In Bezug auf die Arbeit sind diese Wahrscheinlichkeiten wie folgt erklärt. Gegeben ist die Wahrheitsmatrix als Kontingenztafel (Tabelle 3.4):

Tabelle 3.4: Wahrheitsmatrix

		vorhergesagt	
		DAX steigt	DAX fällt
beobachtet	DAX steigt	a	b
	DAX fällt	c	d

Quelle: In Anlehnung an Matignon (2005, S. 399)

$a$  ist die Wahrscheinlichkeit eines richtig vorhergesagten Steigens des DAX,  $d$  die Wahrscheinlichkeit eines richtig vorhergesagten Fallens. Die Sensitivität ist  $\frac{a}{a+b}$ , die Spezifität ist  $\frac{d}{c+d}$ , die Falsch-Positiv-Rate ist  $\frac{c}{c+d}$  ( $1 - \text{Spezifität}$ ) und die Falsch-Negativ-Rate ist  $\frac{b}{a+b}$  ( $1 - \text{Sensitivität}$ ) (Matignon, 2005, S. 399). Diese Wahrscheinlichkeiten werden in Abhängigkeit von den zugenommenen Fällen in einer Grenzwertoptimierungskurve dargestellt:

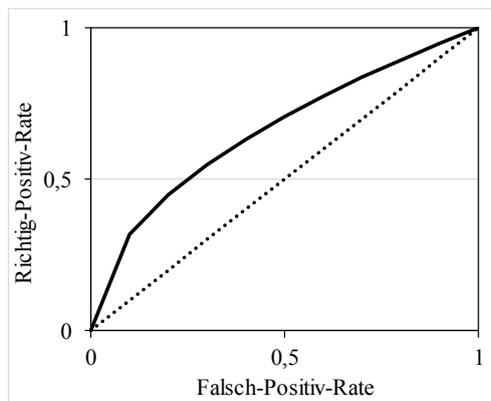


Abbildung 3.6: Grenzwertoptimierungskurve

Quelle: Eigene Darstellung

Die Einheiten der Achsen sind Prozent, mit 100% als Maximum angegeben. Die Ordinate als Sensitivität zeigt die Richtig-Positiv- und die Abszisse die Falsch-Positiv-Rate in Abhängigkeit vom Klassifikations-Schwellwertes (Krzanowski, 2009, S. 12). Die abhängige Variable DAX ist dichotom. Der Anteil richtig klassifizierter Fälle an allen Fällen mit gleicher Ausprägung ist die Sensitivität (Fromm, 2010, S. 134). Die Sensitivität bedeutet: DAX (Fallen oder Steigen) richtig vorhergesagt. Die  $1 - \text{Spezifität}$  bedeutet: DAX falsch vorhergesagt. Die gepunktete 45-Grad-Linie entspricht einem Zufallsprozess. Die Fläche unter der Kurve ist ein Güteindikator für die Vorhersagefähigkeit (Backhaus et al., 2016, S. 301). Je größer die Fläche unter der Kurve, desto besser ist die Klassifikation (James et al., 2013, S. 147). Der Wert der Modellgüte liegt zwischen 0 für eine inakkurate und 1 für eine perfekt akkurate Vorhersage (Looney et al., 2015, S. 307). Die Grenzwertoptimierungskurve beschreibt die Vorhersagekraft bei z. B. einem steigenden DAX. Die Richtig-Positiv-Rate bedeutet: DAX steigt, und das neuronale Netz hat dies richtig vorhergesagt. Die Fläche unter der Grenzwertoptimierungskurve ist das bestimmte

Integral und dient der Beurteilung der Klassifikationsgüte. Tabelle 3.5 zeigt Richtwerte zur Interpretation der Modellgüte.

Tabelle 3.5: Richtwerte zur Bewertung des neuronalen Netzes

Modellgüte	Interpretation
0,00-0,69	Nicht akzeptabel
0,70-0,79	Akzeptabel
0,80-0,89	Ausgezeichnet
0,90-1	Hervorragend

Quelle: Übersetzt von Looney et al. (2015, S. 307)

Die Modelle sagen das Steigen und Fallen des DAX gleichermaßen voraus, d. h. die Güte der jeweiligen Modelle ist bei steigendem und fallendem DAX gleich. Es werden insgesamt 18 Vorhersagen modelliert. So werden jeweils drei Vorhersagen für die Gesamt- und die Themenstimmungen durchgeführt, sowie zwölf Vorhersagen auf Basis der Nutzerstimmungen. Die gesamte Modellgüte wird folglich durch die Netzwerkarchitektur sowie durch die Trainings- und Testphase bestimmt.

### 3.4 Optimales Verfahren

Sollte die Anzahl von Stimmungen für die Vorhersage mit einem neuronalen Netz zu groß sein, so sind diese durch ein neues Verfahren auszusortieren. Es wird daher eine neue Problematik untersucht, nämlich das Aussortieren von Stimmungen mit Hilfe einer Korrelation als vorgelagerte Methode zur Optimierung eines neuronalen Netzes. Hierbei werden die Dimensionen des Eingaberaums reduziert. Das Ausgangsproblem ist, dass ein neuronales Netz insbesondere bei kleinen Stichproben mit einer begrenzten Anzahl von Stimmungen einsetzbar ist. Dies bedeutet, dass nicht alle Nutzerstimmungen mit deren Vorläufen als Eingangsneuronen verwendet werden können. Die Korrelation ist für die Aussortierung eine geeignete Methode zur Optimierung. Ziel ist es, ein neues Verfahren zu formalisieren, welches die Vorläufe der signifikanten Stimmungen anpasst und somit die Modellgüte optimiert. Zur Optimierung eignet sich demzufolge eine serielle Kombination von Algorithmen, dargestellt Abbildung 3.7.

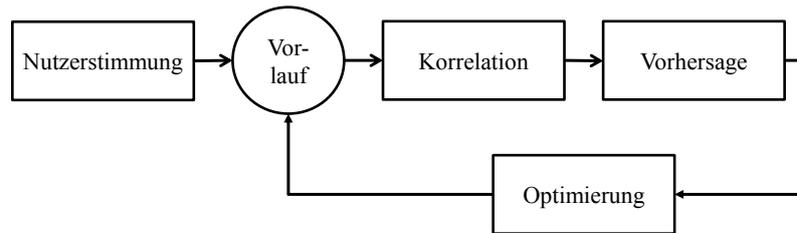


Abbildung 3.7: Serielle Kombination von Algorithmen

Quelle: Eigene Darstellung

Mit Hilfe der Korrelation werden die Stimmungen ausgewählt, die klassifiziert werden sollen. Das neuronale Netz klassifiziert die ausgewählten Stimmungen und berechnet eine Zielfunktion. Das neuronale Netz gibt den Wert des Vorlaufs zur Optimierung der Zielfunktion an die Korrelationsanalyse zurück. So entsteht eine Optimierungsschleife.

Unter Zuverlässigkeit eines Nutzers wird die Eigenschaft einer Stimmung beschrieben, die Muster zur Vorhersage des DAX enthält. Darunter wird nicht die Glaubwürdigkeit oder Vertrauenswürdigkeit von Nachrichten, die Stimmungen enthalten, verstanden. Vertrauenswürdige Tweets enthalten Verknüpfungen auf Internetseiten und verbreiten sich speziell über Twitter (Xia et al., 2012, S. 682). Die Vertraulichkeit von Tweets wurde nicht berücksichtigt.

Die Zuverlässigkeit eines Nutzers, ob er mit seiner Stimmung den DAX vorhersagt, wird mit der Signifikanz des Korrelationskoeffizienten bestimmt. Die Tagesstimmung dieses Nutzers wird nach Prüfung der Signifikanz an das neuronale Netz weitergeleitet. Somit wird die jeweilige Zuverlässigkeit der Einzelstimmungen nicht als gegeben angenommen, sondern sie wird über die Zeit hinweg anhand der Stichprobe geschätzt. Fraglich ist, wie ein Nutzer behandelt wird, der eine negative Korrelation vorweist. In diesem Fall gibt es grundsätzlich zwei Möglichkeiten. Entweder der Nutzer wird als gänzlich unzuverlässig betrachtet, oder seine Stimmung wird nach  $|r_s|$  transformiert. Negative Korrelationen werden jedoch nicht transformiert. Ein negativer Zusammenhang gilt hier als ebenso zuverlässig wie ein positiver Zusammenhang. Die Richtung der individuellen Zusammenhänge berücksichtigt schließlich das neuronale Netz. Die Vorhersagekraft soll durch das neue Verfahren verbessert werden. Dieses schlüsselt die Gesamtstimmung nach Nutzerstimmungen auf und optimiert das neuronale Netz zur Vorhersage. Am Ende sollte eine Kaufentscheidung stehen, d. h. das letzte Glied ist die Klassifikation zur Vorhersage. Im Kontext dieser Arbeit hat sich das neuronale Netz aufgrund der nichtlinearen Zusammenhänge als die geeignetste Methode erwiesen. Diese ist zu optimieren, indem die Stimmungen ausgewählt werden. Mit zunehmender Qualität der Stimmungen sollte die Güte der Vorhersage steigen. Demgemäß ist die Modellgüte des neuronalen Netzes zu optimieren. Das neue Verfahren maximiert das bestimmte Integral als Zielfunktion. Dies wird durch eine

geeignete Vorauswahl der Stimmungen realisiert. Diese werden durch signifikante Korrelation der Einzelnutzer im Vorfeld ausgewählt. Der Parameter zur Optimierung der Zielfunktion ist der Vorlauf der Stimmung. Das neuronale Netz klassifiziert durch Anpassung des Vorlaufes. Die Zielfunktion ist

$$\text{Max} \left( \int_0^1 f(x) dx \right) \quad (3.6)$$

mit  $f(x)$  als Funktion der Grenzwertoptimierungskurve für einen steigenden bzw. fallenden DAX. Die Vorhersagen berücksichtigen den Vorlauf der täglichen Stimmungen. Weiterhin ist die untere Begrenzung der technischen Berechenbarkeit des Korrelationskoeffizienten zu berücksichtigen. So gilt  $u_i > 7$  mit  $u$  als Anzahl der täglichen Stimmungen eines Nutzers  $i$ . Die signifikanten Korrelationen sind mit  $s_i \leq 0,05$  auszuwählen.  $s$  ist die Signifikanz des Korrelationskoeffizienten.

### 3.5 Computerprogramme

Die Rohdaten werden zunächst mit Microsoft Excel aufbereitet. Die statistische Programmiersprache R extrahiert Stimmungen aus Tweets, berechnet die nichtparametrische Korrelation und Regression. Die Ermittlung von Dubletten, die Gruppenunterschiede, die Ähnlichkeitsanalyse, der Chi-Quadrat-Test und das neuronale Netz werden mit IBM SPSS durchgeführt.

## 4 Ergebnis

Im diesem Kapitel werden zunächst die Lexika beschrieben. Darauf folgen die Ergebnisse der thematischen und daraufhin der nutzerbasierten Aufschlüsselung. Das Vorhersagemodell wird auf Gesamt-, Themen und Nutzerebene angewendet und mit Hilfe der Optimierung auf Nutzerebene verbessert.

### 4.1 Gesamtstimmungen

#### Korrelationen

Ausgangspunkt für eine Aufschlüsselung ist der nichtexistierende Zusammenhang der Gesamtstimmung aller Tweets mit dem DAX, dargestellt in Tabelle 4.1.

Tabelle 4.1: Korrelation DAX und deutsche Stimmung

	1	2	3	4	5	6	7	8
1 DAX								
2 Stimmung	0,109							
3 Stimmung <sub>t-1</sub>	0,088	0,101						
4 Stimmung <sub>t-2</sub>	0,124	0,050	0,101					
5 Stimmung <sub>t-3</sub>	0,053	0,065	0,050	0,101				
6 Stimmung <sub>t-4</sub>	0,069	-0,023	0,065	0,050	0,101			
7 Stimmung <sub>t-5</sub>	0,120	0,151*	-0,023	0,065	0,050	0,101		
8 Stimmung <sub>t-6</sub>	0,130	0,061	0,151*	-0,023	0,065	0,050	0,101	
9 Stimmung <sub>t-7</sub>	0,121	0,003	0,061	0,151*	-0,023	0,065	0,050	0,101

\*\* Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Keine der Stimmungen hängt signifikant mit dem DAX zusammen. Lediglich die Stimmung von vor fünf Tagen hängt mit der heutigen Stimmung zusammen ( $r_s=0,151$ ;  $p<0,05$ ).

#### Vorhersage mit Gesamtstimmungen

Zum Vergleich der Modellqualitäten sind in Tabelle B (Seite 97) alle Vorhersagen zusammengefasst. Bei den Gesamtstimmungen werden drei Vorhersagen durchgeführt. Die Vorhersage mit der deutschen Gesamtstimmung ohne Vorlauf hat sowohl beim Fallen (0) als auch beim Steigen (1) eine Modellgüte (siehe zum Begriff Modellgüte Tabelle 3.5, Seite 38) von 0,529 (Modell 1). Wird die englische Gesamtstimmung mitberücksichtigt (Modell 3), steigt die Modellgüte auf 0,595. Die Modellgüte hat sich durch Hinzufügen zweier Gesamtstimmungen verbessert. Weiterhin verbesserte sich die Modellgüte durch Berücksichtigung der Vorläufe bei deutschen Tweets (Modell 2) auf 0,656. Dies entspricht einer Vorhersage mit acht Gesamtstimmungen. Bei der deutschen Gesamtstimmung gibt es keine fehlenden Werte.

Auf Stimmungsebene zeigt sich bereits, dass sowohl die Berücksichtigung von mehreren Sprachen als auch von Vorläufen die Vorhersage verbessert. Bei den Gesamtstimmungen ist die Modellgüte allerdings in allen drei Vorhersagen inakzeptabel für eine Vorhersage. Dies verdeutlicht auch der Kreuzentropiefehler, der bei den Modellen mit Gesamtstimmungen im Training  $>48$  und im Test  $>14$  ist. Die Modellgüte der Vorhersage aus akkumulierter Gesamtstimmung dient somit als Referenz, von der aus optimiert werden soll.

## 4.2 Themenstimmungen

Zunächst werden die Themen-Tweets mit ihren jeweiligen Stimmungen beschrieben.

### Tweets

Es wurden 371.446 (100%) öffentliche Tweets der drei Themen DAX, Wirtschaft und Politik, zunächst in allen Sprachen, vom 02.09.2014 bis zum 07.03.2015 geladen. Eine Übersicht der Tweets pro Thema ist in Tabelle 4.2 dargestellt:

Tabelle 4.2: Anzahl Tweets pro Thema

Thema	Von	Bis	Zeitraum in Tagen	Alle Tweets %	Deutsche Tweets %	Englische Tweets %
DAX	04.09.2014 12:45 Uhr	07.03.2015 01:51 Uhr	184	88.528 100%	33.723 38%	29.302 33%
Wirtschaft	02.09.2014 23:16 Uhr	07.03.2015 00:48 Uhr	186	71.179 100%	69.403 98%	750 1%
Politik	06.09.2014 10:42 Uhr	07.03.2015 08:03 Uhr	182	211.739 100%	67.955 32%	3.293 5%
Summe %				371.446 100%	171.081 46%	33.345 9%
Summe nach Be- schneidung	06.09.2014 0:00 Uhr	06.03.2015 23:59 Uhr	181		171.076	29.115

Quelle: Eigene Darstellung

Die englischen Wirtschafts- und Politik-Tweets werden aufgrund der geringen Anzahl nicht berücksichtigt. Es sind annähernd gleich viele deutsche wie englische DAX-Tweets vorhanden. Am Wochenende werden weniger Nachrichten geschrieben als während der Woche. Dies ist darauf zurückzuführen, dass das Wochenende die inaktive Zeit der institutionellen Nutzer ist.

Es gibt originäre Tweets und Weiterleitungen. Letztere haben ein RT vorangestellt. Der Anteil Weiterleitungen in deutschen Tweets liegt bei 12% bei den DAX-Tweets, 7% bei den Wirtschafts-Tweets und 17% bei den Politik-Tweets. Der Anteil aller Weiterleitungen beträgt 12%. Deutsche und englische Tweets sind bezüglich der Sprache disjunkt. DAX-, Wirtschafts- und

Politik-Tweets sind Teilmengen deutscher Tweets. Diese Teilmengen sind allerdings nicht disjunkt. Dies bedeutet, dass Tweets zu gleichzeitig zwei Themen geschrieben werden können. Die Themenüberlappung ist gering (DAX/Politik: 4 Tweets; DAX/Wirtschaft: 26 Tweets; Wirtschaft/Politik: 112 Tweets; DAX/Wirtschaft/Politik: 3 Tweets). Somit ist die doppelte Berücksichtigung der Tweets, die sich gleichzeitig zu mehreren Themen beziehen, vernachlässigbar. Abbildung 4.1 zeigt die Anzahl der deutschen Tweets im Tagesverlauf über alle Tage gemittelt. Zusätzlich enthalten Tweets unter anderem folgende Merkmale: Nutzernamen, Datum und Uhrzeit, Text, Sprache, Profilbild des Nutzers, Quelle, Ort, Zeitzone, momentane Standortbestimmung, Nutzernamen, Kommentar und Medien. Die Stimmungsanalyse wertet den Text aus.

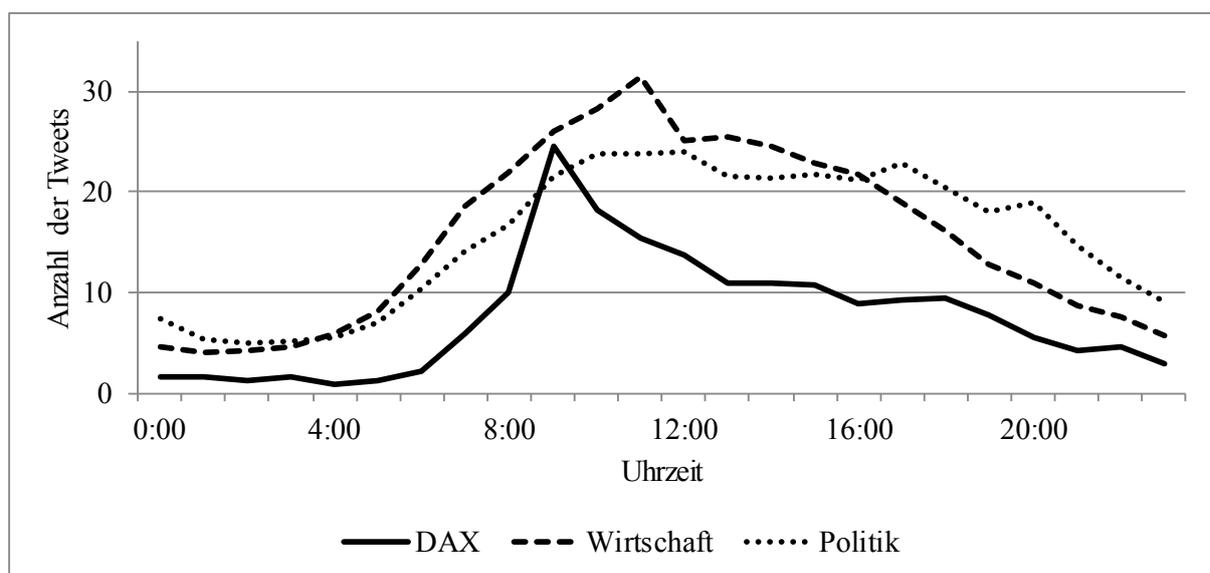


Abbildung 4.1: Anzahl deutscher Tweets der drei Themen nach Uhrzeit

Quelle: Eigene Darstellung

Die Anzahl der Politik- und Wirtschaft-Tweets ähnelt sich im Tagesverlauf. Das Maximum der Anzahl deutscher DAX-Tweets ist kurz nach Handelsbeginn. Beispiele deutscher Tweets sind in Tabelle 4.3 dargestellt.

Tabelle 4.3: Beispiele deutscher Tweets

Thema	Datum	Uhrzeit	Tweet
DAX	03.03.2015	20:58:21	die längst überfällige #korrektur beginnt (hoffentlich!). #dax #Aktien #boerse #trading #investing
Wirtschaft	03.09.2014	09:34:11	#Wirtschaft #Börse Waffenruhe in der Ukraine?: Dax steigt voller Hoffnung: Starke Reaktionen an der Börse: Die... <a href="http://t.co/2bu9FGgJNm">http://t.co/2bu9FGgJNm</a>
Politik	07.09.2014	09:07:07	Nein zur Vorratsdatenspeicherung: Maas kündigt Anti-Terror-Gesetz an <a href="http://t.co/Z4gvXLghbF">http://t.co/Z4gvXLghbF</a> #Politik

Quelle: Eigene Darstellung

Die Tweets wurden mit Suchoperatoren ausgewählt (\* für alle Tweets; \*^¬RT\* für originäre Tweets; RT\* für Weiterleitungen). Im Folgenden ein solches Beispiel:

RT @daf\_tv: Börse Frankfurt Schluss: DAX 9.724 +1,02% #dax #boerse #aktie #chart #trading #finanzen #markt #euro #dollar #dow #nyse #wallst...

### **Kopien und Weiterleitungen**

Es gibt Original-Tweets und Kopien. Ein Tweet kann mit identischem Text wiederholt vom selben oder einem anderen Autor gesendet oder weitergeleitet werden. 92% der deutschen DAX-Tweets sind originär. Die deutschen Wirtschafts-Tweets bestehen zu 5% und die deutschen Politik-Tweets zu 13% aus Kopien. Kopien werden nicht ignoriert, da auch sie von Menschen gelesen werden. Kopien verstärken somit die darin enthaltenen Stimmungen.

### **Unterschiede zwischen Themenstimmungen**

Die Politik-Tweets haben den Median von 10,48 Wörtern, gefolgt von den Wirtschafts-Tweets (9,64) und den DAX-Tweets (8,86). Die DAX-Tweets haben mit 0,99 Wörtern als Interquartilsabstand die größte Streuung an Wörtern pro Tweet, gefolgt von den Politik-Tweets (0,6) und den Wirtschafts-Tweets (0,48). Gemäß Kruskal-Wallis-Test (Chi-Quadrat=411,50;  $p < 0,001$ ) unterscheiden sich die Lageparameter der drei Gruppen gemäß ihrer Anzahl der Wörter pro Tweet signifikant voneinander. So unterscheidet sich gemäß Mann-Whitney-U-Test die Anzahl der Wörter der deutschen DAX-Tweets signifikant von der Anzahl der deutschen Wirtschafts-Tweets ( $U=6.593$ ;  $p < 0,001$ ). Die deutschen DAX-Tweets unterscheiden sich signifikant von den deutschen Politik-Tweets ( $U=0$ ;  $p < 0,001$ ). Die deutschen Wirtschafts-Tweets unterscheiden sich signifikant von den deutschen Politik-Tweets ( $U=0$ ;  $p < 0,001$ ). Ist  $U=0$ , sind alle Werte einer Gruppe zusammen größer als die der anderen Gruppen. Die Gruppierung wurde unter der Annahme getroffen, dass Stimmungen in Twitter themenspezifisch sind. Da der Zusammenhang zwischen DAX und den drei Themen analysiert wird, ist zunächst zu prüfen, ob sich die Themenstimmungen bei den Lageparametern voneinander unterscheiden. Sollte hier kein Unterschied feststellbar sein, würde eine thematische Aufschlüsselung unter Umständen nicht hilfreich sein. Die folgende Analyse dient zur Rechtfertigung der themenspezifischen Betrachtung. Der Kruskal-Wallis-Test zum Vergleich der zentralen Tendenzen ist signifikant (Chi-Quadrat=78,784;  $p < 0,001$ ), d. h. die Mediane der Stimmung der drei Gruppen DAX, Wirtschaft und Politik unterscheiden sich. Beim Wilcoxon-Mann-Whitney-Test unterscheiden sich die Mediane der Stimmungen aller drei Gruppen voneinander. DAX und Wirtschaft: ( $U=13.274$ ;  $p < 0,001$ ), DAX und Politik ( $U=8.776$ ;  $p < 0,001$ ), Wirtschaft und Politik: ( $U=9.905$ ;  $p < 0,001$ ). Die Stimmung in den DAX-Tweets hat die größte Streuung (Interquartilsabstand=0,15) und ist

die am geringsten negative der drei Gruppen (Median=-0,21), gefolgt von der Wirtschaftsstimmung (Median=-0,26). Die Politikstimmung ist die am stärksten negative (Median=-0,33) mit geringster Streuung (Interquartilsabstand=0,07).

Um Unterschiede bei den Stimmungen zwischen den Wochentagen zu ermitteln, werden die Mediane nach Wochentag gebildet, siehe Tabelle 4.4.

Tabelle 4.4 Stimmungen nach Wochentagen

Wochentag	DAX	Wirtschaft	Politik
Montag	-0,209	-0,244	-0,335
Dienstag	-0,195	-0,272	-0,338
Mittwoch	-0,209	-0,272	-0,330
Donnerstag	-0,208	-0,212	-0,318
Freitag	-0,217	-0,259	-0,332
Samstag	-0,194	-0,210	-0,344
Sonntag	-0,203	-0,293	-0,332

Quelle: Eigene Darstellung

Bei den DAX-Tweets gibt es gemäß Kruskal-Wallis-Test keine signifikanten Stimmungsunterschiede zwischen den Medianen der Wochentage (Chi-Quadrat=2,171;  $p=0,903$ ). Ein Gleiches gilt für die Mediane der Stimmungen der Wirtschaft-Tweets (Chi-Quadrat=6,101;  $p=0,412$ ) und die Mediane der Stimmungen der Politik-Tweets (Chi-Quadrat=2,072;  $p=0,913$ ).

Die Stimmungsunterschiede bei den verschiedenen Themen rechtfertigen schließlich die weitere Aufschlüsselung nach Nutzerstimmungen. So werden Nutzer auch themenspezifisch betrachtet, da ein Nutzer zu verschiedenen Themen eine unterschiedliche Meinung haben kann.

### Korrelationen

Mit dem heutigen DAX korreliert die relative Anzahl positiver Wörter in deutschen DAX-Tweets des gleichen Tages positiv ( $r_s=0,216$ ;  $p<0,05$ ), siehe Tabelle C Seite 98.

Die Anzahl der heutigen negativen Wörter der Wirtschaft-Tweets ( $r_s=-0,504$ ;  $p<0,01$ ), die Anzahl täglicher Tweets ( $r_s=-0,372$ ;  $p<0,01$ ) und die Anzahl der Wörter ( $r_s=-0,404$ ;  $p<0,01$ ) korreliert jeweils negativ mit dem DAX, siehe Tabelle D Seite 99.

