

## University of Groningen

### „Das könnte Sie auch interessieren“

Luchs, Inga; Apprich, Clemens; Broersma, Marcel

*Published in:*  
Handbuch Digitale Medien und Methoden

*DOI:*  
[10.1007/978-3-658-36629-2\\_13-1](https://doi.org/10.1007/978-3-658-36629-2_13-1)

**IMPORTANT NOTE: You are advised to consult the publisher's version (publisher's PDF) if you wish to cite from it. Please check the document version below.**

*Document Version*  
Publisher's PDF, also known as Version of record

*Publication date:*  
2024

[Link to publication in University of Groningen/UMCG research database](#)

*Citation for published version (APA):*

Luchs, I., Apprich, C., & Broersma, M. (2024). „Das könnte Sie auch interessieren“: Methoden zur Erforschung algorithmischer Empfehlungssysteme. In S. Stollfuß, L. Niebling, & F. Raczkowski (Eds.), *Handbuch Digitale Medien und Methoden* (pp. 1-18). Springer VS. [https://doi.org/10.1007/978-3-658-36629-2\\_13-1](https://doi.org/10.1007/978-3-658-36629-2_13-1)

#### Copyright

Other than for strictly personal use, it is not permitted to download or to forward/distribute the text or part of it without the consent of the author(s) and/or copyright holder(s), unless the work is under an open content license (like Creative Commons).

The publication may also be distributed here under the terms of Article 25fa of the Dutch Copyright Act, indicated by the “Taverne” license. More information can be found on the University of Groningen website: <https://www.rug.nl/library/open-access/self-archiving-pure/taverne-amendment>.

#### Take-down policy

If you believe that this document breaches copyright please contact us providing details, and we will remove access to the work immediately and investigate your claim.

*Downloaded from the University of Groningen/UMCG research database (Pure): <http://www.rug.nl/research/portal>. For technical reasons the number of authors shown on this cover page is limited to 10 maximum.*



# „Das könnte Sie auch interessieren“ – Methoden zur Erforschung algorithmischer Empfehlungssysteme

Inga Luchs, Clemens Apprich und Marcel Broersma

## Inhalt

1	Einleitung .....	2
2	Klassifikation von Empfehlungssystemen .....	3
3	Erforschung von Empfehlungssystemen .....	5
4	Neubestimmung von Empfehlungssystemen .....	9
5	Fazit und Ausblick .....	15
	Literatur .....	16

## Zusammenfassung

Empfehlungssysteme sind überall. In unserer digitalen Kultur filtern sie nicht nur die für uns „relevanten“ Informationen aus einem immer größer werdenden Datenstrom, sondern prägen auch unsere alltäglichen Medienumgebungen. In diesem Artikel unternehmen wir eine Kartierung bestehender Ansätze zur Untersuchung von Empfehlungssystemen, wobei wir ein besonderes Augenmerk auf einen *Mixed-Methods*-Ansatz aus kritischer Diskursanalyse und genuin digitalen Untersuchungsverfahren (wie z. B. die *Walkthrough*-Methode) setzen. Auf dieser Grundlage werden wir uns der Erforschung von Online-Einführungskursen in das maschinelle Lernen zuwenden, zumal diese einen ganz wesentlichen Einblick in die Funktion, aber auch machtpolitische Bestimmung von algorithmischen Empfehlungssystemen liefern. Uns geht es dabei nicht um eine Kritik bisheriger Arbeiten, sondern vielmehr um eine Erweiterung der methodischen Betrachtung, um so algorithmischen Systemen in ihrer technischen, kulturellen wie politischen Komplexität gerecht zu werden.

I. Luchs · M. Broersma  
University of Groningen, Groningen, Niederlande  
E-Mail: [i.m.luchs@rug.nl](mailto:i.m.luchs@rug.nl); [m.j.broersma@rug.nl](mailto:m.j.broersma@rug.nl)

C. Apprich (✉)  
Universität für angewandte Kunst Wien, Wien, Österreich  
E-Mail: [apprich@uni-ak.ac.at](mailto:apprich@uni-ak.ac.at)

---

**Schlüsselwörter**

Empfehlungssysteme · Filteralgorithmen · Maschinelles Lernen · Kritische Diskursanalyse · Digitale Methoden

