

Messung von Personalisierung in computervermittelter Kommunikation

Jürgens, Pascal; Stark, Birgit; Magin, Melanie

Erstveröffentlichung / Primary Publication

Sammelwerksbeitrag / collection article

Empfohlene Zitierung / Suggested Citation:

Jürgens, Pascal ; Stark, Birgit ; Magin, Melanie: Messung von Personalisierung in computervermittelter Kommunikation. In: Maireder, Axel (Ed.) ; Ausserhofer, Julian (Ed.) ; Schumann, Christina (Ed.) ; Taddicken, Monika (Ed.): *Digitale Methoden in der Kommunikationswissenschaft*. Berlin, 2015 (Digital Communication Research 2). - ISBN 978-3-945681-02-2, 251-270.. <https://doi.org/10.17174/dcr.v2.11>

Nutzungsbedingungen:

Dieser Text wird unter einer CC BY Lizenz (Namensnennung) zur Verfügung gestellt. Nähere Auskünfte zu den CC-Lizenzen finden Sie hier:

<https://creativecommons.org/licenses/by/4.0/deed.de>

Terms of use:

This document is made available under a CC BY Licence (Attribution). For more information see:

<https://creativecommons.org/licenses/by/4.0>

Empfohlene Zitierung: Jürgens, P., Stark, B., & Magin, M. (2015). Messung von Personalisierung in computervermittelter Kommunikation. In A. Maireder, J. Ausserhofer, C. Schumann, & M. Taddicken (Hrsg.), *Digitale Methoden in der Kommunikationswissenschaft* (S. 251-270). doi: 10.17174/dcr.v2.11

Zusammenfassung: Das Ziel personalisierter Online-Angebote ist, Rezipienten bei der Informationssuche zu unterstützen. Dabei greifen sie zwangsläufig in deren Auswahlentscheidungen ein und müssen deshalb als eigenständiger Einflussfaktor empirisch erschlossen werden. Die dahinterstehenden Algorithmen kommerzieller Anbieter sind für die Forschung größtenteils eine intransparente „Black Box“. Automatisierte Online-Experimente stellen eine selten eingesetzte Methode dar, die durch systematische Simulation von Nutzerverhalten die Funktionsweise von Personalisierungsalgorithmen ermitteln kann. Der Beitrag diskutiert zunächst Auswirkungen und Funktionsweise von Personalisierung und stellt daraufhin ein automatisiertes Online-Experiment am Beispiel der Google-Suche dar. Die vorgestellte Methode ermöglicht einen sozialwissenschaftlichen Zugriff auf die Funktionsweise und Inhalte von personalisierten Angeboten und fördert gleichzeitig Validität, Transparenz und Replizierbarkeit von Nutzungsstudien.

Lizenz: Creative Commons Attribution 4.0 (CC-BY 4.0)

Pascal Jürgens, Birgit Stark & Melanie Magin

Messung von Personalisierung in computervermittelter Kommunikation

1 Das individualisierte Web

Mit der Angebotsexplosion im Internet ist die Aufmerksamkeit der Nutzer zu einem knappen Gut geworden. Neben Medienunternehmen suchen auch zahllose andere Webseiten, Rezipienten anzuziehen und zu binden, um Werbeerlöse zu generieren oder Verkäufe zu erzielen. Der wachsenden Konkurrenz begegnen insbesondere technologieaffine Firmen mit personalisierten Angeboten, die die Zufriedenheit der Nutzer erhöhen sollen (Teevan, Dumais, & Horvitz, 2010). Dabei werden Rezipienten bevorzugt solche Inhalte angeboten, die zu ihren individuellen Interessen passen – seien das Filme aus dem Angebot von T-Online, Artikel auf sueddeutsche.de oder Bücher bei Amazon.

Mit dem Siegeszug der digitalen Informationsübertragung geht dabei eine Verschiebung an Verantwortung einher: Wo Rezipienten zuvor eigenständig, geleitet von menschlichen Entscheidungs-, Bewertungs- und Handlungsstrategien Kommunikation bestimmten, können sie nun einen Teil dieser Entscheidungen auslagern. Die (vermeintlich) passendsten Bücher empfiehlt *Amazon*, die interessanteste Musik Spotify und die wichtigsten Statusnachrichten von Freunden kennt Facebook – und in jedem dieser Fälle ist die Empfehlung nicht das Produkt eines menschlichen Experten, sondern das eines Algorithmus. Das alltägliche Menü an Medieninhalten, Unterhaltung, Gütern, Informationen und sozialen

Kontakten wird also von neuen Intermediären mitbestimmt, die sich als Vermittler in die ursprünglich direkte Beziehung zwischen Rezipienten und den etablierten Anbietern bzw. deren Produkte schieben.

Diese Anbieter stehen dem Nutzer dabei meist nicht als Gatekeeper zur Seite, die Informationen weiterleiten bzw. vorenthalten, sondern vielmehr als Ratgeber, der aus einem großen Angebot einzelne Artikel hervorhebt. Die wichtigste Konsequenz solcher algorithmisch erzeugter Zusammenstellungen von Informationen ist, dass Inhalte von Rezipient zu Rezipient abweichen. Dadurch greifen Wirkungshypothesen zu kurz, die davon ausgehen, dass Webseiten zu einem gegebenen Zeitpunkt für jeden Besucher dieselbe Informationsauswahl darstellen. So ist beispielsweise denkbar, dass Nachrichtenangebote ihre Artikelauswahl an die individuellen politischen Einstellungen ihrer Nutzer anpassen.¹ Forschung zu politischer Selektivität (Selective Exposure) stünde dann vor der Herausforderung, zwischen dem Auswahlverhalten durch politisch motivierte Vermeidung bzw. Zuwendung und jenem durch die Personalisierung angebotener Artikel zu differenzieren bzw. ihre Verknüpfung zu beachten.

Die kommunikationswissenschaftliche Forschung sieht sich deshalb zunehmend mit dem Problem konfrontiert, bestehende theoretische und methodische Grundlagen der Online-Forschung um das Element personalisierter Inhalte zu erweitern. Ein prominentes Beispiel hierfür ist die Suchmaschinenforschung, die sich lange mit Verzerrungen durch Suchalgorithmen – wie der verstärkten Lenkung der Nutzer zu populären Webseiten (z.B. Hindman, 2009) – beschäftigt hat. Seit Suchergebnisse an das Verhalten der Suchenden angepasst werden, sind die bestehenden Befunde nicht länger übertragbar: Ob etwa Nutzer bevorzugt populäre („Mainstream“-)Seiten angezeigt bekommen, oder auch Nischenangebote auftauchen, kann von personalisierten Suchergebnissen und somit vom Nutzerverhalten abhängen (Jürgens, Stark, & Magin, 2014). Vor ähnlichen Herausforderungen stehen alle Forschungszweige, deren Gegenstand personalisierte Angebote beinhaltet. Hierzu zählen Nachrichtenseiten inzwischen ebenso wie E-Commerce-Anwendungen, Nachrichtenaggregatoren und soziale Netzwerkseiten.