In Tabelle E auf Seite 100 gibt es einen negativen Zusammenhang zwischen dem DAX und der Stimmung in den Politik-Tweets. Dieser Zusammenhang besteht zwischen der heutigen Politikstimmung in den Tweets und dem DAX ( $r_s=-0,530$ ;  $p<0,01$ ), der gestrigen Stimmung und dem DAX ( $r_s=-0,526$ ;  $p<0,01$ ) und der vorgestrigen Stimmung und dem DAX ( $r_s=-0,465$ ;  $p<0,01$ ), usw. Alle Stimmungen, die bis zu sieben Tagen in die Vergangenheit erhoben wurden ( $t=1$  bis  $t=7$ ), korrelieren negativ mit dem heutigen DAX. Die Stärke der Korrelation ist von heutiger Stimmung bis zur Stimmung von vor drei Tagen ( $t=t-3$ ) abnehmend, ab dem 4. Tag

ansteigend. Die Anzahl der Tweets ( $r_s=-0,505$ ;  $p<0,01$ ) und die Anzahl der Wörter ( $r_s=0,425$ ;  $p<0,01$ ) korreliert positiv mit dem heutigen DAX.

Tabelle F auf Seite 101 zeigt die Korrelationen der Stimmung englischer DAX-Tweets und dem DAX. So gibt es einen schwachen negativen Zusammenhang zwischen der Anzahl der relativen positiven Wörter der Stimmung in englischen DAX-Tweets von vor vier Tagen mit dem heutigen DAX ( $r_s=-0,202$ ;  $p<0,05$ ). Die Anzahl der relativen positiven Wörter ist die durchschnittliche Anzahl positiver Wörter pro Tweet.

Tabelle G auf Seite 102 bezieht sich auf die Frage, ob die Stimmung in den DAX-Tweets mit der Stimmung der Wirtschafts-Tweet korreliert. Die Anzahl der positiven Wörter korreliert stark positiv ( $r_s=-0,754$ ;  $p<0,01$ ) wie auch die negativen Wörter der Wirtschafts-Tweets ( $r_s=-0,640$ ;  $p<0,01$ ) positiv und zeitgleich mit der Anzahl positiver Wörter der DAX-Tweets korrelieren.

Gemäß Tabelle H auf Seite 103 korreliert die Anzahl positiver und negativer Wörter zum Thema DAX- und Politikstimmung signifikant miteinander (positive Wörter:  $r_s=0,603$ ;  $p<0,01$ ; negative Wörter:  $r_s=0,455$ ;  $p<0,01$ ). Die Politikstimmung von vor fünf Tagen korreliert negativ mit der Anzahl positiver Wörter zum Thema DAX ( $r_s=-0,169$ ;  $p<0,05$ ).

Gemäß Tabelle I auf Seite 104 besteht ebenfalls wie in Tabelle H auf Seite 103 eine Korrelation zwischen der Anzahl der Wörter in deutschen Politik- und Wirtschafts-Tweets (positive Wörter:  $r_s=0,497$ ;  $p<0,01$ ; negative Wörter:  $r_s=0,34$ ;  $p<0,01$ ).

Die englische DAX-Stimmung wurde in Tabelle J (Seite 105) wie die deutsche DAX-Stimmung, mit der relativen Zahl negativer Wörter ermittelt. Die Stimmungen korrelieren positiv miteinander ( $r_s=0,197$ ;  $p<0,01$ ).

Gemäß Tabelle K auf Seite 106 korreliert die Anzahl der täglichen negativen Wörter in englischen DAX-Tweets mit Tweets zur deutschen Wirtschaftsstimmung positiv ( $r_s=0,678$ ;  $p<0,01$ ). Die heutige ( $r_s=0,365$ ;  $p<0,01$ ) und gestrige englische DAX-Stimmung korrelieren mit der Anzahl negativer Wörter der deutschen Wirtschafts-Tweets ( $r_s=0,233$ ;  $p<0,01$ ). Die Stärke der Korrelation nimmt von der heutigen zur gestrigen englischen DAX-Stimmung ab.

Die englische DAX-Stimmung korreliert positiv mit der Anzahl negativer Wörter in deutschen Politik-Tweets ( $r_s=0,151$ ;  $p<0,05$ ), siehe Tabelle L, Seite 107. Tabelle 4.5 fasst die signifikanten Korrelationen mit dem DAX zusammen:

Tabelle 4.5: Übersicht signifikanter Korrelationen

Variable 1	Variable 2	Korrelationskoeffizient $r_s$	Signifikanz p
DAX	DAX-Datum	0,779	<0,01
DAX	Anzahl deutscher Politik-Tweets	0,779	<0,01
DAX	Anzahl Wörter deutscher Politik-Tweets	0,425	<0,01
DAX	Anzahl relativer positiver Wörter deutscher DAX-Tweets	0,216	<0,05
DAX	Deutsche Politikstimmung $t=t-1$ bis $t=t-7$	-0,459 bis -0,530	<0,01
DAX	Anzahl deutscher Wirtschafts-Tweets	-0,372	<0,01
DAX	Relative Anzahl positiver Wörter englischer DAX-Tweets	-0,202	0,02

Quelle: Eigene Darstellung

Die einzige stimmungsrelevante Korrelation ist die negative Korrelation deutscher Politikstimmung mit dem DAX. Fraglich ist, ob auch die Streuung der Stimmung, gemessen mit dem Interquartilsabstand, mit der Stimmung zusammenhängt, siehe Tabelle 4.6.

Tabelle 4.6: Korrelation deutscher Stimmung und Streuung der Stimmung

	1	2	3	4	5
1 Politikstimmung					
2 Streuung der Politikstimmung	-0,203**				
3 DAX-Stimmung	0,038	0,098			
4 Streuung der DAX-Stimmung	-0,123	-0,037	-0,324**		
5 Wirtschaftsstimmung	0,022	0,005	-0,015	0,075	
6 Streuung der Wirtschaftsstimmung	0,013	0,081	0,062	-0,156*	0,118

\*\* Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Der stärkste negative Zusammenhang besteht zwischen der Streuung der DAX-Stimmung und der DAX-Stimmung ( $r_s=-0,324$ ;  $p<0,01$ ). Die Streuung der Politikstimmung hängt ebenfalls negativ mit der Politikstimmung zusammen ( $r_s=-0,203$ ;  $p<0,01$ ). Die Streuung der Wirtschaftsstimmung hängt nicht signifikant mit der Wirtschaftsstimmung zusammen, sondern signifikant mit der Streuung der DAX-Stimmung ( $r_s=-0,156$ ;  $p<0,05$ ).

### Ähnlichkeitsanalyse

Mit der Binärtransformation der Stimmungszahlen und des DAX in Steigen und Fallen kann der tägliche Zusammenhang in zeitlicher Abfolge festgestellt werden. Folglich werden sowohl der DAX als auch die zeitgleichen und zeitversetzten deutschen Twitter-Stimmungen als Binärvariable transformiert (0=fällt im Gegensatz zum Vortag; 1=steigt im Gegensatz zum Vortag). Tabelle 4.7 enthält die M-Koeffizienten des DAX und der DAX-Stimmung.

Tabelle 4.7: M-Koeffizienten des DAX und deutsche DAX-Stimmung

	1	2	3	4	5	6	7	8
1 DAX								
2 Stimmung	0,558							
3 Stimmung t=t-1	0,458	0,367						
4 Stimmung t=t-2	0,592	0,550	0,333					
5 Stimmung t=t-3	0,425	0,467	0,517	0,333				
6 Stimmung t=t-4	0,492	0,483	0,467	0,533	0,350			
7 Stimmung t=t-5	0,508	0,517	0,467	0,450	0,533	0,383		
8 Stimmung t=t-6	0,475	0,450	0,533	0,450	0,450	0,483	0,350	
9 Stimmung t=t-7	0,450	0,508	0,475	0,492	0,458	0,508	0,492	0,358

Quelle: Eigene Darstellung

Bei der Methode des M-Koeffizienten gibt es die höchste Ähnlichkeit zwischen dem DAX und der DAX-Stimmung, wenn der DAX von heute mit den Stimmungswerten von vorgestern verglichen wird (M-Koeffizient=0,592). Die zweithöchste Ähnlichkeit gibt es zwischen den beiden Variablen, wenn sie am gleichen Tag bestimmt wurden (M-Koeffizient=0,558), und die dritthöchste Ähnlichkeit gibt es bei einem Abstand von fünf Tagen (M-Koeffizient=0,508), DAX-Kurs gegen DAX-Stimmung. Tabelle 4.8 zeigt die Ähnlichkeitskoeffizienten des DAX und der Wirtschaftsstimmungen.

Tabelle 4.8: M-Koeffizienten des DAX und deutsche Wirtschaftsstimmung

	1	2	3	4	5	6	7	8
1 DAX								
2 Stimmung	0,537							
3 Stimmung t=t-1	0,405	0,372						
4 Stimmung t=t-2	0,512	0,463	0,347					
5 Stimmung t=t-3	0,479	0,529	0,512	0,306				
6 Stimmung t=t-4	0,405	0,471	0,521	0,545	0,314			
7 Stimmung t=t-5	0,570	0,570	0,471	0,512	0,496	0,322		
8 Stimmung t=t-6	0,413	0,479	0,562	0,421	0,537	0,479	0,298	
9 Stimmung t=t-7	0,570	0,488	0,438	0,595	0,413	0,537	0,554	0,314

Quelle: Eigene Darstellung

Aus Tabelle 4.8 wird ersichtlich, dass die höchste Ähnlichkeit zwischen dem DAX-Kurs und der Wirtschaftsstimmung auftritt, wenn die DAX-Ergebnisse von heute mit der Wirtschaftsstimmung von heute verglichen werden (M-Koeffizient=0,537). Die zweitbesten Ergebnisse ergeben sich bei einem Vergleich im Abstand von fünf bzw. sieben Tagen (jeweils M-Koeffizient=0,558). Tabelle 4.9 enthält die Ähnlichkeitskoeffizienten des DAX und der Politikstimmungen.

Tabelle 4.9: M-Koeffizienten des DAX und deutsche Politikstimmung

	1	2	3	4	5	6	7	8
1 DAX								
2 Stimmung	0,496							
3 Stimmung t=t-1	0,580	0,378						
4 Stimmung t=t-2	0,521	0,471	0,370					
5 Stimmung t=t-3	0,471	0,504	0,454	0,395				
6 Stimmung t=t-4	0,521	0,555	0,538	0,412	0,378			
7 Stimmung t=t-5	0,471	0,504	0,521	0,563	0,462	0,328		
8 Stimmung t=t-6	0,429	0,412	0,513	0,487	0,521	0,504	0,319	
9 Stimmung t=t-7	0,521	0,454	0,420	0,546	0,496	0,496	0,479	0,387

Quelle: Eigene Darstellung

Die gestrige Politikstimmung ähnelt dem DAX-Kurs von heute am meisten (M-Koeffizient=0,58). Ein geringerer Wert ist beim Vergleich der Politikstimmung von vorgestern mit dem DAX-Kurs von heute festzustellen (M-Koeffizient=0,521).

### Zusammenhang gleichzeitigen Steigens und Fallens

Die Summe des Steigens bzw. Fallens der binären Stimmung im Vergleich zum Vortag variiert zwischen 0 (keine Stimmungen sind gestiegen) bis 3 (alle Stimmungen sind gestiegen). Dies ist in Tabelle 4.10 dargestellt.

Tabelle 4.10: Kreuztabelle des DAX und deutscher Stimmungen

DAX	Summe Steigen/Fallen der Stimmungen				Aktiver Rand
	0	1	2	3	
Fällt	8	21	13	5	47
Steigt	10	23	35	9	77
Aktiver Rand	18	44	48	14	124

Quelle: Eigene Darstellung

Auffällig ist der Unterschied zwischen zwei steigenden Stimmungen bei steigendem DAX und bei drei steigenden Stimmungen. Gemäß Chi-Quadrat-Tests in Tabelle 4.11 gibt es keinen Zusammenhang zwischen gleichzeitigem Steigen bzw. Fallen bei den Stimmungen und bei dem DAX.

Tabelle 4.11: Chi-Quadrat-Tests deutscher Stimmungen

Variablen	Chi-Quadrat	Signifikanz	n
DAX- und Politikstimmung	0,013	0,911	181
DAX- und Wirtschaftsstimmung	0,002	0,961	183
Politik- und Wirtschaftsstimmung	0,070	0,792	180
DAX-Stimmung und DAX	1,992	0,158	125
Wirtschaftsstimmung und DAX	1,031	0,310	126
Politikstimmung und DAX	0,050	0,822	124

Quelle: Eigene Darstellung

## Nichtlinearer Zusammenhang

Abbildung 4.2 zeigt den nichtlinearen Zusammenhang zwischen dem DAX und der Politikstimmung.

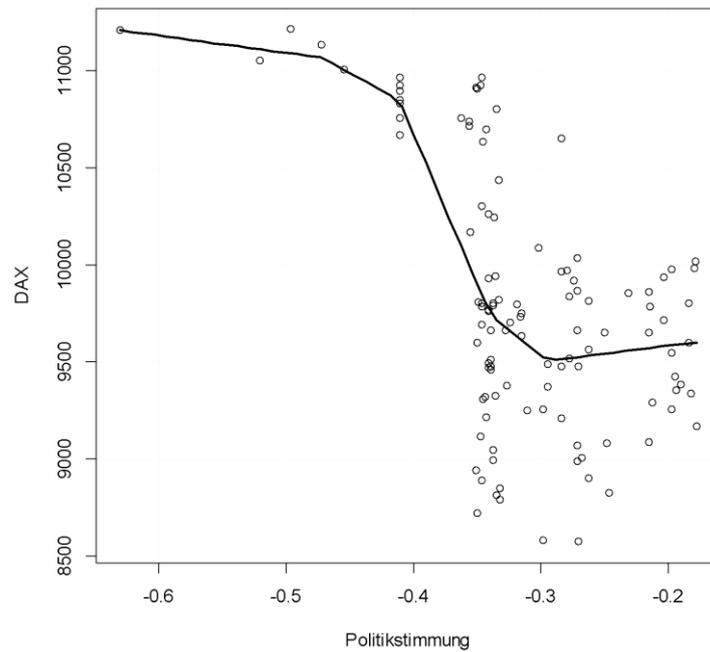


Abbildung 4.2: Zusammenhang zwischen DAX und deutscher Politikstimmung

Quelle: Eigene Darstellung

Der nichtlineare Zusammenhang zwischen den Variablen wird mittels nichtparametrischer Regression verdeutlicht. Der gleiche Sachverhalt ist im zeitlichen Verlauf in Abbildung 4.3 dargestellt.

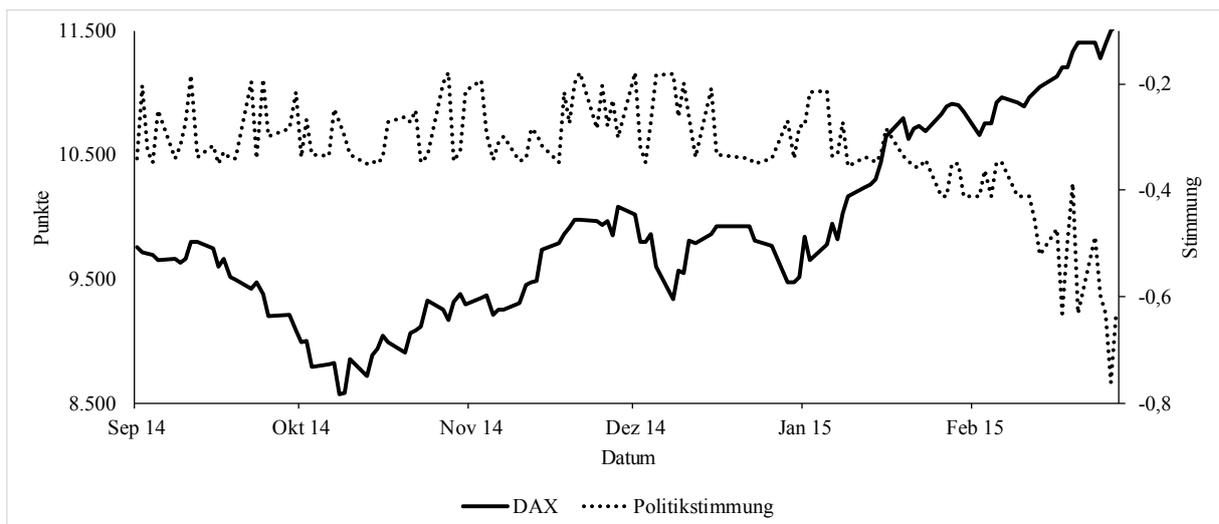


Abbildung 4.3: DAX und deutsche Politikstimmung nach Datum

Quelle: Eigene Darstellung

Auffällig ist die gegensätzliche Bewegung ab ca. Mitte Januar 2015, wobei der DAX einem Aufwärtstrend, die Politikstimmung jedoch einem Abwärtstrend folgt. Dies bedeutet, dass die Stärke bzw. Signifikanz des Zusammenhangs maßgeblich trendbezogen sein kann.

### **Vorhersage mit den Themenstimmungen**

Auf Basis der Themenstimmungen werden ebenfalls drei Vorhersagen mit einem neuronalen Netz berechnet. Werden die drei deutschen Themenstimmungen ohne Vorlauf berücksichtigt, beträgt die Modellgüte 0,635 (Modell 4), siehe Tabelle B im Anhang. Wird zusätzlich die englische DAX-Themenstimmung berücksichtigt, steigt die Modellgüte auf 0,676 (Modell Nr. 5). Zu optimieren ist die Vorhersage auf Themenebene durch die weitere Berücksichtigung der jeweiligen Vorläufe der Stimmungen. Die Modellgüte der Vorhersage aus den nun insgesamt 42 Themenstimmungen steigt auf 0,723 (Modell Nr. 6). Obwohl sich die Güte der deutschen und englischen Themenstimmungen mit Vorläufen im Vergleich zu den Modellen der Gesamtstimmung um 6% verbessert hat, sind die Themenaufschlüsselungen bezüglich Vorhersagequalität inakzeptabel. Dies bestätigt auch der Kreuzentropiefehler, der bei den drei Modellen der Vorhersage auf Basis der Themenstimmungen im Training  $>50$  und im Test  $>16$  ist. Daher erfolgt im Anschluss eine weitere Aufschlüsselung nach Nutzern.

### 4.3 Nutzerstimmungen

Auf Ebene der Nutzer zeigt sich, dass sie als unterschiedliche Signale betrachtet werden können.

#### **Nutzer mit den meisten Abonnenten**

Die vorigen Ergebnisse verdeutlichen, dass eine Aufschlüsselung nach Themen für eine Vorhersage nicht ausreichend ist. Dementsprechend wird weiter nach Nutzern aufgeschlüsselt. Im ersten Schritt der Aufschlüsselung nach Nutzern werden diejenigen Nutzer mit den meisten Abonnenten ausgewählt. Diese sind die Stimmungsmacher. So erreicht ihre Stimmung viele weitere Nutzer, die sich ihrer Stimmung annehmen und diese auch weiterleiten. Die Nutzer mit den meisten Abonnenten deutscher Tweets sind in Tabelle M auf Seite 108 dargestellt. Hier haben Medien wie Axel Springer und Gruner & Jahr die meisten Abonnenten und somit die größte Reichweite. Twitter ersetzt somit traditionelle TV-, Print- und Internetmedien. Dementsprechend ist die Stimmung in Twitter entsprechend der Anzahl ihrer Abonnenten von den Massenmedien dominiert. Dieses Ergebnis deckt sich mit Kwak et al. (2010, S. 600), bei denen 85% der Tweets Schlagzeilen sind oder Nachrichtencharakter haben. Jedoch ist die Anzahl der

Tweets dieser Massenmedien in den Stichproben gering. Lediglich das Handelsblatt veröffentlicht Tweets nahezu täglich. Die Ermittlung der Unterschiede der Stimmungen zwischen den Massenmedien ist aufgrund der wenigen Tweets pro Nutzer nicht möglich. Allerdings lässt sich erkennen, dass diese Nutzer aufgrund ihrer wenigen Tweets minimalen Anteil an der akkumulierten Gesamtstimmung haben. Aufgrund der geringen Anzahl von Tweets kann hier kein Zusammenhang zwischen den individuellen Nutzerstimmungen und dem DAX mit Hilfe von Korrelationsanalysen ermittelt werden. Auch ein Vorhersagemodell ist mit diesen Nutzern nicht möglich. Daher empfiehlt sich eine Aufschlüsselung nach den Nutzern mit der höchsten Aktivität. Ein aktiver Nutzer ist ein Nutzer, der viele Tweets veröffentlicht.

### Nutzer mit höchster Aktivität

Die zehn Nutzer mit der höchsten Aktivität werden aus den drei Themen gewählt. In Tabelle 4.12 und Tabelle 4.13 sind diese Nutzer nach Häufigkeit der geschriebenen Tweets geordnet. Sie sind Händler, Medien, Berater, Makler und Privatpersonen. Hier werden die zehn Nutzer, die zusammen über 50% der Tweets geschrieben haben, kategorisiert. Hierbei wird sich herausstellen, dass sie zu einem überwiegenden Teil einschlägige Medien sind und somit kursrelevante Stimmungen ähnlich wie die Tageszeitungen verbreiten. Bei den aufgeschlüsselten Themen hat Twitter die Eigenschaft eines Nachrichtenkanals und nicht die eines sozialen Netzwerks.

Tabelle 4.12: Nutzer mit höchster Aktivität deutscher DAX- und Wirtschafts-Tweets

Rang	Deutsche DAX-Tweets				Deutsche Wirtschaft-Tweets			
	Autor	Tweets	%	Art	Autor	Tweets	%	Art
1	cfđ_markt	9.127	27%	keine Info	kazi_germany	7.997	12%	Medien
2	4xsetups	1.913	6%	Händler	erdbeer_joghurt	4.869	7%	keine Info
3	Boersende	1.754	5%	Medien	wirtschaftsnews_	4.666	7%	Medien
4	Boersengewinne	1.752	5%	keine Info	ihrmakler	4.555	7%	Makler
5	hanse_trader	1.748	5%	keine Info	moneycab	4.042	6%	Medien
6	Jensklattfx	1.614	5%	Händler	finanzwiese	3.937	6%	Medien
7	Verkaufssteuerer	940	3%	Beratung	maspalomassun	2.788	4%	Makler
8	instock_de	509	2%	Medien	kopffinder	2.163	3%	keine Info
9	Mehrdividende	495	1%	Medien	dpaafx	2.094	3%	Medien
10	Devisenalarm	412	1%	Medien	klug_invest	1.816	3%	keine Info
	SUMME	20.264	60%			38.927	56%	

Quelle: Eigene Darstellung

Tabelle 4.13: Nutzer mit höchster Aktivität deutscher Politik- und englischer DAX-Tweets

Rang	Deutsche Politik-Tweets				Englische DAX-Tweets			
	Autor	Tweets	%	Art	Autor	Tweets	%	Art
1	kazi_germany	18.924	28%	Medien	pawpaw1000	787	3%	Händler
2	finanzwiese	3.934	6%	Medien	atatrading	657	2%	Händler
3	maspalomassun	3.772	6%	Makler	fxsunday	631	2%	keine Info
4	news_tick	3.683	5%	keine Info	theredgis	541	2%	keine Info
5	austriadai	2.120	3%	keine Info	uesmer	518	2%	Privatperson
6	prmeldungen	1.648	2%	Medien	sagaron62	495	2%	Händler
7	neuigkeitende	1.599	2%	keine Info	adsensejob	455	2%	keine Info
8	anonnewsde	641	1%	Medien	followingjob	424	1%	keine Info
9	axelhohl	469	1%	Medien	john_papadak	399	1%	Händler
10	fd_videotip	468	1%	keine Info	jobsila_com	398	1%	keine Info
	SUMME	37.258	55%			5.305	18%	

Quelle: Eigene Darstellung

Bei den deutschen Tweets generieren die zehn Nutzer über die Hälfte der Tweets. Bei diesen Nutzern handelt es sich um professionelle Anbieter, wie Händler und Medien. Dies wurde mit Hilfe von Kontoinformation und Nutzernamen ermittelt. Im Gegensatz zu den deutschen Tweets findet sich bei den englischen Nutzern eine größere Varianz. Die Nutzer mit der höchsten Aktivität sind auch hier überwiegend gewerbliche Nutzer. In allen Listen war ein Nutzer als Privatperson zu ermitteln. Hier ist die monothematische Ausrichtung im Gegensatz zu den großen Medien erkennbar, d. h. diese besonders aktiven Nutzer konzentrieren sich auf DAX-, Politik- oder Wirtschaftsthemen.

### Vorhersage mit den besonders aktiven Nutzern

In Modell Nr. 7 (siehe Tabelle B im Anhang) werden zur Vorhersage des DAX zunächst alle aktiven Nutzer deutscher Tweets ohne Vorlauf ausgewählt. Die Modellgüte beträgt bei 14 Nutzerstimmungen 0,625 und liegt unter der Modellgüte der Themenaufschlüsselung, jedoch wurde der Kreuzentropiefehler auf 30,4 im Training und 13,7 im Test reduziert.

### Vorhersage mit den Nutzern höchster Aktivität, die mit dem DAX korrelieren

Tabelle N auf Seite 109 bis Tabelle R auf Seite 113 enthalten jeweils die Korrelationskoeffizienten der Stimmungen der zehn Nutzer mit dem DAX. Bei zwei der DAX-Nutzer gibt es einen negativen Zusammenhang zum DAX auf dem 5%-Signifikanzniveau. (Nutzer 2 und 9). Bei den Wirtschafts- und Politiknutzern gibt es jeweils drei Zusammenhänge zwischen dem DAX und der Nutzerstimmung, ebenfalls mit der gleichen Signifikanz (Nutzer 5, 9 und 10, sowie Nutzer 1, 5 und 9). Bei den englischen DAX-Nutzern korrelierten drei Tagesstimmungen signifikant mit dem DAX (Nutzer 5, 9 und 10). Daher empfiehlt sich eine Auswahl der Nutzer durch Korrelation mit dem DAX. Tabelle 4.14 enthält die Korrelationskoeffizienten der Nutzer mit der höchsten Aktivität und dem DAX.

