

Algorithmisierte Medienumgebungen

Anna Sophie Kümpel & Martin Fischer

Abstract

Der Beitrag beschäftigt sich mit der Funktionsweise und den Auswirkungen algorithmisierter Medienumgebungen, in denen Inhalte automatisiert personalisiert an Nutzer*innen ausgespielt werden (z.B. Social-Media-Plattformen). Nach einer grundlegenden Einordnung des Phänomens werden die Wirkungen von und in algorithmisierten Medienumgebungen differenziert beschrieben. Diskutiert werden *Wirkungen erster Ebene*, die sich aus dem nutzerseitigen Umgang mit entsprechenden Kanälen/Plattformen ergeben und etwa die Ausbildung eines algorithmischen Bewusstseins umfassen. *Wirkungen zweiter Ebene* beziehen sich auf gesellschaftliche Implikationen wie die vermeintliche Verengung von Informations- und Diskursräumen sowie Effekte auf politisches Wissen, Interesse und Partizipation. Das Fazit greift zudem methodische Herausforderungen bei der Untersuchung von Medienwirkungen in algorithmisierten Umgebungen auf.

Keywords: Algorithmen, Informationsnutzung, Medienwirkungen, Personalisierung, Politisches Verhalten, Social-Media-Plattformen

1. Einleitung

Die Informationsmengen, mit denen wir täglich durch multimediale Umgebungen konfrontiert sind, wachsen kontinuierlich, weshalb auch die *Auswahl* dieser Inhalte stetig an Bedeutung gewinnt. Sei es das Internet mit Millionen Websites, dutzende konkurrierende Fernsehsender, eine ganze Bandbreite von journalistischen Publikationen oder schlicht die alltägliche Reizüberflutung in der Innenstadt: Wir sind als Menschen nicht dafür geschaffen, permanent eine so große Menge an Informationen zu verarbeiten. Unausweichlich müssen wir daher zwischen diesen konkurrierenden Informationsangeboten auswählen (siehe Früh in diesem Band) – oder für uns auswählen lassen. Während dabei Auswahl- und Priorisierungsprozesse durch Dritte auch historisch eine wichtige Rolle gespielt haben – denken wir etwa an Journalist*innen, Filmkritiker*innen oder Empfehlungen durch das soziale Umfeld –, ist spätestens im Zeitalter von

Social-Media-Plattformen ein neuer Kurator hinzugetreten: der *Algorithmus* (Thorson & Wells, 2016; Wallace, 2018). Diese „schrittweisen Prozeduren für das Lösen von Problemen“ (Herzog, 2021, S. 199) erlauben eine Personalisierung von Inhalten, die zuvor nur in Ansätzen erreicht werden konnte. Binnen weniger Jahre haben sich die medialen Nutzungsgewohnheiten so nachhaltig verändert. Dieser Wandel ist auch in Hinblick auf internetbasierte Medien neu: Völlig selbstverständlich erwarten Nutzer*innen inzwischen, dass sich Plattformen an ihre Nutzungsmuster anpassen und individuelle Vorschläge unterbreiten (Bhandari & Bimo, 2022, S. 2).

Tatsächlich findet heute ein erheblicher Teil der informations- sowie unterhaltungsbezogenen Mediennutzung in sogenannten *algorithmisierten Medienumgebungen* wie Social-Media- oder Video-Plattformen statt (Behre et al., 2024; Müller, 2024). Die von mathematischen Modellen und Verhaltensdaten unterfütterten Algorithmen erstellen automatisiert Musik- oder Video-Playlists, empfehlen uns die nächste Serie für einen Streaming-Marathon oder schlagen uns Produkte für den Kauf vor. Dabei laufen im Hintergrund komplexe Prozesse der Klassifizierung, Priorisierung und Filterung ab, die eine große Menge an sehr unterschiedlichen Nutzungs- und Verhaltensdaten auswerten (DeVito, 2017; Ricci et al., 2015; Schwartz & Mahnke, 2021). Oft zeichnen sich diese Prozesse durch ein hohes Maß an Intransparenz hinsichtlich der genauen Funktionslogik aus, was die wissenschaftliche Analyse und folglich auch den gesellschaftlich-kritischen Umgang mit ihnen erschwert. Wenn man bedenkt, dass gerade stark algorithmisch kuratierte Plattformen wie TikTok zunehmende Relevanz auch für den politischen Diskurs erfahren (Granow & Scolari, 2022), erscheint es unausweichlich, sich mit den Auswirkungen dieser neuen Klasse von Kuratoren auseinanderzusetzen. Entsprechend zielt das vorliegende Kapitel darauf ab, zu skizzieren, was algorithmisierte Medienumgebungen auszeichnet und welche Auswirkungen auf Nutzer*innen und Gesellschaft zu beobachten sind.

Angesichts der Tatsache, dass entsprechende Phänomene oft mit wenig analytischer Trennschärfe diskutiert werden, müssen zunächst einige Begriffsklärungen vorgenommen sowie die Funktionen skizziert werden, die Algorithmen im Kontext der Mediennutzung übernehmen. Im Anschluss werden die eigentlichen Wirkungen *von* und *in* algorithmisierten Medienumgebungen in den Blick genommen: Wir unterscheiden dabei zwischen Wirkungen *erster Ebene* und Wirkungen *zweiter Ebene*: Während erstere sich aus dem Umgang von Nutzer*innen mit algorithmisierten Medienumgebungen ergeben (z.B. Bewusstsein über algorithmische Kuratierung, ‚Trainieren‘ von Algorithmen), bezeichnen zweitere die vor allem im Kontext der Informationsnutzung diskutierten gesellschaftlichen Implikationen (z.B. Verengung von Informations-

und Diskursräumen) sowie individuelle Wirkungen auf demokratietheoretisch relevante Zielgrößen wie politisches Wissen, Interesse und Partizipation. Wir schließen mit einem knappen Fazit, welches auch methodische Problemlagen bei der Untersuchung von Medienwirkungen in algorithmisierten Medienumgebungen adressiert.

2. Grundlagen: Algorithmisierte Medienumgebungen

Der Begriff des ‚Algorithmus‘ steht im Mittelpunkt von Diskussionen über Veränderungen der digitalen Medienlandschaft. Umso wichtiger ist es, zu klären, was genau unter Algorithmen und spezifisch unter algorithmisierten Medienumgebungen verstanden wird. Zudem ist zur Einschätzung von Wirkungsprozessen von und in algorithmisierten Medienumgebungen auch ein Blick auf die übergeordneten Funktionen von Algorithmen nötig.

2.1. Begriffsklärungen

Für Softwareingenieur*innen sind *einzelne* Algorithmen sehr kleinteilig, eine klare Abfolge von Anweisungen, die beschreiben, wie ein bestimmtes *Problem* gelöst werden soll (Herzog, 2021, S. 199): „An algorithm is a recipe composed in programmable steps“ (Gillespie, 2016, S. 19). Klassisches Beispiel hierfür sind etwas Sortieralgorithmen: Wie kann eine Liste von beliebig angeordneten Zahlen oder Wörtern z.B. in aufsteigender Reihenfolge angeordnet werden (vgl. dazu etwa Güting & Dieker, 2004)? Abstrakt formuliert steht bei Algorithmen einem definierten Input ein bestimmter gewünschter Output entgegen. Dieses grundlegende Prinzip lässt sich übertragen auf diverse, von Informationstechnologie durchdrungene Medienbereiche: Anbieter von Diensten versuchen, ebenjene an die Bedürfnisse ihrer Nutzer*innen anzupassen; dafür entwickeln sie zunehmend komplexe Prozeduren, um beispielsweise Inhalte oder Werbung möglichst zielgenau anzubieten (Eg et al., 2023).

Im öffentlichen Diskurs ist häufig von *dem* Spotify- oder *dem* TikTok-Algorithmus die Rede; eine Vereinfachung, die die tatsächlich existierenden komplexen Selektionsprozesse nur unzureichend abbildet (Kitchin, 2017; Seaver, 2019; Silva et al., 2022). Ein derartiger Fokus auf den Algorithmus als entscheidenden Mechanismus birgt zudem das Risiko, den Blick auf die komplex verwobenen technischen und menschlichen Komponenten der Systeme zu verstellen (Seaver, 2019). Schlussfolgernd wird im akademischen Kontext zumeist nicht von ‚den Algorithmen‘ gesprochen, sondern durch die Einbettung in ihren systemischen Kontext von „algorithmischen Medien“ (Bucher, 2020) oder – wie im Titel dieses Beitrags – von algorithmischen

bzw. algorithmisierten Medienumgebungen. Letztere umfassen konkret *alle technischen Kanäle oder Plattformen, die Medieninhalte auf Basis von algorithmischen Systemen automatisiert personalisieren*, also Inhalte basierend auf implizit und explizit generierten Präferenzprofilen an ihre Nutzer*innen ausspielen (siehe dazu Kümpel, 2025; Silva et al., 2022; Schweiger et al., 2019).

