

Öffentliche Meinung über Bitcoin

Andreas Fuchs
Institut für Wirtschaftsinformatik
WWU Münster
Leonardo-Campus 3, 48149 Münster
Deutschland
a_fuch05@uni-muenster.de

ABSTRACT

Es gibt unterschiedliche Meinungen über Bitcoin. Einige sind vom System überzeugt und sehen eine tatsächliche Alternative zu den bisherigen Währungen. Andere warnen vor Gefahren, die beispielsweise durch Zahlungen zum Drogenkauf oder durch Geldwäsche unter Pseudonymen¹ entstehen können. Eine strukturierte Übersicht dieser Meinungen existiert momentan nicht.

Dabei kann ein solches Meinungsbild dabei helfen, vergangene Ereignisse in der Bitcoin-Historie durch eine neue Sichtweise zu betrachten und unter Umständen sogar Rückschlüsse aus diesen zu ziehen, um zukünftige Ereignisse vorherzusagen zu können. Zusätzlich kann es einen Überblick der verschiedenen Meinungen zu Bitcoin in der Öffentlichkeit bieten.

In dieser Arbeit wird ein Meinungsbild aus insgesamt 3958 Blog-Einträgen zwischen Januar 2012 und Mai 2013 erstellt. Die Meinungen wurden dabei für jeden Monat in Kategorien von *sehr positiv* bis *sehr negativ* eingeordnet.

Die so erhaltenen Daten wurden in einem Diagramm abgebildet, welches eine Übersicht der verschiedenen Meinungen in der Bitcoin-Historie darstellt.

Keywords

Bitcoin, Public Opinion, Blogs, Sentiment Analysis, Opinion Mining, Content Classification, Content Analysis

1. MOTIVATION

Im Jahr 2008 wurde ein Whitepaper unter dem Pseudonym Satoshi Nakamoto veröffentlicht, das das Konzept von Bitcoin erläutert [16]. Seitdem hat sich Bitcoin zu einer erfolgreichen Alternativ-Währung entwickelt, die im Mai 2013 eine Marktkapitalisierung von über 1 Milliarden US-Dollar aufweist [6]. Bitcoin kann dabei als ein verteiltes peer-to-peer² Buchhaltungssystem [5] angesehen werden, welches auf kryptographischen Verfahren beruht. Besonders hervorzuheben ist, dass es im Bitcoin-System keine zentrale Instanz - wie beispielsweise eine Noten- oder Zentralbank - gibt, sondern, dass etwaige Konflikte per Mehrheitsentscheid im System gelöst werden. Man kann aus einer Vielzahl an Gründen über Bitcoin diskutieren. Einige versuchen über dieses relativ neue Thema zu informieren, um so eine breitere gesellschaftliche Akzeptanz zu schaffen. Sie könnten dabei von der Grundidee einer dezentralen Währung überzeugt sein und möchten, dass möglichst viele weitere Menschen ihrem Beispiel folgen. Andere drücken Sicherheitsbedenken aus und möchten davor warnen, "echtes" Geld in Bitcoins zu investieren. Manche sehen Bitcoins besonders kritisch, weil sie das Bitcoin-System einer unausweichlichen Deflation entgegensteuern sehen. Da es keine zentrale Instanz gibt, die über das Bitcoin-System wacht, gibt es auch keine offiziellen Ansprechpartner bei Fragen zu diesem. Als größtes Diskussionsforum hat sich jedoch <http://bitcointalk.org> etabliert und ein ausführliches Wiki ist auf <http://bitcoin.it> zu finden. Man kann diese Seiten aufsuchen, um sich über Bitcoin zu informieren - und man kann in die Diskussion über Bitcoin einsteigen: in Foren, Blogs oder bei Twitter Fragen stellen, eine eigene Meinung bilden und diese dann auch aktiv vertreten.

Durch die Vielzahl an Diskussionen und unterschiedlichen Meinungen ist es momentan schwierig, einen Gesamtüberblick der Stimmungslage über Bitcoin in der Öffentlichkeit zu bestimmen. Insbesondere ist es auch schwierig, diese Stimmungslage in einen Kontext einzuordnen: *warum war die Stimmung zu einem bestimmten Zeitpunkt besonders gut oder schlecht?* Diese Arbeit stellt einen strukturierten Prozess vor, mit dem diese Frage beantwortet werden kann.

Zusätzlich zu der aktuellen Stimmungslage ist auch ein historischer Rückblick interessant, um erkennen zu können, in wie weit sich die Stimmung über Bitcoin im Zeitverlauf geändert hat. Besonders bedeutsame Ereignisse in der Bitcoin-Historie kann man so mit dem zu diesem Zeitpunkt vorherrschenden Stimmungsbild vergleichen und Rückschlüsse aus diesen ziehen.

¹ Bitcoin bietet keine Anonymität, alle Transaktionen sind öffentlich einsehbar. Allerdings handeln die Bitcoin-Teilnehmer nicht unter Klarnamen, sondern unter einer Kontonummer, welche ohne weiteres Wissen keiner Person zugeordnet werden kann. Kennt man jedoch die Zuordnung von Kontonummer und Person, können alle jemals getätigten Transaktionen dieser Person eingesehen werden. Es entsteht im Bitcoin-System somit eine Pseudonymisierung, eine Anonymität wird nicht garantiert.

² In einem peer-to-peer Rechnernetz sind alle Computer gleichberechtigt

Aus dem Stimmungsbild könnte ferner ein Leitindex erstellt werden, der es ermöglicht, zukünftige Entwicklungen besser abschätzen zu können.

Um eine geeignete Analyse über die öffentliche Meinung machen zu können, wurden 3958 Blog-Einträge auf ihre Stimmungslage hin untersucht. Dazu wurde ein Java-Programm geschrieben, das Ergebnisse der Google Blog Search ausliest und die einzelnen Suchergebnisse in jeweils einem Dokument lokal speichert. Zusätzlich wurde jedes einzelne dieser Dokumente so formatiert, dass nur der eigentliche Beitrag des Verfassers des Blogs in ihnen enthalten ist. Diese formatierten Blog-Einträge wurden anschließend mit einem Klassifizierungswerkzeug analysiert, so dass der Anteil an positiven und negativen Beiträgen ermittelt werden konnte. Diese Klassifizierung wurde pro Monat vorgenommen, um die einzelnen Kategorie-Anteile in einer Zeitreihe grafisch darstellen zu können. Zusätzliches Material, wie zum Beispiel das erstellte Java-Programm, werden zusammen mit der Arbeit zur Verfügung gestellt.³

Im folgenden Kapitel werden vergleichbare Arbeiten vorgestellt, in denen auch Meinungen zu einem bestimmten Thema aus öffentlich zugänglichen Quellen analysiert wurden. Anschließend werden wesentliche Grundlagen der Sentiment-Analyse und des hier eingesetzten Klassifikations-Modells vorgestellt. Darauf aufbauend wird die Analyse beschrieben: von der Beschreibung der Datenbasis über den Prozess der Datenauslese bis hin zu den Ergebnissen der Analyse und ihrer Interpretation. Abgeschlossen wird mit einem Fazit und Ausblick, was aufbauend auf dieser Arbeit möglich ist.

2. RELATED WORK

Viele Sentiment-Analysen konzentrieren sich drauf, einzelne Dokumente richtig zu klassifizieren [19]: *wie ist die Meinung des Autors in einem bestimmten Beitrag?* Dies kann jedoch zu Ungenauigkeiten führen, wenn die einzelnen Dokumente einer Kategorie zugeordnet werden und anschließend die Anteile der Kategorien an der Gesamtmenge ermittelt wird [9]. Im Kapitel 3.1 wird diese Problematik detaillierter erläutert. Da ein öffentliches Meinungsbild jedoch in genau solchen Anteilen gemessen werden soll, wird in dieser Arbeit ein Verfahren von Hopkins und King genutzt, das speziell für diesen Einsatzzweck erstellt worden ist.

In [9] stellen die Autoren Ergebnisse und Einsatzmöglichkeiten ihres Klassifizierungswerkzeug *ReadMe* vor. Dieses Werkzeug ist dazu geeignet, unstrukturierte Texte durch überwachtes Lernen in definierte Kategorien zu klassifizieren. Ein Vorteil von *ReadMe* ist die Genauigkeit⁴ bei der Ermittlung der jeweiligen Anteile der Kategorien in der Gesamtmenge. Die beiden Autoren stellen dabei ihre Ergebnisse anhand eines Beispiels vor, in dem sie politische Meinungen in den Jahren 2006 bis 2007 in Blogs analysiert haben. Der amerikanische Politiker John Kerry hatte im November 2006 während des Kongresswahlkampfes eine umstrittene Äußerung gemacht, in Folge dessen er sich aus dem Wahlkampf zurückgezogen hat: *"Wisst ihr, Bildung - wenn ihr das Beste daraus macht, hart studiert, eure Hausaufgaben macht und euch anstrengt schlau zu sein - dann kann es gut für euch*

³ <https://dl.dropboxusercontent.com/u/25485809/bitcoin.zip>

⁴ Genauigkeit bedeutet hier, in wie weit die ermittelte Kategorisierung mit einer "echten" Kategorisierung übereinstimmt, die von einem Menschen erstellt worden ist.

laufen. Tut ihr das nicht, sitzt ihr irgendwann im Irak fest" [7]. Die Autoren konnten zeigen, dass just in diesem Monat der Anteil der Blog-Einträge mit *sehr negativen* Meinungen über John Kerry von etwa 20% auf ungefähr 60% angestiegen ist. Zusätzlich lag der Anteil der *negativen* Meinungen vor und nach seiner Äußerung bei ungefähr 40%, wohingegen der Anteil *positiver* und *sehr positiver* Äußerungen nur zwischen 5% und 15% lag. In den Medien wurde damals behauptet, John Kerry hätte sich wegen seiner gemachten Äußerung aus dem Wahlkampf zurückgezogen. Die Autoren vermuten jedoch, dass der Anteil der negativen Meinungen, der auch vor seiner gemachten Äußerung schon hoch war, einen entscheidenden Einfluss auf seinen Rücktritt gehabt habe.