Tabelle 4.14: Nutzer mit höchster Aktivität mit signifikantem Zusammenhang zum DAX

Thema	Sprache	Korrelationskoeffizient	Nutzername	n
DAX	Deutsch	-0,494*	Mehrdividende	21
Wirtschaft	Deutsch	0,186*	moneycab	127
Wirtschaft	Deutsch	-0,194*	kopffinder	125
Wirtschaft	Deutsch	-0,214*	fd_videotip	124
Politik	Deutsch	0,244**	kazi_germany	121
Politik	Deutsch	0,188*	austriadai	121
Politik	Deutsch	-0,360	axelhohl	73
DAX	Englisch	-0,230*	uesmer	94
DAX	Englisch	0,295*	john_papadak	94
DAX	Englisch	0,295*	jobsila_com	58

\*\* . Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* . Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Die Beschränkung auf sieben Nutzer ist damit begründet, dass diese eine ausreichende Menge an Tweets pro Tag schreiben. Die Anzahl der Tweets der restlichen Nutzer ist für eine Datenanalyse unzureichend. Die Nutzer, die mit ihrer Stimmung signifikant mit dem DAX zusammenhängen (siehe Tabelle 4.14), wurden nun zur Vorhersage verwendet. Wird die Vorhersage des DAX mit den sieben signifikanten Tagesstimmungen der deutschen Nutzer durchgeführt, ergibt sich eine Modellgüte von 0,584 (Modell Nr. 8), siehe Tabelle B im Anhang). In diesen Fall verschlechtert die Auswahl der Nutzerstimmungen durch eine vorausgelagerte Korrelation die Vorhersage. Dies ist ebenfalls ein Rückschritt im Vergleich zur Themenaufschlüsselung. Die DAX-Vorhersage kann verbessert werden, wenn zusätzlich die englischen Stimmungen der Nutzer mit der höchsten Aktivität, die mit dem DAX korrelieren, hinzugefügt werden. Dies entspricht einer Modellgüte von 0,611 (Modell Nr. 9) bei zehn berücksichtigten Nutzerstimmungen. Ausgehend von dieser letzten Vorhersage, zeigt Modell Nr. 10 eine Verbesserung der DAX-Vorhersage mit einer Modellgüte von 0,722. Hierbei wurde der Nutzer mit den wenigsten Tagesstimmungen ignoriert. Es wurden folglich neun Nutzerstimmungen berücksichtigt. Dieses Ergebnis zeigt, dass ein Vorhersagemodell auch von der Vollständigkeit der Zeitreihen abhängt. Die Modellgüte der Nutzer mit der höchsten Aktivität entspricht der Modellgüte der Themenstimmungen mit beiden Sprachen und jeweiligen Vorläufen. Somit verbessert die Aufschlüsselung nach diesen Nutzern die DAX-Vorhersage nicht.

### Alle Nutzer

Zu fragen ist, ob die Berücksichtigung aller Nutzer, die eine signifikante Korrelation zum DAX haben, zusätzliche Informationen zur Verbesserung der Vorhersage enthalten. Zu diesem Zweck werden diese relevanten Nutzer im Folgenden ausgewählt und überprüft. Hierfür werden die Korrelationen aller Nutzer jeweils mit bis zu sieben Tagen Vorlauf mit dem DAX aus

den deutschen Tweets berechnet. Wenn weniger als acht Tagesstimmungen pro Nutzer bestehen, kann die Korrelation nicht berechnet werden. Tabelle 4.15 enthält die Übersicht der technisch möglichen Berechnungen.

Tabelle 4.15: Übersicht möglicher Korrelationen aller Nutzer

Thema	Anzahl Nutzer	Anzahl möglicher Korrelationen	Anzahl möglicher Korrelationen %
DAX	2.013	63	3%
Wirtschaft	4.845	69	1%
Politik	7.498	145	2%
GESAMT	14.356	277	2%

Quelle: Eigene Darstellung

Es gibt einige Nutzer, deren Stimmungen mit dem DAX korrelieren. Diese Nutzer werden nun für die Vorhersage verwendet. Die Tabelle verdeutlicht, dass es für 2% der gesamten Nutzer möglich ist, Korrelationen zu berechnen. Dies ist damit zu begründen, dass nicht alle Nutzer täglich Tweets schreiben. Somit fehlen Tagesstimmungen. Schließlich konnten 277 Korrelationen mit den dazu gehörigen sieben Vorläufen berechnet werden. Dies entspricht 1.939 Korrelationen. Diese werden wiederum nach Signifikanz ausgewählt. Die signifikanten Nutzerstimmungen sind mit ihrem jeweiligen Vorlauf und Thema in Tabelle R auf Seite 113 dargestellt. Als Signifikanz wurde das 0,05-Niveau gewählt. Es verbleiben 141 signifikante Tagesstimmungen der Nutzer, inklusive der sieben Vorläufe. Dies sind zu viele Nutzerstimmungen für eine Vorhersage. Daher wird ein neues Verfahren benötigt, um die Tagesstimmungen auszuwählen.

### **Optimierung der Nutzerstimmungen**

Da nicht alle Tagesstimmungen der signifikanten Nutzer mit deren Vorläufen gleichzeitig in einem neuronalen Netz berücksichtigt werden können, müssen diese mit dem neuen Verfahren der Optimierung ausgewählt werden. Somit wird für jeden einzelnen Vorlauf der Stimmungen signifikanter Nutzer eine getrennte Vorhersage durchgeführt. Weiterhin sind auch bei der Auswahl durch die Korrelation nicht alle signifikanten Nutzerstimmungen für eine Vorhersage mit dem neuronalen Netz geeignet. Es wird eine bestimmte Anzahl von Tageswerten benötigt, damit eine Klassifizierung möglich ist. Die Untergrenze wurde mit 45 einzelnen Tagesstimmungen pro signifikantem Nutzer bestimmt. So verbleiben bei Berücksichtigung der Untergrenze die sogenannten möglichen Nutzer.

Bei den Vorhersagemodellen aller signifikanten Nutzer (Nr. 11-18) wurden zwischen einer und sieben Tagesstimmungen ausgewählt, da im Durchschnitt 1.627 Tagesstimmungen zur Vorher-

sage mit allen signifikanten Nutzern fehlten. So zeigt die Anzahl der fehlenden Tagesstimmungen, dass nicht bei allen Nutzern eine Stimmung eines jeden Tages vorhanden ist. Ein neuronales Netzwerk funktioniert auch mit einer begrenzten Anzahl von fehlenden Werten bei den Eingangsneuronen. Übersteigen die fehlenden Werte jedoch ein bestimmtes Maß, so können diese Stimmungen nicht zur Vorhersage verwendet werden. Die fehlenden Tagesstimmungen auf Nutzerebene reduzieren somit die signifikanten Nutzer auf die sogenannten möglichen signifikanten Nutzer.

Es wurde mit acht Vorhersagen auf Basis von Nutzerstimmungen die Modellgüte optimiert (Abbildung 4.4).

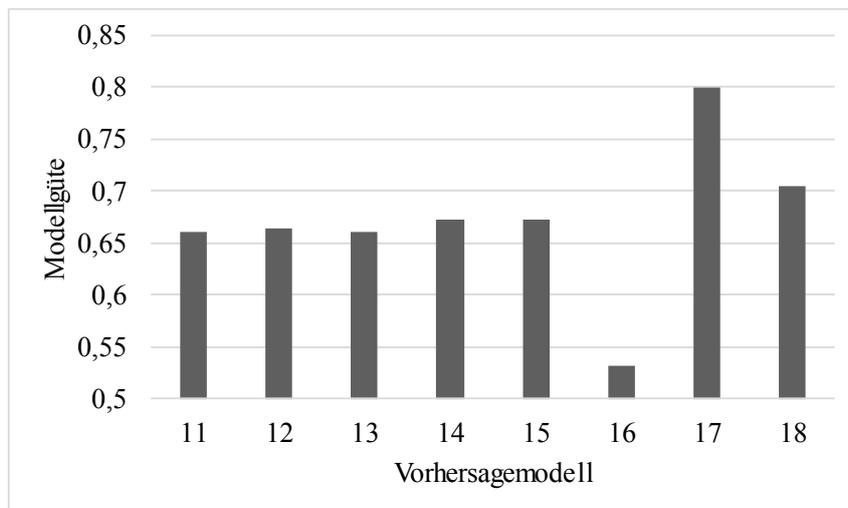


Abbildung 4.4: Optimierung der Vorhersagen mit Nutzerstimmungen

Jedes Modell entsprach einem anderen Vorlauf. Auffällig ist, dass die Modellgüte zwischen 0,532 bei  $t=t-5$  (Modell Nr. 16) mit einer Nutzerstimmung und 0,8 bei  $t=t-6$  (Modell Nr. 17) mit sieben Nutzerstimmungen variiert. Somit entspricht das Modell mit der geringsten Vorhersagekraft mit den signifikanten Tagesstimmungen aller Nutzer einem Zufallsprozess. Das Vorhersagemodell mit der höchsten Vorhersagekraft auf Basis aller signifikanten Nutzer hat eine ausgezeichnete Modellgüte und ist 7% (nun im Modell 17 mit 0,8 und vorher im Modell 10 mit 0,722) präziser als das optimale Modell auf der Ebene der Themenstimmungen (siehe Tabelle B in Anhang). Hier zeigt sich, dass eine gezielte Auswahl weniger Nutzer für eine Vorhersage genügt. Dies bestätigt auch der Kreuzentropiefehler, der im Gegensatz zu den Themenstimmungen im Training und im Test deutlich reduziert wurde. So ist der Kreuzentropiefehler im Test bei allen Vorhersagen auf Ebene der Nutzerstimmungen  $<9,9$ , außer bei den signifikanten Nutzern mit Vorlauf  $t=t-5$ . Hier beträgt der Fehler 16,7. Dies bedeutet, dass eine gute Vorhersage auf Nutzerebene möglich ist.

## 5 Diskussion

Die Ergebnisse der 18 Vorhersagemodelle aus dem vorigen Kapitel werden hier nach ihrer Stimmungsebene erörtert. Zunächst werden die Gesamt-, Themen- und Nutzeraufschlüsselung in Verbindung mit den Hypothesen beschrieben und im Anschluss das neue Verfahren diskutiert. Limitationen des neuen Verfahrens werden aufgezeigt und Handlungsempfehlungen für zukünftige Forschung zur Verbesserung des Verfahrens abgeleitet.

### 5.1 Relevanz der Gesamt- und Themenstimmung

#### **Gesamtstimmung**

Die Hypothese H0, dass kein Zusammenhang zwischen deutschen Tweets und dem DAX besteht, konnte nicht falsifiziert werden. Somit wird eine erste Aufschlüsselung nach Thema gerechtfertigt, siehe das Folgende:

#### **Deutsche DAX-Stimmung und DAX**

Zunächst sind die deutschen Wörter nur nach positiver oder negativer Stimmung eingeordnet. Bei den deutschen DAX-Tweets korreliert die relative Anzahl positiver Wörter signifikant ( $r_s=0,216$ ;  $p<0,05$ ) mit dem DAX am selben Tag. Die Anzahl der relativen positiven Wörter könnte ein Indikator für positive Stimmung sein. Dieser positive Zusammenhang zeigt sich jedoch für die Tweets desselben Tages.

Werden nun die ordinalen Stimmungswerte als Mediane der täglichen Einzelstimmungen berücksichtigt, korrelieren diese feiner abgestuften Stimmungen jedoch nicht mit dem DAX. Somit kann die Hypothese H1, dass die DAX-Stimmung in den Tweets keinen Zusammenhang mit dem DAX desselben Tages hat, nicht falsifiziert werden. Die DAX-Stimmung der vorhergehenden Tage hat auch keinen Übertragungseffekt auf die nachfolgenden Tage. Dies würde bedeuten, dass die Stimmung der Nutzer jeden Tag neu bewertet werden muss. Es wäre aber auch denkbar, dass der Effekt der Stimmungsübertragung auf die nachfolgenden Tage erst auftritt, wenn extrem positive oder negative Ereignisse auftreten, wie dies bei Krieg oder Terrorereignissen der Fall ist (siehe Wisniewski, 2016, S. 21).

#### **Deutsche Wirtschaftsstimmung und DAX**

Bei der Wirtschaftsstimmung zeigten sich folgende signifikanten Zusammenhänge. Die tägliche Anzahl negativer Wörter ( $r_s=-0,504$ ;  $p<0,01$ ), die Anzahl der Tweets ( $r_s=-0,372$ ;  $p<0,01$ )

und die Anzahl der gesamten Wörter deutscher Wirtschafts-Tweets ( $r_s = -0,404$ ;  $p < 0,01$ ) korrelieren negativ mit dem DAX des gleichen Tages. Auch bei der Anzahl der positiven Wörter konnte ein Zusammenhang nachgewiesen werden ( $r = -0,179$ ,  $p < 0,05$ ), dieser ist jedoch ebenfalls negativ. Die Anzahl der negativen Wörter weisen gefolgt von der Anzahl der Wörter im Allgemeinen sowie der Anzahl der Tweets die stärksten negativen Zusammenhänge auf. Jedoch zeigt sich dieser negative Zusammenhang, wenn auch in schwächerer Ausprägung, auch bei den positiven Wörtern bzw. bei positiver Stimmung. Dies könnte ein Indikator dafür sein, dass die negative Stimmung und das allgemeine Verbreiten von Wirtschaftsinformationen zu Unsicherheit führen. Dies geht mit einer Verschlechterung des DAX einher. Auch positive Stimmungen scheinen zu Unsicherheiten oder Skepsis zu führen, die mit dem DAX ebenfalls, wenn auch in geringerer Ausprägung, negativ zusammenhängen. Insgesamt könnte dies bedeuten, dass sowohl die Wirtschaftsstimmung wie auch Wirtschaftsinformationen im Allgemeinen vorsichtig bewertet werden sollten und somit mit einem niedrigeren DAX einhergehen. Auch hier konnten keine Übertragungseffekte der Stimmung auf die nachfolgenden Tage nachgewiesen werden. Bei den eigentlichen Stimmungswerten wurde jedoch kein Zusammenhang festgestellt. Die Hypothese H2, dass kein Zusammenhang zwischen Wirtschaftsstimmung in Tweets und dem DAX besteht, konnte ebenfalls nicht falsifiziert werden.

### **Deutsche Politikstimmung und DAX**

Die Anzahl negativer Wörter in Politik-Tweets am selben Tag wiesen einen positiven Zusammenhang zum DAX auf ( $r_s = 0,480$ ,  $p < 0,01$ ). Dieser Zusammenhang kehrte sich jedoch an den nachfolgenden sieben Tagen um, d. h., dass an allen Folgetagen die Anzahl der negativen Wörter in Politik-Tweets mit einer Verschlechterung des DAX einhergingen. Dieser Zusammenhang zeigte sich ebenfalls in der Politikstimmung ( $t_0$ :  $r_s = -0,530$ ,  $p < 0,01$ ;  $t = t-2$ :  $r_s = 0,541$ ;  $p < 0,01$ ). Auch hier zeigte sich am gleichen Tag ein negativer Zusammenhang, gefolgt von signifikant positiven Zusammenhängen an den sieben darauffolgenden Tagen. Dies könnte bedeuten, dass negative Stimmungen oder Ereignisse in der Politik am gleichen Tag noch zu positiven Effekten beim DAX führen. Dem Anschein nach ist dies für Spekulationen besonders interessant. Eine weitere Möglichkeit ist, dass die Informationen erst vom Anleger verarbeitet werden müssen und sich mit einer Zeitverzögerung negativ auf den DAX auswirken. Die Politikstimmung könnte im Gegensatz zur DAX- oder Wirtschaftsstimmung die Nutzer länger und nachhaltiger beeinflussen. Dies könnte darin begründet sein, dass das politische Geschehen nachhaltige Auswirkungen auf die Wirtschaft und somit auch auf den DAX nehmen kann. Andererseits erstrecken sich in der Politik Veränderungen meist über größere Zeiträume und könnten

somit einen langfristigen Zusammenhang haben. Die Hypothese H3, dass es keinen Zusammenhang zwischen Politikstimmung in Tweets und dem DAX gibt, kann falsifiziert werden. Dies entspricht auch der Erkenntnis von Bollen (2011a, S. 453), dass sich langfristige Veränderungen graduell vollziehen. Dieses Ergebnis steht allerdings auch im Gegensatz zu Stambaugh et al. (2012, S. 301), die bei einer hohen Investorenstimmung eine Überbewertung der Aktien beobachteten. Negative Stimmung in der Politik kann mit Unsicherheit in Verbindung stehen.

### **Zusammenhang englischer DAX-Stimmung und dem DAX**

Hypothese H4, dass die Stimmung englischer DAX-Tweets keinen Zusammenhang zum DAX hat, konnte nicht falsifiziert werden. Dies entspricht dem Ergebnis der deutschen DAX-Stimmung.

### **Stimmungen deutscher Tweets der Themen DAX, Wirtschaft und Politik untereinander**

Die Stimmungen der drei deutschen Themen hängen nicht signifikant miteinander zusammen. Die Hypothesen konnten nicht falsifiziert werden. Ursächlich könnte die Unabhängigkeit der Themen sowie der Nutzer sein. Bei Politik- und Dax-Stimmung ist die Streuung umso höher, je schlechter die jeweilige Stimmung ist.

### **Stimmungen englischer DAX-Tweets und den Stimmungen deutscher Tweets**

Ein Zusammenhang zwischen Stimmungen englischer DAX-Tweets und Stimmungen deutscher DAX-, Wirtschafts- und Politik Tweets konnte nicht nachgewiesen werden. Somit konnten die Hypothesen H8 bis H10 hier nicht falsifiziert werden. Es bestanden nur signifikante Zusammenhänge bei der Anzahl der Wörter. Die fehlenden Zusammenhänge könnten möglicherweise durch die unterschiedlichen Lexika begründet sein. Während im deutschen Lexikon für jedes Wort je nach positiver oder negativer Ausprägung Stimmungszahlen verwendet werden, werden im englischsprachigen Lexikon lediglich positive und negative Wörter unterschieden.

### **Ähnlichkeiten**

Bei dieser Analyse kann festgestellt werden, ob Variablenkonstellationen ähnlicher sind als andere. Aufbauend auf den Ergebnissen der Korrelation wurden die binären Ähnlichkeiten untersucht. Die Ergebnisse der Ähnlichkeitsanalyse berücksichtigen den zeitlichen Verlauf von steigendem und fallendem DAX bzw. steigender und fallender Stimmung. Beim M-Koeffizienten sind in den drei Themenstimmungen Ähnlichkeiten gering über 50% festzustellen. Zeitgleiche Ähnlichkeit ist in diesem Kontext für eine DAX-Vorhersage irrelevant, da zur Vorhersage ein

Vorlauf benötigt wird. Schließlich konnten Ähnlichkeit zwischen den binären Stimmungen in allen drei Themen und dem binären DAX festgestellt werden. Ebenso haben sich Ähnlichkeiten bei dem Vorlauf gezeigt. Die Berücksichtigung der Ähnlichkeit für die Vorhersage ist allerdings mit Informationsverlust verbunden, da die Stimmungen in binäre Daten transformiert werden müssen. Das Ergebnis der Ähnlichkeitsanalyse rechtfertigt jedoch keine Transformation der Stimmungswerte auf ein niedrigeres Skalenniveau.

### **Zusammenhang des Vorlaufs zwischen Stimmungen und dem DAX**

Wie im vorherigen Abschnitt diskutiert, konnte lediglich ein signifikanter Zusammenhang des Vorlaufs in den Stimmungen der Politik-Tweets nachgewiesen werden. Die Stärke der Korrelation zwischen der Politikstimmung und dem DAX nimmt bis zu einem Vorlauf von bis zu drei Tagen in die Vergangenheit sukzessive ab. Dementsprechend hängt die aktuelle Stimmung stärker als die gestrige und vorgestrigte Stimmung mit dem DAX zusammen. Vom vierten bis zum achten Tag zeigte sich jedoch kein Abfall der Stärke des Zusammenhangs. Es zeigte sich an  $t_4$  ein Anstieg der Stärke des Zusammenhanges im Vergleich zum Vortag. So waren an den nachfolgenden Tagen sowohl stärkere als auch schwächere Zusammenhänge zur Stimmung im Vergleich zum ersten Tag nachweisbar. Wenn auch die Unterschiede in der Stärke der Zusammenhänge gering waren ( $t_0$ :  $r=-0.530$  bis  $t_7$ :  $r=-0,488$ ), lässt sich jedoch diese Tendenz aufzeigen. Dies würde nahelegen, dass die Stimmungen aus der Politik in den ersten drei Tagen sukzessive weniger mit dem DAX zusammenhängen. Der stärkste Zusammenhang zeigt sich jedoch an den ersten beiden Tagen sowie an  $t_5$ . Dies bedeutet, dass die aktuelle politische Stimmung den stärksten Zusammenhang zum DAX hat. Jedoch ist der Zusammenhang der Stimmung mit dem DAX unterschiedlich stark bei den darauf folgenden Tagen.

Der Zusammenhang von jeweils allen Vorläufen der Politikstimmung und dem DAX ist nicht ausreichend aussagekräftig. Denn es geht nicht um die absolute Höhe des DAX-Kurses, sondern um seine Veränderung. Alles andere kann als Niveaueffekt interpretiert werden. Während in der Einleitung dieser Arbeit das Tweet mit der Falschmeldung einen kurzfristigen Effekt zeigte (drei Minuten bis zur Regeneration des Kurses), geht es in dieser Arbeit um die mittelfristige Vorhersage mit bis zu sieben Tagen Vorlauf. Langfristanalysen, beispielsweise wie die Politikstimmung einem Trend über Wochen gefolgt ist, waren nicht Bestandteil der Arbeit.

Sowohl Zusammenhangs- als auch Ähnlichkeitsanalyse haben gezeigt, dass es nicht ausreicht, nach Themen aufzuschlüsseln. Hier wurden nicht ausreichend signifikante Themenstimmungen für eine Vorhersage identifiziert. Somit ist es zwingend erforderlich, nach der Themenaufschlüsselung weiter nach Nutzern aufzuschlüsseln, da die Themenstimmungen nicht über die

ausreichende Qualität zur Vorhersage verfügen. Dies bedeutet, dass die Themen nicht in ausreichendem Maße Muster zur Vorhersage enthalten. Sie sind zu verrauscht. Das Rauschen kann durch weitere Aufschlüsselung nach Nutzern herausgefiltert werden.

### **Nutzer mit höchster Aktivität und Nutzer mit den meisten Abonnenten**

Um herauszufinden, welcher Nutzer mit seiner Stimmung am stärksten mit dem Kursverlauf des DAX korreliert, werden die Stimmungszeitreihen auf Nutzerebene berechnet. Da nicht alle Nutzer gleichzeitig zur Vorhersage berücksichtigt werden können, mussten sie ausgewählt werden. Hierzu gäbe es die Möglichkeit der Auswahl durch ein vorgelagertes Verfahren, in diesem Fall einer statistischen Methode zur Identifizierung von Zusammenhängen. Es hat sich jedoch gezeigt, dass weder die Nutzer mit den meisten Abonnenten noch die mit der höchsten Aktivität gemäß geschriebener Tweets geeignet sind.

Die Tabelle N auf Seite 109 bis Tabelle R auf Seite 113 enthalten die Korrelationskoeffizienten der Nutzer mit der höchsten Aktivität. Auffällig ist, dass die Stimmungen dieser Nutzer auch untereinander korrelieren. So hängen vier Nutzerstimmungen (Nutzer 2, 4, 5, 10) bei den DAX-Themen gemäß Tabelle N auf Seite 109 mit der des Nutzers mit der höchsten Aktivität zusammen. Auch bei den Wirtschafts- und Politik-Tweets hängen jeweils drei Nutzerstimmungen mit der des Nutzers mit der höchsten Aktivität zum jeweiligen Thema zusammen. Dies bedeutet, dass der Nutzer mit der höchsten Aktivität die Stimmung vorzugeben scheint und die anderen Nutzer orientieren sich bewusst oder unbewusst daran. Da hier sowohl positive als auch negative Korrelationen zwischen den Nutzern mit der höchsten Aktivität festgestellt wurden, verdeutlicht dies ebenfalls eine gewisse Homogenität bei den Veränderungen der Stimmungen. Dies bedeutet jedoch nicht, dass die Stimmungen unter den Nutzern gleich positiv oder gleich negativ gerichtet sind. Ursächlich könnte auch hier die kontroverse Diskussion der Themen auf Twitter sein. Dies mag auch verursacht sein durch unterschiedliche Gefühlsreaktionen der einzelnen Twitter-Autoren auf Tweets eines abonnierten Nutzers. Bei den englischen DAX-Tweets hängt eine Nutzerstimmung mit der des Nutzers mit der höchsten Aktivität zusammen. So sind die Veränderungen der Stimmungen unter den Nutzern der englischen Tweets heterogener als die der Stimmungen der deutschen Nutzer. Im Anschluss sind die Mechanismen zur Zusammenfassung der Einzelstimmungen zu hinterfragen.

### **Alle Nutzer**

Insgesamt hängen 118 Nutzerstimmungen mit dem DAX zusammen. Die jeweiligen Einzelhypothesen auf Nutzerbasis konnten falsifiziert werden. Diese werden im folgendem bei der Optimierung berücksichtigt.

## 5.2 Optimierung

### **Qualität der Stimmungen**

Die Qualität der Stimmungen ist durch die Themenfilterung verbessert worden. So wurde durch die thematische Homogenität das Rauschen reduziert. Durch die individuelle Betrachtung der Sprachen konnten gemäß Bollen (2011b, S. 7) auch geografische Verzerrungen in der Stichprobe reduziert werden. Auffällig ist allerdings, dass die Güte der Modelle der bereits nach signifikanter Korrelation zum DAX ausgewählten Nutzer zwischen 53% und 80% variiert. So bestehen bei den unterschiedlichen Nutzern gewisse Qualitätsunterschiede der Stimmungsmuster zur Vorhersage. Die vorgelagerte Korrelation ist dementsprechend ein notwendiger Qualitätsfilter und dient der Reduktion. Die Zeitreihen haben bei Gesamt- und Themenstimmungen wenige fehlende Werte. Dies ist auf Nutzerebene nicht der Fall. Dies hat zur Folge, dass im Durchschnitt ca. 25% der signifikant korrelierenden Nutzer zum DAX für eine Vorhersage berücksichtigt werden können.

Zusammenfassend hat sich gezeigt, dass die Klassifikation durch Isolation der Experten mit Hilfe der Kombination statistischer Methoden innerhalb der Stichprobe bei längerfristigem Vorlauf von sechs Tagen zu 80% genau war. Das Modell auf Nutzerebene hat als Vorhersagesystem bezüglich Güte die Modelle der Gesamt- und Themenebene übertroffen. Somit kann durch Auswahl des Vorlaufes die Vorhersagekraft erhöht werden. Diese Modellgüte geht einher mit den Ergebnissen von Sprenger et al. (2010, S. 935), wobei es in dieser Studie auf Nutzerebene keine kurzfristigere Vorhersage mit ähnlicher Güte gibt, was auch Brown et al. (2004, S. 22) bestätigen. Die Verbesserung der Modellgüte durch gezielte Auswahl des 6. Vorlaufes steht im Gegensatz zu den Ergebnissen von Gilbert et al. (2010, S. 62), bei denen die Hinzunahme der Vorläufe ab drei Tagen in die Vergangenheit die Kursvorhersage nicht verbesserten. Auffällig ist, dass sich die Modellgüte der Vorhersage mit steigender Anzahl der berücksichtigten Nutzerstimmungen verbessert. Eine Erklärung hierfür ist die Nutzung der kollektiven Intelligenz, bei der die Güte der Kaufempfehlungen einer Gruppe die eines einzelnen übertrifft.

