

This is a pre-copyedited, author-produced version of an article accepted for publication in the *Handbuch Medienrezeption* (Nomos) following review by the editors.

Citation: Kümpel, A. S. (in press). Medienrezeption in algorithmisierten Umgebungen [Media reception in algorithmic environments]. In V. Gehrau, H. Bilandzic, H. Schramm, & C. Wunsch (Eds.), *Handbuch Medienrezeption*. Baden-Baden: Nomos.

Medienrezeption in algorithmisierten Umgebungen

Anna Sophie Kümpel

Zusammenfassung

Der Beitrag untersucht die Merkmale und Implikationen der Medienrezeption in *algorithmisierten Umgebungen* – definiert als alle technischen Kanäle oder Plattformen, die Medieninhalte auf Basis von algorithmischen Systemen personalisieren und individualisiert an Nutzer:innen ausspielen. Es wird beleuchtet, welche Aufgaben algorithmische Systeme im Kontext der Medienrezeption übernehmen und welche gesellschaftliche Relevanz diesen zukommt. Darauf aufbauend wird der Fokus auf die Interaktion zwischen algorithmisierten Umgebungen und Nutzer:innen gelegt, einschließlich des grundsätzlichen Bewusstseins über das Wirken von Algorithmen (*algorithmic awareness*), Vorstellungen über deren konkrete Funktionsweise (*algorithmic sensemaking*) sowie die Bedeutsamkeit von Kompetenzen im Umgang mit algorithmischen Systemen (*algorithmic literacy*). Der Beitrag schließt mit einer Betrachtung der Implikationen algorithmisierter Medienrezeption für Informiertheit und Meinungsbildung und einer knappen Diskussion methodischer Herausforderungen.

Keywords

Algorithmen, Filterung, Meinungsbildung, Personalisierung, Social-Media-Plattformen

1. Einleitung

Die Rezeption von Medien ist und war schon immer durch Priorisierungen und Empfehlungen anderer Akteur:innen geprägt: So verrät uns die Platzierung und Aufmachung eines Artikels in der Tageszeitung, wie wichtig dieser ist. Ein lachender roter Stern in der TV-Zeitschrift sagt uns, für welchem Film es sich lohnt, den Fernseher anzuschalten und die Charts im Radio geben uns einen Überblick über die aktuellen Musikhits. Gleichermaßen beeinflussen Werbeplakate in der Innenstadt oder Anspieltipps von Freund:innen und Familie nicht nur, welchen Medienangeboten wir uns überhaupt zuwenden, sondern auch, wie wir diese wahrnehmen und verarbeiten. In den letzten Jahren hat angesichts der fortschreitenden Digitalisierung neben diesen journalistischen, strategischen und sozialen Akteur:innen mit „den“ *Algorithmen* zudem eine neue Kategorie an Kurator:innen an Bedeutung gewonnen (Thorson & Wells, 2016; Wallace, 2018). In der Tat findet heute ein Großteil der informations- als auch der unterhaltungsbezogenen Medienrezeption in sogenannten *algorithmisierten Umgebungen* statt (Beisch & Koch, 2021; Hölig et al., 2022). Audio-Streamingdienste wie Spotify erstellen personalisierte Playlists für uns. Videoportale wie YouTube zeigen uns im Anschluss an einen gesehenen Clip direkt weitere thematisch passende Inhalte an und Social-Media-Plattformen wie Instagram bestimmen, welche Fotos oder Videos uns als erstes begegnen, wenn wir die App öffnen. Die dabei stattfindenden Prozesse der Klassifizierung, Priorisierung und Filterung basieren auf mathematischen Modellen, die eine Vielzahl an Signalen und Informationen berücksichtigen – etwa, welche Songs eine Nutzerin viel gehört oder welche Videos sie mit ‚Gefällt mir‘ markiert hat, welche Vorlieben Personen zeigen, die der Nutzerin ähneln oder ob ein Unternehmen dafür gezahlt hat, dass die eigenen Inhalte prominent platziert werden (siehe z.B. DeVito, 2017; Lischka & Stöcker, 2017; Ricci et al., 2015; Schwartz & Mahnke, 2021). Algorithmen beeinflussen somit immer stärker, welche Medienangebote wir nutzen, wie gut informiert oder unterhalten wir uns von diesen fühlen und auf Basis welcher Inhalte wir uns eine Meinung bilden.

Vor diesem Hintergrund verfolgt der vorliegende Beitrag das Ziel, zu erörtern, was die Medienrezeption in algorithmisierten Umgebungen kennzeichnet und welche Implikationen dies für die Rezeptionsprozesse von Mediennutzer:innen hat. Der Schwerpunkt liegt dabei explizit auf der Frage, wie algorithmische Systeme auf ‚normale‘ Nutzer:innen (ein-)wirken. Nicht betrachtet wird somit der Einsatz von Algorithmen, die Community-Manager:innen die Moderation von Kommentaren erleichtern, Plattform-Betreibern die Identifikation von Misinformationen ermöglichen oder Journalist:innen bei der Erstellung von Medienprodukten assistieren oder dies sogar komplett übernehmen (siehe dazu z.B. Haim & Graefe, 2018). Ebenso wird ausgeblendet, wie sich Medienanbieter und -schaffende daran anpassen, dass ihre eigenen Produkte

zunehmend über algorithmisierte Umgebungen verbreitet werden (siehe dazu z.B. Hadida et al., 2021; Zamith, 2019).

Nach einer Definition der Begriffe „Algorithmus“ und „algorithmisierte (Medien-)Umgebungen“ wird zunächst darauf eingegangen, welche Aufgaben algorithmische Systeme im Kontext der Medienrezeption übernehmen und welche gesellschaftliche Relevanz der Nutzung von Medien(angeboten) in algorithmisierten Umgebungen zukommt. Anknüpfend daran werden verschiedene Konstellationen in den Blick genommen, die sich durch die zunehmende Abhängigkeit von algorithmischen Systemen ergeben. Hier geht es vor allem um Fragen danach, inwiefern Mediennutzer:innen überhaupt bewusst ist, ob und wie Algorithmen ihre Rezeption prägen (*algorithmic awareness*), wie dieses (vermeintliche) Wissen über algorithmische Systeme die Auseinandersetzung mit Medien beeinflusst (*algorithmic sensemaking*) und welche Bedeutung übergeordneten Kompetenzen im Umgang mit algorithmisierten Umgebungen (*algorithmic literacy*) zukommt. Abschließend wird zudem knapp auf mögliche Implikationen der Medienrezeption in algorithmisierten Umgebungen eingegangen sowie erörtert, welche methodischen Herausforderungen sich bei deren Untersuchung stellen.

2. Grundlagen

2.1 Definitionen: „Algorithmen“ und „algorithmisierte“ Medienumgebungen

Ein in Online-Shops beliebtes T-Shirt- und Kaffeetassen-Motiv definiert *algorithm* humoristisch als „word used by programmers when they do not want to explain what they did“. In der Tat scheinen viele Mediennutzer:innen wenig konkrete Vorstellungen davon zu haben, was ein Algorithmus ist. Gemäß einer repräsentativen Befragung der Bertelsmann Stiftung im Januar 2022 haben 17% der Befragten den Begriff „Algorithmus“ noch gar nicht gehört, 21% geben an, kaum Wissen darüber zu haben, wie Algorithmen funktionieren und 44% attestieren sich zumindest ein ‚ungefähres‘ Wissen (Overdiek & Petersen, 2022, S. 17). Angesichts dieser Zahlen sowie der Tatsache, dass der Begriff in unterschiedlichen Disziplinen sehr unterschiedlich verwendet wird (Gillespie, 2016; Heise, 2016), soll hier zunächst abgesteckt werden, was mit „Algorithmen“ und „algorithmisierten (Medien-)Umgebungen“ gemeint ist.