In einem anderen Aufsatz wurde die öffentliche Meinung mit dem Stimmungsbild auf Twitter verglichen, welches zum selben Zeitpunkt vorlag [17]. Die öffentlichen Meinungen wurden dabei aus Umfragen über das Konsumklima und über politische Meinungen gewonnen. Ein Ergebnis ist, dass in etwa 80% der Fälle die Meinungen aus den Umfragen mit der Stimmung auf Twitter korrelieren. Allerdings zeigen die Autoren auch, dass das Meinungsbild auf Twitter sehr stark rauscht. Für eine weitere Analyse sei es daher notwendig, die unbekannte Variable, die zu diesem Rauschen führt, mit in die Analyse einzubeziehen. Alternativ sollte auf eine andere Daten-Quelle zurückgegriffen werden. Dennoch könne die Analyse von Texten aus Sozialen Netzwerken, wie Twitter, zu einem möglichen Ersatz für traditionelle Umfragemethoden führen, die zeit- und kostenintensiver sind.

3. GRUNDLAGEN

Im Folgenden wird zunächst die Sentiment-Analyse vorgestellt. Es wird gezeigt, dass eine spezielle Methode der Analyse hier angewendet wird. Im Anschluss daran wird das Modell, welches dieser Methode zugrunde liegt, erläutert.

3.1 Sentiment-Analyse

Bei der Sentiment-Analyse geht es um das Extrahieren von positiven und negativen Meinungen von Texten, die insbesondere auch in unstrukturierter Form vorliegen können [19]. Häufig werden dabei die extrahierten Meinungen in verschiedene Kategorien klassifiziert, oft auch mehr als eine Dichotomie in die beiden Kategorien "positiv" und "negativ". So können weitere Kategorien wie beispielsweise "sehr positiv" und "sehr negativ" eingeführt werden. Im Englischen wird anstelle von Sentiment-Analyse auch oft der Begriff des Opinion Mining verwendet, der den Aspekt der Meinungsgewinnung deutlicher herausstellt. Viele Texte lassen sich grob in die beiden Kategorien "subjektiv" - für eine Meinung enthaltend - und "objektiv" - für keine Meinung enthaltend, sondern informierend - unterteilen. Eine Studie [12] hat gezeigt, dass eine Unterteilung jedoch nicht immer einfach ist. In dieser Studie sollten Menschen unter anderem entscheiden, ob eine gemachte Aussage eine Meinung ist oder nicht - und waren sich dabei oftmals nicht einig. Ein weiteres Ergebnis der Studie war, dass eine Klassifizierung in objektive und subjektive Texte sehr schwierig ist. Andere Wissenschaftler [14] haben gezeigt, dass die Unterscheidung zwischen subjektiven und objektiven Fällen oft schwieriger ist, als eine Beurteilung einer Aussage als positiv oder negativ. Damit hätte eine Verbesserung der Subjektivitäts-Klassifikation auch einen positiven Einfluss auf die Ergebnisse der nachfolgenden Sentiment-Analyse [14].

Bei objektiv beschriebenen Texten kann es beispielsweise das Ziel sein, das Thema des Textes zu ermitteln. Dabei ist es

offensichtlich, dass es je nach Anwendungsfall eine Vielzahl verschiedener Kategorien geben kann - im Extremfall bildet jedes mögliche Thema eine Kategorie. Auf der anderen Seite ist die Anzahl der Kategorien bei der Analyse von subjektiven Texten oft auf eine sehr geringe Anzahl beschränkt, so dass man Kategorien für "positiv" und "negativ" und Abwandlungen dieser wie "sehr positiv" bildet. Diese Kategorisierung ist allgemeiner und kann damit auch für verschiedene Anwendungsfälle gleich bleiben. Zusätzlich besteht zwischen den einzelnen Kategorien in diesem Fall ein Zusammenhang, während es bei der Themen-basierenden Kategorisierung auch zu Kategorien kommen kann, die untereinander in keinem Bezug stehen.

Nach [13] kann eine Meinung durch eine Quintupel aus den fünf Einheiten e_i , a_{ij} , o_{ijkl} , h_k und t_l beschrieben werden. Mit e_i wird der Name einer Entität beschrieben. Eine Entität kann beispielsweise ein Produkt, ein Ereignis oder ein Thema sein. In dieser Arbeit ist die Entität mit dem Thema "Bitcoin" fest belegt. Mit a_{ij} wird ein Aspekt von der Entität e_i beschrieben. Da die öffentliche Meinung über das Thema "Bitcoin" im Allgemeinen gemessen werden soll, wird hier e_i mit "GENERAL" fest belegt. Mit o_{ijkl} wird die Orientierungsrichtung der Meinung angegeben, also beispielsweise "positiv", "negativ" oder "neutral". Hier o_{ijkl} kann also eine Kategorisierung erfolgen. Dies ist der hier relevante Aspekt, welcher durch ein geeignetes Klassifizierungswerkzeug ermittelt werden soll. Mit h_k wird beschrieben, wer die Meinung ausgedrückt hat. Die einzelne Person ist hier unwesentlicher Aspekt, da es bei der Messung der öffentlichen Meinung um Gesamtverhältnisse und nicht um einzelne Meinungen geht. Mit t_l wird der Zeitpunkt beschrieben, zu dem die Meinung geäußert wurde. Der Zeitpunkt wird hier immer in Monatsintervallen angegeben, so dass t_l einen Monat beinhaltet. Eine Meinung im Rahmen dieser Arbeit ist damit vollständig beschrieben durch: ("Bitcoin", "GENERAL", o_{ijkl} , h_k , t_l). Untersucht werden muss also die Meinung o_{ijkl} - die später einer Kategorie zugeordnet wird - welche zum Zeitpunkt t_l vorgelegen hat.

Die Genauigkeit der Ergebnisse einer Sentiment-Analyse kann mit der Übereinstimmung einer menschlichen Beurteilung gemessen werden. Dabei ist allerdings zu erwähnen, dass Untersuchungen [18] gezeigt haben, dass menschliche Beurteilungen in nur 79% der Fälle übereinstimmen. Damit wäre eine Sentiment-Analyse, die eine 70% Übereinstimmung aufweist, bereits sehr nah an der menschlichen Beurteilung. Ein Problem der Einzelklassifizierung ist jedoch, dass eine Aggregation, um ein Gesamtverhältnis bestimmen zu können, zu einem Bias⁵ führen kann [9]. Der Grund ist, dass bei der Einzelklassifizierung ein Übereinstimmungswert von beispielsweise 80% zwar sehr gut ist, jedoch könnte man im schlechtesten Fall mit 20% immer in eine Richtung beziehungsweise in eine Kategorie K abweichen. Bestimmt man nun die Anteile der einzelnen Kategorien am Gesamtverhältnis, dann wäre der Anteil an der Kategorie K mit 20% erhöht und verfälscht. Somit ist selbst eine sehr gute Einzelklassifizierung nicht geeignet, um Anteile der Kategorien an der Grundgesamtheit zu bestimmen. Im Kapitel 4.4.3 werden beide Verfahren gegenübergestellt und eine Entscheidung bezüglich des Verfahrens von [9] begründet.

⁵ Der Bias, oder auch Verzerrung genannt, ist in der mathematischen Statistik die Abweichung des Erwartungswertes vom wahren Wert. Ein erwartungstreuer Schätzer hat dabei keine Verzerrung, also einen Bias von 0.

Bei vielen Sentiment-Analysen ist das Ziel, möglichst exakt einen einzelnen Text in eine bestehende Kategorie zu klassifizieren. Für viele Anwendungsfälle ist diese Einzelklassifizierung auch das gewünschte Ziel. Beispielsweise möchte man eingehende Beschwerdemails so klassifizieren, dass sie automatisch dem besten dafür geeigneten Mitarbeiter zur Bearbeitung weitergeleitet werden können. Oft ist aber auch der Anteil der einzelnen Kategorien an der Grundgesamtheit interessant. Im angeführten Beispiel könnte es interessant sein zu bestimmen, in welchen Bereichen die meisten Beschwerden vorliegen. Für Sozialwissenschaftler ist genau dieses Gesamtverhältnis interessant: *wie ist die Verteilung der Klassifikationen in der Grundgesamtheit?* Die Klassifikation von *einem* bestimmten Text hat dabei eine geringere Bedeutung - ob beispielsweise der Autor *eines* Blog-Eintrags ein neues Produkt gut oder schlecht findet ist nicht so relevant wie die Ermittlung, wie viele Blogger insgesamt das Produkt positiv bzw. negativ beurteilen.

Da für die Ermittlung der öffentlichen Meinung die Verteilungen in der Grundgesamtheit interessant sind, wird für diese Ermittlung ein Klassifikations-Verfahren von Hopkins und King angewendet, das speziell dafür ausgerichtet worden ist. Die Vorstellung des dahinterliegenden Modells findet im nächsten Unterkapitel statt.

3.2 Notation und Modelldefinition

Die hier verwendete Notation ist an [9] und [11] angelehnt.