Der Begriff der Personalisierung stellt den definitorischen Kern algorithmisierter Medienumgebungen dar. Im Einklang mit der bestehenden Literatur (Bozdag, 2013; Thorson & Wells, 2016; Zuiderveen Borgesius et al., 2016) lassen sich zwei Idealtypen von Personalisierung unterscheiden: Implizite und explizite Personalisierung. *Implizite Personalisierung* umfasst das Ableiten der Präferenzen der Nutzer*innen aus den Verhaltenssignalen ebenjener, um basierend darauf Inhalte auszuwählen. In modernen algorithmisierten Medienumgebungen wird hierfür eine breite Palette von Daten herangezogen, von Interaktionsdaten über den Standort bis hin zu sozialen Kontakten. *Explizite Personalisierung* wiederum umfasst die eigenständige Kuratierung von Inhalten durch Nutzer*innen – etwa, wenn sie aktiv bestimmten Accounts folgen oder gegenüber dem System Präferenzen artikulieren (bspw. durch Likes). Beide Formen der Personalisierung wirken schließlich zusammen, um für Nutzer*innen individualisierte Inhalte anzubieten.

Über die konkreten Funktionsmechanismen von Personalisierungssystemen kursieren popkulturell zahllose Spekulationen; die genauen Funktionsweisen der großen Plattformen werden indes wie kaum ein anderes Geschäftsgeheimnis gehütet. Zwar haben inzwischen einige Plattformbetreiber Einblicke in die Funktionsweise ihrer Empfehlungssysteme gewährt und mithin die Erschließung der grundlegenden Algorithmen ermöglicht – die genauen Gewichtungen und Details bleiben jedoch vage (siehe z.B. Amatriain & Basilico, 2017; Mosseri, 2023; TikTok, 2019). Moderne Personalisierungssysteme sind somit weitestgehend eine *Black Box* (Diakopoulos, 2015; Hargittai et al., 2020; Heise, 2016), was sowohl aus einer gesellschaftlichen als auch einer forschungspraktischen Perspektive problematisch ist (Kitchin, 2017).

Nichtsdestotrotz lassen sich durch gezielte Variation von vermuteten Input-Variablen der Empfehlungsalgorithmik gewisse Rückschlüsse auf deren Wirken ziehen (Diakopoulos, 2015; Grandinetti & Bruinsma, 2023; Hilbert et al., 2019; Thorson et al., 2021). Die Befunde entsprechender Studien deuten auf die Dominanz zweier Faktoren hin, die Personalisierungsprozesse

anleiten: *Persönliche Relevanz* sowie *positive Nutzungserfahrungen*. Jedoch existieren aufgrund der Heterogenität algorithmisierter Medienumgebungen durchaus Unterschiede zwischen den verschiedenen Plattformen. Es gibt Hinweise darauf, dass Facebook vor allem explizit artikuliert Interessen sowie bisherige Bewertungs-, Kommentierungs- und Weiterverbreitungsmuster berücksichtigt (DeVito, 2017). Netflix wiederum scheint mehr Wert auf implizite Inferenz von Präferenzen aus Seh dauern sowie über ‚Taste-Communities‘ (Cluster von Nutzer*innen, die ähnliche Präferenzen aufweisen) zu legen (Gaw, 2022), während explizite Personalisierung hier wie bei vielen anderen visuellen Plattformen eine geringere Rolle zu spielen scheint (Narayanan, 2023). Das Primat persönlicher Relevanz und positiver Nutzungserfahrungen wird auch in der Selbstdarstellung der großen Plattformen sichtbar. Instagram sagt etwa von sich selbst, „[w]e want to make the most of people’s time“ (Mosseri, 2023), während Netflix es als sein Ziel beschreibt, jene Titel zu empfehlen, „that a member is most likely to play and enjoy“ (Amatriain & Basilico, 2017). TikTok wiederum möchte Nutzer*innen helfen, „content and creators you love“ zu finden (TikTok, 2019). Normative Zielgrößen wie Vielfalt, Ausgewogenheit, gesellschaftliche Relevanz oder Informationsqualität – die gerade für die Nutzung und Wirkung von Informationsinhalten bedeutsam sind – spielen hingegen in aller Regel keine Rolle (Binst et al., 2024).

2.2. Funktionen von Algorithmen

Die Palette an Funktionen, die durch algorithmische Systeme auf modernen Plattformen übernommen wird, ist breit (siehe nachfolgend Diakopoulos, 2015; Just & Latzer, 2017; Kümpel, 2025): Sie klassifizieren Inhalte und ordnen sie bestimmten Kategorien zu (Klassifikations-Algorithmen), stellen Beziehungen zwischen Inhalten her (Assoziations-Algorithmen) und – am sichtbarsten – legen fest, welche dieser Inhalte wie angezeigt werden (Filter- und Priorisierungs-Algorithmen). Durch das Zusammenspiel dieser Funktionen bestimmen algorithmische Systeme den Informationsfluss der Gesellschaft maßgeblich mit und übernehmen jene Rolle, die man klassischerweise als *Gatekeeper* bezeichnet (Bozdag, 2013; Hagen et al., 2017; Soffer, 2021; Thorson & Wells, 2016; Wallace, 2018). Mit Blick auf die Wirkung von und in algorithmisierten Medienumgebungen spielt insbesondere der Teilaspekt der Priorisierung und Filterung eine Rolle. Diese häufig auch als *Empfehlungs-Algorithmen* bezeichneten Prozeduren bilden mithin den Fokus der nachfolgenden Betrachtungen.

Grundsätzlich lassen sich für Empfehlungs-Algorithmen drei Archetypen von Filtertechniken identifizieren (Schmidt et al., 2018): *Inhaltsbezogene Filtertechniken* empfehlen Inhalte, die jenen ähneln, die von den jeweiligen Nutzer*innen in der Vergangenheit (bestenfalls positiv) rezipiert wurden. *Kollaborative Filtertechniken* wiederum gleichen die Profile ähnlicher Nutzer*innen ab und generieren auf diese Weise Empfehlungen – ein Beispiel dafür sind die zuvor bereits angesprochenen ‚Taste-Communities‘. *Kontextbezogene Filtertechniken* zuletzt beziehen diverse Rahmenbedingungen wie Uhrzeit, Standort oder verwendete Peripheriegeräte ein, um neue Vorschläge zu liefern.

Bei aller medialer Kritik an Empfehlungs-Algorithmen gilt es zu verstehen, dass diese sowohl für Nutzer*innen als auch für Plattformbetreiber grundsätzlich erst einmal nützliche Funktionen übernehmen (sollen). Nutzer*innen helfen sie, mit der eingangs diskutierten Informationsflut umzugehen, indem sie eine Vorauswahl basierend auf ihren individuellen Interessen liefern (Eg et al., 2023). Plattformbetreiber wiederum mögen zwar öffentlich den Nutzen für ihre User betonen, optimieren die Algorithmen jedoch primär hinsichtlich ihrer eigenen ökonomischen Ziele, die etwa über längere Verweildauern oder höheres User-Engagement erreicht werden können (Ricci et al., 2015; Silva et al., 2022). Gerade diese Zielmarken befinden sich jedoch häufig in einem Spannungsverhältnis zu normativen Zielgrößen wie gesellschaftlicher Relevanz, Informationsqualität und -vielfalt. Aus genau diesem Grund ist es essentiell, zu verstehen, dass Algorithmen nicht *neutral* sind, da sie in gleich zweifacher Hinsicht menschengemacht sind: Sowohl ihre Programmierung als auch ihre unmittelbare Steuerung obliegen nach wie vor Menschen. Dementsprechend manifestieren sich hier genau dieselben Biases, die ihren Erschaffer*innen, Nutzer*innen sowie den zugrundeliegenden Trainingsdaten zu eigen sind (Bartley et al., 2021; Reviglio & Agosti, 2020).

Der Bedeutungszuwachs neuer ‚algorithmischer‘ Gatekeeper führt – verbunden mit der Tatsache, dass Nutzer*innen sich diesen ohne vollständigem Verzicht kaum entziehen können – gleichzeitig zu einem Bedeutungsverlust klassischer Gatekeeper wie Journalist*innen (Zamith, 2019, S. 10). Während auch diese sich in ihrer Rolle stets Kritik ausgesetzt sahen, waren die unzweifelhaft ökonomischen Inzentiven der Verlage und Redaktionen gleichwohl eingehegt durch normative Leitplanken wie institutionalisierte Ausbildung, Berufsethos oder journalistische Aufsichtsgremien (Fengler, 2023).