Im grundlegendsten Sinne lassen sich Algorithmen als „schrittweise Prozeduren für das Lösen von Problemen“ (Herzog, 2021, S. 199) verstehen, wobei es stets darum geht, aus einem Input (z.B. Nutzer:innen-Eingaben, aufgezeichnetes Rezeptionsverhalten) einen definierten Output – beispielsweise einen ‚anregend‘ geordneten Newsfeed oder passende Filmempfehlungen – zu

erzeugen (siehe auch Diakopoulos, 2015; Gillespie, 2016; Heise, 2016). Um die Funktionsweise von Algorithmen zu beschreiben, wird daher gerne die Analogie eines *Rezepts* herangezogen (siehe z.B. Gillespie, 2016; Willson, 2017). Ein Rezept hat immer ein konkretes Ziel, zum Beispiel: ein Gemüsecurry. Enthalten ist darin außerdem eine Liste von Zutaten – beispielsweise Kokosmilch, Brokkoli und Süßkartoffeln – sowie insbesondere eine klar strukturierte Abfolge an Zubereitungsschritten, die uns u.a. Auskunft darüber geben, wie klein wir das Gemüse schneiden sollen, in welcher Reihenfolge wir die Zutaten in den Topf werfen müssen oder auf welcher Hitzestufe das Curry köcheln soll. In dem Beispiel sind die Zutaten unser Input, das fertige Curry der Output und die im Rezept enthaltenen Anweisungen der Algorithmus. Im Gegensatz zu Kochrezepten sind Algorithmen in der Informationstechnik jedoch zwingend auf eindeutige Instruktionen bzw. entsprechende Definitionen angewiesen. Ein ‚Klecks‘ Ahornsirup etwa müsste mit Blick auf die Maschinenlesbarkeit und Reproduzierbarkeit des Ergebnisses genau quantifiziert werden. Doch egal ob wir uns in der Küche oder in Online-Umgebungen befinden: „Algorithms make things happen“ (Willson, 2017, S. 140), indem sie aus einer endlichen Zahl an Handlungsanweisungen ein durch die Autor:innen bzw. Programmierer:innen festgelegtes Ergebnis hervorbringen.

Wenngleich wir in der öffentlichen Debatte häufig von *dem* Netflix- oder *dem* Instagram-Algorithmus hören, ist dies eine Vereinfachung, die der Realität nicht gerecht wird (Kitchin, 2017; Mosseri, 2021; Seaver, 2019; Silva et al., 2022). In der Tat haben wir es auf diesen und ähnlichen Plattformen mit einer Vielzahl an Algorithmen oder noch spezifischer mit algorithmischen Systemen zu tun, die sich als „intricate, dynamic arrangements of people and code“ (Seaver, 2019, S. 419) definieren lassen. Um auch sprachlich abzubilden, dass wir uns aus kommunikationswissenschaftlicher Sicht in der Regel für solche „systems of computation“ (Kapsch, 2022, S. 18) interessieren, ist in der akademischen Auseinandersetzung zumeist nicht von ‚den Algorithmen‘, sondern von algorithmischen Medien (z.B. Bucher, 2020), Medien, die „algorithmische Empfehlungssysteme“ (Schmidt et al., 2018, S. 522) verwenden oder im Kontext der Informationsnutzung von (Informations-)Intermediären¹ (z.B. Stark et al., 2021) die Rede. Im Einklang mit dem Titel wird in diesem Beitrag von *algorithmisierten (Medien-)Umgebungen* gesprochen. Gemeint sind damit alle technischen Kanäle oder Plattformen, die Medieninhalte

¹ Streng genommen sind Intermediäre als Angebote zu verstehen, „die *fremden* Content zugänglich machen“ (Schweiger et al., 2019, S. 12) und kaum oder keine eigenen Inhalte erstellen – also etwa Suchmaschinen oder Social-Media-Plattformen. Somit lassen sich nicht alle der in diesem Beitrag diskutierten Kanäle/Plattformen (z.B. Streaming-Plattformen mit eigenen Angeboten) als Intermediäre bezeichnen.

auf Basis von algorithmischen Systemen automatisiert personalisieren, d.h. Inhalte nach explizit und implizit generierten Präferenzprofilen individualisiert an Nutzer:innen ausspielen (siehe ähnlich Schweiger et al., 2019; Silva et al., 2022).

Diese Definition erfordert einige weitere Erklärungen, insbesondere zum Begriff der *Personalisierung*. Thurman und Schifferes (2012) definieren Personalisierung als eine „form of user-to-system interactivity that uses a set of technological features to adapt the content, delivery, and arrangement of a communication to individual users’ explicitly registered and/or implicitly determined preferences“ (S. 776). Dieser und vergleichbaren theoretischen Konzeptualisierungen folgend (siehe z.B. Bozdag, 2013; Thorson & Wells, 2016; Zuiderveen Borgesius et al., 2016), lässt sich im Kontext algorithmisierter Medienumgebungen idealtypisch zwischen impliziter und expliziter Personalisierung differenzieren. Von *impliziter Personalisierung* ist die Rede, wenn die Präferenzen der Nutzer:innen aufgrund ihrer beobachtbaren Handlungen und weiterer Signale vom System inferiert werden und diese Informationen genutzt werden, um Inhalte zu priorisieren und zu filtern. So wird in algorithmisierten Medienumgebungen u.a. erfasst, mit welchen Arten von Inhalten Nutzer:innen interagieren, mit welchem Endgerät und/oder von welchem Ort sie auf das Angebot zugreifen oder welche Beziehungen zu anderen Nutzer:innen sie im Netzwerk besonders intensiv pflegen. Verknüpft mit weiteren Meta-Informationen zu den Inhalten (z.B. Dokumententyp, Veröffentlichungszeitpunkt) sowie globaleren Relevanzindikatoren (z.B. Aufrufzahlen, Verbreitungsgeschwindigkeit) wird dann computationally über die Ausspielung von Inhalten entschieden. Von *expliziter Personalisierung* (z.T. auch persönliche Kuratierung, siehe z.B. Merten, 2021) spricht man indes, wenn Nutzer:innen aktiv und selbstgesteuert festlegen bzw. angeben, mit welchen Inhalten sie konfrontiert werden wollen und mit welchen nicht. Explizite Personalisierung findet also beispielsweise dann statt, wenn eine Nutzerin einen Account auf einer Social-Media-Plattform abonniert oder aber Funktionen wie ‚Kein Interesse‘ nutzt, um so zu veranlassen, dass ähnliche Beiträge künftig seltener angezeigt werden. In algorithmisierten Medienumgebungen wirken beide Formen der Personalisierung zusammen, wobei die implizite Personalisierung bildlich gesprochen stets die Oberhand behält (siehe auch Schweiger et al., 2019, S. 10–11). Zwar werden Akte expliziter Personalisierung als weitere Input-Variablen bei der Ausspielung von Inhalten berücksichtigt. Eine vollständige Kontrolle über deren Selektion oder Ranking haben die Nutzer:innen aber nicht. Deutlich wird daran auch, dass die in algorithmisierten Medienumgebungen genutzten algorithmischen Systeme nicht statisch, sondern kontextabhängig und in ständigem Wandel begriffen sind (Kitchin, 2017, S. 21).

Über die genaue Funktionsweise der automatisierten Personalisierung – welche Input-Parameter berücksichtigt und wie diese gewichtet werden – kann bei den allermeisten algorithmisierten Mediensystemen nur spekuliert werden, da diese als erfolgsrelevante Geschäftsgeheimnisse, wenn überhaupt, nur sehr vage nach außen kommuniziert werden (siehe z.B. Mosseri, 2021; Netflix Help Center, o. D.). Algorithmische Systeme sind somit eine *Black Box* (Diakopoulos, 2015; Hargittai et al., 2020; Heise, 2016), was ihre wissenschaftliche Analyse erschwert bis unmöglich macht. Nichtsdestotrotz lassen sich durch die Untersuchung von öffentlichen Dokumenten der Plattformen (z.B. Patentanmeldungen, siehe DeVito, 2017), Formen des ‚Reverse Engineering‘ (Diakopoulos, 2015; Thorson et al., 2021) oder die gezielte Manipulation von als relevant vermuteten Input-Variablen und anschließenden Output-Analysen (z.B. in Form von agentenbasierten Testverfahren, siehe Haim, 2020) Rückschlüsse darauf ziehen, welche Faktoren besonders relevant sind.