Im Folgenden wird anstelle von einem Text, der klassifiziert werden soll, von einem Dokument gesprochen, in dem dieser Text gespeichert ist. Die Gesamtmenge aller Dokumente wird in zwei nichtleere Mengen aufgeteilt: eine markierte Menge M und eine unmarkierte Menge U . In M sind alle Dokumente enthalten, die im Vorfeld bereits klassifiziert wurden. Diese Menge ist mit dem *Lernvektor* oder auch *Trainingsset* aus dem maschinellen Lernen vergleichbar. In U befinden sich alle noch zu klassifizierenden Dokumente. Dies ist im maschinellen Lernen das *Test Set*. In der Regel sind weniger Elemente in M als in U , es gilt: $|M| < |U|$. Zusätzlich ist eine Schnittmenge von M und U erlaubt, so dass $M \cup U = \emptyset$ nicht immer gelten muss. Es ist also erlaubt, Dokumente zu klassifizieren, die später mit in die Analyse einfließen.

Die möglichen Kategorien j ($j=1, \dots, J$) sind kodiert, so dass über eine Zuordnung jedem j ein für das Modell angemessener Wert zugeordnet werden kann. Mit $j=1$ könnte beispielsweise "*sehr negativ*" verknüpft sein, mit $j=3$ "*neutral*" und mit $j=5$ "*sehr positiv*". Jedem Dokument i ($i=1, \dots, I$) in M wird eine Kategorie j ($j=1, \dots, J$) zugeordnet, so dass gilt: $D_i = j$. Jedes Dokument l ($l=1, \dots, L$) in U hat eine unbeobachtete Klassifikation D_l . Die Gesamtanzahl aller Dokument ist damit $N = I + L$.

Alle benötigten Informationen werden direkt aus den Dokumenten berechnet. Es werden die binäre Variablen S_{ik} und S_{lk} eingeführt, die angeben, ob der Wort-Stamm k im Dokument i von M bzw. im Dokument l von U vorhanden ist:

$$S_{ik} = \begin{cases} 1, & \text{falls Wort-Stamm } k \text{ (} k=1, \dots, K \text{) mindestens einmal im} \\ & \text{Dokument } i \text{ (} i=1, \dots, I \text{) genutzt wurde} \\ 0, & \text{sonst} \end{cases}$$

$$S_{lk} = \begin{cases} 1, & \text{falls Wort-Stamm } k \text{ (} k=1, \dots, K \text{) mindestens einmal im} \\ & \text{Dokument } l \text{ (} l=1, \dots, L \text{) genutzt wurde} \\ 0, & \text{sonst} \end{cases}$$

Wie bereits im Unterkapitel 3.1 beschrieben, sind für viele gängige Anwendungsfälle vor allem die Klassifizierungen der einzelnen Dokumenten in U interessant, d.h. von $\{D_1, \dots, D_L\}$. Das Interesse soll hier aber auf die Verteilungen in der Grundgesamtheit gelegt werden. Es ist also von Interesse, wie hoch der Anteil der Dokumente ist, die in die einzelnen Kategorien fallen:

$$P(D = j) = \frac{1}{L} \sum_{i=1}^L \mathbf{1}(D_i = j)$$

$P(D)$ ist multinomialverteilt und gibt zu jeder Kategorie j an, wie hoch ihr Anteil an der Grundgesamtheit ist. $P(D)$ kann damit J mögliche Werte annehmen.

4. ANALYSE

Dieser Abschnitt beschreibt die einzelnen Schritte, die gemacht wurden, um die Analyse durchzuführen. Anschließend werden die Resultate der Analyse präsentiert und eine Interpretation dessen vorgestellt.

4.1 Analyseziel

Mit der hier vorgestellten Analyse ist es möglich, die öffentliche Meinung zu Bitcoin in einem Zeitverlauf grafisch darzustellen und diese Darstellung vor dem Hintergrund bedeutender Entwicklungen in der Bitcoin-Historie zu interpretieren. Es wird gezeigt, dass sich die Meinungen im Zeitverlauf verändern und dass diese Veränderung in einem Zusammenhang mit der Entwicklung des Bitcoin Handelspreises stehen kann. Ziel der Analyse ist es also, eine Basis zu schaffen, die solche Interpretationen ermöglicht. In einem ersten Schritt wurden 3958 Blog-Einträge zum Thema "Bitcoin" gesammelt, anschließend 250 Einträge manuell klassifiziert und diese Klassifikationen als Trainingsset genutzt, um die restlichen Blog-Einträge zu klassifizieren. Nach der Klassifikation wurde das öffentliche Stimmungsbild zu "Bitcoin" untersucht und ein Lead-Indikator erstellt, der frühzeitig Entwicklungen im Bitcoin-System anhand dieses Stimmungsbildes aufzeigen kann.

4.2 Datenbasis

Da Bitcoin als digitales Buchhaltungssystem momentan ausschließlich über das Internet betrieben wird, sind die Meinungen über Bitcoin im Internet von sehr relevanter Bedeutung. Als Datenbasis wurden Einträge aus der Blogosphäre gesammelt. Ein Blog - die Abkürzung für "web log" - ist eine üblicherweise umgekehrt chronologisch aufgebaute Webseite, in der der Verfasser über verschiedene Themen diskutieren und informieren kann.

Auf Tumblr, einer der größten Blogging-Plattformen weltweit, gibt es über 109,5 Millionen verschiedene Blogs mit über 51,1 Milliarden Einträgen [21]. Auf einer anderen großen Plattform, Wordpress, gibt es über 66 Millionen verschiedene Blogs. Über 368 Millionen Leute sehen sich auf Wordpress-Blogs mehr als 4,1 Milliarden Seiten pro Monat an [22]. Diese Popularität und auch die noch heutzutage große Bedeutung von Blogs zeigt sich unter anderem auch durch die Übernahme von Tumblr durch das kalifornische Internetunternehmen YAHOO! im Mai 2013 für 1,1 Milliarden US-Dollar [23]. Blogs sind also in ihrer Gesamtheit ein gutes Instrument, um verschiedene Meinungen und Ansichten auszudrücken. Für Sozialwissenschaftler sind sie damit auch eine gute Datenquelle, um genau solche Meinungen analysieren zu können. Da Blogs, wie oben dargestellt, sehr weit verbreitet sind, bilden sie in einem gewissen Rahmen auch einen Teil der

öffentlichen Meinung ab. All das sind Gründe dafür, dass für die Analyse Einträge aus der Blogosphäre herangezogen worden sind.

Um möglichst viele verschiedene Blogs als Datenquelle nutzen zu können, reicht es nicht aus die beiden oben genannten Blogging-Plattformen nach relevanten Blogs zum Thema "Bitcoin" zu durchsuchen. Stattdessen wurde auf die Google Blog Search Engine⁶ zurückgegriffen, die ähnlich wie die normale Google Suche aufgebaut ist. Google Blog Search ist im Jahr 2005 gestartet und ist die erste Search Engine, die eine Volltext-Suche von Blogs erlaubt [20].

Ein großer Vorteil dieser Engine ist, dass man dort die Suchergebnisse auf einen bestimmten Zeitraum eingrenzen kann.⁷ Diese Einstellungsmöglichkeit ist deswegen wichtig, weil man damit die Blog-Einträge in verschiedene Zeiträume unterteilen kann, um so einen Verlauf und Trends der verschiedenen Meinungen abbilden zu können. Neben dem Zeitraum wurde noch ein weiterer Filter gesetzt, der nur englisch-sprachige Blogs in die Suche mit einschließt.⁸

Die Zeiträume wurden dabei so eingeteilt, dass jeweils ein ganzer Monat in Betracht gezogen wurde. Als letzter Monat wurde der Mai 2013 gewählt, um so aktuelle Meinungen einholen zu können. Als absolute untere Schranke der Zeiträume wird das Jahr 2008 festgelegt, weil erst in diesem Jahr das Whitepaper, welches das Konzept von Bitcoin erläutert, von Satoshi Nakamoto vorgestellt wurde. Jedoch liegt der Anteil der Blog-Einträge in diesem Jahr bei unter 50 pro Monat, so dass die untere Schranke auf Januar 2012 verschoben wurde. Ab diesem Monat gibt es mit etwa 200 Blog-Einträgen im Monat eine ausreichende Datenbasis, welche die öffentliche Meinung deutlicher abbilden kann. Werden zu wenige Daten pro Monat analysiert, kann dies zu einem verfälschten Meinungsbild führen welches wenig repräsentativ für die Meinung in der Öffentlichkeit wäre.

Somit wird für jeden Monate zwischen Januar 2012 und Mai 2013 eine neue Suchanfrage erstellt, deren Ergebnisse anschließend in die Datenanalyse einfließen.

4.3 Prozess der Datenauslese

Die Ergebnisse dieser einzelnen Suchanfragen wurden manuell gespeichert⁹, so dass der HTML-Code zur weiteren Analyse vorliegt. Die Alternative, die Suchergebnisse über einen Bot automatisch speichern zu lassen, verbieten die *Google Terms of Service*¹⁰. Die einzelnen Suchergebnisse wurden mit Hilfe eines Java-Programms (*SearchResultParser*) geparkt, so dass für jeden Zeitraum eine Liste von den URLs der Suchergebnisse erstellt

⁶ www.google.com/blogsearch

⁷ Die Google API erlaubt eine erweiterte Suche über den Parameter `tbs`, in dem mit `cd_min` und `cd_max` verschiedene Zeiträume angegeben werden können. Soll beispielsweise nur im März gesucht werden, wäre folgender Parameter (-wert) zu verwenden:

```
tbs=cd_min:3/1/2013,cd_max:3/31/2013
```

⁸ Der Parameter für diesen Filter ist:

```
lr=lang_en
```

⁹ Es bietet sich an, die Sucheinstellungen in Google so anzupassen, dass die maximale Anzahl an Ergebnissen pro Seite (100) angezeigt wird.