---

## 1 Einleitung

Empfehlungssysteme spielen eine wichtige Rolle in digitalen Kulturen. Sie filtern nicht nur die für uns „relevanten“ Informationen aus einem immer größer werdenden Datenstrom, sondern prägen auch unsere alltäglichen Medienumgebungen: Musik-, Film- und andere Streaming-Plattformen wie Spotify und Netflix, Online-Versandhändler wie Amazon, oder Dating-Webseiten wie Parship – sie alle sind auf algorithmische Empfehlungssysteme angewiesen. Grundlegend operieren Algorithmen zur Klassifizierung von Online-Inhalten, wie sie in Empfehlungssystemen eingesetzt werden, nach dem Prinzip der Ähnlichkeit: Methoden des kollaborativen oder inhaltsbasierten Filterns schlagen entweder Dinge vor, die von ähnlichen Nutzer\*innen rezipiert wurden, oder Inhalte, die bereits Rezipiertem ähnlich sind (Chun 2020). Ein viel diskutiertes Problem sind die potenziell entstehenden Filterblasen, die zu einer Reduktion des individuell verfügbaren Angebots führen (Pariser 2011). Doch auch weitere diskriminierende Effekte entstehen, wenn Klassifikationsalgorithmen in der Kreditvergabe, bei Einstellungsverfahren, oder im *Predictive Policing* Anwendung finden (Apprigh et al. 2018).

Mit diesen Herausforderungen, aber auch den Potenzialen von Empfehlungssystemen als Forschungsgegenstand hat sich die Medienwissenschaft in den letzten Jahren zunehmend auseinandergesetzt (Crowe 2019a, b; Hallinan und Striphas 2014; Kaiser und Rauchfleisch 2020; Mackenzie 2018; Prey 2018; Seaver 2018; Tofalvy und Kontai 2021). Dabei lag der Fokus bisher vor allem auf sozio-ethischen Betrachtungen der Entwicklung, Nutzung und den sozialen Auswirkungen konkreter algorithmischer Systeme, während die techno-politische Analyse algorithmischen Filterns – also eine tiefer gehend technisch-informierte Betrachtung kombiniert mit einer machtpolitischen Perspektive – oft zu kurz kam (Ausnahmen bilden hier die Arbeiten von Bernhard Rieder [2020] und Wendy Chun [2020]). Eben hier setzt unser Beitrag an, indem er fragt: Wie lassen sich Empfehlungssysteme in ihrer techno-politischen Dimension untersuchen? Und welche methodischen Zugänge können für die Analyse von Klassifikationsalgorithmen in Anschlag gebracht werden?

In diesem Artikel schlagen wir zunächst eine Kartierung bestehender Ansätze zur Untersuchung von Empfehlungssystemen vor, wobei wir ein besonderes Augenmerk auf einen *Mixed-Methods*-Ansatz aus kritischer Diskursanalyse (→ Mämecke; Nohr) und genuin digitalen Untersuchungsverfahren, wie der ‚Walkthrough-Methode‘ (Light et al. 2018), setzen werden. Auf dieser Grundlage werden wir uns der Erforschung von Online-Einführungskursen in das maschinelle Lernen zuwenden, zumal diese einen ganz wesentlichen Einblick in die Funktion, aber auch machtpolitische Bestimmung von algorithmischen Empfehlungssystemen liefern (Luchs et al. 2023). Uns geht es dabei nicht um eine Kritik bisheriger Arbeiten, die sich, wie

gesagt, vor allem mit den sozio-ethischen Gesichtspunkten von Filteralgorithmen beschäftigt haben, sondern vielmehr um eine Erweiterung der methodischen Betrachtung, um so algorithmischen Systemen in ihrer technischen, kulturellen wie politischen Komplexität gerecht zu werden (Seaver 2017).

---

## 2 Klassifikation von Empfehlungssystemen

### 2.1 Ähnlichkeit, Ordnung, Kategorien

Ein Empfehlungssystem ist, aus technischer Sicht, eine Subklasse algorithmischen Filterns, die ihren Nutzer\*innen bei der Entscheidungsfindung – sei es beim Online-Shopping, der Musik- oder Partner\*innenwahl – unterstützt. So empfehlen die Systeme von Amazon, Spotify oder Tinder Dinge (und manchmal eben auch Personen), die von den Nutzer\*innen gekauft, geteilt oder anderweitig *konsumiert* werden sollen. Dabei verarbeitet das Empfehlungssystem eine große Menge an Daten, aus denen es die für eine\*n spezifische\*n Nutzer\*in wichtigen Informationen – oder welche es dafür hält – herausfiltert (Schrage 2020). Hier wird grob zwischen ‚content-based‘ und ‚collaborative-based‘ unterschieden, wobei im ersteren Fall Empfehlungen auf Grundlage ähnlicher Daten, die für den\*die Nutzer\*in bereits in der Vergangenheit von Interesse waren, generiert, im zweiten Fall dagegen Empfehlungen gegeben werden, die sich aus der Ähnlichkeit zu anderen Nutzer\*innen ergeben. Und auch wenn es in der tatsächlichen Anwendung zumeist zu einer Mischung dieser beiden Ansätze kommt, steht klar das Ähnlichkeitsprinzip – sowohl die *User* als auch den *Content* betreffend – im Zentrum dieser Empfehlungssysteme.