So hat DeVito (2017) aufbauend auf einer Analyse öffentlich zugänglicher Textdokumente von Facebook (Blogbeiträge, Patentanmeldungen, SEC Filings) in Anlehnung an die Nachrichtenswertforschung versucht, die dem Newsfeed von Facebook zugrundeliegenden algorithmischen Werte (*algorithmic values*) zu ergründen, die sie als System von Kriterien beschreibt „which are used to make decisions about the inclusion and exclusion of material and which aspects of said material to present in an algorithmically driven news feed“ (S. 754). Insgesamt wurden neun dieser algorithmischen Werte bestimmt, wobei a) Beziehungen zu Freund:innen, b) explizit gemachte Interessen sowie c) das vorherige Bewertungs-, Diskussions- und Verbreitungsverhalten als relevanteste Faktoren identifiziert werden konnten. Gaw (2022) findet bei einer methodisch ähnlichen Analyse im Kontext von Netflix, dass insbesondere implizit inferierte Präferenzen der Nutzer:innen (Welche Titel wurden für wie lange geschaut, wonach wurde gesucht? etc.) sowie das Nutzungsverhalten von ‚Geschmacks-Doppelgänger:innen‘ eine Rolle für die automatisierte Personalisierung spielen. Auf expliziter Personalisierung basierende Indikatoren wie Ratings würden zwar auch berücksichtigt. Sie spielten aber eine untergeordnete Rolle, da diese häufig performativ seien: Nutzer:innen tendierten dazu, kritisch gewürdigte oder ‚wichtige‘ Filme und Serien besser zu bewerten, obwohl sie in Wahrheit vielleicht lieber Realityshows oder Backwettbewerbe ansehen. Betrachtet man, wie die großen algorithmisierten Plattformen ihre Rankings- und Priorisierungsentscheidungen in ihren Hilfebereichen darstellen, wird das Primat *persönlicher Relevanz* und *positiver Nutzungserfahrungen* ebenfalls klar deutlich. So ist die Rede von „a relevant and positive user experience“ (Facebook Help Center, o. D.), dem Ziel, Nutzer:innen „the most interesting and relevant videos“ (TikTok Help Center, o. D.) zu zeigen oder ihnen zu helfen, „more of the videos you love“ (YouTube, o. D.) zu

entdecken. Nachfolgend wird nun eingehender auf die Aufgaben eingegangen, die durch algorithmische Systeme erledigt werden. Zudem werden die Funktionen beschrieben, die die automatisierte Personalisierung für Plattformbetreiber und Mediennutzer:innen erfüllt.

2.2 Funktionen: Aufgaben von Algorithmen im Kontext der Medienrezeption

Algorithmische Systeme übernehmen eine ganze Reihe von unterschiedlichen Aufgaben (siehe nachfolgend Diakopoulos, 2015; Just & Latzer, 2017): So werden sie eingesetzt, um Inhalte hinter den Kulissen anhand spezifischer Merkmale zu klassifizieren und zu ordnen (*Klassifikationsalgorithmen*) sowie Beziehungen zwischen Inhalten herzustellen und so deren Ähnlichkeit zu bestimmen (*Assoziationsalgorithmen*). Am spürbarsten für die Nutzer:innen sind in algorithmisierten Medienumgebungen jedoch vor allem *Filter- und Priorisierungsalgorithmen*². Erstere haben die Aufgabe, aus allen auf einer Plattform verfügbaren Inhalten diejenigen auszuwählen, die überhaupt angezeigt werden sollen, während zweitgenannte die so gefilterten Inhalte in eine definierte Reihenfolge bringen (z.B. auf Basis der inferierten Relevanz für die Nutzer:innen oder der Aktualität). Indem sie Inhalte selektieren und priorisieren, übernehmen algorithmische Systeme letztlich klassische Gatekeeping-Funktionen (Bozdag, 2013; Hagen et al., 2017; Soffer, 2021; Thorson & Wells, 2016; Wallace, 2018) und bestimmen den Informationsfluss in der Gesellschaft erheblich mit.

Im Kontext der Medienrezeption sind insbesondere diese Filter- und Priorisierungsprozesse relevant, die ob ihrer primären Funktion häufig auch als *Empfehlungsalgorithmen* bezeichnet werden. Die nachfolgenden Erläuterungen konzentrieren sich daher vorrangig auf die Funktionsweise von Empfehlungssystemen, die das Herzstück algorithmisierter Medienumgebungen darstellen. Ziel von Empfehlungssystemen ist es, fortlaufend zu analysieren, für welche Inhalte sich Nutzer:innen (als nächstes/im Moment) interessieren könnten und entsprechende Inhalte anzuzeigen bzw. auszuspielen (Bozdag, 2013; Burke, 2007; Ricci et al., 2015). Dabei kommt eine Vielzahl unterschiedlicher Filtertechniken zum Einsatz, wobei in der Literatur häufig zwischen drei grundlegenden Arten unterschieden wird (siehe auch Schmidt et al., 2018):

- **Inhaltsbezogene Filtertechniken** (engl. *content-based filtering*) setzen darauf, den Nutzer:innen Inhalte zu empfehlen, die denjenigen Inhalten ähneln, die sie in der Vergangenheit rezipiert und/oder positiv bewertet haben. Ähnlichkeit wird dabei auf Grundlage von definierten inhaltlichen Attributen bestimmt – im Filmbereich etwa das

² Natürlich bauen auch Filter- und Priorisierungsalgorithmen auf der Klassifikation und Beziehung zwischen Inhalten auf (siehe auch Diakopoulos, 2015, S. 402) – eine analytische Trennung ist aber dennoch sinnvoll, um die ‚Hauptaufgaben‘ algorithmischer Systeme zu unterscheiden.

Genre, die Regisseur:innen, die involvierten Schauspieler:innen oder gar die moralische Haltung der Protagonist:innen (Gaw, 2022).

- **Kollaborative Filtertechniken** (engl. *collaborative filtering*) generieren Empfehlungen, indem sie Informationen über die Rezeptions- bzw. Bewertungsprofile von Nutzer:innen abgleichen und zueinander in Beziehung setzen. Die zugrundeliegende Annahme ist, dass wenn zwei Personen die Vorliebe für bestimmte Inhalte teilen, sie auch bei anderen Inhalten zu einer vergleichbar positiven Bewertung gelangen. Will eine Plattform herausfinden, ob man Person X einen neuen Film empfehlen sollte, würde bei der Anwendung kollaborativer Filtertechniken also betrachtet werden, wie der Film bei Nutzer:innen ankam, die bei vergangenen Rezeptions- bzw. Bewertungsentscheidungen analog zu Person X gehandelt haben.
- **Kontextbezogene Filtertechniken** (engl. *context-based filtering*) berücksichtigen für die Erstellung von Vorschlägen u.a. den zeitlichen, örtlichen oder gerätebezogenen Nutzungskontext. Entsprechend erhalten Nutzer:innen etwa am Morgen andere Empfehlungen als am Abend und auf Reisen oder am Smartphone andere Vorschläge als zuhause oder am Laptop. Je nach verfügbarer Datenlänge können hier auch Aspekte wie das aktuelle Wetter, kürzlich getätigte Suchen oder die soziale Konstellation bei der Medienrezeption einbezogen werden.

Betrachtet man die Funktionen, die Empfehlungsalgorithmen erfüllen sollen, muss die Sicht von Nutzer:innen auf der einen Seite und die Sicht von Plattformbetreibern auf der anderen Seite berücksichtigt werden. Für Nutzer:innen sind algorithmische Empfehlungen zunächst einmal funktional, da sie helfen mit der insbesondere für Online-Umgebungen charakteristischen Informationsüberlastung (engl. *information overload*) umzugehen. Gleichermaßen befriedigt die Anpassung auf die eigenen Interessen und Vorlieben natürlich die (impliziten) Wünsche der Nutzer:innen, sich bei der Medienrezeption primär mit für sie persönlich unterhaltsamen oder interessanten Inhalten auseinanderzusetzen. Während Plattformbetreiber gerade in der öffentlichen Darstellung ebenfalls diesen Mehrwert für die Nutzer:innen betonen, sind die Empfehlungsalgorithmen letztlich dahingehend optimiert, die Organisationsziele zu erreichen (Ricci et al., 2015; Silva et al., 2022). Dazu zählen insbesondere die Erhöhung der Nutzungszufriedenheit und -zeit, die Stärkung der Bindung zur Plattform sowie sich daraus ergebend und den vorherigen Funktionen übergeordnet: die Steigerung von Verkäufen, sowohl auf dem Publikums- als auch auf dem Werbemarkt. Hauptziel der algorithmischen Kuratierung für gewinnorientierte Privatunternehmen wie Social-Media-Plattformen oder Streamingdienste ist mithin

die *Generierung von (Werbe-)Einnahmen*, während normative Zielgrößen wie Vielfalt, Ausgewogenheit oder Informationsqualität in aller Regel keine Rolle spielen.