¹⁰ <http://www.google.com/policies/terms/>

werden konnte. Diese Liste wurde anschließend von einem weiteren Java-Programm (*BlogDownloader*) abgearbeitet, so dass jeder einzelne Blog-Eintrag heruntergeladen und in einem eigenen Dokument gespeichert wurde. Viele Blog-Seiten besitzen neben dem eigentlichen Beitrag auch noch eine Navigationsleiste, Bilder, Verweise auf ähnliche Beiträge, Informationen über den Autor und vieles mehr. All diese für die eigentliche Analyse nicht wichtigen Informationen wurden aus den Dokumenten entfernt. Dazu wurde die Funktionalität von *Readability*¹¹ genutzt, welche aus einem vorhandenen Dokument - wie zum Beispiel der Inhalt einer Webseite - den eigentlichen Beitrag extrahieren kann. Damit dies nicht für jeden einzelnen Blog-Eintrag manuell gemacht werden muss, wurde eine angepasste Version (*ReadabilityFormater*) eines PHP Ports zu *Readability* genutzt [10], welches automatisch alle heruntergeladenen Dokumente analysiert und den eigentlichen Beitrag der Blogs in einem neuen Dokument speichert. Der Ablauf dieses Prozesses ist in Abbildung 1 dargestellt.

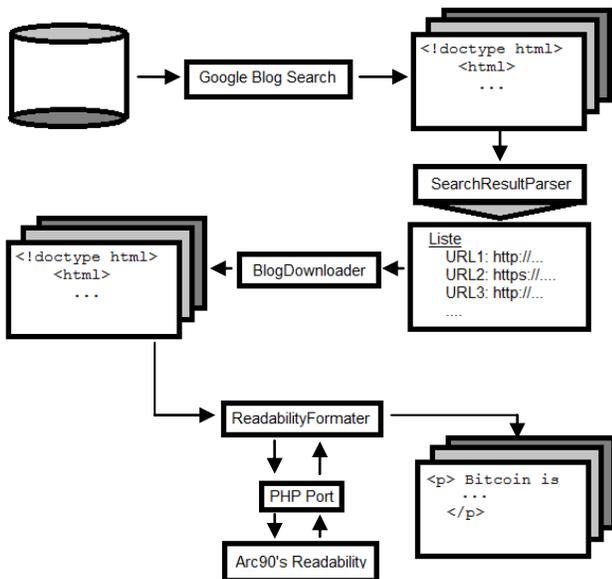


Abbildung 1. Prozess der Datenauslese

4.4 Datenanalyse

Bevor mit der eigentlichen Datenanalyse begonnen werden kann, werden im Vorfeld bereits einige der zuvor ausgelesenen Dokumente klassifiziert. Die Klassifizierung lehnt sich an Hopkins und King an und ist in Tabelle 1 beschrieben. Die Menge der möglichen Kategorien ist vollständig, da sowohl Blog-Einträge mit oder ohne Meinungen, sowie keine Blogs betrachtet werden. Alle klassifizierten Dokumente befinden sich in der Menge M , alle nicht-klassifizierten Dokumente in der Menge U . Die Menge der Dokumente in M werden im überwachten Lernen auch Trainingsset genannt, weil damit das Modell "trainiert" wird. Die Erstellung des Trainingsset ist also die Vorarbeit die geleistet werden muss, damit die Analyse gestartet werden kann. Für das hier erstellte Trainingsset wurden jeweils die ersten 25 Dokumente von August 2012 bis Mai 2013 eingesetzt. Insgesamt ergeben sich damit 250 Dokumente, die manuell klassifiziert wurden.

¹¹ <http://www.readability.com/>

Tabelle 1. Kodierung der Kategorien

Kategorie j im Model	Kodierung im Model	Bedeutung
$j=1$	-2	sehr negativ
$j=2$	-1	negativ
$j=3$	0	neutral
$j=4$	1	positiv
$j=5$	2	sehr positiv
$j=6$	3	kein Blog
$j=7$	4	keine Meinung

4.4.1 Klassifikationsbeispiele

Wie in Tabelle 1 dargestellt gibt es insgesamt 7 Kategorien, in denen ein Blog-Eintrag klassifiziert werden kann. Es werden nun einige Beispiele vorgestellt, die die hier gewählte Zuordnung von Blog-Einträgen zu einer Kategorie nachvollziehbar machen.

4.4.1.1 sehr negativ

In [24] wird sehr stark und einseitig von den negativen Seiten von Bitcoin berichtet und auch davor gewarnt, Bitcoins zu nutzen. Der Autor warnt beispielsweise davor, dass staatliche Stellen in Zukunft in das Bitcoin-System eingreifen werden, weil es auch für illegale Zwecke genutzt wird. Das habe nach Meinung des Autors zur Folge, dass der Wechselkurs von Bitcoin zu US-Dollar auf 0 fallen wird und dort auch bleibt. Es gibt sogar eine Diskussion über diesen Blog-Eintrag im *bitcointalk*-Forum¹². Diese einseitige Betrachtungsweise und die Stärke der Warnungen und Formulierungen¹³ macht diesen Blog-Eintrag zu *sehr negativ*.

4.4.1.2 negativ

In [25] listet der Autor einige negative Kritikpunkte zu Bitcoin auf. So sei der große Bitcoin Marktplatz Mt. Gox sehr stark mit der Regierung verknüpft, welches staatlichen Einfluss auf das Bitcoin-System erlauben könnte. Ein großes Problem sei auch in der Struktur des Bitcoin-Systems, welches zur Deflation führe. Obwohl auch positive Aspekte von Bitcoin angesprochen werden¹⁴ überwiegen klar die negativen Aspekte in diesem Blog-Eintrag. Daher wird dieser Eintrag mit *negativ* bewertet.

4.4.1.3 neutral

Mit *neutral* werden Blog-Einträge klassifiziert, die im gleichen Maße negative und positive Aspekte von Bitcoin ansprechen. In [26] werden in gleichem Maße positive Aspekte¹⁵ als auch negative Aspekte¹⁶ angesprochen. Damit ist dieser Blog-Eintrag *neutral*.

4.4.1.4 positiv

Mit *positiv* werden Blog-Einträge klassifiziert, welche zum überwiegenden Teil positive Aspekte von Bitcoin beinhalten. So werden in [27] einige Vorteile von Bitcoin angepriesen, wie schnelle und kostengünstige Transaktionen. Auf der anderen Seite

¹² <https://bitcointalk.org/index.php?topic=142341.0>

¹³ "BTC is an epic bubble"

¹⁴ "Bitcoin is already one of the most functional currencies in the history of humanity"

¹⁵ "This has some very neat advantages, the largest being that no one entity controls Bitcoin"

¹⁶ "I just don't see it having the right attributes to break out into a larger world of consumer spending"

werden im geringen Maße auch negative Punkte angesprochen, wie beispielsweise eine Zurückhaltung von Unternehmen und Verbrauchern vor Bitcoin, weil sie Betrügereien erwarten könnten.

4.4.1.5 sehr positiv

Ein Blog-Eintrag wird als *sehr positiv* klassifiziert, wenn er ausschließlich positive Aspekte über Bitcoin anspricht und auch in seiner Formulierung einen positiven Gesamteindruck über Bitcoin hinterlässt. So werden in [28] viele Vorteile von Bitcoin im Zusammenhang mit Online Poker erläutert, wie beispielsweise die geringen Transaktionsgebühren. Die Ausdrucksweise der Formulierungen sind ferner sehr positiv¹⁷.

4.4.1.6 kein Blog

Mit *kein Blog* werden Blog-Einträge klassifiziert, die nach der Formatierung durch den *ReadabilityFormater* keinen Beitrag in Textform mehr enthalten haben. Manche [29, 30, 31] Blog-Einträge bestehen beispielsweise nur aus einem Video, welches mit dem hier eingesetzten Klassifikationswerkzeug ReadMe nicht analysiert werden kann.

4.4.1.7 keine Meinung

Ist ein Blog-Eintrag nur informativ, beinhaltet also beispielsweise nur Fakten über Bitcoin, wird er als *keine Meinung* klassifiziert. In [32] wird über die Bestellung einer Pizza im Mai 2010 berichtet, welche als die erste Bitcoin-Transaktion gilt, bei der jemand ein echtes Gut gekauft hat [2]. Der Autor drückt in seinem Blog-Eintrag allerdings *keine Meinung* aus.