3. Medienwirkung von und in algorithmisierten Umgebungen

Betrachtet man die Wirkungen von algorithmisierten Medienumgebungen, lässt sich zwischen verschiedenen Ebenen unterscheiden (siehe ähnlich Gil de Zúñiga & Cheng, 2024): Während Wirkungen *erster Ebene* sich daraus ergeben, wie Nutzer*innen mit entsprechenden Kanälen bzw. Plattformen umgehen und welche Nutzungsmuster sie im Umgang mit ‚den Algorithmen‘ entwickeln, sprechen wir mit Wirkungen *zweiter Ebene* jene Effekte an, die algorithmisierten Medienumgebungen mit Blick auf „democracy determinants“ (ebd., S. 6) zugeschrieben wird. Dazu zählen einerseits übergeordnete gesellschaftliche Implikationen wie die (vermeintliche) Verengung von Informations- und Diskursräumen, andererseits individuelle Wirkungen auf demokratiethoretisch relevante Zielgrößen wie politisches Wissen, Interesse und Partizipation.¹

3.1. Wirkungen erster Ebene

Mediennutzung findet heute zu großen Teilen in algorithmisierten Medienumgebungen statt (Müller, 2024; von Oehsen, 2024): Aber wie gehen Nutzer*innen mit diesem Tatbestand um – und ist ihnen überhaupt bewusst, dass Selektion und Priorisierung von Inhalten auf den entsprechenden Plattformen und Kanälen automatisiert personalisiert abläuft? Das Vorhandensein einer solchen *Algorithmic Awareness* (d.h. ein Wissen darüber, dass Algorithmen existieren und ‚am Werk‘ sind) kann wohl als grundlegendste Wirkung der Existenz von algorithmisierten Medienumgebungen gesehen werden (Oeldorf-Hirsch & Neubaum, 2023). Erste Studien in diesem Bereich wurden in einer Zeit durchgeführt, in der die algorithmische Personalisierung noch keine breite gesellschaftliche Aufmerksamkeit erlangt hatte, und deuteten darauf hin, dass vielen Nutzer*innen nicht klar zu sein schien, dass ihr Social-Media-Feed gefiltert ist (Eslami et al., 2016; Powers, 2017; Rader & Gray, 2015). Allgemeine Aussagen zur *Algorithmic Awareness* von Mediennutzer*innen gestalten sich jedoch schwierig, was vor allem an drei Gründen liegt (siehe auch Kümpel, 2025, S. 742): Erstens entwickeln sich die Plattformen und die ihnen

¹ Fraglos sind auch andere Einteilungen als die hier gewählte denkbar. So unterscheidet etwa Schweiger (2025) übergeordnet zwischen *individuellen* und *gesellschaftlichen* Effekten und unterteilt erstere in Wirkungen mit dem Bezugssystem „Medien & Kommunikation“ sowie „Politik & Gesellschaft“. Die von uns als Wirkungen erster Ebene beschriebenen Effekte wären demnach individuelle Effekte mit dem Bezugssystem „Medien & Kommunikation“, während wir mit Wirkungen zweiter Ebene sowohl gesellschaftliche Effekte als auch individuelle Effekte mit dem Bezugssystem „Politik & Gesellschaft“ ansprechen.

inhärenten – weitgehend intransparenten – algorithmischen Systeme kontinuierlich weiter. Zweitens ist das selbst zugeschriebene Wissen von Nutzer*innen über Algorithmen in den letzten Jahren insgesamt gestiegen (Overdiek & Petersen, 2022). Und drittens ist das Bewusstsein stark von der Aufdringlichkeit algorithmischer Systeme abhängig. So gilt etwa ‚der‘ TikTok-Algorithmus als „the most aggressive“ (Siles & Meléndez-Moran, 2021), weshalb Nutzer*innen hier nicht nur kontinuierlich an ablaufende Personalisierungsprozesse erinnert werden, sondern auch besonders zur Entwicklung von sog. *Folk Theories* neigen – informelle Annahmen über die Funktionsweise algorithmisierter Medienumgebungen (für einen Überblick siehe z.B. Dogruel, 2021; Oeldorf-Hirsch & Neubaum, 2023, S. 7).

Diese Theorien wiederum werden dann von den Nutzer*innen zum Einsatz gebracht, um algorithmische Systeme bewusst zu *trainieren*, indem strategisch mit gewünschtem Content interagiert wird (z.B. durch Likes, Erhöhung der Rezeptionsdauer), die Suchfunktion genutzt wird oder Inhalte, die künftige Empfehlungen ‚verschmutzen‘ könnten, explizit gemieden werden (Jones, 2023; Siles et al., 2024). Wird dieses Training als erfolgreich wahrgenommen, werden die aufgestellten Theorien an die gemachten Erfahrungen angepasst und prägen den weiteren Umgang mit algorithmisierten Medienumgebungen (ebd.). Eng damit verknüpft ist das grundlegende Vertrauen in Algorithmen: Aktuelle Studien zeigen diesbezüglich, dass Nutzer*innen bisweilen gar eine als *Algorithmic Conspiratorship* bezeichnete Vorstellung entwickeln, nach der Algorithmen nicht nur als technische Systeme verstanden werden, sondern als nahezu schicksalshafte Kräfte, die Inhalte im genau richtigen Moment liefern (Cotter et al., 2022).

3.2. Wirkungen zweiter Ebene

Neben dem skizzierten Umgang von Nutzer*innen mit algorithmisierten Medienumgebungen stehen vor allem die gesellschaftlichen Implikationen der Mediennutzung in algorithmisierten Umgebungen sowie individuelle Wirkungen auf demokratietheoretisch relevante Zielgrößen im Fokus kommunikationswissenschaftlicher Forschung. Obwohl selbstredend auch die unterhaltungsbezogene Nutzung in diesem Zusammenhang akademische Aufmerksamkeit verdient

(siehe auch Matthes, 2022; Schweiger et al., 2019, S. 120), konzentrieren sich die nachfolgenden Darstellungen auf den Kontext der (politischen) Informations- und Nachrichtennutzung und dabei insbesondere auf die Rolle von Social-Media-Plattformen.²

In der Öffentlichkeit waren algorithmisierte Medienumgebungen bislang primär Teil von kulturpessimistischen Diskursen, welche die möglichen Gefahren einer zunehmenden Personalisierung des Informationsangebots der Bevölkerung betonten. Oft wurde dabei die Sorge um sogenannte ‚Echokammern‘ und ‚Filterblasen‘ geäußert, sowie die damit verbundene Befürchtung negativer Auswirkungen auf den öffentlichen Diskurs (Geiß et al., 2018; Rau & Stier, 2019). Gleichzeitig gelten Social-Media-Plattformen immer wieder auch als wichtiger ‚Mobilisator‘ in politischen Debatten und mithin als Hoffnungsträger für die Ausbildung von politischem Wissen, Interesse oder Partizipation (Boulianne et al., 2020).

3.2.1 Filterblasen, Echokammern und Desinformation

Der Begriff der *Filterblase*, unter anderem popularisiert durch den amerikanischen Politaktivisten Eli Pariser (2011), wird oft in einem Atemzug mit jenem der *Echokammer* (Sunstein, 2001) genannt. Bei beiden handelt es sich um eng verwandte Phänomene, die pathologische Folgeerscheinungen von algorithmisierten Medienumgebungen metaphorisch beschreiben sollen. Eine Filterblase bezeichnet einen Zustand der Mediennutzung, in welchem Nutzer*innen primär mit Inhalten konfrontiert werden, die sich unmittelbar nach den eigenen Interessen richten. Analog dazu ist eine Echokammer ein Teilbereich des öffentlichen Raums, in welchem Nutzer*innen primär mit der eigenen Meinung konfrontiert werden, welche sich – wie ein Echo – selbst verstärkt (Messingschlager & Holtz, 2020). Die zentrale Folge dieser Pathologien für den öffentlichen Diskurs wiederum lässt sich unter dem Begriff der *Polarisierung* zusammenfassen (siehe Frischlich in diesem Band): Die zunehmende Spaltung der Gesellschaft in gegensätzliche Lager, welche sich durch extreme und vermeintlich unversöhnliche Einstellungen auszeichnen (DiMaggio et al., 1996). Angesichts der in Abschnitt 2 beschriebenen Gemengelage

² Dieser Fokus soll nicht in Abrede stellen, dass auch viele weitere individuelle und gesellschaftliche Effekte der Mediennutzung in algorithmisierten Umgebungen wissenschaftliche Aufmerksamkeit verdienen – und diese auch bekommen: So etwa Fragen nach dem Zusammenhang von Social-Media-Nutzung und dem psychologischen Wohlbefinden (Orben, 2020) oder den Effekten der durch algorithmische Logiken mitverantworteten Tendenz zu aufwärts gerichteten sozialen Vergleichen (McComb et al., 2023).

primär gewinnorientierter Plattformbetreiber und des schleichenden Wegfalls berufsethisch gebundener klassischer Gatekeeper erscheinen die genannten Folgeerscheinungen zunächst plausibel. Der aktuelle Stand der empirischen Forschung kann die Ängste um „algorithmic bubbles, chambers, and loops“ jedoch nicht bestätigen (Eg et al., 2023; siehe auch Möller, 2021; Stark et al., 2021). Im Gegenteil deuten aktuelle Untersuchungen auf positive Zusammenhänge zwischen der Nutzung von Social-Media-Plattformen und der Menge und vor allem Diversität genutzter Nachrichten hin, was u.a. auf die höhere Dichte an losen Verbindungen und mithin Netzwerk-Effekte zurückgeführt werden kann (Fletcher & Nielsen, 2018; Scharkow et al., 2020; siehe auch Schweiger et al., 2019, S. 77).