2.3 Bedeutung: Relevanz der Medienrezeption in algorithmisierten Umgebungen

In der Einleitung und im Verlauf des Beitrags wurden bereits einige algorithmisierte Medienumgebungen bzw. Plattformen angesprochen, die derzeit einen besonderen Stellenwert in der Medienrezeption der deutschen Bevölkerung einnehmen. Wenngleich die Bedeutung einzelner Angebote steten Veränderungen unterliegt, so lässt sich in den letzten Jahren doch ein eindeutiger Trend hin zu einer durch automatisierte Personalisierung geprägten Medienrezeption feststellen.

Gemäß ARD/ZDF-Onlinestudie entfallen im Jahr 2021 55% der Internetnutzung der deutschen Bevölkerung auf die *mediale* Internetnutzung (Beisch & Koch, 2021). Auch mit Bezug auf die Dauer wurden hier – vermutlich verstärkt durch die Corona-Pandemie – mit 136 Minuten täglicher Nutzung neue Rekordwerte gemessen. Die stärksten Treiber seien dabei 1) Video-Streamingdienste wie Netflix und Amazon Prime, 2) das Musikhören über Angebote wie Spotify oder YouTube Music sowie 3) das Lesen von digitalen Artikeln (ebd., S. 489-490). Betrachtet man zusätzlich die Nutzung von Social-Media-Plattformen, die ebenfalls immer stärker auf die Nutzung von speziell aufbereiteten ‚klassischen‘ Medienangeboten (z.B. von TV-Sendern oder Zeitschriften) und medialen Inhalten von diversen ‚Content Creators‘ ausgerichtet ist, wird die Relevanz der Medienrezeption in algorithmisierten Umgebungen weiter deutlich. So seien 59% der Bevölkerung zumindest selten auf Social-Media-Plattformen unterwegs und nutzten „deren vielfältige Verwendungsmöglichkeiten“ (Beisch & Koch, 2021, S. 498). Es kann somit davon ausgegangen werden, dass ein bedeutsamer Anteil der Online-Medienrezeption in algorithmisierten Umgebungen stattfindet – aktuell insbesondere bei jüngeren Nutzer:innen (Beisch & Koch, 2021).

Besondere gesellschaftliche Relevanz hat die Frage nach dem Ausmaß automatisiert personalisierter Medienrezeption im Kontext der Nutzung von Nachrichten und aktuellen politischen Informationen (siehe auch Schweiger et al., 2019). Welche Relevanz „algorithmienbasierte Zugangswege“ (Hölig et al., 2022, S. 43) hier spielen, verdeutlicht der Reuters Institute Digital News Report, der repräsentative Befunde zur Nachrichtennutzung für die deutsche Bevölkerung ab 18 Jahren mit Internetzugang liefert. Für das Erhebungsjahr 2022 zeigt sich für das Auffinden von Inhalten zunächst, dass 44% der Befragten über algorithmisierte Zugangswege wie die Themensuche über Suchmaschinen, Aggregatoren oder Social-Media-Plattformen zu Nachrichten gelangen. Bei den 18- bis 24-Jährigen sind es gar 56%. Fokussiert man spezifisch

soziale Medien und deren aktive Nutzung für Nachrichten – also um diese „zu suchen, zu lesen, anzuschauen, zu teilen oder um darüber zu diskutieren“ (Hölig et al., 2022, S. 51) – ist Facebook über die gesamte Stichprobe hinweg die wichtigste Plattform: 17% nutzen diese (auch) für Nachrichten. Mit Blick auf die unterschiedlichen Altersgruppen zeigen sich dabei jedoch bedeutsame Unterschiede: So ist für die jüngste befragte Altersgruppe der 18- bis 24-Jährigen Instagram die mit Abstand wichtigste Plattform. Sie wird von 29% regelmäßig auch genutzt, um sich über tagesaktuelle Themen zu informieren. 39% der 18- bis 24-Jährigen geben gar an, dass soziale Medien ihre *wichtigste* Nachrichtenquelle im Internet darstellen. Welche Implikationen diese „neue Form der Fremdbestimmung“ (Geiß et al., 2018, S. 503) insbesondere im Bereich der Informationsrezeption hat, wird im Rahmen von Kapitel 4.1 aufgegriffen. In einem nächsten Schritt soll es nun jedoch zunächst um die Frage gehen, inwiefern Mediennutzer:innen überhaupt bewusst ist, ob und wie algorithmische Systeme ihre Rezeption prägen.

3. Konstellationen

3.1 Bewusstsein: Algorithmic Awareness

Wie gezeigt wurde, findet ein Großteil der Medienrezeption heute in algorithmisierten Umgebungen statt: Doch inwiefern nehmen Nutzer:innen überhaupt wahr, dass die Auswahl und Reihenfolge von Inhalten, denen sie in diesen Kanälen begegnen, automatisiert personalisiert werden? Ein solches algorithmisches Bewusstsein (engl. *algorithmic awareness*) kann als „most basic level of algorithmic understanding“ (Oeldorf-Hirsch & Neubaum, 2021, S. 5) verstanden werden und bildet somit die Grundlage für auf diesem Wissen aufbauende Sinngebungsprozesse (Kapitel 3.2) sowie weiterführende Kompetenzen (Kapitel 3.3). Der Begriff ist in der Literatur allerdings nicht eindeutig belegt: Während einige Autor:innen darunter das hier beschriebene basale Wissen fassen, „that a dynamic system is in place that can personalize and customize the information that a user sees or hears“ (Hargittai et al., 2020, S. 771), gehen andere Definitionen deutlich weiter und konzeptualisieren algorithmisches Bewusstsein als das Ausmaß, in dem Menschen *korrekte* Vorstellungen davon haben, was Algorithmen in spezifischen Medienumgebungen tun und welche Auswirkungen dies darauf hat, „how users consume and experience media content“ (Zarouali et al., 2021, S. 2). In einigen Arbeiten wird daher auch der Begriff des algorithmischen Wissens (engl. *algorithmic knowledge*) genutzt, um dieses umfassendere Verständnis zu beschreiben (z.B. Cotter & Reisdorf, 2020; Dogruel et al., 2021). Im Einklang mit Dogruel und Kolleg:innen (2021, S. 5) wird in diesem Beitrag algorithmisches Bewusstsein als das Wissen verstanden, *dass* Algorithmen existieren und verwendet werden, nicht aber das Wissen darüber, *wie* (konkret) diese funktionieren.

Frühere, primär qualitative Arbeiten im Kontext von Facebook konzentrierten sich vor allem auf Fragen danach, ob Nutzer:innen bewusst ist, dass ihnen nicht alle verfügbaren Posts auch wirklich angezeigt werden (Eslami et al., 2016; Powers, 2017; Rader & Gray, 2015). Sie kamen dabei zu der Erkenntnis, dass das Wissen darüber in der Tat nur sehr schwach ausgeprägt zu sein schien. Generell ist es jedoch schwierig, allgemeine Aussagen zum algorithmischen Bewusstsein von Mediennutzer:innen zu treffen, da a) die Plattformen und die zugrundeliegenden algorithmischen Systeme sich beständig ändern *und* zudem die Transparenz der Kommunikation³ über deren Wirken Schwankungen unterliegt, b) das selbsteingeschätzte Wissen über Algorithmen in den letzten Jahren generell zugenommen hat (Overdiek & Petersen, 2022) und c) das Bewusstsein nicht über alle genutzten Plattformen hinweg identisch ist. So bestimmen etwa Aspekte wie die ‚Aggressivität‘ bzw. Offenkundigkeit der operierenden algorithmischen Systeme (Siles & Meléndez-Moran, 2021), Nutzungsintensität und -erfahrungen (Cotter & Reisdorf, 2020) oder während der Nutzung erlebte Widersprüche zwischen erwarteten und tatsächlich angezeigten Inhalten (Swart, 2021), wie bewusst Nutzer:innen die Algorithmisierung wahrnehmen. Doch selbst das oberflächliche Wissen darüber, dass Algorithmen am Werk sind, öffnet bereits die Möglichkeit für die Ausbildung eines „algorithmic imaginary“ (Bucher, 2017) bzw. die Entwicklung von naiven Medientheorien darüber, wie Algorithmen auf spezifischen Plattformen arbeiten.