4.4.2 Genauigkeit des Trainingsset

Nach der Klassifizierung der Dokumente wurde die Genauigkeit des Trainingsset untersucht. Dazu wurde eine 2-fache Kreuzvalidierung durchgeführt, die beim überwachten Lernen oft zur Verbesserung des Trainingsset eingesetzt wird [1]. M wurde in zwei gleich große Mengen M_1 und M_2 aufgeteilt. Die Dokumente in M_1 wurden als Trainingsset genutzt, um den Anteil der Kategorien der Dokumente in M_2 zu ermitteln. Die Daten dazu sind in Tabelle 2 abgebildet: "Berechnet" beschreibt den ermittelten Anteil je Kategorie; "Wahr" beschreibt den Anteilswert, der durch die Klassifikation im Vorfeld bereits erstellt wurde; "QA" ist die quadrierte Abweichung dieser beiden Werte. Die Summe von "QA" ist in der letzten Zeile der Tabelle 2 abgebildet. In Abbildung 2 sind die Werte für die "berechneten" und "wahren" Anteile der Kategorien abgebildet. Auf der Abszisse sind die *wahren* Anteilswerte, auf der Ordinate die *berechneten* Anteilswerte abgebildet. Wären diese beiden Werte gleich, würden sie auf der 45° Linie, die ebenfalls eingezeichnet ist, liegen. Analog dazu wurden die Dokumente in M_2 als Trainingsset genutzt, um die Anteilswerte der Dokumente in M_1 zu berechnen. Die Werte dazu stehen in Tabelle 3 und die berechneten Kategorie-Anteile sind in Abbildung 3 dargestellt. Da die Summe der quadrierten Abweichungen in beiden Fällen sehr gering ist (0,016 im ersten Fall und 0,005 im zweiten Fall), sind die klassifizierten Dokumente in M insgesamt gut als Trainingsset geeignet, um die Kategorie-Anteile der übrigen Dokumente in U zu bestimmen. Die hier genutzten Klassifizierungen sind öffentlich verfügbar.¹⁸

Tabelle 2. Ergebnisdaten der Kreuzvalidierung M_1 *

Kategorie	-2	-1	0	1	2	3	4
Berechnet	.010	.080	.137	.163	.098	.134	.378
Wahr	.056	.087	.087	.095	.063	.167	.444
QA	.002	.000	.002	.005	.001	.001	.004
QA*1000	2.052	0.060	2.478	4.551	1.225	1.078	4.410
Σ QA	0,016						

*Zahlen auf 3 Nachkommastellen gerundet

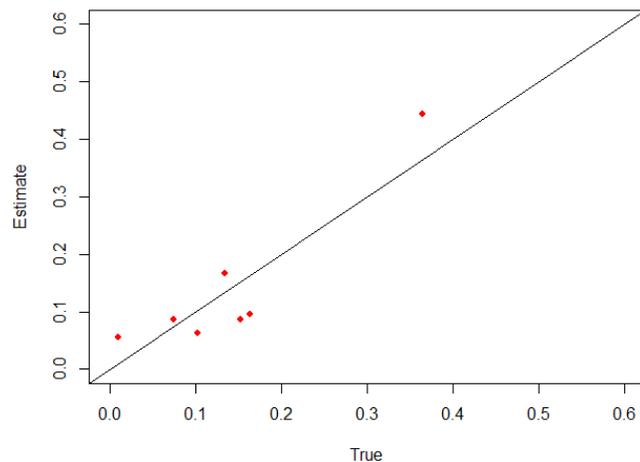


Abbildung 2. Kreuzvalidierung mit M_1 als Trainingsset

Tabelle 3. Ergebnisdaten der Kreuzvalidierung M_2 *

Kategorie	-2	-1	0	1	2	3	4
Berechnet	.050	.058	.089	.106	.062	.158	.477
Wahr	.008	.056	.105	.153	.048	.145	.484
QA	.002	.000	.000	.002	.000	.000	.000
QA*1000	1.772	.001	.239	2.207	.188	.157	.049
Σ QA	0,005						

*Zahlen auf 3 Nachkommastellen gerundet

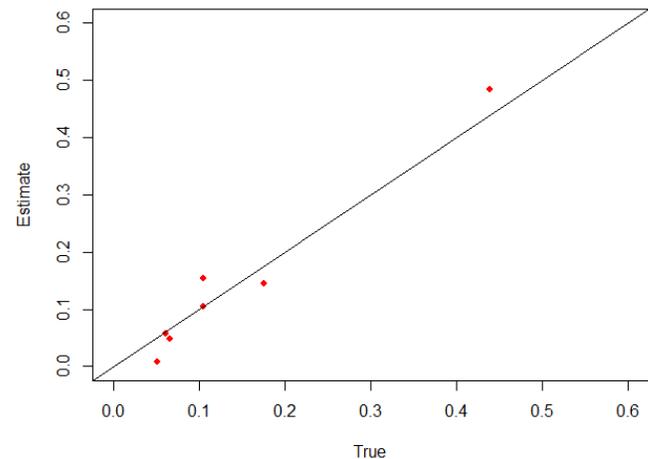


Abbildung 3. Kreuzvalidierung mit M_2 als Trainingsset

¹⁷ "Bitcoin is one of the most amazing feats of human technical achievement I have witnessed in my lifetime"

¹⁸ <https://dl.dropboxusercontent.com/u/25485809/bitcoin.zip>

4.4.3 Berechnung der Anteilswerte durch ReadMe

Das hier eingesetzte Klassifikationswerkzeug ReadMe hat zur Berechnung der Anteilswerte der jeweiligen Kategorien folgende grobe Vorgehensweise. Im ersten Schritt werden die Wörter des Textes auf Kleinbuchstaben konvertiert und alle Satz- und Sonderzeichen aus dem Dokument entfernt. Anschließend werden die einzelnen Wörter auf ihren Wort-Stamm reduziert. Bei den Wörtern "überzeugend", "überzeugte" und "Überzeugung" wäre der Wort-Stamm beispielsweise "überzeugt". Die Anzahl der Wort-Stämme pro Monat sind in Tabelle 4 dargestellt und liegen in Bereich von 2611 bis 3310.

Tabelle 4. Anzahl der Wort-Stämme pro Monat

2012 -01	2012 -02	2012 -03	2012 -04	2012 -05	2012 -06	2012 -08	2012 -09
2898	2875	2625	2674	2689	2611	2762	2695
2012 -10	2012 -11	2012 -12	2013 -01	2013 -02	2013 -03	2013 -04	2013 -05
2846	3053	2688	2768	2643	2686	2915	3310

Bei einem zu klassifizierenden Dokument aus U wird überprüft, welche Wort-Stämme in diesem vorkommen. Diese Wort-Stämme werden mit den Wort-Stämmen aus den manuell klassifizierten Dokumenten aus M verglichen, um so die Wahrscheinlichkeit $P(D = j)$ zu bestimmen, dass das zu klassifizierende Dokument in Kategorie j gehört. [9]

4.4.4 Einzelklassifikation

Um die Anteile der Kategorien an der Grundgesamtheit zu bestimmen, wurde das Klassifikationswerkzeug ReadMe genutzt. Eine andere Möglichkeit wäre, jedes Dokument einzeln - mit einer anderen Methode - zu klassifizieren und anschließend aus den Einzelklassifizierungen die Anteile zu berechnen.

Zur Überprüfung, wie genau eine Einzelklassifizierung wäre, wird eine solche Klassifizierung mit SentiWordNet¹⁹ durchgeführt. Dabei werden die Dokumente aus M klassifiziert. Somit kann man anschließend die Ergebnisse der Klassifizierung von SentiWordNet mit der "wahren", also manuellen, Klassifizierung vergleichen. Anschließend wurden die Abweichungen der "wahren" von der berechneten Klassifizierung von allen 250 Dokumenten aus M ermittelt und die Anteile der so erhaltenden Abweichungen bestimmt. In Abbildung 4 sind diese Anteile dargestellt.

Man erkennt, dass das Ergebnis der Klassifizierung durch SentiWordNet in ungefähr 65% der Fälle gleich mit der "wahren" Beurteilung ist - die Abweichung ist also null. Für eine Einzelklassifizierung ist dies ein guter Wert, wie Unterkapitel 3.1 bereits gezeigt wurde. Zu überprüfen sind im nächsten Schritt allerdings noch die Anteile der Kategorien insgesamt an der Grundgesamtheit.

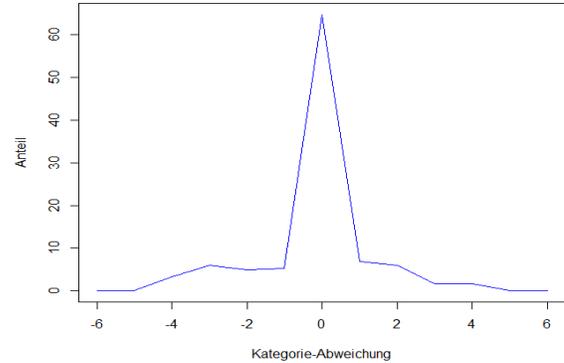


Abbildung 4. Kategorie-Abweichungen bei Einzelklassifizierung

Zur Bestimmung, in welche Kategorien ein Dokument eingeordnet wird, wird bei SentiWordNet ein Score S berechnet, dessen Wert das Stimmungsbild im Dokument wiedergibt. Ein sehr negativer Wert bedeutet zum Beispiel, dass das Dokument insgesamt in die Kategorie "sehr negativ" klassifiziert wird. Der Score wird dabei nach folgender Definition berechnet:

$$D_i = \begin{cases} -2 & \text{wenn } S \leq -0,75 \\ -1 & \text{wenn } -0,75 < S < 0 \\ 0 & \text{wenn } S = 0 \\ 1 & \text{wenn } 0 < S < 0,75 \\ 2 & \text{wenn } S \geq 0,75 \end{cases}$$

Problematisch ist, dass es dabei einen festen Zusammenhang zwischen diesen Kategorien geben muss, denn alle Kategorien beziehen sich auf den einen berechneten Wert des Score. Möchte man beispielsweise eine Kategorie "keine Meinung" einfügen, müsste man für diese Kategorie einen Wert bestimmen, ab wann dieser gelten soll. Man könnte dafür einen Wert von 0 nehmen, jedoch ist dieser Wert bereits mit der Kategorie "neutral" belegt. Beim Klassifizierungswerkzeug ReadMe sind solche Zusammenhänge zwischen den einzelnen Kategorien nicht nötig [9], so dass weitere Kategorien wie "keine Meinung" und "kein Blog" problemlos eingeführt werden können. Es zeigt sich außerdem, dass die Ränder des Scores, also $D_i = -2$ und $D_i = 2$ im Vergleich zu den übrigen Kategorien sehr stark ausgeprägt sind. Dies sieht man in Abbildung 5, wo der Anteil der *sehr negativen* Kategorie rot und der Anteil an der *sehr positiven* Kategorie grün dargestellt ist. Der Anteilswert von SentiWordNet ist jeweils der zweite Balken.