### **Reduktion der Nutzerstimmungen**

Die Ergebnisse haben gezeigt, dass eine Optimierung mit Nutzern aus bestimmten Themen nützlich ist. Die Themenstimmungen selbst sind nicht differenziert genug, was anhand der Hypothesen nachgewiesen wurde. So ist es erforderlich, nach Nutzerstimmungen zu optimieren. Eine isolierte Anwendung mit einer Methode ist aufgrund der Anzahl der Nutzerstimmungen

gemäß technischer Restriktionen nicht möglich. So lag die Problematik der bisherigen Forschung darin, dass die statistischen Methoden jeweils isoliert auf eine Gesamtstimmung angewendet wurden. Folglich ist auch die isolierte Vorhersage mit Hilfe des neuronalen Netzes nicht zielführend. Dies ist damit begründet, dass selbst wenn alle Nutzerstimmungen einzeln als Eingangsneuronen berücksichtigt würden, es aufgrund der Komplexität nicht möglich wäre, den DAX vorherzusagen. Es wären zu viele Informationen. Hier waren es 14.356 Nutzer, jeweils mit einem Vorlauf bis zu sieben Tagen, welches 100.492 Eingangsneuronen entspräche. Die Aufschlüsselung nach Themen ist jedoch nicht ausreichend für eine Vorhersage. Daher ist es zwingend erforderlich, aus diesen Themen weitere Teilmengen zu bilden, die sich für eine Vorhersage eignen.

Diese Arbeit hat sich auf eine beschränkte Stichprobe konzentriert. Die Komplexität aufgrund der Anzahl von Nutzerstimmungen wird allerdings deutlicher, wenn über einen längeren Zeitraum und mit zusätzlichen Themen eine Vorhersage modelliert werden soll. Grundsätzlich empfiehlt sich, zusätzliche verwandte Themen, die ebenfalls mit dem #-Symbol in einem DAX-Tweet auftreten, sowie alle Sprachen und alle Nutzer zu berücksichtigen. Bei 336 Millionen aktiven Nutzern (Statista GmbH, 2018) sind gemäß Tabelle 4.15 (Seite 55) ca. 2% der Nutzer aufgrund der benötigten Mindestanzahl von Tweets durch geeignete statistische Methoden auszuwählen. Dies entspricht 6,7 Millionen Nutzern. Werden die jeweiligen Vorläufe von sieben Tagen hinzugerechnet, so ergibt dies ca. 46 Millionen Tagesstimmungen. Bei dieser Anzahl von Tagesstimmungen könnte die Anpassung der Vorläufe zwischen dem neuronalen Netz und der Korrelation jedoch Zeitkomplexitäten erzeugen. Dies gilt auch für die Anzahl der (Eingangs-)Neuronen, die für die Vorhersage im neuronalen Netz benötigt werden. Es handelt bei den einzelnen Modellierungen um seriell verschaltete Algorithmen zur Optimierung der Vorhersage. Dies ist ein praktisches Problem bezogen auf die Rechenzeit, die durch die einzelnen Rechenschritte benötigt wird. Daher ist es notwendig, die Anzahl der Eingangsvariablen und somit auch die Anzahl der Neuronen des neuronalen Netzes zu reduzieren. Bei den 18 Modellierungen wurde jeweils eine verborgene Schicht verwendet, welches die Komplexität der Netzwerkarchitektur und somit die Rechenzeit für das Training und den Test reduziert.

Eine Möglichkeit der Reduktion von Stimmungen ist die Anpassung von Optimierungsparameter. Diese sind der Vorlauf und die Signifikanz der Korrelation. Schließlich kann dieses neue Verfahren mit jeweils unterschiedlichen Parametern bei Vorlauf und Signifikanzniveau der Korrelation verwendet werden. Diese Parameter sind bei jeder Modellierung zwischen Korrelation und neuronalem Netz auszutauschen.

### **Themenstimmungen und Nutzer mit höchster Aktivität**

Die Vorhersagekraft des neuronalen Netzes auf Basis der Themenstimmungen war inakzeptabel. Somit enthalten die Themenstimmungen noch zu viel Rauschen. Weiterhin war die Vorhersage des DAX durch die Nutzer mit höchster Aktivität ebenfalls nicht akzeptabel. Demzufolge sind es die individuellen Nutzerstimmungen, die eine Vorhersage verbessern. So wurde mit der Korrelation die Qualität der Nutzerstimmungen zur Vorhersage verbessert.

### **Themenspezifische Nutzerstimmungen**

Insgesamt hat sich gezeigt, dass die Aufschlüsselung der Gesamtstimmung nach Themen und anschließend nach Nutzern die Vorhersage des DAX verbessert. Es entstanden somit die themenspezifischen Tagesstimmungen eines Nutzers. Den Ergebnissen zufolge hat ein Nutzer zu unterschiedlichen Themen auch unterschiedliche Stimmungen. Zunächst wird thematisch aufgeschlüsselt. Darauf wird nach Nutzern aufgeschlüsselt und anschließend werden die Tagesstimmungen über die Korrelation ausgewählt. Ein Nutzer kann zu mehreren Themen schreiben, beispielsweise positiv über den DAX und negativ über die Wirtschaft. Daher wurden die Nutzerstimmungen nach Thema getrennt. Das Schätzen der Verlässlichkeit eines Nutzers mit der vorgelagerten Korrelation steht im Gegensatz zu den Ergebnissen von Yamaguchi et al. (2010, S. 250). Die Autoren haben die Verlässlichkeit eines Nutzers unter anderem über das Verhältnis seiner Tweets zu deren Weiterleitungen bestimmt.

### **Gesamtstimmung eines Nutzers**

Die Gesamtstimmung einer Person zu allen Themen, also ob sie optimistisch oder pessimistisch ist, wurde nicht berücksichtigt. Fraglich ist, ob nicht dieses generelle Stimmungsniveau eines Nutzers ebenfalls weitere Informationen enthält, ob ein positives Tweet zum DAX von einer pessimistischen Person höher zu bewerten wäre als von einer optimistischen Person. Hier wäre die gesamte Nutzerstimmung aus seinen einzelnen Themenstimmungen zu berechnen. Hierfür müssten folglich seine Einzelstimmungen zu einem Thema zusammengefasst werden. So ist die gesamte Stimmung

$$\sum_{i=1}^n g_i \quad (5.1)$$

für die Themenstimmung  $g$  eines Nutzers  $i$ .

### **Berücksichtigung einer individuellen Korrelation je Vorlauf**

Die Zusammenhänge zum DAX sind bei Themen und Nutzern bei jeweils unterschiedlichen Vorläufen signifikant. Dies bedeutet, dass nicht ein Vorlauf für alle Nutzer festgelegt werden sollte. So wird bei der Modellierung die Tagesstimmung eines Nutzers gemäß Signifikanz für jeden Vorlauf bestimmt. Auf Nutzerebene, welche nach der Themenebene aufgeschlüsselt ist, sind die signifikanten Korrelationen jedes einzelnen Nutzers fortlaufend zu bestimmen. So wird hier nicht ausschließlich nach dem Vorlauf optimiert, sondern zielgerichtet nach jedem Nutzer pro Vorlauf.

### **Neuronales Netz**

Das neuronale Netz übernimmt die anschließende Zusammenfassung, um letztlich eine Entscheidung zu treffen. Schließlich wird ein Gesamtergebnis zusammengesetzt. Hierbei ist das neuronale Netz die geeignete statistische Methode für Stimmungen, die nichtlinear miteinander zusammenhängen. Zu berücksichtigen ist jedoch, dass es sich hierbei um ein komplexes System handelt, welches über Training und maschinelles Lernen Zusammenhänge herstellt, die komplex, nichtlinear und dynamisch sind. Zudem muss berücksichtigt werden, dass es sich hierbei um ein künstliches System handelt. Die zugrundeliegenden Zusammenhänge sind nicht offensichtlich. Einschränkend ist zu erwähnen, dass diese Systeme auch übertrainiert werden können. Ein weiterer Nachteil neuronaler Netze ist, dass nicht bekannt ist, wie die Eingangsneuronen für die Klassifikation verarbeitet werden, d. h. es gibt nur eine Matrix der Verbindungsgewichte zwischen den Neuronen (Hawley et al., 2008, S. 68). Den Autoren zufolge kann somit die Verarbeitung der Eingangsvariablen nicht mit Algorithmen beschrieben werden, die außerhalb des neuronalen Netzes verwendet werden können. Im Kontext dieser Arbeit bedeutet dies, dass die Ergebnisse bei der Vorhersage auch modellgebunden sind. Die Vorhersagekraft anhand der Stimmungsparameter unterstreicht jedoch die Bedeutung und den Zusammenhang zwischen den Nutzerstimmungen in den Themen DAX, Wirtschaft und Politik und dem DAX.

### **Kreuzentropiefehler je Vorhersagemodell**

Neben der Modellgüte ist ebenfalls der Kreuzentropiefehler ein Indiz für die Güte der Vorhersage. Abbildung 5.1 stellt den Kreuzentropiefehler je Modell für das Training und den Test der Vorhersage dar.

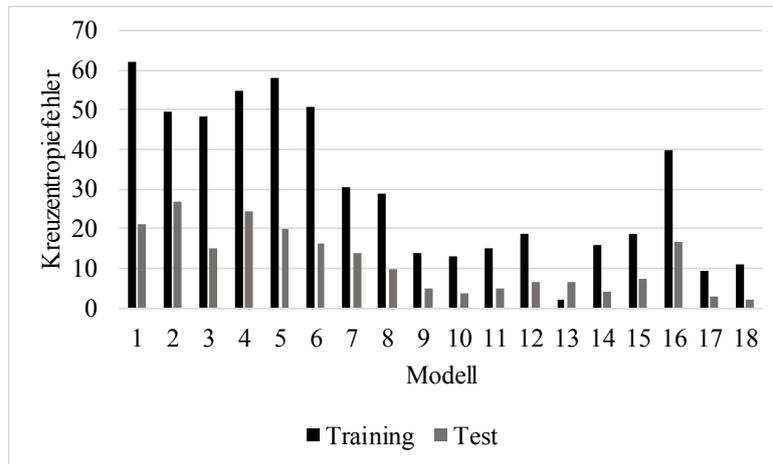


Abbildung 5.1: Kreuzentropiefehler je Modell

Quelle: Eigene Darstellung

Bei den Gesamtstimmungen (Modell Nr. 1-3) sowie bei den Themenstimmungen (Modell Nr. 4-6) sind die Kreuzentropiefehler im Training hoch. Erst auf Basis der Nutzerstimmungen (ab Modell Nr. 7) nimmt der Fehler deutlich ab. Dies bedeutet, dass die Vorhersage auf Basis der Nutzerstimmungen zu präferieren ist. Auffällig ist, dass in Modell Nr. 6 bei 42 Stimmungen die Kreuzentropiefehler zur Vorhersage nicht von den Modellen abweicht, die weniger als zehn Stimmungen haben. Dies führt zu dem Schluss, dass die Vorhersage mit Hilfe eines neuronalen Netzes mit größerer Parametrisierung (42 Stimmungen) technisch möglich ist, jedoch nicht zu einem geringeren Fehler führt. Weicht der Fehler im Training von dem im Test deutlich ab, so reduziert sich die Generalisierbarkeit eines Modells. Bei den Gesamt- und Themenstimmungen sind abweichenden Kreuzentropiefehler feststellbar. So hat auch das optimale Modell (Nr. 17), welches ebenfalls auf Nutzerstimmung basiert, eine Differenz zwischen den Kreuzentropiefehlern im Training und Test von 6,451. Zur Reduktion der Kreuzentropiefehler wird empfohlen, die Stichprobe zu vergrößern.

### Wichtigkeit der Nutzer

Gemäß Tabelle S (Seite 116) wurden für die acht Modelle auf der Ebene der signifikant zum DAX korrelierenden Nutzer insgesamt 34 Tagesstimmungen von 16 Nutzern verwendet. Tabelle 5.1 zeigt die kumulierten Wichtigkeiten der Stimmungen auf der Ebene dieser Nutzer.

Tabelle 5.1: Wichtigkeit nach Nutzern

Nutzer	Kumulierte Wichtigkeit	Vorkommen in Modell 11-18	Wichtigkeit in Modell 17
Moneycab	1,684	5	0,256
AnonNewsDE	1,230	3	0,081
AustriaDaily	0,955	5	
AxelHohl	0,951	4	
worldnetnews	0,821	5	
Kazi_Germany	0,633	2	0,171
CFD_Markt	0,411	2	0,242
StutzPartner	0,368	1	
YasinBerlinDE	0,363	1	
brokertest	0,170	1	
NeuigkeitenDE	0,127	1	0,127
Erdbeer_Joghurt	0,108	1	
WirtschaftNews	0,081	1	0,081
schlagzeilenl	0,058	1	
Finanzwiese	0,042	1	0,042

Quelle: Eigene Darstellung

Die Tabelle ist absteigend nach kumulierter Wichtigkeit der Nutzerstimmungen geordnet. Die kumulierte Wichtigkeit ist die Summe der Wichtigkeiten der Stimmungen bei den Modellen auf Nutzerebene mit dem neuen Verfahren der Optimierung (Modell Nr. 11-18). Die Wichtigkeit wird für das Modell 17 gesondert herausgestellt. Bei diesem Modell ist die Güte der DAX-Vorhersage mit 80% am höchsten. Acht Nutzer wurden mit ihrer Tagesstimmung einmal für eine Vorhersage verwendet. So sind auch jene Nutzer für eine DAX-Vorhersage geeignet, die auch mehrfach mit ihren Tagesstimmungen, insbesondere auch mit ihren Vorläufen, durch die Optimierung ausgewählt wurden. Es gibt drei Experten, deren Tagesstimmungen in acht Modellen (über 50% der Modelle) auf Nutzerebene ausgewählt worden sind. Dies bedeutet, dass es wenige Experten gibt, die mit ihren zeitverschobenen Tagesstimmungen den DAX-Verlauf antizipieren. Hierbei muss nicht weiter berücksichtigt werden, ob die Stimmungen dieser ausgewählten Nutzer positiv oder negativ mit dem DAX zusammenhängen. Ihre Tagesstimmung muss folglich bei negativer Korrelation zum DAX nicht als absoluter Wert betrachtet werden. Auffällig ist ebenfalls, dass die Hälfte der Nutzer für mehrere Vorläufe ausgewählt wurde. So ist der Nutzer mit der höchsten kumulierten Wichtigkeit ebenfalls im besten Vorhersagemodell vertreten und wurde insgesamt bei fünf von acht Modellen berücksichtigt.

### Anwendung für die Praxis

Es hat sich gezeigt, dass sich mit dem neuen Verfahren die DAX-Vorhersage mit Twitter verbessern lässt. So trägt diese Arbeit dazu bei, die Vorhersage verrauschter und unscharfer Daten

durch Aufschlüsselung und durch Einsatz eines vorgelagerten Verfahrens auf Nutzerebene zu verbessern. Der praxisbezogene Anwendungsfall dieses neuen Verfahrens ist die Echtzeitanwendung. Wurde hier ein begrenzter Zeitraum betrachtet, könnte das Verfahren permanent und fortlaufend die Tweets analysieren und eine aktuelle Kaufempfehlung geben. Es hat sich weiterhin gezeigt, dass mehrere Experten auf Nutzerebene zu identifizieren sind. Den Stimmungen dieser Experten könnte ein Anleger automatisch mit Hilfe dieser auf Algorithmen basierten Handelsstrategie folgen und sein Portfolio dementsprechend steuern. Somit ist die Anwendung gemäß Brown (2012, S. 40) ein Entscheidungsunterstützungssystem für Investoren.

### 5.3 Limitationen

#### **Stichprobe**

Diese Arbeit beschränkt sich auf die Stimmungsanalyse einer Textquelle: Texte aus öffentlichen Tweets. Weiterhin wurden die Sprachen Deutsch und Englisch berücksichtigt. Die Stichprobe beinhaltet 180 Tage. Folglich könnte die Stichprobe nicht repräsentativ und daher verzerrt sein. So empfiehlt sich gemäß Bae et al. (2012, S. 2534), die Stichprobe zu vergrößern, um den Zusammenhang bzw. die Zuverlässigkeit der Experten auch über einen längeren Zeitraum zu bestimmen. Dies ließe sich bezüglich Datenverfügbarkeit und Rechenzeit realisieren. Vorhersagen, die auf Erhebungen innerhalb einer Stichprobe beruhen, sind verlässlicher als Vorhersagen, die sich auf Erhebungen außerhalb einer Stichprobe beziehen (Inoue et al., 2005, S. 396). Dementsprechend haben die verwendeten Stimmungen innerhalb der Stichprobe dieser Arbeit signifikante Vorhersagekraft bei Aktienrenditen (Rapach et al., 2006, S. 245).

Neuronale Netze können dazu tendieren, die Daten zur Vorhersage zu erinnern statt sie zu generalisieren (Armstrong, 2001, S. 251). Gemäß dem Autor besteht dieses Problem besonders bei kleinen Datensätzen in Verbindung mit einer hohen Anzahl von Stimmungen. Armstrong empfiehlt, die Architektur des neuronalen Netzes klein zu halten (2001, S. 251). So empfehlen auch Raabe et al. (2006, S. 196) das Weglassen von konstanten Werten und stark verrauschten Variablen.

#### **Stimmungslexika**

Es wurden universelle Stimmungslexika angewandt. Themenbezogene Stimmungslexika, in diesem Kontext Lexika speziell für den Aktienmarkt, könnten die Vorhersage des DAX optimieren. Nach Zhang (2011b, S. 8) erschweren die speziellen Eigenschaften von Tweets die

Extraktion mittels Stimmungsexika und das maschinelle Lernen. Humor, Sarkasmus, Werbung, Wortspiele und Mehrdeutigkeit komplizieren die Stimmungsextraktion. Ein Beispiel für Humor aus der Stichprobe der DAX-Tweets ist:

#csu ist eine tolerante Partei #liberalitasbavariae. Indes ist die #CSU wie eine #DAX gelistetes AG. Misserfolge #seehofer = Amtsverlust

Ein Beispiel für eine Werbenachricht aus den DAX-Tweets ist:

Urlaub auf #Sylt - am besten zu zweit! Escort-Rubensfee begleitet Dich! <http://t.co/vB03gAQ1Mh> #meer #dax

Diese Beispiele zeigen, dass die Stimmungen in diesen unerwünschten Werbenachrichten und humoristischen Tweets mitberücksichtigt werden. Gleichzeitig ist es für Algorithmen unmöglich, diese falschen Informationen zu identifizieren. Durch Berücksichtigung der Abonnenten könnte die Relevanz solcher Tweets bewertet werden. Bei Werbenachrichten könnte der thematische Bezug mit beispielsweise untypischen Wörtern für den DAX gemessen werden, um die Vorhersage zu optimieren. Schließlich kann Agarwal et al. (2011, S. 38) zugestimmt werden, der ebenfalls eine umfassendere linguistische Textanalyse mit Berücksichtigung der Semantik fordert. Auch Barbosa et al. (2010, S. 43) fordern eine feinere Textanalyse in Bezug auf antagonistische Stimmungen innerhalb eines Tweets, die auch durch Verneinungen verursacht werden können. Gerade in Bezug auf Finanznachrichten bietet sich an, gemäß (Rajadesingan et al., 2015, S. 100) auch zwei Worte oder eine Phrase, sogenannte N-Gramme, in die Stimmungsextraktion zu integrieren.

Eine von Menschen durchgeführte Bestimmung einer Stimmung könnte die Genauigkeit der Stimmungserkennung erhöhen. Aufgrund der Datenmenge (200.191 Tweets) wurde sich auf Algorithmen beschränkt. Für eine durch Menschen durchgeführte Stimmungsanalyse wäre die Auslagerung der manuellen Stimmungsbestimmung an Nutzer über das Internet denkbar (Nakov et al., 2016, S. 3).

### **Berücksichtigung weiterer Metadaten**

Zusätzliche Informationen zu einem Tweet wie enthaltene Internetverknüpfungen oder die Quelle, also von welcher Plattform aus ein Tweet geschrieben wird, könnte auch berücksichtigt werden. Die Plattformen sind in Tabelle 5.2 nach Thema gelistet.

Tabelle 5.2: Quellen der Tweets

Rang	DAX-Quelle	DAX-Abonnenten	Wirtschaft-Quelle	Wirtschaft-Abonnenten	Politik-Quelle	Politik-Abonnenten
1	Twitter Web Client	18.332	twitterfeed	20.951	twitterfeed	17.609
2	dlvr.it	11.192	dlvr.it	5.976	dlvr.it	13.319
3	TweetDeck	3.662	ForceTweet	4.551	Google	3.157
4	HubSpot	2.587	Twitter Web Client	3.753	Twitter Web Client	2.918
5	Twitter for iPhone	2.362	Hootsuite	2.497	IFTTT	2.353
6	Twitter for Android	1.458	IFTTT	2.449	Twitter for Android	2.166
7	Twitter for Websites	1.219	dpaAFXTweetConnect	1.422	Twitter for iPhone	1.114
8	twitterfeed	911	Twitter for Websites	1.373	Hootsuite	1.060
9	Hootsuite	823	Google	1.304	Twitter for BlackBerry	937
10	Twitter for iPad	613	Twitter for Android	706	Twitter for Websites	495

Quelle: Eigene Darstellung

Auffällig ist, dass bei den deutschen DAX-Tweets der Twitter-eigene Zugang die meisten Abonnenten hat. Dies deutet auf eine fragmentierte und individualisierte Nutzung der Twitter-Autoren hin, da professionelle Autorensysteme nicht schwerpunktmäßig genutzt werden. Auffällig ist ebenfalls, dass bei allen deutschen Themen an zweiter Stelle automatisierte Plattformen zum Erstellen von Inhalten in sozialen Netzwerken genutzt werden. Dies deutet bei den Abonnenten des DAX-Themas auf ein Interesse an Inhalten hin, die nicht über Schnittstellen automatisiert veröffentlicht werden. Es entspricht der individuellen Suche nach den Experten, die nicht zu den Massenmedien gehören.

Die Anzahl der Follower, weiterer Themen und Trendthemen wären zusätzlich einzubeziehen. Die weiteren zehn meist genannten Themen sind in Tabelle 5.3 gelistet.

Tabelle 5.3: Weitere erwähnte Themen in der Stichprobe

Rang	DAX-Thema	DAX-Tweets	Wirtschaft-Thema	Wirtschafts-Tweets	Politik-Thema	Politik-Tweets
1	#cfd_market	5.792	#news	10.764	#svb	3.100
2	#forex	4.393	#böerse	3.878	#news	1.799
3	#ftse	3.704	#finanzen	2.517	#berita	1.799
4	#gold	3.198	#geld	1.403	#dunia	1.621
5	#trading	2.683	#politik	.706	#tempo	1.349
6	#news	2.282	#aktuell	439	#vivanews	1.105
7	#cac40	2.144	#eu	433	#breakingnews	676
8	#cac	1.936	#forex	388	#svpol	526
9	#jobs	1.936	#business	381	#val2014	252
10	#jobsila	1.912	#deutschland	347	#beritamalaysia	246

Quelle: Eigene Darstellung

Bei den DAX-Themen fällt das weitere Interesse an Differenzkontrakten, am Devisenmarkt und am Goldpreis auf. Letzterer dient vermutlich als Referenz zur Rendite, im Gegensatz zu den beiden anderen erwähnten Anlagemöglichkeiten.

Ein weiteres Metadatum sind die besonders gekennzeichneten Finanzinformationen. Diese werden in Twitter vermehrt mit dem \$-Symbol gekennzeichnet und in Investorenkreisen benutzt (Oliveira et al., 2013, S. 2). Twitter interpretiert dies als Link und zeigt Tweets und weitere Informationen zu diesem Unternehmen an. Ein Beispiel für ein Tweet mit solch einer Kennzeichnung ist:

\$DAX im Sinkflug. Wie geht's weiter? Unsere A1:AY33724 sind gute Frühindikatoren. <https://t.co/vJ4Zn98saw> #Dax #boerse

Dieser Aspekt wurde nicht berücksichtigt.

Insgesamt wäre die Analyse der eigentlichen Verbreitung von Stimmungen in Twitter sinnvoll. Fraglich wäre, ob Personen Nutzern mit guter oder schlechter Stimmung folgen und wie sich Stimmung auf andere Nutzer auswirkt, also ob sie angenommen wird.

## 5.4 Zukünftige Forschung

Zu untersuchen wäre, ob auch andere vorgelagerte Methoden an Stelle der Korrelation zur Auswahl der Stimmungen für die Vorhersage eingesetzt werden können. So könnte das Modellbildungsverfahren mit Optimierung durch weitere Methode verfeinert werden, die beispielsweise auch einen verlängerten Vorlauf berücksichtigen. So könnte ebenfalls untersucht werden, welche Nutzer bei unterschiedlichen Vorläufen jeweils mehrfach signifikant sind und ob es gegensätzliche Stimmungen eines Nutzers bei unterschiedlichen Themen gibt. Diese Merkmale könnten bei einer Vorhersage berücksichtigt werden.

### **Korrelationen außerhalb des Datensatzes und Individueller Vorlauf pro Nutzer**

Die bisherige Forschung hat bis heute keinen Experten gefunden, der den DAX-Kurs exakt vorhersagen konnte. Um eine Vorhersage verbessern zu können, sollten Einzelstimmungen kombiniert werden. Weiterhin könnte zielführend sein, die signifikanten Nutzer nicht auf Grundlage des DAX selbst zu bestimmen, sondern diese mit Korrelationen von deren Nutzerstimmung und Aktien auszuwählen.

Die Optimierung der Vorhersage berücksichtige für alle Nutzer jeweils den gleichen Vorlauf. Somit wird eine Vorhersage für jeden einzelnen Vorlauf modelliert. Die Vorhersage wäre zu verbessern, indem in einem Modell auch die individuellen Vorläufe eines Nutzers berücksichtigt würden. In diesem Fall würde nicht nach Vorlauf für alle Nutzer optimiert, sondern nach den individuellen Vorläufen des jeweiligen Nutzers.

### **Autokorrelation und Kreuzkorrelation**

Neben der Korrelation könnten auch die Autokorrelationen der Tagesstimmungen berechnet werden. Hierbei korrelieren die Werte einer Tagesstimmung zeitverzögert mit sich selbst (Brosius, 2013, S. 1001). So könnten periodische Stimmungsphasen in Form eines wiederkehrenden Stimmungshochs oder Stimmungstiefs eines Nutzers ermittelt werden.

