

Masterarbeit

Die Auswirkungen Algorithmen-basierter
Empfehlungssysteme in der Plattformökonomie auf
die Entstehung von Filterblasen am Beispiel von
YouTube

von:

Julia Hollitsch, BA
1710404820

Begutachter:

FH-Prof. Priv.-Doz. Dr. Michael Litschka

Zweitbegutachter:

FH-Prof. Mag. Roland Steiner, Bakk.

St. Pölten, am 28.08.2019

1. Abgabe

Ehrenwörtliche Erklärung

Ich versichere, dass

- ich die vorliegende Masterarbeit selbständig verfasst, andere als die angegebenen Quellen und Hilfsmittel nicht benutzt und mich auch sonst keiner unerlaubten Hilfe bedient habe.
- ich dieses Masterarbeitsthema bisher weder im Inland noch im Ausland einem Begutachter / einer Begutachterin zur Beurteilung oder in irgendeiner Form als Prüfungsarbeit vorgelegt habe.

Diese Arbeit stimmt mit der vom Begutachter / von der Begutachterin beurteilten Arbeit überein.

.....
Ort, Datum

.....
Unterschrift

Danksagung

Ich möchte mich hiermit an dieser Stelle bei all den Menschen herzlichst bedanken, die mich während der Zeit meines Studiums und der Erstellung der vorliegenden Masterarbeit unterstützt haben.

Zu allererst gilt der Dank meinen Eltern, die mir meinen Weg bis hierher geebnet haben. Sie haben mich stets dabei unterstützt, meine Ziele zu erreichen, ohne jegliche Gegenleistung zu erwarten.

Auch meinem Betreuer, FH-Prof. Priv.-Doz. Dr. Michael Litschka, möchte ich danken, der mich während dieser Zeit durch seine Fragen und seine Unterstützung immer wieder zurück auf den richtigen Weg gebracht hat.

Mein besonderer Dank gilt an dieser Stelle Dipl.Wirtsch.-Ing. Martin Possekel. Er nahm während der letzten Jahre die Rolle eines Mentors ein und stand mir von Anfang bis zum Ende dieser Arbeit, als auch darüber hinaus, durch intensive Gespräche, hilfreiche Anregungen und konstruktivem Feedback stets zur Seite.

Zusammenfassung

Plattformunternehmen, wie YouTube, zeichnen sich nicht nur durch die Merkmale wie einer hohen Skalierbarkeit und Reichweite, der Möglichkeit zur Auswertung einer großen Datenmenge, niedrige Transaktionskosten, starke Netzwerkeffekte, sowie einer hohen Dynamik aus, sondern instrumentalisieren als digitale Intermediäre Algorithmen. Der Einsatz digitaler Empfehlungssysteme steht oft unter der Kritik, Nutzer*innen zu ihrem Hang zur Homogenität und damit Selbstauswahlprozesse zu unterstützen. Damit kann von einem Algorithmus-basierten Filterblaseneffekt gesprochen werden, der im Rahmen der vorliegenden Masterarbeit näher erforscht wurde. Dabei wurde der Video-Streaming-Dienst YouTube, als Gegenstand der Untersuchung herangezogen. Die Leitfrage dieser Arbeit lautete „*Wie wirken sich Algorithmen-basierte Empfehlungssysteme auf die Entstehung von Filterblasen in der Plattformökonomie am Beispiel von YouTube aus?*“.

Die theoretische Basis bildeten insgesamt vier Mediennutzungstheorien: Der Uses-and-Gratifications-Ansatz, selektions- als auch rezeptionsorientierte Ansätze, sowie kontextbezogene Ansätze. Inhaltlich wurde außerdem auf die Themen Plattformökonomie, Künstliche Intelligenz (KI), Machine Learning (ML), Algorithmen, als auch auf die Thematik rund um Algorithmen-basierte Empfehlungssysteme und den Filterblaseneffekt eingegangen. Methodisch wurde die empirische Untersuchung im Rahmen eines Experiments umgesetzt. Untersucht wurde inwieweit die politische Gesinnung einer Nutzerin bzw. eines Nutzers Einfluss auf den YouTube-Algorithmus und das darauf aufbauende Empfehlungssystem hinsichtlich der Entstehung von Filterblasen hat und inwiefern dieser auf Interaktionen mit politischen Videos durch Nutzer*innen reagiert?

Die zentralen Ergebnisse dieser Arbeit können wie folgt zusammengefasst werden: Die politische Gesinnung einer Nutzerin bzw. eines Nutzers hat einen Einfluss auf den YouTube-Algorithmus und das darauf aufbauende Empfehlungssystem hinsichtlich der Entstehung von Filterblasen. Zudem reagiert der YouTube-Empfehlungsalgorithmus stärker auf die Interaktionen rechts-konservativ gesinnter Nutzer*innen, als links-liberal gesinnter Nutzer*innen. Grundsätzlich führen Algorithmen-basierte Empfehlungssysteme also zur Entstehung von Filterblasen, wer dafür allerdings in letzter Konsequenz die Verantwortung übernehmen muss, ist eine andere Frage.

Abstract

Platform companies, such as YouTube, are not only characterized by features such as high scalability and reach, the ability to analyze large amounts of data, low transaction costs, strong network effects, and high dynamics but also instrumentalize algorithms as digital intermediates. The use of digital recommendation systems is often criticized for supporting users in their tendency towards homogeneity and thus self-selection processes. Therefore, we can speak of an algorithm-based filter bubble effect, which has been researched in more detail within this master thesis. The video streaming service YouTube was used as the object of the investigation. The main question of this thesis is "How do algorithm-based recommendation systems affect the development of filter bubbles in platform economics, using YouTube as an example?".

The theoretical basis was formed by a total of four theories on media use: The Uses-and-Gratifications approach, selection- and reception-oriented approaches, as well as context-related approaches. In addition, the topics platform economy, artificial intelligence (AI), machine learning (ML), algorithms, as well as the topic around algorithm-based recommendation systems and the filter bubble effect were discussed. The empirical investigation was methodically implemented within the framework of an experiment. To what extent did the political attitude of a user influence the YouTube algorithm and the recommendation system based on it with regard to the development of filter bubbles and to what extent did it react to interactions with political videos by users?

The central results of this work can be summarized as follows: The political attitude of a user has an influence on the YouTube algorithm and the recommendation system based on it with regard to the development of filter bubbles. Additionally, the YouTube recommendation algorithm reacts more strongly to the interactions of right-wing conservative users than left-wing liberal users. In principle, algorithm-based recommendation systems thus lead to the development of filter bubbles, but who has to take responsibility for this is a separate question.

Inhaltsverzeichnis

Zusammenfassung	II
Abstract	IV
Inhaltsverzeichnis	V
1 Einleitung	1
1.1 Problem- und Fragestellung.....	1
1.2 Erkenntnisinteresse und Zielsetzung.....	3
1.3 Aufbau und Methodik.....	3
2 Darlegung des Forschungsstands.....	4
2.1 Aktuelle Forschungslage.....	5
2.2 Zwischenfazit.....	9
3 Theorien der Mediennutzung.....	9
3.1 Der Uses-and-Gratifications-Ansatz	10
3.2 Selektionsorientierte Ansätze	12
3.3 Rezeptionsorientierte Ansätze	15
3.4 Kontextbezogene Ansätze.....	17
3.5 Zwischenfazit.....	21
4 Die Plattformökonomie	22
4.1 Grundlagen zur Plattformökonomie	22
4.2 YouTube als Plattform	26
4.3 YouTube in Österreich	31
4.4 Zwischenfazit.....	32
5 Künstliche Intelligenz, maschinelles Lernen und Algorithmen	33
5.1 Künstliche Intelligenz als Überbegriff	33
5.2 Maschinelles Lernen und Algorithmen	38
5.3 Zwischenfazit.....	45
6 Algorithmen-basierte Empfehlungssysteme und die Entstehung von Filterblasen	46
6.1 Algorithmen-basierte Empfehlungssysteme	47
6.2 Der Filterblaseneffekt.....	50
6.3 Zwischenfazit.....	53
7 Conclusio	54

7.1	Fazit zur Theorie	54
7.2	Forschungsfragen	57
7.3	Ausblick Empirie	58
8	Methodologie	59
8.1	Erläuterung der Erhebungsmethode	59
8.2	Erläuterung der Auswertungsmethode	62
8.3	Operationalisierung und Vorgehensweise	67
9	Empirische Analyse.....	78
9.1	Analyse und Interpretation der Ergebnisse	79
9.2	Ableitung der Hypothesen.....	86
10	Diskussion.....	88
10.1	Limitationen dieser Arbeit	91
10.2	Ausblick	91
	Quellenverzeichnis.....	93
	Anhang	106

Abbildungsverzeichnis

Abbildung 1 – Die Plattform YouTube: Ein multiseitiger Markt (eigene Darstellung)	28
Abbildung 2 – YouTube-Nutzer*innen in Österreich nach Alter (in Anlehnung an Gadringer, et. al., Digital News Report 2018, S. 66).....	31
Abbildung 3 – Videoauswahlprozess und Entscheidungsverfahren (eigene Darstellung)	77
Abbildung 4 – Entscheidungsprozess hinsichtlich der Bewertung politischer YouTube- Videos (eigene Darstellung).....	77
Abbildung 5 – Neue Darstellung der Inhalte auf YouTube (Stand 13.08.2019)	79
Abbildung 6 – Unveränderte Darstellung der Inhalte auf YouTube (Stand 14.08.2019)	80

Tabellenverzeichnis

Tabelle 1 – Medienfaktoren & Rezipient*innenfaktoren, in Anlehnung an Schweiger 2007, S. 178-182.....	14
Tabelle 2 – Liberale und konservative Werte (in Anlehnung an Thurich 2011, S. 103)	64
Tabelle 3 – Liberalismus & Konservativismus: Stereotypen (in Anlehnung an DellaPosta, Shi & Macy 2015, S. 1482 ff.)	66
Tabelle 4 – Attribute zur Erstellung der Google-Accounts (aufgelistet nach Simulationsaccount).....	68
Tabelle 5 – Demographischer und soziodemographischer Hintergrund der fiktiven Personen (aufgelistet nach Simulationsaccount)	69
Tabelle 6 - Werte und Einstellungen zum aktuellen politischen und gesellschaftlichen Diskurs (aufgelistet nach Simulationsaccount)	73
Tabelle 7 – Dauer und Zeitraum Durchführung Experiment.....	73
Tabelle 8 – Dokumentation und Analyse (Startseite und einzelne Videos).....	74
Tabelle 9 – Dokumentation und Analyse (rezipierte Videos)	75
Tabelle 10 – Startseitenanalyse	81
Tabelle 11 – Rezeptionsanalyse	82
Tabelle 12 – Kanal-Abonnements	83
Tabelle 13 – Themen-Abonnements	84
Tabelle 14 – Überblick Themen- und Kanal-Empfehlungen.....	84
Tabelle 15 – Zustimmung zum Inhalt rezipierter Videos	85

1 Einleitung

Seit über zehn Jahren verlagert sich unsere gesellschaftliche Kommunikation zunehmend in virtuelle Räume. Diverse digitale Medien-Angebote sind mittlerweile integraler Bestandteil unseres Alltags. Plattformunternehmen wie Google, YouTube und Facebook führen seit mehreren Jahren internationale Website-Rankings an (Alexa Ranking 2019). Auch in Österreich stellt YouTube eines der relevantesten Social Media-Angebote dar. In der Gruppe der 18- bis 24-Jährigen liegt der Video-Streaming-Dienst, mit einer Gesamtnutzung von knapp 82 Prozent, sogar vor allen anderen sozialen Medien. Generell steigt die Nutzung sozialer Medien von Jahr zu Jahr. Insbesondere mit dem Smartphone als Hauptgerät der Nachrichtennutzung, bilden Plattformen wie Facebook, WhatsApp und YouTube die ersten Anlaufstellen, um Nachrichten mobil zu konsumieren. Beinahe ein Viertel der YouTube-Nutzer*innen (22,9 Prozent) rezipieren bereits Nachrichten über den Dienst. (Digital News Report 2018) Eine aktuelle Studie von HubSpot (2017) verdeutlicht zudem, dass Video-Inhalte in Zukunft vermehrt, insbesondere von einer jüngeren Zielgruppe, nachgefragt werden, und dabei von einer höheren Aufmerksamkeit betreffend der Inhalte auszugehen ist. Ebenfalls ist anzunehmen, dass der Video-Streaming-Dienst YouTube in den kommenden Jahren weiterwachsen wird und dementsprechend seine Relevanz, auch am österreichischen Markt, weiter ausbauen kann. Allerdings sehen sich Plattformen zusehends massiver Kritik ausgesetzt. YouTube wird gar als Extremismus-Maschine bezeichnet, die Nutzer*innen immer tiefer in die Filterblase drängen (Tanriverdi 2017). Im nächsten Absatz wird nun, im Rahmen der Problem- und Fragestellung, näher auf die Problematik rund um Plattformen eingegangen und abschließend auch die Leitfrage dieser Arbeit formuliert.

1.1 Problem- und Fragestellung

Digitale Plattformen und Plattformmärkte zeichnen sich insbesondere durch eine hohe Skalierbarkeit und Reichweite, der Möglichkeit zur Auswertung einer großen Datenmenge, niedrige Transaktionskosten, starke Netzwerkeffekte, sowie einer hohen Dynamik aus (Engelhardt, Wangler und Wischmann 2017, S. 11-15). Auch

der Video-Streaming-Dienst YouTube, als Teil des Alphabet-Konzerns, kann der Plattformökonomie zugeordnet werden. Plattformen, wie YouTube, treten in erster Linie als wirtschaftlich ausgerichteter und digitaler Intermediär auf, der die oben genannten Merkmale aufweist.

Allerdings verbindet Plattformunternehmen noch ein weiterer wichtiger Aspekt: Die Instrumentalisierung von Algorithmen. Wie genau die Algorithmen der unterschiedlichen Plattformunternehmen, insbesondere der zu untersuchenden Plattform YouTube, funktionieren bleibt allerdings unklar. Sie bilden einen wichtigen Erfolgsfaktor als auch eine Abgrenzungsmöglichkeit zur Konkurrenz, und werden von den Unternehmen somit immer als Betriebsgeheimnis gehandelt. Die alleinige Existenz von Algorithmen und ihr Einsatz, um Informationen zu selektieren stellen noch kein Problem oder einen Grund zur Besorgnis dar. Auch Journalismus dient der Vorselektion von Inhalten, um das Weltgeschehen für die Rezipient*innenschaft besser einordbar zu machen, und dieser zu ermöglichen sich eine eigene Meinung zu bilden. Allerdings neigen Menschen – dies allerdings in individuell unterschiedlicher Ausprägung – zur Homogenität, mithin Zugehörigkeit zu einer Gruppe, also beispielsweise zu sozialen Freundeskreisen, die ähnliche Meinungen vertreten bzw. zu Menschen, die uns ähnlich sind, gemeint ist. In Kombination mit Empfehlungssystemen, die bestimmte Inhalte individuell als relevant einstufen, führt dieser Zustand mit ernstzunehmender Wahrscheinlichkeit zu einem Informations(-such)verhalten, das in sogenannten Filterblasen stattfindet. (Zweig et al. 2017, Katzenbach 2018, Schmidt 2018)

Es kann also von einem Algorithmus-basierten Filterblaseneffekt gesprochen werden. Dieser stellt in der Plattformökonomie ein kontrovers diskutiertes Themengebiet dar und gibt Anlass dazu, sich dieser Thematik anzunehmen. Für diese Masterarbeit wird der Video-Streaming-Dienst YouTube, aus zuvor beschriebenen Gründen, als Gegenstand der Untersuchung herangezogen. Die Leitfrage dieser Arbeit lautet folgendermaßen:

„Wie wirken sich Algorithmen-basierte Empfehlungssysteme auf die Entstehung von Filterblasen in der Plattformökonomie am Beispiel von YouTube aus?“

1.2 Erkenntnisinteresse und Zielsetzung

Plattformunternehmen, wie YouTube, stellen ein wichtiges Medium zur Nachrichtenrezeption für eine zunehmend jüngere Zielgruppe dar. Mit der Instrumentalisierung von Algorithmen unterstützen diese Systeme ihre Nutzer*innen in ihrem Hang zur Homogenität. Inhalte werden also zunehmend in sogenannten Filterblasen rezipiert, die besonders die eigene Meinung reflektieren sollen. Die wissenschaftliche Relevanz dieser Masterarbeit begründet sich demnach einerseits aus den Problemen, die durch den Einsatz von Algorithmen auf Plattformen auftreten können, und andererseits aus der zunehmenden Relevanz der Video-Streaming-Plattform YouTube in Österreich.

Die praktische Relevanz des Themas begründet sich insbesondere aus der Funktionsweise Algorithmen-basierter Empfehlungssysteme und der Entstehung von Filterblasen, die in der Mediennutzung auftreten, als auch in der Frage nach den Auswirkungen dieser. Hier schließt sich die Relevanz ebenfalls dem Studienfach des digitalen Medienmanagements betreffend an: Die Thematik kann insbesondere im Bereich Medien- und Internetökonomie verortet werden, zieht sich allerdings durch alle studienrelevanten Inhalte. Das Verständnis der Plattformökonomie ist substantiell, gerade im Bereich der digitalen Medien.

Die Zielsetzung der Arbeit besteht darin, die Frage, wie sich der Algorithmen-basierte Filterblaseneffekt in der Plattformökonomie am Beispiel von YouTube auswirkt, zu erforschen und wichtige Erkenntnisse in dieser Ebene zu erhalten.

1.3 Aufbau und Methodik

Um das Ziel dieser Arbeit zu erreichen soll zu Beginn der bisherige Forschungsstand dargelegt werden. Aktuelle empirische Studien zu YouTube im Speziellen und der Plattformökonomie im Allgemeinen, als auch zu den davon eingesetzten Algorithmen und Empfehlungssystemen fließen in dieses Kapitel mit ein. In Kapitel Drei werden die relevantesten Medienwirkungstheorien, darunter der Uses and Gratifications-Ansatz, als auch selektionsorientierte, rezeptionsorientierte und kontextbezogene Ansätze, erläutert. Das vierte Kapitel befasst sich mit dem Themengebiet der Plattformökonomie. Es werden Grundlagen zur Plattformökonomie, als auch YouTube als Plattform im Speziellen betrachtet.

Kapitel Fünf setzt sich mit Künstlicher Intelligenz (KI), maschinellem Lernen (ML) und Algorithmen auseinander, und betrachtet diese in Verbindung zueinander. Grundsätzlich wird der Fokus auf digitale Empfehlungssysteme gelegt, welche innerhalb des sechsten Kapitels näher erläutert werden. Dieses schließt außerdem mit dem Phänomen der Filterblase den Theorienteil dieser Masterarbeit ab. Insbesondere der Nutzen und die Gefahren von Filterblasen werden betrachtet. Das siebente Kapitel, die Conclusio, fasst die bisherigen Erkenntnisse des Theorienteils überblicksmäßig zusammen. Zusätzlich werden in diesem Kapitel die Forschungsfragen, für die es gilt, im Zuge der Empirie geeignete Hypothesen abzuleiten, formuliert.

Mit Kapitel Acht beginnt der empirische Teil dieser Masterarbeit. Es werden die Erhebungsmethode als auch die Auswertungsmethode erläutert. Die Methodologie schließt mit einer Operationalisierung und einem Ausblick bezüglich der weiteren Vorgehensweise, ab. Das neunte Kapitel wird der empirischen Analyse und der Interpretation der Ergebnisse gewidmet. Das Kapitel schließt mit der Generierung der Hypothesen ab.

Im zehnten und letzten Kapitel dieser Arbeit werden die Erkenntnisse in ihrer Gesamtheit nochmals zusammengefasst und diskutiert. Auf die Limitationen der Arbeit wird ebenfalls eingegangen. Abschließend soll die vorliegende Arbeit einen Ausblick auf Forschungsarbeiten der Zukunft liefern.

2 Darlegung des Forschungsstands

Im folgenden Abschnitt wird auf aktuelle empirische Studien eingegangen, die sich insbesondere mit dem Video-Streaming-Dienst YouTube auseinandersetzen. YouTube bildet das zentrale Interessensgebiet dieser Arbeit, in Kombination fließen weitere Aspekte und Erkenntnisse aus der Plattformökonomie, der Thematik rund um Algorithmen und digitalen Empfehlungssystemen in dieses Kapitel mit ein. Die Darlegung des Forschungsstands dient dazu, den Status Quo festzuhalten und bildet die Grundlage für die weiterführenden Kapitel dieser Arbeit.

2.1 Aktuelle Forschungslage

YouTube gilt als eine der beliebtesten Websites unter den sozialen Medien. Viele Studien spezialisieren sich daher auf die Popularität von Inhalten und soziale Dynamiken auf der Plattform. Beispielsweise führte Cha et al. (2009, 2007) umfassende Analysen zu den Eigenschaften beliebter Videos auf YouTube durch. Cheng et al. (2008) entdeckte, dass die Verbreitung von YouTube-Videos weit fortgeschritten ist, die Netzwerke verwandter Videos allerdings Merkmale aufweisen, die auf ein sogenanntes Kleine-Welt-Netzwerk („Small-World-Network“) hinweisen (ein Phänomen, dass auf sozialen Medien häufig auftritt; bedeutet, dass Menschen mit allen anderen verbunden sind, allerdings nur durch kurze Ketten von Bekanntschaften (Milgram 1967, S. 60-67)). Brodersen et al. (2012) zeigten in ihrer Arbeit, dass die Popularität von YouTube-Videos durch die geografische Lokalität, die für Nutzer*innen spezifisch von Interesse ist, eingeschränkt wird. Chatzopoulou et al. (2010) untersuchte mehrere Beliebtheitskennzahlen auf der Grundlage eines YouTube-Datensatzes und stellte fest, dass die Anzahl der Aufrufe stark mit der Anzahl der Kommentare, Bewertungen und der Speicherung von Favoriten korreliert. Die Metriken zeigen jedoch eine geringe Korrelation mit der Durchschnittsbewertung. Crane und Sornette (2008) untersuchten das soziale System YouTube anhand von endogenen als auch exogenen Aktivitätsausbrüchen. Sie kamen zu dem Ergebnis, dass die Popularität bzw. der zeitliche Ablauf von Aufrufen (Views) einzelner Videos anfangs dem Potenzgesetz folgt, nach dem ersten Aktivitätsausbruch aber eine sogenannte Entspannungsreaktion folgt. Ratkiewicz et al. (2010) unterstützen in ihrer Arbeit diese These: Sie untersuchten die Wikipedia und den gesamten Webbereich eines Landes, und kamen ebenfalls zu dem Ergebnis, dass sich die Dynamik der Popularität durch Ausbrüche charakterisieren lässt. Im Zuge dessen schlagen sie ein Minimalmodell vor, das den klassischen Mechanismus zur Erhöhung der Beliebtheit mit dem Auftreten zufälliger Verschiebungen von Präferenzen aufgrund exogener Faktoren kombiniert, um Popularitätsdynamiken zu charakterisieren. In „Characterizing and modelling popularity of user-generated videos“ (Borghol et al. 2011) wird ein dreiphasiger Charakterisierungsansatz vorgeschlagen, um die Entwicklung der Popularität neu

hochgeladener Videos auf YouTube zu modellieren. In einer weiteren Studie untersuchten Borghol et al. (2012) den Einfluss verschiedener „inhaltsagnostischer“ Faktoren auf die Popularität von Videos und analysieren dazu eine Reihe von Phänomenen: Beispielsweise sind Videos, die von Nutzer*innen mit großen sozialen Netzwerken hochgeladen werden, tendenziell beliebter, da sie tendenziell interessantere Inhalte enthalten, nicht weil die Größe ihrer sozialen Netzwerke einen erheblichen direkten Einfluss auf die Beliebtheit hat. Bei der Untersuchung der Videoinhalte konnte ein starker linearer „rich-get-richer“-Effekt – wobei die Gesamtzahl der vorherigen Aufrufe (Views) den wichtigsten Faktor darstellt, außer bei sehr jungen Videos – beobachtet werden. Bei jungen Videos zählen vor allem die Eigenschaften der Uploaderin bzw. des Uploaders, sowie die Anzahl der verwendeten Keywords. Figueiredo et al. (2011) charakterisierten in ihrer Arbeit ebenfalls Wachstumsmuster der Popularität von YouTube-Videos für insgesamt drei verschiedene Arten von Videos: Quality-, Viral- und Junk-Videos. Insbesondere urheberrechtlich geschützte Videos (Quality-Videos) erhalten in den meisten Fällen zu einem früheren Zeitpunkt den größten Teil ihrer Aufrufe und zeigen oft ein Beliebtheitswachstum, das durch einen virenepidemischen Ausbreitungsprozess gekennzeichnet ist. Im Gegensatz dazu neigen Videos in den Top-Listen (Viral-Videos) zu plötzlichen, erheblichen Populationsanstürmen. Darüber hinaus präsentierte Figueiredo (2013) in einer seiner darauffolgenden Arbeiten ein Vorhersagemodell für Trends und Treffer in von Nutzer*innen erstellten Videos. In seiner jüngsten Arbeit (Figueiredo et al. 2014) untersucht der Autor mit seinem Team wie bestimmte Faktoren, die sich auf die Beliebtheitsdynamik von sozialen Medien auswirken, effektiv genutzt werden können und bietet damit Content Creator*innen und Werbetreibenden wertvolle Einblicke. In der Arbeit „Viral Video Style: A Closer Look at Viral Videos on YouTube“ untersuchten die Autor*innen (Jiang et al. 2014) die Beliebtheitseigenschaften viraler Videos und schlugen ein Modell vor, um den zukünftigen Spitzentag viraler Videos vorherzusagen, indem unter anderem auch Videometadaten in die Vorhersage einbezogen werden. Chen et al. (2014) untersuchen die Entwicklung der Popularität verschiedener Videotypen anhand eines Lebenszeitmodells. Als Hauptergebnis kann festgehalten werden, dass die glorreichen Tage eines Videos schnell vorbei gehen, die Lebenszeit also aufgrund ständig neu verfügbarer Inhalte kurz ist, und die Wahrscheinlichkeit, dass

Videos von derselben Nutzerin bzw. demselben Nutzer nochmals wiedergegeben werden, entsprechend gering ist.

Social Media ist auch für Werbetreibende zu einem Kanal von hoher Bedeutung geworden: Die Vorhersage der Beliebtheit und Popularität der zur Veröffentlichung bestimmten Inhalte hat dementsprechend an Bedeutung gewonnen. Modelle zur Vorhersage der Beliebtheit von Online-Inhalten, darunter Bilder und YouTube-Videos, liefern vor allem die Autor*innen Ahmed et al. (2013), Lerman et al. (2008, 2010), Pinto, Almeida und Goncalves (2013), Szabo und Huberman (2010), Yu et al. (2014) sowie Deshmukh und Chouragade (2016) in ihren Arbeiten.

Des Weiteren existieren eine Reihe von Studien, die sich auf das Design und die Bewertung von Inhaltserkennungssystemen (Content Discovery Systems) beziehen. Beispielsweise wurde in „High-order distance based multiview stochastic learning in image classification“ eine entfernungsisierte stochastische Lernmethode mit hoher Auflösung für die inhaltsbasierte Bildwiederherstellung vorgeschlagen (Yu et al. 2014). Nie et al. (2014) nutzten in ihrer Arbeit „Social interaction based video recommendation: Recommending YouTube videos to Facebook users“ soziale Interaktionen, um YouTube-Videos an Facebook-Nutzer*innen zu empfehlen, und erzielten mit ihrem Algorithmus eine Verbesserung der Empfehlungsgenauigkeit. Ein Such- und Indexierungssystem wird in „Video search and indexing with reinforcement agent for interactive multimedia services“ vorgestellt, das auf einem State Support Vector Network basiert (Paul et al. 2013). In der Arbeit „Parallel reconfigurable computing-based mapping algorithm for motion estimation in advanced video coding“ schlugen die Autor*innen einen neuartigen parallelen Partitionierungsalgorithmus vor, der die Videoverarbeitung zu minimalen Kosten beschleunigen kann (Paul et al. 2012). Wie in „NetTube: Exploring Social Networks for Peer-to-Peer Short Video Sharing“ dargestellt, werden YouTube-Videos basierend auf Video-Metadaten (Titel, Beschreibung, usw.) und den Daten zu Aktivitäten der Benutzer*innen (Verlauf der Videobetrachtung, Videobewertung, usw.) empfohlen. Die Autor*innen stellen im Zuge dessen ein neuartiges Peer-to-Peer-gestütztes Bereitstellungs-Framework („NetTube“) vor, das das Clustering in sozialen Netzwerken für das Teilen von kurzen Videos untersucht. (Cheng und Liu

2009) Die Beziehung zwischen einem Video und den zugehörigen Videos wurde in den Arbeiten von Chatzopoulou et al. (2010) und Cheng und Liu (2009) untersucht. Leem und Chun (2014) zeigten, dass Social Network Analysis (SNA)-Maße für Empfehlungsnetzwerke, wie unter anderem der Grad an Zentralität sowie die Nähe der Zentralität (z.B. Bücher, die zusätzlich zu einem Buch gekauft wurden) einen erheblichen Einfluss auf die Nachfrage haben. Die Auswirkungen von Empfehlungssystemen im Zusammenhang mit E-Commerce wurden in „Recommender Systems and their Impact on Sales Diversity“ (Fleder und Hosanagar 2007) und „Blockbuster Culture’s next Rise or Fall: The Impact of Recommender Systems on Sales Diversity“ (Fleder und Hosanagar 2009) untersucht. Die Autor*innen führten ihre Analysen anhand einer Modellierung der pfadabhängigen Auswirkungen von Empfehlungssystemen durch und kombinierten im Rahmen der Simulation Wahlmodelle mit tatsächlichen Implementierungen von Empfehlungssystemen. Das Ziel ihrer Arbeit war die zwei vorherrschenden Ansichten – Empfehlungssysteme helfen Kund*innen, neue Produkte zu entdecken (dadurch kommt es zu einer Erhöhung der Absatzvielfalt) bzw. Empfehlungssysteme verstärken die Beliebtheit einzelner Produkte – miteinander in Einklang zu bringen. Das Ergebnis sieht wie folgt aus: Empfehlungssysteme, die bereits bekannt sind bzw. eingesetzt werden (z.B. kollaborative Filter) führen zu einer Verringerung der Vertriebsvielfalt, da sie Produkte anhand von abgeschlossenen Verkäufen und Bewertungen empfehlen. Für beliebte Produkte kommt es demnach zu einem „rich-get-richer“ Effekt, für weniger populäre Produkte gilt Gegenteiliges. Die Autor*innen halten in ihren Ergebnissen außerdem fest, dass Empfehlungssysteme auf der Individualebene zu einer erhöhten Vielfalt führen können, diese insgesamt allerdings zu einer geringeren Vielfalt führen. Im Gegensatz dazu zeigen die Ergebnisse von Zhou et al. (2016), dass das auf YouTube eingesetzte Videoempfehlungssystem die Gesamtvielfalt der Aufrufe (Views) erhöht. Dies könnte auf eine unterschiedliche Gestaltung von Empfehlungssystemen für E-Commerce- und Social-Media-Websites zurückgeführt werden. Außerdem wird der Einfluss anderer Quellen für Videoaufrufe (Views), nämlich durch die Suche und die Hervorhebungen (Highlights), auf die Vielfalt untersucht. Das Ergebnis der Autor*innen zeigt, dass die untersuchten Quellen die

Vielfalt der gesehenen Videos verringern. Einmal mehr kann also von einem „rich-get-richer“-Effekt gesprochen werden.

2.2 Zwischenfazit

Die eben beschriebenen Studien zu YouTube basieren vor allem auf der Entstehung von Popularität und fokussieren sich fast ausschließlich auf die ökonomischen Aspekte dieser Plattform. Sie helfen zwar zu verstehen, wie Videos erfolgreich sein können, hinterfragen aber die Wirkungsweise solcher Dynamiken nicht. YouTube steht seit längerem unter dem Verdacht, immer extremere Meinungen bis hin zu Verschwörungstheorien zu unterstützen, und so die Desinformation der Bevölkerung zu fördern. Als aktuellstes Beispiel kann die Studie von Asheley Landrum (2019) herangezogen werden, die YouTube vorwirft die „Flat Earth“-Bewegung – bestehend aus Menschen, die der Meinung sind, die Erde wäre flach – als primäre Verbreitungsplattform maßgeblich zu unterstützen. Brodnig, Hammer und Holnburger (Digitalreport 2018, S.15-21) zeigen in einer anschaulichen Datenanalyse zu YouTube in Österreich, dass vor allem rechte Parteien, insbesondere die FPÖ, die Themen Nachrichten und Politik auf der Plattform dominieren. Eine Tatsache, die nicht zu unterschätzen ist, zumal YouTube eine wichtige Anlaufstelle für Informationen – insbesondere vor Wahlen – darstellt. Diese Arbeit fokussiert sich auf die Filterblasen-Thematik und deren Wirkungsweise in der auf Algorithmen-basierenden Plattformökonomie anhand von YouTube. Die eben beschriebenen Dynamiken sollen untersucht und kritisch hinterfragt werden.

3 Theorien der Mediennutzung

Im folgenden Kapitel werden anwendbare Theorien der Massenkommunikation näher beleuchtet. Die Relevanz dieser theoretischen Betrachtung wird insbesondere durch die Tatsache begründet, dass YouTube als Plattform zahlreiche Nutzer*innen erreicht und ein Kommunikationsmittel für sämtliche „Content Creator*innen“ schafft. Die Erläuterung der folgenden Theorien, darunter der Uses-and-Gratifications-Ansatz, als auch selektions- und rezeptionsorientierte,

sowie kontextbezogene Ansätze sollen die Grundlage für das Verständnis schaffen, warum Plattformen wie YouTube überhaupt genutzt werden.