3.2 Sinngebung: Algorithmic Sensemaking

Gerade weil viele Nutzer:innen nur über eingeschränktes Wissen darüber verfügen, wie genau Algorithmen auf diversen Plattformen arbeiten, sind *Vorstellungen* über deren Funktionsweise weit verbreitet. Solche „naiven Medientheorien“ (Naab, 2013), die als Sonderform der in der Sozialpsychologie vielfach untersuchten *folk theories* gelten können, beschreiben im Kontext von algorithmischen Systemen alle informellen Annahmen, die Nutzer:innen entwickeln, um sich zu erklären, anhand welcher Parameter die automatische Personalisierung in algorithmisierten Medienumgebungen erfolgt (siehe z.B. Dogruel, 2021b; Eslami et al., 2016; Ytre-Arne & Moe, 2021).

Aus kommunikationswissenschaftlicher Sicht ist die Untersuchung von solchen Sinngebungsprozessen nicht nur aufschlussreich, weil sie etwas über tatsächliche Wissensbestände verraten kann (siehe auch Oeldorf-Hirsch & Neubaum, 2021, S. 10), sondern insbesondere, weil auch

³ So hat Facebook etwa im Frühjahr 2019 die Funktion „Warum wird mir dieser Beitrag angezeigt?“ eingeführt, die es Nutzer:innen ermöglichen soll, besser zu verstehen, welche Faktoren über die Ausspielung von Inhalten im Newsfeed entscheiden.

falsche oder unvollständige Vorstellungen hochgradig handlungsrelevant sein können. So zeigen Studien, dass individuelle Theorien über die Funktionsweise von Algorithmen beeinflussen, mit welchen Inhalten Nutzer:innen bewusst (nicht) interagieren und welche Erwartungen sie an Plattformen stellen (für einen Überblick siehe Cotter, 2022). Genau wie wissenschaftliche Theorien werden auch naive Medientheorien getestet: Gehe ich etwa davon aus, dass ich auf Facebook umso mehr Inhalte von einem Account angezeigt bekomme, je mehr ich mit diesem Account interagiere (*personal engagement theory*, Eslami et al., 2016), kann ich das durch mein eigenes Handeln und anschließende Beobachtungen meines Newsfeeds ‚überprüfen‘. In der Forschung wurde eine Vielzahl an naiven Medientheorien über algorithmische Systeme identifiziert, die auf unterschiedlichen Abstraktionsebenen liegen und sich zudem in Abhängigkeit davon unterscheiden, ob sie sich allgemein auf Algorithmen in Online-Umgebungen beziehen (Dogruel, 2021b) oder auf die Funktionsweise spezifischer Plattformen wie Facebook (Eslami et al., 2016), Spotify (Siles et al., 2020) oder TikTok (Karizat et al., 2021) ausgerichtet sind. Dabei gibt es aber durchaus Überschneidungen, was sich etwa an der Prävalenz von Theorien zeigt, die auf der allgemeinen Popularität von Inhalten (‚Angezeigt wird, was allgemein beliebt ist‘), dem Verhalten von ähnlichen Nutzer:innen (‚Angezeigt wird, was Leute mögen, die mir ähneln‘) oder dem eigenen Interaktionsverhalten (‚Angezeigt wird, was ich häufig nutze/anklicke/bewerte‘) beruhen. Erneut vergleichbar zu wissenschaftlichen Theorien bilden sich auch naive Medientheorien entweder induktiv durch individuelle Erfahrungen und Beobachtungen, die innerhalb der Plattform gemacht werden, oder aber deduktiv, indem z.B. aus Medienberichten über algorithmische Systeme oder den Theorien anderer Nutzer:innen Annahmen abgeleitet werden (siehe auch DeVito et al., 2018).

Das (vermeintliche) Wissen wird von vielen Nutzer:innen schließlich auch angewendet, um algorithmische Systeme zu *trainieren* (Karizat et al., 2021; Siles et al., 2020; Siles & Meléndez-Moran, 2021), was über Optionen zur expliziten Personalisierung oder kalkultiertes Nutzungsverhalten realisiert wird. Siles und Kolleg:innen (2020) etwa zeigen, wie Spotify-Nutzer:innen bewusst Songs liken, Künstler:innen folgen oder wiederholt die gleichen Alben hören, um ‚dem Algorithmus‘ zu zeigen, was sie mögen. Bei der besonders stark durch algorithmische Kuratierung geprägten Plattform TikTok sind die Trainingsprozesse aus Sicht der Nutzer:innen essentiell (Karizat et al., 2021; Siles & Meléndez-Moran, 2021): Nur durch regelmäßiges Liken, bewusste Suchen nach Inhalten, die man mag, oder die Nutzung des ‚Nicht interessiert‘-Features sei es möglich, die For-You-Page zu ‚zähmen‘. Wirklich genießen, so die befragten Nutzer:innen, könne man TikTok erst, wenn das Training abgeschlossen sei und die App sich so verhält, wie man das möchte (Siles & Meléndez-Moran, 2021, S. 19). Der Erfolg des Algorithmus-

Trainings kann dann wiederum Gestalt und Inhalt der naiven Medientheorien der Nutzer:innen verändern, indem die individuellen Hypothesen über die Funktionsweise der algorithmischen Systeme modifiziert werden. Für Nutzer:innen, die in algorithmisierten Medienumgebungen mit eigenen Inhalten erfolgreich sein wollen, stehen mittlerweile eine ganze Reihe von selbst-erklärten Algorithmus-Expert:innen bereit, die Theorien über die Sichtbarkeit beeinflussende Faktoren an aufstrebende ‚Content Creators‘ verkaufen (Bishop, 2020).

Die Vorstellungen über algorithmische Systeme gehen Hand in Hand mit spezifischen *Einstellungen*, die sich auf einem Spektrum von Aversion (engl. *algorithmic aversion*) bis Wertschätzung (engl. *algorithmic appreciation*) abbilden lassen (Oeldorf-Hirsch & Neubaum, 2021, S. 11). Darunter fallen zunächst allgemeine Einstellungen bzgl. der Nützlichkeit/Güte algorithmischer Empfehlungen, aber auch plattform- und situationsspezifische Zu- und Abneigungen. So werden vor allem spürbare Änderungen der algorithmischen Systeme häufig negativ wahrgenommen und sorgen für Kritik auf Seiten der Nutzer:innen, was sich auch in Hashtags wie #RIPTwitter oder in Petitionen wie ‚Make Instagram Instagram again‘ widerspiegelt (Gollmer, 2022). Die auf Algorithmen gerichteten Einstellungen und Sinngebungsprozesse stehen schließlich auch in engem Zusammenhang mit algorithmischen Kompetenzen, die für Nutzer:innen immer wichtiger werden, um sich selbstbestimmt in algorithmisierten Medienumgebungen zu bewegen.

3.3 Kompetenz: Algorithmic Literacy

Obwohl sich kommunikationswissenschaftliche Beobachter:innen einig darüber sind, dass ein fundiertes Wissen über algorithmische Systeme sowie die Fähigkeit, souverän durch algorithmisierte Medienumgebungen zu navigieren, für Nutzer:innen heute unabdingbar sind, gab es bisher kaum Bemühungen, das Konzept der algorithmischen Kompetenz (engl. *algorithmic literacy*) umfassend zu dimensionieren und definieren (siehe Dogruel, 2021a; Oeldorf-Hirsch & Neubaum, 2021). Vielversprechend und breit anwendbar ist die Konzeptualisierung von Dogruel (2021a; Dogruel et al., 2021), die auf Basis eines Literatur-Reviews von verwandten Kompetenzkonzepten, bestehenden Definitionen von *algorithmic literacy* sowie einer qualitativen Interviewstudie vier relevante Dimensionen ableitet: (1) Bewusstsein und Wissen, (2) kritische Bewertung, (3) Bewältigungsstrategien und (4) Gestaltungs- und Designfähigkeiten. Demnach umfasst algorithmische Kompetenz das Wissen um die Verwendung von Algorithmen in Online-Umgebungen, die Kenntnis über deren Funktionsweise, die Fähigkeit, algorithmische Auswahlprozesse kritisch zu bewerten sowie konkrete Fertigkeiten, die nötig sind, um

mit algorithmischen Systemen umzugehen sowie diese aktiv zu beeinflussen (Dogruel et al., 2021, S. 4).