Bei einer Kreuzkorrelation kann es sich gemäß dem oben genannten Autor auch um eine verzögerte Korrelation, auch zwischen den unterschiedlichen Tagesstimmungen handeln. Damit ließe sich feststellen, ob und welche Nutzer die Stimmung eines anderen Nutzers mit welcher Verzögerung adaptieren. Nach Pennacchiotti et al. (2011, S. 287) ist anhand von Tweets eine Klassifikation der Nutzer nach politischer Richtung möglich. Fraglich ist, ob die Stimmungen der Nutzer der jeweils politischen Richtungen ebenfalls untereinander in einem Zusammenhang stehen. Die Kreuzkorrelation prüft hier die Unabhängigkeit der Tagesstimmungen einzelner Nutzer. Sie könnte weiterhin die Unabhängigkeit einer Nutzerstimmung von der Themenstimmung prüfen. Somit könnten die Themenstimmungen auch voneinander abhängig sein, wie bei den DAX- und den Wirtschafts-Tweets, welches naheliegend ist. Zum anderen könnten einzelne Nutzer abhängig voneinander sein, wenn sie über einen gleichen Sachverhalt diskutieren.

### **Fourier-Transformation, Wavelet-Analyse und Rauschfilter**

Um Strukturen in den Tagesstimmungen einzelner Nutzer zu entdecken, könnte die Betrachtung der Zeitreihe in Bezug auf harmonische Oszillation mit der Fourier-Transformation aufschlussreich sein. Bei einer metrischen Stimmung würde sich die Analyse der Einzelstimmungen mit Hilfe einer schnellen Fourier-Transformation im Zusammenhang mit einer Wavelet-Analyse anbieten. Dies bedeutet, dass sich die Stimmungen in der Frequenzdomäne statt der

Zeitdomäne betrachten ließen. So könnten harmonische Oszillationen als Frequenz einer Auf- und Abwärtsbewegung einer Stimmung über die Zeit bestimmt werden. Dabei könnte der Wiener-Filter das Rauschen aus den Tagesstimmungen entfernen, welches das Auffinden von Mustern erleichtert.

### **Rekurrierendes und faltendes neuronales Netz**

Sollten auch Vorläufe mit mehr als sieben Tagen berücksichtigt werden, so bietet sich an, die Vorhersage mit einem rekurrerenden neuronalen Netz gemäß Chen et al. (2017, S. 4) mit zusätzlichem beständigem Speicher zu modellieren. So hat das Vorhersagemodell ein erweitertes Erinnerungsvermögen, das ihm das Auffinden von Mustern in Zeitreihen ermöglicht.

Wären Stimmungen nicht eindimensional, wie die hier untersuchten, sondern gemäß Arvidsson (2011) mehrdimensional, könnte bei Erweiterung der Dimension auch ein faltendes neuronales Netz eingesetzt werden. Dieses erkennt mit Hilfe von Faltungsmatrizen primär bei Bildern visuelle Muster mit minimalem Rechenaufwand (Sewak et al., 2018, S. 7). Durch diese Kernfaltung könnte die Mehrdimensionalität berücksichtigt werden.

### **Schlussbemerkung**

Grundsätzlich sind menschliche Stimmungszustände per definitionem variabel. Jedoch gelang es in dieser Arbeit, gewisse Strukturen zu entdecken. Hauptergebnis dieser Studie ist, dass einzelne Nutzerstimmungen, nachdem sie nach Themen gefiltert wurden, geeignet sind, die DAX-Vorhersage zu verbessern – und dies trotz der Tatsache, dass es wenige Nutzer gibt, deren Stimmung mit dem DAX-Kurs korrelieren. Diese Arbeit löst das Problem der Stimmungsauswahl für eine Vorhersage. Damit können Handelsalgorithmen optimiert werden, die textbasiert Stimmungen mit diesem neuen Verfahren für Twitter auswerten. Durch die entwickelte Methodik konnte eine Vorhersagegenauigkeit von 80% erreicht werden.

Die Vorhersage wurde auf Grundlage von Änderungen der Nutzerstimmungen modelliert. Die Suche nach verlässlichen Stimmungen wurde durch Kombination klassischer statistischer Methoden und maschinellem Lernen realisiert. In Verbindung mit der Datenverfügbarkeit in Echtzeit bietet dieses System mit geringen technologischen Barrieren eine zusätzliche Entscheidungsunterstützung für Investoren. So wurde die Vorhersage durch die Optimierung von Einzelstimmungen verbessert, bei der nach Themen und anschließend nach Nutzern aufgeschlüsselt wurde. Die Vorhersage eines Aktienindex wurde mit Nutzerstimmungen modelliert. Der Index besteht aus Einzelaktien. Für zukünftige Forschung kann das vorgeschlagene Modell der

Vorhersage auf Nutzerebene ebenfalls auf Einzelaktien ausgeweitet werden. Diese Optimierung könnte für die Praxis eine präzisere Vorhersage und damit einhergehend eine Reduktion der Informationsasymmetrie bedeuten.

## Literaturverzeichnis

Dieses Verzeichnis beinhaltet ebenfalls die Literatur von Tabelle A (Seite 91), die zur verbesserten Lesbarkeit in den Anhang verschoben wurde.

- Adebiyi, A. A., Adewumi, A. O. und Ayo, C. K. (2014): „Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction”. *Journal of Applied Mathematics* 2014, Nr. 1, S. 1-7
- Adler, J. (2009): „R in a Nutshell”. Sebastopol: O’Reilly
- Agarwal, A., Xie, B., Vovsha, I., Rambow, O. und Passonneau, R. (2011): „Sentiment Analysis of Twitter Data”. Tagungsband des Workshops Languages in Social Media, Association for Computational Linguistics, S. 30-38
- Allcott, H. und Gentzkow, M. (2017): „Social Media and Fake News in the 2016 Election”. *Journal of Economic Perspectives*, Band 31, Nr. 2, S. 211-236
- Antweiler, W. und Frank, M. Z. (2004): „Is All That Talk Just Noise? The Information Content of Internet Stock Message Boards”. *The Journal of Finance*, Band 59, Nr. 3, S. 1259-1294
- Armstrong, J. S. (2001): „Principles of Forecasting: A Handbook for Researchers and Practitioners”. New York: Springer Science & Business Media
- Arvidsson, A. (2011): „General Sentiment: How Value and Affect Converge in the Information Economy”. *The Sociological Review*, Band 59, S. 39-59
- Asur, S. und Huberman, B. A. (2010): „Predicting the Future with Social Media”. Tagungsband der 2010 International Conference on Web Intelligence and Intelligent Agent Technology, Band 1, S. 492-499
- Baccianella, S., Esuli, A. und Sebastiani, F. (2010): SentiWordNet 3.0: “An Enhanced Lexical Resource for Sentiment Analysis and Opinion Mining”. Tagungsband der 7. International Conference on Language Resources and Evaluation, S. 2200-2204
- Backhaus, K., Erichson, B., Plinke, W. und Weiber, R. (2016): „Multivariate Analysemethoden: Eine anwendungsorientierte Einführung“, Band 14, Berlin/Heidelberg: Springer-Verlag
- Bae, Y. und Lee, H. (2012): „Sentiment Analysis of Twitter Audiences: Measuring the Positive or Negative Influence of Popular Twitterers”. *Journal of the American Society for Information Science and Technology*, Band 63, Nr. 12, S. 2521-2535
- Baker, M., Wurgler, J. und Yuan, Y. (2011): „Global, Local, and Contagious Investor Sentiment”. *Journal of Financial Economics*, Band 104, Nr. 2, S. 272-287

- 
- Barbosa, L. und Feng, J. (2010): „Robust Sentiment Detection on Twitter from Biased and Noisy Data”. Tagungsband der 23. International Conference on Computational Linguistics, S. 36-44
- Bartov, E., Faurel, L. und Mohanram, P. S. (2017): „Can Twitter Help Predict Firm-Level Earnings and Stock Returns?" *The Accounting Review*, Band 93, Nr. 3, S. 25-57
- Basiri, M. E., Naghsh-Nilchi, A. R. und Ghasem-Aghaee, N. (2014): “Sentiment Prediction Based on Dempster-Shafer Theory of Evidence”. *Mathematical Problems in Engineering*, Band 2014, S. 1-14
- Behrens, H. (2013): „Sprachwissenschaft: Grammatik-Interaktion-Kognition“. Berlin/Heidelberg: Springer-Verlag
- Bibliographisches Institut GmbH – Dudenverlag. (2016): „Duden | Emo-ti-con | Rechtschreibung, Bedeutung, Definition, Herkunft“. Abgerufen am 19.06.2018 von <http://www.duden.de/rechtschreibung/Emoticon>
- Bird, S. (2006): „NLTK: The Natural Language Toolkit”. Tagungsband der International Conference on Computational Linguistics – Interactive Presentation Sessions, S. 69-72.
- Bishop, C. und Bishop, C. M. (1995): „Neural Networks for Pattern Recognition”. New York: Oxford University Press
- Blankespoor, E., Miller, G. S. und White, H. D. (2013): „The Role of Dissemination in Market Liquidity: Evidence from Firms’ Use of Twitter”. *The Accounting Review*, Band 89, Nr. 1, S. 79-112
- Bollen, J., Mao, H. und Pepe, A. (2011a): „Modeling Public Mood and Emotion: Twitter Sentiment and Socio-Economic Phenomena”. Tagungsband der 2004 International AAAI Conference on Web and Social Media, S. 450-453
- Bollen, J., Mao, H. und Zeng, X. (2011b): „Twitter Mood Predicts the Stock Market”. *Journal of Computational Science*, Band 2, Nr. 1, S. 1-8.
- Brandewinder, M. (2015): „Machine Learning Projects for .NET Developers“. New York: Apress
- Brauch, W., Dreyer, H. J. und Haacke, W. (1995): „Mathematik für Ingenieure“. Stuttgart: Teubner.
- Brenig, W. (2013): „Statistische Theorie der Wärme: Gleichgewichtsphänomene“. Berlin/Heidelberg: Springer-Verlag
- Brigida, M. und Pratt, W. R. (2017): „Fake news“. *The North American Journal of Economics and Finance*, Band 42, S. 564-573



- Declerck, T. und Krieger, H. (2014): „Harmonization of German Lexical Resources for Opinion Mining”. Tagungsband der 2014 Language Resources and Evaluation Conference, S. 3872-3876
- Dempster, A. P. (1967): „Upper and Lower Probabilities Induced by a Multivalued Mapping”. *The Annals of Mathematical Statistics*, Band 38, Nr. 2, S. 325-339
- Denecke, K. (2008): „Using SentiWordNet for Multilingual Sentiment Analysis”. Tagungsband der 24. International Conference on Data Engineering, S. 507-512
- Dennis, A. R. und Yuan, L. I. (2014): „Trading on Twitter: The Financial Information Content of Emotion in Social Media”. Tagungsband der 47. Hawaii International Conference on System Sciences, S. 806-815
- Deutscher Bundestag (2016): „Sachstand – Der Umgang mit Fake-News – Rechtslage und Reformansätze“
- Donahoe, J. W. (1997): „The Necessity of Neural Networks”. In: Donahoe, J. W. und Dorsel, V. P.: *Advances in Psychology: Neural Network Models of Cognition: Biobehavioral Foundations*, Band 121, S. 1-19, Elsevier
- Dunn, G. und Everitt, B. S. (2004): „An Introduction to Mathematical Taxonomy”. Mineola: Dover Publications
- Dunne, R. A. (2007): „A Statistical Approach to Neural Networks for Pattern Recognition”. Hoboken: John Wiley & Sons
- Elliott, A. C. und Woodward, W. A. (2007): „Statistical Analysis Quick Reference Guidebook: With SPSS examples”. Thousand Oaks: Sage
- English, T. und Carstensen, L. L. (2015): „Does Positivity Operate When the Stakes Are High? Health Status and Decision Making Among Older Adults”. *Psychology and Aging*, Band 30, Nr. 2, S. 348-355
- Fama, E. (1970): „Efficient Capital Markets: A Review of Theory and Empirical Work”. *The Journal of Finance*, Band 25, Nr. 2, S. 383-417
- Fausett, L. V. (1994): „Fundamentals of Neural Networks: Architectures, Algorithms, and Applications”. Upper Saddle River: Prentice-Hall
- Figueira, Á. und Oliveira, L. (2017): „The Current State of Fake News: Challenges and Opportunities”. *Procedia Computer Science*, Band 121, S. 817-825
- Fromm, S. (2010): „Datenanalyse mit SPSS für Fortgeschrittene 2: Multivariate Verfahren für Querschnittsdaten“, Wiesbaden: Springer VS

- Füss, R. und Bechtel, M. M. (2007): „Partisan Politics and Stock Market Performance: The Effect of Expected Government Partisanship on Stock Returns in the 2002 German Federal Election”. *Public Choice*, Band 135, Nr. 3-4, S. 131-150
- Gahirwal, M., Moghe, S., Kulkarni, T., Khakhar, D. und Bhatia, J. (2018): „Fake News Detection”. *International Journal of Advance Research, Ideas and Innovations in Technology*, Band 4, Nr. 1, S. 817-819
- Gerdes, I., Klawonn, F. und Kruse, R. (2004): „Evolutionäre Algorithmen: Genetische Algorithmen-Strategien und Optimierungsverfahren-Beispielanwendungen“. Wiesbaden: Vieweg
- Gilbert, E. und Karahalios, K. (2010): „Widespread Worry and the Stock Market”. Tagungsband der 4. International AAAI Conference on Weblogs and Social Media, S. 58-65
- Go, A., Bhayani, R. und Huang, L. (2009): „Twitter Sentiment Classification using Distant Supervision”. *CS224N Project Report*, Stanford, Band 1, Nr. 12, S. 1-6
- Godbole, N., Srinivasaiah, M. und Skiena, S. (2007): „Large-Scale Sentiment Analysis for News and Blogs”. Tagungsband der 2007 Conference on Weblogs and Social Media, Band 7, S. 219-222
- Granger, C. W. J. (1969): „Investigating Causal Relations by Econometric Models and Cross-Spectral Methods”. *Econometrica: Journal of the Econometric Society*, S. 424-438
- Graves, A. (2012): „Supervised Sequence Labelling with Recurrent Neural Networks”. Berlin/Heidelberg: Springer-Verlag
- Gundecha, P. und Liu, H. (2012): „Mining Social Media: A brief Introduction”. *Tutorials in Operations Research*, Band 1, Nr. 4, S. 1-17
- Hafezi, R., Shahrabi, J. und Hadavandi, E. (2015): „A Bat-Neural Network Multi-Agent System (BNNMAS) for Stock Price Prediction: Case Study of DAX Stock Price”. *Applied Soft Computing*, Band 29, S. 196-210
- Hájek, P., Olej, V., Mysková, R. (2013): „Forecasting Stock Prices using Sentiment Information in Annual Reports – A Neural Network and Support Vector Regression Approach”. Tagungsband der WSEAS Transactions on Business and Economics, Band 10, Nr. 4, S. 293-305
- Han, B. und Baldwin, T. (2011): „Lexical Normalisation of Short Text Messages: Mkn Sens a #Twitter”. Tagungsband des 49. Annual Meeting of the Association for Computational Linguistics: Human Language Technologies, Band 1, S. 368-378
- Hanke-Bourgeois, M. (2002): „Grundlagen der Numerischen Mathematik und des Wissenschaftlichen Rechnens“. Stuttgart: Teubner

- Hawley, D. D., Johnson, J. D. und Raina, D. (1990): „Artificial Neural Systems: A New Tool for Financial Decision-Making”. *Financial Analysts Journal*, Band 46, Nr. 6, S. 63-72
- Hinton, G. E. und Salakhutdinov, R. R. (2006): „Reducing the Dimensionality of Data with Neural Networks”. *Science*, Band 313, Nr. 5786, S. 504-507
- Hirshleifer, D. und Shumway, T. (2003): „Good Day Sunshine: Stock Returns and the Weather”. *Journal of Finance*, Band 58, Nr. 3, S. 1009-1032
- Hockey, G. R. J., John Maule, A., Clough, P. J. und Bdzola, L. (2000): „Effects of Negative Mood States on Risk in Everyday Decision Making”. *Cognition & Emotion*, Band 14, Nr. 6, S. 823-855
- Holland, J. H. (1992): “Complex Adaptive Systems”. *Daedalus*, Band 121, Nr. 1, S. 17-30
- Hu, M. und Liu, B. (2004): „Mining Opinion Features in Customer Reviews”. Tagungsband der National Conference on Artificial Intelligence, Band 4, Nr. 4, S. 755-760
- Ihara, S. (1993): „Information Theory for Continuous Systems”, Band 2, Singapur: World Scientific
- Inoue, A. und Kilian, L. (2004): „In-Sample or Out-of-Sample Tests of Predictability: Which One Should We Use?”. *Econometric Reviews*, Band 23, Nr. 4, S. 371-402
- Jabreel, M., Hassan, F., Moreno, A. (2018): „Target-Dependent Sentiment Analysis of Tweets Using Bidirectional Gated Recurrent Neural Networks”. In: Hatzilygeroudis, I. und Palade, V.: *Advances in Hybridization of Intelligent Methods*, Cham: Springer International Publishing
- Jain, T. I. und Nemade, D. (2010): „Recognizing Contextual Polarity in Phrase-Level Sentiment Analysis”. *International Journal of Computer Applications*. Band 7, Nr. 5, S. 12-21
- James, G., Witten, D., Hastie, T. und Tibshirani, R. (2013): „An Introduction to Statistical Learning. New York: Springer Science+Business Media
- Joachims, T. (2002): „Learning to Classify Text Using Support Vector Machines: Methods, Theory and Algorithms”. New York: Springer Science+Business Media
- Kapur, J. N. (1989): „Maximum Entropy Models in Science and Engineering”. Daryaganj: Wiley Eastern Limited
- Karabulut, Y. (2013): „Can Facebook Predict Stock Market Activity?” SSRN eLibrary, S. 1-58
- Kim, S.-M. und Hovy, E. (2004): „Determining the Sentiment of Opinions”. Präsentiert auf der 20. International Conference on Computational Linguistics, Artikel Nr. 1367, S-1-8
- Kirchgässner, G. und Wolters, J. (2006): „Einführung in die moderne Zeitreihenanalyse“. München Verlag Franz Vahlen

- 
- Koenker, R., P. Ng und S. Portnoy, (1994): „Quantile Smoothing Splines“. *Biometrika*, Band 81, S. 673-680
- Koenker, R. und Mizera, I. (2004): „Penalized Triograms: Total Variation Regularization for Bivariate Smoothing“. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, Band 66, Nr. 1, S. 145-163
- Kouloumpis, E., Wilson, T. und Moore, J. (2011): „Twitter Sentiment Analysis: The Good the Bad and the OMG!“. Tagungsband der 5. International AAAI Conference on Weblogs and Social Media, 2011, S. 538-541
- Krämer, W. und Runde, R. (1997): „Stocks and the Weather: An Exercise in Data Mining or yet another Capital Market Anomaly?“ *Empirical Economics*, Band 22, Nr. 4, S. 637-641
- Kruse, R., Borgelt, C., Klawonn, F., Moewes, C., Ruß, G. und Steinbrecher, M. (2011): „Computational Intelligence: Eine methodische Einführung in Künstliche Neuronale Netze. Evolutionäre Algorithmen, Fuzzy-Systeme und Bayes-Netze“. Wiesbaden: Springer Vieweg
- Krzanowski, W. J. und Hand, D. J. (2009): „ROC Curves for Continuous Data“. Boca Raton: CRC Press
- Kwak, H., Lee, C., Park, H. und Moon, S. (2010). „What is Twitter, a Social Network or a News Media?“. Tagungsband der 19. International Conference on World Wide Web, S. 591-600
- Lansing, J. S. (2003): „Complex Adaptive Systems“. *Annual Review of Anthropology*, Band 32, Nr. 1, S. 183-204
- Larsson, A. O. und Moe, H. (2012): „Studying Political Microblogging: Twitter Users in the 2010 Swedish Election Campaign“. *New Media & Society*, Band 14, Nr. 5, S. 729-747
- Lee, T. H., White, H., & Granger, C. W. (1993): „Testing for Neglected Nonlinearity in Time Series Models: A Comparison of Neural Network Methods and Alternative Tests.“ *Journal of Econometrics*, Band 56, Nr. 3, S. 269-290
- Looney, S. W. und Hagan, J. L. (2015): „Analysis of Biomarker Data: A Practical Guide“. Hoboken: John Wiley & Sons
- Lugmayr, A. (2013): „Predicting the Future of Investor Sentiment with Social Media in Stock Exchange Investments: A Basic Framework for the DAX“. In Friedrichsen, M.: *Handbook of Social Media Management: Value Chain and Business Models in Changing Media Markets*, S. 565-589, Berlin/Heidelberg: Springer-Verlag
- Lugmayr, A. und Gossen, G. (2013): „Evaluation of Methods and Techniques for Language Based Sentiment Analysis for DAX 30 Stock Exchange – A First Concept of a ‘LUGO’

- Sentiment Indicator". Tagungsband des 5. International Workshop on Semantic Ambient Media Experience, 2012, S. 69-76
- Luo, X., Zhang, J. und Duan, W. (2013): „Social Media and Firm Equity Value". *Information Systems Research*, Band 41, Nr. 1, S. 146-163
- Lux, T. (2011): „Sentiment dynamics and Stock Returns: The Case of the German Stock Market". *Empirical Economics*, Band 41, Nr. 3, S. 663-679
- Makice, K. (2009): „Twitter API: Up and Running: Learn How to Build Applications with the Twitter API". Sebastopol: O'Reilly Media
- Martínez-Cámara, E., Teresa Martín-Valdivia, M., Alfonso Ureña-López, L. und Rtuero Montejó-Ráez, A. (2014): „Sentiment Analysis in Twitter". *Natural Language Engineering*, Band 20, Nr. 1, S. 1-28
- Matignon, R. (2005): „Neural Network Modeling Using SAS Enterprise Miner". Bloomington: AuthorHouse
- Mauboussin, M. J. (2002): „Revisiting Market Efficiency: The Stock Market as a Complex Adaptive System". *Journal of Applied Corporate Finance*, Band 14, Nr. 4, S. 8-16
- Medsker, L. und Jain, L. C. (Hrsg.). (1999): „Recurrent Neural Networks: Design and Applications". Boca Raton: CRC press
- Meeder, B., Tam, J., Kelly, P. G. und Cranor, L. F. (2010): „RT @IWantPrivacy: Widespread Violation of Privacy Settings in the Twitter Social Network". *Web 2.0 Security and Privacy*, Band 2, S. 1-12
- Menshawy, A. (2018): „Deep Learning by Example: A Hands-On Guide to Implementing Advanced Machine Learning Algorithms and Neural Networks". Birmingham: Packt Publishing
- Miller, G. a. (1995): „WordNet: A Lexical Database for English". *Communications of the Association of Computing Machinery*, Band 38, Nr. 11, S. 39-41
- Mishne, G. und Glance, N. (2006): „Predicting Movie Sales from Blogger Sentiment". Tagungsband des Association for the Advancement of Artificial Intelligence Spring Symposium: Computational Approaches to Analyzing Weblogs, S. 155-158
- Nagar, A. und Hahsler, M. (2012): „Using Text and Data Mining Techniques to extract Stock Market Sentiment from Live News Streams". Tagungsband der 2012 International Conference on Computer Technology and Science, Band 47, S. 91-95
- Nakov, P., Ritter, A., Rosenthal, S., Stoyanov, V. und Sebastiani, F. (2016): „SemEval-2016 Task 4: Sentiment Analysis in Twitter". Tagungsband des 10. International Workshop on Semantic Evaluation, S. 1-18

- 
- Nann, S., Krauss, J. und Schoder, D. (2013): „Predictive Analytics on Public Data – the Case of Stock Markets”. Präsentiert auf der 21. European Conference on Information Systems, Artikel Nr. 116, S. 1-12
- Nassirtoussi, A. K., Aghabozorgi, S., Wah, T. Y. und Ngo, D. C. L. (2014): „Text Mining for Market Prediction: A Systematic Review”. *Expert Systems with Applications*, Band 41, Nr. 16, S. 7653-7670
- Nassirtoussi, A-K., Aghabozorgi, S., Wah, T. Y. und Ngo, D. C. L. (2015): „Text Mining of News-Headlines for FOREX Market Prediction: A Multi-Layer Dimension Reduction Algorithm with Semantics and Sentiment”. *Expert Systems with Applications*, Band 42, Nr. 1, S. 306-324
- Negi, R., Prabhu, V. U. und Rodrigues, M. (2014): „Latent Sentiment Detection in Online Social Networks: A Communications-Oriented View”. Tagungsband der 2014 IEEE International Conference on Communications, S. 3758-3763
- Nofer, M. (2015): „Using Twitter to Predict the Stock Market: Where is the Mood Effect?” In: *The Value of Social Media for Predicting Stock Returns: Preconditions, Instruments and Performance Analysis*, S. 63-88. Wiesbaden: Springer Vieweg
- Nofer, M. und Hinz, O. (2014): „Are Crowds on the Internet Wiser than Experts? The Case of a Stock Prediction Community”. *Journal of Business Economics*, Band 84, Nr. 3, S. 303-338
- Nofsinger, J. R. (2005): „Social Mood and Financial Economics”. *Journal of Behavioral Finance*, Band 6, Nr. 3, S. 144-160
- O’Connor, B., Balasubramanyan, R., Routledge, B. R. und Smith, N. a. (2010): „From Tweets to Polls: Linking Text Sentiment to Public Opinion Time Series”. Tagungsband der International AAAI Conference on Web and Social Media, S. 122-129
- Oh, C. und Sheng, O. (2011): „Investigating Predictive Power of Stock Micro Blog Sentiment in Forecasting Future Stock Price Directional Movement”. Tagungsband der 2011 International Conference on Information Systems, S. 1-19
- Oliveira, N., Cortez, P. und Areal, N. (2013): „Some Experiments on Modeling Stock Market Behavior Using Investor Sentiment Analysis and Posting Volume from Twitter”. Präsentiert auf der 3. International Conference on Web Intelligence, Mining and Semantics, Artikel Nr. 31, S. 1-8
- Pak, A. und Paroubek, P. (2010): „Twitter as a Corpus for Sentiment Analysis and Opinion Mining”. Tagungsband der 2010 Language Resources and Evaluation Conference, S. 1320-1326