1 In den USA setzt die Huffington Post bereits Personalisierung ein, um Nutzern eine interessensspezifische Artikelauswahl zu präsentieren (Reid, 2014).

Sowohl die Funktionsweise als auch die Auswirkungen von Personalisierung sind in der Kommunikationswissenschaft noch weitgehend ungeklärt. Im Zuge der fortschreitenden Verbreitung der Technologie (Springer, 2014) wird es zunehmend wichtiger, zumindest empirisch überprüfen zu können, ob ein Angebot personalisiert ist und gegebenenfalls die Auswirkungen exemplarisch untersuchen zu können. Der vorliegende Aufsatz liefert hierzu einen ersten Beitrag: Zuerst stellt er die Verfahren der Personalisierung sowie damit verbundene Wirkungshypothesen kurz vor und entwickelt anschließend eine computergestützte Methode, anhand derer Personalisierungseffekte identifiziert und gemessen werden können. Abschließend werden potenzielle Weiterentwicklungen im Kontext technischer Innovationen diskutiert.

Personalisierung als Bias

Eine empirische Messung der Auswirkungen von Personalisierung erscheint auf den ersten Blick kaum umsetzbar: Welche Arten von Inhalten für welche Nutzer in welchem System bevorzugt angeboten werden, hängt nicht nur von einer Vielzahl an Kontextvariablen (Zeit und Ort des Abrufs), sondern auch von dem Verhalten des Nutzers ab und ist deshalb schwer vorhersagbar. Sowohl in der Informatik als auch in der Kommunikationswissenschaft stehen Bemühungen, die Auswirkungen dieser komplexen Interaktionen zu erfassen, erst am Anfang.² Erste theoretische und methodische Annäherungen können sich allerdings auf zwei bestehende Konzepte stützen, die zumindest eine erste Orientierung bieten:

- (1) In Bezug auf die *einheitliche Wirkung* von Softwaresystemen stellt sich zunächst die Frage nach einer von Personalisierung unabhängigen, systematischen Bevorzugung oder Benachteiligung spezifischer Inhalte. Diese Perspektive ist unter dem Stichwort des „Bias“ sowohl in der Kommunikationswissenschaft als auch in der Informatik bereits etabliert (Friedman & Kahn, 2008; Friedman & Nissenbaum, 1996). Im Kern von Bias-Hypothe-

2 Den größten Beitrag in diesem Bereich liefert wohl das interdisziplinäre Forschungsfeld der „Complexity Science“, in dem sich Informatik, Physik, Wirtschaftswissenschaften, Psychologie und weitere Disziplinen der Modellierung von Systemen mit nichtlinearen Verhaltensweisen annehmen (siehe Mitchell, 2009).

sen steht die Erkenntnis, dass Computersysteme trotz ihrer maschinellen Funktionsweise nicht automatisch neutrale Informationsvermittler sein müssen (Friedman & Nissenbaum, 1996; Rieder, 2004). Im Zuge der Verarbeitung können sie vielmehr Informationen gänzlich unterdrücken (als Gatekeeper, Filter oder Zensor) sowie in der Darstellung hervorheben oder herunterspielen. Eine Verzerrung oder „Bias“ liegt dieser Sichtweise folgend dann vor, wenn die Zugänglichkeit zu Informationen im Verarbeitungsprozess durch ein Computersystem verändert wird. Im Fall des Herausfilterns von Informationen ist der Bias vergleichsweise einfach zu definieren und empirisch nachzuweisen: Sobald Inhalte der Software als Input zur Verfügung stehen, aber nicht an den Nutzer weitergereicht werden, wirkt sie verzerrend. Dies ist beispielsweise der Fall, wenn Facebook-Nutzer nur ausgewählte Nachrichten von Freunden zu sehen bekommen (Bucher, 2012) oder wenn Suchmaschinen einzelne Seiten aufgrund von staatlichen Vorgaben nicht in den Ergebnislisten anzeigen (Taneja & Wu, 2013). Wenn es allerdings nicht um das Vorenthalten, sondern um die Hervorhebung von Informationen geht, wird die Definition von Verzerrungen schwieriger: Denn dann lässt sich ein Bias nur im Vergleich zu einem neutralen Maßstab konzipieren. So wäre ein verzerrendes System beispielsweise eine Hotelsuchmaschine, die Angebote der eigenen Firma grundsätzlich an oberster Stelle anzeigt, selbst wenn diese nicht die günstigsten sind (Vergleich der produzierten Reihenfolge am neutralen Maßstab Preis).

- (2) Der Zweck von personalisierten Angeboten besteht darüber hinaus darin, *unterschiedlichen Nutzern differierende Inhalte* vorzulegen. Hierdurch können solche Systeme Unterschiede in der Informationsauswahl verstärken und so Tendenzen zur Fragmentierung in der Nutzerschaft auslösen. Diese auch als „Filter Bubble“ (Pariser, 2011) bekannt gewordene und von zahlreichen Autoren vorgebrachte Hypothese (Sunstein, 2009) ist eine mögliche Folge der Überspezialisierung („Over-Specialization“). Aus dem Blickwinkel der Praxis erscheint dieses dystopische Szenario von vollständig isolierten Nutzern und einer komplett fragmentierten Öffentlichkeit allerdings nicht realistisch (hierzu auch Garrett, Carnahan, & Lynch, 2013). Eine vollständig personalisierte Informationsauswahl ist hier bereits deshalb nicht wün-

schenswert, weil vielfältige Angebote den Nutzern häufig einen größeren Mehrwert bieten (siehe Diaz, 2008; Adomavicius & Tuzhilin, 2005).

2 Personalisierung aus technischer Sicht

Im Kontext computervermittelter Kommunikation werden unter dem Begriff „Personalisierung“ Verfahren zusammengefasst, die digitale Inhalte in Abhängigkeit von bestimmten Merkmalen eines Nutzers anpassen (eine Übersicht über Definitionen unterschiedlicher Disziplinen liefern Fan & Poole, 2006; siehe auch Pitkow, Schütze, Cass, Cooley, Turnbull, Edmonds, et al., 2002). Für die weitere Argumentation werden unter Personalisierung (und in der Konsequenz unter personalisierten Angeboten) Systeme verstanden, die Inhalte einer Webseite gegenüber dem Nutzer durch Anwendung von Algorithmen anpassen.