Gleichwohl wird angesichts beobachtbarer globaler Trends – etwa der Prävalenz von Inzivilität oder dem unter dem Begriff der ‚Enshittification‘ diskutierten Qualitätsverlust von Online-Diensten – klar, dass Social-Media-Plattformen den emanzipativen Hoffnungen ihrer Anfangszeit nur bedingt gerecht werden. Neben den beiden oben genannten Topoi ist es vor allem die Furcht vor *Desinformationen*, die in den frühen 2020er-Jahren die öffentliche Debatte um soziale Medien prägt, gerade im Zusammenhang mit Wahlkampagnen (siehe Denner in diesem Band). Desinformation ist dabei im weitesten Sinne jegliche Information, deren Rezeption zu Falschannahmen über die wirkliche Welt und speziell politischen Zusammenhänge führen kann (Tucker et al., 2018, S. 3). Es gestaltet sich als herausfordernd, die Verbreitung solcher Informationen einzudämmen – nicht zuletzt da die Anreizsysteme algorithmisierter Medienumgebungen die Sichtbarkeit derartiger Inhalte potenziell befördern. Gerade reißerisch aufgemachte (Falsch-)Informationen können schnell zu hohem Engagement, Viralität und damit zu rapider Verbreitung führen (Chen et al., 2023); eine automatisierte ‚Wahrheitsprüfung‘ ist sowohl technisch als auch normativ hochproblematisch (Wirtschaftler & Majumder, 2023). Die Betreiber großer Social-Media-Plattformen sehen sich in diesem Zusammenhang immer wieder mit Appellen aus der Zivilgesellschaft und Regulierungsversuchen politischer Organe konfrontiert, Mechanismen zur Eindämmung von Desinformationen zu entwickeln. Gerade hier stellt jedoch das Spannungsverhältnis zwischen ökonomischen Inzentiven und gesellschaftlicher Verantwortung der Plattformbetreiber ein demokratietheoretisches Problem dar, welches bisher keine adäquate Lösung gefunden hat.

3.2.2 Politisches Wissen, Interesse und Partizipation

Die unter ‚Filterblasen‘ und ‚Echokammern‘ zusammengefassten Wirkungen sowie die Debatte um Desinformationen fokussieren das übergeordnete Informationsökosystem sowie die gesamtgesellschaftlichen (und primär *negativen*) Implikationen algorithmisierter Medienumgebungen. Daneben gibt es eine Reihe von Studien, die sich stärker auf individuelle Effekte konzentrieren und dabei einen Schwerpunkt auf jene Zielgrößen legen, die aus demokratietheoretischer Sicht grundsätzlich als *positiv* und wünschenswert betrachtet werden: Politisches Wissen, politisches Interesse und politische Partizipation.

Politisches Wissen umfasst grundlegende Kenntnisse über politische Strukturen, Prozesse und aktuelle Themen. Bürger*innen mit besseren Kenntnissen sind eher in der Lage, Wahlentscheidung im Einklang mit ihren politischen Positionen zu treffen, beteiligen sich mehr und sind deutlich konsistenter in ihren Ansichten – drei Faktoren, die für das Funktionieren einer Demokratie essentiell sind (siehe dazu etwa Kleinberg & Lau, 2019). Die Medienforschung zeigt – intuitiv nachvollziehbar –, dass der Konsum von Nachrichten und politischen Inhalten einer der wichtigsten Faktoren für den Erwerb politischen Wissens ist (De Vreese & Boomgaarden, 2006; Graber, 2001; Lecheler & De Vreese, 2017). Doch wie hat sich dies unter den Bedingungen algorithmischer Personalisierung verändert und welche Implikationen hat es, dass immer mehr Menschen ihre Informationen nicht mehr (ausschließlich) über ‚klassische‘ Medienkanäle beziehen, sondern über Social-Media-Plattformen?

Der Forschungsstand zeichnet hier ein gemischtes Bild (Amsalem & Zoizner, 2023; Lorenz-Spreen et al., 2023). Einige Forscher*innen zeigen sich optimistisch und sind überzeugt, dass speziell das hohe Maß an Interaktivität einen positiven Beitrag zur politischen Wissensvermittlung leistet (Amsalem & Zoizner, 2023; siehe dazu auch im Detail Allcott et al., 2020; Bode, 2016; Gottfried et al., 2017). Dem gegenüber steht primär die bereits oben diskutierte Perspektive, die angesichts des diversitätsreduzierenden Potenzials von Personalisierungsprozessen mögliche Effekte auf das politische Wissen deutlich pessimistischer betrachtet. Eine wichtige vermittelnde Rolle scheint die *Algorithmic Literacy* der Nutzer*innen zu spielen, d.h. die Kompetenz und das Verständnis der Nutzer*innen im Umgang mit Empfehlungsalgorithmen (Silva et al., 2022). Erste Studien deuten an, dass Nutzer*innen mit höherer *Literacy* häufiger politische Inhalte auf Social-Media-Plattformen sehen (Boulianne & Hoffmann, 2024; Naderer et al., 2020), und dass dies auch zu mehr politischem Wissen führen kann (Park & Kaye, 2019). Die

Kehrseite zu einem kompetenten Umgang mit Algorithmen bildet das durch Personalisierungsalgorithmen populär gewordene Einstellungsmuster, welches als ‚News-finds-me‘-Wahrnehmung bezeichnet wird: Die Annahme, dass man nicht aktiv nach Informationen suchen muss, sondern allein durch den Konsum des personalisierten Feeds alle relevanten Nachrichten automatisch erfährt (Gil de Zúñiga & Cheng, 2024). Dieses Muster wiederum scheint sich negativ auf politisches Wissen auszuwirken (ebd.).

In der Summe haben algorithmisierte Medienumgebungen und speziell Social-Media-Plattformen jedoch keinen klaren Einfluss auf das politische Wissen ihrer Nutzer*innen – weder positiv, noch negativ, wie sich etwa in der umfangreichen Metaanalyse von Amsalem und Zoizner (2023) zeigt. Die Autoren werteten 76 Einzelstudien zum Thema aus und konnten auch bei Berücksichtigung von Plattformfokus, Region oder Zeitperiode im Mittel keinen Effekt der Social-Media-Nutzung auf das politische Wissen feststellen. Lediglich für die untersuchten Experimentalstudien zeigen sich geringe, aber statistisch signifikante Wissenszuwächse. Hier ist jedoch zu bedenken, dass das Gros der Erhebungen unter künstlichen (nicht-personalisierten) Bedingungen stattfindet, mit Forced-Exposure-Designs arbeitet und Wissen einmalig und unmittelbar nach der Informationsaufnahme erhebt. Der wahre Effekt dürfte mithin überschätzt sein (ebd., S. 10).

Politisches Interesse bezeichnet die grundsätzliche Motivation, sich mit politischen Themen zu befassen, insbesondere auch, Informationen zu politischen Themen aktiv zu suchen und zu rezipieren; auch hierbei handelt es sich um eine wichtige Determinante einer funktionierenden Demokratie (Gil De Zúñiga & Diehl, 2019; Lorenz-Spreen et al., 2023). Gerade auch als Voraussetzung *für* den Erwerb von politischem Wissen und für die politische Partizipation kommt dem Interesse an Politik eine entscheidende Vermittlerrolle zu. Wie also wirken sich algorithmisierte Medienumgebungen auf diesen Faktor aus? Der Forschungsstand lässt hier nur vorsichtige Schlussfolgerungen zu, da politisches Interesse vor allem als Prädiktor- oder Moderatorvariable berücksichtigt wurde (etwa in Barnidge, 2023; Feezell & Ortiz, 2021), jedoch nur selten als abhängige Variable (Ausnahmen z.B. Boulianne, 2015; Holt et al., 2013). Wie bereits für politisches Wissen, zeigt sich auch für politisches Interesse eine inverse Beziehung mit einer ausgeprägten ‚News-finds-me‘-Wahrnehmung (Gil de Zúñiga & Cheng, 2024): So scheint das Fehlen einer regelmäßigen *aktiven* Nachrichtennutzung das politische Interesse graduell zu re-

duzieren. Verschärft wird dies durch plattformspezifische Personalisierungsprozesse, die es gerade für Nutzer*innen mit einem geringen Grundinteresse an Politik unwahrscheinlich machen, ‚zufällig‘ über politische Inhalte zu stolpern (Kümpel, 2020; Thorson et al., 2021).