3.1 Der Uses-and-Gratifications-Ansatz

Der Uses-and-Gratifications-Ansatz setzt sich grundlegend mit den Fragestellungen auseinander, weshalb Menschen welche Medien nutzen, was sie mit diesen machen und welche individuellen Bedürfnisse dabei eine Rolle spielen. Grundsätzlich wird davon ausgegangen, dass Menschen ihre individuellen Bedürfnisse und Wünsche durch die Nutzung von Medien befriedigen (Katz, Blumler und Gurevitch 1973, S. 509-523, Schweiger 2007, S. 60). Die zentrale Annahme dieses Ansatzes besagt, dass Medien aktiv selektiert und rezipiert werden und dies auf eine funktionale Art und Weise erfolgt, da immer bestimmte Wirkungen erreicht werden sollen. Zwei Bedürfniskategorien stechen dabei besonders heraus: Das Informations- und das Unterhaltungsbedürfnis. Im Gegensatz zur klassischen Medienwirkungsforschung fragt der Uses-and-Gratifications-Ansatz nach den Bedürfnissen des Individuums, die zu einer Zuwendung zu einem bestimmten Medium führen, mit der zwangsläufig eine Veränderung der Perspektive einhergeht. Die Beziehung zwischen Medium und beeinflussbarer bzw. beeinflussbarem Rezipient*in wird in diesem Ansatz als gegeben vorausgesetzt. Es geht also nicht nur um die aktive, sondern auch um die freiwillige Zuwendung zu einem bestimmten Medium. Daraus leitet sich eine weitere Grundannahme ab: Medien stehen in direkter Konkurrenz zu anderen Möglichkeiten der Bedürfnisbefriedigung. Wobei auch beachtet werden muss, dass Medien nicht alle menschlichen Bedürfnisse (z.B. Hunger, Müdigkeit, etc.) stillen können. Im Uses-and-Gratifications-Ansatz wird dem Menschen zu jeder Zeit eine entsprechende Entscheidungsfreiheit zugesprochen. Mit dieser Aussage wird ein weiteres Mal die Grundannahme einer „aktiv-bewussten Medienentscheidung“ hervorgehoben. (Schweiger 2007, S. 60-62)

Grundsätzlich wurde der Uses-and-Gratifications-Ansatz bereits in einer Vielzahl von Studien herangezogen. Die Fähigkeit zur Befriedigung von Publikumsbedürfnissen einzelner Mediengattungen (auch durch Intermedia-Vergleiche), Medientechniken im Rahmen bestehender Mediengattungen bzw.

interpersonaler Kommunikationsmittel und Internetmodi, sowie spezifischer Inhalte und Genres oder auch spezifischer Medienangebote wurde breit untersucht. (Schweiger 2007, S. 64)

Für diese Arbeit gilt es zusätzlich herauszufinden, welche Bedürfnisse und Motive dazu führen, den Video-Streaming-Dienst YouTube zu nutzen. Hanson und Haridakis (2008, S. 1-12) untersuchten beispielsweise in ihrer Arbeit „YouTube Users Watching and Sharing the News: A Uses and Gratifications Approach“ wie Student*innen Nachrichten-Inhalte auf YouTube rezipieren und teilen, und welche unterschiedlichen Motive dahinterstecken. Mittels eines Fragebogens sammelten die Autoren Daten zur sozialen und psychologischen Vorgeschiede der Student*innen (darunter Kontrollüberzeugung, Sensationssuchverhalten, zwischenmenschliches Interaktionsverhalten, soziale Aktivitäten), zu den Motiven hinsichtlich der Verwendung von YouTube und wie oft die befragten Personen Videos auf YouTube angesehen und geteilt haben. Insgesamt wurden 51 Motivaussagen von den Studierenden bewertet, wobei vier Hauptmotive identifiziert werden konnten: Freizeitunterhaltung, zwischenmenschlicher Ausdruck, Informationssuche und Kameradschaft. Die Ergebnisse der Studie zeigen, dass weder Alter und Geschlecht noch die untersuchte soziale und psychologische Vorgeschiede signifikante Prädiktoren für die Rezeption von Nachrichten-Inhalten auf YouTube sind. Hingegen spielt das Motiv der Informationssuche eine weitaus tragendere Rolle. Mehr noch: Diejenigen, die nach Informationen suchten, sahen mit größerer Wahrscheinlichkeit traditionelle Nachrichteninhalte (d.h. Videos, die von klassischen Medienunternehmen produziert und auf YouTube publiziert wurden) – auf dem Video-Streaming-Dienst als ihre Kolleg*innen. Bei der Rezeption von Nachrichten im Comedy- und Satire-Format sieht es etwas anders aus: das männliche Geschlecht und das Motiv der Freizeitunterhaltung können hier als maßgebliche Faktoren festgehalten werden. Die zwei weiteren Hauptmotive – zwischenmenschlicher Ausdruck und Kameradschaft – spielen insbesondere für das Teilen von Videos eine Rolle.

3.2 Selektionsorientierte Ansätze

Selektionsorientierte Ansätze konzentrieren sich insbesondere auf die Hintergründe und Struktur von Auswahlprozessen. Sie bilden die erste Gruppe – neben den rezeptionsorientierten Ansätzen – der prozessualen Mediennutzungstheorien (im Unterschied zu funktionalen und strukturellen Theorieansätzen). Beide Ansätze trennscharf voneinander zu unterscheiden fällt allerdings schwer, da der Übergang von Selektion zu Rezeption ein Fließender ist und die Prozesse selbst eng ineinander verwoben sind. Die meisten Studien zu Selektionsprozessen wenden insgesamt drei Perspektiven an: die Perspektive der Ökonomik, die entscheidungstheoretische Perspektive, sowie die Perspektive der Informationsverarbeitung.

Ersterem liegt die Interpretation von Medienangeboten (in Form von Medienproduktionsgütern, Mediendienstleistungen und Informationen bzw. Medieninhalten) als konkurrierende Konsumgüter im Rahmen des Publikumsmarkts zugrunde. Es wird in diesem Kontext davon ausgegangen, dass Rezipient*innen rationale Kosten-/Nutzen-Entscheidungen (*Homo oeconomicus*) treffen. Dabei schließt sich der Kreis zum Uses-and-Gratifications-Ansatz: Welche Arten von Nutzen vorliegen können und wie der Nutzen eines Medienproduktes von Rezipient*innen beurteilt wird, kann unter anderem mithilfe dieses Ansatzes analysiert werden. Mit dem Nutzen sind auch immer Kosten verbunden, die sich in diesem Fall in monetäre Kosten und Aufmerksamkeit (als Kombination aus Zeit- und Energieressourcen) aufgliedern lassen. Die Aufmerksamkeit spielt im Medienbereich eine bedeutende Rolle, sodass sogar von einem „Aufmerksamkeitsmarkt“ gesprochen werden kann. Das verfügbare Informationsangebot hat sich über die Jahre durch das Internet erheblich erhöht und Rezipient*innen reagieren mit zunehmender Sparsamkeit in Anbetracht ihrer Aufmerksamkeit. Nicht alle Bedürfnisse können in einer bestimmten Situation befriedigt werden. Der Kampf konkurrierender Medienprodukte ist darum ein entsprechend heftiger. Ergänzend zu den direkten Kosten der Mediennutzung müssen also Transaktions- und Opportunitätskosten, sowie die Knappheit von Ressourcen beachtet werden. Abschließend erfolgt jede Kosten-/Nutzen-Entscheidung unter Unsicherheit, da Rezipient*innen niemals die benötigten

Informationen vollständig zur Verfügung stehen. Insbesondere bei Mediengütern lässt sich der Nutzen erst nach der Rezeption (Erfahrungsgüter, z.B. Unterhaltungsangebote) bzw. gar nicht beurteilen (Vertrauensgüter, z.B. Nachrichten). Aus ökonomischer Sicht ist der Nutzen massenmedialer Inhalte eher gering, denn Selektionsentscheidungen werden in der Regel spontan und mit minimaler Anstrengung getroffen.

Zweitere Perspektive geht davon aus, dass jeder Akt der Selektion eine Entscheidung ist. Grundsätzlich hat die Entscheidungstheorie zwei zentrale Forschungsanliegen: Zum einen werden präskriptive bzw. ökonomische Entscheidungsstrategien entwickelt, um theoretisch optimale Management-Entscheidungen zu treffen. Zum anderen wird versucht herauszufinden, nach welchen Regeln, in Abhängigkeit zu spezifischen Zielen, tatsächlich Entscheidungen gefällt werden. Letztere steht der bereits erläuterten Ökonomik sehr nahe, da beide Rezipient*innenentscheidungen als rationales Kosten-/Nutzen-Kalkül begreifen. Allerdings fokussiert sich die Entscheidungstheorie hierbei auf den Verlauf von Entscheidungsprozessen und modelliert diese in unterschiedlichsten Ausprägungen: einfach-spontan bis hin zu gründlich-analytisch. Optionen, Konsequenzen und Ziele zählen zu den wichtigsten Grundbegriffen dieser deskriptiven und kognitionspsychologischen Theorie. Entscheidungen selbst bestehen aus den beiden Komponenten Informationsaufnahme und -verarbeitung. Zusätzlich wird zwischen analytischen Entscheidungsregeln und Heuristiken unterschieden. Entscheidungsregeln beziehen sich auf die Art der getroffenen Entscheidung hinsichtlich der Informationsaufnahme und -verarbeitung. Analytische Regeln zielen beispielsweise auf die jeweils beste Option ab. Verfügbare Information werden also vollständig evaluiert und intensiv bearbeitet. Im Gegensatz dazu werden bei impulsiven oder habituellen Entscheidungen fast immer Heuristiken, also kognitive Abkürzungen, Annäherungen bzw. Faustregeln eingesetzt, um den zeitlichen und kognitiven Aufwand so gering wie möglich zu halten. Grundsätzlich liegt aber allen Entscheidungen ein Evaluierungsprozess zugrunde, der die zur Verfügung stehenden Optionen auf ihre Beschaffenheit und ihren voraussichtlichen Nutzen überprüft. Dazu kommen vier Entscheidungstypen – routinierte, stereotype, reflektierte und konstruktive Entscheidungen – die sich in

ihrem kognitiven Aufwand voneinander unterscheiden. Welche Regeln Rezipient*innen bei ihren Selektionsentscheidungen allerdings tatsächlich anwenden, hängt von unterschiedlichen Faktoren ab, die sich grundsätzlich der Medien- oder der Rezipient*innenseite zuordnen lassen:

Medienfaktoren	Rezipient*innenfaktoren
Kosten-/Nutzenverhältnis	Höhe des Interesses bzw. Involvement
Reversibilität und Verhaltensaufwand	Medienkompetenz
Entscheidungskomplexität	Habitualisierte Mediennutzung
Gegebene vs. Offene Optionsmenge	Persönlichkeit der Rezipientin bzw. des Rezipienten
Gleichzeitige vs. aufeinander folgende Präsentation der Optionen	
Gleichzeitige vs. aufeinander folgende Präsentation der Attribute (Beschaffenheit)	
Einstufigkeit vs. Mehrstufigkeit der Entscheidungen	

Tabelle 1 – Medienfaktoren & Rezipient*innenfaktoren, in Anlehnung an Schweiger 2007, S. 178-182

Letztere Perspektive der selektionsorientierten Ansätze befindet sich im Einklang mit den anderen beschriebenen Ansätzen und betont insbesondere die Rolle von Vorwissen und Routinen bei der Selektion von Medien.

Zusammenfassend gehen selektionsorientierte Ansätze davon aus, dass die Selektion von Medien meist in Niedrigkostensituationen stattfindet, in denen Rezipient*innen, soweit es ihnen möglich ist, ihren Gewohnheiten folgen und Medienangebote nur oberflächlich evaluieren bzw. nach bestehenden Heuristiken entscheiden. Orientierung bieten hierfür medienbezogene Schemata (Vorwissen bzw. Bewertungen) und „Hervorhebungen in Medienangeboten, deren Bedeutung

als redaktioneller Relevanzindikator sie im Lauf ihrer persönlichen Mediensozialisation erlernt haben (Medienkompetenz)“. (Schweiger 2007, S. 167-196)

3.3 Rezeptionsorientierte Ansätze

Rezeptionsorientierte Ansätze fokussieren sich, im Gegensatz zu den bereits beschriebenen selektionsorientierten Ansätzen (siehe Absatz 3.2), auf die Verarbeitung von Informationen, Emotionen und dem subjektiven Erleben während der Rezeption. Sie bilden die zweite Gruppe der prozessualen Mediennutzungstheorien und beinhalten grundsätzlich zwei Auffassungsmöglichkeiten des Terminus Rezeption: Rezeption als Informationsverarbeitung und Rezeption als „Erleben“. Erstere Perspektive fragt nach den Voraussetzungen und Hindernissen effizienter Mediennutzung. Die Intensität der Rezeption, also wie konzentriert oder beiläufig Medien von Individuen genutzt werden, wird hierbei als zentraler Aspekt verstanden. Das Involvement-Konzept spielt in diesem Zusammenhang eine große Rolle und hat sich insbesondere in der Kommunikationswissenschaft und Medienpsychologie über die vergangenen Jahre etabliert. Allerdings besteht dieses aus zwei konkurrierenden Vorstellungen von Involvement:

- *Kognitives Involvement*

Unter kognitivem Involvement ist das Interesse bzw. die Motivation eines Individuums zu verstehen, einen (Medien-)Inhalt aufmerksam und aktiv aufzunehmen und zu verarbeiten. Eine geringe Überredbarkeit, erkennbare Lerneffekte und eine dauerhafte Meinungsanpassung, sofern die oder der Rezipient*In von guten Argumenten persuadiert wurde, lassen sich zu den Ergebnissen einer solchen „distanziert-analysierenden“ Rezeption zählen.

- *Affektives Involvement*

Mit dem affektiven Involvement ist die emotionale Ergriffenheit oder auch Erregtheit in der Rezeptionsphase gemeint, die zwar mit einer hohen Aufmerksamkeit einhergeht, hingegen eine aktiv-analytische

Informationsverarbeitung nicht zulässt. Man kann diese Vorstellung von Involvement auch als „distanzlos-involvierte“ Rezeption beschreiben und spricht in diesem Kontext von einem „Low-Involvement“.

In Bezug auf Medienrezeptionssituationen gilt das bildhaft-emotionalisierende Fernsehen beispielsweise als „Low-Involvement-Situation“, die kognitiv-aktiv geprägte Nutzung von Printmedien hingegen gilt eher als „High-Involvement-Situation“. Innerhalb einer Nutzungsepisode oder auch über einen längeren Zeitraum hinweg kann sich das Involvement zu jeder Zeit ändern. Man spricht in diesem Kontext auch von Themenkarrieren und damit zusammenhängenden Ermüdungserscheinungen der Rezipient*innenschaft, welche unter dem „Wear-out-Effekt“ bekannt sind. Insgesamt haben sich zum Einfluss des Involvements auf die Prozesse der Informationsverarbeitung mehrere Theorien entwickelt, unter den drei bekanntesten finden sich das „Elaboration-Likelihood-Modell“ von Petty und Cacioppo (1986), das „Heuristic-Systematic-Model“ von Chaiken (1980) und das „Modell der Alltagsrationalität“ von Brosius (1995). In allen erwähnten Ansätzen existieren ebenfalls die zwei bereits erwähnten Informationsverarbeitungsmodi: High-Involvement und Low-Involvement. Eine Weiterentwicklung der bisher dargelegten Dual-Process-Theorien stellt das „Limited-Capacity-Model“ von Lang (1995, 2000) dar. Dabei nimmt die Autorin drei aufeinanderfolgende Subprozesse der Informationsverarbeitung an: An erster Stelle steht der untergeordnete Prozess der Enkodierung („encoding“), gefolgt von der Speicherung („storage“) und dem dritten Subprozess des Abrufens von Informationen („retrieval“). Diese Subprozesse konkurrieren untereinander um die verfügbaren kognitiven Ressourcen einer Rezipientin oder eines Rezipienten. Hier schließt sich ebenfalls der Kreis zum zuvor beschriebenen Involvement-Konzept: Bei zu geringem Involvement reicht die eingesetzte Energiemenge für die einzelnen Subprozesse wahrscheinlich nicht aus. Im Gegensatz dazu kann es bei einem hohen bis hin zu einem maximalen Involvement zu einer Informationsüberlastung kommen. Erregende und reizvolle Inhalte können demnach die Fähigkeit, Zusammenhänge zu verstehen, einschränken.

Allerdings liegt das Hauptaugenmerk der rezeptionsorientierten Ansätze mittlerweile beim (Medien-)Erlebnis. Bei der Rezeption als „Erleben“ – zweitere Perspektive der rezeptionsorientierten Ansätze – geht es um die kognitive und affektive Erlebnisqualität der Mediennutzung. Die Qualität eines solchen Erlebnisses kann in diesem Zuge als hoch eingestuft werden, wenn die erstrebten Emotionen während einer Mediennutzung empfunden werden. Je intensiver und positiver der Akt der Rezeption erlebt wird und sich damit einhergehend auch die erwarteten mit den erhaltenen Gratifikationen decken, desto häufiger werden entsprechende Medien auch in Zukunft genutzt. Hauptgrundlage der Erlebnisqualität bilden Interaktivität und Multimedialität. Das zuvor beschriebene Involvement-Konzept findet in diesem Zusammenhang kaum mehr Anwendung. Stattdessen entwickelte die Medienpsychologie weitere Konzepte – die berühmtesten darunter: Flow, Presence (inkl. der Perceived-Reality-Forschung), Immersion und Transportation – um intensive Medienerlebnisse zu beschreiben. (Schweiger 2007, S. 196-221)

3.4 Kontextbezogene Ansätze

Die eben beschriebenen selektions- und rezeptionsorientierten Ansätze sind Bestandteil der prozessualen Perspektive der Theorien zur Mediennutzung. Die kontextbezogenen Ansätze werden der strukturellen Perspektive der Mediennutzung zugeordnet und haben grundsätzlich eines gemeinsam: sie untersuchen und analysieren menschliches Verhalten mittels qualitativer Methoden, meist in Form von Beobachtungen und Beschreibungen bestimmter Individuen, Gruppen und Situationen in sozialen und kulturellen Kontexten. Drei bedeutende kontextbezogene Ansätze stellen die Handlungstheorie, die Medienaneignung, sowie die Cultural Studies. Wobei die Medienaneignung für qualitativ Forschende, die sich auf die Handlungstheorie oder auch die Cultural Studies berufen, ein zentrales Konzept darstellt.

Die Handlungstheorie versucht vor allem die inneren Vorgänge, also Gedanken, Intentionen und Gefühle in die Analyse miteinzubeziehen. Allgemeine Gesetzmäßigkeiten werden im Gegensatz zum Behaviorismus bzw. der

Verhaltenstheorie nicht abgeleitet. Die Rede ist in diesem Zusammenhang von einem symbolischen Interaktionismus, der den Menschen in einer symbolhaften Welt konzeptualisiert, in der soziale Situationen, Objekte und Handlungen „zusätzliche symbolische Bedeutungen enthalten“. Menschen müssen den erlebten Interaktionen also erst einen Sinn geben und interpretieren („sense-making“). In Bezug auf Medieninhalte wirken diese nicht alleine auf den Menschen, vielmehr ist die mit dem Medieninhalt einhergehende situativ-subjektive Interpretation die wirkende Komponente. Handlungen werden als sinnvoll-intentionaler Akt, der auf bewusster Interpretation basiert, verstanden. Unterschieden wird allerdings zwischen gelernten bzw. auf Erfahrung aufbauenden Handlungen (Routinen) und Handlungen, die situativ eine vollständige und interpretative Verarbeitung verlangen, da der Vorrat an Wissen in dieser Situation nicht ausreichend vorhanden ist. Allerdings wird auch in solchen nicht-alltäglichen, problematischen Situationen nicht unwissend gehandelt, denn bereits bekannte Motive („Um-zu-Motiv“, „Weil-Motiv“) und die Referenz zu früheren Situationen prägen die zu tätigende Handlung. Der symbolische Interaktionismus schlägt hierfür drei Konzepte vor:

- *Situationen*

Situationen liefern einen Rahmen für jede Handlung und haben Einfluss wie Handlungen getätigter werden. Eine Lösung der Handlung von der jeweiligen Situation, in der diese getätigter wird, macht in der Analyse dementsprechend wenig Sinn. Letztendlich könnte auch behauptet werden, dass jegliches Ziel zur Verallgemeinerung von Handlungen nicht erreicht werden kann. Rezeptionsforscher*innen helfen sich in diesem Falle mit der Bildung klar umrissener und vergleichbarer Handlungstypen und bewerten selbige nur in tatsächlich vergleichbaren Situationen bzw. Handlungsklassen.

- *Rollen*

Je nach Situation nimmt die oder der Handelnde eine bestimmte Rolle ein. Solch ein soziales Schemata erleichtert den zwischenmenschlichen Umgang und gibt klare Hinweise, wie Personen ihre Situation einordnen bzw.

interpretieren können und sind imstande, das Verhalten einer Person zu prognostizieren.

- *Perspektiven*

Perspektiven sind mit Rollen eng verbunden, denn mit jeder Situation und eingenommenen Rolle gehen auch bestimmte Interessen einher. Situativ eingenommene Rollen prägen also einerseits das Handeln, und andererseits auch die Perspektive, mit der die jeweilige Situation interpretiert wird.

Ein weiteres bedeutendes Konzept unter den kontextbezogenen Ansätzen stellt das Medienaneignungskonzept, worin unterschiedliche Konstrukte der Mediennutzung betrachtet werden. Zentrales Element bildet der Rezeptionsprozess, indem erst die ursprüngliche Bedeutung des Medieninhalts und die anschließende subjektive und situative Interpretation analysiert werden. Das Konzept der Medienaneignung geht also noch einen Schritt weiter als die Rezeptionsforschung, und setzt Interpretationen von Inhalten – wobei mehrere Interpretationsschritte aufeinander folgen – in Verbindung zu persönlichen Erfahrungshintergründen und Wissen von Mediennutzer*innen. Aus dieser Verbindung resultiert auch der Begriff „Aneignung“, denn Mediennutzer*innen machen sich den Inhalt eines Mediums während und nach der Nutzung buchstäblich zu eigen. Rückbeziehend auf die Handlungstheorie lassen sich Rezeptions- als auch Aneignungsprozesse nur unter Rücksichtnahme auf situative Kontexte und soziokulturelle Praxen verstehen. Allerdings kann diese intensive Untersuchung des Medienumgangs nur qualitativ erfolgen und begrenzt somit die Möglichkeit zur Verallgemeinerung der Ergebnisse. Zentraler Kritikpunkt dieses Konzepts ist die Uneinigkeit über den wissenschaftlichen Wert der Ergebnisse aus Einzelfallbeobachtungen. Abhilfe schafft das dritte und letzte bedeutende Konzept der kontextbezogenen Ansätze: Die Cultural Studies. Sie bemühen sich insbesondere um die Veränderung der soziokulturellen und politischen Verhältnisse. Der ursprünglich elitäre Kulturbegriff wurde durch die Kulturwissenschaft in den 1960er-Jahre aufgebrochen und um alle sozialen und kulturellen Bräuche, alltäglichen Aneignungsprozesse sowie der öffentlichen Meinung erweitert. Die Cultural Studies dienen seitdem als fächerübergreifender Forschungsansatz und beruhen auf fünf Prinzipien:

- *Politische Intervention*

Analysen im Rahmen der Cultural Studies beziehen eine klare Position und dienen als ideologischer Beitrag in kulturell-politisch geprägten Diskursen. Soziale Realität bzw. Wahrheit entsteht aus einem Wettstreit der Ideen, Meinungen und Realitätsentwürfe. Wissenschaft soll in diesem Sinne ganz klar argumentativ überzeugen und zu etwaigen Veränderungen motivieren. Statt lediglich Fakten zu produzieren geht es darum, die Gesellschaft zu verbessern und sich gegen wahrgenommene Mängel bzw. Fehlentwicklungen stark zu machen. Damit wenden sich Cultural Studies nicht nur an die Wissenschaftsgemeinde, sondern an die Öffentlichkeit.

- *Radikaler Kontextualismus*

Praktiken sind kulturell geprägt und können laut dem radikalen Kontextualismus nur unter Rücksichtnahme auf bestehende Machtstrukturen und weiterer sozialer Kontexte demonstriert werden.

- *Kontextuelles Theorieverständnis*

Theorien dürfen nie aus dem Kontext herausgelöst werden, in dem sie entstanden sind.

- *Selbstreflexion*

Forscher*innen sind dazu aufgefordert ihre persönliche Nähe (persönliche Neigungen, politische Werte, normative Interessen, etc.) zur Auseinandersetzung mit dem Untersuchungsgegenstand offen zu legen und darüber zu reflektieren. Die alleinige methodische Transparenz reicht in diesem Falle nicht aus.

- *Interdisziplinarität*

Das zuvor erwähnte offene Kulturkonzept der Cultural Studies erweist sich im Sinne der Interdisziplinarität als hilfreiche Klammer für die Zusammenarbeit unterschiedlicher geistes- und sozialwissenschaftlicher Fächer.

Grundsätzlich lässt sich die Forschung im Bereich der Cultural Studies in zwei Strömungen aufteilen: Kulturalismus und Strukturalismus. Erstere begreift Kultur als jegliche Erscheinung sozialer Praxis und hebt im Zuge dessen die Fähigkeiten des

Menschen im Umgang mit Medien und weiteren kulturellen Artefakten hervor. Im Kulturalismus geht es also um die Decodierung von (Medien-)Inhalten in konkreten sozialen Kontexten. Zweitere Strömung, der Strukturalismus, versteht im Gegensatz dazu, Kultur als ein abstraktes System: Gesellschaftliche Teilgruppen und Schichten haben einen unterschiedlich großen Anteil am sozialen Diskurs. Die Rede ist hier von diskursiven Machtverhältnissen. (Schweiger 2007, S. 313-328)

3.5 Zwischenfazit

Im vorangegangenen Kapitel wurde näher auf Mediennutzungstheorien eingegangen. Darunter wurden speziell der Uses-and-Gratifications-Ansatz, sowie selektions- und rezeptionsorientierte, als auch kontextbezogene Ansätze erläutert. Sie spielen auch für Plattformen wie YouTube eine wichtige Rolle.

Allgemein beschäftigt sich der Uses-and-Gratifications-Ansatz mit den Fragestellungen, weshalb Menschen welche Medien nutzen, was sie mit diesen machen und welche individuellen Bedürfnisse im Zuge der Mediennutzung befriedigt werden sollen. Während dieser Ansatz also die funktionale Perspektive der Mediennutzungstheorien einnimmt, bilden selektions- und rezeptionsorientierte Ansätze die prozessuale Perspektive der Mediennutzungstheorien. Sie beschäftigen sich mit den Hintergründen und Strukturen von Selektionsprozessen sowie die Verarbeitung von Informationen, Emotionen und dem subjektiven Erleben während der Rezeption. Selektionsprozesse wurden in diesem Kapitel aus drei unterschiedlichen Perspektiven - der Ökonomik, der Entscheidungstheorie und der Informationsverarbeitung - betrachtet. Im Abschnitt der rezeptionsorientierten Ansätze wurden ebenfalls zwei Perspektiven erläutert: Rezeption als Informationsverarbeitung und Rezeption als „Erleben“. Die kontextbezogenen Ansätze nehmen abschließend die strukturelle Perspektive der Mediennutzungstheorien ein. Beschrieben wurden in diesem Abschnitt die Handlungstheorie, die Medienaneignung und die Cultural Studies als drei bedeutende kontextbezogene Ansätze. Sie versuchen mittels qualitativer Methoden das menschliche Verhalten in Bezug auf die Nutzung von Medien zu analysieren.

Bezugnehmend auf YouTube als Plattform geht aus diesem Kapitel klar hervor, dass weder das Alter und Geschlecht noch die soziale und psychologische Vorgeschiede der Nutzer*innen signifikante Prädiktoren für die Rezeption von Nachrichten-Inhalten auf YouTube sind. Das Motiv der Informationssuche spielt in diesem Kontext eine weitaus tragendere Rolle. Zusätzlich greift YouTube auf bekannte Heuristiken, wie sie bereits in den selektionsorientierten Ansätzen beschrieben wurden, zurück, indem beispielsweise passende Videos im Anschluss vorgeschlagen werden. Der Video-Streaming-Dienst übernimmt also im Vorfeld die Selektion.

4 Die Plattformökonomie

Von Uber oder AirBnb, über Amazon, bis hin zu den populären Social Media-Plattformen Facebook, Instagram und YouTube: Unternehmen, die gekonnt die Plattform-Logik für sich nutzen und zunehmend die Welt beherrschen. Im vorliegenden Kapitel soll nun näher auf die Grundlagen der Plattformökonomie und deren Geschäftsmodelle eingegangen werden. Die Relevanz von YouTube, insbesondere in Österreich und dessen konkrete Funktionsweise sollen ebenfalls Eingang in dieses Kapitel finden.

4.1 Grundlagen zur Plattformökonomie

Plattformmärkte, so wie wir sie bisher kennen, sind hoch dynamisch und zeichnen sich durch eine hohe Kompetitivität aus. Wie bereits im vorangegangenen Kapitel zu den Mediennutzungstheorien (Kapitel Drei) beschrieben wurde, ist Aufmerksamkeit das höchste Gut dieser Zeit. Im Wettbewerb geht es nicht mehr darum, wie man die Wertschöpfungskette kontrolliert, sondern darum, generative Aktivitäten mithilfe einer Plattform zusammenzuführen (de Reuver, Sørensen & Basole 2018, S. 124). Digitale Plattformen verändern Phänomene in der gesamten Informationssystem-Landschaft. Die Interaktion von Nutzer*innen mit Organisationen verändert sich, da digitale Plattformen den Zusammenschluss von Verbraucher*innen mittels Online-Communities erleichtern (Spagnoletti et al. 2015). Die interorganisatorischen Beziehungen der Informationssystem-Entwicklung

verändern sich, da traditionelle Principal-Agent-Beziehungen für die Softwareentwicklung durch marktübliche Beziehungen zwischen App-Entwickler*innen und Plattformanbieter*innen ersetzt werden (Tiwana & Konsynski 2010; Ghazawneh & Henfridsson 2013; Eaton et al. 2015). Die Architekturen von Informationssystem-Artefakten ändern sich, da die Modularität digitaler Plattformen traditionelle monolithische Ansätze ersetzt (Tiwana & Konsynski 2010).

Wissenschaftler*innen im Bereich des industriellen Innovationsmanagements sehen in Plattformen einen stabilen Kern und eine variable Peripherie (Baldwin & Woodard 2009). Diese Konzeptualisierung sieht Möglichkeiten für eine verteilte Entwicklung und rekombinante Innovation durch Modularisierung vor (Henderson & Clark 1990; Baldwin & Clark 2000). Aus dieser Perspektive kann eine Plattform nach ihrem Umfang des Produktionsprozesses kategorisiert werden:

- Interne Plattformen, die eine Rekombination von Untereinheiten innerhalb des Unternehmens ermöglichen
- Supply-Chain-Plattformen, die externe Lieferanten um einen Assembler herum koordinieren
- Industriekonzerne, bei denen ein Plattformführer externe Fähigkeiten von Komplementoren bündelt (Gawer 2014).

Bei den beiden letztgenannten Typen bieten Plattformen nicht nur einen stabilen Kern, sondern vermitteln auch zwischen verschiedenen Gruppen von Nutzer*innen. Eine Plattform, die verschiedene Nutzer*innengruppen wie Käufer*innen und Verkäufer*innen vermittelt, wird typischerweise als multiseitige Plattform bezeichnet (Boudreau & Hagi 2009). Beidseitige Märkte führen zwei verschiedene Gruppen in einer Beziehung zusammen, bei der der Wert für eine Gruppe mit zunehmender Anzahl der Teilnehmer*innen aus der anderen Gruppe steigt (Evans 2003; Eisenman et al. 2006). In diesem Kontext wird insbesondere von Netzwerkeffekten oder auch Netzwerkexternalitäten gesprochen. Netzwerkexternalitäten bedeuten, dass der Nutzen einer Technologie mit zunehmender Anzahl der installierten Nutzer*innen steigt (Katz & Shapiro 1985; Shapiro & Varian 1998). Steigende Akzeptanzniveaus können positive Feedback-Zyklen auslösen, die den Nutzen der Technologie weiter erhöhen (Arthur 1989). Evans (2003) betont hierbei ebenfalls die Notwendigkeit eines Vermittlers bzw. Intermediärs zur Internalisierung von Externalitäten, die von einer Gruppe zum Nutzen der anderen geschaffen wurden.

Typischerweise sind Netzwerkexternalitäten (Katz & Shapiro 1985) direkt, wenn der Wert der Plattform von der Anzahl der Nutzer*innen in derselben Nutzer*innengruppe abhängt, d.h. der Wert des Produkts steigt, wenn andere die gleiche Plattform oder die über die Plattform bereitgestellten Dienste kaufen, verbinden oder nutzen. Beispiele für direkte Netzwerkeffekte sind Social Media Plattformen, die wertvoller werden, wenn mehr Endnutzer*innen der Plattform beitreten. Externalitäten sind indirekt, wenn der Wert der Plattformen von der Anzahl der Nutzer*innen in einer anderen Nutzer*innengruppe abhängt. Beispielsweise werden Videospielkonsolen für Verbraucher*innen immer wertvoller, sobald mehr Entwickler*innen Spiele für diese Konsole entwickeln. Indirekte Netzwerkeffekte können allerdings auch negativ sein: Sobald die Einführung eines neuen Produkts oder einer neuen Technologie begonnen hat, bieten diese Netzwerkexternalitäten sowohl neuen als auch bestehenden Nutzer*innen Vorteile wie reduzierte Preise, geringere Unsicherheit über zukünftige Versionen von Plattformen und ergänzenden Diensten, Gemeinschaften von Nutzer*innen, höherwertige Produkte und neue Marktchancen (Dew & Read 2007).