Unter diese breite Definition fällt der regionale Wetterbericht einer Nachrichtenwebseite (Anpassung an den Ort des Nutzers) ebenso wie der Kontaktvorschlag einer Webseite für Partnervermittlung (Anpassung an Interessen und Charakter des Nutzers). Während im ersten Fall das dahinterstehende Computersystem vorhandene Daten³ ohne Interaktion mit dem Nutzer verwenden kann, sind die Merkmale im zweiten Fall nur explizit erfragbar (Sundar & Marathe, 2010). Der angestrebte Nutzen für den User ist in beiden Fällen gleich: „passende“ Informationen sollen den Nutzer bei der Selektion unter einer Vielzahl an potenziell uninteressanten Informationen unterstützen, ihn dadurch entlasten und schnell zu den „besten“ Inhalten führen, was in einer höheren Zufriedenheit mündet (Teevan et al., 2010).

Den Kern jedes personalisierten Angebots stellen die gesammelten Daten zu den vermuteten Interessen des Nutzers dar. In dem sogenannten „user model“ oder „user profile“ (Jannach, Zanker, Felfernig, & Friedrich, 2010, S. 1) werden Informationen gesammelt, die über den individuellen Geschmack und somit über

3 So kann beispielsweise der Ort eines Nutzers grob anhand der IP-Adresse des genutzten Geräts ermittelt werden (GeoIP). Eine frei verfügbare Datenbank mit entsprechenden Daten bietet beispielsweise MaxMind an. Die Open Source-Software „freegeoip“ kann als passende Rechercheplattform dazu verwendet werden.

die Gratifikationserwartungen des Nutzers Aufschluss geben. Ein solches Interessenprofil kann unter Einsatz von expliziten Fragen entstehen, zum Beispiel indem eine Dating-Webseite Selbsteinschätzungen des Charakters und persönliche Vorlieben abfragt. In vielen Fällen werden die Profile allerdings implizit aus den ohnehin bei der Benutzung des Angebots entstehenden Daten generiert. Dies ist etwa der Fall, wenn aus den in der Vergangenheit gekauften Produkten Vorschläge für zukünftige Kaufentscheidungen produziert werden.

Die Forschung zu *Recommender Systems* trennt weiterhin zwei Grundtypen von Algorithmen, die sich in Bezug auf die Empfehlungskriterien für „passende“ Inhalte unterscheiden (Ricci, Rokach, Shapira, & Kantor, 2010; Jannach et al., 2010):

- (1) Das sogenannte „*Collaborative Filtering*“ vergleicht lediglich unterschiedliche Profile miteinander und ermittelt, welche Rezipienten sich anhand des bisherigen Verhaltens ähnlich sind. Nach diesem Prinzip zeigt beispielsweise Google News personalisierte Nachrichten, die mit Hilfe der Profile ähnlicher Nutzer zusammengestellt werden (Das, Datar, Garg, & Rajaram, 2007). Ebenso bietet Amazon seinen Kunden Bücher an, die andere Leser mit ähnlichen Interessen bereits gekauft haben. Diese Gruppe an Verfahren ist relativ einfach und universell umsetzbar, da sie nicht auf die Eigenschaften der Produkte eingeht. Was für Objekte empfohlen werden ist egal: So lange genügend Datensätze vorliegen, lassen sich Personen mit ähnlichen Interessen identifizieren und dem Nutzer bislang unbekannte Einträge aus deren Profil anbieten.
- (2) Eine Weiterentwicklung des „*Collaborative Filtering*“ sind Empfehlungssysteme, die sich auch nach dem Inhalt empfohlener Texte richten („*Content-based recommendation*“, Jannach et al., 2010). Ein solches System kommt bei der US-Ausgabe der Huffington Post zum Einsatz. Dort ermittelt es aus den zuvor gelesenen Artikeln die Themenpräferenzen von Nutzern und passt die Startseite an, um die individuellen Präferenzen besser zu bedienen (Reid, 2014). Der Algorithmus ist dabei journalistischen Selektionsentscheidungen sehr ähnlich, da er erwartete Interessen auf Seiten des Rezipienten mit Merkmalen der empfohlenen Inhalte in Bezug setzt. Je deutlicher ein Objekt mit den Wünschen des Nutzers zusammenhängt, des-

to höher wird es eingestuft. Inhaltsbezogene Empfehlungssysteme haben den Vorteil, dass auch dann Empfehlungen abgegeben werden können, wenn bislang nur wenige Daten über andere Nutzer vorliegen. Die Kehrseite aus wirtschaftlicher Perspektive ist allerdings eine deutlich gesteigerte Komplexität für die Programmierer: Zunächst müssen die relevanten Merkmale der Artikel (z.B. Thema, Gegenstand, Textgattung usw.) erhoben werden. Außerdem ist nicht immer offensichtlich, aufgrund welches Merkmals ein Nutzer einen Artikel ausgewählt hat – ob er/sie also das Thema interessant findet, die Textgattung mag oder den Autor schätzt. Die genaue Beziehung muss deshalb erst durch statistische Verfahren ermittelt werden (Jannach et al., 2010). Ein in der Praxis erfolgreiches und häufig angeführtes Beispiel für ein solches Empfehlungssystem ist das Portal „Rotten Tomatoes“, auf dem Nutzer Filme finden können, die ihren eigenen Vorlieben (z.B. in Bezug auf Genre, auftretende Schauspieler usw.) entsprechen. Innerhalb dieser beiden Typen differenzieren sich einzelne Systeme weiter aus. Je nach Anwendungsgebiet werden unterschiedliche Nutzer- und Inhaltsmerkmale gemessen und diese anhand verschiedener Algorithmen miteinander verglichen.

Von der verwendeten Definition von „Personalisierung“ ausgenommen sind hingegen Anwendungen, die der Nutzer selbst den eigenen Vorstellungen und Wünschen entsprechend anpassen kann, indem er beispielsweise das Aussehen einer Webseite oder die Auswahl der angezeigten Informationen ändert. Solche Anpassungen, die der Nutzer aktiv selbst vornimmt, sind in der Fachliteratur unter dem Begriff „customization“ (also eine Modifikation) gefasst. Personalisierte Angebote hingegen funktionieren vollautomatisch und ohne Initiative des Rezipienten (siehe zu dieser Unterscheidung auch Sundar & Marathe, 2010).