- 
- Pang, B., Lee, L. und Vaithyanathan, S. (2002): „Thumbs up? Sentiment Classification Using Machine Learning Techniques”. Tagungsband der Conference on Empirical Methods in Natural Language Processing, S. 79-86
- Pennacchiotti, M. und Popescu, A. M. (2011): „A Machine Learning Approach to Twitter User Classification”. Tagungsband der 5. International Conference on Web and Social Media. Band 11, Nr. 1, S. 281-288
- Phillips, S. J., Anderson, R. P. und Schapire, R. E. (2006): „Maximum Entropy Modeling of Species Geographic Distributions”. *Ecological Modelling*, Band 190, Nr.3-4, S. 231-259.
- Ponce-Cruz, P. und Ramírez-Figueroa, F. D. (2009): „Intelligent Control Systems with LabVIEW™”. Springer-Verlag London
- Potts, C. (2011): „On the Negativity of Negation \*”. *Semantics and Linguistic Theory*, Band 20, S. 636-659
- Prechter, R. R., Goel, D., Parker, W. D. und Lampert, M. (2012): „Social Mood, Stock Market Performance and U.S. Presidential Elections: A Socionomic Perspective on Voting Results”. *SAGE Open*, Band 2, Nr. 4, S. 1-13
- Qian, B. und Rasheed, K. (2007): „Stock Market Prediction with Multiple Classifiers”. *Applied Intelligence*, Band 26, Nr. 1, S. 25-33
- Raabe, D., Roters, F., Barlat, F. und Chen, L. Q. (2006): „Continuum Scale Simulation of Engineering Materials: Fundamentals-Microstructures-Process Applications”. Weinheim: Wiley-VCH Verlag
- Rajadesingan, A., Zafarani, R. und Liu, H. (2015): „Sarcasm Detection on Twitter: A Behavioral Modeling Approach”. Tagungsband der 8. Association for Computing Machinery International Conference on Web Search and Data Mining, S. 97-106
- Ranco, G., Aleksovski, D., Caldarelli, G., Grcar, M. und Mozetic, I. (2015): „The Effects of Twitter Sentiment on Stock Price Returns”. *PLoS ONE*, Band 10, Nr. 9, S. 1-27
- Rao, T. und Srivastava, S. (2012): „Analyzing Stock Market Movements Using Twitter Sentiment Analysis”. Tagungsband der 2012 International Conference on Advances in Social Networks Analysis and Mining, S. 119-123
- Rapach, D. E. und Wohar, M. E. (2006): „In-Sample vs. Out-of-Sample Tests of Stock Return Predictability in the Context of Data Mining”. *Journal of Empirical Finance*, Band 13, Nr. 2, S. 231-247
- Reese, R. M. (2015): „Natural Language Processing with Java”. Birmingham: Packt Publishing

- Reinel, D. (2013). „Evaluation der Qualität lexikalischer Ressourcen zur Stimmungserkennung in literarischen Texten“. Tagungsband der Konferenz Lernen-Wissen-Adaption, S. 168-172
- Remus, R., Ahmad, K. und Heyer, G. (2009): „Sentiment in German-Language News and Blogs, and the DAX“. Tagungsband der Conference on Text Mining Services, S. 149-158
- Remus, R., Quasthoff, U. und Heyer, G. (2010): „SentiWS – a Publicly Available German-language Resource for Sentiment Analysis“. Tagungsband der 7. International Conference on Language Resources and Evaluation, S. 1168-1171
- Remus, R., Quasthoff, U. und Heyer, G. (2018): „SentiWS“. Abgerufen am 03.06.2018, von <http://wortschatz.uni-leipzig.de/de/download>
- Reuter, C. und Schröter, J. (2015): „Microblogging during the European Floods 2013: What Twitter May Contribute in German Emergencies“. *International Journal of Information Systems for Crisis Response and Management*, Band 7, Nr. 1, S. 22-41
- Rojas, R. (2013): „Neural Networks: A Systematic Introduction“. Berlin/Heidelberg: Springer-Verlag
- Rosenblatt, F. (1958): „The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain“. *Psychological Review*, Band 65, Nr. 6, S. 386-408.
- Runkler, T. A. (2015): „Data Mining: Methoden und Algorithmen intelligenter Datenanalyse“. Wiesbaden: Springer Vieweg
- Ruppenhofer, J., Struß, J. M., Sonntag, J. und Gindl, S. (2014): „IGGSA-STEPS: Shared Task on Source and Target Extraction from Political Speeches“. *Journal of Language Technology and Computational Linguistics*, Band 29, Nr. 1, S. 33-46
- Santa-Clara, P. und Valkanov, R. (2003): „The Presidential Puzzle: Political Cycles and the Stock Market“. *The Journal of Finance*, Band 58, Nr. 5, S. 1841-1872
- Scheufele, B. und Haas, A. (2008): „Medien und Aktien: Theoretische und empirische Modellierung der Rolle der Berichterstattung für das Börsengeschehen“. Wiesbaden: VS Verlag
- Schmidt, J., Klüver, C. und Klüver, J. (2010): „Programmierung naturanaloger Verfahren“. Wiesbaden: Vieweg+Teubner Verlag
- Schniederjans, D., Cao, E. S. und Schniederjans, M. (2013): „Enhancing Financial Performance with Social Media: An Impression Management Perspective“. *Decision Support Systems*, Band 55, Nr. 4, S. 911-918
- Segaran, T. (2007): „Programming Collective Intelligence: Building Smart Web 2.0 Applications“. Sebastopol: O'Reilly Media

- Sewak, M., Karim, M. R. und Pujari, P. (2018): „Practical Convolutional Neural Networks: Implement Advanced Deep Learning Models using Python”. Birmingham: Packt Publishing
- Shafer, G. (1976): „A Mathematical Theory of Evidence”. Princeton/London: Princeton University Press
- Shariff, S. M., Zhang, X. und Sanderson, M. (2017): „On the Credibility Perception of News on Twitter: Readers, Topics and Features”. *Computers in Human Behavior*, Band 75, S. 785-796
- Si, J., Mukherjee, A., Liu, B., Pan, S. J. S., Li, Q. und Li, H. (2014): „Exploiting Social Relations and Sentiment for Stock Prediction”. Tagungsband der 2014 Conference on Empirical Methods in Natural Language Processing, S. 1139-1145
- Sivanandam, S. N. und Deepa, S. N. (2006): „Introduction to Neural Networks Using Matlab 6.0”. Neu-Delhi: Tata McGraw-Hill Education
- Smailović, J., Grčar, M., Žnidaršič, M. und Lavrač, N. (2012): „Sentiment Analysis on Tweets in a Financial Domain”. Tagungsband der 4. Jožef Stefan International Postgraduate School Students Conference, Band 1, S. 169-175
- Smailović, J., Grčar, M., Lavrač, N. und Žnidaršič, M. (2014). “Stream-Based Active Learning for Sentiment Analysis in the Financial Domain. *Information Sciences*, Band 285, S. 181-203
- Sprenger, T. und Welp, I. (2010): „Tweets and Trades – the Information Content of Stock Microblogs”. *European Financial Management*, Band 20, Nr. 5, S. 926-957
- Sriram, B., Fuhry, D., Demir, E., Ferhatosmanoglu, H. und Demirbas, M. (2010): „Short Text Classification in Twitter to Improve Information Filtering”. Tagungsband der 33. International Conference on Research and Development in Information Retrieval, ACM, S. 841-842
- Stambaugh, R. F., Yu, J. und Yuan, Y. (2012): „The short of it: Investor sentiment and anomalies”. *Journal of Financial Economics*, Band 104, Nr. 2, S. 288-302
- Statista GmbH. (2015): „Soziale Netzwerke in Deutschland nach Anzahl der Visits im Dezember 2014 (in Millionen)“. Abgerufen am 12.11.2015 von <http://de.statista.com/statistik/daten/studie/70232/umfrage/soziale-netzwerke---nutzer-pro-monat/>
- Statista GmbH. (2018): „Anzahl der monatlich aktiven Nutzer von Twitter weltweit vom 1. Quartal 2010 bis zum 1. Quartal 2018 (in Millionen)“. Abgerufen am 26.05.2015 von <https://de.statista.com/statistik/daten/studie/232401/umfrage/monatlich-aktive-nutzer-von-twitter-weltweit-zeitreihe/>

- Stevenson, R. T. (2001): „The Economy and Policy Mood: A Fundamental Dynamic of Democratic Politics?” *American Journal of Political Science*, Band 45, Nr. 3, S. 620-633.
- Swingler, K. (1996): „Applying Neural Networks: A Practical Guide”. San Francisco: Morgan Kaufmann Publishers
- Taddy, M. (2013): „Measuring Political Sentiment on Twitter: Factor Optimal Design for Multinomial Inverse Regression”. *Technometrics*, Band 55, Nr. 4, S. 415-425
- Tetlock, P. C. (2007): „Giving Content to Investor Sentiment: The Role of Media in the Stock Market”. *Journal of Finance*, Band 62, Nr. 3, S. 1139-1168
- Tumasjan, A., Sprenger, T., Sandner, P. und Welpe, I. (2010): „Predicting Elections with Twitter: What 140 Characters Reveal about Political Sentiment”. Tagungsband der 4. International AAI Conference on Weblogs and Social Media, S. 178-185
- Turney, P. D. (2002): „Thumbs up or Thumbs down? Semantic Orientation applied to Unsupervised Classification of Reviews”. Tagungsband des 40. Annual Meeting of the Association for Computational Linguistics, S. 417-424
- Tversky, A. und Kahneman, D. (1991): „Loss Aversion in Riskless Choice: A Reference-Dependent Model”. *The Quarterly Journal of Economics*, S. 1039-1061
- Twitter Inc. (2016a): „Häufig gestellte Fragen zum Following | Twitter Hilfe-Center“. Abgerufen am 10.06.2016 von <https://support.twitter.com/articles/336102>
- Twitter Inc. (2016b): „Retweeten eines Tweets | Twitter Hilfe-Center“. Abgerufen am 10.06.2016 von <https://support.twitter.com/articles/20170060>
- Twitter Inc. (2016c): „Tweets | Twitter Developers”. Abgerufen am 19.06.2016 von <https://dev.twitter.com/overview/api/tweets>
- Twitter Inc. (2016d): „Was sind Hashtags (# Symbole)? | Twitter Hilfe-Center“. Abgerufen am 10.06.2016, von <https://support.twitter.com/articles/314917>
- Udani, G. (2012): „An Exhaustive Study of Twitter Users across the World – Social Media Analytics | Beevolve”. Abgerufen am 09.06.2018 von <http://www.beevolve.com/twitter-statistics/#c1>
- Vincent, A. und Armstrong, M. (2010): „Predicting Break-Points in Trading Strategies with Twitter”. *SSRN Electronic Journal*, S. 1-11
- Vö, M. L. H., Jacobs, A. M. und Conrad, M. (2006): „Cross-validating the Berlin Affective Word List”. *Behavior Research Methods*, Band 38, Nr. 4, S. 606-609
- Volna, E., Kotyrba, M. und Janosek, M. (2016): „Pattern Recognition and Classification in Time Series Data”. Hershey: IGI Global

- Waltinger, U. (2010): „GermanPolarityClues: A Lexical Resource for German Sentiment Analysis”. Tagungsband der Language Resources and Evaluation Conference, S. 1638-1642
- Watkins, B. (2003): „Riding the Wave of Sentiment: An Analysis of Return Consistency as a Predictor of Future Returns”. *Journal of Behavioral Finance*, Band 4, Nr. 4, S. 191-200
- Wisniewski, T. P. (2016): „Is there a Link between Politics and Stock Returns? A Literature Survey.” *International Review of Financial Analysis*, Band 47, S. 15-23
- Wu, D. D., Zheng, L. und Olson, D. L. (2014): „A Decision Support Approach for Online Stock Forum Sentiment Analysis”. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, Band 44, Nr. 8, S. 1077-1087
- Xia, X., Yang, X., Wu, C., Li, S. und Bao, L. (2012): „Information Credibility on Twitter”. Tagungsband der 20. International Conference on World Wide Web, ACM, S. 675-684
- Xie, B., Passonneau, R. J. und Wu, L. (2013): „Semantic Frames to Predict Stock Price Movement”. Tagungsband des 51. Annual Meeting of the Association for Computational Linguistics, S. 873-883
- Xu, E., Wynne, H., Mong, L. L. und Patel, D. (2014): "Inferring Topic-Level Influence from Network Data". In: Decker, H., Lhotská, L., Link, S., Spies, M., & Wagher, R. R.: Database and Expert Systems Applications: Tagungsband der 25. International Conference, DEXA 2014, München, Deutschland, Teil 2, Cham: Springer International Publishing
- Yamaguchi, Y., Takahashi, T., Amagasa, T. und Kitagawa, H. (2010): „TURank: Twitter User Ranking Based on User-Tweet Graph Analysis.” Tagungsband der 11. International Conference on Web Information Systems Engineering, S. 240-253
- Yu, Y., Duan, W. und Cao, Q. (2013): „The Impact of Social and Conventional Media on Firm Equity Value: A Sentiment Analysis Approach”. *Decision Support Systems*, Band 55, Nr. 4, S. 919-926
- Zhang, G. P. (2004): „Neural Networks in Business Forecasting”. Hershey: IRM Press
- Zhang, X., Fuehres, H. und Gloor, P. a. (2011a): „Predicting Stock Market Indicators through Twitter ‘I hope it is not as bad as I fear’”. *Procedia – Social and Behavioral Sciences*, Band 26, S. 55-62
- Zhang, L., Ghosh, R., Dekhil, M., Hsu, M. und Liu, B. (2011b): „Combining Lexicon-based and Learning-based Methods for Twitter Sentiment Analysis”, S. 1-8
- Zhang, Y. und Zhang, D. (2014): „Automatically Predicting the Helpfulness of Online Reviews”. Tagungsband der 15. International Conference on Information Reuse and Integration 2014, S. 662-668

Zinsmeister, H. und Lemnitzer, L. (2006): „Korpuslinguistik: Eine Einführung“. Tübingen:  
Narr Francke Attempto Verlag

## Anhangsverzeichnis

Tabelle A: Zusammenfassung relevanter Arbeiten zur Stimmungsanalyse.....	91
Tabelle B: Zusammenfassung der Vorhersagemodelle.....	97
Tabelle C: Korrelation DAX und deutsche DAX-Stimmung .....	98
Tabelle D: Korrelation DAX und deutsche Wirtschaftsstimmung .....	99
Tabelle E: Korrelation DAX und deutsche Politikstimmung.....	100
Tabelle F: Korrelation DAX und englische DAX-Stimmung.....	101
Tabelle G: Korrelation deutsche DAX- und Wirtschaftsstimmung .....	102
Tabelle H: Korrelation deutsche DAX- und Politikstimmung.....	103
Tabelle I: Korrelation deutsche Wirtschafts- und Politikstimmung.....	104
Tabelle J: Korrelation englische und deutsche DAX-Stimmung.....	105
Tabelle K: Korrelation englische DAX- und deutsche Wirtschaftsstimmung .....	106
Tabelle L: Korrelation englische DAX- und deutsche Politikstimmung .....	107
Tabelle M: Deutsche Nutzer mit den meisten Abonnenten .....	108
Tabelle N: Korrelation DAX und deutsche DAX-Nutzer mit höchster Aktivität.....	109
Tabelle O: Korrelation DAX und deutsche Wirtschafts-Nutzer mit höchster Aktivität .	110
Tabelle P: Korrelation DAX und deutsche Politik-Nutzer mit höchster Aktivität.....	111
Tabelle Q: Korrelation DAX und englische DAX-Nutzer mit höchster Aktivität.....	112
Tabelle R: Signifikante Korrelationen DAX und deutsche Nutzerstimmungen .....	113
Tabelle S: Wichtigkeiten der Nutzer für die Vorhersage .....	116

Tabelle A: Zusammenfassung relevanter Arbeiten zur Stimmungsanalyse

Autor (Jahr)	Inhalt	Software <i>Korpus</i>	Sprache	Statistisches Metho- den	Medium	Variablen	Ergebnis
Asur et al. (2010)	Training einer Klassifikation durch Auslagerung der manuellen Stimmungsbestimmung an Nutzer über das Internet	LingPipe, Dynamic Language Model Classifier	Englisch	Vorkommenshäufigkeit-inverse Dokumenthäufigkeit-Maß, logistische Regression	Twitter	Filmverkäufe	Themenspezifische Stimmungsextraktion von Twitter verbessert die Vorhersage sozialer Median
Baccianella et al. (2010)	Lexikonerstellung	<i>SentiWordNet 3.0</i>	Englisch	Klassifikation durch Menschen, Zufallsbewegung			Stimmungslexika, bei denen die Stimmungen der Worte menschlich bestimmt wurden, sind genauer als rein maschinelle bestimmte Stimmungen
Basiri et al. (2014)	Erstellung eines Bewertungssystems	<i>SentiStrength</i>	Englisch	Adaptives Boosting, Bayessches Netz, Entscheidungsbäume (J48 Klassifikation), K-Star, Bayes-Klassifikation, Stützvektormaschine, Evidenztheorie	CitySearch, TripAdvisor		Evidenztheorie ist anderen Aggregationsmechanismen wie Zufall, Durchschnitt der Ähnlichkeitsbewertung, Summe der Maxima, Maximum der Bewertung überlegen
Bird (2006)	Entwicklungsumgebung in Python	Natural Language Toolkit	Englisch	Zerteilen und Segmentieren von Texten			Entwicklung eines freien Programms zur Sprachanalyse
Bollen et al. (2011b)	Zusammenhangsanalyse	OpinionFinder, Google Profile of Mood States, <i>Multi-Perspective Question Answering, Profile of Mood States Bipolar Scale</i>	Englisch	Granger-Kausalität, Selbstorganisierende Neuronale Netze	Twitter	Dow Jones Industrial Average	Vorhersage des Aktienindex durch Stimmungsanalyse verbessert

Autor (Jahr)	Inhalt	Software <i>Korpus</i>	Sprache	Statistisches Metho- den	Medium	Variablen	Ergebnis
Clematide et al. (2012)	Lexikonerstellung	<i>Multi-layered Reference Corpus for German Sentiment Analysis</i>	Deutsch				Multi-Layer Korpus verbessert Vergleichbarkeit und Reproduzierbarkeit von Stimmungsanalysen
Das et al. (2007)	Klassifizierung		Englisch	Bayes-Klassifikation, Korrelation	Stimmungen aus Aktien-Nachrichten-Boards	Morgan Stanley High-Tech Index	Zusammenhang von Stimmungen aus Börsen-Boards mit Aktien
Gilbert et al. (2010)	Stimmungsextraktion		Englisch	Granger-Kausalität, Monte-Carlo-Simulation	Emotionen des weblogs LiveJournal	Standard & Poor's 500	Angst hängt negativ mit Standard & Poor's 500 zusammen
Hirshleifer et al. (2003)	Zusammenhangsanalyse		Englisch	Regression, Korrelation	Wetterdaten	Aktienrenditen	Sonnenschein korreliert mit Aktienrenditen
Jain et al. (2010)	Kontextuale Stimmungsanalyse, Klassifikation	<i>Multi-Perspective Question Answering Opinion Corpus</i>	Englisch	Maschinelles Lernen			Entwicklung kontextualer Analyse
Karabulut (2013)	Zusammenhangsanalyse		Englisch	Regression	Facebook	Aktien, Bruttonationalglück	Standardabweichung des Bruttonationalglücks hängt mit Renditen zusammen
Lux (2011)	Fragebogen	animusX-Investors sentiment	Deutsch	Vektorautoregressive Modelle	Investorenstimmung	Deutscher Aktienindex	Handelsstrategien, basierend auf vektorautoregressiven Modellen verbessern Kaufen- oder Halten-Bezugswerte
Miller (1995)	Lexikonerstellung	<i>WordNet</i>	Englisch				Entwicklung einer lexikalischen Datenbank
Mishne et al. (2006)	Stimmung und Filmein-nahmen		Englisch	Pearson Korrelation	BlogPulse.com, Verweise auf Filme in Weblogs	Filmverkäufe	Verbesserung der Vorhersage durch Kontextlimitierung
Nagar et al. (2011)	Zusammenhangsanalyse	tm.plugin.webmining <i>Multi-Perspective Question Answering Subjectivity Lexicon</i>	Englisch		Bloomberg	Apple Nachrichten, Apple Aktienkurs	Zusammengang von NewsSentiment mit Aktienkursen

Autor (Jahr)	Inhalt	Software <i>Korpus</i>	Sprache	Statistisches Metho- den	Medium	Variablen	Ergebnis
Nann et al. (2013)	Stimmungsanalyse		Englisch	Bildung von Quotienten	Twitter	Standard & Poor's 500, Unternehmens-Nachrichten	Entwicklung eines Stimmungsbasierten Handelsmodells
Nassirtoussi et al. (2015)	Zusammenhangsanalyse	<i>SentiWordNet</i>	Englisch	Vorkommenshäufigkeit-inverse Dokumenthäufigkeit-Maß, maschinelles Lernen	Finanznachricht-Schlagzeilen	Devisenmarkt	Verbesserung der Zusammenhangsanalyse zwischen Nachrichten und dem Devisenmarkt
Nofer (2015)	Depressive Stimmungs-Zustände		Deutsch	Vektorautoregressive Modelle, Granger Kausalität, Regression	Twitter	Aktien	
O'Connor et al. (2010)	Zusammenhangsanalyse	<i>OpinionFinder, Multi-Perspective Question Answering</i>	Englisch	Korrelation	Twitter	Verbrauchervertrauen, Präsidentschaftswahlen	Zusammenhang von langfristigen Trends zwischen Umfragen und Twitter-Stimmung
Ruppenhofer et al. (2014)	Entwicklung eines Korpus	<i>Multi-layered Reference Corpus for German Sentiment Analysis</i>	Deutsch		Politische Reden		Extraktion von Informationsquelle und Informationsziel
Oh et al. (2011)	Klassifizierung		Englisch	Gewichtete F-Statistik	Nachrichten auf stocktwits.com	Aktien	Diskussionen über Aktien haben Vorhersagekraft bei Aktien
Pak et al. (2010)	Linguistische Analyse, hand-kommentiertes Training		Englisch	Bayes-Klassifikation, Shannon Entropie	Twitter		Methode zur automatisierten Korpus-sammlung um damit Stimmungs-Klassifikation zu trainieren
Pang et al. (2002)	Stimmungsklassifizierung auf Dokumentenebene		Englisch	Bayes-Klassifikation, logistische Regression, Stützvektormaschine	Filmkritiken	Filmverkäufe	Methoden des maschinellen Lernens sind denen der traditionellen themenbasierten Klassifizierung unterlegen

Autor (Jahr)	Inhalt	Software <i>Korpus</i>	Sprache	Statistisches Metho- den	Medium	Variablen	Ergebnis
Ranco et al. (2015)	Ereignisstudie, manuelle Klassifizierung von Tweets		Englisch	Stützvektorma- schine, Pearson-Kor- relation, Granger- Kausalität	Twitter-Stimmung	Aktienpreis von -Un- ternehmen aus dem Dow Jones Industrial Average	Stimmungen bei Twit- ter-Spitzen zeigen die Richtung abnormaler Renditen an
Rao et al. (2012)	Zusammenhangsanalyse		Englisch	Korrelation, Gran- ger-Kausalität, au- toregressive Modelle	Twitter, Google	Rohstoffe, Aktien, Suchvolumina	Aktienpreise hängen mit den Stimmungen in kurzfristigen Twit- ter-Diskussionen zu- sammen
Reinel (2013)	Qualität lexikalischer Ressourcen	OpenNLP4 Zerleger, AOpenNLP Wortartenzuordnung, Morphy <i>Tagger 1, Sentiment Phrase List, SentiWS, NRC Emo- tion Lexicon</i>	Deutsch	Cohens Kappa	Märchengeschich- ten		Automatische Klassifi- zierung von Texten hängt mit manuell klassifizierten Texten zusammen
Remus et al. (2009)	Vergleich von Verteilun- gen	<i>SentiWS</i>	Deutsch	Deskriptive Statistik mit Mittelwert, Stan- dardabweichung, Schiefe und Kurtosis	Zeitungsartikel und Blogs	DAX	Serie von affektiven Worten in Zeitungen und Blogs ähneln Fi- nanz-Zeitreihen
Si et al. (2014)	Semantische Aktien- Knoten		Englisch	Vektorautoregres- sive Modelle	Twitter	Aktien	Stimmung über Aktien und verwandten The- men haben Vorhersa- gekraft
Smailović et al. (2012)	Zusammenhangsanalyse		Englisch	Stützvektorma- schine, Granger- Kausalität	Twitter	Apple Aktie	Anzahl und Stimmun- gen von Tweets hän- gen mit dem Apple Aktienkurs zusammen
Smailović et al. (2014)	Zusammenhangsanalyse		Englisch	Stützvektorma- schine, Granger- Kausalität	Twitter	Aktie	Erweiterung der Ein- teilung der Stimmung in die drei Klassen po- sitiv, neutral und nega- tiv verbessert die Vor- hersage im Gegensatz zu den zwei Klassen positiv und negativ.