Die ökonomische Forschung zu zweiseitigen Märkten befasst sich vor allem mit der finanziellen Dynamik des Wettbewerbs zwischen Plattformen und der Quersubventionierung (Rochet & Tirol 2003), ihrer Preisdynamik und dem intensiven Wettbewerb (Eisenman et al. 2006). Der übergreifende Fokus der ökonomischen Sichtweise liegt darauf, wie die wirtschaftlichen Kräfte vielschichtige Märkte von anderen Marktordnungen unterscheiden. Das Interesse an Preisstrategien und finanzieller Dynamik steht im Mittelpunkt der ökonomischen Forschung zu Plattformen.

Was genau macht nun digitale Plattformen aus? Grundsätzlich gibt es verschiedene Konzeptualisierungen von digitalen Plattformen. Sie können einerseits als rein technische Artefakte definiert werden, bei denen die Plattform eine erweiterbare Codebasis ist und das Ökosystem aus Modulen Dritter besteht, die diese Codebasis ergänzen (Tiwana et al. 2010; Boudreau 2012). Eine digitale Plattform kann andererseits aber auch als soziotechnische Assemblage charakterisiert werden, die die technischen Elemente (von Software und Hardware) und die damit verbundenen organisatorischen Prozesse und Standards umfasst (Tilson et al. 2012).

Ghazawneh und Henfridsson (2015) bauen auf Tiwana et al. (2010) auf, indem sie digitale Plattformen als „softwarebasierte externe Plattformen, die aus der erweiterbaren Codebasis eines softwarebasierten Systems bestehen, das Kernfunktionen bereitstellt, die von den Modulen, die mit ihm interagieren, und den Schnittstellen, über die sie interagieren, gemeinsam genutzt werden“ definieren. Eine digitale Plattform umfasst demnach verschiedene Module, die die Funktionalität des Softwareprodukts erweitern (Sanchez & Mahoney 1996; Baldwin & Clark 2000). Diese Module können als "Add-on-Software-Subsysteme" bezeichnet werden (Tiwana & Konsynski 2010, S. 676), oft in Form von Anwendungen, die von Drittanbieter*innen entworfen und entwickelt wurden. Solche Anwendungen können auch als "ausführbare Software, die als Anwendungen, Dienste oder Systeme für Endnutzer*innen angeboten wird", definiert werden (Ghazawneh & Henfridsson, 2013, S. 175). Damit geht auch die Frage einher, wie digitale Plattformen zu verwalten sind. Beispielsweise wirft die Rekombinierbarkeit digitalisierter Elemente durch digitale Konvergenz und die damit verbundene Genitivität paradoxe Beziehungen von Veränderung und Kontrolle auf (Tilson et al., 2010): Das Paradoxon des Wandels impliziert, dass digitale Plattformen gleichzeitig stabil bleiben müssen, um eine solide Grundlage für die weitere Einschreibung zu bilden, und dennoch ausreichend flexibel sind, um scheinbar grenzenloses Wachstum zu unterstützen. Das Paradoxon der Kontrolle stellt die gegensätzliche Logik digitaler Plattformen dar, die gleichzeitig von einer zentralisierten und verteilten Kontrolleinheit gesteuert werden. Die Entwicklung der iOS- und Android-Plattformen und der damit verbundenen Ökosysteme von Apps und Stakeholdern veranschaulicht das Kontrollparadoxon, da unterschiedliche Kontrollregelungen die Generativität sowohl behindert als auch verstärkt haben. Die Fähigkeit, einen schnellen, selbstverwalteten Prozess der kontinuierlichen automatischen Aktualisierung von Apps und Betriebssystem-Ressourcen zu ermöglichen, hat stabile, aber sich ständig weiterentwickelnde Plattformen geschaffen. Dies stellt die bestehenden Vorstellungen von der Geschwindigkeit des Wandels in großen verteilten technischen Einrichtungen in Frage. (de Reuver, Sørensen & Basole 2018, S. 127)

Henfridsson und Bygstad (2013) schlagen in ihrer Arbeit „The Generative Mechanisms of Digital Infrastructure Evolution“ vor, dass zum besseren Verständnis

der Dynamik digitaler Plattformen der Gegenstand der Analyse nicht die Plattform selbst sein sollte, sondern ihre Grenzkapazitäten. Begrenzte Ressourcen bestehen aus Softwaretools und Vorschriften, die die marktüblichen Beziehungen zwischen Plattformanbieter*innen und App-Entwickler*innen erleichtern. Eaton et al. (2015) bauen auf dieser Idee auf, indem sie die Plattformdynamik in Form von verteilten Akteur*innen konzeptionieren, die die Ressourcen an den Grenzen sammeln. Diese alternativen Analyseeinheiten markieren eine Abkehr von eigner*innenzentrierten Ansichten in der traditionellen Literatur des Innovationsmanagements, die sich auf die bzw. den Plattformbesitzer*in als Schlüsselorganisation konzentriert, die eine Reihe von Komplementoren verwaltet (Iansiti & Levien 2004a, b). Während Offenheit in Bezug auf nicht-digitale Plattformen diskutiert wurde (Eisenman et al., 2006), macht die Digitalität auch hier einen grundlegenden Unterschied. Für digitale Plattformen bezieht sich Offenheit nicht nur auf organisatorische Regelungen wie Ein- und Austrittsregeln, sondern auch auf die Offenheit von Technologien wie APIs und Software Development Kits (SDKs). Für mobile Plattformen wie iOS und Android (Benlian et al. 2015), digitale Marktplätze (Ghazawneh & Henfridsson 2015) und Zahlungsplattformen (Ondrus et al. 2015) gibt es in der Praxis unterschiedliche Offenheitsgrade.

Abschließend können digitale Plattformen als ein weniger komplexer Subtyp der digitalen Infrastruktur mit spezifischen Kontrollregelungen angesehen werden (Hanseth & Lyytinen 2010). Sie zeichnen sich zusammenfassend durch eine hohe Skalierbarkeit und Reichweite, der Möglichkeit zur Auswertung einer großen Datenmenge, niedrige Transaktionskosten, starke Netzwerkeffekte, sowie einer hohen Dynamik aus (von Engelhardt, Wangler & Wischmann 2017, S. 11-15). Digitale Plattformen, treten in erster Linie als wirtschaftlich ausgerichteter und digitaler Intermediär auf, der die oben genannten Merkmale aufweist.

4.2 YouTube als Plattform

Der Video-Streaming-Dienst YouTube, 2005 gegründet und aktuell Teil des Alphabet-Konzerns, kann ebenfalls der Plattformökonomie zugeordnet werden. Zusätzlich gilt YouTube als zweitgrößte Suchmaschine der Welt, nach Google. Allem voran ist YouTube die weltweit größte Plattform zum Erstellen, Teilen und

Entdecken von Videoinhalten. YouTube-Empfehlungen sind dafür verantwortlich, dass Nutzer*innen personalisierte Inhalte aus einem ständig wachsenden Bestand an Videos entdecken. (Covington, Adams & Sargin 2016, S. 1) Nach Covington, Adams und Sargin (2016) ist die Plattform eines der größten und leistungsfähigsten industriellen Empfehlungssysteme überhaupt. Was das bedeutet wird allerdings in den folgenden Kapiteln zu Algorithmen (Kapitel Fünf) und Algorithmen-basierter Empfehlungssysteme und die Entstehung von Filterblasen (Kapitel Sechs) eingegangen.

Grundsätzlich erreicht YouTube global 1,9 Milliarden Nutzer*innen, die sich monatlich anmelden. Täglich werden über eine Milliarde Stunden Videos wiedergegeben und damit Milliarden Aufrufe generiert. Insgesamt werden durch 91 lokalisierte Versionen der Plattform, in insgesamt 80 verschiedenen Sprachen, rund 95 Prozent der Gesamtheit der Internetnutzer*innen erreicht. Hinsichtlich der Nutzung ist auch bei YouTube ein Trend erkennbar: Nutzer*innen tendieren dazu die gewünschten Videos zu über 70 Prozent der gesamten Wiedergabezeit über mobile Geräte aufzurufen. (YouTube, Presseinhalt, 2019) Durch die Nutzung werden „Leersituationen“ im Leben der Menschen gefüllt. Etwa während der Nutzung des öffentlichen Verkehrsnetzes oder in Wartezimmern von Ärzt*innen. In letzter Konsequenz dienen also Plattformen, wie YouTube, der Überbrückung dieser leeren Zeit.

Zunächst soll aber darauf eingegangen werden was den Video-Streaming-Dienst überhaupt zu einer Plattform macht. Wie bereits im vorangegangenen Abschnitt beschrieben wurde, zeichnen sich Plattformmärkte insbesondere durch ihre Beid- bzw. Mehrseitigkeit aus. Folgende Grafik (Abbildung 1) verdeutlicht diesen Zustand:

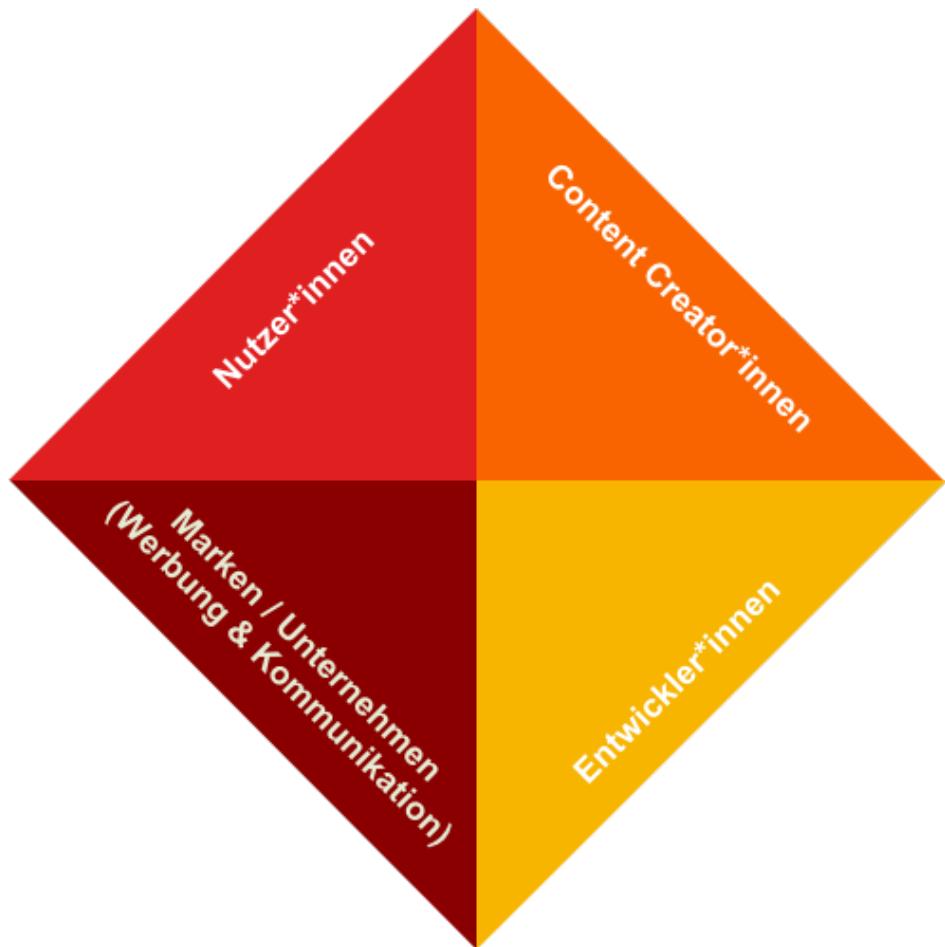


Abbildung 1 – Die Plattform YouTube: Ein multiseitiger Markt (eigene Darstellung)

Insgesamt verbindet YouTube als Intermediär vier Akteursgruppen: Erstens die Nutzer*innen, die auf YouTube veröffentlichten Inhalte rezipieren, zweitens die Content Creator*innen, also Personen, die diese Inhalte erstellen, darunter finden sich auch die allseits bekannten „Influencer*innen“ (Personen, die als Markenbotschafter*innen auftreten und dabei großen Wert auf ihre Authentizität legen), drittens Marken und Unternehmen, die mithilfe von YouTube ihre Botschaften (Werbung und Kommunikation) an die gewünschte Zielgruppe senden, sowie viertens Entwickler*innen, die dabei helfen, die Reichweite der Plattform zu steigern.

Für erstere Gruppe, den Nutzer*innen, kann von einem eher passiven Nutzungsverhalten („lean-back“) gesprochen werden. Das Algorithmen-basierte Empfehlungssystem, das seitens YouTube eingesetzt wird, hat einen großen Einfluss auf das Nutzungsverhalten. Beispielsweise wird nach jedem Video

augenblicklich das nächste Video per Autoplay-Funktion abgespielt. Dadurch haben Empfehlungen einen größeren Einfluss, denn die Nutzer*innen müssen sich nicht aktiv für den nächsten Inhalt entscheiden. Mit der Zeit lernt der Empfehlungsalgorithmus zudem, welche Inhalte am besten zum Profil einer Nutzerin bzw. eines Nutzers passen und passt dementsprechend die Vorschläge immer besser an. Hier kann bereits von der Entstehung sogenannter Filterblasen gesprochen werden, auf die in Kapitel Sechs dieser Arbeit noch näher eingegangen wird. Das Ziel der Plattform ist natürlich die Sessions der Nutzer*innen so lange wie möglich zu gestalten. Laut dem Media Activity Guide (2018, S. 26) liegt die durchschnittliche tägliche Nutzungsdauer von YouTube bei 11 Minuten.

Content-Creator*innen erstellen Inhalte in Form von Videos. Hervorzuheben ist hierbei, dass diese Gruppe von Akteur*innen, teilweise auch Geld mit dieser Arbeit verdienen. Laut YouTube ist die Anzahl an Kanälen, die pro Jahr sechsstellige Einnahmen erzielen, im Vergleich zum Vorjahr um 40 Prozent gestiegen. Die Anzahl an Kanälen, die pro Jahr fünfstellige Einnahmen erzielen, ist im Vergleich zum Vorjahr um 50 Prozent gestiegen. Ebenfalls ist die Anzahl an Kanälen mit mehr als einer Million Abonnent*innen im Vergleich zum Vorjahr um mehr als 75 Prozent gestiegen. (YouTube, Presseinhalte, 2019) Daraus geht klar hervor, dass die Plattform wächst, genaue Zahlen werden allerdings nicht veröffentlicht.

Nachdem Content-Creator*innen eine wichtige Gruppe für den Video-Streaming-Dienst darstellen, bietet YouTube für diese zahlreiche Benefits. Den Anfang bildet eine eigene YouTube „Creator Academy“ (YouTube Creators, 2019), mit digitalen Kursangeboten, wie beispielsweise „Mit Anzeigen auf YouTube Geld verdienen“, „Langfristiger Erfolg auf YouTube“ oder auch „360-Grad-Videos und virtuelle Realität“. Analog vereint YouTube seine Content Creator*innen im sogenannten „YouTube Space“, Orte an denen YouTuber*innen zusammenkommen, sich austauschen und an von YouTube organisierten Veranstaltungen und Workshops teilnehmen können. Zusätzlich kann auf modernstes Produktionsequipment zurückgegriffen werden. (YouTube Space, 2019) Darüber hinaus veranstaltet YouTube im Rahmen des „YouTube NextUp“-Wettbewerbs mehrmals im Jahr fünftägige „Creator Camps“. Durch die Teilnahme haben Content Creaor*innen die Möglichkeit zahlreiche Kurse zu belegen, um ihren eigenen Kanal noch

erfolgreicher zu machen. (YouTube NextUp, 2019) Ab einer Anzahl von 100.000 Abonennnt*innen stellt YouTube den Produzent*innen sogar eine*n eigenen Partnermanager*in zur Seite.

Mit der dritten und letzten Gruppe, der Marken und Unternehmen, wird auch das Geschäftsmodell YouTubes offengelegt. Werbung hat einen großen Stellenwert für die Plattform, schließlich wird ein Großteil der Erlöse über den Verkauf von Werbeplätzen generiert. Ähnlich wie bei Google haben Marken und Unternehmen die Möglichkeit Videoanzeigen zu schalten. Die Zielgruppe kann präzise festgelegt werden und verrechnet wird erst, wenn die oder der jeweilige Nutzer*in Interesse daran zeigt. Interesse wird dann zum Ausdruck gebracht, wenn die Anzeige beispielsweise für mindestens 30 Sekunden aufgerufen oder mit ihr interagiert wird, indem die oder der Nutzer*in entweder auf ein Overlay mit Call-to-Action, eine Infokarte oder ein Companion-Banner klickt. Vorab haben Werbepartner*innen die Möglichkeit ihr Budget festzulegen, je nachdem wie breit das Spektrum potenzieller Kund*innen, das es zu erreichen gilt, sein soll. Anpassungen können jederzeit getroffen werden. (YouTube Werbung, 2019)

Entwickler*innen erhalten von YouTube kostenlosen Zugang zu Application Programming Interfaces (APIs) und Tools, damit sämtliche YouTube-Funktionen auf weiteren Websites, Apps und Geräten integriert werden können. (YouTube für Entwickler, 2019) Damit trägt diese Akteursgruppe ebenfalls dazu bei, die Plattform noch bekannter zu machen, und dementsprechend beflügeln sie auch das Geschäft des Anbieters.

Unklar bleibt allerdings wie hoch die Erlöse der Plattform tatsächlich sind. Wie Wakabayashi von der New York Times (2019) berichtet liegt YouTubes Jahresumsatz wahrscheinlich bei 16 bis 25 Milliarden US-Dollar. Damit ist der Video-Streaming-Dienst groß genug sogar die obere Hälfte der Fortune 500 zu knacken. Warum es stets bei Vermutungen diesbezüglich bleibt liegt klar auf der Hand: Die finanziellen Ergebnisse des Unternehmens werden mit dem Rest des Mutterkonzerns Google in einen Topf geworfen, der vergangenes Jahr 137 Milliarden US-Dollar Umsatz erwirtschaftete.

Der folgende Abschnitt setzt sich nun mit der Relevanz der Plattform in Österreich auseinander.

4.3 YouTube in Österreich

Auch in Österreich erfreut sich der Video-Streaming-Dienst YouTube immer größerer Beliebtheit. Laut dem Digital News Report (2018, S. 65) ist YouTube sogar das am zweit häufigsten genutzte soziale Medium im Land. Vor allem die Plattform YouTube bietet einen Dienst, der von allen Altersgruppen stark verwendet wird. Der Großteil der Nutzer*innen, knappe 82 Prozent, sind allerdings zwischen 18 und 24 Jahren alt. Das folgende Diagramm (Abbildung 2) zeigt die Verteilung der YouTube Nutzer*innen nach Alter.

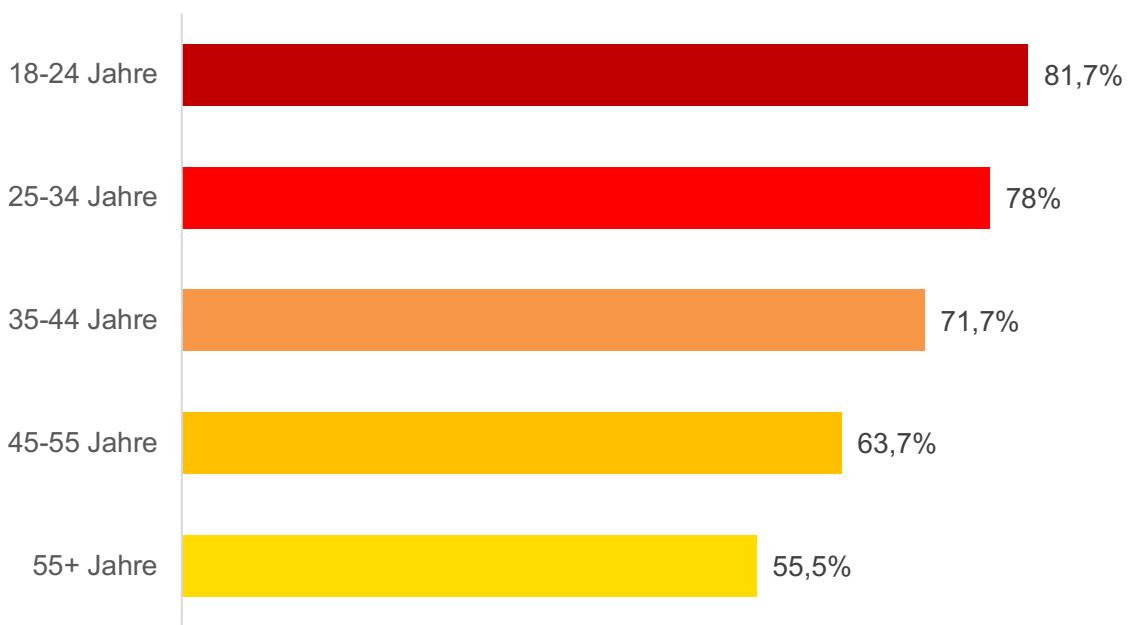


Abbildung 2 – YouTube-Nutzer*innen in Österreich nach Alter (in Anlehnung an Gadringer, et. al., Digital News Report 2018, S. 66)

YouTube zählt zudem zu den am häufigsten für Nachrichten genutzten Social Media-Dienste (19,5 Prozent), nach Facebook (30,4 Prozent) und vor WhatsApp (19,1 Prozent). Dabei hat YouTube auf jeden Fall Wachstumspotenzial auch in dieser Ebene, denn die Nutzung von Facebook, insbesondere in den jüngeren Alterskohorten, geht zurück. Allerdings zeigt sich, dass vor allem die 35- bis 44-Jährigen seltener auf YouTube (14 Prozent) und WhatsApp (16,1 Prozent)

zurückgreifen, um Nachrichten zu beziehen, als die restlichen Altersgruppen. Nach Brodnig, Hammer und Holnburger (Digitalreport 2018, S. 15) führt die Freiheitliche Partei Österreich (FPÖ) die Kategorie „Nachrichten und Politik“ klar an. Die beiden FPÖ-Kanäle – FPÖ TV (Platz Eins) und Oesterreichzuerst (Platz Fünf) – schaffen es sogar unter die ersten fünf unter den „Top 20“-Kanälen dieser Kategorie. Andere Parteien, wie beispielsweise die SPÖ oder die ÖVP, schaffen es beispielsweise gar nicht in diese Liste, entweder haben sie eine zu geringe Anzahl an Abonniert*innen oder Kanäle, wie zum Beispiel der von Sebastian Kurz (ÖVP), wird nicht unter der Kategorie „Politik und Nachrichten“ geführt. Auch etablierte Medien finden sich in einem äußerst geringen Ausmaß in dieser Auflistung. Zu den „Top 20“-Nachrichten- und Politik-Kanälen Österreichs zählen folgende YouTube-Kanäle (von Platz Eins bis 20 gelistet): FPÖ TV, ServusTV, Österreichs Bundesheer, VOL.AT – Vorarlberg Online, Oesterreichzuerst, Esterreicherr, TheFalseFlag Main Channel, DerDualSchock, DER STANDARD, AustriaTV, SALZBURG24 Redaktion, Die Grünen, Gerald Grosz, FALTER, Oesterreich TV2 MiaSemper, Idealism Prevails, Dina Christina Lieb, NEOS – Das Neue Österreich, SmallCap InvestorTV, LaendleTVNews. (Brodnig, Hammer & Holnburger, Digitalreport 2018, S. 15)

4.4 Zwischenfazit

Digitale Plattformen und Plattformmärkte zeichnen sich insbesondere durch eine hohe Skalierbarkeit und Reichweite, der Möglichkeit zur Auswertung einer großen Datenmenge, niedrige Transaktionskosten, starke Netzwerkeffekte, sowie einer hohen Dynamik aus (Vgl. Engelhardt, Wangler und Wischmann, 2017, S. 11-15). Die genauen Grundlagen zur Plattformökonomie wurden im ersten Abschnitt (Abschnitt 4.1) dieses Kapitels ausführlich erläutert. Der Video-Streaming-Dienst YouTube, als Teil des Alphabet-Konzerns, kann ebenfalls der Plattformökonomie zugeordnet werden, wie in Abschnitt 4.2 verdeutlicht wurde. Plattformen, wie YouTube, treten in erster Linie als wirtschaftlich ausgerichteter und digitaler Intermediär auf, der die bereits genannten Merkmale aufweist. Genau genommen verbindet YouTube insgesamt vier Akteursgruppen: Nutzer*innen, Content Creator*innen, Werbepartner*innen (Marken und Unternehmen), sowie Entwickler*innen. Im letzten Abschnitt des vorliegenden Kapitels wurde die

Relevanz von YouTube in Österreich beleuchtet. Insbesondere Jüngere greifen auf den Video-Streaming-Dienst immer häufiger zurück, auch um Nachrichten zu beziehen. Diese Entwicklung wirft zusätzliche Bedenken auf, denn wie eben beschrieben, dominieren vorerst rechtspopulistische Parteien die Kategorie „Politik und Nachrichten“. Was das bedeuten kann, wird in den nächsten Kapiteln näher betrachtet, denn Plattformunternehmen verbindet noch ein weiterer wichtiger Aspekt: Die Instrumentalisierung von Algorithmen.

5 Künstliche Intelligenz, maschinelles Lernen und Algorithmen

Algorithmen sind mittlerweile zu einem wesentlichen Bestandteil unserer heutigen digitalen Wirtschaft geworden. Insbesondere Plattformen legen ihre Geschäftsgrundlage in die „virtuellen Hände“ von Maschinen und damit auch von Algorithmen. Die Welt wäre ohne die Existenz von Algorithmen nicht mehr vorstellbar. Sie werden eingesetzt, damit Fahrzeuge selbst fahren können, Kühlschränke automatisiert ermittelte Leerstände wieder selbst auffüllen können oder die bzw. der geeignete Kandidat*in für einen Job bereits vorselektiert der bzw. dem zuständigen Hiring Manager*in vorliegt. Algorithmen sind vielseitig einsetzbar, aber was ist unter diesem Terminus genau zu verstehen? Was bedeutet in diesem Kontext „Künstliche Intelligenz“? Wann spricht man von Machine Learning? Mit diesen Fragestellungen beschäftigt sich das vorliegende Kapitel. Es soll Aufschluss darüber geben, was Algorithmen sind und warum sie so wichtig, gerade für digitale Empfehlungssysteme sind, auf die im nächstfolgenden Kapitel noch näher eingegangen wird.

5.1 Künstliche Intelligenz als Überbegriff

Der Begriff „Künstliche Intelligenz“ hat sich in den letzten Jahren zu einem wahrlichen Buzzword entwickelt und wird oft als Bedrohung der Menschheit gehandelt. Kaum einer hat davon noch nicht gehört, doch an Verständnis, hinsichtlich dem, was darunter zu verstehen ist, mangelt es.

Künstliche Intelligenz (oft auch als KI bezeichnet) ist ein Bereich der Informatik, der sich mit der Automatisierung von Intelligenz und der Fähigkeit von Maschinen beschäftigt, komplexe Aufgaben in komplexen Umgebungen zu erfüllen. (Goebel et al. 2016; Luger 2005). Der Terminus dient also als Überbegriff für ein breites Spektrum an Subdisziplinen. Grundsätzlich erlangte die Künstliche Intelligenz erst nach etwa 70 Jahren Anerkennung. Der Anfang der Geschichte liegt allerdings noch mehrere Jahrhunderte zurück. Die große Herausforderung in diesem Bereich ist vor allem die Identifizierung und Differenzierung von dem Künstlichen und dem Realen. In einigen Fällen kann sich diese Unterscheidung als schwierig herausstellen, denn Realitäten können künstlich erzeugt oder gar gefälscht werden. Intelligenz hingegen hat eine ganz andere Bedeutung. Sie ist nicht vortäuschbar, man kann keine Illusion von Intelligenz erschaffen. Entweder man – das kann ein Lebewesen oder eine Maschine sein – handelt intelligent, und ist demzufolge intelligent, oder nicht. Bezuglich Maschinen ist keine Möglichkeit bekannt, dass diese Intelligenz zufällig demonstrieren würden. (Batarseh 2018, S. 1)

Der Bereich der Künstlichen Intelligenz wirft ständig eine Reihe von Fragen auf: Wie kann man Intelligenz definieren oder beobachten? Ist die KI sicher? Können Maschinen so etwas wie eine „Super-Intelligenz“ erreichen? In seinem berühmten Manuskript "Computing Machinery and Intelligence" ebnete Turing (1950, S. 433-460) vielen Wissenschaftler*innen den Weg über Künstliche Intelligenz nachzudenken, indem er auf folgende Fragestellung antwortete: Können Maschinen denken? Seine Arbeit führte einen Benchmark-Standard ein, um Maschinenintelligenz zu demonstrieren, so dass eine Maschine intelligent und reaktionsschnell sein muss, so dass sie sich nicht von einer eines Menschen unterscheiden kann.

Um die menschliche Intelligenz imitieren, replizieren oder erweitern zu können, ist es entscheidend, zuerst zu verstehen, was Intelligenz genau bedeutet. Dazu wird die KI zu einem Feld, das sich mit anderen Studienbereichen überschneidet, insbesondere mit der Biologie (Fähigkeit erlangen, das menschliche Gehirn und Nervensystem zu verstehen) und der Philosophie (Verständnis erlangen, wie die KI die Zukunft der Menschheit beeinflussen würde - neben vielen anderen philosophischen Diskussionen). Über die letzten Jahre gab es zahlreiche

Bemühungen, intelligente Maschinen zu kreieren. Die Auseinandersetzung mit dieser Thematik führte zu einer Vielzahl an Disziplinen in diesem Bereich (Batarseh 2018, S. 2):

- Machine Learning
- Neuronale Netzwerke
- Genetische Algorithmen (GA)
- Natural Language Processing (NLP)
- Wissensbasierte Systeme (KBS)
- Computer Vision
- Robotik
- Data Science und Advanced Analytics

Insbesondere auf Machine Learning wird im kommenden Abschnitt noch näher eingegangen.

Wie kann Intelligenz nun bewertet werden? Liu, Shi & Liu (2017, S. 180f.) schlagen in ihrer Arbeit diesbezüglich eine mehrstufige Struktur der intellektuellen Fähigkeiten eines intelligenten Systems vor, sozusagen ein "Standard-Intelligenzmodell". Dieses baut auf einer Reihe von bereits bestehenden Intelligenzmodellen auf und kombiniert diese, darunter die Neumann-Architektur, David Wechslers „Human Intelligence-Modell“, das DIKW-Modell (DIKW ist die Kurzform für Daten, Informationen, Wissensvorsprung und Weisheit), und noch weitere Ansätze. Das Autor*innen-Team hat für ihr Standard-Intelligenzmodell folgende Merkmale definiert (Liu, Shi & Liu 2017, S. 181):

- *Merkmal 1:*
Das System ist in der Lage, Daten, Informationen und Wissen aus der Außenwelt aus akustischen, bildmäßigen und/oder textuellen Eingaben zu gewinnen (dieser Wissenstransfer beinhaltet diese drei Modi, ist aber nicht darauf beschränkt);
- *Merkmal 2:*

Das System ist in der Lage, solche externen Daten, Informationen und Kenntnisse in internes Wissen umzuwandeln, das das System beherrschen kann;

- *Merkmal 3:*

Basierend auf der Nachfrage, die durch externe Daten, Informationen und Wissen erzeugt wird, ist das System in der Lage, sein eigenes Wissen auf innovative Weise zu nutzen. Diese Innovationsfähigkeit beinhaltet, ist aber nicht beschränkt auf die Fähigkeit, zusammenzuarbeiten, zu erschaffen, sich vorzustellen, zu entdecken, etc. Durch die Nutzung dieser Fähigkeit können neue Erkenntnisse gebildet und durch das System gewonnen werden;

- *Merkmal 4:*

Das System ist in der Lage, Daten, Informationen und Wissen, die vom System erzeugt werden, an die Außenwelt durch akustische, bild- oder textuelle Ausgabe weiterzugeben (in einer Weise, die diese drei Modi beinhaltet, aber nicht darauf beschränkt ist), so dass das System die Außenwelt ändern kann.