Politische Partizipation schließlich umfasst jegliche Form des aktiven Engagements im politischen Bereich, wie etwa das Wählen, das Diskutieren politischer Themen oder die Teilnahme an Protesten. Angesichts der zunehmenden Etablierung von Social-Media-Plattformen in den Kommunikationsstrategien politischer Akteur*innen sowie der niedrigschwelligen Möglichkeiten der Plattformen für direkte diskursive Beteiligung, hat die Zielgröße politische Partizipation besonders starke Aufmerksamkeit in der Forschung erfahren. In der Tat gibt es bereits eine ganze Reihe an Überblicksarbeiten und Meta-Analysen, die sich spezifisch mit dem Zusammenhang zwischen der Nutzung (algorithmisierter) digitaler Medien und politischer Partizipation beschäftigen haben (z.B. Angyal & Fellner, 2020; Boulianne, 2020; Lorenz-Spreen et al., 2023; Oser & Boulianne, 2020). Die Befundlage spricht dabei konsistent für *positive* Effekte und somit dafür, dass die Nutzung von digitalen Medien im Allgemeinen und Social-Media-Plattformen im Besonderen die Beteiligung am bürgerlichen und politischen Leben erhöht.

Allerdings stellt sich die Frage, ob es sich dabei in allen Fällen um wünschenswerte Beteiligung handelt oder vielmehr um das, was in der Forschung als „dark participation“ (Westlund, 2021) beschrieben wird. Charakteristisch für algorithmisierte Medientumgebungen sind, wie bereits erwähnt, die Logiken von Emotionalität und Viralität, handelt es sich bei diesen schließlich um relevante Prädiktoren von (plattformseitig gewünschtem) User-Engagement. Diese Logiken können Partizipation stärken, wenngleich in einer Weise, die ambivalent zu bewerten ist. Vor allem Einzelthemen besitzen in diesem Kontext ein hohes Mobilisierungspotenzial, der vielleicht bekannteste Kristallisationspunkt davon ist der ‚Shitstorm‘: Getrieben von einem stark emotionalisierenden Stimulus erreicht die Information zu einem kontroversen Einzelthema in kürzester Zeit sehr viele Nutzer*innen, wobei die relative Anonymität sozialer Medien mit einem starken Maß von Empörung, Negativität und Inzivilität einher geht (Kümpel & Rieger, 2019). Daran wird die Kehrseite algorithmisch getriebener Partizipation sichtbar: Politische Debatten werden zunehmend um Einzelthemen und Personalien herum ausgetragen, ein idealtypisch rationaler Diskurs erscheint so kaum denkbar. Darüber hinaus gelingt es „Polarisierungsunternehmen“, derartige Phänomene gezielt anzufachen und in ihrem Sinne zu instrumentalisieren (Mau, 2022). Das Fazit muss mithin gemischt ausfallen: Zwar können algorithm-

misierete Medienumgebungen ihre Nutzer*innen nachweislich politisch mobilisieren, gleichzeitig geschieht dies jedoch häufig in einer Form, die einem produktiven demokratisch-diskursivem Austausch nur bedingt zuträglich ist.

4. Fazit und Ausblick

Mediennutzung *ohne* Personalisierung wird zunehmend zur Ausnahme: Lineare Verbreitungswege verlieren stetig an Bedeutung, während das Hören kuratierter Spotify-Playlists, das Schauen von Videos auf YouTube oder die Rezeption von Newsposts auf Instagram für viele Menschen fester Teil des Alltags geworden sind. Auch klassische Nachrichtenanbieter setzen online zunehmend auf sog. *News Recommender Systems*, die personalisierte Inhalte für Nutzer*innen auswählen (Mitova et al., 2023).

Die auf den entsprechenden Plattformen wirkenden algorithmischen Systeme haben nicht nur einen Einfluss darauf, welche Inhalte überhaupt auf unseren Radar gelangen, sondern auch, wie wir diese wahrnehmen, verarbeiten und weiterführend mit ihnen umgehen. Wenngleich auch das Bewusstsein über die Existenz und Funktionsweise von algorithmisierten Medienumgebungen allmählich wächst, ergeben sich aus dieser Entwicklung Herausforderungen. Zum einen müssen Nutzer*innen lernen, selbstbestimmt und kompetent mit Personalisierungsprozessen umzugehen. Zum anderen muss auch in Politik und Gesellschaft ein Umgang mit algorithmisierten Medien gefunden werden, der eine Balance findet zwischen dem aus empirischer Sicht übersteigerten Gefahrendiskurs auf der einen Seite und einer positiven Verklärung auf der anderen Seite. Zentral scheint vor diesem Hintergrund auch ein Blick auf die Frage, wie Empfehlungsalgorithmen – insbesondere im Bereich der Informations- und Nachrichtennutzung – gestaltet werden können, die Diversität und gesamtgesellschaftliche Relevanz explizit berücksichtigen (Heitz et al., 2022; Helberger, 2019).

Die Untersuchung algorithmisierter Medienumgebungen stellt die Kommunikationswissenschaft fraglos auch vor erhebliche *methodische* Herausforderungen (Kümpel, 2022; Y. Peters et al., 2023). Die zentrale Problematik liegt in der Individualisierung, Dynamik und Flüchtigkeit von Inhalten, die Nutzer*innen etwa auf Social-Media-Plattformen präsentiert werden. Dies erschwert es, standardisierte und verallgemeinerbare Aussagen über Medienangebot und -nutzung zu treffen und nicht zuletzt auch, individuelle Medienwirkungen adäquat abzubilden und zu messen. Gerade kontrollierte Experimentalstudien weisen oft eine nur geringe externe Validität auf, da etwa für Social-Media-Umgebungen charakteristische Aspekte wie der persönliche

Mix an Inhalten oder der Einfluss von Empfehlungen durch Freund*innen nur unzureichend abgebildet werden können. Gleichzeitig sind echte Feldexperimente nahezu unmöglich, da Plattformbetreiber Datenzugang und Interventionsmöglichkeiten durch Forscher*innen kontrollieren. In empirischen Studien wird daher zumeist mit ‚Zwischenlösungen‘ gearbeitet, bei denen beispielsweise Teilnehmer*innen aufgefordert werden, auf tatsächlichen Social-Media-Plattformen bestimmten Accounts zu folgen, die kontrolliert von Forscher*innen bespielt werden (für einen Überblick siehe Mosleh et al., 2022) oder aber mit sog. Mock-Tools gearbeitet wird, die Aussehen und Funktionalität von echten Plattformen emulieren (Jagayat et al., 2021). Als ertragreich könnte sich künftig auch die Arbeit mit Datenspenden erweisen, bei denen Nutzer*innen gebeten werden, die über sie erhobenen personenbezogenen Daten (z.B. aus ihrer Social-Media-Nutzung) mit Forscher*innen zu teilen (van Driel et al., 2022). Während bisherige Forschung aus diesem Bereich primär auf einmalige Analysen setzt, ist es denkbar, die Methode auch mit (quasi-)experimentellen Logiken zu verknüpfen: Eine Baseline-Datenspende zu t_1 in Kombination mit einer instruktionsbasierten Manipulation ließe dann zu t_2 Rückschlüsse auf die Wirksamkeit des Treatments unter realweltlichen Nutzungsbedingungen zu.

Aufmerksamkeit verdienen dabei nicht zuletzt auch ethische Überlegungen, die Aspekte wie die Achtung von Privatsphäre oder die (Un-)Möglichkeit informierter Einwilligung berücksichtigen. Entsprechend gilt es neben der Weiterentwicklung von innovativen methodischen Ansätzen auch deren kritische Reflexion nicht aus den Augen zu verlieren.

Literaturtipps

Eg, R., Demirkol Tønnesen, Ö., & Tennfjord, M. K. (2023). A Scoping Review of Personalized User Experiences on Social Media: The Interplay Between Algorithms and Human Factors. *Computers in Human Behavior Reports*, 9, 100253.

<https://doi.org/10.1016/j.chbr.2022.100253>

Kitchin, R. (2017). Thinking Critically About and Researching Algorithms. *Information, Communication & Society*, 20(1), 14–29.