Am Beispiel des Video-Streamingdienstes Netflix lässt sich dies illustrieren: Eine kompetente Nutzerin wüsste hier nicht nur, dass die Film- und Serienempfehlungen auf der Startseite durch algorithmische Systeme kuratiert sind und welche Faktoren deren Auswahl und Darstellung prinzipiell mitbestimmen können. Sie kann auch bewerten und reflektieren, inwiefern diese Selektion ihre und die Entscheidungen anderer Nutzer:innen lenkt und möglicherweise einschränkt. Schließlich ist sie in der Lage, durch gezielte Ratings, Suchen oder das Anlegen von Profilen Einfluss auf die algorithmische Kuratierung zu nehmen und das Angebot so selbstbestimmt zu nutzen.

Ein großes Problem bei der Untersuchung von *algorithmic literacy* ist der bereits angesprochene Black-Box-Charakter von algorithmischen Systemen (DeVito et al., 2018; Hargittai et al., 2020; Oeldorf-Hirsch & Neubaum, 2021): Da auch die Forscher:innen in aller Regel nicht ‚die Wahrheit‘ kennen bzw. über alle Indikatoren Bescheid wissen, die die algorithmische Kuratierung beeinflussen, ist es schwierig, algorithmische Kompetenzen valide zu messen. Das gilt insbesondere dann, wenn man an der Entwicklung von quantitativen Messinstrumenten interessiert ist, die idealerweise auf mehrere Plattformen/Anwendungen übertragbar sind und auch in einigen Jahren noch sinnvoll eingesetzt werden können. Vor diesem Hintergrund verwundert es nicht, dass die Frage nach algorithmischen Kompetenzen bislang vor allem qualitativ-explorativ untersucht wurde oder lediglich für bestimmte Plattformen zu bestimmten Entwicklungsstufen der sich dynamisch wandelnden algorithmischen Systeme betrachtet wurde (für einen Überblick siehe Oeldorf-Hirsch & Neubaum, 2021, S. 15–17). Dogruel und Kollegen (2021) versuchen sich auf Basis der oben vorgestellten Definition an der Entwicklung einer standardisierten Skala, die zumindest die *kognitiven* Aspekte algorithmischer Kompetenzen (d.h., Bewusstsein und Wissen) generalisiert für Online-Umgebungen messen kann. Zur Abfrage des Bewusstseins müssen die Befragten dabei für verschiedene Medientechnologien entscheiden, ob diese algorithmische Systeme nutzen (z.B. Smartspeaker), während für die Messung des Wissens eine Reihe von Statements als wahr oder falsch klassifiziert werden muss (z.B. „Durch den Einsatz von Algorithmen, die personalisierte Inhalte liefern, kann es dazu kommen, dass einen hauptsächlich Inhalte erreichen, die der eigenen Meinung ähnlich sind“).

Solche globalen Messungen sind gerade im Rahmen von bevölkerungsrepräsentativen Befragungen hilfreich, um einen generellen Eindruck von algorithmischen Kompetenzen und deren Veränderungen im Zeitverlauf zu bekommen. Es bleibt ob der großen Unterschiede zwischen

algorithmischen Systemen aber dennoch wichtig und sinnvoll, auch kontext- und plattformspezifische Studien durchzuführen sowie zu betrachten, inwiefern Nutzer:innen motiviert sind, ihr vorhandenes Wissen in *Handeln* umzusetzen (Riesmeyer et al., 2016). Denn nur weil eine Person weiß, dass ihr Newsfeed algorithmisch personalisiert ist oder wie sie beeinflussen kann, welche Inhalte dort angezeigt werden, bedeutet das noch lange nicht, dass sie auch entsprechend kompetent handelt und etwa bewusst dafür Sorge trägt, dass sie auch mit Inhalten konfrontiert wird, die ihre eigene Meinung herausfordern oder neue Perspektiven auf ein Thema aufzeigen (siehe auch Fouquaert & Mechant, 2021). Um algorithmische Kompetenz zu fördern – die neben Bewusstsein und Wissen eben auch kompetentes Handeln umfasst –, müssen demnach Vermittlungsansätze entwickelt werden, die nicht nur darauf abzielen, Nutzer:innen die Funktionsweise von Algorithmen näherzubringen, sondern diese auch dazu motivieren, aktiv aneignend mit algorithmischen Systemen umzugehen. Oeldorf-Hirsch und Neubaum (2021, S. 22–24) sehen hier insbesondere in dem Wecken von Neugierde über Algorithmen sowie dem praktischen Umgang mit algorithmischen Systemen fruchtbare Ansätze. Gerade ersteres könnte auch durch die Plattformen selbst forciert werden, indem etwa bei der Selektion von Inhalten ein Pop-Up die Nutzer:innen zur Auseinandersetzung anregt (z.B. „Neugierig, warum dir dieser Inhalt angezeigt wird?“, ebd., S. 23). Wie gleich noch abschließend betrachtet wird, ist es gerade im Kontext von Informationsnutzungsprozessen zentral, dass Nutzer:innen mögliche Probleme der automatisiert personalisierten Auswahl von Inhalten kritisch reflektieren und sich bei ihrer informationsbezogenen Medienrezeption nicht ausschließlich von Empfehlungsalgorithmen leiten lassen.

4. Fazit und Ausblick

4.1 Implikationen der Medienrezeption in algorithmisierten Umgebungen

Der in den letzten Jahren zu beobachtende „algorithmic turn“ (Napoli, 2014) bzw. „algorithmische Strukturwandel der Öffentlichkeit“ (Hagen et al., 2017) wurde insbesondere in der öffentlichen Debatte von Ängsten über zunehmende Fragmentierung, Polarisierung und Radikalisierung des Diskurses begleitet (für einen Überblick siehe z.B. Geiß et al., 2018; Rau & Stier, 2019; Stark et al., 2021). Unter Bezugnahme auf die intuitiv anschaulichen Buzzwords „Filterblasen“ und „Echokammern“⁴ befürchtete man, dass Nutzer:innen sich in eine Medienumge-

⁴ Die Begriffe werden gerade in nicht-wissenschaftlichen Debatten oft synonym verwendet, um auf dysfunktionale Verzerrungen in algorithmisierten Medienumgebungen hinzuweisen. Diese Vermischung liegt auch daran, dass sie verwandte, aber keineswegs identische Phänomene beschreiben: Der Begriff „Echokammer“ ist stärker

bung begeben (oder ohne ihr Zutun in diese gelangen), in der sie nur noch mit Themen konfrontiert werden, die sie interessieren und in der sie ausschließlich Meinungen begegnen, die ihrem eigenen Standpunkt entsprechen (Stark et al., 2021, S. 303). Diskutiert wurden mögliche gesellschaftlichen Folgen der automatisierten Personalisierung durch algorithmische Systeme vor allem für (politische) Informationsnutzungsprozesse, wenngleich einige Autor:innen auch auf die Gefahren der unterhaltungsbezogenen Medienrezeption verweisen. So könne auch die Nutzung von Unterhaltungsangeboten in algorithmisierten Umgebungen aufgrund von Kultivierungseffekten „die politische Informiertheit und Meinungsbildung der Bevölkerung durchaus [beeinträchtigen]“ (Schweiger et al., 2019, S. 120).

In der Tat scheinen diese Ängste auf den ersten Blick plausibel: Wie eingangs verdeutlicht wurde, haben die gewinnorientierten algorithmisierten Plattformen vor allem die Generierung von (Werbe-)Einnahmen im Blick: In den Feed ‚gespült‘ wird das, was die Nutzer:innen lange bei der Stange hält – also nur Themen, die persönlich interessant sind, und Meinungen, die man teilt? Der aktuelle Forschungsstand spricht dafür, dass diese Befürchtungen weitgehend unbegründet scheinen und die mit Filterblasen und Echokammern in Verbindung gebrachten Gefahren überschätzt werden (siehe zusammenfassend Möller, 2021; Stark et al., 2021). Dies soll jedoch nicht in Abrede stellen, dass für einzelne Nutzer:innen mit spezifischen Persönlichkeits- und Mediennutzungsprofilen ein ungleich größeres Risiko einer thematisch und weltanschaulich verengten Informationsversorgung besteht. Dafür sind jedoch nicht nur algorithmische Systeme, sondern nicht zuletzt individuelle *menschliche* Entscheidungen und selektive Verarbeitungsprozesse verantwortlich, was erneut auf die Notwendigkeit der Förderung von algorithmischen Kompetenzen verweist.