Das vorgeschlagene Modell soll die zukünftige Entwicklung des Verhältnisses von künstlicher Intelligenz zu menschlicher Intelligenz beurteilen und Wachstumskurven für jede Intelligenz ermitteln. Insgesamt wurden in der Arbeit von Liu, Shi und Liu (2017, S. 185) sieben Intelligenzgrade (0-7) festgelegt, um den Intelligenzquotienten und den Intelligenzstufenzustand zu beschreiben. Allerdings muss erwähnt werden, dass es in Wirklichkeit so etwas wie ein künstlich intelligentes System nullten Grades nicht existiert (die grundlegenden Eigenschaften dieser existieren nur in der Theorie). Das grundlegende Merkmal einer künstlichen Intelligenz ersten Grades ist, dass es keine informationsbezogene Interaktion mit menschlichen Tester*innen (Menschen) durchführen kann. Künstliche Intelligenz zweiten Grades haben bereits die Fähigkeit zur Interaktion mit menschlichen Tester*innen, Kontrolleinheiten sind implementiert und sie haben die Fähigkeit, Erinnerungen zu speichern; die internen Wissensdatenbanken solcher Systeme können jedoch nicht zunehmen. Künstlich intelligente Systeme dritten Grades haben die Eigenschaften von Systemen der zweiten Stufe mit der zusätzlichen Fähigkeit, Programme oder Daten im System über nicht vernetzte

Schnittstellen zu aktualisieren oder zu ergänzen. Allerdings sind diese Systeme noch nicht in der Lage mit anderen Systemen über die "Cloud" zu kommunizieren bzw. keine informative Interaktion mit diesen durchzuführen. Sobald ein künstlich intelligentes System den vierten Grad erreicht hat, wird dieser Informations- und Wissenstransfer möglich. Diese Art von Systemen sind insofern noch begrenzt, als alle Informationen direkt aus der Außenwelt kommen; das Innensystem kann nicht unabhängig, innovativ oder kreativ neues Wissen generieren. Hier kommt der fünfte Grad künstlicher intelligenter Systeme ins Spiel: Ab diesem Zeitpunkt erlangen Maschinen die Fähigkeit zu schaffen und zu innovieren, die Fähigkeit, den Wert von Innovation und Kreativität für den Menschen zu erkennen und zu identifizieren, und die Fähigkeit, innovative und kreative Ergebnisse auf den Prozess der menschlichen Entwicklung anzuwenden. Menschliche Wesen, die als besonderes "künstliches Intelligenzsystem" der Natur angesehen werden können, sind das prominenteste Beispiel für Systeme fünften Grades. Im Gegensatz zu den bisherigen vier Arten von Systemen teilen Menschen und einige andere Lebewesen eine charakteristische Handschrift der Kreativität, die sich in den komplexen Netzwerken des Wissensvorsprungs widerspiegeln. Sie reichen von der Philosophie über die Naturwissenschaften, die Literatur, die Kunst, die Politik usw. bis hin zu den menschlichen Gesellschaften. Fünftgradige Systeme können Informationen mit menschlichen Tester*innen und Nutzer*innen austauschen, neue Wissensvorsprünge schaffen und Informationen sowohl über "analoge" Mittel wie Schreiben, Sprechen und Radio/TV/Kabelkommunikation als auch über das Internet und die "Cloud" austauschen. Abschließend zeichnet sich der sechste Grad künstlich intelligenter Systeme durch ein intelligentes System aus, das kontinuierlich innovativ ist und neues Wissen schafft, mit I/O-Fähigkeit, Wissenskompetenz und Anwendungsfähigkeit, die sich mit der Zeit unendlichen Werten nähern. Dies spiegelt sich zum Beispiel in der christlichen Definition eines Gottes wider, der "allwissend und allmächtig" ist. Wenn intelligente Systeme, vom Menschen oder anderweitig repräsentiert, weiterhin innovativ sind, Wissen schaffen und akkumulieren, ist es möglich, dass sie nach ausreichender Zeit "allwissend und allmächtig" werden könnten. Aus der Sicht der intelligenten Systementwicklung können die "übernatürlichen Wesen" in den östlichen Kulturen oder das "Gott"-Konzept der westlichen Kulturen als evolutionäre Endpunkte intelligenter Systeme

(einschließlich des Menschen) in ferner Zukunft betrachtet werden. (Liu, Shi & Liu 2017, S. 185-187)

5.2 Maschinelles Lernen und Algorithmen

Machine Learning (kurz: ML) ist ein Zweig der künstlichen Intelligenz, der systematisch Algorithmen anwendet, um die zugrunde liegenden Beziehungen zwischen Daten und Informationen zu synthetisieren. Beispielsweise können ML-Systeme auf automatischen Spracherkennungssystemen (wie z.B. Siri) trainiert werden, um akustische Informationen in einer Folge von Sprachdaten in eine semantische Struktur umzuwandeln, die dann in Form einer Wortfolge ausgedrückt wird. Machine Learning Anwendungen sind bereits weit verbreitet beispielsweise Anwendungen in den Bereichen Websuche, Anzeigenschaltung, Kreditwürdigkeitsprüfung, Börsenprognose, Gensequenzanalyse, Verhaltensanalyse, Smart Coupons, Medikamentenentwicklung, Wettervorhersage, Big Data Analytics und vielen weiteren Anwendungen. (Awad & Khanna 2015, S. 1) Auch der Video-Streaming-Dienst YouTube setzt maschinelles Lernen für die Abwicklung von Werbeanzeigen ein. (Dischler, Think with Google 2018)

Grundsätzlich gehen Awad und Khanna (2015, S.1-2) davon aus, dass Machine Learning eine entscheidende Rolle bei der Entwicklung einer Vielzahl von benutzer*innenorientierten Innovationen spielen wird. Die Technologie selbst verdankt seine wachsende Akzeptanz seiner Fähigkeit, die zugrunde liegenden Beziehungen innerhalb großer Datenmengen so zu charakterisieren, dass Probleme in der Big Data-Analytik, der Verhaltensmustererkennung und der Informationsentwicklung gelöst werden. Machine Learning-Systeme können darüber hinaus geschult werden, um die sich ändernden Bedingungen eines Prozesses zu kategorisieren und so Schwankungen im Betriebsverhalten zu modellieren. Da sich Wissensbestände unter dem Einfluss neuer Ideen und Technologien entwickeln, können Systeme maschinellen Lernens Störungen bestehender Modelle identifizieren, diese neu gestalten und sich dementsprechend neu ausrichten, um sich an das neue Wissen anzupassen und mit diesem zu koevolutionieren.

Bezüglich der rechnerischen Leistung von Machine Learning, zählen die Verallgemeinerung der Trainingserfahrung (oder anderen Beispielen) und die Ausgabe einer Hypothese, die die Zielfunktion schätzt, zu den wichtigsten Merkmalen. Das Generalisierungsattribut von Machine Learning ermöglicht es dem System, bei unsichtbaren Dateninstanzen eine gute Leistung zu erbringen, indem es zukünftige Daten genau voraussagt. Im Gegensatz zu anderen Optimierungsproblemen hat Machine Learning keine klar definierte Funktion, die optimiert werden kann. Stattdessen dienen Trainingsfehler als Katalysator, um Lernfehler zu testen. Der Prozess der Generalisierung erfordert Klassifikatoren, die diskrete oder kontinuierliche Merkmalsvektoren eingeben und eine Klasse ausgeben.

Das übergeordnete Ziel maschinellen Lernens ist es, zukünftige Ereignisse oder Szenarien vorherzusagen, die dem Computer unbekannt sind. Im Jahr 1959 beschrieb Samuel Machine Learning als das "Studienfach, das Computern die Möglichkeit gibt, zu lernen, ohne explizit dafür programmiert zu werden" (Samuel 1959). Er kam zu dem Schluss, dass die Programmierung von Computern, um aus Erfahrungen lernen zu können, letztendlich die Notwendigkeit eines detaillierten Programmieraufwands beseitigen sollte. Denn in Anlehnung an Mitchells Definition von Machine Learning „soll ein Computerprogramm aus der Erfahrung E in Bezug auf eine Klasse von Aufgaben T (Tasks) lernen und die Leistungskennzahl P (Performance), wenn sich seine Leistung bei Aufgaben in T, gemessen an P, mit der Erfahrung E verbessert“. Der Lernprozess spielt eine entscheidende Rolle bei der Verallgemeinerung des Problems, indem er auf seine historische Erfahrung zurückgreift. Erfahrungen liegen in Form von Trainingsdatensätzen vor, die helfen, bei neuen und unsichtbaren Aufgaben genaue Ergebnisse zu erzielen. Die Trainingsdatensätze umfassen eine bestehende Problemdomäne, mit der die lernende Maschine ein allgemeines Modell über diese Domäne erstellt. Dies ermöglicht es dem Modell, in neuen Fällen weitgehend genaue Vorhersagen zu treffen. (Awad & Khanna 2015, S. 1-2)

Exkurs: Die Termini Machine Learning und Deep Learning werden oft miteinander gleichgesetzt. Allerdings gibt es zwischen den beiden Arten des Lernens einen wesentlichen Unterschied. Deep Learning geht über die traditionell flachen

Lernarchitekturen hinaus. In der maschinellen Lerngemeinschaft ist Deep Learning auf dem Vormarsch, denn diese haben sich für die anspruchsvolleren Aufgaben des maschinellen Lernens und der starken künstlichen Intelligenz (KI) als ungeeignet erwiesen. Der Anstieg in, sowie die breite Verfügbarkeit von erhöhter Rechenleistung (Misra & Saha 2010), verbunden mit der Schaffung effizienter Trainingsalgorithmen, als auch der Fortschritte in den Neurowissenschaften haben die Umsetzung von Prinzipien des Deep Learnings ermöglicht, die bisher unmöglich waren. Diese Entwicklungen haben zur Bildung von Algorithmen für tiefe Architekturen geführt, die sich mit kognitiven Neurowissenschaften beschäftigen, um biologisch inspirierte Lernlösungen vorzuschlagen. (Awad & Khanna, S. 167)

Machine Learning hilft bei der Entwicklung von Programmen, die ihre Leistung für eine bestimmte Aufgabe durch Erfahrung und Training verbessern. Viele große Datenanwendungen nutzen maschinelles Lernen, um höchst effizient zu arbeiten. Das schiere Volumen, die Vielfalt und die Geschwindigkeit des Datenflusses haben es unmöglich gemacht, die natürlichen Fähigkeiten von Menschen zu nutzen, um Daten in Echtzeit zu analysieren. Der Anstieg der sozialen Netzwerke und die breite Nutzung internetbasierter Anwendungen haben nicht nur zu einem größeren Datenvolumen, sondern auch zu einer höheren Komplexität der Daten geführt. Um die Datenauflösung zu erhalten und Datenverluste zu vermeiden, müssen diese Datenströme also in Echtzeit analysiert werden.

Die Heterogenität des großen Datenstroms und die enorme Rechenleistung, die heutzutage zum Standard geworden sind, bieten zahlreiche Möglichkeiten, Lernmethoden zu fördern, die Best Practices für ein bestimmtes Geschäftsproblem identifizieren können. Die Komplexität moderner Computermaschinen kann große Datenmengen, größere Komplexität und Terabyte an Speicherplatz bewältigen. Darüber hinaus können intelligente Programmabläufe, die auf diesen Maschinen laufen, viele so komplexe Datenströme verarbeiten und kombinieren, um prädiktive Modelle zu entwickeln und intrinsische Muster in ansonsten verrauschten Daten zu extrahieren. Wenn beispielsweise ein bestimmter Zielwert vorhergesagt oder prognostiziert werden muss, ist überwachtes Lernen die richtige Wahl. Grundsätzlich wird dabei, je nach Sollwert zwischen Clustering (bei einem diskreten Sollwert) und Regression (bei einem numerischen Sollwert) entschieden. Zuerst

müssen also alle Kennzahlen identifiziert werden, die für den jeweiligen Entscheidungsprozess Priorität besitzen, um mit der Entwicklung von Machine Learning zu beginnen. Die Prozesse maschinellen Lernens synthetisieren Modelle zur Optimierung der Metriken.

Es muss allerdings erwähnt werden, dass Machine Learning von Natur aus keine perfekte Genauigkeit liefern kann. Lösungen, die hochpräzise Ergebnisse in einem begrenzten Zeitraum erfordern, bedürfen möglicherweise einen anderen Ansatz. Im Allgemeinen sind die folgenden Bedingungen für die Anwendung von Machine Learning günstig: (1) sehr hohe Genauigkeit ist nicht erwünscht; (2) große Datenmengen enthalten unentdeckte Muster oder zu synthetisierende Informationen; (3) das Problem selbst ist aufgrund mangelnder Kenntnisse oder historischer Informationen als Grundlage für die Entwicklung geeigneter Algorithmen nicht sehr gut verstanden; und (4) das Problem muss sich an veränderte Umgebungsbedingungen anpassen. (Awad & Khanna, S. 5)

Zunächst soll erläutert werden, was unter Algorithmen überhaupt verstanden werden kann, und anschließend in welche Kategorien Machine Learning-Algorithmen eingeordnet werden können.

Die AutorInnen Zweig, Krafft und Deussen (2017) verstehen unter einem Algorithmus, „eine definierte Handlungsvorschrift, die für jede mögliche Eingabe von Informationen eine Ausgabe generiert, die bestimmte Eigenschaften hat“. Um diese Definition verständlicher zu abstrahieren, ziehen sie das Beispiel einer Routennavigation heran: Als Eingabe dient der Startpunkt und der Zielort, sowie Straßenkarten und aktuelle Verkehrsinformationen. Eine mögliche Fahrstrecke mit der kürzesten zu erwartender Dauer, die unter Einbeziehung der vorhandenen Eingabe-Daten berechnet wurde, bildet am Ende die Ausgabe. Mahnke (2015) kommt in seiner Beschreibung eines Algorithmus ebenfalls zu dem Punkt, dass dieser eine Reihe von schrittweisen Befehlen, die durchgeführt werden sollen, um aus einer Eingabe eine Ausgabe zu erzeugen und damit ein Problem zu lösen, ist. Empfehlungssysteme gehören zu den häufigsten Formen des maschinellen Lernens, mit denen Nutzer*innen konfrontiert werden, unabhängig davon, ob sie davon Kenntnis haben oder nicht. Sie unterstützen damit beispielsweise die kuratierten Zeitleisten auf Facebook und Twitter, sowie „Vorgeschlagene Videos“

auf YouTube. Auf Empfehlungssysteme wird im Rahmen des sechsten Kapitels dieser Arbeit noch näher eingegangen. In ihrer Arbeit „Algorithmen und Meinungsbildung“ geht das Autor*innen-Team (Zweig, Krafft & Deussen 2017) noch näher auf die Funktionsweise algorithmischer Empfehlungssysteme, wie sie beispielsweise von den Unternehmen Facebook oder Google bzw. auf den dazugehörigen Plattformen genutzt werden, ein: Algorithmische Empfehlungssysteme treffen aus einer großen Informationsmenge (z.B. i.F.v. Dokumenten oder Webseiten) eine grundlegende Auswahl, sortieren diese anhand geeigneter Kriterien und zeigen aufgrund dessen möglichst relevante Informationen zuerst an. Als Beispiel dient den AutorInnen die Funktionsweise des Google PageRanks, ein Suchalgorithmus zur Linkanalyse, der die Elemente von hyperlinked Dokumenten im World Wide Web klassifiziert, um deren Bedeutung im Vergleich zu anderen Links zu messen. Allerdings kam es in den vergangenen Jahren, gerade durch die Offenlegung über die Wirkungsweise solcher algorithmischer Empfehlungssysteme auch zu gezielten Manipulationen, um beispielsweise in den Google Suchergebnissen ein höheres Ranking zu erzielen. Mittlerweile werden, neben der Berechnung des Page Ranks, auch Informationen verarbeitet, die darauf hinweisen, welche Inhalte für Nutzer*innen besonders interessant sind. Algorithmen des sogenannten maschinellen Lernens, beobachten also menschliche Nutzer*innen und tracken ihr gesamtes maschinell verfolgbares Verhalten. Dabei strukturieren selbstlernende Algorithmen aus einer Vielzahl an Informationen selbstständig Entscheidungen, meist in Form von Entscheidungsbäumen, um verschiedene Inhalte in Gruppen bzw. Kategorien zu bündeln. Diese Methode wird auch Clustering genannt. Eine solche Arbeitsweise dient vor allem der Personalisierung, beispielsweise von Suchergebnissen, und zielt darauf ab, möglichst relevante Inhalte und Informationen individuell für die Nutzer*innen zusammenzustellen. Genauer genommen existieren sechs Kategorien, in die Algorithmen des maschinellen Lernens eingeordnet werden können:

1. *Superviertes Lernen* ist ein Lernmechanismus, der die zugrunde liegende Beziehung zwischen den beobachteten Daten (auch Eingangsdaten genannt) und einer Zielvariablen ableitet (eine abhängige Variable oder ein Label), die einer Vorhersage unterliegt. Ein gut

trainiertes Funktionsmodell, das auf einem überwachten Lernalgorithmus basiert, kann die Klassenbezeichnungen für versteckte Phänomene, die in unbekannte oder unbeobachtete Dateninstanzen eingebettet sind, genau vorhersagen. Das Ziel von Lernalgorithmen ist es, den Fehler für einen bestimmten Satz von Eingaben (den Trainingssatz) zu minimieren.

2. *Unüberwachte Lernalgorithmen* sollen versteckte Strukturen in unmarkierten Datensätzen aufdecken, bei denen der gewünschte Output unbekannt ist. Dieser Mechanismus hat viele Anwendungen in den Bereichen Datenkompression, Ausreißererkennung, Klassifizierung, menschliches Lernen und so weiter gefunden. Der allgemeine Ansatz für das Lernen beinhaltet das Training durch probabilistische Datenmodelle. Das Ziel von Machine Learning in diesem Fall ist es, Darstellungen der Eingangsdaten für eine effiziente Entscheidungsfindung, Prognose, Informationsfilterung und Clustering zu hypothetisieren. Unüberwachte Lernalgorithmen, die sich auf ein probabilistisches Verteilungsmodell konzentrieren, verwenden im Allgemeinen Maximum-Likelihood-Schätzungen (MLE), Maximum a posteriori (MAP) oder Bayes-Methoden.
3. *Semi-supervisiertes Lernen* verwendet eine Kombination aus einer kleinen Anzahl von beschrifteten und einer großen Anzahl von nicht beschrifteten Datensätzen, um eine Modelfunktion oder einen Klassifikator zu erzeugen. Diese Lernmethode kann einen Wert von praktischer und theoretischer Bedeutung liefern, insbesondere in Bereichen, die mit dem menschlichen Lernen zusammenhängen, wie Sprache, Sehen und Schreiben, die eine geringe Menge an direktem Unterricht und eine große Menge an nicht gekennzeichneter Erfahrung erfordern.
4. Die *RL-Methodik (Reinforcement Learning)* beinhaltet die Erforschung einer adaptiven Abfolge von Handlungen oder Verhaltensweisen durch einen intelligenten Agenten (RL-Agenten) in einer gegebenen Umgebung mit der Motivation, die kumulative Vergütung zu maximieren. Die Aktion des intelligenten Agenten löst eine beobachtbare Veränderung des Umgebungszustands aus. Die Lerntechnik synthetisiert ein Anpassungsmodell, indem sie sich selbst für einen gegebenen Satz von

experimentellen Aktionen und beobachteten Reaktionen auf den Zustand der Umgebung trainiert. Im Allgemeinen kann diese Methodik als ein kontrolltheoretisches Trial-and-Error-Lernparadigma mit Belohnungen und Strafen im Zusammenhang mit der eine Folge von Aktionen assoziiert werden. Der RL-Agent ändert seine Richtlinien basierend auf der kollektiven Erfahrung und den daraus resultierenden Belohnungen. Reinforcement Learning sucht nach vergangenen Aktionen, die es erforscht hat und die zu Belohnungen führten. Um eine umfassende Datenbank oder ein Modell aller möglichen Aktions- und Belohnungsprojektionen aufzubauen, müssen viele unbewiesene Aktionen ausprobiert werden. Diese ungetesteten Aktionen müssen möglicherweise mehrmals durchgeführt werden, bevor ihre Stärke festgestellt werden kann. Daher müssen Sie ein Gleichgewicht zwischen der Erforschung neuer möglicher Aktionen und der Wahrscheinlichkeit des Scheiterns, die sich aus diesen Aktionen ergibt, finden.

5. *Transduktives Lernen* (auch bekannt als transduktive Inferenz) versucht, exklusive Modelfunktionen für bestimmte Testfälle vorherzusagen, indem zusätzliche Beobachtungen am Trainingsdatensatz in Bezug auf die neuen Fälle verwendet werden (Vapnik 1998).
6. *Induktive Inferenz* schätzt die Modelfunktion basierend auf der Beziehung von Daten auf den gesamten Hypothesenraum und nutzt dieses Modell, um Ausgabewerte für Beispiele außerhalb des Trainingssets zu prognostizieren. Viele statistische Lernmethoden beginnen mit ersten Lösungen für den Hypothesenraum und entwickeln sie dann iterativ weiter, um Fehler zu reduzieren. Viele gängige Algorithmen fallen in diese Kategorie, darunter Support Vector Machines (SVMs) (Vapnik 1998), neuronale Netzwerkmodelle (NN) (Carpenter und Grossberg 1991) und Neuro-Fuzzy-Algorithmen (Jang 1993, S. 665-685). (Awad & Khanna, S. 6ff.)

Zu den zehn wichtigsten Data-Mining-Algorithmen maschinellen Lernens zählen C4.5, k-means, Support Vector Machines (SVMs), Apriori, estimation

maximation(EM), PageRank, AdaBoost, k-nearest neighbors (k-NN), naive Bayes und Klassifikations- und Regressionsbäume (CARTs) (Wu et al. 2008, S. 1-37).

5.3 Zwischenfazit

Künstliche Intelligenz vereint eine Vielzahl an Disziplinen. Ein Buzzword das in vielen wohl Unbehagen auslöst, denn nicht selten ist die Rede von „gott-gleichen“ Maschinen, die die Menschheit in Zukunft um den Platz an der Spitze der Nahrungskette bringen könnten. In Abschnitt 5.1 wurde ermittelt, was künstliche Intelligenz bedeutet bzw. wie Intelligenz bewertet werden kann. Dazu wurde das von Liu, Shi und Liu (2017) entwickelte „Standard-Intelligenzmodell“ vorgestellt, sowie die sieben Grade künstlich intelligenter Systeme erläutert, die der Einordnung von Intelligenz dienen sollen. In Abschnitt 5.2 wurde maschinelles Lernen (ML) als Teil Künstlicher Intelligenz behandelt. Das übergeordnete Ziel maschinellen Lernens ist es, zukünftige Ereignisse oder Szenarien vorherzusagen, die dem Computer unbekannt sind. Aufgrund der immer höher werdenden Komplexität durch eine zunehmende Anzahl der Dimensionen, wodurch immer detailliertere Entscheidungen getroffen werden können, scheitern Algorithmen maschinellen Lernens in den meisten Fällen, die perfekte Entscheidungsstruktur für jede einzelne Nutzerin bzw. jeden einzelnen Nutzer zu bilden. Diese Algorithmen versuchen also eine Balance zwischen Genauigkeit und Trefferquote herzustellen. Wie genau die Algorithmen der unterschiedlichen Plattformunternehmen, insbesondere der zu untersuchenden Plattform YouTube, funktionieren bleibt allerdings unklar. Sie bilden einen wichtigen Erfolgsfaktor als auch eine Abgrenzungsmöglichkeit zur Konkurrenz, und werden von den Unternehmen somit immer als Betriebsgeheimnis gehandelt. YouTube steht insbesondere aufgrund problematischer Inhalte unter Kritik, auf die nur sehr langsam eingegangen wird. Das Unternehmen hat beispielsweise begonnen „Human Reviewer“ einzustellen, die Machine Learning nutzen, um potenzielle Policy-Vergehen aufzudecken. Tanriverdi (2017) bezeichnet in seinem Artikel in der Süddeutschen Zeitung Empfehlungs-Algorithmen gar als Extremismus-Maschine. Immer wieder wird auch auf die Fehlerbetroffenheit von Algorithmen verwiesen. Eines der jüngsten Beispiele bezüglich des YouTube-Algorithmus stellt der Fall des Feuers von Notre Dame dar. Wie beispielsweise

Nieman Lab (2019) berichtete, kam es zu einem algorithmischen Irrtum: YouTube verwies unter den Videos vertrauenswürdiger Nachrichtenorganisationen plötzlich auf Informationen bezüglich der Terroranschläge am 11. September (9/11).

6 Algorithmen-basierte Empfehlungssysteme und die Entstehung von Filterblasen

Algorithmen sind allgegenwärtig und personalisieren unsere digitalen Informationsflüsse. Der Einsatz digitaler Empfehlungssysteme wird häufig als notwendig dargestellt, um die Informationsüberflutung im Zeitalter des Internets zu bewältigen und Nutzer*innen Autonomie zu ermöglichen (Gauch et al. 2007, S. 54-89; Friedman & Nissenbaum 1997, S. 466-469). Andere sehen Personalisierung jedoch als Bedrohung und argumentieren, dass Algorithmen unser Weltbild manipulieren könnten, weil sie Menschen und Gemeinschaften in „Filterblasen“ und „Echokammern“ treiben. Sie sind insbesondere besorgt aufgrund der Undurchsichtigkeit personalisierter Empfehlungen. Diese Filterung kann zu den eben genannten unerwünschten Folgen führen, auf die in diesem Kapitel noch näher eingegangen wird. (Borgesius et al. 2016, S. 1-11; Pariser 2011; Sunstein 2007; Yeung 2017). Ein weiterer, zu erwartender negativer Effekt besteht darin, dass die von Plattformen eingesetzten Algorithmen die Selbstauswahlprozesse verstärken können. In Studien von Stroud (2011) und Sears und Freedman (1967, S. 194-213) hat sich beispielsweise gezeigt, dass Nutzern*innen von Nachrichten, diejenigen Quellen bevorzugen, die ihrer Ideologie und Weltanschauung entsprechen, auch um beispielsweise kognitiven Stress abzuwenden. Empfehlungsalgorithmen können diesen Selbstauswahlprozess potenziell katalysieren, indem sie den Nutzer*innen die Wahl nehmen, dissonante Inhalte zu vermeiden oder ihnen aktiv entgegenzutreten. Eine solche Situation könnte im Widerspruch zu den aktuellen Grundwerten unserer Informationsgesellschaft stehen, einschließlich des Zugangs zu vielfältigen Informationen, der Herstellung einer gemeinsamen Öffentlichkeit (Castells 2008, S. 87-93; Habermas 1989), der Fähigkeit, freie und informierte Entscheidungen privat zu treffen oder an politischen Entscheidungen teilzunehmen.

In den folgenden Abschnitten soll geklärt werden, was Algorithmen-basierte Empfehlungssysteme und Filterblasen sind, wie diese grundsätzlich funktionieren und welcher Nutzen bzw. welche Gefahren mit ihnen einhergehen.

6.1 Algorithmen-basierte Empfehlungssysteme

Die Personalisierung von medialen Inhalten in der Plattformökonomie ist ein wichtiges Alleinstellungsmerkmal für Dienste-Anbieter, wie beispielsweise YouTube. Ein besonders kritischer Punkt hinsichtlich des Einsatzes von Algorithmen, in Form von Empfehlungssystemen, bestehender Plattformen, ist die fehlende Transparenz. In diesem Abschnitt werden digitalen Empfehlungssystemen zugrunde liegende Prinzipien und einige wichtige Aspekte erläutert.

Die Personalisierung im Web zielt darauf ab, Nutzer*innen die Inhalte zur Verfügung zu stellen, die sie zum aktuellen Zeitpunkt wollen oder brauchen, ohne dass sie explizit danach fragen müssen (Mulvenna, Anand & Büchner 2000, S. 122-125). Solche adaptiven Systeme passen den gelieferten Inhalt automatisch an das vergangene bzw. gegenwärtige Verhalten der aktuellen Nutzerin bzw. des aktuellen Nutzers, sowie an die Schlussfolgerungen anderer gleichgesinnter Nutzer*innen an (Yu 1999, S. 6-13). Im Zuge der Implementierung wenden Empfehlungssysteme bestimmte Informationsfiltertechniken an, um Elemente, wie beispielsweise Filme, Musik, Bücher, und im Falle von YouTube, Videos, auszuwählen, die den Interessen verschiedener Nutzer*innen am besten entsprechen (Adomavicius & Tuzhilin 2005, S. 734-749).

Basierend auf den Informationen, die für die Generierung von Empfehlungen verwendet werden, können aktuelle Empfehlungssysteme in drei Hauptkategorien unterteilt werden:

(1) Nicht-personalisierte Empfehlungssysteme

Diese Klasse von Algorithmen nutzt Statistiken und/oder zusammenfassende Informationen, um allen Nutzer*innen dieselben

interessanten (z. B. am höchsten bewerteten) Inhalte zu empfehlen. (Sarwat & Mokbel 2017, S. 2)

(1) Inhaltsbasierte Empfehlungssysteme

Diese Algorithmenfamilie analysiert die Informationen bestimmter Inhalte und empfiehlt Nutzer*innen eine Reihe von Inhalten, die jenen ähneln, die ihnen bereits in der Vergangenheit gefallen haben. Zu diesem Zweck analysiert das System den Verlauf von Nutzer*innen-Präferenzen ("Gefällt mir" / "Gefällt mir nicht"). (Sarwat & Mokbel 2017, S. 2-3) Inhaltsbasierte Empfehlungs- bzw. Filtersysteme beschreiben also einzelne Elemente in Form von freiem Text anhand eines festen Satzes an Attribut-Wert-Paaren und gehen davon aus, dass Nutzer*innenpräferenzen durch die Beschreibung der Elemente erfasst werden, die ihnen in der Vergangenheit gefallen haben. Daher repräsentieren diese Systeme normalerweise jeden Artikel durch eine Reihe von textuellen oder numerischen Attributen, die aus der Inhaltsbeschreibung des Artikels extrahiert wurden. Das Profil der aktuellen Nutzerin oder des aktuellen Nutzers, das sich aus den oben genannten Attributen zusammensetzt, fasst alle Elemente zusammen, die diese bzw. dieser bereits angezeigt bekommen hat. Elemente, die der oder dem Nutzer*in zuvor noch nicht angezeigt wurden, werden dann mit diesem Profil verglichen, um festzustellen, ob sie den Vorlieben der Nutzerin bzw. des Nutzers entsprechen könnten, sodass der bzw. dem Nutzer*in die ähnlichsten Elemente empfohlen werden. Ein häufiges Problem dieser Systematik besteht darin, dass die empfohlenen Elemente den von der Nutzerin bzw. des Nutzers besuchten Elementen zu ähnlich sind. Dieses Phänomen wird auch als „Überspezialisierung“ bezeichnet. (Balabanović & Shoham 1997, S. 66-72; Pazzani & Billsus 2007, S. 325-341; Li 2010, S. 129-130)

(2) Kollaborative Empfehlungssysteme

Diese Art von Empfehlungs- bzw. Filtersystemen beschäftigen sich hingegen nicht mit dem Inhalt von Gegenständen, sondern gehen davon aus, dass die Nutzer*innen anhand ihrer Interessen in verschiedene Gruppen unterteilt

werden können. Es wird also der Schluss gezogen, dass die bzw. der aktuelle Nutzer*in jene Elemente bevorzugt, die auch von anderen Nutzer*innen derselben Gruppe bevorzugt werden. Entsprechend dieser Idee werden die Nutzer*innenprofile, die sich aus den Bewertungen der von ihnen betrachteten Elemente zusammensetzen, verwendet, um das Naheverhältnis der aktuellen Nutzerin bzw. des aktuellen Nutzers zu anderen Nutzer*innen mit demselben Geschmack identifizieren zu können. Solche kollaborativen Systeme können das Problem der Überspezialisierung, das bei den zuvor beschriebenen inhaltsbasierten Ansätzen auftritt, wirksam vermeiden und haben eine höhere Wahrscheinlichkeit, unerwartete Elemente zu empfehlen. Dies führt wiederum zu einer erheblichen Erhöhung der Zufriedenheit der Nutzer*innen. Damit ein solches kollaboratives System allerdings funktionieren und nützliche Empfehlungen abgeben kann, muss erst eine beträchtliche Anzahl von Bewertungen durch Nutzer*innen erreicht werden. (Resnick et. al. 1994, S. 175-186; O'Connor & Herlocker 2001; Schafer et. al. 2007, S. 291-324)

Eine weitere Möglichkeit der kollaborativen Filterung bietet der itembasierte Ansatz (deutsch: Artikelbasierter Ansatz). Dieser berechnet die Ähnlichkeit zwischen Elementen anstatt von Nutzer*innen. Diese Art der Ähnlichkeitsberechnung hat den Vorteil, dass das Online-Empfehlungsverfahren in Echtzeit wesentlich beschleunigt werden kann. (Li 2010, S. 129-130; Sarwat & Mokbel 2017, S. 2)

Insbesondere bei den führenden Suchmaschinen ist ein Trend hin zu einer Personalisierung der Nutzer*innen-spezifisch abgefragten Suchergebnisse zu sehen, welche auf den spezifischen Rückmeldungen einer Nutzerin bzw. eines Nutzers in der Vergangenheit basieren. (Sarwat & Mokbel 2017, S. 3)

Im folgenden Abschnitt wird nun näher auf die Thematik rund um den Filterblaseneffekt eingegangen, der im Zuge der Anwendung Algorithmen-basierter Empfehlungssysteme auftritt.

6.2 Der Filterblaseneffekt

Die Personalisierung war, seit der Veröffentlichung von Eli Parisers (2011) einflussreichem Buch über Filterblasen, Gegenstand intensiver Debatten. Er argumentiert darin, dass Algorithmen, die der Personalisierung dienen, Menschen in interessenbasierten Filterblasen einschließen. Dieses Argument beruht auf einigen, etwas vereinfachten Annahmen, wie zum Beispiel:

- Einzelne Nutzer*innen schätzen eine inhaltliche Vielfalt nicht und interessieren sich nicht für komplexe gesellschaftliche Fragestellungen (Pariser 2011, S. 51).
- Algorithmen erkennen und bedienen keine komplexen Nutzer*innenprofile und ignorieren ihre Präferenzen, sowie den Wunsch der Nutzer*innen nach vielfältigen oder detaillierten Nachrichten (Pariser 2011, S. 54).
- Das einzige Ziel von Algorithmen ist es, enge persönliche Interessen zu identifizieren und den Menschen relevante Informationen zu liefern, die zu ihrem Profil passen (Pariser 2011, S. 54–56).
- Personalisierung ist bereits allgegenwärtig, und bald wird es nur noch personalisierte Medien geben (Pariser 2011, S. 33). Diese Personalisierung wird in diesem Kontext für Menschen unsichtbar sein (Pariser 2011, S. 10).

Die alleinige Existenz von Algorithmen und ihr Einsatz, um Informationen zu selektieren, stellen noch kein Problem oder einen Grund zur Besorgnis dar. Auch Journalismus dient der Vorselektion von Inhalten, um das Weltgeschehen für das Publikum besser einordbar zu machen, und diesem zu ermöglichen sich eine eigene Meinung zu bilden. Auch die Selektion durch Algorithmen kann für Nutzer*innen durchaus nützlich sein. Sie schaffen hinsichtlich einer Informationsüberlastung Abhilfe und helfen Nutzer*innen schneller bzw. mit dem geringstmöglichen Aufwand an ein gewünschtes Ziel bzw. zu den gewünschten Informationen, zu gelangen.