Insofern muss bei einer ersten Einordnung von Empfehlungssystemen festgehalten werden, dass diese stark von der Grundannahme der Homophilie durchzogen sind (Chun 2021, S. 81 ff.). Die Idee beruht auf der Überlegung, dass wir häufig die besten Empfehlungen von jemandem erhalten, der oder die uns ähnlich ist. Wenn also eine Person A das gleiche Interesse an einem Inhalt oder Artikel hat wie Person B, teilt A – so die Annahme – auch das Interesse von B an einem anderen Inhalt oder Artikel. Das heißt letztlich, dass die Vorhersagen über unser Verhalten, welches den Empfehlungen zu Grunde gelegt wird, nicht alleine auf unserem bisherigen, individuellen Verhalten basiert, sondern auf dem Verhalten aller anderen, mit denen wir eine Art Ähnlichkeitsnetzwerk bilden. Wir werden ständig in vordefinierte *Cluster* zusammengefasst und miteinander verglichen, um letztlich Vorhersagen über, sprich Empfehlungen für unser zukünftiges Verhalten treffen zu können (Schrage 2020, S. 117 ff.).

Eine solches Ähnlichkeitsprinzip strukturiert die Klassifizierung von Empfehlungssystemen gleichsam vor. Die Klassifikation beinhaltet somit eine *Ordnung* gegenüber den Dingen, die klassifiziert werden; sie vermittelt jeweils eine eigene Perspektive, ein eigenes Weltbild, eine eigene Geschichte, die wiederum klassifiziert, wie die Homophilie als Ordnungsprinzip von Empfehlungssystemen gut zeigt (Kurgan et al. 2019). Somit dient die Klassifikation als ein Instrument in zwei Richtungen: Zum einen ermöglicht sie eine Kontrolle über den Fluss an möglichen

Erfahrungen („if you like A, you might also like B“), zum anderen liefert sie eine Interpretation eben dieser Erfahrungen gleich mit („you like this because others like you also liked it“). Empfehlungssysteme klassifizieren auf Grundlage dessen, wie sie selbst klassifiziert wurden; es handelt sich bei ihnen also um ‚self-fulfilling prophecies‘ (Apprich et al. 2018).

Da Klassifikationen nur in sozialen Interaktionen bzw. Diskursen existieren, sind sie ständig Veränderungen ausgesetzt (Hodge und Kress 1993, S. 63–65). Bezogen auf Empfehlungssysteme bestehen hierzu zwei Möglichkeiten: Entweder werden neue Daten in das System aufgenommen, was zu einer graduellen Neubestimmung der im System vermerkten Interessen (und damit Empfehlungen) führt; oder es entstehen neue Kategorien der Klassifikation, was eine strukturelle Veränderung des bestehenden Systems impliziert. Die Nutzer\*innen sind im Verhältnis zu Empfehlungssystemen sowohl passiv als auch aktiv; sie bewegen sich zwischen dem bereits klassifizierten System und dem Inhalt, den sie klassifizieren. Der Prozess der Klassifikation, in dem neue Kategorien entstehen können, ist somit ein dynamischer Vorgang, der allerdings stark von der Handlungsmacht der jeweiligen Akteur\*innen abhängt (Cheney-Lippold 2017, S. 46–92).