3 Methodische Herausforderungen durch Personalisierung

Die Entwicklung von neuen Instrumenten in der Forschung zu computervermittelter Kommunikation ist mit dem Anspruch konfrontiert, Neu- und Weiterentwicklungen im Bereich der Personalisierung zu berücksichtigen. Insbesondere die Sicherung der Validität stellt hier eine zentrale Herausforderung dar.

Bei dieser Aufgabe steht die empirische Kommunikationswissenschaft von zwei Seiten aus unter Druck (siehe z.B. zu den Herausforderungen für die Suchmaschinenforschung auch Granka, 2010):

- (1) Die *Sicherung der internen Validität* stellt vorwiegend eine technische Herausforderung dar: Online-Angebote beziehen zunehmend Indikatoren in ihre Funktionsweise ein, die aus dem Verhalten der Nutzer abgeleitet sind. Webseiten versuchen für Leser attraktiver zu werden: Sie passen die Zusammenstellung der Startseite an die vermuteten Interessen des Nutzers an und gehen in einigen Fällen sogar auf besondere Details aus seinem Leben ein – was Google beispielsweise durch ein Glückwunschk-Doodle zum Geburtstag erreicht (Springer, 2014). Empirische Methoden stehen aufgrund der Vielzahl an personalisierten Angeboten unter einem anhaltenden Innovationsdruck, um nicht an interner Validität einzubüßen: So lange empirische Studien die genaue Zusammenstellung personalisierter Angebote nicht erheben können (siehe Emmer & Strippel in diesem Band) besteht die Gefahr, dass Personalisierung als Störfaktor auftritt. Untersucht beispielsweise ein Experiment innerhalb von Facebook die Reaktion von Nutzern auf Anfeindungen, dann können die Intensität der Beziehung zwischen „Angreifer“ und „Opfer“ sowie die daraus resultierende Personalisierung des Feeds als konfundierende Variable wirken: Sind die beiden nur weitläufig miteinander bekannt, wird dem „Opfer“ der Post des „Angreifers“ gegebenenfalls gar nicht angezeigt (siehe auch Bucher, 2012). Ein erster Schritt zur Untersuchung von personalisierten Angeboten muss demnach sein, die Funktionsweise der Personalisierung selbst zu messen. Da in den meisten Fällen unbekannt ist, welche Aspekte des Nutzerverhaltens (z.B. die angeklickten Artikel, das „Liken“ von Inhalten) und welche Kontextfaktoren (z.B. der verwendete Browser, der Zeitpunkt des Aufrufs, das verwendete Gerät) in die Personalisierung eingehen, ist die Simulation von Rezipientenverhalten ein besonders geeignetes Mittel. Dabei gibt sich der Forscher gegenüber einem Angebot als neuer Nutzer aus und interagiert systematisch mit der Webseite, wobei Kontextfaktoren wie Ort, Zeit und die verwendete Browser-Software kontrolliert werden. Zudem bleiben durch das automatisierte „Klickverhalten“ Faktoren konstant, deren Rolle für die Personalisierung nicht be-

kannt ist – wie etwa die Latenz zwischen Aufruf der Seite und dem Klick auf ein Ergebnis.

- (2) Ein wesentlich größeres Problem ist die *Sicherung der externen Validität*: In den meisten Fällen dürfte nicht bekannt sein, wie sich Rezipienten in ihrer Interaktion mit einer Seite verhalten. Da aber deren Inhalt selbst nun vom Verhalten abhängt, bleibt unklar, welchen Inhalten die Rezipienten de facto ausgesetzt sind (siehe Emmer & Strippel in diesem Band). Damit Erkenntnisse über das Rezeptionsverhalten auch unter den Vorzeichen einer Personalisierung generalisierbar sind, muss entweder bekanntes Nutzerverhalten nachgeahmt oder aber systematisch konzipiert werden. Die einfachste Form systematischen Verhaltens wäre dabei eine Monte-Carlo-Simulation (Mooney, 1997), die blind eine große Zahl zufälliger Stimuli anwendet und aus den Ergebnissen die Funktionsweise des Systems rekonstruiert. Ein solches Vorgehen ist jedoch nur dann pragmatisch durchführbar, wenn die Anzahl der möglichen Eingaben begrenzt ist. Für den programmatischen Zugang über eine API (Application Programming Interface) sind beispielsweise nur 100 Anfragen pro Tag umsonst – darüber hinaus sind \$5 pro 1.000 Anfragen zu bezahlen (Google, 2014).

Hinter der gestiegenen Anforderung an die Erhebungsmethodik stehen größtenteils technische Gründe. Personalisierung entsteht erst im Laufe der Zeit, da die entsprechenden Angebote zunächst Informationen über den Nutzer sammeln müssen, anhand derer die Webseite subsequent angepasst werden kann. Um überhaupt einen Eindruck der Personalisierung – etwa von Google News – zu erlangen, muss der Forscher zumindest die Webseite für zwei deutlich unterschiedliche Nutzungsstile im Zeitverlauf vergleichen. Am leichtesten fällt dies, wenn dazu Nutzerkonten mit Passwörtern erstellt werden. Denn dann ist jeweils sicher gestellt, dass nur die Webseiteninteraktion nach dem Login Einfluss auf das jeweilige Nutzerprofil hat. Sollen Inhalte systematisch erfasst werden, muss die dazu eingesetzte Software ebenfalls den passenden Benutzernamen und das Passwort verwenden, um Zugriff auf dieselbe Ansicht zu erhalten. Bereits an dieser Stelle können jedoch Komplikationen auftreten: Als Schutz vor Missbrauch (z.B. durch gezielte Manipulation mit kommerziellen Zielen wie im Fall von Search Engine Optimization) verhindern viele Betreiber von Webseiten den Zugriff durch

automatisierte Programme. Anhand der Hinweise von technischen Merkmalen wie zum Beispiel dem Namen des verwendeten Programms⁴ oder Verhaltensindikatoren (z.B. die Anzahl und Regelmäßigkeit von Anfragen) werden Zugriffe gegebenenfalls abgewiesen.