Die Besorgnis rund um den sogenannten Filterblaseneffekt basiert – wie im vorangegangenen Abschnitt bereits beschrieben wurde – in der Regel auf zwei grundlegenden Annahmen:

- (1) Menschen sind hinsichtlich einer Vielfalt an Information abgeneigt (Informationsüberschuss). Algorithmen dienen der Verringerung von Vielfalt und schaffen dementsprechend Abhilfe.
- (2) Nutzer*innen und Algorithmen bilden zusammen eine Spirale, in der Nutzer*innen eindimensional sind und es vorziehen, ihre Informationsdiät so zu filtern, dass sie ihre Interessen widerspiegelt, und in der diese Filterung die Eindimensionalität des Einzelnen verstärkt. (Bodó et al. 2018, S. 207)

Basierend auf diesen Annahmen warnt der Diskurs über Filterblasen vor verschiedenen Effekten: Beispielsweise einer Verringerung der Vielfalt von Informationen und Meinungen, denen Menschen ausgesetzt sind, der Bildung von Filterblasen und Echokammern, als auch die anschließende Polarisierung und Fragmentierung der öffentlichen Debatte, sowie die Trennung bestimmter sozialer Gruppen vom politischen Prozess. Dem Diskurs über Filterblasen liegt somit eine weitere, implizite Annahme zugrunde, nämlich, dass Diversität und die Exposition gegenüber diversen Nachrichten, von Natur aus, eine gute Sache sind. Es ist erwähnenswert, dass diese Annahme nicht selbstverständlich ist. Diversität kann mit anderen, nicht weniger wichtigen öffentlichen oder wirtschaftlichen Werten konkurrieren, wie zum Beispiel der Notwendigkeit, Komplexität zu reduzieren (Neuberger & Lobigs 2010), der persönlichen Autonomie des Publikums und der Bereitstellung von Informationen von persönlicher Bedeutung für das Publikum. Weitere Untersuchungen zeigen, dass Diversitätsstrategien und die Auseinandersetzung mit unterschiedlichen Perspektiven zuweilen nach hinten losgehen und die Polarisierung verstärken können, anstatt sie zu verringern. (Dilliplane 2011, S. 287-316; Wojcieszak 2011, S. 596-617) Es gibt jedoch Hinweise darauf, dass die Medienvielfalt den Nutzer*innen die Möglichkeit bieten kann, auf unterschiedliche Meinungen zu stoßen, ihre eigenen Ansichten zu reflektieren (Kwon, Moon & Stefanone 2015, S. 1.417-1.435) und die soziale und kulturelle Inklusion zu fördern (Huckfeldt, Johnson & Sprague 2002, S. 1-21). Weitere Befürchtungen hinsichtlich einer selektiven Auseinandersetzung mit Informationen und Filterblasen gehen davon aus, dass personalisierte Empfehlungen den Menschen genau die Informationen liefern, an denen sie interessiert sind. Einige algorithmische Empfehlungen konzentrieren sich in der Tat

stark auf kurzfristige Ziele und vereinfachende Metriken wie die Anzahl der Klicks und Likes („Gefällt mir“/„Gefällt mir nicht“). Dies ist jedoch nur ein Teil der Geschichte. Algorithmische Empfehlungen könnten Menschen auch eine breitere Auswahl, mehr Tiefe oder weniger beliebte Inhalte bieten (Munson & Resnick 2010, S. 1.457-1.466; Jannach et al. 2010). Die Technologie hinter Empfehlungssystemen reift, ebenso wie die Ziele der Nachrichtenmedien und sozialer Netzwerke, Websites, Suchmaschinen und anderer Parteien (Newman et al. 2017, S. 15). Nachrichtenorganisationen beschäftigen sich zunehmend mit Empfehlungssystemen, um ihren Nutzer*innen bessere Dienste und mehr Auswahl zu bieten als auch das langfristige Engagement zu steigern (Bodó 2018; Newman et al. 2017 & 2018). Wahrscheinlich führen diese marktorientierten Entwicklungen zu komplexeren und ausgefeilten Empfehlungssystemen, die das Publikum erstens besser profilieren, zweitens besser auf ihre tatsächlichen Vorlieben eingehen und drittens diese auch besser steuern können. Algorithmen und Zielgruppen entwickeln sich nicht isoliert: Personalisierung prägt die zukünftigen Einstellungen und Erwartungen der Nutzer*innen, die wiederum mit Algorithmen gemessen und besser genutzt werden sollen. Daher ist es wichtig, die Kräfte, die die Entwicklung der Beziehung zu den Nutzer*innen mit persönlichen Empfehlungen beeinflussen, besser zu verstehen. (Bodó et al. 2019, S. 209)

Weitere Studien haben gezeigt, dass die Art der Information einen signifikanten Einfluss auf die Informationsvermeidung hat, insbesondere wenn die Informationen gegenläufig sind (Lee 2016, S. 56-71; O'Hara & Stevens 2015, S. 401-422; Messing & Westwood 2014, S. 1.042-1.063; Knobloch-Westerwick & Kleinman 2012, S. 170-193; Wojcieszak 2010, S. 637-655; Hart et al. 2009, S. 555-588; Valentino et al. 2009, S. 591-613; Sears & Freedman 1967, S. 194-213). Darüber hinaus erhöht die Auswahl alternativer Medienquellen die Wahrscheinlichkeit, unterschiedlichen Informationen ausgesetzt zu sein. Online-Medien bieten eine scheinbar unbegrenzte Auswahl an Quellen und erhöhen den Zugang zu verschiedenen Inhalten, wenn nicht sogar die Exposition zu diesen Inhalten (Napoli 2011, S. 246-259). Zudem wurde gezeigt, dass soziale Netzwerke, die in den letzten Jahren zu einer immer wichtigeren Nachrichtenquelle geworden sind, Menschen aufgrund der Vielfalt und des Zufalls vielfältigeren Informationen aussetzen als herkömmliche Medien oder physische Netzwerke von Freund*innen, Familie, Kolleg*innen und

Nachbar*innen. (Bakshy, Messing & Adamic 2015, S. 1.130-1.132; Barberá et al. 2015, 1.531-1.542.; Bozdag 2015; Duggan & Smith 2016; Flaxman & Rao 2016, 298-320; Webster 2010, S. 593-612)

6.3 Zwischenfazit

Algorithmen-basierte Empfehlungssysteme führen bisher in den meisten Fällen zu der Entstehung von Filterblasen. In den vorangegangenen Abschnitten wurden die digitalen Empfehlungssysteme näher beschrieben. Insgesamt lassen sich diese in drei Hauptkategorien unterteilen: Die nicht-personalisierten Empfehlungssysteme, die inhaltsbasierten Empfehlungssysteme und die kollaborativen Empfehlungssysteme. Bei den führenden Suchmaschinen, wie beispielsweise Google, ist vor allem ein Trend erkennbar. Die durch die Nutzer*innen abgefragten Suchergebnisse werden aufgrund der spezifischen Rückmeldungen durch die oder den Nutzer*in in der Vergangenheit personalisiert.

Grundsätzlich hat diese Personalisierung von Empfehlungen einen großen Vorteil: Die Last durch einen Überschuss an Information wird reduziert. Für die Nutzer*innen wird durch Algorithmen-basierte Empfehlungssysteme vieles erleichtert. Nutzer*innen können zu jeder Zeit die nötigen Informationen abrufen. Im Falle von YouTube kann neben der aktiven Suche nach Information auch eine „passive Konsum-Haltung“ (Lean-Back) eingenommen werden, indem der Empfehlungsalgorithmus einfach immer wieder neue Videos vorschlägt und automatisch abspielt. Allerdings führt diese Personalisierung auch zu einer Reihe an negativen Effekten. Menschen werden mit einer geringeren Vielfalt an Informationen konfrontiert, Selbstauswahlprozesse werden potenziell verstärkt, und dies führt in weiterer Folge zu einer Fragmentierung der öffentlichen Meinung, in der ein Konsens bzw. die Herstellung einer gemeinsamen öffentlichen Meinung schwer fällt, die einzelne Bürgerin oder der einzelne Bürger nicht mehr in der Lage ist freie und informierte Entscheidungen für sich selbst zu treffen, geschweige davon an politischen Entscheidungen teilzunehmen.

Erwähnenswert ist auch die fehlende Transparenz dieser Systeme. Einige der sich im Einsatz befindenden Empfehlungssysteme zielen nach wie vor auf kurzfristige und einfache Metriken, wie beispielsweise die Anzahl der Klicks oder Likes („Gefällt

mir“/“Gefällt mir nicht“) ab. Wie genau sie jedoch funktionieren bleibt jedoch unklar. Auch YouTube steht diesbezüglich immer wieder in der Kritik (Stokel-Walker 2019). Klar ist, dass die Plattformen in der Verantwortung stehen, die Funktionsweise algorithmischer Empfehlungen zu ändern bzw. zu verbessern. So könnten Menschen beispielsweise mit einer breiteren Auswahl mit mehr Tiefe oder auch weniger beliebten Inhalten ausgesetzt bzw. konfrontiert werden. Die Theorie zu Filterblasen selbst wurde vielfach kritisiert. Allerdings legen weitere Untersuchungen nahe, dass viele andere Faktoren die Vielfalt der Informationsdiät eines Menschen beeinflussen. Algorithmen sind nur einer, und wahrscheinlich nicht der wichtigste, dieser Faktoren (Thies 2017, S. 101-104).

7 Conclusio

Die vorliegende Masterarbeit befasst sich mit den Auswirkungen Algorithmenbasierter Empfehlungssysteme auf die Entstehung von Filterblasen in der Plattformökonomie am Beispiel von YouTube. Dieses Kapitel bildet den Abschluss des Theorieteils dieser Arbeit. In den folgenden Abschnitten sollen erst die wichtigsten gewonnenen Erkenntnisse zusammengefasst werden, anschließend Forschungsfragen abgeleitet werden, und abschließend ein Ausblick auf den empirischen Teil dieser Arbeit gegeben werden.

7.1 Fazit zur Theorie

Zu Beginn dieser Arbeit wurden aktuelle empirische Studien im Rahmen des Forschungsstands (Kapitel Zwei) vorgestellt und analysiert. Eingang in dieses Kapitel fanden insbesondere Studien, die sich mit dem Video-Streaming-Dienst YouTube auseinandersetzten, sowie mit der Thematik der Plattformökonomie, Algorithmen und digitalen Empfehlungssystemen. Beschriebene Studien zu YouTube basieren vor allem auf der Entstehung von Popularität und fokussieren sich fast ausschließlich auf die ökonomischen Aspekte der Plattform. Wie Videos auf der Plattform erfolgreich sein können wurde hinreichend untersucht, eröffnet aber die Notwendigkeit sich tiefer mit Wirkungsweise dieser Dynamiken auseinanderzusetzen.

In Kapitel Drei wurden relevante Mediennutzungstheorien erläutert, darunter der Uses-and-Gratifications-Approach, sowie selektions- und rezeptionsorientierte, als auch kontextbezogene Ansätze. Die beschriebenen Theorien zur Mediennutzung beschäftigen sich insbesondere mit den Fragestellungen, weshalb Menschen welche Medien nutzen, was sie mit diesen machen und welche individuellen Bedürfnisse im Zuge der Mediennutzung befriedigt werden sollen (Uses-and-Gratifications-Ansatz), welche Hintergründe und Strukturen von Selektionsprozessen bestehen, wie Informationen verarbeitet werden, und wie diese emotional und subjektiv erlebt werden (Selektions- und rezeptionsorientierte Ansätze), als auch wie sich Menschen im Zuge der Mediennutzung verhalten (kontextbezogenen Ansätze). Bezugnehmend auf YouTube als Plattform geht aus diesem Kapitel klar hervor, dass weder das Alter und Geschlecht noch die soziale und psychologische Vorgeschichte der Nutzer*innen signifikante Prädiktoren für die Rezeption von Nachrichten-Inhalten auf YouTube sind. Das Motiv der Informationssuche spielt in diesem Kontext eine weitaus tragendere Rolle. Zusätzlich greift YouTube auf bekannte Heuristiken zurück, indem beispielsweise passende Videos im Anschluss vorgeschlagen werden. Der Video-Streaming-Dienst übernimmt in diesem Fall also im Vorfeld die Selektion.

Die weiteren Kapitel des Theorieteils befassten sich auf weitere thematisch wichtige theoretische Grundlagen:

In Kapitel Vier wurden Grundlagen zur Plattformökonomie und die Relevanz von YouTube in Österreich geklärt. Zusammenfassend können Plattformen als digitale Intermediäre beschrieben werden, die mehrere Akteursgruppen – im Falle von YouTube sind das die Nutzer*innen, die Content Creator*innen, die Marken und Unternehmen (Werbepartner*innen), sowie die Entwickler*innen-Community – zusammenbringen. Sie zeichnen sich insbesondere durch die Merkmale einer hohen Skalierbarkeit und Reichweite, der Möglichkeit zur Auswertung einer großen Datenmenge, niedrigen Transaktionskosten, starken Netzwerkeffekte, als auch einer hohen Dynamik aus (Vgl. Engelhardt, Wangler und Wischmann, 2017, S. 11-15). Die genauen Grundlagen zur Plattformökonomie wurden im ersten Abschnitt (Abschnitt 4.1) dieses Kapitels ausführlich erläutert. Betreffend der Relevanz von YouTube als Plattform in Österreich kann festgehalten werden, dass insbesondere

Jüngere auf den Video-Streaming-Dienst immer häufiger zurückgreifen, auch um Nachrichten zu beziehen. Diese Entwicklung wirft allerdings zusätzliche Bedenken auf, denn rechtspopulistische Parteien dominieren im Moment die Kategorie „Politik und Nachrichten“ in Österreich. Mit der Instrumentalisierung von Algorithmen durch die Plattformökonomie kommt noch ein weiterer wichtiger Aspekt hinzu, auf den in Kapitel Fünf näher eingegangen wurde. Dieses befasste sich mit dem Terminus der Algorithmen in Kontext zum Überbegriff der künstlichen Intelligenz (KI) und Machine Learning (ML). Wichtig zu verstehen ist, dass der Einsatz von Algorithmen nicht immer fehlerfrei ist. Maschinelles Lernen wird zunächst eingesetzt, um zukünftige Ereignisse oder Szenarien vorherzusagen, die dem Computer unbekannt sind. Aufgrund der immer höher werdenden Komplexität durch eine zunehmende Anzahl der Dimensionen, wodurch immer detailliertere Entscheidungen getroffen werden können, scheitern Algorithmen maschinellen Lernens in den meisten Fällen, die perfekte Entscheidungsstruktur für jede einzelne Nutzerin bzw. jeden einzelnen Nutzer zu bilden. Algorithmen versuchen also eine Balance zwischen Genauigkeit und Trefferquote herzustellen. Dabei bleibt unklar, wie diese Entscheidungsstrukturen genau aussehen und wie der Empfehlungsalgorithmus im Falle von YouTube überhaupt funktioniert. Denn sie bilden einen wichtigen Erfolgsfaktor als auch eine Abgrenzungsmöglichkeit zur Konkurrenz, und werden von den Unternehmen somit immer als Betriebsgeheimnis gehandelt. Jedoch steht YouTube insbesondere aufgrund problematischer Inhalte zunehmend unter Kritik, auf die das Unternehmen nur schleppend eingeht. Die Rede ist von einer Extremismus-Maschine, die Verschwörungstheorien befeuert oder beispielsweise, als eines der jüngsten Beispiele, das Feuer Notre Dames mit den Terroranschlägen vom 11. September in Verbindung setzte.

Den Abschluss des theoretischen Teils dieser Masterarbeit bildete das sechste Kapitel, welches sich speziell mit Algorithmen-basierten Empfehlungssystemen und der Entstehung von Filterblasen auseinandersetzte. Grundsätzlich lässt sich festhalten, dass Algorithmen-basierte Empfehlungssysteme bisher in den meisten Fällen zu der Entstehung von Filterblasen beitragen. Allerdings muss hier zwischen den Vor- und Nachteilen abgewogen werden. Denn eine Personalisierung von Empfehlungen einen großen Vorteil: Die Last durch einen Überschuss an Information wird reduziert. Für die Nutzer*innen wird durch Algorithmen-basierte

Empfehlungssysteme vieles erleichtert. Primär kommt es zu einer deutlichen Zeitersparnis, um Informationen zu beziehen. Allerdings führt eine Personalisierung von Informationen und Empfehlungen auch zu einer Reihe an negativen Effekten. Menschen werden mit einer geringeren Vielfalt an Informationen konfrontiert, Selbstauswahlprozesse werden potenziell verstärkt (d.h. Menschen werden in ihrem Hang zur Homogenität unterstützt), und dies führt in weiterer Folge zu einer Fragmentierung der öffentlichen Meinung, in der ein Konsens bzw. die Herstellung einer gemeinsamen öffentlichen Meinung schwer fällt, die einzelne Bürgerin oder der Bürger nicht mehr in der Lage ist freie und informierte Entscheidungen für sich selbst zu treffen, geschweige davon an politischen Entscheidungen teilzunehmen. Fraglich sind auch die Ziele der eingesetzten Empfehlungsalgorithmen. Betrachtet man die populären Plattformen dieses Planeten, dann zielen die sich im Einsatz befindenden Empfehlungssysteme- und Algorithmen klar auf sehr kurzfristige und einfache Metriken, wie beispielsweise die Anzahl der Klicks oder Likes („Gefällt mir“/„Gefällt mir nicht“), ab. Allerdings haben Plattformen auch wenig bis gar keine Anreize in Zukunft anders zu handeln, schließlich ist der Profit davon abhängig. Zusätzlich fehlt es an Transparenz diesbezüglich. Klar ist aber auch, dass Plattformen an erster Stelle in der Verantwortung stehen, die Funktionsweise algorithmischer Empfehlungen zu ändern bzw. zu verbessern. Abschließend wurde die Theorie zu Filterblasen selbst vielfach kritisiert. Allerdings legen weitere Untersuchungen nahe, dass viele andere Faktoren die Vielfalt der Informationsdiät eines Menschen beeinflussen. Algorithmen sind nur einer, und wahrscheinlich nicht der wichtigste, dieser Faktoren (Thies 2017, S. 101-104).

Mit diesem Wissen sollen nun im folgenden Abschnitt die Forschungsfragen abgeleitet werden, welche im Zuge der Empirie herangezogen werden.

7.2 Forschungsfragen

In diesem Abschnitt sollen nun die Forschungsfragen, die im Zuge des empirischen Teils dieser Arbeit untersucht werden, abgeleitet werden. Die Leitfrage dieser Arbeit lautet folgendermaßen:

„Wie wirken sich Algorithmen-basierte Empfehlungssysteme in der Plattformökonomie auf die Entstehung von Filterblasen am Beispiel von YouTube aus?“

Daraus können zwei weitere Forschungsfragen abgeleitet werden:

Erstere nimmt Bezug auf den Faktor der politischen Gesinnung, auf die im nächsten Kapitel noch näher eingegangen wird. Es soll herausgefunden werden, welchen Einfluss die politische Gesinnung einer Nutzerin bzw. eines Nutzers auf den YouTube-Algorithmus, und damit in weiterer Folge auf die Empfehlungen, die vom System generiert werden, hat. Die erste Forschungsfrage dieser Arbeit lautet folgendermaßen:

FF1: Inwieweit hat die politische Gesinnung einer Nutzerin bzw. eines Nutzers Einfluss auf den YouTube-Algorithmus und das darauf aufbauende Empfehlungssystem hinsichtlich der Entstehung von Filterblasen?

Die zweite Forschungsfrage geht auf die Reaktionen des YouTube-Empfehlungsalgorithmus ein und dient der Untersuchung, inwieweit sich das System an die Nutzerin bzw. den Nutzer, aufgrund seiner getätigten Interaktionen, anpasst. Die zweite Forschungsfrage dieser Arbeit lautet demnach folgendermaßen:

FF2: Inwiefern reagiert der YouTube-Empfehlungsalgorithmus auf Interaktionen mit politischen Videos?

Im nächsten Abschnitt soll nun ein Ausblick auf den empirischen Teil dieser Arbeit geworfen werden.

7.3 Ausblick Empirie

Im empirischen Teil dieser Arbeit wird zunächst die gewählte Methode zur Untersuchung der Auswirkungen Algorithmen-basierter Empfehlungssysteme in der Plattformökonomie auf die Entstehung von Filterblasen am Beispiel von YouTube

vorgestellt. Das Kapitel zur Methodologie (Kapitel Acht) gliedert sich in drei Abschnitte: Erläuterung der Erhebungsmethode (Abschnitt 8.1), Erläuterung der Auswertungsmethode (Abschnitt 8.2), sowie der Operationalisierung und Vorgehensweise (Abschnitt 8.3), in der konkrete Handlungsanweisungen für die Durchführung des Experiments aufgeschlüsselt werden. In Kapitel Neun werden anschließend die Ergebnisse aus der Durchführung des Experiments zusammenfassend analysiert und interpretiert. Das Kapitel schließt mit der Ableitung und Generierung der Hypothesen ab.

8 Methodologie

In den folgenden Absätzen sollen nun die Erhebungs- sowie Auswertungsmethode, um die Auswirkungen der Algorithmen-basierten Empfehlungssysteme in der Plattformökonomie auf die Entstehung von Filterblasen am Beispiel von YouTube zu untersuchen, erläutert werden. Das Kapitel zur Methodologie schließt mit der Operationalisierung und Erläuterung der Vorgehensweise ab.

8.1 Erläuterung der Erhebungsmethode

Filterblasen sind im politischen Diskurs mittlerweile ein bekannter Terminus, und geben insbesondere in demokratischen Ländern Anlass zur Sorge. Bürger*innen sind gefährdet angesichts der zunehmenden Polarisierung in politischen Fragen, den Zugang zu den Argumenten der Gegenseite zu verlieren. Vielmehr könnten sie in weiterer Konsequenz nur noch von Menschen und Nachrichtenquellen umgeben sein, die ähnlicher bzw. der gleichen Meinung sind.

Um die Auswirkungen Algorithmen-basierter Empfehlungssysteme auf die Entstehung von Filterblasen in der Plattformökonomie am Beispiel von YouTube zu untersuchen, wird die Methode des Experiments herangezogen. Mithilfe von Experimenten sollen allgemein Kausalzusammenhänge systematisch untersucht werden, indem spezifische Forschungsdesigns verwendet werden. Grundsätzlich zielen Experimente in der Sozialwissenschaft also auf die Gewinnung von Erkenntnissen hinsichtlich der Beziehung zwischen Ursache und Wirkung ab. Sie bilden die Grundlage, soziale Phänomene erkläbar zu machen. (Koch, Peter &

Müller 2019, S. 4; Kubbe 2017, S. 85) In ihrer Arbeit „Das Experiment in der Kommunikations- und Medienwissenschaft“ definieren die AutorInnen (Koch, Peter & Müller 2019, S. 4-5) ein Experiment folgendermaßen:

„Ein Experiment ist eine Untersuchungsanordnung zur Überprüfung von Kausalannahmen, bei der unter kontrollierten Bedingungen mindestens eine unabhängige Variable aktiv variiert und deren Einfluss auf eine oder mehrere abhängige Variablen gemessen wird.“

Die unabhängige Variable (auch: exogene bzw. erklärende Variable) kann als jene Größe verstanden werden, der man die potenzielle Ursache für eine zu untersuchende Wirkung zuschreibt. Diese Variable wird im Kontext des Experiments manipuliert, indem beispielsweise zwei unterschiedliche Gruppen (Experimentalgruppe und Kontrollgruppe) gebildet und miteinander verglichen werden. Beide Gruppen können entweder unterschiedlichen Stimuli-Ausprägungen ausgesetzt werden, oder eine Gruppe erhält den Stimulus und die andere nicht. Diese aktiven Variationen unabhängiger Variablen erfolgen alle systematisch und unterliegen einem bestimmten Plan. Nur so kann der Einfluss einer „Manipulation auf eine oder mehrere abhängige Variablen (auch: endogene bzw. erklärte Variable)“ gemessen werden.

Für das im Rahmen dieser Arbeit durchzuführende Experiment wird die politische Gesinnung einer Person als unabhängige Variable definiert. Denn gerade dieser Faktor hat einen wesentlichen Einfluss auf das Informations(-such)verhalten von Individuen. Kürzlich fanden beispielsweise Marks et. al. (2019) in ihrer Studie „Epistemic spillovers: Learning others’ political views reduces the ability to assess and use their expertise in nonpolitical domains“ heraus, dass Menschen es bei politischen Fragen vorziehen, sich mit denjenigen zu beraten bzw. von jenen zu lernen, deren politische Ansichten den eigenen ähneln. Dadurch verstärkt sich das Entstehungsrisiko von Filterblasen. Die Ergebnisse dieser Studie zeigen ebenfalls, dass das Wissen über die politischen Ansichten anderer Personen, die Fähigkeit beeinträchtigt, die Kompetenzen des Gegenübers in nicht zusammenhängenden Bereichen realistisch einzuschätzen. Dies führt folglich zu suboptimalen Entscheidungen hinsichtlich der Informationssuche als auch zu

Fehleinschätzungen. Damit haben die Ergebnisse insbesondere Auswirkungen auf die politische Polarisierung und das soziale Lernen inmitten politischer Spaltungen.

Es kann also davon ausgegangen werden, dass die politische Gesinnung einer Person eine wichtige Rolle hinsichtlich der Algorithmen-basierten Empfehlungen auf YouTube spielen. Die erste Forschungsfrage dieser Arbeit – *Inwieweit hat die politische Gesinnung einer Nutzerin bzw. eines Nutzers Einfluss auf den YouTube-Algorithmus und das darauf aufbauende Empfehlungssystem hinsichtlich der Entstehung von Filterblasen?* – fließt hiermit in die Untersuchung ein.

Allerdings ist es wichtig ein Experiment unter kontrollierten Bedingungen durchzuführen. Schließlich soll sichergestellt werden, ob Veränderungen bzw. Effekte der abhängigen Variable auch wirklich durch die Manipulation bzw. Variation der unabhängigen Variable hervorgerufen werden. Potenzielle Einflüsse müssen im Rahmen des experimentellen Vorgehens also ausgeschalten bzw. konstant gehalten werden. (Koch, Peter & Müller 2019, S. 5) Aus diesem Grund werden zwei Simulationsaccounts getrennt voneinander erstellt. Die fiktiven Personen, die hinter diesen Accounts stecken, unterscheiden sich lediglich in ihrer politischen Gesinnung, welche bereits als unabhängige Variable definiert wurde. Bei der Erstellung der Accounts muss allerdings darauf geachtet werden, dass sämtliche Informationen, wie beispielsweise das Geschlecht und das Alter übereinstimmen. Im Abschnitt 9.3 zur Operationalisierung und Vorgehensweise werden diese Attribute noch näher beschrieben. Auch das Verhalten der fiktiven Personen hinsichtlich politischer Videos wird in diesem Abschnitt erläutert. Damit fließt ebenfalls die zweite Forschungsfrage dieser Arbeit – *Inwiefern reagiert der YouTube-Empfehlungsalgorithmus auf Interaktionen mit politischen Videos?* – in die Untersuchung ein.

Experimente stellen in der Sozialwissenschaft so gut wie immer eine quantitative Erhebungsmethode dar. Qualitative Experimente sind dementsprechend eine Seltenheit, kommen jedoch vor, wenn keine bestehenden Annahmen überprüft werden sollen. (Koch, Peter & Müller 2019, S. 9) Nachdem im Rahmen dieser Arbeit die Auswirkungen Algorithmen-basierter Empfehlungssysteme in der

Plattformökonomie auf die Entstehung von Filterblasen am Beispiel von YouTube untersucht werden sollen, ist das durchzuführende Experiment der qualitativen Forschung zuzuordnen. Kleining (1986, S. 724) definiert ein qualitatives Experiment folgendermaßen: „*Das qualitative Experiment ist der nach wissenschaftlichen Regeln vorgenommene Eingriff in einen (sozialen) Gegenstand zur Erforschung seiner Struktur. Es ist die explorative, heuristische Form des Experiments.*“ Die Idee hinter dem qualitativen Ansatz in Bezug auf Experimente ist es, neue Annahmen zu treffen bzw. Neues zu entdecken und Strukturen zu explorieren (Koch, Peter & Müller 2019, S. 10). Im Gegensatz zum quantitativen Experiment, das hypothesenprüfend verfährt und auf kausale bzw. zahlenmäßig erfassbare Relationen abzielt, werden mithilfe eines qualitativen Experiments Hypothesen generiert. (Kleining 1986, S. 725)

Im folgenden Abschnitt wird nun näher auf die Methode der Auswertung des durchzuführenden Experiments eingegangen.

8.2 Erläuterung der Auswertungsmethode

Im vorangegangenen Abschnitt wurde beschrieben, warum zwei Simulationsaccounts eingesetzt werden, um Videos auf YouTube über einen gewissen Zeitraum anzusehen und zu analysieren. In diesem Abschnitt geht es nun darum, wie die Variable „politische Gesinnung“ im Zuge der Durchführung des Experiments umgesetzt wird und wie die Auswirkungen auf weitere Faktoren festgestellt werden können.

Während des Experiments sehen die fiktiven Personen, die den beiden Simulationsaccounts zugrunde liegen, pro Tag eine gewisse Anzahl an Videos – näheres wird im kommenden Abschnitt 9.3 beschrieben – und bewerten diese anhand ihrer politischen Gesinnung. Dafür ist es zuerst notwendig, auf den Sprachgebrauch innerhalb der Videos, die im Rahmen des Experiments rezipiert werden, einzugehen. Denn Sprache und bestimmte Wörter prägen das Denken. Nicht ohne Grund wird Sprache, insbesondere in der Politik, für manipulative Zwecke genutzt. Die Populismusforschung und Diskursanalyse setzen sich mit diesem Problem auseinander. Es soll also geklärt werden, wie der Sprachgebrauch,

die Entscheidungen hinsichtlich einer Bewertung durch die beiden fiktiven Personen steuert. Grundsätzlich werden hierfür die Tags der Videos auf YouTube herangezogen. Allerdings muss dafür erst definiert werden, welche Wörter und Wortgruppen links-liberalen bzw. rechts-konservativen Kohorten zugeordnet werden können. Die Einordnung der Tags soll anschließend auch die Entscheidung hinsichtlich einer Zustimmung zum Inhalt eines Videos, und die darauffolgende mögliche Bewertung, erleichtern. Eine Likert-Skala (1 = Stimme nicht zu, 2 = Stimme eher nicht zu, 3 = Stimme eher zu, 4 = Stimme zu) dient der Messung der Zustimmung während des Experiments. Mit der Einordnung der Zustimmung und der Bewertung eines Videos in letzter Konsequenz wird somit auch das Video politisch eingeordnet. Allerdings muss, neben der politischen Einordnung der Tags, definiert werden, nach welchen Kriterien den Inhalten eines Videos zugestimmt bzw. nicht zugestimmt werden kann. Mikos (2018, S. 92) klärt dazu im Handbuch der qualitativen Videoanalyse einen wichtigen Aspekt: „Filme und Fernsehsendungen können nur Angebote machen und mögliche Lesarten inszenieren, über die sie die Aktivitäten der Zuschauer*innen vorstrukturieren. Eines können sie aber nicht: Sie können nicht die Bedeutung festlegen.“ Allerdings „müssen sie als Aspekt der Kommunikation mit den Zuschauer*innen gesehen werden“. Das Erkenntnisinteresse der Analyse von Filmen und Fernsehsendungen, bzw. im Kontext dieser Arbeit, YouTube-Videos, kann sich laut Mikos (2018, S. 93) auf fünf Ebenen beziehen:

- (1) Inhalt und Repräsentation
- (2) Narration und Dramaturgie
- (3) Figuren und Akteure
- (4) Ästhetik und Gestaltung
- (5) Kontexte

Grundsätzlich könnten alle diese Ebenen in die Erhebung einfließen, allerdings wird im Rahmen dieser Arbeit insbesondere der Fokus auf den Inhalt und die Repräsentation dieses Inhalts (1) gelegt. Denn die erste Ebene ist eng mit der Bedeutungsbildung verbunden. Mit den Inhalten eines Videos wird eine soziale Welt repräsentiert. Alles, was im Rahmen eines YouTube-Videos gesagt oder gezeigt wird, kann als Inhalt definiert werden. Für die Analyse der YouTube-Videos, die sich stark an die von Mikos beschriebene Film- und Fernsehanalyse anlehnt, ist es

interessant, wie die Inhalte präsentiert werden. Denn dies trägt letztendlich zur sozialen Konstruktion von gesellschaftlicher Wirklichkeit bei. Grundsätzlich ist davon auszugehen, dass alles, was innerhalb eines Videos gezeigt wird, von hoher Bedeutung für die Zuschauer*innen ist. Erst mit einer Analyse der ersten Ebene können die Prozesse hinsichtlich eines sinnhaften Aufbaus der sozialen Welt verstanden werden. Die wiedergegebenen Texte innerhalb von YouTube-Videos korrespondieren als Repräsentationen mit gesellschaftlichen Strukturen und beziehen sich zugleich auf den gesellschaftlichen Wissensvorrat, der die Positionierung des Individuums in der Gesellschaft bestimmt (Peltzer & Keppler 2015, S. 5ff.; Berger & Luckmann 2010, S. 43). Die Bedeutung von Filmen und Fernsehsendungen, bzw. im Kontext dieser Arbeit YouTube-Videos, „ergibt sich erst aus der Rezeption und Aneignung im gesellschaftlichen Kontext und den kommunikativen Zusammenhängen der Lebenswelt“. (Mikos 2018, S. 93 ff.)

Für die Analyse innerhalb des Experiments gilt es ein allgemeines Erkenntnisinteresse zu entwickeln, das in weiterer Folge dabei hilft, die Zustimmung zum Inhalt eines YouTube-Videos einordnen zu können (Mikos 2018, S. 96). Generell sollen der Sprachgebrauch und die Repräsentation der Inhalte ausschlaggebend für die Einordnung sein. Das Erkenntnisinteresse in diesem Teil der Analyse beinhaltet dementsprechend die Repräsentation von links-liberalen bzw. rechts-konservativen Werten und Einstellungen innerhalb der YouTube-Videos, die im Rahmen des Experiments rezipiert werden. Folgende Gegenüberstellung soll hierbei Hilfe leisten (Thurich 2011, S. 103):

Links-liberale Werte	Rechts-konservative Werte
Gleichheit, Gerechtigkeit, Nähe, Wärme, Formlosigkeit, das "Du", Spontaneität, das Internationale und Kosmopolitische	Betonung der Unterschiede, Autorität, Distanz, geregelte Umgangsformen, das "Sie", Disziplin, das Nationale.