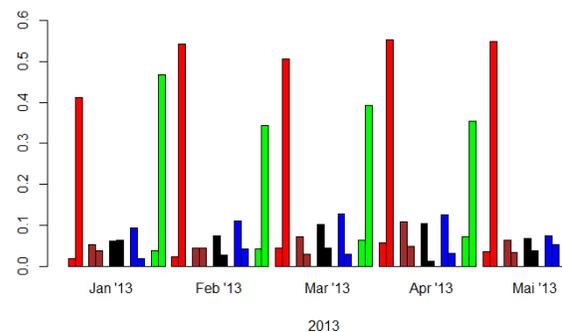


Abbildung 5. Vergleich von SentiWordNet und ReadMe

Der erste Balken ist der Anteil von ReadMe, der zweite Balken von SentiWordNet. Die roten Balken zeigen den Anteil der *sehr negativen* Meinungen, die braunen Balken den Anteil der *negativen* Meinungen, die schwarzen Balken den Anteil der *neutralen* Meinungen, die blauen Balken den Anteil der *positiven* Meinungen und die grünen Balken den Anteil der *sehr positiven* Meinungen.

¹⁹ <http://sentiwordnet.isti.cnr.it/> - Hier wurde eine leicht angepasste Version genutzt, welche ebenfalls mit dem zusätzlichen Material zur Verfügung gestellt wird.

Ein Grund dafür könnte sein, dass es dort in der Definition offene Grenzen gibt - mit jeweils größer beziehungsweise kleiner als 0,75. Die Definition, wie der Score Einfluss auf die Kategorisierung nimmt, ist somit bei der Einzelklassifizierung von entscheidender Bedeutung. Da es jedoch kein strukturiertes Vorgehen zur Bestimmung einer solchen Definition gibt, wird auf das Klassifizierungswerkzeug ReadMe zurückgegriffen, welches eine solche Problematik nicht hat. Im Vergleich von SentiWordNet mit ReadMe (Abbildung 5) erkennt man zudem, dass es auch bei den Anteilen der anderen Kategorien teils große Unterschiede gibt, wie beispielsweise im April der Anteil der positiven (blau) und neutralen (schwarz) Kategorien. Wegen der Problematik der Definition des Score und der offenen Grenzen an den Rändern der Klassifikation bei der Einzelklassifizierung wurde ReadMe in der Auswahl bevorzugt.

4.5 Analyseergebnisse

In den folgenden Unterabschnitten werden die einzelnen Analyseergebnisse präsentiert.

4.5.1 Bloganzahl

In Abbildung 6 werden die Anzahl der analysierten Blog-Einträge pro Monat dargestellt. Insgesamt wurden 3958 Blog-Einträge analysiert. Man erkennt in der Abbildung einen leichten Trend zu mehr Blog-Einträgen. Wurden im Januar 2012 noch knapp über 200 relevante Einträge analysiert, gab es im Mai 2013 fast 350 relevante Einträge. Das kann ein Indiz für ein gestiegenes Interesse an dem Thema "Bitcoin" in der Blogosphäre - und auch in der Öffentlichkeit allgemein - sein.

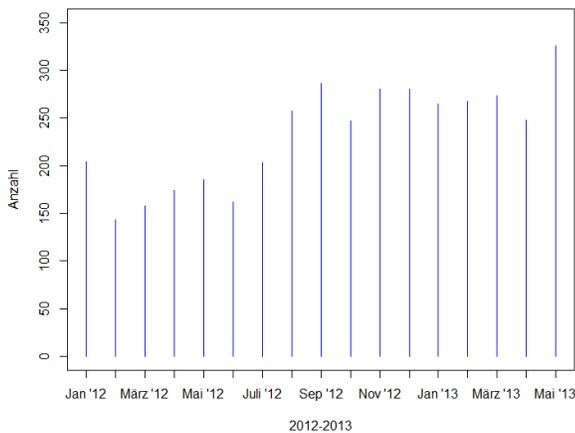


Abbildung 6. Anzahl der analysierten Blogs

4.5.2 Stimmungsbild in der Blogosphäre

In der Abbildung 7 sind die Anteile der Kategorien $j = \{-2, -1, 0, 1, 2\}$ dargestellt, die aus der Klassifikation aller Blog-Einträge entstanden sind. Von Januar bis Juni 2012 sind die Anteile der verschiedenen Kategorien in etwa gleichverteilt. Ab Juli 2012 sinkt der Anteil der *sehr negativen* Meinungen (rot), bis dieser Anteil im April 2013 wieder steigt. Dagegen steigt der Anteil der *positiven* Meinungen (blau) ab Dezember 2012 stark an, bis er im April 2013 wieder fällt. Zwei Monate nach dem Anstieg der positiven Meinungen, im Februar 2013, steigt auch der Anteil der negativen Meinungen (braun). Zwischen Dezember 2012 und Februar 2013 gab es also mehr positive als negative Meinungen zu Bitcoin. Der in Kapitel 4.5.3 vorgestellte Lead-Indikator

veranschaulicht diese Entwicklung. Ab April sinkt der Anteil aller Kategorien. Da in der Abbildung 7 nur die Kategorien dargestellt sind, die eine Meinung beinhalten, bedeutet dieser Abfall, dass der Anteil der objektiven Meinungen in diesem Zeitraum gestiegen ist.

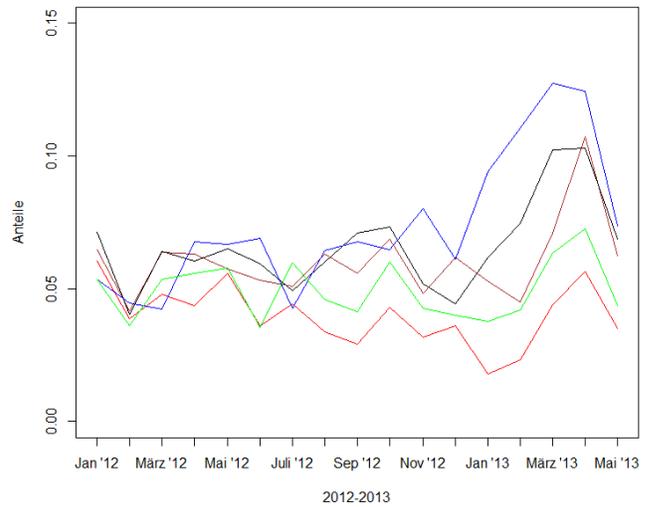


Abbildung 7. Stimmungsbild in der Blogosphäre

Die rote Kurve zeigt den Anteil der *sehr negativen* Meinungen, die braune Kurve den Anteil der *negativen* Meinungen, die schwarze Kurve den Anteil der *neutralen* Meinungen, die blaue Kurve den Anteil der *positiven* Meinungen und die grüne Kurve den Anteil der *sehr positiven* Meinungen.

In Abbildung 8 ist der Anteil der objektiven Meinungen dargestellt, welcher in diesem Zeitraum besonders hoch ist. Viele Blogger haben also im Mai mehr über das Thema "Bitcoin" informiert als eine Meinung ausgedrückt. In dieser Abbildung sind die *positiven* und *sehr positiven* Meinungen in der grünen Kurve zusammen abgebildet. Analog dazu wurden die *negativen* und *sehr negativen* Meinungen in der roten Kurve abgebildet. Die *neutralen* Meinungen bleiben im Zeitverlauf relativ konstant.

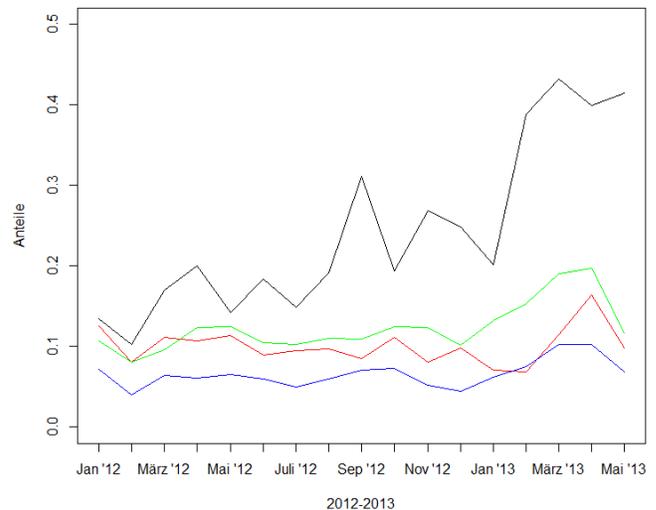


Abbildung 8. Aggregiertes Stimmungsbild in der Blogosphäre

Die rote Kurve zeigt den Anteil aller *negativen* Meinungen, die blaue Kurve den Anteil der *neutralen* Meinungen und die grüne Kurve den Anteil aller *positiven* Meinungen. Die schwarze Kurve zeigt den Anteil der objektiven Blogbeiträge.