Für die öffentliche Auseinandersetzung scheint es demnach fruchtbarer, den Diskurs wegzu lenken von den häufig übertriebenen Gefahren hin zu einer rationalen Auseinandersetzung mit der Frage, wie algorithmisierte Medientumgebungen Informationsökologien gestalten und welche positive oder negative Rolle sie vor diesem Hintergrund für Informationsnutzung und Meinungsbildung spielen. Zentral ist etwa ein besseres Verständnis davon, wie algorithmische Personalisierung die Wahrnehmung des Meinungsklimas beeinflusst oder Ungleichheiten in der

mit Mechanismen der *expliziten* Personalisierung verbunden und fußt auf einer *gruppenspezifischen* Perspektive: Menschen suchten demnach auch in Online-Umgebungen primär nach Netzwerken an Gleichgesinnten, innerhalb derer es schließlich zu einer andauernden gegenseitigen Bestätigung der eigenen (geteilten) Meinung und in Folge zu einer Verengung politischer Perspektiven käme. Der Begriff „Filterblase“ ist hingegen stärker mit Mechanismen der *impliziten* Personalisierung verbunden und fußt auf einer eher *technikdeterministischen* Perspektive: Menschen würden demnach durch das Wirken algorithmischer Systeme ohne ihr Zutun in einem individuellen Informations-Ökosystem landen, was ebenfalls zu einer verengten Weltsicht führe. (Hagen et al., 2017, S. 133; Rau & Stier, 2019, S. 402; Stark et al., 2021, S. 306–307)

Auseinandersetzung mit Informationsinhalten begünstigen kann (Möller, 2021, S. 97; Stark et al., 2021, S. 316). Gleichmaßen lässt sich fragen, wie Empfehlungssysteme gestaltet werden können, die Zielgrößen wie Vielfalt und gesellschaftliche Relevanz berücksichtigen und so etwa auch von öffentlich-rechtlichen Medienanbietern genutzt werden können (Schmidt et al., 2018).

4.2 Entwicklung und methodische Herausforderungen

Die Entwicklungen im Mediennutzungsverhalten der letzten Jahre zeigen deutlich, welche große Bedeutung algorithmisierten Umgebungen zukommt. Algorithmen beeinflussen dabei nicht nur die Selektion von Medieninhalten, sondern ob ihrer Priorisierungs- und Hervorhebungsfunktion auch deren emotionale und kognitive Verarbeitung. Alle Anzeichen deuten darauf hin, dass der Trend zur automatisierten Personalisierung auch künftig nicht abbricht (Schweiger et al., 2019, S. 120). Vielmehr muss man angesichts des anhaltenden Erfolgs von Social-Media-Plattformen, Streamingdiensten & Co. die Frage stellen, ob es künftig überhaupt noch so etwas wie ‚unalgorithmisierte‘ Mediennutzung geben wird.

Für die Kommunikationswissenschaft lässt sich daraus zum einen der Auftrag ableiten, kontinuierlich zu analysieren, wie verschiedene algorithmisierte Umgebungen die Medienrezeption prägen, wie Nutzer:innen sich in diesen bewegen und insbesondere, wie die Wechselwirkung aus Plattformlogiken und menschlichem Verhalten beeinflusst, welche Inhalte Aufmerksamkeit erhalten und mithin Auswirkungen auf unser Denken und Handeln nehmen können. Zum anderen ergeben sich aus eben diesem Auftrag spezifische *methodische* Herausforderungen: Wenn alle Nutzer:innen mit einer jeweils einzigartigen und dynamischen Auswahl an Inhalten konfrontiert werden, die sich zudem mit jedem neuen Zugriff ändern können, wie lässt sich Medienrezeption dann überhaupt noch untersuchen? Vor diesem Hintergrund wurde bislang vor allem diskutiert, wie sich herausfinden lässt, mit welchen Inhalten Nutzer:innen in algorithmisierten Umgebungen in Kontakt kommen (für einen Überblick siehe Haim, 2020). Fruchtbare Ansätze in diesem Bereich sind etwa die Gewinnung von Primärdaten durch Datenspenden⁵ oder aber die Nutzung von Browser-Plug-Ins, die bspw. automatisiert beobachten können, welche Posts einzelne Nutzer:innen sehen, wenn sie auf Social-Media-Plattformen unterwegs sind (Haim & Nienierza, 2019). Ist man indes an Medienrezeption im engeren Sinne interessiert – d.h. an der tatsächlichen Auseinandersetzung mit Inhalten und den damit zusammenhängenden

⁵ Die Grundidee von Datenspenden (engl. *data donations*) basiert darauf, dass Nutzer:innen freiwillig Daten über ihre Nutzung digitaler Plattformen und Dienste für die Wissenschaft zur Verfügung stellen, indem sie von ihrem durch die DSGVO bzw. GDPR gedeckten Recht Gebrauch machen, die über sie erhobenen Daten anzufordern (Boeschoten et al., 2020).

Kognitionen und Emotionen – sind weitere methodische Zugänge vonnöten. Hier eignen sich stärker qualitative Zugänge, die direkte Beobachtungen des Rezeptionsverhaltens mit Post-Exposure-Walkthroughs verbinden (Kümpel, 2019) oder mit Think-Aloud-Protokollen arbeiten (Freiling, 2019), um Rezeptionspraktiken sowie deren Bedeutung zu erfassen. Für eine umfassende Analyse von Medienrezeption in algorithmisierten Umgebungen erscheint nicht zuletzt die Kombination von quantitativ-computationalen und qualitativ-rekonstruierenden Verfahren in Form von Mixed-Methods-Designs unabdingbar.

Literaturempfehlungen

- Dogruel, L. (2021). What is algorithm literacy? A conceptualization and challenges regarding its empirical measurement. *Algorithms and Communication*, 67–93. <https://doi.org/10.48541/DCR.V9.3>
- Kitchin, R. (2017). Thinking critically about and researching algorithms. *Information, Communication & Society*, 20(1), 14–29. <https://doi.org/10.1080/1369118X.2016.1154087>
- 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. https://doi.org/10.1007/978-3-658-32133-8_17

Literatur

- Beisch, N., & Koch, W. (2021). 25 Jahre ARD/ZDF-Onlinestudie: Unterwegsnutzung steigt wieder und Streaming/ Mediatheken sind weiterhin Treiber des medialen Internets. *Media Perspektiven*, 10, 486–503.
- Bishop, S. (2020). Algorithmic experts: Selling algorithmic lore on youtube. *Social Media + Society*, 6(1). <https://doi.org/10.1177/2056305119897323>
- Boeschoten, L., Ausloos, J., Moeller, J., Araujo, T., & Oberski, D. L. (2020). Digital trace data collection through data donation. *arXiv:2011.09851 [cs, stat]*. <http://arxiv.org/abs/2011.09851>
- 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. (2017). The algorithmic imaginary: Exploring the ordinary affects of Facebook algorithms. *Information, Communication & Society*, 20(1), 30–44. <https://doi.org/10.1080/1369118X.2016.1154086>
- 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>
- Burke, R. (2007). Hybrid web recommender systems. In P. Brusilovsky, A. Kobsa, & W. Nejdl (Hrsg.), *The Adaptive Web: Methods and Strategies of Web Personalization* (S. 377–408). Springer. https://doi.org/10.1007/978-3-540-72079-9_12