## 2.2 Diskursanalytische Betrachtung

Die kritische Diskursanalyse beschäftigt sich mit dem Wechselverhältnis aus Klassifikation als einem abstrakt-allgemeinen Phänomen, das eine Ordnung, eine Perspektive, eine Ideologie beinhaltet, und Kategorisierung, einem im Vergleich vielmehr konkret-individuellen Prozess, der eine praxisorientierte Darstellung der menschlichen Realität impliziert (Fairclough 2001). In diesem Sinne beinhaltet jede Kategorisierung von Realität – und etwas anderes sind Empfehlungssysteme letztlich nicht – zugleich ihre Klassifikation, da erst die Kategorisierung der Dinge dem Menschen ermöglicht, die Komplexität der Welt zu strukturieren und somit auf erfassbare Teile zu reduzieren („this is what you like“). Insofern gilt es darauf zu achten, welche Wirkung die Kategorien in einem bestimmten Kontext erhalten (sprich wie sie sich in dem zuvor beschriebenen dynamischen Wechselverhältnis entfalten) und somit zur Konstruktion von Realität beitragen; es kommt also nicht darauf an zu hinterfragen, ob die jeweilige Kategorie *richtig* oder *falsch* ist, sondern sie ist in ihrer besonderen Interaktion und Kontextualität zu sehen (Potter 1996).

Die Auswahl eines bestimmten Realitätsfensters, das durch algorithmische Verfahren gleichsam automatisiert und verfestigt wird, ist insofern problematisch, als damit die bereits erwähnten Filterblasen entstehen (Pariser 2011). Auch diese sind in ihrem jeweiligen Kontext zu verstehen, zumal sie keine monolithischen, das heißt vollständig strukturierten Systeme darstellen – darin unterscheiden sie sich etwas von Echokammern – sondern im Sinne der Klassifikation immer auch brüchig bleiben (siehe, z. B., Arguedas et al. 2022). Laut Foucault bietet daher die diskursanalytische Betrachtung die Möglichkeit, den jeweiligen Wahrheitsdiskurs in Bezug auf seine jeweiligen Machtmechanismen und -institutionen zu untersuchen (Fou-

cault 1996); ein Unterfangen, das uns gerade auch mit Blick auf die Entstehung von Empfehlungssystemen fruchtbar scheint.

Empfehlungssysteme setzen sich aus einer Vielzahl ,diskursiver Elemente' zusammen (z. B. spezifische Algorithmen und Klassifikationsverfahren, aber auch Beschreibungen ihrer Funktionsweise in Arbeitspapieren, Blogs sowie Webseiten). Wir werden uns daher – im Anschluss an eine Darstellung unterschiedlicher Methoden zur Analyse algorithmischer Verfahren – der diskursiven Einbettung von Empfehlungssystemen widmen, indem wir Onlinekurse betrachten, die einen wesentlichen Baustein in ihrer Genese darstellen. In ihrer diskursiven Funktion, noch dazu als von großen Unternehmen angebotene Lehrmaterialien, üben diese Kurse „als Träger von (jeweils gültigem) ,Wissen' Macht aus; sie sind selbst ein Machtfaktor, in dem sie geeignet sind, Verhalten und (andere) Diskurse zu induzieren“ (Jäger 2001, S. 85). Darüber hinaus tragen sie zur Strukturierung von Machtverhältnissen bei, indem sie gesellschaftlich dominante Klassifikationsverfahren fort- und immer wieder auch in unsere Medienumgebungen einschreiben.

Ein Feld, das ganz wesentlich von großen Online-Unternehmen, wie etwa Google, Baidu oder IBM, dominiert wird, bedarf einer solchen diskursanalytischen Perspektive, um Rückschlüsse auf die jeweiligen Machtverhältnisse von Empfehlungssystemen ziehen zu können. Gemeinsam mit einer technischen Untersuchung kann so die diskursive Funktion dieser Systeme, die sowohl klassifiziert werden als auch selbst klassifizieren, in ihrer Wirkung auf unsere Realität betrachtet werden. Die kombinierte Betrachtungsweise ermöglicht es nach der gesellschaftlichen Wirklichkeit von Macht zu fragen, insbesondere wer sie ausübt und mit welchen Mitteln.

---

## 3 Erforschung von Empfehlungssystemen

### 3.1 Algorithmen, Code, Software

Bereits Anfang der 2000er – mit dem Aufkommen neuer technologischer Anwendungen – begannen sich die Medienwissenschaften zunehmend mit den technischen Gegebenheiten von Software, Algorithmen und Code auseinanderzusetzen. So sah Lev Manovich (2002, S. 65) die Notwendigkeit der Öffnung der Disziplin hin zum Feld der Informatik, weil gerade dort das nötige Vokabular zum Verständnis programmierbarer Medien zu finden sei. Auch in späteren Jahren wurde Software oftmals als blinder Fleck in der kulturtheoretischen Auseinandersetzung mit digitalen Medien charakterisiert (Fuller 2008, S. 3).