Tabelle 2 – Liberale und konservative Werte (in Anlehnung an Thurich 2011, S. 103)

Zudem liefert die Studie „Why do Liberals drink Latte?“ von DellaPosta, Shi und Macy (2015) wichtige Einblicke in den Bereich der „Lifestyle-Politik“. Neben den populären politischen Themen, darunter beispielsweise Abtreibung und gleichgeschlechtliche Ehe, erweitern die Autor*innen den Anwendungsbereich ihrer Untersuchung um Freizeitaktivitäten, Verbraucher*innenpräferenzen, ästhetische Vorlieben und persönliche Überzeugungen und korrelieren diese mit politischen Ansichten. Insbesondere in Hinblick auf die Entstehung von Filterblasen stellt dies einen wichtigen Aspekt dar. Natürlich entspricht die statistische Signifikanz nicht unbedingt der theoretischen Signifikanz mancher Aussagen. Viele der verwendeten Elemente sind nur schwache Prädiktoren dafür, ob eine Person liberal oder konservativ ist. Allerdings konnten die Autor*innen einige signifikante Korrelationen aufdecken. Die wichtigste Erkenntnis ihrer Arbeit ist nicht, dass alle Korrelationen groß sind, sondern dass viele groß genug sind, um systematische Erklärungsbemühungen zu rechtfertigen.

Die folgende Tabelle stellt zusammenfassend unterschiedliche Aussagen über Liberale und Konservative gegenüber, die aus den Untersuchungen der Autor*innen (DellaPosta, Shi & Macy 2015, S. 1482 ff.) hervorgehen:

	Stereotypische Aussagen über Liberale	Stereotypische Aussagen über Konservative
Moralische Urteile	Liberale sind sich überwiegend eher einig, dass „es eine gute Idee für ein Paar ist, das heiraten möchte, zuerst zusammenzuleben“. „wenn eine Ehe in Schwierigkeiten und unglücklich ist, ist es im Allgemeinen besser“ für die Eheleute und Kinder, wenn das Paar geschieden wird, anstatt zusammen zu bleiben.	Konservative sind eher der Ansicht, dass „eine Ehe ohne Kinder nicht vollständig ist“. Konservative stimmen eher darin überein, dass „es manchmal notwendig ist, ein Kind mit einer guten, harten Tracht Prügel zu bestrafen“. „Schwarz-Weiß“-Denken

	„Recht und Unrecht sind in der Regel keine einfache Sache von Schwarz und Weiß; es gibt viele Grautöne.“	
Glaube, Religion & Spiritualität	Liberale beten weniger häufig. Liberale haben mit größerer Wahrscheinlichkeit als Konservative Horoskope oder persönliche astrologische Berichte gelesen und glauben eher an die „übernatürlichen Kräfte verstorbener Vorfahren“.	Konservative sind eher gläubig. Konservative sind sich eher einig, dass „wir zu viel Vertrauen in die Wissenschaft und nicht genug in den religiösen Glauben haben“.
Umgang mit Tieren	„Tiere sollten die gleichen moralischen Rechte haben wie Menschen.“	Keine Aussagen vorhanden.
Musikalische Vorlieben	New Age, Blues/Rhythm, Rock, Country, Rap	Keine Aussagen vorhanden.
Kunst	Liberale sind weniger geneigt als Konservative, der Aussage zuzustimmen, dass „moderne Malerei ist keine Kunst; ein Kind könnte es tun“.	Keine Aussagen vorhanden.
Wissenschaft	Keine Aussagen vorhanden.	Konservative sind sich eher einig, dass „wir zu viel Vertrauen in die Wissenschaft und nicht genug in den religiösen Glauben haben“.

Tabelle 3 – Liberalismus & Konservativismus: Stereotypen (in Anlehnung an DellaPosta, Shi & Macy 2015, S. 1482 ff.)

Udolf (1973) bestätigt in seiner Arbeit, dass liberale Personen kognitiv zu glauben scheinen, dass konservative Personen, so sind, wie konservative Personen sich selbst beschreiben würden und umgekehrt. In anderen Worten, das was über Konservative oder Liberale gesagt wird, scheint auch so zu stimmen.

Die zusammengetragenen Aussagen liefern also, insbesondere für die Entwicklung der fiktiven Personen bzw. den beiden Simulationsaccounts im nächsten Abschnitt, wichtige und hilfreiche Einblicke.

Im vorangegangenen Abschnitt wurde festgestellt, dass es sich bei dem durchzuführenden Experiment um ein Qualitatives handelt. Dieses arbeitet hypothesengenerierend und nicht prüfend. Allerdings können im Rahmen der Auswertung einige quantitative Vergleiche angestellt werden. Die Stichprobe von lediglich zwei Personen ($n=2$) lässt zwar keine Verallgemeinerungen zu, Vergleiche sind dennoch nötig und hilfreich, um aussagekräftige Hypothesen zu generieren. Quantitativ könnten also folgende Dinge miteinander verglichen werden:

- Anzahl der positiven bzw. negativen Bewertungen der rezipierten Videos bzw. der Videos auf der Startseite
- Vergleich der Zustimmung zu den Inhalten der YouTube-Videos, je nach Simulationsaccounts
- Kanal-Abonnements pro Simulationsaccount
- Durchschnittliche Anzahl der verifizierten Kanäle innerhalb der Vorschläge und der Rezeption

8.3 Operationalisierung und Vorgehensweise

Ziel des, im Rahmen dieser Arbeit durchzuführenden Experiments ist es, die Auswirkungen der Algorithmen-basierten Empfehlungssysteme in der Plattformökonomie auf die Entstehung von Filterblasen anhand von YouTube, festzuhalten und zu beschreiben.

Hierfür werden zwei voneinander unabhängige Simulationsaccounts erstellt. Die fiktiven Personen, die diesen Accounts zugrunde liegen, unterscheiden sich lediglich in ihrer politischen Gesinnung. Für die Erstellung der Google-Accounts werden folgende Attribute festgelegt:

	Account A	Account B
Vorname	Petra	Pia
Nachname	Meister	Muster
E-Mail-Adresse	dmm17.p.m.Acc.A@gmail.com	dmm17.p.m.Acc.B@gmail.com
Geburtsdatum	30.8.1995	30.8.1995
Geschlecht	weiblich	weiblich

Tabelle 4 – Attribute zur Erstellung der Google-Accounts (aufgelistet nach Simulationsaccount)

Wie bereits in Abschnitt 9.1 beschrieben wurde, stellen das Geburtsdatum bzw. das Alter und das Geschlecht potenzielle Einflüsse innerhalb der Untersuchung dar. Aus diesem Grund wird für beide Simulationsaccounts Gleiches angegeben.

Bezüglich des demographischen als auch soziodemographischen Hintergrund beider Persönlichkeiten, wird folgendes festgelegt (in Anlehnung an DellaPosta, Shi & Macy 2015):

Demographischer & soziodemographischer Hintergrund	Account A	Account B
Geschlecht	weiblich	weiblich
Geburtskohorte	Jahrgang 1995	Jahrgang 1995
Staatsangehörigkeit	Österreich	Österreich
Region, Wohnort	Niederösterreich, Mödling	Niederösterreich, Mödling
Höchster Bildungsstand	Bachelor-Abschluss	Bachelor-Abschluss
Beziehungsstatus	Unverheiratet, in keiner Beziehung	Unverheiratet, in keiner Beziehung
Elternschaft	Keine Kinder	Keine Kinder

Religion/Konfession	Gehört keiner Glaubensgemeinschaft an	Römisch-katholisch
---------------------	---------------------------------------	--------------------

Tabelle 5 – Demographischer und soziodemographischer Hintergrund der fiktiven Personen
(aufgelistet nach Simulationsaccount)

Weitere Werte und Einstellungen zu aktuellen politischen und gesellschaftlichen Diskurs-Themen, werden wie folgt für beide Simulationsaccounts bzw. fiktive Persönlichkeiten definiert bzw. anhand von spezifischen Aussagen geklärt:

Werte & Einstellungen zum aktuellen politischen und gesellschaftlichen Diskurs	Account A	Account B
Politische Gesinnung	Links-liberal	Rechts-konservativ
Europa & EU	+ „Wir müssen noch enger zusammenrücken. Meine Vision ist ein gemeinsames Europa, in dem alle einen europäischen Pass besitzen.“	+/- „Grundsätzlich finde ich die Idee eines gemeinsamen Europas gut. Ich stehe dem Funktionieren der europäischen Union allerdings skeptisch gegenüber.“
Österreich als Sozialstaat	+ „Das Gemeinwohl aller ist wichtig, wir sollten uns gegen Ungleichheit und Ausbeutung stark machen.“	- „Viele Österreicher*innen finden mit ihrem Gehalt ein zu geringes Auskommen.“

		<p><i>„Ich habe oft gehört, dass die Mindestsicherung für Zugewanderte höher ist, als manche Pension einer Österreicherin bzw. eines Österreichers.“</i></p>
Flüchtlinge in Europa & Integration	<p>+</p> <p><i>„Jede*r Mensch hat ein Recht auf Schutz und Frieden, deswegen muss Flüchtlingen geholfen werden.“</i></p> <p><i>„Damit Integration funktionieren kann, muss einiges getan werden, aber es ist machbar.“</i></p>	<p>-</p> <p><i>„... Europa kann keine Menschen mehr aufnehmen.“</i></p> <p><i>„Integration kann nicht funktionieren. Zu viele unterschiedliche Kulturen prallen aufeinander.“</i></p>
Umwelt-/Klimaschutz	<p>+</p> <p><i>„Der Schutz unseres Klimas ist momentan unsere wichtigste Aufgabe.“</i></p>	<p>+</p> <p><i>„Wir müssen auf den Schutz unserer Umwelt achten.“</i></p>
Forschung, Entwicklung & Bildung	<p>+</p> <p><i>„Jede*r Mensch hat ein Recht auf Bildung. Wir müssen sicherstellen, dass jede*r auch in den Genuss von Bildung kommt.“</i></p>	<p>+</p> <p><i>„Bildung ist äußerst wichtig. Österreich sollte einen freien Hochschulzugang gewährleisten.“</i></p>

	<i>„Eine bessere Bildung kann die Welt verändern.“</i>	
Digitalisierung & Netzpolitik	<p>+</p> <p><i>„Die Digitalisierung hilft uns als EU-Bürger*innen näher zusammenzurücken.“</i></p> <p><i>„Grundsätzlich bin ich für viele Ideen offen. Eine gemeinsame Kryptowährung für Europa hört sich nach einem spannenden Konzept an.“</i></p>	<p>+/-</p> <p><i>„Die Digitalisierung sollte schneller voranschreiten, allerdings soll damit nicht alles zentral gesteuert werden. Die einzelnen Staaten sollen ihre Rechte behalten.“</i></p>
Technologie (Künstliche Intelligenz, Big Data, Robotik, etc.)	<p>+</p> <p><i>„Die aktuellen technologischen Entwicklungen stellen eine Chance dar. Ich bin zuversichtlich, dass in Zukunft neue Jobs entstehen.“</i></p>	<p>+</p> <p><i>„Es ist wichtig, dass Österreich nicht den Anschluss im Hinblick auf die technologischen Entwicklungen verliert.“</i></p> <p><i>„Meine Zuversicht hält sich in Grenzen.“</i></p>
Überwachung & Sicherheit	<p>-</p> <p><i>„Ich persönlich lehne eine anlasslose Vorratsdatenspeicherung ab.“</i></p>	<p>+</p> <p><i>„Der Schutz vor Kriminalität und Terror ist mir persönlich ein Anliegen.“</i></p>

		<p>„Ein wirksamer Außengrenzschutz ist wichtig.“</p>
Urheber- und Medienrecht	<p>+</p> <p>„Urheber*innen sollten fair entlohnt werden. Die Kontrolle darüber sollte aber nicht zu einer Zensurinfrastruktur führen.“</p> <p>„Die Freiheit der Medien ist die Grundlage einer funktionierenden Demokratie.“</p>	<p>-</p> <p>„Mir persönlich fällt es schwer den Medien in Österreich zu vertrauen.“</p> <p>„Zwangsgebühren für staatlich subventionierte Medien sollten abgeschafft werden.“</p>
Glauben & Religion	<p>-</p> <p>„Glaube und Religion sind der Grund für alles Schlechte dieser Welt.“</p>	<p>+</p> <p>„Traditionen sind wertvoll. Mein Ziel ist, diese auch einmal an meine Kinder weiterzugeben.“</p>
Homosexualität / Gleichgeschlechtliche Ehe	<p>+</p> <p>„Jede*r hat das Recht von jeder bzw. jedem, unabhängig des Geschlechts oder anderweitiger Zugehörigkeit geliebt zu werden und zu lieben.“</p>	<p>+/-</p> <p>„Eine Ehe kann nur zwischen Mann und Frau geschlossen werden.“</p>
Schwangerschaftsabbruch	<p>+</p>	<p>-</p>

	<i>„Jede*r ist für seinen Körper selbstverantwortlich und soll eigene Entscheidungen treffen dürfen.“</i>	<i>„Jede*r Mensch hat ein Recht auf Leben.“</i>
--	---	---

Tabelle 6 - Werte und Einstellungen zum aktuellen politischen und gesellschaftlichen Diskurs (aufgelistet nach Simulationsaccount)

Die Aussagen wurden speziell für die fiktiven Persönlichkeiten erstellt, um ein besseres Gefühl für ihr Bild auf die Welt zu bekommen. Die beschriebenen und definierten Werte und Einstellungen leiten sich insbesondere aus den, in den vorangegangenen Abschnitten beschriebenen stereotypischen Werten und Einstellungen ab, wurden aber auch individuell ergänzt.

Die Dauer und der Zeitraum für die Durchführung des Experiments wird folgendermaßen festgelegt:

Dauer des Experiments	Durchführungszeitraum des Experiments
28 Tage (4 Wochen)	Samstag, 20.7.2019 bis Freitag, 16.8.2019

Tabelle 7 – Dauer und Zeitraum Durchführung Experiment

Pro Tag werden jeweils drei Videos pro Simulationsaccount angesehen. Wobei nur eines davon aus dem Bereich Nachrichten bzw. Politik stammen soll (d.h. es wird aktiv ein Video aus dieser Kategorie täglich ausgewählt, hierfür werden anfangs die Themen „Nachrichten“, „Nationale Nachrichten“ und „Internationale Nachrichten“ abonniert). Damit soll einerseits sichergestellt werden, dass nur die Vorschläge von YouTube selbst in die Untersuchung miteinfließen, ohne darin anderweitig einzugreifen, wie zum Beispiel durch die Suche nach bestimmten Inhalten. Andererseits werden dadurch die Vorschläge, die beide fiktiven Personen durch ihre Nutzung bekommen, vergleichbar. Beispielsweise könnte der

Empfehlungsalgorithmus von YouTube schon eine gewisse politische Voreinstellung haben, ohne dem Zutun der fiktiven Personen. Damit könnte es auch leichter zur Entstehung einer Filterblase in einem politischen Spektrum kommen, als in einem anderen. Am Ende geht es also darum, so wenig Einfluss auf die Entstehung einer Filterblase zu nehmen, wie möglich, indem lediglich auf die bereits bestehenden Vorschläge von YouTube selbst zurückgegriffen wird.

Bevor die drei erwähnten Videos pro Tag allerdings rezipiert werden, werden pro Simulationsaccount die Vorschläge auf der Startseite festgehalten. Folgende Informationen sollen im Zuge der täglichen Startseiten-Analyse dokumentiert werden:

Startseite	Beispiel
Kategorien, die auf der Startseite empfohlen werden	Trends, Nachrichten, etc.
Themen, die empfohlen werden (die ersten Drei)	Handwerk, Dokumentarfilme, etc.
Kanäle, die empfohlen werden (die ersten Drei)	Jungle Survival, Quantum Tech HD, etc.
Video	Beispiel
Kategorie	Nachrichten
Titel	Konservative gewinnen Wahl in Griechenland
Kanal	tagesschau
Kanalverifizierung	vorhanden
Dauer	7:26 Minuten
Aufrufanzahl	4.915
Uploadzeitpunkt	Vor 7 Stunden
Link	https://www.youtube.com/watch?v=rHSAtfztKxM

Tabelle 8 – Dokumentation und Analyse (Startseite und einzelne Videos)

Die drei Videos, die pro Simulationsaccount an einem Tag rezipiert werden, sollen nach dem Zufallsprinzip ausgewählt werden. Pro rezipiertes Video sollen folgende Informationen dokumentiert werden:

Pro gesehenem Video	Vorschlag (Watch next)
Titel	Titel
Dauer	Aufrufanzahl
Aufrufanzahl	Dauer
Uploadzeitpunkt	Kanal
Anzahl der positiven Bewertungen	Link
Anzahl der negativen Bewertungen	Tags
Anzahl der Kommentare	
Kanal	
Kanalverifizierung	
Anzahl der Abonnent*innen des Kanals	
Zustimmung zum Inhalt (Likert-Skala)	
Bewertung durch Simulationsaccount (positiv/negativ)	
Abonnement des Kanals durch Simulationsaccount	
Link	
Tags	

Tabelle 9 – Dokumentation und Analyse (rezipierte Videos)

Es werden somit folgende Verhaltensregeln für den Umgang mit bzw. die Nutzung von YouTube mittels der beiden Simulationsaccounts festgelegt:

- Es werden nur Video-Vorschläge rezipiert, die entweder auf der Startseite oder unter der Kategorie „Nachrichten und Politik“ erscheinen.

- Es werden ausschließlich politische Videos positiv bzw. negativ bewertet, da sie so politisch eingeordnet werden und die unabhängige Variable „politische Gesinnung“ beeinflussen soll und nicht umgekehrt.
- Je nach Zustimmung zum Inhalt, werden politische Videos positiv bzw. negativ bewertet:
 - Die Zustimmung zu einem Inhalt eines Videos wird anhand einer Likert-Skala gemessen (1 = Stimme nicht zu, 2 = Stimme eher nicht zu, 3 = Stimme eher zu, 4 = Stimme zu).
 - Grundsätzlich wird der Inhalt eines Videos für die Einordnung der Zustimmung herangezogen. Die Tags der Videos, die im Zuge der Dokumentation festgehalten werden, sollen zusätzlich die Entscheidung hinsichtlich der Zustimmung zum Inhalt eines Videos erleichtern.
 - Videos werden nur dann positiv bzw. negativ bewertet, wenn den Inhalten zugestimmt (= 4) bzw. nicht zugestimmt (= 1) wird.
- Die ausgewählten Videos werden bis zum Ende angesehen und zwischendurch nicht abgebrochen.
- Sobald drei Videos desselben Kanals durch einen der Simulationsaccounts rezipiert wurden, wird der Kanal abonniert.
- Sobald drei Mal derselbe Kanal bzw. dasselbe Thema innerhalb der Startseite vorgeschlagen wird, wird dieser bzw. dieses durch den jeweiligen Simulationsaccount abonniert.

Folgendes Modell illustriert das Verfahren im Rahmen der Durchführung des Experiments:

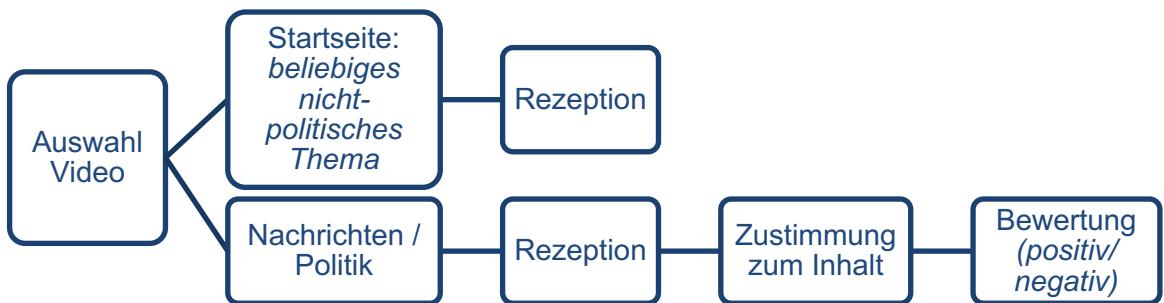


Abbildung 3 – Videoauswahlprozess und Entscheidungsverfahren (eigene Darstellung)

Zudem visualisiert das folgende Modell den grundlegenden Entscheidungsprozess, der beiden fiktiven Personen bzw. Simulationsaccounts zugrunde liegt, sofern es sich um ein politisches Video handelt:

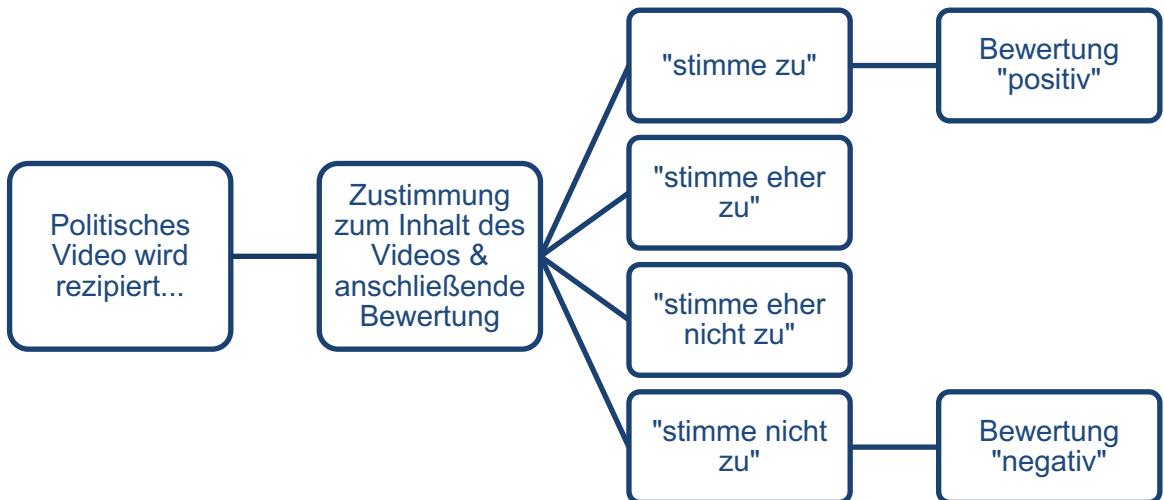


Abbildung 4 – Entscheidungsprozess hinsichtlich der Bewertung politischer YouTube-Videos (eigene Darstellung)

Wichtig in diesem Kontext ist zu beschreiben, wann und warum ein Video wie bewertet wird, und welche Konsequenzen mit einer Bewertung einhergehen.

Grundsätzlich gibt es zwei Fälle, die eintreten können, nachdem der Inhalt eines YouTube-Videos beurteilt werden kann:

- (1) Inhalt des Videos vertritt stark liberale bzw. konservative Werte und Einstellungen / kann politisch klar eingeordnet werden.
- (2) Inhalt des Videos vertritt liberale bzw. konservative Werte und Einstellungen, entweder in einem geringeren Ausmaß oder tendiert eher in eine Richtung, als in eine andere.

Im ersten Fall wird das Video entweder positiv oder negativ bewertet. Abhängig vom Simulationsaccount bzw. der fiktiven Persönlichkeit, kann das Video, falls es klar liberale bzw. konservative Werte vertritt, positiv bewertet werden, oder genau umgekehrt, also negativ bewertet werden. Die zuvor definierte politische Gesinnung und die aufgelisteten Werte und Einstellungen dienen der Hilfestellung zur Entscheidungsfindung. Nachdem im Rahmen des Experiments nur politische YouTube-Videos überhaupt eingeordnet und bewertet werden, wurde absichtlich auf eine neutrale Entscheidungsmöglichkeit verzichtet.

Für die Durchführung des Experiments steht für jeden Simulationsaccount jeweils ein mobiles Gerät (Marke: Terra, Modell: Terra Mobile 1507) zur Verfügung. Beide Geräte sind mit demselben WLAN-Netzwerk verbunden. Im Realitätsfall wäre es beispielsweise möglich, dass die fiktiven Personen Geschwister im selben Haushalt sind oder in derselben Wohngemeinschaft miteinander leben. Die Website „www.youtube.com“ wird während der Durchführung mittels des Google Chrome Browsers geöffnet.

Die zu dokumentierenden Inhalte werden mittels Excel-Tabelle festgehalten.

9 Empirische Analyse

Im vorliegenden Kapitel werden nun die Ergebnisse des durchgeföhrten Experiments, welches im vorangegangenen Kapitel Acht zur Methodologie bereits

näher erläutert und operationalisiert wurde, analysiert und interpretiert. Die Ergebnisse sollen abschließend zur Generierung der Hypothesen herangezogen werden.

9.1 Analyse und Interpretation der Ergebnisse

Im vorliegenden Kapitelabschnitt werden nun die relevanten Ergebnisse, die aus der Durchführung des bereits beschriebenen Experiments hervorgehen, analysiert und interpretiert.

Zu Beginn muss allerdings festgehalten werden, dass das Experiment anstatt der zuvor festgelegten Anzahl von 28 Tagen, nur 24 Tage durchgeführt werden konnte. Grund für den um vier Tage verkürzten Durchführungszeitraum, ist eine Adaption der Darstellung der Inhalte seitens YouTube. Während der 24 Tage (20.07.2019 bis 12.08.2019) wurden jeweils bis zu drei Kategorie-Empfehlungen, Themen-Empfehlungen sowie Kanal-Empfehlungen, mitsamt der ersten drei Video-Vorschläge, festgehalten und dokumentiert. Seit dem 13.08.2019 wird der Inhalt allerdings anders dargestellt. YouTube gliedert die Video-Empfehlungen nicht mehr anhand dieser drei Elemente, sondern reiht Video-Empfehlung an Video-Empfehlung. Es geht damit also nicht mehr klar hervor, welche Videos, Themen oder Kanäle empfohlen werden oder welche Videos erst kürzlich hochgeladen wurden.

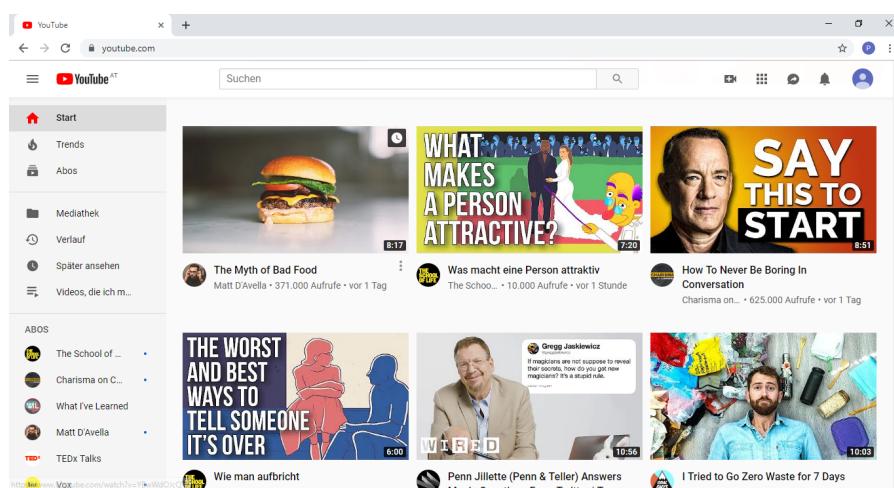


Abbildung 5 – Neue Darstellung der Inhalte auf YouTube (Stand 13.08.2019)

Die erstellten Simulationsaccounts könnten damit selbst Teil eines Experiments geworden sein, oder YouTube hat die Darstellung nur für Windows-Systeme umgestellt. Denn diese ist beispielsweise für zwei weitere, untersuchte Apple-Geräte nach wie vor dieselbe:

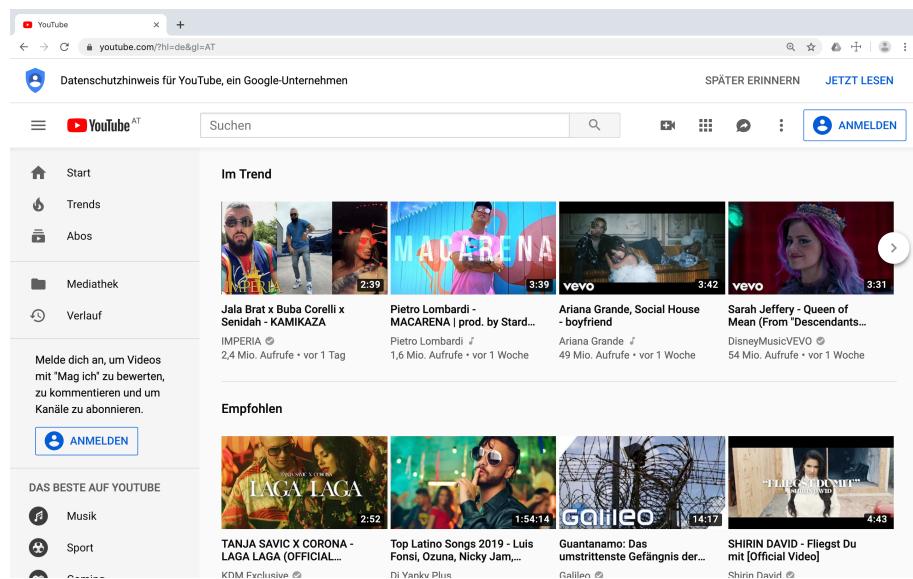


Abbildung 6 – Unveränderte Darstellung der Inhalte auf YouTube auf Apple-Geräten (Stand 14.08.2019)

Die Dokumentation konnte unter diesen Umständen somit nicht fortgesetzt werden. Folgende Ergebnisse können dennoch festgehalten werden:

Wie bereits beschrieben, wurden täglich für die ersten drei Kategorie-, Themen- und Kanal-Empfehlungen jeweils die ersten drei empfohlenen Videos dokumentiert. Aus dem Vergleich der Startseite gehen folgende Ergebnisse hervor:

	Account A	Account B
Summe der dokumentierten empfohlenen Videos (Startseite)	551	546
Summe der verifizierten Kanäle (pro Video-Empfehlung auf der Startseite)	467 (85%)	268 (49%)
Summe der nicht-verifizierten Kanäle (pro Video-Empfehlung auf der Startseite)	84 (15%)	278 (51%)

Tabelle 10 – Startseitenanalyse

Die Anzahl der Video-Empfehlungen weicht minimal ab. Grund für diesen Unterschied, ist die Darstellung der Video-Empfehlungen seitens YouTube. Beispielsweise wird ab und zu ein Kanal oder ein Thema empfohlen und nur ein Video speziell hervorgehoben. Grundsätzlich kann jedoch festgehalten werden, dass der erste Simulationsaccount (Account A) in Summe wesentlich mehr Videos vorgeschlagen bekommt, die von verifizierten Kanälen stammen, als von Nicht-verifizierten. Bei Account B sieht das anders aus: Hier gleichen sich die Video-Vorschläge bezüglich einer vorhandenen oder nicht vorhandenen Kanalverifizierung aus, wobei Videos von nicht-verifizierten Kanälen etwas öfter (~ 2 Prozent) vorgeschlagen werden. Voraussetzung für eine Kanalverifizierung sind laut YouTube (2019) eine Mindestanzahl von 100.000 Abonnent*innen. Kanälen mit einer Verifizierung sollte im Grunde genommen mehr vertraut werden können, da diese von der Plattform selbst bestätigt wurden.

Betrachtet man nun diese Entwicklung über die Dauer von 24 Tagen etwas detaillierter, fällt auf, dass zu Beginn des Experiments beiden Accounts fast ausschließlich nur Videos empfohlen wurden, die von verifizierten Kanälen stammen. Bei ersterem Simulationsaccount (Account A) bleibt dies über die 24 Tage relativ konstant der Fall. Zwar gibt es ein paar Ausreißer, beispielsweise am achten Tag der Durchführung des Experiments überwiegen die nicht-verifizierten Empfehlungen auf der Startseite (63 Prozent der Videos stammen von nicht-verifizierten Kanälen) die verifizierten Empfehlungen. Grundsätzlich stammen aber durchschnittlich 84 Prozent von verifizierten Quellen. Bei Account B hingegen beginnen die Empfehlungen von verifizierten Kanälen schon ab dem zweiten Tag konstant zu sinken. Insbesondere am elften Tag des Experiments wurden hauptsächlich Inhalte von nicht-verifizierten Quellen empfohlen – nur zwei von 24 Video-Empfehlungen stammen von verifizierten Kanälen. Bis auf ein paar Ausreißer überwiegen ab diesem Zeitpunkt die von nicht-verifizierten Kanälen stammenden Video-Empfehlungen.

Von beiden Accounts wurden insgesamt 72 Videos im Erhebungszeitraum rezipiert. Folgende Unterschiede lassen sich in diesem Zusammenhang feststellen:

	Account A	Account B
Summe der gesehenen Stunden während des Untersuchungszeitraums	08:04:55	08:17:12
Durchschnittlich gesehene Minuten pro Tag	00:20:12	00:20:43
Gesehene Videos von verifizierten Kanälen	64 (89%)	35 (49%)
Gesehene Videos von nicht-verifizierten Kanälen	8 (11%)	37 (51%)

Tabelle 11 – Rezeptionsanalyse

Sobald Kanäle oder Themen drei Mal in Folge auf der Startseite empfohlen wurden, wurden diese abonniert. Kanäle wurden auch dann abonniert, sobald drei Videos des betreffenden Kanals rezipiert wurden.

Folgende Kanäle wurden von den beiden Simulationsaccounts im Laufe des Experiments anhand der festgelegten Handlungsanweisungen abonniert:

	Account A	Account B
1	WIRED	SPIEGEL TV
2	Matt D'Avella	Frühstücksfernsehen
3	TEDx Talks	tagesschau
4	tagesschau	ARD
5	Vanity Fair	Addendum
6	faz	BILD
7	What I've Learned	Galileo
8	Charisma on Command	Gottfried Curio
9	TheEllenShow	OE24.TV
10	Med School Insiders	marktcheck
11	TED	Gerald Grosz
12	Vox	Ignaz Bearth

13	Doctor Mike	faz
14	First We Feast	
15	Jamie Oliver	
16	Quarks	
17	Nathaniel Drew	

Tabelle 12 – Kanal-Abonnements

Bei den Kanal-Abonnements liegen zwei Überschneidungen – tagesschau, faz – vor.