Ein Grund für den Anstieg der *positiven* Meinungen kann der Anstieg des Bitcoin-Handelspreis sein, welcher in Abbildung 9 dargestellt ist. Gerade in der Phase des Anstieges im Februar und März 2013 ist der Anteil der *positiven* Meinungen insgesamt am Höchsten, wohingegen der Anteil der *negativen* Meinungen im Februar 2013 sogar seinen Tiefstwert erreicht. Auf der anderen Seite sinkt der Anteil der *positiven* Meinungen nach dem Absturz des Handelspreises im April 2013 wieder. Bemerkenswert ist, dass der Anteil der *negativen* Meinungen im gleichen Zeitraum ebenfalls fällt. Ein Grund kann sein, dass viele Blogger bereits im April zum Zeitpunkt des Absturzes ihren Unmut ausgedrückt haben, weswegen der Anteil der negativen Meinungen in diesem Zeitraum ebenfalls hoch ist.

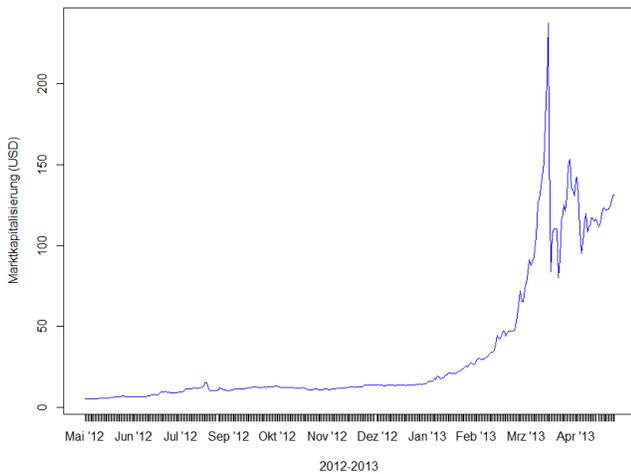


Abbildung 9. Bitcoin Handelspreis

Die Abbildung 9 zeigt den Marktpreis von Bitcoin beim größten Marktplatz [3] Mt. Gox in US-Dollar. Im Mai 2012 lag der Marktpreis bei knapp über 5 US-Dollar pro Bitcoin und ist bis August 2012 auf etwa 10 US-Dollar gestiegen. Von August bis Dezember 2012 ist dieser Marktpreis weitgehend konstant zwischen 10 und 13 US-Dollar geblieben. Ab Januar 2013 stieg der Marktpreis. Anfangs nur leicht mit etwa einen US-Dollar mehr pro Tag, ab März jedoch rasanter bis zum Höchstpreis von 237 US-Dollar pro Bitcoin im April 2013. Im selben Monat ist der Marktpreis rapide auf bis zu 80 US-Dollar gesunken, bevor er sich im Mai wieder auf ein Niveau von 120 bis 130 US-Dollar eingependelt hat. Ein Grund für diesen starken Marktpreiserückgang ist laut Mt. Gox [15], dass sie einem Distributed-Denial-of-Service (DDoS) Angriff ausgesetzt wurden, der sie dazu zwang, den Online-Marktplatz für mehrere Stunden außer Betrieb zu nehmen.

4.5.3 Lead-Indikator

Der in dieser Arbeit erstellte Lead-Indikator kann dazu genutzt werden, zukünftige Entwicklungen besser einschätzen zu können. Der Lead-Indikator sollte dabei im Zeitverlauf betrachtet werden, um einen Anstieg und einen Abfall von diesem erkennen zu können. Steigt der Lead-Indikator, kann dies als ein Hinweis auf einen mittelbaren positiven Einfluss auf das Bitcoin-System gesehen werden. Ein stark fallender Lead-Indikator kann dabei als eine Art Vorwarnung gesehen werden, die in zukünftige Entscheidungen - beispielsweise den Ankauf weiterer Bitcoins - einfließen sollte.

Der Lead-Indikator drückt dabei das Verhältnis aller positiven Meinungen zu allen positiven und negativen Meinungen aus, und ist für den Monat i definiert als:

$$L_i = \frac{P(D_i = 1) + P(D_i = 2)}{P(D_i = -2) + P(D_i = -1) + P(D_i = 1) + P(D_i = 2)}$$

In Abbildung 10 sind die einzelnen Lead-Indikator Werte dargestellt. Damit ein Zusammenhang zwischen diesen Werten und bedeutenden Ereignissen in der Bitcoin Historie hergestellt werden kann, wird im Folgenden der Wert des Lead-Indikators modifiziert und zusammen mit dem Bitcoin-Handelspreis in Abbildung 11 dargestellt.

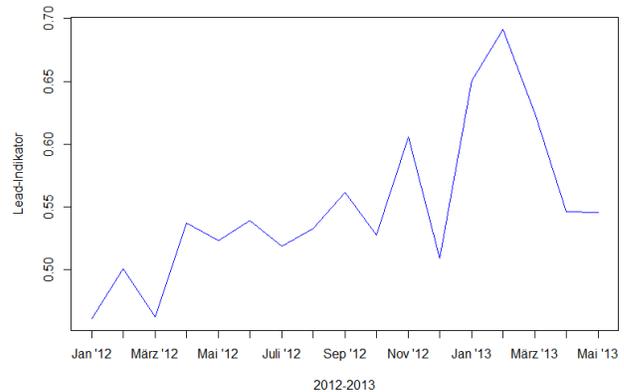


Abbildung 10. Lead-Indikator

Da der Lead-Indikator eine reelle Zahl zwischen 0 und 1 ist, muss er für eine Darstellung mit dem Bitcoin-Handelspreis angepasst werden. In einem ersten Schritt wird der Lead-Indikator normiert, so dass er tatsächlich von 0 bis 1 geht: der geringste Lead-Indikator Wert wird zur 0 und der größte Lead-Indikator Wert wird zur 1. In einem zweiten Schritt werden die normierten Lead-Indikator Werte auf die Werte des Bitcoin-Handelspreises skaliert. Dies geschieht, indem die einzelnen Werte mit dem größten dargestellten Handelspreis-Wert multipliziert werden:

$$L_i^{Norm} = \frac{L_i - \min(L)}{\max(L) - \min(L)}$$

$$L_i^{Skal} = L_i^{Norm} * \max(\text{Handelspreis})$$

Schließlich werden die skalierten Lead-Indikatoren L_i^{Skal} , die für den gesamten Monat i gelten, gestreckt, so dass sie im Monat i konstant bleiben. Dadurch entsteht für den Lead-Indikator die treppenförmige Darstellung.

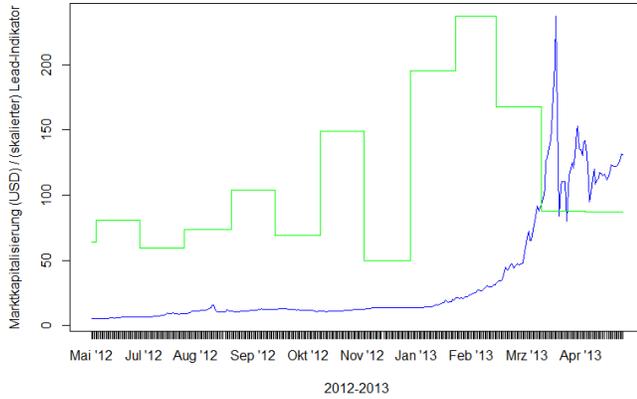


Abbildung 11. Bitcoin Handelspreis & Lead-Indikator

Die grüne treppenförmige "Kurve" zeigt den Verlauf des Lead-Indikators und die blaue Kurve zeigt den Bitcoin Handelspreis.

In Abbildung 11 erkennt man, dass ab Dezember 2012 der Lead-Indikator stark ansteigt. Die positive Stimmungslage kann dazu geführt haben, dass der Bitcoin-Handelspreis angestiegen ist. Zu erkennen ist auch, dass der Anstieg des Lead-Indikators etwa zwei Monate vor dem Anstieg des Handelspreises stattgefunden hat. Somit kann der Lead-Indikator einen ersten Hinweis auf einen möglichen Kursanstieg geben. Der rasante Abfall des Lead-Indikators ab Februar 2013 kann als Vorwarnung auf einen zukünftigen Kurssturz gesehen werden. Zwar ist der Handelspreis, wie bereits erwähnt, aufgrund eines DDoS stark gefallen. Jedoch können Anleger aufgrund des starken Anstiegs von einer möglichen Spekulationsblase abgeschreckt worden sein, welche unabhängig von dem DDoS Angriff ebenfalls zu einem Kurssturz geführt hätte [8]. Einer der führenden Bitcoin-Entwickler beim *Bitcoin Project*, Gavin Andresen, hat bereits im Juli 2010 mehrere Spekulationsblasen für die nächsten Jahre vorhergesagt [4]. Zudem hat er darauf hingewiesen, dass sobald der Kurs stark ansteigt, viele weitere Leute in Bitcoin "investieren" werden, womit der Kurs weiter steigt - solange, bis einige Leute behaupten, der Kurs werde nicht mehr weiter steigen und die Leute möglichst schnell wieder verkaufen möchten, welches zu einem Kurssturz führen wird [4]. Deswegen ist es auch möglich, dass unabhängig von dem DDoS Angriff auf Mt. Gox der Kurs des Bitcoin-Handelspreises stark gefallen wäre - und der Lead-Indikator an dieser Stelle auch einen Hinweis auf diesen Fall geben würde.