<https://doi.org/10.1080/1369118X.2016.1154087>

Kümpel, A. S. (2022). Social Media Information Environments and Their Implications for the Uses and Effects of News: The PINGS Framework. *Communication Theory*, 32(2), 223–242. <https://doi.org/10.1093/ct/qtab012>

Lorenz-Spreen, P., Oswald, L., Lewandowsky, S., & Hertwig, R. (2023). A Systematic Review of Worldwide Causal and Correlational Evidence on Digital Media and Democracy. *Nature Human Behaviour*, 7(1), 74–101. <https://doi.org/10.1038/s41562-022-01460-1>

Literaturverzeichnis

- Allcott, H., Braghieri, L., Eichmeyer, S., & Gentzkow, M. (2020). The Welfare Effects of Social Media. *American Economic Review*, 110(3), 629–676. <https://doi.org/10.1257/aer.20190658>
- Amatriain, X., & Basilico, J. (2017, 18. April). Netflix Recommendations: Beyond the 5 stars. *Netflix Technology Blog*. <https://netflixtechblog.com/netflix-recommendations-beyond-the-5-stars-part-1-55838468f429>
- Amsalem, E., & Zoizner, A. (2023). Do People Learn About Politics on Social Media? A Meta-Analysis of 76 Studies. *Journal of Communication*, 73(1), 3–13. <https://doi.org/10.1093/joc/jqac034>
- Angyal, E. É., & Fellner, Z. (2020). How are Online and Offline Political Activities Connected? A Comparison of Studies. *Intersections. East European Journal of Society and Politics*, 6(2), 81–98.
- Barnidge, M. (2023). Incidental Exposure and News Engagement: Testing Temporal Order and the Role of Political Interest. *Digital Journalism*, 11(1), 125–143. <https://doi.org/10.1080/21670811.2021.1906290>
- Bartley, N., Abeliuk, A., Ferrara, E., & Lerman, K. (2021). Auditing Algorithmic Bias on Twitter. *13th ACM Web Science Conference 2021*, 65–73. <https://doi.org/10.1145/3447535.3462491>
- Behre, J., Hölig, S., & Möller, J. (2024). *Reuters Institute Digital News Report 2024 – Ergebnisse für Deutschland* (No. 72; Arbeitspapiere des Hans-Bredow-Instituts). Hans-Bredow-Institut. <https://doi.org/10.21241/ssoar.94461>
- Bhandari, A., & Bimo, S. (2022). Why’s Everyone on TikTok Now? The Algorithmized Self and the Future of Self-Making on Social Media. *Social Media + Society*, 8(1), 20563051221086241. <https://doi.org/10.1177/20563051221086241>
- Binst, B., Vandenbroucke, H., Li, D., & Puskas, I. (2024). Towards a Pragmatic Approach for Studying Normative Recommender Systems: Exploring Power Dynamics in Digital Platform Markets. *NORMALize 2023 Normative Design and Evaluation of Recommender Systems 2023*, 3639. <https://ceur-ws.org/Vol-3639/paper1.pdf>
- Bode, L. (2016). Political News in the News Feed: Learning Politics from Social Media. *Mass Communication and Society*, 19(1), 24–48. <https://doi.org/10.1080/15205436.2015.1045149>

- Boulianne, S. (2015). Generating Political Interest with Online News. In L. Robinson, S. R. Cotten, & J. Schulz (Hrsg.), *Communication and Information Technologies Annual* (Bd. 9, S. 53–76). Emerald Group Publishing Limited.
- Boulianne, S. (2020). Twenty Years of Digital Media Effects on Civic and Political Participation. *Communication Research*, 47(7), 947–966.
<https://doi.org/10.1177/0093650218808186>
- Boulianne, S., & Hoffmann, C. P. (2024). Digital Inclusion Through Algorithmic Knowledge: Curated Flows of Civic and Political Information on Instagram. *Media and Communication*, 12, 8102. <https://doi.org/10.17645/mac.8102>
- Boulianne, S., Koc-Michalska, K., & Bimber, B. (2020). Mobilizing Media: Comparing Tv and Social Media Effects on Protest Mobilization. *Information, Communication & Society*. <https://www.tandfonline.com/doi/abs/10.1080/1369118X.2020.1713847>
- Bozdag, E. (2013). Bias in Algorithmic Filtering and Personalization. *Ethics and Information Technology*, 15(3), 209–227. <https://doi.org/10.1007/s10676-013-9321-6>
- Bucher, T. (2020). The Right-Time Web: Theorizing the Kairologic of Algorithmic Media. *New Media & Society*, 22(9), 1699–1714. <https://doi.org/10.1177/1461444820913560>
- Chen, S., Xiao, L., & Kumar, A. (2023). Spread of Misinformation on Social Media: What Contributes to It and How to Combat It. *Computers in Human Behavior*, 141, 107643. <https://doi.org/10.1016/j.chb.2022.107643>
- Cotter, K., DeCook, J. R., Kanthawala, S., & Foyle, K. (2022). In FYP We Trust: The Divine Force of Algorithmic Conspiratorship. *International Journal of Communication*, 16, Article 0.
- De Vreese, C. H., & Boomgaarden, H. (2006). News, Political Knowledge and Participation: The Differential Effects of News Media Exposure on Political Knowledge and Participation. *Acta Politica*, 41(4), 317–341. <https://doi.org/10.1057/palgrave.ap.5500164>
- DeVito, M. A. (2017). From Editors to Algorithms. A Values-Based Approach to Understanding Story Selection in the Facebook News Feed. *Digital Journalism*, 5(6), 753–773. <https://doi.org/10.1080/21670811.2016.1178592>
- Diakopoulos, N. (2015). Algorithmic Accountability. Journalistic Investigation of Computational Power Structures. *Digital Journalism*, 3(3), 398–415. <https://doi.org/10.1080/21670811.2014.976411>
- DiMaggio, P., Evans, J., & Bryson, B. (1996). Have American's Social Attitudes Become More Polarized? *American Journal of Sociology*, 102(3), 690–755. <https://doi.org/10.1086/230995>
- Dogruel, L. (2021). Folk Theories of Algorithmic Operations During Internet Use: A Mixed Methods Study. *The Information Society*, 37(5), 287–298. <https://doi.org/10.1080/01972243.2021.1949768>

- Eg, R., Demirkol Tønnesen, Ö., & Tennfjord, M. K. (2023). A Scoping Review of Personalized User Experiences on Social Media: The Interplay Between Algorithms and Human Factors. *Computers in Human Behavior Reports*, 9, 100253. <https://doi.org/10.1016/j.chbr.2022.100253>
- Eslami, M., Karahalios, K., Sandvig, C., Vaccaro, K., Rickman, A., Hamilton, K., & Kirlik, A. (2016). First I „Like“ It, Then I Hide It: Folk Theories of Social Feeds. *CHI '16: Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems*, 2371–2382. <https://doi.org/10.1145/2858036.2858494>
- Feezell, J. T., & Ortiz, B. (2021). ‘I Saw It on Facebook’: An Experimental Analysis of Political Learning Through Social Media. *Information, Communication & Society*, 24(9), 1283–1302. <https://doi.org/10.1080/1369118X.2019.1697340>
- Fengler, S. (2023). Verantwortung und Selbstkontrolle im Journalismus. In K. Meier & C. Neuberger (Hrsg.), *Journalismusforschung* (S. 135–154). Nomos Verlagsgesellschaft mbH & Co. KG. <https://doi.org/10.5771/9783748928522-135>
- Fletcher, R., & Nielsen, R. K. (2018). Are People Incidentally Exposed to News on Social Media? A Comparative Analysis. *New Media & Society*, 20(7), 2450–2468. <https://doi.org/10.1177/1461444817724170>
- Gaw, F. (2022). Algorithmic Logics and the Construction of Cultural Taste of the Netflix Recommender System. *Media, Culture & Society*, 44(4), 706–725. <https://doi.org/10.1177/01634437211053767>
- Geiß, S., Magin, M., Stark, B., & Jürgens, P. (2018). „Common Meeting Ground” in Gefahr? Selektionslogiken politischer Informationsquellen und ihr Einfluss auf die Fragmentierung individueller Themenhorizonte. *Medien & Kommunikationswissenschaft*, 66(4), 502–525. <https://doi.org/10.5771/1615-634X-2018-4-502>
- Gil de Zúñiga, H., & Cheng, Z. (2024). Origin and Evolution of the News Finds Me Perception: Review of Theory and Effects. In M. Goyanes & A. Cañedo (Hrsg.), *Media Influence on Opinion Change and Democracy: How Private, Public and Social Media Organizations Shape Public Opinion* (S. 151–179). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-70231-0_10
- Gil De Zúñiga, H., & Diehl, T. (2019). News finds me perception and democracy: Effects on political knowledge, political interest, and voting. *New Media & Society*, 21(6), 1253–1271. <https://doi.org/10.1177/1461444818817548>
- Gillespie, T. (2016). Algorithm. In B. Peters (Hrsg.), *Digital keywords: A vocabulary of information society and culture* (S. 18–30). Princeton University Press. <https://doi.org/10.1515/9781400880553-004>
- Gottfried, J. A., Hardy, B. W., Holbert, R. L., Winneg, K. M., & Jamieson, K. H. (2017). The Changing Nature of Political Debate Consumption: Social Media, Multitasking, and Knowledge Acquisition. *Political Communication*, 34(2), 172–199. <https://doi.org/10.1080/10584609.2016.1154120>