In weiteren Verlauf wurden die folgenden Themen von den Simulationsaccounts abonniert:

	Account A	Account B
1	Nachrichten	Nachrichten
2	Internationale Nachrichten	Internationale Nachrichten
3	Nationale Nachrichten	Nationale Nachrichten
4	Autos	Autos
5	Kochrezept	Kochrezept
6	TED	Sat.1 Frühstücksfernsehen
7	Technologie	Cartoon
8	Trickfilme	Technologie
9	Zeichentrickfilme	Kochen
10	Dokumentarfilme	Dokumentarfilme
11	Comedy	Heimtier
12	Kochen	
13	Talkshows	
14	Gordon Ramsay	

15	Unterhaltungselektronik	
16	Visuelle Künste	

Tabelle 13 – Themen-Abonnements

Insgesamt liegen bei den Themen-Abonnements acht Überschneidungen – Nachrichten, Internationale Nachrichten, Nationale Nachrichten (wobei diese drei Abonnements vorab festgelegt wurden), Autos, Kochrezept, Technologie, Kochen und Dokumentarfilme – vor.

Account A hat nach dieser Aufstellung insgesamt 33 Abonnements abgeschlossen, Account B hingegen nur 24. Betrachtet man die gesamten Empfehlungen, die die beiden Simulationsaccounts über die Dauer des Experiments erhielten, kann festgehalten werden, dass Account B circa 8 Prozent mehr Empfehlungen (dies entspricht einer Anzahl von sechs Empfehlungen) erhielt als Account A.

	Account A	Account B
Anzahl der empfohlenen Themen	38	37
Anzahl der empfohlenen Kanäle	36	43
Summe der Empfehlungen	74	80

Tabelle 14 – Überblick Themen- und Kanal-Empfehlungen

Diese Abweichung kann möglicherweise dazu geführt haben, dass Account B weniger Abonnements abgeschlossen hat, als Account A. Prozentual gesehen wurde von Account A fast jeder zweiten Empfehlung (~45 Prozent) nachgegangen, indem ein Kanal oder ein Thema abonniert wurde. Von Account B hingegen wurde durchschnittlich nur jeder dritte Kanal bzw. jedes dritte Thema (30 Prozent) abonniert. Je mehr Vorschläge ein Account also bekommt, desto weniger häufig kommt es dazu, dass ein Vorschlag in den nächsten Tagen wiederholt wird. Somit sinken in diesem Fall auch die Chancen einen Kanal oder ein Thema zu abonnieren.

Im Rahmen des Experiments wurden zudem ausschließlich politische Videoinhalte bewertet, um den Einfluss der politischen Gesinnung einer Person – in diesem Fall die fiktiven Personen, die hinter den erstellten Simulationsaccounts stecken – zu

erforschen. Vergleicht man nun, wie häufig die beiden Simulationsaccounts rezipierte Videos bewertet haben, indem anhand einer Likert-Skala die Zustimmung zum Inhalt des gesehenen Videos definiert wurde, kann folgendes beobachtet werden:

	Account A	Account B
1 – Stimme nicht zu	7	6
2 – Stimme eher nicht zu	2	14
3 – Stimme eher zu	5	21
4 – Stimme zu	11	11
Σ	25	52
%	35	72

Tabelle 15 – Zustimmung zum Inhalt rezipierter Videos

Zunächst fällt auf, dass Account B wesentlich stärker mit politischen Videos konfrontiert wurde als es bei Account A der Fall war. Beinahe drei von vier Videos (72 Prozent), die durch Account B rezipiert wurden, hatten einen politischen Einschlag, der dazu führte dass 52 Videos, also circa 2,2 politische Videos pro Tag, anhand der zuvor erwähnten Likert-Skala bewertet wurden. Bei Account A hingegen war nur circa jedes dritte Video (35 Prozent) politisch, weshalb auch nur 25 Videos insgesamt bewertet wurden, dies entspricht ungefähr einem rezipierten politischen Video pro Tag. Sobald ein Account dem jeweiligen rezipierten Video zustimmt (4 – Stimme zu) oder nicht zustimmt (1 – Stimme nicht zu) wurde dieses zusätzlich aktiv auf YouTube bewertet. Dementsprechend hat Account A elf „Daumen hoch“ (positive Bewertung auf YouTube) und sieben „Daumen runter“ (negative Bewertung auf YouTube), Account B ebenfalls elf „Daumen hoch“ und sechs „Daumen runter“ gegeben.

Abschließend kann gesagt werden, dass das Experiment, trotz des um vier Tage verkürzten Durchführungszeitraums, erfolgreich abgeschlossen werden konnte. Beide Simulationsaccounts finden sich nach Abschluss des Experiments in zwei fast völlig unterschiedlichen Filterblasen wieder. Während bei Account A kaum

politische Inhalte vorkommen, sind diese bei Account B wesentlich präsenter. Die Ergebnisse, die in diesem Abschnitt zusammenfassend analysiert und interpretiert wurden, liefern einschlägige Einblicke in die Entstehung von Filterblasen durch Algorithmen-basierte Empfehlungssysteme in der Plattformökonomie. Diese sollen nun genutzt werden, um im nachfolgenden Abschnitt die Hypothesen dieser Arbeit abzuleiten.

9.2 Ableitung der Hypothesen

In diesem Abschnitt sollen nun die Hypothesen aus den bereits interpretierten Analyseergebnissen abgeleitet werden.

Die erste Forschungsfrage dieser Arbeit lautete folgendermaßen:

FF1: Inwieweit hat die politische Gesinnung einer Nutzerin bzw. eines Nutzers Einfluss auf den YouTube-Algorithmus und das darauf aufbauende Empfehlungssystem hinsichtlich der Entstehung von Filterblasen?

Um für diese Forschungsfrage eine geeignete Hypothese ableiten zu können, muss nochmals darauf verwiesen werden, dass als einzige unabhängige Variable der fiktiven Personen beider Simulationsaccounts die politische Gesinnung definiert wurde. Abhängig von der politischen Gesinnung wurden YouTube-Videos rezipiert und bewertet. Wie im vorangegangenen Abschnitt bereits ausführlich beschrieben wurde, konnten wesentliche Unterschiede zwischen den beiden Simulationsaccounts hinsichtlich der Entwicklung der vorgeschlagenen und in Folge dessen rezipierten Inhalten festgehalten werden. Während Account B fast ausschließlich politische Videos rezipierte, setzte sich Account A sichtlich weniger häufig mit politischen Inhalten auseinander. Ausschlaggebend dafür könnte natürlich die Ausprägung der politischen Gesinnung sein, somit wird die erste Hypothese dieser Arbeit folgendermaßen formuliert:

H1: Die politische Gesinnung einer Nutzerin bzw. eines Nutzers hat einen Einfluss auf den YouTube-Algorithmus und das darauf aufbauende Empfehlungssystem hinsichtlich der Entstehung von Filterblasen.

Die zweite Forschungsfrage dieser Arbeit lautete wie folgt:

FF2: Inwiefern reagiert der YouTube-Empfehlungsalgorithmus auf Interaktionen mit politischen Videos?

Die beiden Simulationsaccounts rezipierten über einen Zeitraum von 24 Tagen jeweils 72 YouTube-Videos. Beide bewerteten zu ungefähr gleich häufigen Anteilen diese Videos positiv bzw. negativ (siehe Abschnitt 9.1). Anhand dieser Informationen müsste der YouTube-Algorithmus grundsätzlich beiden Accounts zu gleichen Teilen Videos mit politischen Inhalten empfehlen. Scheinbar gibt es aber einen Unterschied aufgrund der Ausprägung der politischen Gesinnung. Der YouTube-Algorithmus empfiehlt der rechts-konservativ gesinnten fiktiven Person während dem Experiment weitaus häufiger Videos mit politischem Hintergrund als der links-liberalen fiktiven Person. Betrachtet man nur diesen Zustand, kann die zweite Hypothese dieser Arbeit folgendermaßen formuliert werden:

*H2: Der YouTube-Empfehlungsalgorithmus reagiert stärker auf die Interaktionen rechts-konservativ gesinnter Nutzer*innen, als links-liberal gesinnter Nutzer*innen.*

Wie bereits in Kapitel Zwei zur Darlegung des Forschungsstands erwähnt wurde, zeigen Brodnig, Hammer und Holnburger (Digitalreport 2018, S.15-21) in ihrer Datenanalyse zu YouTube in Österreich, dass vor allem rechte Parteien, insbesondere die FPÖ, die Themen Nachrichten und Politik auf der Plattform dominieren. Wenn man sich die Abonnements des zweiten Accounts (Account B) ein weiteres Mal ansieht, fällt allerdings auf, dass von keiner Dominanz der FPÖ gesprochen werden kann. Auch der Standort Österreich spielte scheinbar weniger eine Rolle, denn neun von 13 Kanal-Abonnements sind deutsche Kanäle; darunter auch ein AfD-Politiker – Gottfried Curio. Gerald Grosz, dem der Simulationsaccount ebenfalls folgt, kann dem BZÖ (Bündnis Zukunft Österreich), einer rechtspopulistischen, österreichischen Partei, zugeordnet werden. Damit stellt sich auch die Frage, ob für die Zielgruppe, der rechts-konservativ Gesinnten, grundsätzlich mehr Inhalte, als für ein links-liberales Publikum, zur Verfügung

stehen, die vom YouTube-Empfehlungsalgorithmus dementsprechend weiterempfohlen werden.

Im folgenden Kapitel sollen nun die grundlegenden Erkenntnisse dieser Arbeit diskutiert werden. Einen Teil davon bilden auch die Limitationen dieser Arbeit sowie ein Ausblick auf die zukünftige Forschung in diesem Bereich.

10 Diskussion

Die vorliegende Arbeit befasste sich mit den Auswirkungen Algorithmen-basierter Empfehlungssysteme in der Plattformökonomie auf die Entstehung von Filterblasen am Beispiel von YouTube. Im theoretischen Teil dieser Arbeit wurden erst Problem- und Fragestellung, Erkenntnisinteresse und Zielsetzung erläutert.

Die Darlegung des Forschungsstandes (Kapitel Zwei) präsentiert die aktuellsten Forschungsarbeiten, die sich primär mit dem Video-Streaming-Dienst YouTube und den ökonomischen Aspekten dieser Plattform auseinandersetzen. Aus diesem Kapitel ging hervor, dass Studien insbesondere zur Entstehung von Filterblasen durch die Nutzung von YouTube noch Nachholbedarf haben. Kapitel Drei setzte sich mit, für diese Arbeit, relevanten Mediennutzungstheorien auseinander, darunter der Uses-and-Gratifications-Ansatz (Abschnitt 3.1), sowie selektions- (Abschnitt 3.2) und rezeptionsorientierte (Abschnitt 3.3), als auch kontextbezogene Ansätze (Abschnitt 3.4). Kapitel Vier diente der Erläuterung der Grundlagen zur Plattformökonomie (Abschnitt 4.1) und erklärte weshalb der Video-Streaming-Dienst YouTube dieser zugeordnet werden kann (Abschnitt 4.2). Eingang in dieses Kapitel fand auch die Relevanz von YouTube in Österreich (Abschnitt 4.3). In Kapitel Fünf wurde erst Künstliche Intelligenz (KI) als Überbegriff (Abschnitt 5.1) erläutert, dem maschinelles Lernen (ML) untergeordnet werden kann. Welche Rolle Algorithmen (Abschnitt 5.2) dazu spielen, wurde ebenfalls in diesem Kapitel betrachtet. Den Abschluss des theoretischen Teils dieser Masterarbeit bildete das sechste Kapitel. Hier wurden Algorithmen-basierte Empfehlungssysteme (Abschnitt 6.1), sowie der Filterblaseneffekt (Abschnitt 6.2) näher betrachtet. Die Erkenntnisse

aus den Inhalten wurden innerhalb der Conclusio (Kapitel 7) zusammengefasst. Daraus wurden außerdem die Forschungsfragen (Abschnitt 7.2) aufgestellt und ein Ausblick auf den empirischen Teil dieser Arbeit (Abschnitt 7.3) geworfen. Mit dem achten Kapitel wurde dieser eingeleitet: Abschnitt 8.1 diente der Erläuterung der Erhebungsmethode, einem qualitativen Experiment, und Abschnitt 8.2 der Erläuterung der Auswertungsmethode. Im letzten Abschnitt des Kapitels (Abschnitt 8.3) wurde die gewählte Methode operationalisiert und die Vorgehensweise konkretisiert. Die Ergebnisse wurden innerhalb des neunten Kapitels dieser Arbeit festgehalten und interpretiert (Abschnitt 9.1). Dies diente abschließend der Generierung der Hypothesen (Abschnitt 9.2) für zukünftige Forschungszwecke.

Die Leitfrage diese Masterarbeit lautete folgendermaßen:

„Wie wirken sich Algorithmen-basierte Empfehlungssysteme in der Plattformökonomie auf die Entstehung von Filterblasen am Beispiel von YouTube aus?“

Die folgenden Absätze dienen nun dem Versuch einer Beantwortung dieser Fragestellung. Zu Beginn soll allerdings ein letztes Mal erwähnt werden, dass das Ziel dieser Arbeit die Generierung von Hypothesen darstellte, die in Zukunft für weitere Forschungszwecke herangezogen werden können.

Aus dem gesammelten Wissen und den Erkenntnissen innerhalb des Theoriebereichs dieser Arbeit kann festgehalten werden, dass Algorithmen-basierte Empfehlungssysteme, so wie sie derzeit von Plattformen implementiert und angewendet werden, die Entstehung von Filterblasen unterstützen. Dieser Zustand ist insofern zu Beginn neutral zu betrachten, als dass Filterblasen viele Vorteile und Nachteile miteinander vereinen. Einerseits helfen Empfehlungssysteme die Informationen zu selektieren und die für die jeweilige bzw. den jeweiligen Nutzer*in wichtigsten Informationen an die Oberfläche zu bringen. In diesem Zusammenhang darf das menschliche Verhalten im Hinblick auf den Informationsbezug nicht außer Acht gelassen werden. Die in Kapitel Drei beschriebenen Mediennutzungstheorien geben hier wichtige Einblicke in diese Thematik. Grundsätzlich kann aber

festgehalten werden, dass Menschen zu Homogenität neigen, und dementsprechend sich primär mit Informationen (als auch Menschen, etc.) umgeben, die dieselbe oder zumindest ähnliche Meinungen, Wertesysteme, usw. vertreten. Aus der Theorie geht ebenfalls hervor, dass Empfehlungssysteme diese Selbstauswahlprozesse verstärken, was sich zusätzlich schlecht auf den politischen Diskurs und unsere Gesellschaft im Allgemeinen auswirkt. Ob Plattformen, wie YouTube, nun die alleinige Schuld an diesem Zustand tragen ist fragwürdig. Hinterfragbar bleiben aber auch die Zielsetzungen, die hinter der Funktionsweise von Empfehlungssystemen stecken. Einfache Metriken sollen gesteigert werden, und damit kann innerhalb dieser Arbeit auf die Funktionsweise des gesamten kapitalistischen Systems unserer heutigen Gesellschaft ausgezoomt werden. Den Plattformen kann natürlich einiges vorgeworfen werden, allerdings werden diese auch nicht zum Wohl der Nutzer*innen geschaffen, sondern verfolgen ein Ziel, das wohl jedes privatwirtschaftliche Unternehmen verfolgt: Wachstum. Solange dieses übergeordnete Ziel nicht mit der Adaption entsprechender Algorithmen-basierter Empfehlungssysteme vereinbar ist, werden Plattformen wohl gesetzlich in die Pflicht genommen werden müssen. Es steht zu keiner Debatte, dass Inhalte wie beispielsweise Kinderpornographie oder Rassismus, auf einer Plattform wie YouTube, etwas verloren haben.

Um die Antwort auf die leitende Fragestellung dieser Masterarbeit noch klarer zu formulieren: Filterblasen entstehen durch den Einsatz Algorithmen-basierter Empfehlungssysteme, die Auswirkungen gehen allerdings nicht ohne menschliches Zutun, im Sinne von Verhalten, in eine negative oder positive Richtung. Schließlich müssen alle Parteien zur Verantwortung gezogen werden: Nutzer*innen von YouTube haben die Verantwortung, damit Demokratie stattfinden kann, sich ausreichend zu informieren. Content-Creator*innen haben die Verantwortung, dass ihre Inhalte, sofern sie zur politischen Debatte beitragen, der Wahrheit entsprechen, auch wenn die eigene Meinung mitgeteilt werden soll. Ob das verlangt werden kann, und wie, ist wiederum eine andere Frage. Marken und Unternehmen haben die Verantwortung über die Art und Weise wie ihre Produkte beworben werden. Entwickler*innen und die Plattform selbst haben die Verantwortung, das Erlebnis der Nutzer*innen so zu gestalten, dass es auch zum Wohle der Gesellschaft beiträgt. Allerdings müssen wir uns wohl von dem naiven Gedanken verabschieden,

dass die erwähnten Akteursgruppen ihr Verhalten an ihre jeweilige Verantwortung anpassen. Vielmehr muss dafür Bewusstsein geschaffen werden und entsprechende Anreize geschaffen werden. Wie diese allerdings aussehen könnten und müssten ist wiederum eine andere Sache.

10.1 Limitationen dieser Arbeit

Unter den Limitationen dieser Arbeit lassen sich insbesondere zwei Punkte hervorheben. Erstens kam es durch die Änderung der Darstellung der Inhalte auf YouTube seitens der Plattform zu einem vier Tage verkürztem Erhebungszeitraum bei der Durchführung des Experiments. Allerdings konnten trotzdem wichtige Erkenntnisse gewonnen werden, die der Generierung der Hypothesen in Abschnitt 9.2 dienten. Die zweite Limitation dieser Arbeit ist eine wesentlich erheblichere:

Für die Durchführung des Experiments wurden zwei Simulationsaccounts erstellt. Beiden wurden die gleichen Attribute zugeordnet (weibliches Geschlecht, selbes Geburtsdatum, etc.), nur die politische Gesinnung wurde als variierende, also unabhängige Variable definiert. Die Durchführung des Experiments trägt aufgrund der geringen Anzahl von Simulationsaccounts ($n=2$) nur bedingt zur Erforschung der Auswirkungen Algorithmen-basierter Empfehlungssysteme in der Plattformökonomie auf die Entstehung von Filterblasen am Beispiel von YouTube bei. Es wäre interessant zu sehen, wie sehr beispielsweise die Inhalte je nach Alter, Geschlecht bzw. sonstigen (sozio-)demographischen Unterschieden variieren. Die Untersuchung all dieser Variationen war aufgrund des Umfangs dieser Masterarbeit allerdings nicht möglich und ohne die nötigen Ressourcen auch nicht sinnvoll.

10.2 Ausblick

Abschließend kann davon ausgegangen werden, dass Plattformen viele unserer Lebensbereiche weiterhin umkrepeln werden. Wir leben in einem Zeitalter der Information, in dem Aufmerksamkeit als höchstes Gut gehandelt wird. Algorithmen-basierte Empfehlungssysteme werden weiterhin bestehen bleiben, vielmehr werden die Plattformen der heutigen Zeit auf den Einsatz Künstlicher Intelligenz (KI) in Form

maschinellen Lernens als auch Deep Learning setzen, um die eigenen Ziele noch besser und schneller zu erreichen.

Die vorliegende Masterarbeit lieferte wichtige Einblicke im Hinblick auf die Auswirkungen Algorithmen-basierter Empfehlungssysteme in der Plattformökonomie auf die Entstehung von Filterblasen am Beispiel von YouTube. Diesen sollte auch in Zukunft nachgegangen werden. Konkret liefert diese Arbeit nicht nur Hypothesen (Abschnitt 9.1), sondern wirft vielmehr noch weitere Fragen auf. Beispielsweise stellt sich die Frage, weswegen rechts-konservative und rechts-populistische Parteien in Österreich die Kategorie „Nachrichten und Politik“ scheinbar dominieren. Wissen diese Parteien die neuen Medien einfach besser zu nutzen als andere? Wo sind die Inhalte der Parteien, die das restliche politische Spektrum besetzen? Warum sind vertrauenswürdige Medien in Österreich so schwach auf YouTube vertreten? Mit all diesen Fragestellungen müssten sich zukünftige Forschungsarbeiten in diesem Gebiet auseinandersetzen.

Quellenverzeichnis

Alexa Ranking, 2019. The top 500 sites on the web. Unter:
<https://www.alexa.com/topsites> (Zugriff am: 5.1.2019)

Arthur, W.B., 1989. Competing Technologies, Increasing Returns, and Lock-in by Historical Events. In: The Economic Journal, Vol. 89, S. 116-131.

Awad, M., Khanna, R., 2015. Efficient Learning Machines. Theories, Concepts, and Applications for Engineers and System Designers. Appress Media.

Baldwin, C.Y., Clark, K.B., 2000. Design Rules, Vol. 1: The Power of Modularity, Cambridge, MA: MIT Press.

Baldwin, C.Y., Woodard, C.J., 2009. The Architecture of Platforms: A Unified View. In: Gawer, A. (Hrsg.), Platforms, Markets and Innovation. Edward Elgar, Cheltenham. S. 19-44.

Batarseh, F. A., 2018. Artificial Intelligence. In: Schintler, L. A., McNeely, C.L. (Hrsg.), 2018. Encyclopedia of Big Data. Springer International Publishing AG.

Benlian, A., Hilkert, D., Hess, T., 2015. How Open is This Platform? The Meaning and Measurement of Platform Openness from the Complementors' Perspective. In: Journal of Information Technology, Vol. 30, Nr. 3, S. 209-228.

Benton, J., 2019. As Notre Dame burned, an algorithmic error at YouTube put information about 9/11 under news videos. Unter:
<https://www.niemanlab.org/2019/04/as-notre-dame-burned-an-algorithmic-error-at-youtube-put-information-about-9-11-under-news-videos/> (Zugriff am 23.08.2019)

Berger, P., Luckmann, T., 2010. Die gesellschaftliche Konstruktion der Wirklichkeit. Eine Theorie der Wissenssoziologie, 23. Aufl., Fischer Verlag, Frankfurt am Main. S. 43.

Boudreau, K.J., 2012. Let a Thousand Flowers Bloom? An Early Look at Large Numbers of Software App Developers and Patterns of Innovation. In: Organization Science, Vol. 23, Nr. 5, S. 1.409-1.427.

Boudreau, K.J., Hagiu, A., 2009. Platform Rules: Multi-sided Platforms as Regulators. In: Gawer, A. (Hrsg.); Platforms, Markets and Innovation. Edward Elgar Publishing Limited, Cheltenham, UK. S. 163-191.

Brosius, H.-B., 1995. Alltagsrationalität in der Nachrichtenrezeption. Ein Modell zur Wahrnehmung und Verarbeitung von Nachrichteninhalten. Westdeutscher Verlag, Opladen.

Carpenter, G. A., Grossberg, S., 1991. Pattern Recognition by Self-Organizing Neural Networks. In: Massachusetts Institute of Technology Press. Massachusetts, Cambridge.

Cha, M., Kwak, H., Rodriguez, P., Ahn, Y., Moon, S., 2009. Analyzing the video popularity characteristics of large-scale user generated content systems. In: IEEE/ACM Trans Networking (TON), Vol. 17, Nr. 5, S. 1357-1370.

Chaiken, S., 1980. Heuristic versus systematic information processing and the use of source versus message cues in persuasion. In: Journal of Personality and Social Psychology, Vol. 39, S. 752-766.

Chatzopoulou, G., Sheng, C., Faloutsos, M., 2010. A First Step Towards Understanding Popularity in YouTube. In: INFOCOM IEEE Conference on Computer Communications Workshops, 2010, S. 1-6.

Chen, L., Zhou, Y., Chiu, D. M., 2014. A lifetime model of online video popularity. In: 2014 IEEE 23rd International Conference on Computer Communication and Networks (ICCCN), S. 1-8.

Cheng, X., Dale, C., Liu, J., 2008. Statistics and social network of Youtube videos. In: International Workshop on Quality of Service (IWQoS'08). IEEE, S. 229-238.

Cheng, X., Liu, J., 2009. NetTube: Exploring Social Networks for Peer-to-Peer Short Video Sharing. In: IEEE INFOCOM 2009, S. 1152-1160.

Crane, R., Sornette, D., 2008. Robust dynamic classes revealed by measuring the response function of a social system. In: Proceedings of the National Academy of Sciences (PNAS) of the United States of America, Vol. 105, Nr. 41, S. 15649-15653. Unter: <https://www.pnas.org/content/105/41/15649> (Zugriff am 17.4.2019)

Davidson, J., Liebald, B., Liu, J., Nandy, P., Van Vleet, T., 2010. The YouTube video recommendation system. In: Proceedings of the fourth ACM conference on Recommender systems, S. 293-296.

DellaPosta, D., Shi, Y., Macy, M., 2015. Why do Liberals drink Latte? In: American Journal of Sociology, Vol. 120, Nr. 5, S. 1473-1511. University of Chicago.

Deshmukh, A. R., Chouragade, P. M., 2016. Click prediction for web image reranking using multimodal sparse coding. In: International Journal of Scientific & Engineering Research, Vol. 7, Nr. 2, S. 95-97

Dew, N., Read, S., 2007. The More We Get Together: Coordinating Network Externality Product Introduction in the RFID Industry. In: Technovation, Vol. 27, Nr. 10, S. 569-581.

Dischler, J., Think with Google, 2018. Maschinelles Lernen für jeden Werbetreibenden. Unter: <https://www.thinkwithgoogle.com/intl/de-de/insights/blog/maschinelles-lernen-fuer-jeden-werbetreibenden/> (Zugriff am 21.08.2019)

Eaton, B.D., Elaluf-Calderwood, S., Sørensen, C., Yoo, Y., 2015. Distributed Tuning of Boundary Resources: The Case of Apple's iOS Service System. In: MIS

Quarterly: Special Issue on Service Innovation in a Digital Age, Vol. 39, Nr. 1, S. 217-243.

Eisenman, T., Parker, G., van Aystyne, M.W., 2006. Strategies for Two-Sided Markets. In: Harvard Business Review, Vol. 84, Nr. 10, S. 92-101.

Evans, D.S., 2003. Some Empirical Aspects of Multi-Sided Platform Industries. In: Review of Network Economics, Vol. 2, Nr. 3, S. 191-209.

Figueiredo, F., 2013. On the prediction of popularity of trends and hits for user generated videos. In: Proceedings of the sixth ACM international conference on Web search and data mining, S. 741-746.

Figueiredo, F., Almeida, J. M., Goncalves, M. A., Benevenuto, F., 2014. On the dynamics of social media popularity: A YouTube case study. In: ACM Transactions on Internet Technology, Vol. 1, Nr. 1, S. 1-22.

Figueiredo, F., Benevenuto, F., Almeida, J. M., 2011. The tube over time: characterizing popularity growth of youtube videos. In: Proceedings of the fourth ACM international conference on Web search and data mining, S. 745-754.

Fleder, D., Hosanagar, K., 2007. Recommender Systems and their Impact on Sales Diversity. In: Proceedings of the 8th ACM conference on Electronic commerce, S. 199.

Fleder, D., Hosanagar, K., 2009. Blockbuster Culture's next Rise or Fall: The Impact of Recommender Systems on Sales Diversity. In: Management Science, Vol. 55, Nr. 5, S. 697-712.

Gadringer, S., Holzinger, R., Sparviero, S., Trappel, J., Nening, I., Digital News Report Network Austria (Hrsg.), 2018. Digital News Report 2018 – Detailergebnisse für Österreich, unter:
<http://www.digitalnewsreport.at/reports/2018-2/> (Zugriff am: 5.1.2019)

Gawer, A., 2014. Bridging Differing Perspectives on Technological Platforms: Toward an Integrative Framework. In: Research Policy, Vol. 43, Nr. 7, S. 1.239-1.249.

Ghazawneh, A., Henfridsson, O., 2013. Balancing Platform Control and External Contribution in Third-Party Development: The Boundary Resources Model. In: Information Systems Journal, Vol. 23, Nr. 2, S. 173-192.

Ghazawneh, A., Henfridsson, O., 2015. A Paradigmatic Analysis of Digital Application Marketplaces. In: Journal of Information Technology, Vol. 30, Nr. 3, S. 198-208.

Goebel, R., Tanaka, Y., Wolfgang, W., 2016. Lecture notes in artificial intelligence series. In: Proceedings of the ninth conference on artificial general intelligence, New York.

Hanseth, O., Lyytinen, K., 2010. Design Theory for Dynamic Complexity in Information Infrastructures: The Case of Building Internet. In: Journal of Information Technology, Vol. 25, Nr. 1, S. 1-19.

Hanson, G., Haridakis, P., 2008. YouTube Users Watching and Sharing the News: A Uses and Gratifications Approach. In: Journals of Electronic Publishing, Vol. 11, Nr. 3.

Henderson, R.M., Clark, K.B., 1990. Architectural Innovation: The Reconfiguration of Existing Product Technologies and the Failure of Established Firms. In: Administrative Science Quarterly, Vol. 35, S. 9-30.

Henfridsson, O., Bygstad, B., 2013. The Generative Mechanisms of Digital Infrastructure Evolution. In: MIS Quarterly, Vol. 37, Nr. 3, S. 907-931.

- Iansiti, M., Levien, R., 2004a. The Keystone Advantage: What the New Dynamics of Business Ecosystems Mean for Strategy, Innovation, and Sustainability. In: Harvard Business Press, Brighton.
- Jang, J.-S. R., 1993. "ANFIS: Adaptive-Network-Based Fuzzy Inference System." IEEE Transactions on Systems. In: Man and Cybernetics, Vol. 23, Nr. 3, S. 665-685.
- Jiang, L., Miao, Y., Yang, Y., Lan, Z., Hauptmann, A. G., 2014. Viral video style: a closer look at viral videos on YouTube. In: Proceedings of International Conference on Multimedia Retrieval.
- Katz, E., Blumler, J. G., Gurevitch, M., 1973. Uses and Gratifications Research. In: Public Opinion Quarterly, Vol. 37, Nr. 4, S. 509-523.
- Katz, M.L., Shapiro, C., 1985. Network Externalities, Companition and Compatibility. In: American Economic Review, Vol. 75, S. 424-440.
- Katzenbach, C., 2018. Die Ordnung der Algorithmen - zur Automatisierung von Relevanz und Regulierung gesellschaftlicher Kommunikation. In: Mohabbat Kar, R., Thapa, B. E. P., Parycek, P., 2018. (Un)berechenbar? Algorithmen und Automatisierung in Staat und Gesellschaft. Fraunhofer-Institut für Offene Kommunikationssysteme FOKUS, Kompetenzzentrum Öffentliche IT (ÖFIT). S. 1-15.
- Kleining, G., 1986. Das qualitative Experiment. In: Kölner Zeitschrift für Soziologie und Sozialpsychologie, Vol. 38, Nr. 4, S. 724-750.
- Koch, T., Peter, C., Müller, P., 2019. Das Experiment in der Kommunikations- und Medienwissenschaft - Grundlagen, Durchführung und Auswertung experimenteller Forschung. Springer Fachmedien, Wiesbaden.

Kubbe, I., 2017. In: Jäckle, S. (Hrsg.), Neue Trends in den Sozialwissenschaften. Springer Fachmedien, Wiesbaden. S. 85-114.

Landrum, A., 2019. YouTube as the primary propagator of Flat Earth. Unter: http://www.asheleylandrum.com/uploads/4/7/8/3/47833717/landrum_2019_02.18_aaas_online.pdf (Zugriff am 17.4.2019)

Lang, A., 1995. Defining Audio/Video Redundancy From a Limited-Capacity Information Processing Perspective. In: Communication Research, Vol. 22, S. 86-115.

Lang, A., 2000. The Limited Capacity Model of Mediated Message Processing. In: Journal of Communication, Vol. 50, S. 46-70.

Leem, B., Chun, H., 2014. An impact of online recommendation network on demand. Expert Systems with Applications, Vol. 41, Nr. 4, S. 1723-1729.

Lerman, K., Galstyan, A., 2008. Analysis of social voting patterns on Digg. In: Proceedings of the first workshop on Online social networks, S. 7-12.

Lerman, K., Hogg, T., 2010. Using a model of social dynamics to predict popularity of news. In: Proceedings of the 19th international conference on World wide web, S. 621-630.

Luger, G., 2005. Artificial intelligence, structures and strategies for complex problem solving (5th ed.). Addison Wesley.

Mahnke, M., 2015. Der Algorithmus, bei dem man mit muss? Ein Perspektivwechsel. In: Communicatio Socialis, Vol. 48, 1. S. 34-45.

Marks, J., Copland, E., Loh, E., Sunstein, C. R., Sharot, T., 2019. Epistemic spillovers: Learning others' political views reduces the ability to assess and use their expertise in nonpolitical domains. In: Cognition, Vol. 188, S. 74-84.