Der wissenschaftliche Zugriff wird weiterhin durch Programme erschwert, die auf dem Computer des Nutzers im Webbrowser ablaufen und die Seite erst dort in ihre letztlich sichtbare Form bringen. Die in der Programmiersprache *JavaScript* geschriebenen Anwendungen werden insbesondere eingesetzt, damit Webseiten schnell und einfach interaktiv bedient werden können. Klickt ein Nutzer eine entsprechende Schaltfläche an, wird keine komplett neue Seite geladen. Vielmehr fragt das Programm im Hintergrund neue Daten vom Server an, um diese dann in die bestehende Seite einzufügen und ggf. vorhandene Daten zu ersetzen (McCaw, 2011). Auf Basis dieser Technologien entwickelte und meist als „Web Apps“ bezeichnete Angebote, sind für den Großteil der Werkzeuge zur systematischen Speicherung und Archivierung von Webseiten nicht abbildbar. Wer beispielsweise eine Seite mit Suchergebnissen von Google mittels eines Computerprogramms herunterlädt⁵, erhält nur eine weitgehend leere „Hülle“. Die eigentliche Liste an Webseiten wird erst durch den Browser des Nutzers nachgeladen. Solche dynamischen Angebote stellen eine erhebliche Herausforderung für die reliable Erfassung der Inhalte von modernen Web-Angeboten dar (grundlegend aus der Perspektive digitaler Archive: Masanès, 2005, 2006; Lyman, 2002).

4 Das Öffnen der „Black Box“

Den Herausforderungen in Bezug auf die interne und externe Validität begegnet das hier vorgestellte Forschungsdesign durch eine automatisierte Simulation, die die bekannten Kontext-Drittvariablen (verwendete Soft- und Hardware, IP-Adresse, Zeitpunkt des Aufrufs) kontrollieren kann und eine authentische Simu-

4 Der sogenannte „User Agent“, den ein Programm bei HTTP-Anfragen mitsendet, kann allerdings frei manipuliert werden (RFC 2616, 14.43: <http://tools.ietf.org/html/rfc2616#section-14.43>)

5 Die zugehörige URL folgt schlicht dem Schema „<https://www.google.de/?q=test>“ mit „test“ als Suchbegriff.

lation von Nutzerverhalten erlaubt. Prinzipiell ermöglicht diese Methode den Zugriff auf personalisierte Angebote, durch den die angezeigten Inhalte passiv erhoben werden können und durch den auch aktiv mit ihnen interagiert werden kann. Eine erste nützliche Anwendung sind Studien mit quasi-experimentellem Design, die Licht auf die Funktionsweise von personalisierten Angeboten werfen.

Je mehr Online-Angebote Nutzer mit personalisierten Empfehlungen bei der Auswahl von Inhalten unterstützen, desto stärker nehmen sie dadurch Einfluss auf Rezeptionsentscheidungen (siehe zu Suchmaschinen etwa Pan, Hembrooke, Joachims, Lorigo, Gay, & Granka, 2007). Forschungsfelder wie die Mediennutzungsforschung, die Nutzerentscheidungen zuvor als Handeln des Rezipienten gegenüber einem fixen Angebot auffassen konnten, müssen ihren Fokus in Zukunft um Personalisierungseffekte erweitern.

Die größte Herausforderung ist dabei die Intransparenz der Funktionsweise: Wie genau ein Algorithmus Informationen auswählt und bewertet, kann mit abschließender Sicherheit nur an seinem Quellcode abgelesen werden. Ist ein Einblick in den Code nicht gestattet, dann muss die Funktionsweise der Software rekonstruiert werden. Hierzu setzt die verwendete Methode simuliertes Nutzerverhalten ein: Die grundlegende Arbeitsweise des Personalisierungsalgorithmus wird ermittelt, indem In- und Output unter systematisch veränderten Bedingungen verglichen werden. So könnte beispielsweise eine Nachrichtenwebseite von zwei simulierten Nutzern besucht werden, von denen einer nur Artikel über nationale Politik liest, während sich der zweite nur für internationales Geschehen „interessiert“. Wenn die Startseite anhand der Themenpräferenzen personalisiert wird, dann zeigt sich dies an einer im Zeitverlauf divergierenden Zusammenstellung der Themen.

Algorithmen sind komplexe Systeme, die viele verschiedene Variablen verwenden und oft schwierig nachzuvollziehenden Art und Weise verarbeiten (siehe z.B. McGeoch, 2002 zu Simulationsstudien von Algorithmen)⁶. Fälle, in denen ein großes

6 Einführende Darstellungen zu der Verwendung von Experimenten als Instrument in den Ingenieurwissenschaften und der Informatik finden sich bei Mason, Gunst und Hess (2003) und Feitelson (2006) mit Parallelen zur sozialwissenschaftlichen Experimentallogik. Kohavi, Longbotham, Sommerfield und Henne (2009) behandeln Web-Experimente mit menschlichen Probanden, wohingegen Paxson (2004) auf die Rolle von technischen Hürden bei Messungen von Internet-Anwendungen eingeht. Die Literaturstudie von Tichy, Lukowicz, Prechelt und Heinz (1995) betrachtet schließlich die Professionalisierung des Feldes in Bezug auf die Verwendung von Experimenten.

Spektrum aller In- und Outputs eines solchen Systems im Stil einer Monte-Carlo-Simulation ausprobiert werden können, dürften eine Seltenheit darstellen. Die meisten Web-Anwendungen erlauben vielmehr eine nahezu uneingeschränkte Bandbreite an Eingaben, die in Empfehlungen von Inhalten umgewandelt werden. Diese Konstellationen können selbstverständlich nicht alle getestet werden. Vielmehr müssen empirische Studien – wie auch bei klassischen Experimenten – zugespitzte Kontrastbedingungen finden, die mit einer zielführenden und theoriebezogenen Hypothese verknüpft sind. Sinnvolle Anknüpfungspunkte hierfür sind die eingangs angesprochenen Typen der Verzerrung: Wird beispielsweise die Zensur bestimmter politischer Positionen vermutet, dann muss verglichen werden, ob der Output des Algorithmus relevante Inhalte vermissen lässt, die eigentlich verfügbar wären.

Fallstudie Googleisierung der Informationssuche

Die Methode der automatisierten Simulation von Nutzerverhalten wurde im Rahmen des Forschungsprojekts „Googleisierung der Informationssuche“ das erste Mal eingesetzt, um Personalisierungseffekte bei Google-Suchanfragen zu messen (Jürgens et al., 2014). Das Experiment diente als empirischer Test der Hypothese, dass personalisierte Ergebnisse von Suchmaschinen zu einer Fragmentierung der von Nutzern wahrgenommenen Informationen führen („Filter Bubble“, Pariser, 2011). Die zu prüfende Nullhypothese war dementsprechend, dass die angezeigten Suchergebnisse für zwei Nutzer im Schnitt identisch sind, obwohl diese sich in ihrem Suchverhalten (das die Personalisierung bestimmt) unterscheiden. Im Folgenden werden die einzelnen Phasen der Methode exemplarisch dargestellt. Prinzipiell kann dasselbe Vorgehen mit nur geringfügigen Anpassungen auch auf andere Anbieter wie zum Beispiel Facebook mit dem EdgeRank-Algorithmus angewendet werden.