Autor (Jahr)	Inhalt	Software <i>Korpus</i>	Sprache	Statistisches Metho- den	Medium	Variablen	Ergebnis
Sprenger et al. (2010)	Zusammenhangsanalyse		Englisch	Bayes-Klassifikation, Regression	Twitter	Standard & Poor's 100	Benutzer, die überdurchschnittliche Anzahl von Investitionsratschlägen geben, haben mehr Abonnenten
Taddy (2013)	Zusammenhangsanalyse		Englisch	Inverse Regression	Twitter	Politische Stimmung	Experimentelle Modelle und Variableninteraktion in Verbindung mit Dimensionsreduktion eignen sich zur Textanalyse
Tumasjan et al. (2010)	Wahlvorhersage	Linguistic Inquiry and Word Count	Englisch	Distanzmaß, Mittlerer absoluter Fehler	Twitter	Wahlen	Twitter-Stimmungen reflektieren die reale politische Landschaft
Turney (2002)	Semantische Klassifikation		Englisch	Punktweise gegenseitige Information und Informationsrückgewinnung		Rezensionen, Positiv, Negativ	Algorithmische Klassifikation sollte durch Menschen ergänzt werden
Võ et al. (2006)	Manuelle Bewertung	<i>Berlin Affective Word List</i>	Deutsch	Mittelwert, Regression			Beziehung zwischen emotionaler Bewertungen und Antwortzeit wird durch invertierte U-förmige Funktion beschrieben
Waltinger (2010)	Lexikonerstellung	<i>GermanPolarityClues</i>	Deutsch	Stützvektormaschine	Amazon		Lexikon ist hilfreich zur stimmungsbasierten Merkmalsselektion
Zhang et al. (2011a)	Zusammenhangsanalyse		Englisch	Pearson Korrelation	Twitter	Dow Jones, NASDAQ, Standard & Poor's 500	Besonders emotionale Texte mit Hoffnung, Angst und Sorge hängen negativ mit dem Index zusammen

---

Autor (Jahr)	Inhalt	Software <i>Korpus</i>	Sprache	Statistisches Metho- den	Medium	Variablen	Ergebnis
Zhang et al. (2014)		Waikato Environment for Knowledge Analysis, tm.plugin.sentiment	Englisch	Stützvektormaschine	Amazon	Kundenbewertungen, Nützlichkeit	Reputation des Bewer- tenden ist maßgeblich für die Nützlichkeit

Quelle: Eigene Darstellung

Tabelle B: Zusammenfassung der Vorhersagemodelle

Modell	Stimmungsebene	Sprache(n)	Vorlauf	Variablen	Fehlende Tagesstim-mungen	Berück-sichtigte Variablen	Modellgüte	Kreuzentro-piefehler im Training	Kreuzentro-piefehler im Test
1	Gesamt	deutsch	0	1	0	1	0,529	61,989	21,255
2	Gesamt	deutsch	0-7	8	0	8	0,656	49,451	26,864
3	Gesamt	deutsch und englisch	0	3	311	3	0,595	48,330	14,973
4	Themen	deutsch	0	3	1	3	0,635	54,728	24,462
5	Themen	deutsch und englisch	0	5	312	5	0,676	58,179	20,072
6	Themen	deutsch und englisch	0-7	42	2.496	42	0,723	50,900	16,279
7	Nutzer mit höchster Aktivität	deutsch	0	30	3.730	14	0,625	30,412	13,723
8	Signifikante Nutzer mit höchster Aktivität	deutsch	0	30	3.730	7	0,584	29,054	9,870
9	Signifikante Nutzer mit höchster Aktivität	deutsch und englisch	0	40	5.898	10	0,611	14,011	4,846
10	Signifikante Nutzer mit höchster Aktivität	deutsch und englisch	0	40	5.898	9	0,722	12,854	3,898
11	Alle signifikanten Nutzer	deutsch	0	23	1.151	6	0,660	14,914	5,099
12	Alle signifikanten Nutzer	deutsch	1	15	1.598	2	0,665	18,644	6,573
13	Alle signifikanten Nutzer	deutsch	2	12	1.197	4	0,660	1,981	6,661
14	Alle signifikanten Nutzer	deutsch	3	13	1.122	5	0,673	15,715	4,303
15	Alle signifikanten Nutzer	deutsch	4	19	2.029	3	0,673	18,774	7,278
16	Alle signifikanten Nutzer	deutsch	5	17	1.906	1	0,532	39,619	16,695
17	Alle signifikanten Nutzer	deutsch	6	18	1.598	7	0,800	9,287	2,836
18	Alle signifikanten Nutzer	deutsch	7	25	2.414	6	0,705	10,883	2,198

Quelle: Eigene Darstellung

Tabelle C: Korrelation DAX und deutsche DAX-Stimmung

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1 DAX														
2 Stimmung	0,116													
3 Stimmung <sub>t-1</sub>	0,076	0,067												
4 Stimmung <sub>t-2</sub>	0,026	0,023	0,067											
5 Stimmung <sub>t-3</sub>	-0,073	-0,073	0,023	0,067										
6 Stimmung <sub>t-4</sub>	-0,065	-0,089	-0,073	0,023	0,067									
7 Stimmung <sub>t-5</sub>	-0,004	0,057	-0,089	-0,073	0,023	0,067								
8 Stimmung <sub>t-6</sub>	0,033	0,018	0,057	-0,089	-0,073	0,023	0,067							
9 Stimmung <sub>t-7</sub>	0,085	0,108	0,018	0,057	-0,089	-0,073	0,023	0,067						
10 Tweets	-0,079	0,006	0,134	0,063	0,035	0,021	0,024	-0,005	-0,052					
11 Wörter	-0,006	0	0,135	0,058	0,032	0,017	0,012	-0,016	-0,04	0,992**				
12 Positive Wörter	0,107	-0,025	0,08	0,03	0,082	0,042	0,043	0,005	-0,077	0,906**	0,915**			
13 Negative Wörter	-0,07	-0,084	0,086	0,068	0,012	0,047	0,160*	0,055	-0,016	0,779**	0,777**	0,706**		
14 Rel. positive Wörter	0,216*	0,041	-0,104	-0,034	0,049	0,064	0,091	-0,008	0,027	-0,055	-0,052	0,283**	-0,076	
15 Rel. negative Wörter	-0,131	-0,139	-0,006	-0,048	-0,062	0,041	0,174*	0,076	0,032	-0,026	-0,035	-0,097	0,519**	-0,169*

\*\* . Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* . Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle D: Korrelation DAX und deutsche Wirtschaftsstimung

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1 DAX														
2 Stimmung	-0,02													
3 Stimmung <sub>t-1</sub>	0,003	-0,002												
4 Stimmung <sub>t-2</sub>	0,134	-0,002	-0,002											
5 Stimmung <sub>t-3</sub>	0,135	-0,049	-0,002	-0,002										
6 Stimmung <sub>t-4</sub>	0,05	-0,064	-0,049	-0,002	-0,002									
7 Stimmung <sub>t-5</sub>	-0,023	0,103	-0,064	-0,049	-0,002	-0,002								
8 Stimmung <sub>t-6</sub>	-0,081	-0,018	0,103	-0,064	-0,049	-0,002	-0,002							
9 Stimmung <sub>t-7</sub>	-0,031	-0,04	-0,018	0,103	-0,064	-0,049	-0,002	-0,002						
10 Tweets	-0,372**	0,002	-0,013	0,047	0,103	-0,044	-0,002	-0,056	-0,012					
11 Wörter	-0,404**	0,015	-0,016	0,062	0,083	-0,033	-0,014	-0,062	-0,015	0,990**				
12 Positive Wörter	-0,179*	0,008	-0,06	0,049	0,098	-0,047	0,011	-0,032	-0,008	0,908**	0,898**			
13 Negative Wörter	-0,504**	0,007	0,029	0,006	0,073	0,012	-0,032	-0,022	-0,063	0,884**	0,898**	0,778**		
14 Rel. positive Wörter	0,128	0,079	-0,086	0,015	0,055	-0,006	0,011	0,054	0,014	0,279**	0,254**	0,591**	0,164*	
15 Rel. negative Wörter	-0,452**	-0,023	0,078	-0,111	0,019	0,103	-0,038	0,025	-0,102	0,078	0,098	-0,04	0,435**	-0,195**

\*\* . Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* . Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle E: Korrelation DAX und deutsche Politikstimmung

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1 DAX														
2 Stimmung	-0,530**													
3 Stimmung <sub>t-1</sub>	-0,526**	0,541**												
4 Stimmung <sub>t-2</sub>	-0,465**	0,495**	0,541**											
5 Stimmung <sub>t-3</sub>	-0,459**	0,560**	0,495**	0,541**										
6 Stimmung <sub>t-4</sub>	-0,462**	0,478**	0,560**	0,495**	0,541**									
7 Stimmung <sub>t-5</sub>	-0,496**	0,472**	0,478**	0,560**	0,495**	0,541**								
8 Stimmung <sub>t-6</sub>	-0,481**	0,409**	0,472**	0,478**	0,560**	0,495**	0,541**							
9 Stimmung <sub>t-7</sub>	-0,488**	0,385**	0,409**	0,472**	0,478**	0,560**	0,495**	0,541**						
10 Tweets	0,505**	-0,244**	-0,291**	-0,345**	-0,364**	-0,355**	-0,382**	-0,374**	-0,325**					
11 Wörter	0,425**	-0,214**	-0,259**	-0,326**	-0,325**	-0,318**	-0,355**	-0,341**	-0,299**	0,985**				
12 Positive Wörter	0,293**	-0,11	-0,189*	-0,247**	-0,241**	-0,274**	-0,261**	-0,243**	-0,252**	0,825**	0,846**			
13 Negative Wörter	0,480**	-0,326**	-0,376**	-0,461**	-0,484**	-0,449**	-0,466**	-0,470**	-0,407**	0,865**	0,857**	0,666**		
14 Rel. positive Wörter	-0,197*	0,259**	0,156*	0,141	0,112	0,09	0,206**	0,125	0,028	-0,075	-0,062	0,409**	-0,172*	
15 Rel. negative Wörter	0,545**	-0,373**	-0,408**	-0,434**	-0,452**	-0,462**	-0,435**	-0,405**	-0,377**	0,285**	0,259**	0,112	0,666**	-0,274**

\*\* . Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* . Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle F: Korrelation DAX und englische DAX-Stimmung

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1 DAX																				
2 Tweets	0,046																			
3 Wörter	-0,023	0,987**																		
4 Positive Wörter	-0,065	0,893**	0,902**																	
5 Negative Wörter	-0,079	0,884**	0,881**	0,792**																
6 Rel. positive Wörter	-0,106	-0,044	-0,047	0,348**	-0,067															
7 Rel. negative Wörter	-0,129	0,329**	0,307**	0,268**	0,695**	-0,055														
8 Rel. positive Wörter <sub>t-1</sub>	-0,062	-0,022	-0,019	0,06	-0,032	0,153*	-0,056													
9 Rel. negative Wörter <sub>t-1</sub>	-0,092	0,132	0,132	0,168*	0,185*	0,046	0,144	-0,055												
10 Rel. positive Wörter <sub>t-2</sub>	-0,042	-0,082	-0,071	-0,004	-0,085	0,189*	-0,052	0,153*	-0,056											
11 Rel. negative Wörter <sub>t-2</sub>	-0,079	-0,069	-0,074	-0,039	0,042	0,08	0,195**	0,046	0,144	-0,055										
12 Rel. positive Wörter <sub>t-3</sub>	-0,117	-0,124	-0,117	-0,12	-0,051	-0,01	0,097	0,189*	-0,052	0,153*	-0,056									
13 Rel. negative Wörter <sub>t-3</sub>	-0,023	-0,024	-0,024	0,005	0,027	-0,033	0,041	0,08	0,195**	0,046	0,144	-0,055								
14 Rel. positive Wörter <sub>t-4</sub>	-0,202*	-0,087	-0,069	-0,088	-0,046	0,005	0,025	-0,01	0,097	0,189*	-0,052	0,153*	-0,056							
15 Rel. negative Wörter <sub>t-4</sub>	0,057	-0,034	-0,021	0,039	-0,034	0,084	-0,007	-0,033	0,041	0,08	0,195**	0,046	0,144	-0,055						
16 Rel. positive Wörter <sub>t-5</sub>	-0,167	-0,015	-0,007	-0,026	-0,029	-0,054	0,029	0,005	0,025	-0,01	0,097	0,189*	-0,052	0,153*	-0,056					
17 Rel. negative Wörter <sub>t-5</sub>	0,07	-0,121	-0,11	-0,131	-0,094	-0,048	-0,059	0,084	-0,007	-0,033	0,041	0,08	0,195**	0,046	0,144	-0,055				
18 Rel. positive Wörter <sub>t-6</sub>	-0,142	0,003	-0,003	0,013	-0,007	0,027	0,033	-0,054	0,029	0,005	0,025	-0,01	0,097	0,189*	-0,052	0,153*	-0,056			
19 Rel. negative Wörter <sub>t-6</sub>	0,063	0,016	0,034	0,09	0,001	0,152*	0,008	-0,048	-0,059	0,084	-0,007	-0,033	0,041	0,08	0,195**	0,046	0,144	-0,055		
20 Rel. positive Wörter <sub>t-7</sub>	-0,158	0,031	0,034	0,04	0,026	0,076	-0,036	0,027	0,033	-0,054	0,029	0,005	0,025	-0,01	0,097	0,189*	-0,052	0,153*	-0,056	
21 Rel. negative Wörter <sub>t-7</sub>	0,019	0,158*	0,153*	0,167*	0,12	0,041	0,073	0,152*	0,008	-0,048	-0,059	0,084	-0,007	-0,033	0,041	0,08	0,195**	0,046	0,144	-0,055

\* Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

\*\* Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle G: Korrelation deutsche DAX- und Wirtschaftsstimmung

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
1 DAX pos. Wörter																							
2 DAX neg. Wörter	0,686**																						
3 DAX-Stimmung	0,014	-0,03																					
4 DAX-Stimmung <sub>t-1</sub>	0,079	0,127	0,11																				
5 DAX-Stimmung <sub>t-2</sub>	0,06	0,063	-0,012	0,11																			
6 DAX-Stimmung <sub>t-3</sub>	0,059	0,064	-0,039	-0,012	0,11																		
7 DAX-Stimmung <sub>t-4</sub>	0,013	0,01	-0,079	-0,039	-0,012	0,11																	
8 DAX-Stimmung <sub>t-5</sub>	0,028	0,099	0,086	-0,079	-0,039	-0,012	0,11																
9 DAX-Stimmung <sub>t-6</sub>	0,001	0,06	0,015	0,086	-0,079	-0,039	-0,012	0,11															
10 DAX-Stimmung <sub>t-7</sub>	-0,068	0,034	0,117	0,015	0,086	-0,079	-0,039	-0,012	0,11														
11 DAX Rel. pos. Wörter	0,144	-0,105	0,039	-0,13	-0,013	0,018	0,044	0,07	0	0,04													
12 DAX Rel. neg. Wörter	-0,099	0,495**	-0,126	0,045	-0,029	-0,005	0,045	0,187*	0,119	0,061	-0,098												
13 Wirtschaft pos. Wörter	0,754**	0,603**	-0,003	0,013	0,08	0,03	-0,041	0,032	-0,005	-0,06	0,046	0,005											
14 Wirtschaft neg. Wörter	0,640**	0,673**	-0,053	0,077	0,064	0	-0,059	0,026	0,092	0,031	-0,097	0,142	0,819**										
15 Wirtschaftsstimmung	0,047	0,045	-0,025	-0,037	0,048	0,065	-0,013	0,054	-0,054	-0,005	-0,005	0,037	0,022	0,022									
16 Wirtschaftsstimmung <sub>t-1</sub>	-0,07	0,012	-0,045	-0,025	-0,037	0,048	0,065	-0,013	0,054	-0,054	-0,098	0,103	-0,028	-0,003	0,055								
17 Wirtschaftsstimmung <sub>t-2</sub>	0,009	0,038	0,072	-0,045	-0,025	-0,037	0,048	0,065	-0,013	0,054	-0,013	0,074	0,004	-0,023	0,029	0,055							
18 Wirtschaftsstimmung <sub>t-3</sub>	0,078	0,13	0,13	0,072	-0,045	-0,025	-0,037	0,048	0,065	-0,013	0,096	0,039	0,062	0,028	-0,041	0,029	0,055						
19 Wirtschaftsstimmung <sub>t-4</sub>	-0,09	0,001	-0,078	0,13	0,072	-0,045	-0,025	-0,037	0,048	0,065	0,011	0,094	-0,076	-0,027	-0,035	-0,041	0,029	0,055					
20 Wirtschaftsstimmung <sub>t-5</sub>	-0,074	-0,021	0,033	-0,078	0,13	0,072	-0,045	-0,025	-0,037	0,048	0,032	-0,001	-0,042	-0,064	0,086	-0,035	-0,041	0,029	0,055				
21 Wirtschaftsstimmung <sub>t-6</sub>	-0,021	0,07	0,042	0,033	-0,078	0,13	0,072	-0,045	-0,025	-0,037	0,095	0,107	-0,011	-0,019	-0,026	0,086	-0,035	-0,041	0,029	0,055			
22 Wirtschaftsstimmung <sub>t-7</sub>	0,064	0,017	0,059	0,042	0,033	-0,078	0,13	0,072	-0,045	-0,025	0,114	0,009	0,035	-0,031	-0,001	-0,026	0,086	-0,035	-0,041	0,029	0,055		
23 Wirtschaft Rel. pos. Wörter	0,296**	0,160*	-0,026	-0,07	0,036	0,007	-0,076	-0,036	-0,055	-0,039	0,210**	-0,023	0,529**	0,145*	0,058	-0,079	-0,016	0,071	-0,037	0,021	0,052	0,071	
24 Wirtschaft Rel. Neg. Wörter	-0,114	0,167*	-0,122	0,086	-0,008	-0,047	-0,119	-0,063	0,162*	0,155*	-0,171*	0,267**	-0,044	0,409**	-0,113	0,035	-0,098	-0,007	0,069	-0,063	0,032	-0,096	-0,190**

\* Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

\*\* Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle H: Korrelation deutsche DAX- und Politikstimmung

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	
1 DAX pos. Wörter																									
2 DAX neg. Wörter	0,706**																								
3 DAX-Stimmung	-0,025	-0,084																							
4 DAX-Stimmung <sub>t-1</sub>	0,08	0,086	0,067																						
5 DAX-Stimmung <sub>t-2</sub>	0,03	0,068	0,023	0,067																					
6 DAX-Stimmung <sub>t-3</sub>	0,082	0,012	-0,073	0,023	0,067																				
7 DAX-Stimmung <sub>t-4</sub>	0,042	0,047	-0,089	-0,073	0,023	0,067																			
8 DAX-Stimmung <sub>t-5</sub>	0,043	0,160*	0,057	-0,089	-0,073	0,023	0,067																		
9 DAX-Stimmung <sub>t-6</sub>	0,005	0,055	0,018	0,057	-0,089	-0,073	0,023	0,067																	
10 DAX-Stimmung <sub>t-7</sub>	-0,077	-0,016	0,108	0,018	0,057	-0,089	-0,073	0,023	0,067																
11 DAX rel. pos. Wörter	0,283**	-0,076	0,041	-0,104	-0,034	0,049	0,064	0,091	-0,008	0,027															
12 DAX rel. neg. Wörter	-0,097	0,519**	-0,139	-0,006	-0,048	-0,062	0,041	0,174*	0,076	0,032	-0,169*														
13 Politik pos. Wörter	0,603**	0,588**	0,037	0,013	0,084	0,061	-0,019	0,135	0,14	0,021	0,183*	0,106													
14 Politik neg. Wörter	0,455**	0,413**	0,083	0,056	0,074	0,047	-0,033	-0,027	0,04	-0,017	0,11	-0,009	0,666**												
15 Politikstimmung	0,027	0,033	0,038	-0,01	0,064	-0,068	-0,081	-0,02	-0,126	-0,04	-0,064	0,02	-0,011	-0,326**											
16 Politikstimmung <sub>t-1</sub>	-0,045	-0,034	0,055	0,038	-0,01	0,064	-0,068	-0,081	-0,02	-0,126	-0,08	-0,03	-0,189*	-0,376**	0,541**										
17 Politikstimmung <sub>t-2</sub>	-0,064	-0,083	0,028	0,055	0,038	-0,01	0,064	-0,068	-0,081	-0,02	-0,114	-0,059	-0,247**	-0,461**	0,495**	0,541**									
18 Politikstimmung <sub>t-3</sub>	-0,026	-0,061	0,019	0,028	0,055	0,038	-0,01	0,064	-0,068	-0,081	-0,104	-0,05	-0,241**	-0,484**	0,560**	0,495**	0,541**								
19 Politikstimmung <sub>t-4</sub>	-0,047	-0,079	-0,022	0,019	0,028	0,055	0,038	-0,01	0,064	-0,068	-0,065	-0,034	-0,274**	-0,449**	0,478**	0,560**	0,495**	0,541**							
20 Politikstimmung <sub>t-5</sub>	-0,169*	-0,138	-0,037	-0,022	0,019	0,028	0,055	0,038	-0,01	0,064	-0,121	0,006	-0,261**	-0,466**	0,472**	0,478**	0,560**	0,495**	0,541**						
21 Politikstimmung <sub>t-6</sub>	-0,078	-0,07	-0,027	-0,037	-0,022	0,019	0,028	0,055	0,038	-0,01	-0,137	-0,006	-0,243**	-0,470**	0,409**	0,472**	0,478**	0,560**	0,495**	0,541**					
22 Politikstimmung <sub>t-7</sub>	-0,041	-0,071	0,034	-0,027	-0,037	-0,022	0,019	0,028	0,055	0,038	-0,022	-0,058	-0,252**	-0,407**	0,385**	0,409**	0,472**	0,478**	0,560**	0,495**	0,541**				
23 Politik rel. pos. Wörter	0,077	0,161*	-0,036	-0,111	-0,036	-0,015	0,036	0,126	0,107	0,026	0,067	0,172*	0,409**	-0,172*	0,259**	0,156*	0,141	0,112	0,09	0,206**	0,125	0,028			
24 Politik rel. neg. Wörter	0,015	-0,007	0,047	-0,017	-0,012	-0,011	-0,032	-0,117	-0,035	-0,046	0,01	-0,045	0,112	0,666**	-0,373**	-0,408**	-0,434**	-0,452**	-0,462**	-0,435**	-0,405**	-0,377**	-0,274**		

\* Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

\*\* Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle I: Korrelation deutsche Wirtschafts- und Politikstimmung

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	
1	Wirtschaft pos. Wörter																								
2	Wirtschaft neg. Wörter	0,778**																							
3	Wirtschaftsstimmung	0,008	0,007																						
4	Wirtschaftsstimmung <sub>t-1</sub>	-0,06	0,029	-0,002																					
5	Wirtschaftsstimmung <sub>t-2</sub>	0,049	0,006	-0,002	-0,002																				
6	Wirtschaftsstimmung <sub>t-3</sub>	0,098	0,073	-0,049	-0,002	-0,002																			
7	Wirtschaftsstimmung <sub>t-4</sub>	-0,047	0,012	-0,064	-0,049	-0,002	-0,002																		
8	Wirtschaftsstimmung <sub>t-5</sub>	0,011	-0,032	0,103	-0,064	-0,049	-0,002	-0,002																	
9	Wirtschaftsstimmung <sub>t-6</sub>	-0,032	-0,022	-0,018	0,103	-0,064	-0,049	-0,002	-0,002																
10	Wirtschaftsstimmung <sub>t-7</sub>	-0,008	-0,063	-0,04	-0,018	0,103	-0,064	-0,049	-0,002	-0,002															
11	Wirtschaft rel. pos. Wörter	0,591**	0,164*	0,079	-0,086	0,015	0,055	-0,006	0,011	0,054	0,014														
12	Wirtschaft rel. neg. Wörter	-0,04	0,435**	-0,023	0,078	-0,111	0,019	0,103	-0,038	0,025	-0,102	-0,195**													
13	Politik pos. Wörter	0,497**	0,456**	-0,072	-0,062	0,047	0,081	0,016	0,008	0,063	-0,043	0,212**	-0,1												
14	Politik neg. Wörter	0,340**	0,246**	-0,031	0,015	0	0,005	-0,007	0,029	0,087	-0,034	0,161*	-0,262**	0,666**											
15	Politikstimmung	0,091	0,242**	0,022	0,034	-0,094	0,057	-0,042	-0,049	0,137	-0,054	-0,116	0,341**	-0,11	-0,326**										
16	Politikstimmung <sub>t-1</sub>	0,061	0,151*	-0,061	0,022	0,034	-0,094	0,057	-0,042	-0,049	0,137	-0,106	0,253**	-0,189*	-0,376**	0,541**									
17	Politikstimmung <sub>t-2</sub>	0,013	0,127	0,021	-0,061	0,022	0,034	-0,094	0,057	-0,042	-0,049	-0,149*	0,211**	-0,247**	-0,461**	0,495**	0,541**								
18	Politikstimmung <sub>t-3</sub>	0,031	0,163*	0,076	0,021	-0,061	0,022	0,034	-0,094	0,057	-0,042	-0,106	0,222**	-0,241**	-0,484**	0,560**	0,495**	0,541**							
19	Politikstimmung <sub>t-4</sub>	0,072	0,118	0,106	0,076	0,021	-0,061	0,022	0,034	-0,094	0,057	-0,033	0,148*	-0,274**	-0,449**	0,478**	0,560**	0,495**	0,541**						
20	Politikstimmung <sub>t-5</sub>	-0,008	0,103	0,036	0,106	0,076	0,021	-0,061	0,022	0,034	-0,094	-0,1	0,259**	-0,261**	-0,466**	0,472**	0,478**	0,560**	0,495**	0,541**					
21	Politikstimmung <sub>t-6</sub>	0,001	0,133	-0,016	0,036	0,106	0,076	0,021	-0,061	0,022	0,034	-0,162*	0,174*	-0,243**	-0,470**	0,409**	0,472**	0,478**	0,560**	0,495**	0,541**				
22	Politikstimmung <sub>t-7</sub>	0,069	0,223**	0,093	-0,016	0,036	0,106	0,076	0,021	-0,061	0,022	-0,08	0,275**	-0,252**	-0,407**	0,385**	0,409**	0,472**	0,478**	0,560**	0,495**	0,541**			
23	Politik rel. pos. Wörter	0,093	0,138	0,044	-0,096	0,042	0,037	-0,035	-0,025	0,084	0,082	0,028	0,164*	0,409**	-0,172*	0,259**	0,156*	0,141	0,112	0,09	0,206**	0,125	0,028		
24	Politik rel. neg. Wörter	-0,11	-0,200**	-0,006	0,009	0	-0,017	-0,013	0,03	0,055	-0,039	-0,035	-0,275**	0,112	0,666**	-0,373**	-0,408**	-0,434**	-0,452**	-0,462**	-0,435**	-0,405**	-0,377**	-0,274**	

\* Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

\*\* Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle J: Korrelation englische und deutsche DAX-Stimmung

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
1 DAX neg. Wörter																		
2 DAX-Stimmung	-0,084																	
3 DAX-Stimmung <sub>t-1</sub>	0,086	0,067																
4 DAX-Stimmung <sub>t-2</sub>	0,068	0,023	0,067															
5 DAX-Stimmung <sub>t-3</sub>	0,012	-0,073	0,023	0,067														
6 DAX-Stimmung <sub>t-4</sub>	0,047	-0,089	-0,073	0,023	0,067													
7 DAX-Stimmung <sub>t-5</sub>	0,160*	0,057	-0,089	-0,073	0,023	0,067												
8 DAX-Stimmung <sub>t-6</sub>	0,055	0,018	0,057	-0,089	-0,073	0,023	0,067											
9 DAX-Stimmung <sub>t-7</sub>	-0,016	0,108	0,018	0,057	-0,089	-0,073	0,023	0,067										
10 DAX rel. neg. Wörter	0,519**	-0,139	-0,006	-0,048	-0,062	0,041	0,174*	0,076	0,032									
11 Engl. DAX neg. Wörter	0,773**	-0,064	-0,005	0,053	-0,017	0,022	0,002	-0,021	-0,012	0,179*								
12 Engl. DAX-Stimmung	0,448**	-0,114	-0,079	0,021	-0,025	-0,039	0,049	-0,006	0,082	0,197**	0,695**							
13 Engl. DAX-Stimmung <sub>t-1</sub>	0,179*	-0,135	-0,114	-0,079	0,021	-0,025	-0,039	0,049	-0,006	0,113	0,185*	0,144						
14 Engl. DAX-Stimmung <sub>t-2</sub>	-0,042	-0,01	-0,135	-0,114	-0,079	0,021	-0,025	-0,039	0,049	0,084	0,042	0,195**	0,144					
15 Engl. DAX-Stimmung <sub>t-3</sub>	0,012	-0,02	-0,01	-0,135	-0,114	-0,079	0,021	-0,025	-0,039	0,177*	0,027	0,041	0,195**	0,144				
16 Engl. DAX-Stimmung <sub>t-4</sub>	-0,061	-0,017	-0,02	-0,01	-0,135	-0,114	-0,079	0,021	-0,025	-0,036	-0,034	-0,007	0,041	0,195**	0,144			
17 Engl. DAX-Stimmung <sub>t-5</sub>	-0,077	0,105	-0,017	-0,02	-0,01	-0,135	-0,114	-0,079	0,021	-0,018	-0,094	-0,059	-0,007	0,041	0,195**	0,144		
18 Engl. DAX-Stimmung <sub>t-6</sub>	0,079	-0,084	0,105	-0,017	-0,02	-0,01	-0,135	-0,114	-0,079	0,007	0,001	0,008	-0,059	-0,007	0,041	0,195**	0,144	
19 Engl. DAX-Stimmung <sub>t-7</sub>	0,302**	-0,091	-0,084	0,105	-0,017	-0,02	-0,01	-0,135	-0,114	0,144	0,12	0,073	0,008	-0,059	-0,007	0,041	0,195**	0,144