- Graber, D. A. (2001). *Processing politics: Learning from television in the Internet age*. The University of Chicago Press.
- Grandinetti, J., & Bruinsma, J. (2023). The Affective Algorithms of Conspiracy TikTok. *Journal of Broadcasting & Electronic Media*, 67(3), 274–293. <https://doi.org/10.1080/08838151.2022.2140806>
- Granow, V. V. C., & Scolari, J. (2022). TikTok – Nutzung und Potenziale der -Kurzvideo-Plattform. *Media Perspektiven*, 4, 166–176.
- Güting, R. H., & Dieker, S. (2004). Sortieralgorithmen. In R. H. Güting & S. Dieker (Hrsg.), *Datenstrukturen und Algorithmen* (S. 203–233). Vieweg+Teubner Verlag. https://doi.org/10.1007/978-3-322-89113-6_6
- Hagen, L. M., Wieland, M., & In der Au, A.-M. (2017). Algorithmischer Strukturwandel der Öffentlichkeit: Wie die automatische Selektion im Social Web die politische Kommunikation verändert und welche Gefahren dies birgt. *MedienJournal*, 41(2), 127–143. <https://doi.org/10.24989/medienjournal.v41i2.1476>
- Hargittai, E., Gruber, J., Djukaric, T., Fuchs, J., & Brombach, L. (2020). Black Box Measures? How to Study People’s Algorithm Skills. *Information, Communication & Society*, 23(5), 764–775. <https://doi.org/10.1080/1369118X.2020.1713846>
- Heise, N. (2016). Algorithmen. In J. Heesen (Hrsg.), *Handbuch Medien- und Informationsethik* (S. 202–209). J.B. Metzler. https://doi.org/10.1007/978-3-476-05394-7_27
- Heitz, L., Lischka, J. A., Birrer, A., Paudel, B., Tolmeijer, S., Laugwitz, L., & Bernstein, A. (2022). Benefits of Diverse News Recommendations for Democracy: A User Study. *Digital Journalism*, 10(10), 1710–1730. <https://doi.org/10.1080/21670811.2021.2021804>
- Helberger, N. (2019). On the Democratic Role of News Recommenders. *Digital Journalism*, 7(8), 993–1012. <https://doi.org/10.1080/21670811.2019.1623700>
- Herzog, L. (2021). Algorithmisches Entscheiden, Ambiguitätstoleranz und die Frage nach dem Sinn. *Deutsche Zeitschrift Für Philosophie*, 69(2), 197–213. <https://doi.org/10.1515/dzph-2021-0016>
- Hilbert, M., Liu, B., Luu, J., & Fishbein, J. (2019). Behavioral Experiments With Social Algorithms: An Information Theoretic Approach to Input–Output Conversions. *Communication Methods and Measures*, 13(4), 267–286. <https://doi.org/10.1080/19312458.2019.1620712>
- Holt, K., Shehata, A., Strömbäck, J., & Ljungberg, E. (2013). Age and the Effects of News Media Attention and Social Media Use on Political Interest and Participation: Do Social Media Function as Leveller? *European Journal of Communication*, 28(1), 19–34. <https://doi.org/10.1177/0267323112465369>
- Jagayat, A., Boparai, G., Pun, C., & Choma, B. L. (2021). *Mock Social Media Website Tool* (Version 1.0) [Software]. <https://docs.studysocial.media/>

- Jones, C. (2023). How to Train Your Algorithm: The Struggle for Public Control Over Private Audience Commodities on TikTok. *Media, Culture & Society*, 45(6), 1192–1209. <https://doi.org/10.1177/01634437231159555>
- Just, N., & Latzer, M. (2017). Governance by Algorithms: Reality Construction by Algorithmic Selection on the Internet. *Media, Culture & Society*, 39(2), 238–258. <https://doi.org/10.1177/0163443716643157>
- Kitchin, R. (2017). Thinking Critically About and Researching Algorithms. *Information, Communication & Society*, 20(1), 14–29. <https://doi.org/10.1080/1369118X.2016.1154087>
- Kleinberg, M. S., & Lau, R. R. (2019). The Importance of Political Knowledge for Effective Citizenship. *Public Opinion Quarterly*, 83(2), 338–362. <https://doi.org/10.1093/poq/nfz025>
- Kümpel, A. S. (2020). The Matthew Effect in Social Media News Use: Assessing Inequalities in News Exposure and News Engagement on Social Network Sites (sns). *Journalism*, 21(8), 1083–1098. <https://doi.org/10.1177/1464884920915374>
- Kümpel, A. S. (2022). Social Media Information Environments and Their Implications for the Uses and Effects of News: The Pings Framework. *Communication Theory*, 32(2), 223–242. <https://doi.org/10.1093/ct/qtab012>
- Kümpel, A. S. (2025). Medienrezeption in algorithmisierten Umgebungen. In V. Gehrau, H. Bilandzic, H. Schramm, & C. Wünsch (Hrsg.), *Medienrezeption* (S. 735–752). Nomos. <https://doi.org/10.5771/9783748913597-735>
- Kümpel, A. S., & Rieger, D. (2019). *Wandel der Sprach- und Debattenkultur in sozialen Online-Medien: Ein Literaturüberblick zu Ursachen und Wirkungen von inziviler Kommunikation*. Ludwig-Maximilians-Universität München. <https://doi.org/10.5282/ubm/epub.68880>
- Lecheler, S., & De Vreese, C. H. (2017). News Media, Knowledge, and Political Interest: Evidence of a Dual Role From a Field Experiment: News Media, Knowledge, and Political Interest. *Journal of Communication*, 67(4), 545–564. <https://doi.org/10.1111/jcom.12314>
- Lorenz-Spreen, P., Oswald, L., Lewandowsky, S., & Hertwig, R. (2023). A Systematic Review of Worldwide Causal and Correlational Evidence on Digital Media and Democracy. *Nature Human Behaviour*, 7(1), 74–101. <https://doi.org/10.1038/s41562-022-01460-1>
- Matthes, J. (2022). Social Media and the Political Engagement of Young Adults: Between Mobilization and Distraction. *Online Media and Global Communication*, 1(1), 6–22. <https://doi.org/10.1515/omgc-2022-0006>

- Mau, S. (2022). „Die Welt ist bunter, als meist angenommen“: Ein Gespräch mit Steffen Mau über Polarisierungsunternehmer, Veränderungserschöpfung und gesellschaftliche Gewöhnungsprozesse. *Soziopolis: Gesellschaft beobachten*.
- McComb, C. A., Vanman, Eric J., & Tobin, S. J. (2023). A Meta-Analysis of the Effects of Social Media Exposure to Upward Comparison Targets on Self-Evaluations and Emotions. *Media Psychology*, 26(5), 612–635.
<https://doi.org/10.1080/15213269.2023.2180647>
- Messingschlager, T., & Holtz, P. (2020). Filter Bubbles und Echo Chambers. In M. Appel (Hrsg.), *Die Psychologie des Postfaktischen: Über Fake News, „Lügenpresse“, Clickbait & Co.* (S. 91–103). Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-662-58695-2>
- Mitova, E., Blassnig, S., Strikovic, E., Urman, A., Hannak, A., de Vreese, C. H., & Esser, F. (2023). News Recommender Systems: A Programmatic Research Review. *Annals of the International Communication Association*, 47(1), 84–113.
<https://doi.org/10.1080/23808985.2022.2142149>
- Möller, J. (2021). Filter Bubbles and Digital Echo Chambers. In H. Tumber & S. Waisbord (Hrsg.), *The Routledge Companion to Media Disinformation and Populism* (S. 92–100). Routledge.
- Mosleh, M., Pennycook, G., & Rand, D. G. (2022). Field Experiments on Social Media. *Current Directions in Psychological Science*, 31(1), 69–75.
<https://doi.org/10.1177/09637214211054761>
- Mosseri, A. (2023). *Instagram Ranking Explained*. <https://about.instagram.com/blog/announcements/instagram-ranking-explained/>
- Müller, T. (2024). Zahl der Social-Media-Nutzenden steigt auf 60 Prozent. *Media Perspektiven*, 28, 1–8.
- Naderer, B., Heiss, R., & Matthes, J. (2020). The Skilled and the Interested: How Personal Curation Skills Increase or Decrease Exposure to Political Information on Social Media. *Journal of Information Technology & Politics*, 17(4), 452–460.
<https://doi.org/10.1080/19331681.2020.1742843>
- Narayanan, A. (2023). Understanding Social Media Recommendation Algorithms. *Knight First Amend*. <http://knightcolumbia.org/content/understanding-social-media-recommendation-algorithms>
- Oeldorf-Hirsch, A., & Neubaum, G. (2023). What Do We Know About Algorithmic Literacy? The Status Quo and a Research Agenda for a Growing Field. *New Media & Society*, 1–21. <https://doi.org/10.1177/14614448231182662>
- Orben, A. (2020). Teenagers, Screens and Social Media: A Narrative Review of Reviews and Key Studies. *Social Psychiatry and Psychiatric Epidemiology*, 55(4), 407–414.
<https://doi.org/10.1007/s00127-019-01825-4>