Zugang zu Angebot und Nutzerprofilen

Der wichtigste Vorteil der automatisierten Interaktion mit Web-Angeboten liegt in der Reliabilität, der Validität und Replizierbarkeit der Erhebungen (King, 1995). Voraussetzung dafür ist, dass ein Computerprogramm mit dem Angebot so interagieren kann, dass es dieselben Inhalte erhält, die auch ein menschlicher Nutzer sehen würde. Damit automatisierte Anfragen authentisch erscheinen, müssen sie einen Internet-Browser starten und darin Aktionen wie die Eingabe

von Text oder Mausklicks auslösen können. Für die Evaluation und Tests von Software wurden mehrere Programme entwickelt, die das erlauben: Projekte wie Selenium und PhantomJS erlauben dem Forscher, Aktionen innerhalb des Browsers zu automatisieren, ohne dass dieser auf dem Bildschirm sichtbar sein muss. Für die Messung der Google-Personalisierung wurde ein Programm erstellt, das PhantomJS nutzt, um zunächst einen neu angelegten Nutzer bei Google anzumelden. Dazu startet das Programm den Browser, öffnet die Google-Startseite, klickt auf den Link zur Anmeldung, trägt Benutzername und Passwort ein und landet schließlich erneut auf der Startseite. Bei jedem weiteren Start wird für den jeweiligen Nutzer der Login-Status über Cookies wieder hergestellt.⁷

Kontrolle von Kontextvariablen

Bei der automatisierten Verwendung der Google-Suchmaschine besteht stets die volle Kontrolle über alle technischen Merkmale des Browsers. Sofern keine Cookies geladen werden, startet das Programm bei jedem neuen Durchlauf in einem deterministischen, neutralen Zustand und übermittelt deshalb keine profilbezogenen Daten. So wird sichergestellt, dass die Webseite jeweils nur exakt die vorgesehene Nutzerinteraktion als Input erhält und nicht auf Spuren vergangener Nutzung (z.B. bestehende Cookies) zurückgreift. Sofern das Programm stets auf demselben Computer läuft, sind auch Änderungen der IP-Adresse bzw. des Ortes als Einfluss auf Personalisierung ausgeschlossen.

Stimulation von Personalisierung

Nachdem der Zugang zu dem jeweiligen Webangebot – hier Google – besteht, wird die Personalisierung durch gezielte Nutzung stimuliert. Dies setzt zumindest eine einfache Annahme voraus, welches Verhalten die Grundlage für die Anpassungen des Algorithmus bildet. Hierzu muss aus der Fachliteratur, aus firmeneigenen Publikationen und Experteninterviews zumindest ein plausibler Verhaltensindikator ermittelt werden, von dem angenommen wird, dass er sich auf die Personali-

7 Siehe hierzu die Dokumentation von PhantomJS: <http://phantomjs.org/api/phantom/property/cookies.html> bzw. Selenium http://docs.seleniumhq.org/docs/03_webdriver.jsp#cookies

sierung auswirkt. Die Google-Suche protokolliert nicht nur, welche Suchanfragen ein Rezipient sendet, sondern auch, auf welche Ergebnisse er klickt. Daher bestand die Manipulation aus regelmäßigen Suchen, bei denen jeweils zwei Nutzer nach Begriffen aus zwei unterschiedlichen Bereichen eines Themas suchten (zur Entwicklung des Stimulusmaterials siehe Jürgens et al., 2014). Nach jeder Suche wurde ein zufällig ausgewählter Link der ersten Ergebnisseite angeklickt (siehe Beispieldesign in Tabelle 1).

Für das Design der Manipulation ist die Anknüpfung an die eingangs beschriebenen Verzerrungstypen sinnvoll, um zum Beispiel wie im angeführten Beispiel auf simple Unterschiede zwischen zwei Profilen zu schließen. Prinzipiell ist es allerdings auch möglich, Personalisierung mit mehr als zwei Ausprägungen der Manipulation zu konzipieren, wenn etwa überprüft werden soll, ob die Anpassung an Nutzerinteressen bei verschiedenen politischen Präferenzen identisch ausfallen. Dann sind jeweils so viele simulierte Nutzer nötig wie Ausprägungen der UV vorhanden.

Tabelle 1: Beispiel eines Experimentaldesigns

Faktor: Bedeutungsebenen des Wortes „Stollen“	Treatment	Messung
<i>Experimentalnutzer 1</i>	<i>Sucht nach Begriffen rund um Weihnachten</i>	
<i>Experimentalnutzer 2</i>	<i>Sucht nach Begriffen rund um Bergbau</i>	<i>Suche nach „Stollen“</i>
<i>Kontrollsuche</i>	<i>Keine Suche</i>	

Messung der Personalisierung

Der eigentliche Test auf Personalisierung erfolgt in regelmäßigen Abständen durch den Vergleich eines einheitlichen Stimulus. Im Fall von Google sind dies Ergebnislisten, die beide Nutzer zu ein und demselben themenbezogenen Suchbegriff erhalten. Erhält ein Nutzer Treffer angezeigt, die dem anderen Profil feh-

len und gleichzeitig mit den Stimulus-Suchanfragen zusammen hängen, dann kann davon ausgegangen werden, dass dies eine Folge der Anpassung an das Nutzerprofil, also ein personalisiertes Ergebnis ist. Da Computersysteme deterministisch vorgehen ist für die Verallgemeinerung der Ergebnisse keine Stichprobe nötig: Wird die Personalisierung einmalig nachgewiesen, gilt das Ergebnis zumindest solange der Anbieter den Algorithmus nicht ändert. Für die Google-Suche konnten auch nach vierwöchiger Simulation keine nennenswerten, insbesondere keine mit dem Stimulus zusammenhängenden Personalisierungen nachgewiesen werden (eine ausführliche Darstellung findet sich in Jürgens et al., 2014).