\*\* Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle K: Korrelation englische DAX- und deutsche Wirtschaftsstimung

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
1 Wirtschaft neg. Wörter																		
2 Wirtschaftsstimung	0,007																	
3 Wirtschaftsstimung <sub>t-1</sub>	0,029	-0,002																
4 Wirtschaftsstimung <sub>t-2</sub>	0,006	-0,002	-0,002															
5 Wirtschaftsstimung <sub>t-3</sub>	0,073	-0,049	-0,002	-0,002														
6 Wirtschaftsstimung <sub>t-4</sub>	0,012	-0,064	-0,049	-0,002	-0,002													
7 Wirtschaftsstimung <sub>t-5</sub>	-0,032	0,103	-0,064	-0,049	-0,002	-0,002												
8 Wirtschaftsstimung <sub>t-6</sub>	-0,022	-0,018	0,103	-0,064	-0,049	-0,002	-0,002											
9 Wirtschaftsstimung <sub>t-7</sub>	-0,063	-0,04	-0,018	0,103	-0,064	-0,049	-0,002	-0,002										
10 Wirtschaft rel. neg. Wörter	0,435**	-0,023	0,078	-0,111	0,019	0,103	-0,038	0,025	-0,102									
11 Engl.-DAX neg. Wörter	0,678**	-0,029	-0,03	-0,006	0,057	-0,053	-0,018	0,009	-0,059	0,015								
12 Engl. DAX-Stimmung	0,365**	-0,06	-0,039	0,025	0,022	-0,019	0,091	0,059	-0,019	0,091	0,695**							
13 Engl. DAX-Stimmung <sub>t-1</sub>	0,233**	-0,041	-0,06	-0,039	0,025	0,022	-0,019	0,091	0,059	0,182*	0,185*	0,144						
14 Engl. DAX-Stimmung <sub>t-2</sub>	-0,074	0,143	-0,041	-0,06	-0,039	0,025	0,022	-0,019	0,091	0,012	0,042	0,195**	0,144					
15 Engl. DAX-Stimmung <sub>t-3</sub>	-0,066	0,047	0,143	-0,041	-0,06	-0,039	0,025	0,022	-0,019	0,03	0,027	0,041	0,195**	0,144				
16 Engl. DAX-Stimmung <sub>t-4</sub>	-0,12	0,1	0,047	0,143	-0,041	-0,06	-0,039	0,025	0,022	-0,077	-0,034	-0,007	0,041	0,195**	0,144			
17 Engl. DAX-Stimmung <sub>t-5</sub>	-0,1	0,118	0,1	0,047	0,143	-0,041	-0,06	-0,039	0,025	-0,062	-0,094	-0,059	-0,007	0,041	0,195**	0,144		
18 Engl. DAX-Stimmung <sub>t-6</sub>	0,018	0,057	0,118	0,1	0,047	0,143	-0,041	-0,06	-0,039	-0,106	0,001	0,008	-0,059	-0,007	0,041	0,195**	0,144	
19 Engl. DAX-Stimmung <sub>t-7</sub>	0,268**	0,083	0,057	0,118	0,1	0,047	0,143	-0,041	-0,06	0,03	0,12	0,073	0,008	-0,059	-0,007	0,041	0,195**	0,144

\*\* Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle L: Korrelation englische DAX- und deutsche Politikstimmung

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
1 Politik neg. Wörter																		
2 Politikstimmung	-0,326**																	
3 Politikstimmung <sub>t-1</sub>	-0,376**	0,541**																
4 Politikstimmung <sub>t-2</sub>	-0,461**	0,495**	0,541**															
5 Politikstimmung <sub>t-3</sub>	-0,484**	0,560**	0,495**	0,541**														
6 Politikstimmung <sub>t-4</sub>	-0,449**	0,478**	0,560**	0,495**	0,541**													
7 Politikstimmung <sub>t-5</sub>	-0,466**	0,472**	0,478**	0,560**	0,495**	0,541**												
8 Politikstimmung <sub>t-6</sub>	-0,470**	0,409**	0,472**	0,478**	0,560**	0,495**	0,541**											
9 Politikstimmung <sub>t-7</sub>	-0,407**	0,385**	0,409**	0,472**	0,478**	0,560**	0,495**	0,541**										
10 Politik rel. neg. Wörter	0,666**	-0,373**	-0,408**	-0,434**	-0,452**	-0,462**	-0,435**	-0,405**	-0,377**									
11 Engl. DAX neg. Wörter	0,448**	0,019	-0,095	-0,093	-0,088	-0,14	-0,184*	-0,138	-0,094	0,063								
12 Engl. DAX-Stimmung	0,151*	0,111	0,017	0,09	0,008	0,007	-0,035	0,028	-0,02	-0,039	0,695**							
13 Engl. DAX-Stimmung <sub>t-1</sub>	0,145	0,097	0,111	0,017	0,09	0,008	0,007	-0,035	0,028	-0,018	0,185*	0,144						
14 Engl. DAX-Stimmung <sub>t-2</sub>	-0,019	0,119	0,097	0,111	0,017	0,09	0,008	0,007	-0,035	-0,057	0,042	0,195**	0,144					
15 Engl. DAX-Stimmung <sub>t-3</sub>	-0,011	0,124	0,119	0,097	0,111	0,017	0,09	0,008	0,007	-0,052	0,027	0,041	0,195**	0,144				
16 Engl. DAX-Stimmung <sub>t-4</sub>	-0,031	0,146	0,124	0,119	0,097	0,111	0,017	0,09	0,008	-0,015	-0,034	-0,007	0,041	0,195**	0,144			
17 Engl. DAX-Stimmung <sub>t-5</sub>	0,031	0,106	0,146	0,124	0,119	0,097	0,111	0,017	0,09	0,126	-0,094	-0,059	-0,007	0,041	0,195**	0,144		
18 Engl. DAX-Stimmung <sub>t-6</sub>	0,058	0,149*	0,106	0,146	0,124	0,119	0,097	0,111	0,017	0,04	0,001	0,008	-0,059	-0,007	0,041	0,195**	0,144	
19 Engl. DAX-Stimmung <sub>t-7</sub>	0,113	0,133	0,149*	0,106	0,146	0,124	0,119	0,097	0,111	-0,032	0,12	0,073	0,008	-0,059	-0,007	0,041	0,195**	0,144

\*\* Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle M: Deutsche Nutzer mit den meisten Abonnenten

Rang	DAX			Wirtschaft			Politik		
	Name	Abonnen-ten	Tweets	Name	Abonnenten	Tweets	Name	Abonnenten	Tweets
1	BILD	713.428	2	DRJAMESCABOT	1.643.824	1	DRJAMESCABOT	1.643.648	1
2	Zeitonline	614.170	3	sternde	540.857	2	LordLouis3	1.115.699	1
3	SPIEGELON- LINE	612.532	10	tagesschau	484.818	10	tagesschau	481.679	1
4	Tagesschau	563.579	27	SPIEGELONLINE	417.904	1	SPIEGELONLINE	467.208	1
5	Sternde	545.478	1	ntvde	395.984	23	manuel_c	407.020	1
6	AxelKoster	523.014	1	SZ	365.064	2	ntvde	393.672	18
7	Welt	407.180	7	welt	319.497	4	JulianArtwork	162.806	1
8	Ntvde	387.761	1	AuswaertigesAmt	207.578	1	DasErste	158.134	4
9	handelsblatt	172.728	103	tazgezwitscher	184.149	1	nixon_kill	148.765	1
10	Faznet	159.530	5	handelsblatt	149.154	4	tagesspiegel	148.608	6

Quelle: Eigene Darstellung

Tabelle N: Korrelation DAX und deutsche DAX-Nutzer mit höchster Aktivität

	1	2	3	4	5	6	7	8	9	10
1 DAX										
2 Nutzer 1	0,142									
3 Nutzer 2	-1,000**	1,000**								
4 Nutzer 3	0,089	0,128								
5 Nutzer 4	0,039	0,378**		-0,071						
6 Nutzer 5	0,039	0,378**		-0,071	1,000**					
7 Nutzer 6	0,145	-0,043	-1,000**	0,056	-0,281**	-0,281**				
8 Nutzer 7										
9 Nutzer 8	0,107	-0,099		-0,144	0,028	0,028	-0,006			
10 Nutzer 9	-0,494*	-0,178		0,072	-0,270	-0,270	0,410		0,021	
11 Nutzer 10	0,054	0,291*		0,012	0,431**	0,431**	-0,033		0,049	0,078

\*\* . Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* . Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle O: Korrelation DAX und deutsche Wirtschafts-Nutzer mit höchster Aktivität

	1	2	3	4	5	6	7	8	9	10
1 DAX										
2 Nutzer 1	-0,016									
3 Nutzer 2	0,122	0,668**								
4 Nutzer 3	-0,038	-0,079	-0,029							
5 Nutzer 4	0,033	0,052	0,016	-0,184						
6 Nutzer 5	0,186*	0,073	0,058	0,115	0,019					
7 Nutzer 6	0,001	0,500**	0,505**	0,074	0,020	0,159				
8 Nutzer 7	0,046	0,055	-0,017	-0,033	-0,042	0,067	0,099			
9 Nutzer 8	-0,194*	0,369**	0,053	0,026	0,053	-0,008	0,106	0,079		
10 Nutzer 9	-0,002	0,034	-0,080	0,129	-0,083	0,023	-0,105	-0,042	0,018	
11 Nutzer 10	-0,214*	0,245**	0,108	-0,056	-0,104	-0,054	0,045	0,060	0,301**	0,102

\*\* . Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* . Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle P: Korrelation DAX und deutsche Politik-Nutzer mit höchster Aktivität

	1	2	3	4	5	6	7	8	9	10
1 DAX										
2 Nutzer 1	0,244**									
3 Nutzer 2	0,018	0,331**								
4 Nutzer 3	0,005	0,128	0,055							
5 Nutzer 4	-0,063	0,083	0,015	0,722**						
6 Nutzer 5	0,188*	0,273**	-0,086	0,048	0,026					
7 Nutzer 6	0,034	0,105	0,078	0,177	0,086	0,067				
8 Nutzer 7	0,137	0,067	0,156	-0,082	-0,168	-0,060	-0,083			
9 Nutzer 8	-0,111	0,268**	0,067	0,098	0,044	-0,065	0,096	0,047		
10 Nutzer 9	-0,360**	-0,069	-0,250*	0,114	0,183	-0,090	-0,126	-0,134	-0,061	
11 Nutzer 10	0,090	0,156	0,150	-0,130	-0,137	-0,113	-0,400	-0,034		-0,035

\*\* . Die Korrelation ist auf dem 0,01 Niveau signifikant (zweiseitig).

\* . Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle Q: Korrelation DAX und englische DAX-Nutzer mit höchster Aktivität

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1 DAX																				
2 Nutzer 1 pos. Wörter	0,041																			
3 Nutzer 1 neg. Wörter	0,043	0,119																		
4 Nutzer 2 pos. Wörter	-0,175	-0,159	-0,065																	
5 Nutzer 2 neg. Wörter	-0,076	0,086	0,070	0,102																
6 Nutzer 3 pos. Wörter	0,226	-0,148	-0,014	0,383*	-0,072															
7 Nutzer 3 neg. Wörter	0,160					0,220*														
8 Nutzer 4 pos. Wörter	0,204																			
9 Nutzer 4 neg. Wörter																				
10 Nutzer 5 pos. Wörter	-0,148	-0,174	-0,020	-0,271	-0,162	-0,121	-0,200													
11 Nutzer 5 neg. Wörter	-0,230*	-0,198	-0,042	-0,112	0,055	-0,295*	-0,133		0,100											
12 Nutzer 6 pos. Wörter	-0,054	0,043	0,078	-0,206	-0,063	-0,220		0,148	-0,044	-0,003										
13 Nutzer 6 neg. Wörter	0,030	-0,229*	-0,066	0,033	-0,064	0,005		0,049	-0,036	0,040	0,027									
14 Nutzer 7 pos. Wörter	-0,050	-0,084	-0,068	0,074	-0,263	0,402		0,034	-0,130	0,147	0,199	0,035								
15 Nutzer 7 neg. Wörter	-0,217	0,106	0,114	-0,359	0,346	-0,451		-0,086	0,204	0,015	-0,383*	-0,270	-0,238							
16 Nutzer 8 pos. Wörter	-0,050	-0,001	-0,017	0,041	-0,263	0,402		-0,052	-0,168	0,202	0,256	0,083	0,948**	-0,217						
17 Nutzer 8 neg. Wörter	-0,134	0,104	-0,013	-0,304	0,352	-0,451		-0,086	0,195	-0,068	-,413*	-0,261	-0,238	0,901**	-0,237					
18 Nutzer 9 pos. Wörter	0,295*	0,084	-0,060	-0,416*	-0,044	-0,070	0,155		0,058	-0,276	-0,067	0,330*	0,866	-0,866	0,866	-0,866				
19 Nutzer 9 neg. Wörter	-0,051	0,141	0,146	-0,222	-0,111	-0,136	-0,135		0,165	-0,217	0,256	-0,098	1,000**	-0,500	1,000**	-0,500	0,223			
20 Nutzer 10 pos. Wörter	0,295*	0,084	-0,060	-0,416*	-0,044	-0,070	0,155		0,058	-0,276	-0,067	0,330*	0,866	-0,866	0,866	-0,866	1,000**	0,223		
21 Nutzer 10 neg. Wörter	-0,051	0,141	0,146	-0,222	-0,111	-0,136	-0,135		0,165	-0,217	0,256	-0,098	1,000**	-0,500	1,000**	-0,500	0,223	1,000**	0,223	

\*\* Die Korrelation ist auf dem 0.01 Niveau signifikant (zweiseitig).

\* Die Korrelation ist auf dem 0,05 Niveau signifikant (zweiseitig).

Quelle: Eigene Darstellung

Tabelle R: Signifikante Korrelationen DAX und deutsche Nutzerstimmungen

Nutzername	Korrelationskoeffizient	Signifikanz	Anzahl Tweets	Thema	Vorlauf	Anzahl Tagesstimmungen	Geeignet für Vorhersage
wiegelmann m	0,77	0,02	21	DAX	0	9	0
boersestuttgart	0,38	0,02	99	DAX	0	38	0
RENIXX News	0,41	0,04	85	DAX	0	25	0
sysmarketcom	-0,44	0,04	126	DAX	0	22	0
FAZ Finance	-0,73	0,04	39	DAX	0	8	0
FAZ NET	-0,73	0,04	41	DAX	0	8	0
mehrdividende	-0,43	0,05	478	DAX	0	21	0
Moneycab	0,23	0,01	3.797	Wirtschaft	0	117	1
SHC GmbH	-0,77	0,03	21	Wirtschaft	0	8	0
AustriaDaily	-0,20	0,03	1.150	Wirtschaft	0	114	1
IFeedom	-0,88	0,05	37	Wirtschaft	0	5	0
Erdbeer Joghurt	0,18	0,05	4.611	Wirtschaft	0	116	1
YasinBerlinDE	0,54	0,00	425	Politik	0	27	0
miloquadros	-0,64	0,00	113	Politik	0	18	0
MarcLussy	0,77	0,01	117	Politik	0	11	0
fdlap37	-0,89	0,01	58	Politik	0	7	0
open thinking	0,87	0,01	17	Politik	0	7	0
AxelHohl	-0,30	0,01	458	Politik	0	69	1
NorthernHell	-0,83	0,02	50	Politik	0	7	0
DeutscheTweeter	-0,80	0,03	38	Politik	0	7	0
AustriaDaily	0,19	0,04	2.031	Politik	0	114	1
Nordpirat	-0,61	0,05	66	Politik	0	11	0
worldnetnews	-0,29	0,05	253	Politik	0	47	1
mehrdividende	-0,49	0,03	478	DAX	1	21	0
boersestuttgart	0,37	0,05	99	DAX	1	38	0
Moneycab	0,25	0,01	3.797	Wirtschaft	1	117	1
SHC GmbH	-0,79	0,04	21	Wirtschaft	1	8	0
miloquadros	-0,72	0,00	113	Politik	1	18	0
YasinBerlinDE	0,54	0,00	425	Politik	1	27	0
patriciahuttenh	0,82	0,01	40	Politik	1	8	0
lotusandmoon	0,85	0,01	27	Politik	1	5	0
MarcLussy	0,58	0,02	117	Politik	1	11	0
DeutscheTweeter	-0,75	0,03	38	Politik	1	7	0
Medienkritik	-0,46	0,03	133	Politik	1	22	0
PParzival	0,74	0,04	55	Politik	1	8	0
worldnetnews	-0,30	0,04	253	Politik	1	48	1
JonNormann37	-0,82	0,04	41	Politik	1	6	0
AxelHohl	-0,26	0,04	458	Politik	1	6	0
brokertest	0,31	0,04	359	DAX	2	64	1
21ChinaNews	-0,57	0,03	71	Wirtschaft	2	19	0
YasinBerlinDE	-0,27	0,04	1.058	Wirtschaft	2	100	1
StutzPartner	0,31	0,04	328	Wirtschaft	2	51	1
miloquadros	-0,75	0,00	113	Politik	2	18	0
MarcLussy	0,70	0,01	117	Politik	2	11	0
AxelHohl	-0,35	0,01	458	Politik	2	69	1
YasinBerlinDE	0,46	0,02	425	Politik	2	27	0
21CenturyMonk	0,39	0,03	157	Politik	2	33	0
patriciahuttenh	0,80	0,03	40	Politik	2	8	0
JonNormann37	-0,84	0,04	41	Politik	2	6	0
RaulRadon	-0,77	0,04	20	Politik	2	6	0
wiegelmann m	0,87	0,01	21	DAX	3	9	0
finanzmarktwelt	-0,53	0,02	208	DAX	3	29	0
foerdesparkasse	-0,61	0,02	108	DAX	3	25	0
sysmarketcom	-0,59	0,03	126	DAX	3	22	0
CFD Markt	0,20	0,03	9.127	DAX	3	116	1
Michael Weyland	-0,52	0,03	253	Wirtschaft	3	26	0
Moneycab	0,23	0,03	3797	Wirtschaft	3	117	1

Nutzername	Korrelationskoeffizient	Signifikanz	Anzahl Tweets	Thema	Vorlauf	Anzahl Tagesstimmungen	Geeignet für Vorhersage
BoersenSpiegel	0,56	0,05	163	Wirtschaft	3	27	0
AxelHohl	-0,39	0,00	458	Politik	3	69	1
worldnetnews	-0,42	0,01	253	Politik	3	47	1
msxy2	0,57	0,03	63	Politik	3	13	0
AustriaDaily	0,20	0,03	2.031	Politik	3	114	1
GarionCoyote	-0,83	0,04	37	Politik	3	7	0
foerdesparkasse	-0,55	0,02	108	DAX	4	25	0
mycomfor	0,48	0,03	107	DAX	4	27	0
sysmarketcom	-0,53	0,04	126	DAX	4	22	0
MarcLussy	0,71	0,00	117	Politik	4	11	0
KJangdom	-0,59	0,01	156	Politik	4	23	0
metalchickencom	0,96	0,01	45	Politik	4	10	0
OhProtector	0,68	0,02	66	Politik	4	12	0
YasinBerlinDE	0,44	0,02	425	Politik	4	27	0
cenjur	0,98	0,02	24	Politik	4	7	0
worldnetnews	-0,38	0,02	253	Politik	4	47	1
Kazi Germany	0,21	0,03	18.539	Politik	4	116	1
mellubo1	-1,00	0,04	36	Politik	4	5	0
KelsangPaglam	0,96	0,04	26	Politik	4	8	0
VajraShugden	0,37	0,04	193	Politik	4	32	0
AustriaDaily	0,19	0,04	2.031	Politik	4	114	1
BarbaraKube	0,89	0,05	44	Politik	4	6	0
ProtetorShugden	0,58	0,05	66	Politik	4	13	0
PiepCindy	-0,88	0,05	27	Politik	4	6	0
RaulRadon	-0,76	0,05	20	Politik	4	6	0
HypoVereinsbank	0,99	0,01	44	DAX	5	8	0
RENIXX News	0,65	0,01	85	DAX	5	27	0
boersestuttgart	0,40	0,04	99	DAX	5	38	0
ntvde	1,00	0,03	21	Wirtschaft	5	7	0
wirtschaftsfens	0,50	0,04	579	Wirtschaft	5	29	0
ProtetorShugden	0,76	0,00	66	Politik	5	13	0
YasinBerlinDE	0,54	0,00	425	Politik	5	27	0
VajraShugden	0,49	0,01	193	Politik	5	32	0
pflegekasse	-0,46	0,01	206	Politik	5	36	0
PiepCindy	-0,95	0,01	27	Politik	5	6	0
MarcLussy	0,62	0,02	117	Politik	5	11	0
37jandom	0,86	0,03	47	Politik	5	11	0
AnonNewsDE	-0,25	0,03	641	Politik	5	82	1
MTaege	0,91	0,03	21	Politik	5	6	0
patriciahuttenh	0,80	0,03	40	Politik	5	8	0
UserKingsize	0,44	0,04	88	Politik	5	24	0
OhProtector	0,62	0,04	66	Politik	5	12	0
RENIXX News	0,51	0,02	85	DAX	6	25	0
FAZ Finance	-0,88	0,02	39	DAX	6	8	0
FAZ NET	-0,88	0,02	41	DAX	6	8	0
CFD Markt	0,18	0,05	9.127	DAX	6	116	1
WirtschaftNews	-0,32	0,01	4.666	Wirtschaft	6	61	1
Moneycab	0,23	0,02	3.797	Wirtschaft	6	117	1
YasinBerlinDE	0,64	0,00	425	Politik	6	27	0
AnonNewsDE	-0,29	0,01	641	Politik	6	82	1
pdhofer	0,94	0,02	47	Politik	6	8	0
37daka37	-0,79	0,02	47	Politik	6	8	0
Sternrubin	0,66	0,03	44	Politik	6	11	0
Finanzwiese	0,21	0,03	3.727	Politik	6	116	1
mellubo1	1,00	0,03	36	Politik	6	5	0
miloquadros	-0,50	0,03	113	Politik	6	18	0
NeuigkeitenDE	0,30	0,03	1.506	Politik	6	52	1
VajraShugden	0,37	0,04	193	Politik	6	32	0
MTaege	0,78	0,04	21	Politik	6	6	0

Nutzername	Korrelationskoeffizient	Signifikanz	Anzahl Tweets	Thema	Vorlauf	Anzahl Tagesstimmungen	Geeignet für Vorhersage
Kazi Germany	0,18	0,05	18.539	Politik	6	116	1
boersestuttgart	0,33	0,04	107	DAX	7	41	0
mehrdividende	-0,46	0,04	495	DAX	7	21	0
FAZ Finance	-0,77	0,04	41	DAX	7	8	0
FAZ NET	-0,77	0,04	43	DAX	7	8	0
ARDboerse	-0,40	0,05	185	DAX	7	24	0
Moneycab	0,22	0,02	3.797	Wirtschaft	7	117	1
SHC GmbH	-0,82	0,02	21	Wirtschaft	7	8	0
AustriaDaily	-0,20	0,03	1150	Wirtschaft	7	114	1
schlagzeilen1	-0,19	0,04	1672	Wirtschaft	7	117	1
GJConsulting	0,47	0,04	150	Wirtschaft	7	19	0
YasinBerlinDE	0,62	0,00	426	Politik	7	28	0
fdlap37	-0,81	0,00	65	Politik	7	10	0
Bayern Waehlt	-0,87	0,01	40	Politik	7	8	0
MarcLussy	0,76	0,01	118	Politik	7	11	0
NorthernHell	-0,81	0,01	58	Politik	7	9	0
AnonNewsDE	-0,27	0,01	641	Politik	7	82	1
pdhofer	0,81	0,02	47	Politik	7	8	0
DeutscheTweeter	-0,89	0,02	38	Politik	7	7	0
miloquadros	-0,49	0,02	121	Politik	7	21	0
AxelHohl	-0,27	0,03	461	Politik	7	70	1
RaulRadon	-0,81	0,03	20	Politik	7	6	0
worldnetnews	-0,32	0,03	254	Politik	7	47	1
virgilja	-0,63	0,04	47	Politik	7	10	0
AT OESI	-0,67	0,05	64	Politik	7	9	0

Quelle: Eigene Darstellung

Tabelle S: Wichtigkeiten der Nutzer für die Vorhersage

Nutzer	Wichtigkeit	Normalisierte Wichtigkeit	Vorlauf
AxelHohl	0,305	100,00%	0
AustriaDaily	0,21	68,70%	0
worldnetnews	0,168	54,90%	0
AustriaDaily	0,129	42,10%	0
Erdbeer_Joghurt	0,108	35,50%	0
Moneycab	0,080	26,30%	0
Moneycab	0,725	100,00%	1
worldnetnews	0,275	38,00%	1
StutzPartner	0,368	100,00%	2
YasinBerlinDE	0,363	98,80%	2
brokertest	0,170	46,20%	2
AxelHohl	0,100	27,10%	2
Moneycab	0,454	100,00%	3
CFD_Markt	0,169	37,30%	3
AustriaDaily	0,149	32,70%	3
AxelHohl	0,144	31,70%	3
worldnetnews	0,085	18,70%	3
Kazi_Germany	0,462	100,00%	4
AustriaDaily	0,294	63,60%	4
worldnetnews	0,243	52,60%	4
AnonNewsDE	1,000	100,00%	5
Moneycab	0,256	100,00%	6
CFD_Markt	0,242	94,50%	6
Kazi_Germany	0,171	66,70%	6
NeuigkeitenDE	0,127	49,50%	6
WirtschaftNews_	0,081	31,80%	6
AnonNewsDE	0,081	31,60%	6
Finanzwiese	0,042	16,60%	6
AxelHohl	0,402	100,00%	7
AustriaDaily	0,173	43,00%	7
Moneycab	0,169	42,00%	7
AnonNewsDE	0,149	37,00%	7
schlagzeilen1	0,058	14,50%	7
worldnetnews	0,050	12,40%	7

Quelle: Eigene Darstellung