Der Lead-Indikator kann ferner eine Entscheidungshilfe bei der Investition in Bitcoin sein. Dazu wird eine Entscheidungsregel aus den Werten des Lead-Indikators abgeleitet:

$$\text{investiere im Monat } i \begin{cases} \text{ja} & \text{wenn } \partial > 15 \\ \text{nein} & \text{sonst} \end{cases} \quad \text{mit: } \partial = \frac{L_i - L_{i-1}}{L_i} * 100$$

Eine Investition in Bitcoin sollte demnach nur vorgenommen werden, wenn sich eine Verbesserung der Stimmungslage vom letzten Monat auf den aktuellen Monat abzeichnet. Der Schwellwert, ab dem investiert werden sollte, wird hier bei 15 angegeben. Dieser Wert hat sich aus der Bitcoin-Historie als plausibel erwiesen. In Abbildung 12 wird neben dem Bitcoin-Handelspreis und den Werten des Lead-Indikators noch die Investitions-Entscheidung dargestellt (rote Kurve). Man erkennt, dass demnach eine Investition im Januar empfohlen werden konnte, da in diesem Monat der Investitions-Wert über dem Schwellwert (gestrichelte Linie) liegt. In diesem Monat lag der Handelspreis bei etwa 13 US-Dollar für einen Bitcoin.

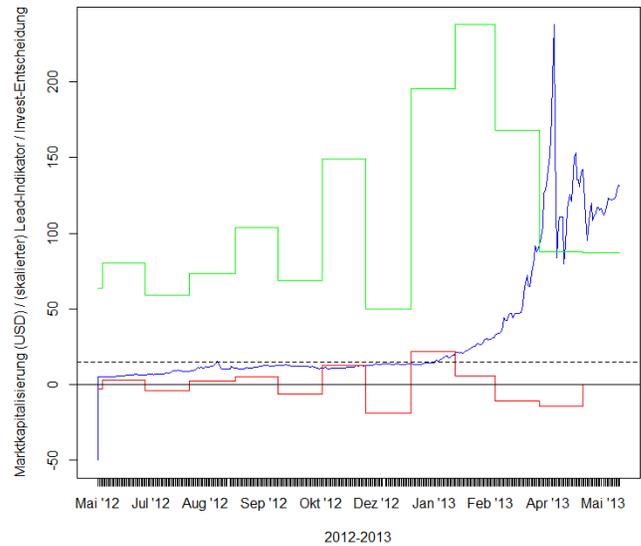


Abbildung 12. Bitcoin Handelspreis, Lead-Indikator und Invest-Entscheidung

5. ACKNOWLEDGEMENT

Ich bedanke mich bei den anonymen Gutachtern, die nützliche Verbesserungsvorschläge und Anregungen gegeben haben, in weitere Richtungen zu forschen.

6. FAZIT

Durch die Analyse der Blogs konnte gezeigt werden, dass es in der Öffentlichkeit eine Vielzahl an verschiedenen Meinungen gibt, die sich im Zeitverlauf ändern. Zusätzlich konnte ein Zusammenhang von Meinungen und tatsächlichen Entwicklungen im Bitcoin-System gezeigt werden, indem der Anteil der positiven und auch negativen Meinungen steigt beziehungsweise sinkt, wenn der Bitcoin-Handelspreis sich rapide verändert. Der vorgestellte Lead-Indikator kann einen frühen Hinweis auf eine solche Entwicklung geben, und sollte bei zukünftigen Entscheidungen mit einbezogen werden. Um eine detaillierte Analyse der öffentlichen Meinung erstellen zu können, ist eine größere Datenbasis aus mehreren Quellen notwendig. Es gibt Anbieter, die historischen Daten aus verschiedenen Quellen bereitstellen - allerdings in der Regel kostenpflichtig.

7. REFERENCES

- [1] Alpaydin, E. 2004. *Machine Learning*. The MIT Press.
- [2] Bitcoin Wiki, 2013. *Bitcoin Firsts*. Abgerufen Mai 2013. https://en.bitcoin.it/wiki/Bitcoin_Firsts
- [3] Bitcoin Wiki, 2013. *Handel*. Abgerufen Mai 2013. https://de.bitcoin.it/wiki/Handel#Exchange-Plattformen_2F_elektronische_B.C3.B6rsen
- [4] bitcointalk, 2013. *Bubble and crashes*. Abgerufen Mai 2013. <https://bitcointalk.org/index.php?topic=249.msg2083#msg2083>
- [5] Böhme, R. und Breuker, D. 2013. *Vertiefungsmodel Bitcoin*. Westfälische Wilhelmsuniversität Münster, NRW.
- [6] Blockchain, 23.05.2013. *Marktkapitalisierung*. Abgerufen Mai 2013. <http://blockchain.info/de/charts/market-cap>
- [7] CNN, 2006. *Bush on Kerry remark: U.S. troops are 'plenty smart'*. Abgerufen Mai 2013. <http://edition.cnn.com/2006/POLITICS/10/31/kerry.mccain/>
- [8] Financial Times, 2013. *Bitcoin bubble grows and grows*. Abgerufen Mai 2013. <http://www.ft.com/intl/cms/s/0/b4be7d8e-9c73-11e2-9a4b-00144feabdc0.html#axzz2UmN6V5bc>
- [9] Hopkins, D. und King, G. 2010. A Method of Automated Nonparametric Content Analysis for Social Science. *American Journal of Political Science* 54, 229-247.
- [10] Keyvan, 2010. PHP Port of Arc90's Readability. Abgerufen Mai 2013. <http://www.keyvan.net/2010/08/php-readability/>
- [11] King, G., Lu, Y. 2008. *Verbal Autopsy Methods with Multiple Causes of Death*. Statistical Science. <http://gking.harvard.edu/files/abs/vamc-abs.shtml>
- [12] Kim, S.M., Hovy, E. 2006. Identifying and analyzing judgment opinions. *Proceedings of the main conference on Human Language Technology Conference of the North American Chapter of the Association of Computational Linguistics 06*, 200-207
- [13] Liu, Bing, Zhang, Lei. 2010. *A Survey of Opinion Mining and Sentiment Analysis*. http://www.cs.uic.edu/~lzhang3/paper/opinion_survey.pdf
- [14] Mihalcea, R., Banea, C., Wiebe, J. 2007. Learning Multilingual Subjective Language via Cross-Lingual Projections. *Proceedings of the 45th Annual Meeting of the Association of Computational Linguistics*.
- [15] Mt. Gox, 2013. Statement Regarding Recent DDoS Attacks and Mitigation. https://mtgox.com/pdf/20130424_ddos_statement_and_faq.pdf
- [16] Nakamoto, S. 2008. Bitcoin: A Peer-to-Peer Electronic Cash System. <http://bitcoin.org/bitcoin.pdf>
- [17] O'Connor, B., Blasubramanyan, R., Routledge, B.R., Smith, N.A. 2010. *From Tweets to Polls: Linking Text Sentiment to Public Opinion Time Series*. Carnegie Mellon University. Tepper School of Business. <http://repository.cmu.edu/cgi/viewcontent.cgi?article=1575&context=tepper>
- [18] Ogneva, M. 2010. *How Companies Can Use Sentiment Analysis to Improve Their Business*. Abgerufen Mai 2013. <http://mashable.com/2010/04/19/sentiment-analysis/>
- [19] Pang, B. und Lee, L. 2008. *Opinion Mining and Sentiment Analysis*. (Mai 2013). DOI=<http://dx.doi.org/10.1561/1500000011>
- [20] SearchEngineWatch, 2005. *Google Launches Industrial Strength Blog Search*. Abgerufen Mai 2013. <http://searchenginewatch.com/article/2068035/Google-Launches-Industrial-Strength-Blog-Search>
- [21] Tumblr, 2013. *Über Tumblr*. Abgerufen Mai 2013. <http://www.tumblr.com/about>
- [22] Wordpress, 2013. *Stats*. Abgerufen Mai 2013. <http://en.wordpress.com/stats/>
- [23] WSJ, 2013. *Yahoo Deal to Buy Tumblr Shows Power Shift*. Abgerufen Mai 2013. <http://online.wsj.com/article/SB10001424127887324787004578493130789235150.html>
- [24] Unqualified Reservations, 2013. *How Bitcoin dies*. Abgerufen Mai 2013. <http://unqualified-reservations.blogspot.de/2013/01/how-bitcoin-dies.html>
- [25] Laissez Faire Today, 2013. *Bumps on the Bitcoin Road*. Abgerufen Mai 2013. <http://lfb.org/today/bumps-on-the-bitcoin-road/>
- [26] The Nyaruka Blog, 2012. *Bitcoin's Biggest Problem: It's a Den of Thieves*. Abgerufen Mai 2013. <http://blog.nyaruka.com/bitcoins-biggest-problem-dens-of-thieves>
- [27] Data Center Knowledge, 2013. *UK Provider Accepts BitCoin for Hosting Accounts*. Abgerufen Mai 2013. <http://www.datacenterknowledge.com/archives/2013/02/19/uk-host-accepts-non-traditional-payment-method-bitcoin/>
- [28] Pokerfuse, 2012. *Bitcoin Poker: Changing The Game*. Abgerufen Mai 2013. <http://pokerfuse.com/features/editorial-opinion/bitcoin-poker-changing-the-game-21-10/>
- [29] Activist Post, 2013. *Bitcoin is Forcing the Financial World to Adapt or Die*. Abgerufen Mai 2013. <http://www.activistpost.com/2013/05/bitcoin-is-forcing-financial-world-to.html>
- [30] Bitcoin Report, 2013. *Bitcoin Boom: Is This the New Safe Haven?* Abgerufen Mai 2013. <http://bitcoinreport.com/bitcoin-nick-colas-on-bloomberg/>
- [31] BITCOIN The Documentary, 2013. Interview set. Abgerufen Mai 2013. <https://bitcointhedocumentary.org/wordpress/?p=366>
- [32] Bristol Pound, 2013. *Bitcoin and the \$2.6 million pizzas*. Abgerufen Mai 2013. <http://bristolpound.org/blog/2013/05/14/bitcoin-and-the-2-6-million-pizzas/>