In einer vereinfachten Darstellung läuft eine automatisierte Erhebung nach dem folgenden universellen Schema ab:

Tabelle 2: Ablauf eines Online-Experiments zur Messung von Personalisierungseffekten

1	Start des Browsers und laden des Skripts, das den Ablauf der Studie in Programmform beschreibt
	ggf. Laden von nutzerbezogenen Daten aus Cookies oder Login eines Nutzers
2	Öffnen der Initial-URL (z.B. Startseite des Angebots)
3	UV: Interaktion mit dem System mit dem Ziel, Personalisierung auszulösen. Dazu Durchführung von Handlungen, die aus der Vorrecherche mit der Personalisierung in Verbindung gebracht werden (z.B. „Liken“ von Artikeln, Suche nach Begriffen).
4	Protokollierung des Outputs durch Screenshots, Speichern des Quellcodes der Seite oder gezielte Extraktion von Daten
...	Beliebige Wiederholungen von Schritt 3 und 4
5	Messung von Personalisierungseffekten: Vergleich des System-Outputs bei identischen Nutzeranfragen (z.B. Vergleich der Zusammenstellung der Startseite)
6	Abmeldung, Beenden des Browsers, Speicherung der erhobenen Daten

5 Ausblick: Chancen und Risiken

Sozialwissenschaftler sind mit ihren Forschungsinteressen im Internet Leidtragende von rasch fortschreitender technischer Innovation, einem Wettrennen zwischen Anbietern und Manipulationsversuchen durch Dritte (siehe exemplarisch zu der Ko-Evolution von Suchmaschinen und deren Manipulation Metaxas, 2010; zu Spam siehe Brunton, 2013). In diesem „Arms Race“ versuchen Betreiber von Online-Webseiten der gezielten Manipulation ihrer Angebote – sei diese ökonomisch oder ideologisch motiviert – einen Riegel vorzuschieben (siehe etwa den Überblick bei Zerkowitz, 2011; und Jakobsson, 2012). Hierzu setzen sie verstärkt Lösungen ein, die automatisierte Anfragen verhindern, etwa indem Nutzer verzerrten Text lesen und in ein Formular eintippen müssen (sogenannte „Captchas“). Die Online-Forschung steht somit vor dem Problem, durch die veränderte Funktionsweise von Angeboten stärker auf automatisierte Verfahren angewiesen zu sein, während deren Einsatz gleichzeitig einen immer höheren technischen Aufwand mit sich bringt.

Sowohl automatisierte Erhebungen als auch die Simulation von Nutzerverhalten versprechen jedoch nicht nur validere, reliablere und replizierbare Erhebungen, sondern eröffnen der Kommunikationswissenschaft Zugang zu den Inhalten und Funktionsweisen von personalisierten Webangeboten. Bislang müssen sich Erhebungen zum Beispiel von der Nutzung von Nachrichtenwebseiten und sozialen Netzwerkseiten auf Daten verlassen, die vom Betreiber bereitgestellt werden (z.B. Protokolldaten, siehe Pass, Chowdhury, & Torgeson, 2006; und kritisch Zimmer, 2010). Die beschriebene Methode systematisiert dagegen die „normale“ Benutzung der Angebote und kann deshalb ohne privilegierten Zugriff durchgeführt werden, was den Forscher von einem Entgegenkommen des Anbieters unabhängig macht. Das „Verkörpern“ des Nutzers als Kunstpersona kann so helfen, intransparente, technisch determinierte Effekte aufzudecken. Die Vorgehensweise knüpft dabei an Erfahrungen aus der Experimentalforschung an und macht sich deren Stärke in der Formulierung von Fragestellungen und Hypothesen zu nutzen.

Eine Investition in die Methodenentwicklung kann langfristig die Beobachtbarkeit des digitalen Kommunikationsraums sichern (King, 2011). Die hier aufgezeigte Methodeninnovation wird – ebenso wie parallele Entwicklungen aus dem Bereich der *Digital Methods* (Rogers, 2013) – zusätzlich umso wichtiger, je stärker der durchschnittliche Forschungsaufwand von Studien in einer fortwährend

wachsenden digitalen Landschaft steigt (Lazer, Pentland, Adamic, Aral, Barabási, Brewer, et al., 2009). Der mit technischen Weiterentwicklungen steigende Aufwand setzt allerdings entweder interdisziplinäre Kooperationen mit der Informatik oder aber den Einkauf spezialisierter Expertise voraus.

Pascal Jürgens, M.A. ist wissenschaftlicher Mitarbeiter am Institut für Publizistik der Johannes Gutenberg-Universität Mainz

Prof. Dr. Birgit Stark ist Professorin für Kommunikationswissenschaft am Institut für Publizistik der Johannes Gutenberg-Universität Mainz

Dr. Melanie Magin ist Akademische Rätin am Institut für Publizistik der Johannes Gutenberg-Universität Mainz

Quellenverzeichnis

- Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734-749. doi: 10.1109/TKDE.2005.99
- Bucher, T. (2012). Want to be on the top? Algorithmic power and the threat of invisibility on Facebook. *New Media & Society*, 14(7), 1164-1180. doi: 10.1177/1461444812440159
- Brunton, F. (2013). *Spam*. MIT Press.
- Das, A. S., Datar, M., Garg, A., & Rajaram, S. (2007). Google News Personalization: Scalable Online Collaborative Filtering. *Proceedings of the 16th International Conference on World Wide Web* (S. 271-280), New York, NY, USA: ACM. doi: 10.1145/1242572.1242610
- Diaz, A. (2008). Through the Google Goggles: Sociopolitical Bias in Search Engine Design. In A. Spink & E. Zimmer (Hrsg.), *Web Search: Multidisciplinary Perspectives* (S. 11-34). Berlin: Springer. doi: 10.1007/978-3-540-75829-7_2
- Fan, H., & Poole, M. S. (2006). What Is Personalization? Perspectives on the Design and Implementation of Personalization in Information Systems. *Journal of Organizational Computing and Electronic Commerce*, 16(3-4), 179-202. doi: 10.1080/10919392.2006.9681199