- Oser, J., & Boulianne, S. (2020). Reinforcement Effects between Digital Media Use and Political Participation: A Meta-Analysis of Repeated-Wave Panel Data. *Public Opinion Quarterly*, 84(S1), 355–365. <https://doi.org/10.1093/poq/nfaa017>
- Overdiek, M., & Petersen, T. (2022). *Was Deutschland über Algorithmen und Künstliche Intelligenz weiß und denkt: Ergebnisse einer repräsentativen Bevölkerungsumfrage: Update 2022*. <https://doi.org/10.11586/2022053>
- Pariser, E. (2011). *Beware online „filter bubbles“*. TED Talk. https://www.ted.com/talks/eli_pariser_beware_online_filter_bubbles
- Park, C. S., & Kaye, B. K. (2019). Mediating Roles of News Curation and News Elaboration in the Relationship Between Social Media Use for News and Political Knowledge. *Journal of Broadcasting & Electronic Media*, 63(3), 455–473. <https://doi.org/10.1080/08838151.2019.1653070>
- Peters, Y., Nehls, P., & Thimm, C. (2023). Plattformforschung mit Instagram-Daten – Eine Übersicht über analytische Zugänge, digitale Erhebungsverfahren und forschungsethische Perspektiven in Zeiten der APIcalypse. *Publizistik*, 68(2), 225–239. <https://doi.org/10.1007/s11616-023-00786-8>
- Powers, E. (2017). My News Feed Is Filtered? Awareness of News Personalization Among College Students. *Digital Journalism*, 5(10), 1315–1335. <https://doi.org/10.1080/21670811.2017.1286943>
- Rader, E., & Gray, R. (2015). Understanding User Beliefs About Algorithmic Curation in the Facebook News Feed. *Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems*, 173–182. <https://doi.org/10.1145/2702123.2702174>
- Rau, J. P., & Stier, S. (2019). Die Echokammer-Hypothese: Fragmentierung der Öffentlichkeit und politische Polarisierung durch digitale Medien? *Zeitschrift für Vergleichende Politikwissenschaft*, 13(3), 399–417. <https://doi.org/10.1007/s12286-019-00429-1>
- Reviglio, U., & Agosti, C. (2020). Thinking Outside the Black-Box: The Case for “Algorithmic Sovereignty” in Social Media. *Social Media + Society*, 6(2), 2056305120915613. <https://doi.org/10.1177/2056305120915613>
- Ricci, F., Rokach, L., & Shapira, B. (2015). Recommender Systems: Introduction and Challenges. In F. Ricci, L. Rokach, & B. Shapira (Hrsg.), *Recommender Systems Handbook* (S. 1–34). Springer US. https://doi.org/10.1007/978-1-4899-7637-6_1
- Scharkow, M., Mangold, F., Stier, S., & Breuer, J. (2020). How Social Network Sites and Other Online Intermediaries Increase Exposure to News. *Proceedings of the National Academy of Sciences*, 117(6), 2761–2763. <https://doi.org/10.1073/pnas.1918279117>
- Schmidt, J.-H., Sørensen, J., Dreyer, S., & Hasebrink, U. (2018). Wie können Empfehlungssysteme zur Vielfalt von Medieninhalten beitragen? *Media Perspektiven*, 11, 522–531.

- Schwartz, S. A., & Mahnke, M. S. (2021). Facebook Use as a Communicative Relation: Exploring the Relation Between Facebook Users and the Algorithmic News Feed. *Information, Communication & Society*, 24(7), 1041–1056. <https://doi.org/10.1080/1369118X.2020.1718179>
- Schweiger, W. (2025). Online-Informationen: Individuelle und gesellschaftliche Effekte. In W. Schweiger, K. Beck, & V. Karnowski (Hrsg.), *Handbuch Online-Kommunikation* (S. 1–19). Springer. https://doi.org/10.1007/978-3-658-18017-1_41-1
- Schweiger, W., Weber, P., Prochazka, F., & Brückner, L. (2019). *Algorithmisch personalisierte Nachrichtenkanäle: Begriffe, Nutzung, Wirkung*. Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-24062-2>
- Seaver, N. (2019). Knowing Algorithms. In *digitalSTS: A Field Guide for Science & Technology Studies* (S. 412–422). Princeton University Press. <https://doi.org/10.1515/9780691190600-028>
- Siles, I., & Meléndez-Moran, A. (2021, Mai). “The Most Aggressive of Algorithms”: User Awareness of and Attachment to TikTok’s Content Personalization. 71. Jahrestagung der ICA „Engaging the Essential Work of Care: Communication, Connectedness, and Social Justice“, Virtual Conference (originally to be held in Denver, CO, USA).
- Siles, I., Valerio-Alfaro, L., & Meléndez-Moran, A. (2024). Learning to like TikTok . . . and not: Algorithm awareness as process. *New Media & Society*, 26(10), 5702–5718. <https://doi.org/10.1177/14614448221138973>
- Silva, D. E., Chen, C., & Zhu, Y. (2022). Facets of Algorithmic Literacy: Information, Experience, and Individual Factors Predict Attitudes Toward Algorithmic Systems. *New Media & Society*. <https://doi.org/10.1177/14614448221098042>
- Soffer, O. (2021). Algorithmic Personalization and the Two-Step Flow of Communication. *Communication Theory*, 31(3), 297–315. <https://doi.org/10.1093/ct/qtz008>
- Stark, B., Magin, M., & Jürgens, P. (2021). Maßlos überschätzt. Ein Überblick über theoretische Annahmen und empirische Befunde zu Filterblasen und Echokammern. In M. Eisenegger, M. Prinzing, P. Ettinger, & R. Blum (Hrsg.), *Digitaler Strukturwandel der Öffentlichkeit: Historische Verortung, Modelle und Konsequenzen* (S. 303–321). Springer Fachmedien. https://doi.org/10.1007/978-3-658-32133-8_17
- Sunstein, C. R. (2001). *Republic.com*. Princeton University Press.
- Thorson, K., Cotter, K., Medeiros, M., & Pak, C. (2021). Algorithmic Inference, Political Interest, and Exposure to News and Politics on Facebook. *Information, Communication & Society*, 24(2), 183–200. <https://doi.org/10.1080/1369118X.2019.1642934>
- Thorson, K., & Wells, C. (2016). Curated Flows: A Framework for Mapping Media Exposure in the Digital Age. *Communication Theory*, 26(3), 309–328. <https://doi.org/10.1111/comt.12087>

- TikTok. (2019, 16. August). How TikTok recommends videos #ForYou. *Newsroom* | TikTok. <https://newsroom.tiktok.com/en-us/how-tiktok-recommends-videos-for-you>
- Tucker, J., Guess, A., Barbera, P., Vaccari, C., Siegel, A., Sanovich, S., Stukal, D., & Nyhan, B. (2018). Social Media, Political Polarization, and Political Disinformation: A Review of the Scientific Literature. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3144139>
- van Driel, I. I., Giachanou, Anastasia, Pouwels, J. Loes, Boeschoten, Laura, Beyens, Ine, & Valkenburg, P. M. (2022). Promises and Pitfalls of Social Media Data Donations. *Communication Methods and Measures*, 16(4), 266–282. <https://doi.org/10.1080/19312458.2022.2109608>
- von Oehsen, D. (2024). Negativtrend der linearen Mediennutzung setzt sich fort. *Media Perspektiven*, 24, 1–9.
- Wallace, J. (2018). Modelling Contemporary Gatekeeping. The Rise of Individuals, Algorithms and Platforms in Digital News Dissemination. *Digital Journalism*, 6(3), 274–293. <https://doi.org/10.1080/21670811.2017.1343648>
- Westlund, O. (2021). Advancing Research into Dark Participation. *Media and Communication*, 9(1), 209–214. <https://doi.org/10.17645/mac.v9i1.1770>
- Wirtschafter, V., & Majumder, S. (2023). Future Challenges for Online, Crowdsourced Content Moderation: Evidence from Twitter’s Community Notes. *Journal of Online Trust and Safety*, 2(1), Article 1. <https://doi.org/10.54501/jots.v2i1.139>
- Zamith, R. (2019). Algorithms and Journalism. In H. Örnebring, Y. Y. Chan, M. Carlson, S. Craft, M. Karlsson, H. Sjøvaag, & H. Wasserman (Hrsg.), *The Oxford Encyclopedia of Journalism Studies*. Oxford University Press. <https://doi.org/10.1093/acrefore/9780190228613.013.779>
- Zuiderveen Borgesius, F. J., Trilling, D., Möller, J., Bodó, B., de Vreese, C. H., & Helberger, N. (2016). Should We Worry About Filter Bubbles? *Internet Policy Review*, 5(1), 1–16. <https://doi.org/10.14763/2016.1.401>