- Mikos, L., 2018. Methoden der Film- und Fernsehanalyse. In: Moritz, C., Corsten, M. (Hrsg.). Handbuch Qualitative Videoanalyse. S. 89-100.
- Milgram, S., 1967. The Small World Problem. *Psychology Today*, Vol. 2, Nr. 1, S. 60-67.
- Nie, B., Zhang, H., Liu, Y., 2014. Social interaction based video recommendation: Recommending YouTube videos to Facebook users. In: 2014 IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS), S. 97-102.
- o. A., SevenOne Media, 2018. Media Activity Guide 2018. Unter:
<https://www.sevenonemedia.de/documents/924471/1111769/Media+Activity+Guide+2018/0d7f33af-210a-682c-6c21-9aad7ae863f8> (Zugriff am 20.08.2019)
- o. A., YouTube, 2019. YouTube Creators. Unter:
<https://www.youtube.com/intl/de/creators/> (Zugriff am 20.08.2019)
- o. A., YouTube, 2019. YouTube Presseinhalte. Unter:
<https://www.youtube.com/intl/de/yt/about/press/> (Zugriff am 20.08.2019)
- o. A., YouTube, 2019. YouTube Space. Unter:
<https://www.youtube.com/intl/de/space/> (Zugriff am 20.08.2019)
- o. A., YouTube, 2019. YouTube Werbung. Unter:
<https://www.youtube.com/intl/de/ads/> (Zugriff am 20.08.2019)
- o. A., HubSpot, 2017. The Future of Content Marketing. Unter:
https://cdn2.hubspot.net/hubfs/53/Hubspot_Future-of-Content-Marketing-2017.pdf?t=1525275495041 (Zugriff am 11.1.2019)

o.S., YouTube, 2019. Bestätigungskennzeichen auf Kanälen. Unter:
<https://support.google.com/youtube/answer/3046484?hl=de> (Zugriff am
17.08.2019)

Ondrus, J., Gannamaneni, A., Lyytinen, K., 2015. The Impact of Openness on the Market Potential of Multi-sided Platforms: A Case Study of Mobile Payment Platforms. In: Journal of Information Technology, Vol. 30, Nr. 3, S. 260-275.

Paul, A., Chen, B.-W., Bharanitharan, K., Wang, J.-F., 2013. Video search and indexing with reinforcement agent for interactive multimedia services. In: ACM Transactions on Embedded Computing Systems (TECS), Vol. 12, Nr. 2, S. 25.

Paul, A., Jiang, Y.-C., Wang, J.-F., Yang, J.-F., 2012. Parallel reconfigurable computing-based mapping algorithm for motion estimation in advanced video coding. In: ACM Transactions on Embedded Computing Systems (TECS), Vol. 11, Nr. S2, S. 40.

Peltzer, A., Keppler, A., 2015. Die soziologische Film- und Fernsehanalyse. De Gruyter Oldenbourg, Berlin. S. 5ff.

Petty, R.E., Cacioppo, J.T., 1986. Communication and Persuasion. Central and Peripheral Routes to Attitude Change. Springer Verlag, New York.

Pinto, H., Almeida, J. M., Goncalves, M. A., 2013. Using early view patterns to predict the popularity of YouTube videos. In: Proceedings of the sixth ACM international conference on Web search and data mining, S. 365-374.

Ratkiewicz, J., Fortunato, S., Flammini, A., Menczer, F., Vespignani, A., 2010. Characterizing and modeling the dynamics of online popularity. In: Physical Review Letters of the American Physical Society, Vol. 105, Nr. 15, S. 158701-1 - 158701-4.

- Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., Riedl, J., 1994. GroupLens: An open architecture for collaborative filtering of netnews. In: Proceedings of ACM 1994, Conference on Computer Supported Cooperative Work. S. 175-186.
- Rochet, J.-C., Tirole, J., 2003. Platform Competition in Two-Sided Markets. In: Journal of the European Economic Association, Vol. 1, Nr. 4, 990-1029.
- Sanchez, R.A., Mahoney, J.T., 1996. Modularity, Flexibility and Knowledge Management in Product and Organization Design. In: Strategic Management Journal, Vol. 17, S. 63-76.
- Sarwat, M., Mokbel, M. F., 2017. Recommender Systems. In: Liu, L., Özsü, M. T. (eds.), Encyclopedia of Database Systems. Springer, New York. S. 1-5.
- Schafer, J. B., Frankowski, D., Herlocker, J., Sen, S., 2007. Collaborative filtering recommender systems. In Brusilovsky, P., Kobsa, A., Nejdl, W. (Eds.), 2007. The Adaptive Web: Methods and Strategies of Web Personalization, Vol. 4.321 of Lecture Notes in Computer Science. Springer, Berlin. Kapitel 9, S. 291-324.
- Schmidt, J.-H., 2018. Social Media, 2. Auflage. Springer Fachmedien, Wiesbaden.
- Schweiger, W., 2007. Theorien der Mediennutzung - Eine Einführung. VS Verlag für Sozialwissenschaften, Wiesbaden.
- Sears, D. O., Freedman, J. L., 1967. Selective Exposure to Information: A Critical Review. In: Public Opinion Quarterly, Vol. 31, Nr. 2, S. 194-213.
- Shapiro, C., Varian, H.R., 1998. Information Rules: A Strategic Guide to the Network Economy, Boston: Harvard Business School Press.
- Stokel-Walker, C., 2019. Algorithms Won't Fix What's Wrong With YouTube. Unter: <https://www.nytimes.com/2019/06/14/opinion/youtube-algorithm.html> (Zugriff am: 04.08.2019)

Stroud, N. J., 2011. *Niche News: The Politics of News Choice*. Oxford University Press, Oxford.

Sunstein, C. R., 2007. *Republic.com 2.0*. Princeton: Princeton University Press.

Szabo, G., Huberman, B., 2010. Predicting the popularity of online content. In: *Communications of the ACM*, Vol. 53, Nr. 8, S. 80-88.

Tanriverdi, H., 2017. Youtube schottet rechte Nutzer von anderen Meinungen ab. Unter: <https://www.sueddeutsche.de/digital/afd-fans-unter-sich-youtube-schottet-rechte-nutzer-von-anderen-meinungen-ab-1.3702786> (Zugriff am 23.08.2019)

Thies, B., 2017. Mythos Filterblase. In: Kappes, C., Krone, J., Novy, L. (Hrsg.), 2017. *Medienwandel kompakt 2014 - 2016. Netzveröffentlichungen zu Medienökonomie, Medienpolitik & Journalismus*. Springer Fachmedien, Wiesbaden. S. 101-104.

Thurich, E., 2011. *Pocket Politik. Demokratie in Deutschland*, 4. Auflage. Bundeszentrale für politische Bildung, Bonn, S. 103.

Tilson, D., Sørensen, C., Lyytinen, K., 2012. Change and Control Paradoxes in Mobile Infrastructure Innovation: The Android and iOS Mobile Operating Systems Cases. In: *45th Hawaii International Conference on System Science (HICSS 45)*, Maui, HI.

Tiwana, A., Konsynski, B., 2010. Complementarities Between Organizational IT Architecture and Governance Structure. In: *Information Systems Research*, Vol. 21, Nr. 2, S. 288-304.

Tiwana, A., Konsynski, B., 2010. Complementarities Between Organizational IT Architecture and Governance Structure. In: *Information Systems Research*, Vol. 21, Nr. 2, S. 288-304.

- Tiwana, A., Konsynsky, B., Bush, A.A., 2010. Platform Evolution: Coevolution of Platform Architecture, Governance, and Environmental Dynamics. In: Information Systems Research, Vol. 21, Nr. 4, S. 675-687.
- Turing, A. M., 1950. Computing machinery and intelligence. In: Journal of the Mind, Vol. 59, S. 433-460.
- Udolf, R., 1973. Liberal and Conservative Political Stereotypes in Terms of Belief Response Hierarchies. In: Psychological Reports, Vol. 32, S. 275-284. Hofstra University, Hempstead, New York.
- Valentino, N. A., Banks, A. J., Hutchings, V. L., Davis, A. K., 2009. Selective Exposure in the Internet Age: The Interaction between Anxiety and Information Utility. In: Political Psychology, Vol. 30, Nr. 4, S. 591-613.
- Vapnik, V. N., 1998. Statistical Learning Theory. Wiley, New York.
- von Engelhardt, S., Wangler, L., Wischmann, S., Begleitforschung AUTONOMIK für Industrie 4.0 (Hrsg.), 2017. Eigenschaften und Erfolgsfaktoren digitaler Plattformen. Unter: https://www.digitale-technologien.de/DT/Redaktion/DE/Downloads/Publikation/autonomik-studie-digitale-plattformen.pdf?__blob=publicationFile&v=9 (Zugriff am: 5.1.2019)
- Wakabayashi, D., New York Times, 2019. YouTube Is a Big Business. Just How Big Is Anyone's Guess. Unter:
<https://www.nytimes.com/2019/07/24/technology/youtube-financial-disclosure-google.html> (Zugriff am 20.08.2019)
- Webster, J. G., 2010. User Information Regimes: How Social Media Shape Patterns of Consumption. In: Northwestern University Law Review, Vol. 104, Nr. 2, S. 593-612.

- Wojcieszak, M., 2010. 'Don't Talk to Me': Effects of Ideologically Homogeneous Online Groups and Politically Dissimilar Offline Ties on Extremism. In: New Media and Society, Vol. 12, Nr. 4, S. 637-655.
- Wojcieszak, M., 2011. Deliberation and attitude polarization. In: Journal of Communication, Vol. 61, S. 596-617.
- Wu, X., Kumar, V., Quinlan, R., Ghosh, J., Yang, Q., Motoda, H., McLachlan, G. J., Ng, A., Liu, B., Yu, P. S., Zhou, Z.-H., Steinbach, M., Hand, D. J., Steinberg, D., 2008. Top 10 Algorithms in Data Mining. In: Knowledge and Information Systems, Vol. 14, S. 1-37.
- Yeung, K., 2017. 'Hypernudge': Big Data as a Mode of Regulation by Design. In: Information Communication and Society, Vol. 20, Nr. 1, S. 118-136.
- Yu, J., Rui, Y., Tang, Y., Tao, D., 2014. High-order distance based multiview stochastic learning in image classification. In: IEEE Transactions on Cybernetics, Vol. 44, Nr. 12, S. 2431-2442.
- Yu, P. S., 1999. Data mining and personalization technologies. In: Proceedings of the Sixth International Conference on Database Systems for Advanced Applications (DASFAA'99), Washington, DC, USA, IEEE Computer Society, S. 6-13.
- Zhou, R., Khemmarat, S., Gao, L., Wan, J., Zhang, J. 2016. How YouTube videos are discovered and ist impact on video views. In: Multimed Tools Appl, Vol. 75, S. 6035-6058.
- Zweig, K. A., Krafft, T. D. (Hrsg.), Deussen, O., 2017. Algorithmen und Meinungsbildung – Eine grundlegende Einführung. Springer-Verlag, Berlin, Heidelberg.

Anhang

Exposé

Familienname	Hollitsch	
Vorname	Julia	
Matrikelnummer	1710404820	
Mailadresse	mm171820@fhstp.ac.at / hollitsch.julia@gmail.com	
Telefonnummer	+43 (0)681 81518439	
Datum	11.01.2019	
Name BetreuerIn	FH-Prof. Priv.-Doz. Dr. Michael Litschka (Studiengangsleiter Digital Media Management, Department Medien und Wirtschaft)	Bestätigung der Betreuung durch Unterschrift des Betreuers
Thema	Digital Media, Medien- und Internetökonomie	
Arbeitstitel	Die Auswirkungen des Algorithmen-basierten Filterblaseneffekts in der Plattformökonomie am Beispiel von YouTube	
Problemstellung/ Forschungsfrage	<p>Seit über zehn Jahren verlagert sich unsere gesellschaftliche Kommunikation zunehmend in virtuelle Räume bzw. sind diverse digitale Medien-Angebote mittlerweile zum integralen Bestandteil unseres Alltags geworden. Plattformunternehmen wie Google, YouTube und Facebook führen seit mehreren Jahren internationale Website-Rankings an (Vgl. Alexa Ranking, 2019). Auch in Österreich stellt YouTube eines der relevantesten Social Media-Angebote dar. Nur der Messenger-Dienst WhatsApp liegt in der Gesamtbetrachtung noch vor der Plattform, wobei Facebook im Vergleich zum Vorjahr von YouTube mittlerweile</p>	

	<p>überholt wurde. In der Gruppe der 18- bis 24-Jährigen liegt der Video-Streaming-Dienst, mit einer Gesamtnutzung von knapp 82 Prozent, sogar vor allen anderen sozialen Medien. Generell steigt die Nutzung von sozialen Medien von Jahr zu Jahr und mit dem Smartphone als Hauptgerät der Nachrichtennutzung, bilden Plattformen wie Facebook, WhatsApp und YouTube die ersten Anlaufstellen, um Nachrichten mobil zu konsumieren. Beinahe ein Viertel der YouTube-Nutzer*innen (22,9 Prozent) rezipieren Nachrichten über den Dienst. (Vgl. Digital News Report, 2018) Eine aktuelle Studie von HubSpot (2017) verdeutlicht zudem, dass Video-Inhalte in Zukunft vermehrt, insbesondere von einer jüngeren Zielgruppe, nachgefragt werden, und zudem mit einer höheren Aufmerksamkeit konsumiert werden. Somit kann von einem kontinuierlichen Nutzungszuwachses des Video-Streaming-Dienstes YouTube in den kommenden Jahren ausgegangen werden.</p> <p>Digitale Plattformen und Plattformmärkte zeichnen sich insbesondere durch eine hohe Skalierbarkeit und Reichweite, der Möglichkeit zur Auswertung einer großen Datenmenge, niedrige Transaktionskosten, starke Netzwerkeffekte, sowie einer hohen Dynamik aus (Vgl. Engelhardt, Wangler und Wischmann, 2017, S. 11-15). Auch der Video-Streaming-Dienst YouTube, als Teil des Alphabet-Konzerns, kann der Plattformökonomie zugeordnet werden. Plattformen, wie YouTube, treten in erster Linie als wirtschaftlich ausgerichteter und digitaler Intermediär auf, der die oben genannten Merkmale aufweist.</p> <p>Allerdings verbindet Plattformunternehmen noch ein weiterer wichtiger Aspekt: Die Instrumentalisierung von Algorithmen. Die Autor*innen Zweig, Krafft und Deussen (2017) verstehen unter einem Algorithmus, „eine definierte Handlungsvorschrift, die für jede mögliche Eingabe von Informationen eine Ausgabe generiert, die bestimmte Eigenschaften hat“. Um diese Definition verständlicher zu abstrahieren, ziehen sie das Beispiel einer Routennavigation heran: Als Eingabe dient der Startpunkt und der Zielort, sowie Straßenkarten und aktuelle</p>
--	---

	<p>Verkehrsinformationen. Eine mögliche Fahrstrecke mit der kürzesten zu erwartender Dauer, die unter Einbeziehung der vorhandenen Eingabe-Daten berechnet wurde, bildet am Ende die Ausgabe. Mahnke (2015) kommt in seiner Beschreibung eines Algorithmus ebenfalls zu dem Punkt, dass dieser eine Reihe von schrittweisen Befehlen, die durchgeführt werden sollen, um aus einer Eingabe eine Ausgabe zu erzeugen und damit ein Problem zu lösen, ist. Heutzutage werden Algorithmen in sämtlichen Gesellschaftsbereichen zu verschiedensten Zwecken, von der Automatisierung, über die Mustererkennung oder der Risikoanalyse, bis hin zur Kontrolle, verwendet. (Vgl. Humborg & Nguyen 2018) Ein aktuelles Beispiel liefert China mit dem Citizen Score, der demnächst eingeführt werden soll (Vgl. Wired 2017).</p> <p>In ihrer Arbeit „Algorithmen und Meinungsbildung“ geht das Autor*innen-Team noch näher auf die Funktionsweise algorithmischer Empfehlungssysteme, wie sie beispielsweise von den Unternehmen Facebook oder Google bzw. auf den dazugehörigen Plattformen genutzt werden, ein: Algorithmische Empfehlungssysteme treffen aus einer großen Informationsmenge (z.B. i.F.v. Dokumenten oder Webseiten) eine grundlegende Auswahl, sortieren diese anhand geeigneter Kriterien und zeigen aufgrund dessen möglichst relevante Informationen zuerst an. Als Beispiel dient den Autor*innen die Funktionsweise des Google PageRanks. Allerdings kam es in den vergangenen Jahren, gerade durch die Offenlegung über die Wirkungsweise solcher algorithmischer Empfehlungssysteme auch zu gezielten Manipulationen, um beispielsweise in den Google Suchergebnissen ein höheres Ranking zu erzielen. Mittlerweile werden, neben der Berechnung des Page Ranks, auch Informationen verarbeitet, die darauf hinweisen, welche Inhalte für Nutzer*innen besonders interessant sind. Algorithmen des sogenannten maschinellen Lernens, beobachten also menschliche Nutzer*innen und tracken ihr gesamtes maschinell verfolgbares Informations(-such)verhalten. Dabei strukturieren selbstlernende Algorithmen aus einer Vielzahl an Informationen</p>
--	---

	<p>selbstständig Entscheidungen, meist in Form von Entscheidungsbäumen, um verschiedene Inhalte in Gruppen bzw. Kategorien zu bündeln. Diese Methode wird auch Clustering genannt. Eine solche Arbeitsweise dient vor allem der Personalisierung, beispielsweise von Suchergebnissen, und zielt darauf ab, möglichst relevante Inhalte und Informationen individuell für die Nutzer*innen zusammenzustellen. Aufgrund der immer höher werdenden Komplexität durch eine zunehmende Anzahl der Dimensionen, wodurch immer detailliertere Entscheidungen getroffen werden können, scheitern Algorithmen maschinellen Lernens in den meisten Fällen, die perfekte Entscheidungsstruktur für jede einzelne Nutzerin bzw. jeden einzelnen Nutzer zu bilden. Diese Algorithmen versuchen also eine Balance zwischen Genauigkeit und Trefferquote herzustellen. Diese Art von Technologie wurde, laut den Autor*innen, schon vielfach implementiert und beruht oftmals auf relativ einfachen statistischen Methoden. Sie gehen außerdem davon aus, dass der Einsatz solcher Algorithmen nicht (mehr) fehlerhaft ist und diese für sich genommen auch objektiv sind. (Vgl. Zweig, et al 2017) Wie genau die Algorithmen der unterschiedlichen Plattformunternehmen, insbesondere der zu untersuchenden Plattform YouTube, funktionieren bleibt allerdings unklar. Sie bilden einen wichtigen Erfolgsfaktor als auch eine Abgrenzungsmöglichkeit zur Konkurrenz, und werden von den Unternehmen somit immer als Betriebsgeheimnis gehandelt.</p> <p>Die alleinige Existenz von Algorithmen und ihr Einsatz um Informationen zu selektieren stellen noch kein Problem oder einen Grund zur Besorgnis dar. Auch Journalismus dient der Vorselektion von Inhalten um das Weltgeschehen für die Rezipient*innenschaft besser einordbar zu machen, und dieser zu ermöglichen sich eine eigene Meinung zu bilden. Allerdings neigen alle Menschen – dies allerdings in individuell unterschiedlicher Ausprägung - zur Homogenität, mithin Zugehörigkeit zu einer Gruppe, also z.B. zu sozialen Freundeskreisen, die ähnliche Meinungen vertreten, bzw. zu</p>
--	---

	Menschen, die uns ähnlich sind, gemeint ist. In Kombination mit Empfehlungssystemen, die bestimmte Inhalte individuell als relevant einstufen, führt dieser Zustand allerdings zu einem Informations(-such)verhalten, das in sogenannten Filterblasen stattfindet. (Vgl. Zweig, et al 2017; Katzenbach 2018; Schmidt 2018) Ein Phänomen, das von Eli Pariser im Jahr 2011 zum ersten Mal beschrieben wurde (Vgl. Schmidt 2018, S. 67; Humborg & Nguyen 2018, S. 25; Schweiger 2017). Ausgangspunkt der Kritik an der Bildung von Filterblasen ist in erster Linie die Sorge, dass die Möglichkeit zur eigenen Meinungsbildung durch starke Algorithmen, wie sie in der Plattformökonomie Anwendung finden, eingeschränkt wird. Nutzer*innen digitaler Medien-Angebote, die der Plattformökonomie zuordenbar sind, werden dementsprechend in ihrer Meinung von Tag zu Tag bestätigt. Schließt man dazu auch jegliche Skepsis bzw. eine kritische Haltung gegenüber der vom System empfohlenen Inhalte aus, bewegen sich Nutzer*innen im Internet bzw. auf diesen Plattformen ab einem gewissen Zeitpunkt nur noch in sogenannten geschlossenen Echokammern von Personen, die einer Meinung sind. Sie bekommen also die eigene Weltsicht stets als Echo reflektiert. (Vgl. Humborg & Nguyen 2018) Die alleinige Nutzung dieser Angebote soll langfristig zu einer einseitigen Verzerrung der Realität, die bei klassischen Medien in dieser Ausprägung nicht stattfindet, führen. (Vgl. Zweig, et al 2017; Schmidt 2018) Zweig, Krafft und Deussen (2017) streichen in ihrer Arbeit „Algorithmen und Meinungsbildung – Eine grundlegende Einführung“ allerdings hervor, dass das Phänomen der Filterblase noch nicht hinreichend untersucht wurde. Algorithmen und insbesondere algorithmische Entscheidungssysteme, die für Nutzer*innen die Vorselektion der Inhalte vornehmen, stellen womöglich in Zukunft einen wichtigen Dreh- und Angelpunkt politischer Meinungsbildung dar. Damit liefern die Autor*innen ein trifftes Argument sich mit den Auswirkungen des Algorithmen-basierten Filterblaseneffekts in der Plattformökonomie näher auseinanderzusetzen. Denn wie stark der Einfluss dieses
--	---

	<p>Phänomens letztendlich auf die Meinungsbildung der Menschen tatsächlich ist, bleibt weiterhin ungeklärt bzw. kann nur erahnt werden. Kritiker behaupten, dass jener Effekt überschätzt wird, da Nutzer*innen aufgrund ihres, oben bereits beschriebenen Bedürfnisses nach Homogenität tendenziell nach Inhalten suchen bzw. solche Inhalte rezipieren, die ihre politischen Einstellungen untermauern. (Vgl. Zweig, et al 2017; Humborg & Nguyen 2018) Digitale Medien werden demnach ebenfalls selektiv genutzt, wobei kongruente Inhalte eher rezipiert werden. Nicht-kongruente Inhalte werden allerdings auch nicht aktiv vermieden. (Vgl. Trilling 2014; Garrett et al. 2013) Bakshy et al. (2015) kommen zu dem Schluss, dass digitale Filterblasen aufgrund von individuellen Entscheidungen der Nutzer*innen entstehen, also weniger durch Algorithmen. Durch die Vernetzung, die durch Plattformen wie Facebook ermöglicht wird, sei die Chance auf andere politische Meinungen zu stoßen für Nutzer*innen sogar größer als in einer analogen Welt. Allerdings muss dazu auch erwähnt werden, dass diese Studie in Kooperation mit Facebook entstanden ist bzw. der Autor Teil des Core Data Science Teams der Plattform ist (Vgl. Bakshy o.D.). Gegenüber Facebook wurden in den letzten Jahren immer wieder kritische Stimmen erhoben, insbesondere durch den Datenskandal um Cambridge Analytica (Vgl. sueddeutsche.de 2018). Das Ergebnis dieser Studie muss dementsprechend kritisch betrachtet werden, da Facebook in jedem Fall Interesse daran hat das eigene Image nach den aktuellsten Ereignissen zu verbessern.</p> <p>Abschließend stellt der Algorithmen-basierte Filterblaseneffekt in der Plattformökonomie ein kontrovers diskutiertes Themengebiet dar und gibt Anlass dazu, sich dieser Thematik anzunehmen. Für diese Masterarbeit wird der Video-Streaming-Dienst YouTube, aus zuvor beschriebenen Gründen, als Gegenstand der Untersuchung herangezogen. Die Leitfrage dieser Arbeit lautet folgendermaßen:</p>
--	---

	<i>Wie wirkt sich der Algorithmen-basierte Filterblaseneffekt in der Plattformökonomie am Beispiel von YouTube aus?</i>
Aufbau und Gliederung	<p>Die Masterthese soll folgendermaßen aufgebaut und gegliedert werden:</p> <p>Titelblatt Ehrenwörtliche Erklärung Zusammenfassung & Abstract Vorwort Inhaltsverzeichnis / Abbildungsverzeichnis / Tabellenverzeichnis</p> <p>1 Einleitung 1.1 Problem- und Fragestellung 1.2 Erkenntnisinteresse und Zielsetzung 1.3 Aufbau und Methodik</p> <p>2 Darlegung des Forschungsstands 2.1 Empirische Studien 2.2 Forschungsfragen</p> <p>3 Theorien der Mediennutzung 3.1 Der Uses-and-Gratifications-Ansatz 3.2 Selektionsorientierte Ansätze 3.3 Rezeptionsorientierte Ansätze 3.4 Kontextbezogene Ansätze 3.5 Zwischenfazit</p> <p>4 Die Plattformökonomie 4.1 Grundlagen zur Plattformökonomie 4.2 Die Relevanz von YouTube in Österreich 4.3 Die Funktionsweise von YouTube im Speziellen 4.4 Zwischenfazit</p> <p>5 Deep Learning Algorithmen 5.1 Der Oberbegriff Künstliche Intelligenz 5.2 Machine Learning 5.3 Deep Learning 5.4 Einordnung Algorithmen 5.5 Zwischenfazit</p> <p>6 Grundlagen zum Informationsverhalten und Informationssuchverhalten 6.1 Entwicklung der Informationsverhaltensforschung</p>

	<p>6.2 Ausgewählte Modelle des Informationssuchverhaltens 6.3 Zwischenfazit</p> <p>7 Filterblasen 7.1 Definitionen 7.2 Grundlegende Funktionsweise von Filterblasen 7.3 Nutzen und Gefahren von Filterblasen 7.4 Zwischenfazit</p> <p>8 Conclusio 8.1 Beantwortung der Forschungsfragen 8.2 Aufstellung der Hypothesen</p> <p>9 Methodologie 9.1 Erläuterung der Erhebungsmethode 9.2 Erläuterung der Auswertungsmethode 9.3 Operationalisierung und Vorgehensweise</p> <p>10 Empirische Analyse 10.1 Analyseergebnisse 10.2 Interpretation 10.3 Prüfung der Hypothese(n) 10.4 Limitation</p> <p>11 Diskussion</p> <p>Quellenverzeichnis Anhang</p>
Methodenwahl	<p>Um die Auswirkungen des Algorithmen-basierten Filterblaseneffekts in der Plattformökonomie am Beispiel von YouTube zu untersuchen, wird die Methode des Experiments herangezogen. In den folgenden Absätzen soll die Herangehensweise grundsätzlich beschrieben werden:</p> <p>Für das Experiment werden zwei unterschiedliche Personas kreiert, die sich demographisch nicht voneinander unterscheiden, allerdings Unterschiede in ihren Werten und Einstellungen (Soziodemographie) aufweisen. Die genauen Unterschiede werden im Rahmen der Erläuterung der Erhebungsmethode präzise herausgearbeitet. Allerdings kann jetzt schon gesagt werden, dass die eine Persona eine eher</p>

	<p>links-liberale Einstellung, und die andere Persona eine eher rechts-konservative Einstellung vertritt. Für beide Personas wird zudem ein eigener Google-Mail-Account (z.B. persona1@gmail.com und persona2@gmail.com) sowie ein eigener YouTube-Account angelegt.</p> <p>Das Experiment selbst gliedert sich in zwei Phasen: Die erste Phase dient der Anreicherung des Algorithmus mit Informationen. Das heißt, dem Algorithmus soll Zeit gegeben werden, zu lernen welche Werte und Einstellungen die jeweilige Persona vertritt. Dafür werden zumindest vier Wochen eingeplant. Das Verhalten der jeweiligen Persona, wird nach vorab bestimmten Kriterien bzw. eines Regelsatzes gesteuert. Beispielsweise würde die erste Persona (links-liberal) ein Video ganz zu Ende sehen, welches zu ihrer Einstellung und individuellen Weltsicht passt, dieses eventuell positiv bewerten, (und) kommentieren, oder sogar den Channel abonnieren. Selbiges gilt für die zweite Persona (rechts-konservativ), allerdings sähen ihre gesetzten Handlungen anders aus: Das Video wird in der ersten Hälfte schon abgebrochen, eventuell auch das Video schlecht bewertet, (und) negativ kommentiert, usw. Der YouTube-Algorithmus wird also anhand der Reaktionen der jeweiligen Persona unterschiedlich mit Informationen angereichert. Die einzige Variable in diesem Experiment bildet das Nutzer*innen- bzw. Nutzungsverhalten.</p> <p>In der zweiten Phase werden nun die möglichen Unterschiede der Vorschläge von YouTube untersucht. Denn der angewendete Algorithmus sollte nach der ersten Phase des Experiments in der Lage sein, aufgrund des Informations(such)verhaltens, für den oder die NutzerIn, relevante Vorschläge zu liefern. In dieser Phase sollen also die Unterschiede in der Aufbereitung und Gliederung der Startseite als auch Unterschiede in den Suchergebnissen analysiert werden. Die Begriffe für die Suche werden wiederum vorab festgelegt. Diese Begriffe sollen allerdings aus Vielzahl von unterschiedlichen Lebensbereichen stammen: Sowohl politisch relevante, als auch</p>
--	---

	<p>neutrale Themenbereiche werden in der Suche durch beide Personas gleichermaßen abgedeckt.</p> <p>Im Sinne der Nachvollziehbarkeit, als auch für die spätere Auswertung der Ergebnisse werden jegliche Schritte und Reaktionen dokumentiert.</p> <p>Nach Abschluss des Experiments wird es interessant sein, zu sehen, welche Vorschläge, welche Persona, erhält, obwohl sie vielleicht nie danach gesucht hat, oder auch in welche Richtung der Algorithmus die jeweilige Persona führt, wie weit bzw. über welche Bereiche hinweg, Filterblasen reichen können, und ob der Filterblaseneffekt in einer Meinungsgruppe stärker ausgeprägt ist oder aber auch kein Unterschied festgemacht werden kann.</p> <p>Ziel des Experiments ist die Auswirkungen des Algorithmenbasierten Filterblaseneffekts in der Plattformökonomie anhand von YouTube, festzuhalten und zu beschreiben.</p>
Literaturhinweise	<p>Monographien</p> <p>Humborg, C., Nguyen, T. A., 2018. Die publizistische Gesellschaft – Journalismus und Medien im Zeitalter des Plattformkapitalismus. Springer Fachmedien, Wiesbaden.</p> <p>Schmidt, J.-H., 2018. Social Media, 2. Auflage. Springer Fachmedien, Wiesbaden.</p> <p>Schweiger, W., 2007. Theorien der Mediennutzung – Eine Einführung, 1. Auflage. VS Verlag für Sozialwissenschaften / GWV Fachverlage GmbH, Wiesbaden.</p> <p>Schweiger, W., 2017. Der (des)informierte Bürger im Netz. Wie soziale Medien die Meinungsbildung verändern. Springer Fachmedien, Wiesbaden.</p> <p>Sammelände</p> <p>Zweig, K. A., Krafft, T. D. (Hrsg.), Deussen, O., 2017. Algorithmen und Meinungsbildung – Eine grundlegende Einführung. Springer-Verlag, Berlin, Heidelberg.</p>

	<p>Journals</p> <p>Bakshy, E., Messing, S., Adamic, L., 2015. Exposure to ideologically diverse news and opinion on Facebook. In: Science, 348, 6239. S. 1130–1132.</p> <p>Garrett, R. K., Carnahan, D., Lynch, E. K.. 2013. A turn toward avoidance? Selective exposure to online political information, 2004–2008. In: Political Behavior, Vol. 35, 1. S. 113–134.</p> <p>Katzenbach, C., 2018. Die Ordnung der Algorithmen - zur Automatisierung von Relevanz und Regulierung gesellschaftlicher Kommunikation. In: Mohabbat Kar, R., Thapa, B. E. P., Parycek, P., 2018. (Un)berechenbar? Algorithmen und Automatisierung in Staat und Gesellschaft. Fraunhofer-Institut für Offene Kommunikationssysteme FOKUS, Kompetenzzentrum Öffentliche IT (ÖFIT). S. 1-15.</p> <p>Mahnke, M., 2015. Der Algorithmus, bei dem man mit muss? Ein Perspektivwechsel. In: Communicatio Socialis, Vol. 48, 1. S. 34-45.</p> <p>Trilling, D., 2014. Grenzen der Selektivität: Kann der Selective-exposure-Ansatz komplementäre und komplexe Nutzungsmuster erklären? In: Kleinen von Königslöw, K., Förster, K. (Hrsg.), Medienkonvergenz und Medienkomplementarität aus Rezeptions- und Wirkungsperspektive. Nomos, Baden-Baden. S. 75–92.</p> <p>Internetquellen</p> <p>Alexa Ranking, 2019. The top 500 sites on the web, unter: https://www.alexa.com/topsites (Zugriff am: 5.1.2019)</p> <p>Bakshy, o.D. Eytan Bakshy, unter: https://eytan.github.io (Zugriff am: 7.1.2019)</p>
--	---

	<p>Botsman, R., 2017. Big Data meets Big Brother as China moves to rate its citizens, unter: https://www.wired.co.uk/article/chinese-government-social-credit-score-privacy-invasion (Zugriff am: 6.1.2019)</p> <p>Gadringer, S., Holzinger, R., Sparviero, S., Trappel, J., Nening, I., Digital News Report Network Austria (Hrsg.), 2018. Digital News Report 2018 – Detailergebnisse für Österreich, unter: http://www.digitalnewsreport.at/reports/2018-2/ (Zugriff am: 5.1.2019)</p> <p>Google, 2019. Funktionsweise der Suchalgorithmen, unter: https://www.google.com/search/howsearchworks/algorithms/ (Zugriff am: 6.1.2019)</p> <p>Brühl, J., Hauck, M., Hurtz, S., sueddeutsche.de, 2018. Was ist eigentlich bei Facebook los?, unter: https://www.sueddeutsche.de/digital/datenmissbrauch-was-ist-eigentlich-gerade-bei-facebook-los-1.3932349 (Zugriff am: 7.1.2019)</p> <p>von Engelhardt, S., Wangler, L., Wischmann, S., Begleitforschung AUTONOMIK für Industrie 4.0 (Hrsg.), 2017. Eigenschaften und Erfolgsfaktoren digitaler Plattformen, unter: https://www.digitale-technologien.de/DT/Redaktion/DE/Downloads/Publikation/autonomik-studie-digitale-plattformen.pdf?blob=publicationFile&v=9 (Zugriff am: 5.1.2019)</p>
--	---