- Feitelson, D. G. (2006). Experimental computer science: The need for a cultural change. Abgerufen von <http://www.cs.huji.ac.il/~feit/papers/exp05.pdf>
- Friedman, B., & Nissenbaum, H. (1996). Bias in computer systems. *Transactions on Information Systems*, 14(3), 330-347. doi: 10.1145/230538.230561
- Friedman, B., & Kahn, P. H., Jr. (2008). Human values, ethics, and design. In A. Sears & J. A. Jacko (Hrsg.), *The Human-Computer Interaction Handbook*. Hillsdale, NJ, USA: Lawrence Erlbaum Associates.
- Garrett, R. K., Carnahan, D., & Lynch, E. K. (2013). A Turn Toward Avoidance? Selective Exposure to Online Political Information, 2004-2008. *Political Behavior*, 35(1), 113-134. doi: 10.1007/s11109-011-9185-6
- Google (2014). Custom Search JSON/Atom API. Abgerufen von <https://developers.google.com/custom-search/json-api/v1/overview>
- Granka, L. A. (2010). The Politics of Search: A Decade Retrospective. *The Information Society*, 26(5), 364-374. doi: 10.1080/01972243.2010.511560
- Hindman, M. (2009). *The myth of digital democracy*. Princeton, NJ: Princeton UP.
- Jannach, D., Zanker, M., Felfernig, A., & Friedrich, G. (2010). *Recommender Systems*. Cambridge University Press.
- Jakobsson, M. (2012). *The Death of the Internet*. John Wiley & Sons.
- Jürgens, P., Stark, B., & Magin, M. (2014). Gefangen in der Filter Bubble? Search Engine Bias und Personalisierungsprozesse bei Suchmaschinen. In B. Stark, D. Dörr, & S. Aufenanger (Hrsg.), *Die Googleisierung der Informationssuche. Suchmaschinen zwischen Nutzung und Regulierung* (S. 89-135). Berlin, Boston: De Gruyter.
- King, G. (1995). Replication, Replication. *Political Science and Politics*, 28(3), 444-452. doi: 10.2307/420301
- King, G. (2011). Ensuring the Data-Rich Future of the Social Sciences. *Science*, 331(6018), 719-721. doi: 10.1126/science.1197872
- Kohavi, R., Longbotham, R., Sommerfield, D., & Henne, R. M. (2009). Controlled experiments on the web: survey and practical guide. *Data Mining and Knowledge Discovery*, 18(1), 140-181. doi: 10.1007/s10618-008-0114-1
- Lazer, D., Pentland, A., Adamic, L., Aral, S., Barabási, A.-L., et al. (2009). Computational Social Science. *Science*, 323(5915), 721-723. doi: 10.1126/science.1167742
- Lyman, P. (2002). Archiving the World Wide Web. Building a National Strategy for Preservation: Issues in Digital Media Archiving. Council on Library and Information Resources Washington, D.C. and Library of Congress, Page 38-51. Abgerufen von <http://www.clir.org/PUBS/reports/pub106/pub106.pdf>

- MacCaw, A. (2011). *JavaScript Web Applications*. O'Reilly Media, Inc.
- Masanès, J. (2005). Web Archiving Methods and Approaches: A Comparative Study. *Library Trends*, 54(1), 72-90. doi: 10.1353/lib.2006.0005
- Masanès, J. (2006). *Web archiving*. Berlin: Springer.
- Mason, R. L., Gunst, R. F., & Hess, J. L. (2003). *Statistical Design and Analysis of Experiments*. John Wiley & Sons.
- McGeoch, C. C. (2002). Experimental Analysis of Algorithms. In P. M. Pardalos & H. E. Romeijn (Hrsg.), *Handbook of Global Optimization, Volume 2* (S. 489-513). Boston, MA: Springer US. doi: 10.1007/978-1-4757-5362-2_14
- Metaxas, P. T. (2010). Web Spam, Social Propaganda and the Evolution of Search Engine Rankings. In J. Cordeiro & J. Filipe (Hrsg.), *Web Information Systems and Technologies. 5th International Conference, WEBIST 2009, Lisbon, Portugal, March 23-26, 2009, Revised Selected Papers* (S. 170-182). Berlin, Heidelberg: Springer. doi: 10.1007/978-3-642-12436-5_13
- Mitchell, M. (2009). *Complexity: A Guided Tour*. Oxford University Press.
- Mooney, C. (1997). *Monte Carlo Simulation*. Sage Publications.
- Pan, B., Hembrooke, H., Joachims, T., Lorigo, L., Gay, G., & Granka, L. (2007). In Google We Trust: Users' Decisions on Rank, Position, and Relevance. *Journal of Computer-Mediated Communication*, 12(3), 801-823. doi: 10.1111/j.1083-6101.2007.00351.x
- Pariser, E. (2011). *The Filter Bubble: What The Internet Is Hiding From You*. London: Penguin UK.
- Pass, G., Chowdhury, A., & Torgeson, C. (2006). A Picture of Search. *Proceedings of the 1st International Conference on Scalable Information Systems*, New York, NY, USA: ACM. doi: 10.1145/1146847.1146848
- Paxson, V. (2004). Strategies for sound internet measurement. *Proceedings of the 4th ACM SIGCOMM Conference*, 263-271. doi: 10.1145/1028788.1028824
- Pitkow, J., Schütze, H., Cass, T., Cooley, R., Turnbull, D., Edmonds, A., et al. (2002). Personalized search. *Communications of the ACM*, 45(9), 50-55. doi: 10.1145/567498.567526
- Reid, A. (2014, 20. Mai). Can personalisation save the news homepage? [journalism.co.uk](http://www.journalism.co.uk). Abgerufen von <http://www.journalism.co.uk/news/can-personalisation-save-the-news-homepage-/s2/a556786/>
- Rieder, B. (2004). Algorithmische Mediatoren: Software-Agenten als Gegenstand der Medienwissenschaften. *Medien Journal*, 28(1), 36-46.

- Ricci, F., Rokach, L., Shapira, B., & Kantor, P. B. (2010). *Recommender Systems Handbook*. New York: Springer.
- Rogers, R. (2013). *Digital Methods*. Cambridge, MA: MIT Press.
- Springer, R. (2014, 26. Mai). Personalizing Personalization: It's About More Than Just Knowing Your User's Name. *EContent*. Abgerufen von <http://www.econtentmag.com/Articles/News/News-Feature/Personalizing-Personalization-Its-About-More-Than-Just-Knowing-Your-Users-Name-96731.htm>
- Sundar, S. S., & Marathe, S. S. (2010). Personalization versus Customization: The Importance of Agency, Privacy, and Power Usage. *Human Communication Research*, 36(3), 298-322. doi: 10.1111/j.1468-2958.2010.01377.x
- Sunstein, C. R. (2009). *Republic.com 2.0*. Princeton, PA: Princeton University Press.
- Taneja, H., & Wu, A. X. (2013, 15. Mai). Does the Great Firewall really isolate the Chinese? Integrating access blockage with cultural factors to explain web user behavior. *arXiv.org*. Abgerufen von <http://arxiv.org/abs/1305.3311>
- Teevan, J., Dumais, S. T., & Horvitz, E. (2010). Potential for personalization. *ACM Transactions on Computer-Human Interaction*, 17(1), 1-31. doi: 10.1145/1721831.1721835
- Tichy, W. F., Lukowicz, P., Prechelt, L., & Heinz, E. A. (1995). Experimental evaluation in computer science: A quantitative study. *Journal of Systems and Software*, 28(1), 9-18. doi: 10.1016/0164-1212(94)00111-Y
- Zelkowitz, M. (2011). *Security on the Web*. London u.a.: Academic Press.
- Zimmer, M. (2010b). "But the data is already public": On the ethics of research in Facebook. *Ethics and Information Technology*, 12(4), 313-325.