- Cotter, K. (2022). Practical knowledge of algorithms: The case of BreadTube. *New Media & Society*, 14614448221081802. <https://doi.org/10.1177/14614448221081802>
- Cotter, K., & Reisdorf, B. C. (2020). Algorithmic knowledge gaps: A new horizon of (digital) inequality. *International Journal of Communication*, 14, 745–765.
- 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>
- DeVito, M. A., Birnholtz, J., Hancock, J. T., French, M., & Liu, S. (2018). How people form folk theories of social media feeds and what it means for how we study self-presentation. *CHI '18: Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems*, 1–12. <https://doi.org/10.1145/3173574.3173694>
- 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>
- Dogruel, L. (2021a). What is algorithm literacy? A conceptualization and challenges regarding its empirical measurement. *Algorithms and Communication*, 67–93. <https://doi.org/10.48541/DCR.V9.3>
- Dogruel, L. (2021b). 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>
- Dogruel, L., Masur, P., & Joeckel, S. (2021). Development and validation of an algorithm literacy scale for Internet users. *Communication Methods and Measures*. <https://doi.org/10.1080/19312458.2021.1968361>
- 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>
- Facebook Help Center. (o. D.). *How does the Facebook feed ranking work?* <https://www.facebook.com/help/2856031874648203/>
- Fouquaert, T., & Mechant, P. (2021). Making curation algorithms apparent: A case study of ‘Instawareness’ as a means to heighten awareness and understanding of Instagram’s algorithm. *Information, Communication & Society*. <https://doi.org/10.1080/1369118X.2021.1883707>
- Freiling, I. (2019). Detecting misinformation in online social networks: A think-aloud study on user strategies. *Studies in Communication and Media*, 8(4), 471–496. <https://doi.org/10.5771/2192-4007-2019-4-471>
- 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>

- 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>
- Gollmer, P. (2022, Juli 29). Instagram und Facebook: Änderungen am Feed im Kampf gegen Tiktok. *Neue Zürcher Zeitung*. <https://www.nzz.ch/technologie/instagram-und-facebook-veraenderungen-im-algorithmus-ld.1695604>
- Hadida, A. L., Lampel, J., Walls, W. D., & Joshi, A. (2021). Hollywood studio filmmaking in the age of Netflix: A tale of two institutional logics. *Journal of Cultural Economics*, 45(2), 213–238. <https://doi.org/10.1007/s10824-020-09379-z>
- 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>
- Haim, M. (2020). Agent-based testing: An automated approach toward artificial reactions to human behavior. *Journalism Studies*, 21(7), 895–911. <https://doi.org/10.1080/1461670X.2019.1702892>
- Haim, M., & Graefe, A. (2018). Automatisierter Journalismus. In C. Nuernbergk & C. Neuberger (Hrsg.), *Journalismus im Internet: Profession—Partizipation—Technisierung* (S. 139–160). Springer. https://doi.org/10.1007/978-3-531-93284-2_5
- Haim, M., & Nienierza, A. (2019). Computational observation: Challenges and opportunities of automated observation within algorithmically curated media environments using a browser plug-in. *Computational Communication Research*, 1(1), 79–102. <https://doi.org/10.5117/CCR2019.1.004.HAIM>
- 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
- 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>
- Hölig, S., Behre, J., & Schulz, W. (2022). *Reuters Institute Digital News Report 2022 – Ergebnisse für Deutschland* (Nr. 63; Arbeitspapiere des Hans-Bredow-Instituts). Hans-Bredow-Institut.
- 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>
- Kapsch, P. H. (2022). Exploring user agency and small acts of algorithm engagement in everyday media use. *Media International Australia*, 183(1), 16–29. <https://doi.org/10.1177/1329878X211067803>
- Karizat, N., Delmonaco, D., Eslami, M., & Andalibi, N. (2021). Algorithmic folk theories and identity: How TikTok users co-produce knowledge of identity and engage in algorithmic resistance. *Proceedings of the ACM on Human-Computer Interaction*, 5(CSCW2), 1–44. <https://doi.org/10.1145/3476046>

- 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. (2019). Dynamik im Blick: Die qualitative Beobachtung mit Post-Exposure-Walkthrough als Verfahren für die Rekonstruktion individueller Navigations- und Selektionshandlungen auf sozialen Netzwerkseiten (SNS). In P. Müller, S. Geiss, C. Schemer, T. K. Naab, & C. Peter (Hrsg.), *Dynamische Prozesse der öffentlichen Kommunikation. Methodische Herausforderungen* (S. 216–238). Herbert von Halem.
- Lischka, K., & Stöcker, C. (2017). *Digitale Öffentlichkeit. Wie algorithmische Prozesse den gesellschaftlichen Diskurs beeinflussen* [Arbeitspapier]. Bertelsmann Stiftung. https://www.bertelsmann-stiftung.de/index.php?id=5772&tx_rsmbstpublications_pi2%5bdoi%5d=10.11586/2017028&no_cache=1
- Merten, L. (2021). Block, hide or follow—Personal news curation practices on social media. *Digital Journalism*, 9(8), 1018–1039. <https://doi.org/10.1080/21670811.2020.1829978>
- 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.
- Mosseri, A. (2021, Juni 8). Shedding more light on how Instagram works. *Instagram Blog*. <https://about.instagram.com/blog/announcements/shedding-more-light-on-how-instagram-works>
- Naab, T. (2013). *Naive Medientheorien und Third-Person Perception: Eine Untersuchung zur Integrierbarkeit beider Konzepte* (1. Auflage). Nomos.
- Napoli, P. M. (2014). Automated media: An institutional theory perspective on algorithmic media production and consumption. *Communication Theory*, 24(3), 340–360. <https://doi.org/10.1111/comt.12039>
- Netflix Help Center. (o. D.). *How Netflix's recommendations system works*. <https://help.netflix.com/en/node/100639>
- Oeldorf-Hirsch, A., & Neubaum, G. (2021). *What do we know about algorithmic literacy? The status quo and a research agenda for a growing field*. SocArXiv. <https://doi.org/10.31235/osf.io/2fd4j>
- Overdiek, M., & Petersen, T. (2022). *Was Deutschland über Algorithmen und Künstliche Intelligenz weiß und denkt: Ergebnisse einer repräsentativen Bevölkerungsumfrage: Update 2022*. Bertelsmann Stiftung. <https://www.bertelsmann-stiftung.de/doi/10.11586/2022053>
- 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>
- 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. https://doi.org/10.1007/978-1-4899-7637-6_1

- Riesmeyer, C., Pfaff-Rüdiger, S., & Kümpel, A. S. (2016). Wenn Wissen zu Handeln wird: Medienkompetenz aus motivationaler Perspektive. *Medien & Kommunikationswissenschaft*, 64(1), 36–55. <https://doi.org/10.5771/1615-634X-2016-1-36>
- 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., Weber, P., Prochazka, F., & Brückner, L. (2019). *Algorithmisch personalisierte Nachrichtenkanäle: Begriffe, Nutzung, Wirkung*. Springer. <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., Segura-Castillo, A., Solís, R., & Sancho, M. (2020). Folk theories of algorithmic recommendations on Spotify: Enacting data assemblages in the global South. *Big Data & Society*, 7(1). <https://doi.org/10.1177/2053951720923377>
- 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. https://doi.org/10.1007/978-3-658-32133-8_17
- Swart, J. (2021). Experiencing algorithms: How young people understand, feel about, and engage with algorithmic news selection on social media. *Social Media + Society*, 7(2). <https://doi.org/10.1177/20563051211008828>
- 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>
- Thurman, N., & Schifferes, S. (2012). The future of personalization at news websites. Lessons from a longitudinal study. *Journalism Studies*, 13(5–6), 775–790. <https://doi.org/10.1080/1461670X.2012.664341>
- TikTok Help Center. (o. D.). *For You*. <https://support.tiktok.com/en/getting-started/for-you>

- 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>
- Willson, M. (2017). Algorithms (and the) everyday. *Information, Communication & Society*, 20(1), 137–150. <https://doi.org/10.1080/1369118X.2016.1200645>
- YouTube. (o. D.). *Recommended videos*. <https://www.youtube.com/howyoutubeworks/product-features/recommendations/>
- Ytre-Arne, B., & Moe, H. (2021). Folk theories of algorithms: Understanding digital irritation. *Media, Culture & Society*, 43(5), 807–824. <https://doi.org/10.1177/0163443720972314>
- 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>
- Zarouali, B., Boerman, S. C., & de Vreese, C. H. (2021). Is this recommended by an algorithm? The development and validation of the algorithmic media content awareness scale (AMCA-scale). *Telematics and Informatics*, 62, 101607. <https://doi.org/10.1016/j.tele.2021.101607>
- 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>