Beschreibungen wie diese finden wir auch in der Betrachtung zeitgenössischer Algorithmen und ihrer Voraussetzungen (siehe beispielsweise die *Critical Algorithm Studies* oder die *Critical Code Studies* weiter unten). Was diese Ansätze vereint, ist der Wunsch nach einem tiefergreifenden Verständnis technologischer Systeme, um somit eine Verschiebung unserer Aufmerksamkeit weg von ihren Effekten und hin zu ihrem ,Kern' zu ermöglichen (Manovich 2013, S. 9). Dies umfasst zum einen eine Auseinandersetzung mit der Funktionsweise und Entwicklung technologischer Systeme; zum anderen soll der Blick auf den Programmiercode erfolgen – sowohl durch

ein *Close Reading* (→ Inderst), um die ihm inne wohnenden Werte und Normen freizulegen, als auch anhand einer praktischen Auseinandersetzung, indem dieser selbst produziert und somit in seiner Komplexität erfahren werden kann (Berry 2013, S. 9).

Diese Herangehensweise beinhaltet jedoch auch, wie Wendy Hui Kyong Chun bemerkt, die Gefahr einer verkürzten Betrachtung von Software und Code als dasjenige, was es zu wissen gilt und somit aus sich heraus Erkenntnis bringt (Chun 2011, S. 19–54). In dieselbe Kerbe schlägt Nick Seaver (2017, S. 5), wenn er fordert, Algorithmen nicht nur in ihrer Technizität, sondern im Zusammenspiel mit gesellschaftlichen, ökonomischen und politischen Entwicklungen, sprich ihrer diskursiven Einbettung, zu betrachten. Dies steht im Einklang mit den Arbeiten Bernhard Rieders, der sich auf ‚algorithmische Techniken‘ konzentriert, also denjenigen Wissens- und Technikkonzepte, die wiederholt in der Entwicklung algorithmischer Systeme Anwendung finden (Rieder 2020, S. 13). Anstatt, wie in der Tradition der *Software Studies*, den Fokus auf bestimmte, bereits ausdifferenzierte technische Entitäten zu legen, geht es Rieder um deren historische Entstehung, um so die ihnen inhärenten heterogenen und kontingenten Ideen nachzuvollziehen. Hierbei bedient er sich der Tradition der Kulturtechnikforschung, die, um den Dualismus von Kultur und Medien zu überwinden, den Fokus nicht auf ein ontologisches Verständnis technischer Medien richtet, sondern sie vielmehr in ihrer ontischen Genese versteht, d. h., in der Entstehung der in ihnen eingeschriebenen Techniken (Engell und Siegert 2010, S. 7).

Um dieser Komplexität gerecht zu werden, kartieren wir im Folgenden zunächst verschiedene Analysemethoden zur Erforschung von Algorithmen und algorithmischer Systeme. Im Anschluss diskutieren wir, wie diese für einen *Mixed-Methods*-Ansatz, bestehend aus kritischer Diskursanalyse und *Walkthrough*-Methode, genutzt werden können, der algorithmischen Systemen sowohl in ihrer technischen Komplexität sowie in ihren politischen, sozialen und kulturellen Auswirkungen gerecht wird. Während es in der bisherigen medienwissenschaftlichen Forschung bereits vielversprechende Herangehensweisen zur Betrachtung technologischer Systeme in ihren jeweiligen soziokulturellen Kontexten gibt, wollen hiermit zu einer tiefer gehenden Aneignung und Reflexion von technischem Wissen in seiner machtpolitischen Dimension beitragen.

## 3.2 Digitale Methoden

Wie Algorithmen generell können auch Empfehlungssysteme im Speziellen aus unterschiedlichen Perspektiven verstanden und analysiert werden: in ihrer Konzeptualisierung, ihrer Entwicklung und ihrem konkreten Design, in ihrer Nutzung oder auch in der Genealogie sowie den Auswirkungen ihrer zugrunde liegenden Ideen und Annahmen. In dieser Hinsicht lassen sich zum einen Ansätze finden, die sich aus technischer Perspektive mit algorithmischen Systemen beschäftigen, zum anderen Bestrebungen, die auf ihre sozio-ethischen Aspekte fokussieren. Zudem entstehen

mit und um Empfehlungssysteme eine Vielzahl textlicher Materialien, die gerade für eine diskursanalytische Betrachtung geeignet sind.

Medientechnologien provozieren nicht nur neue epistemologische Fragestellungen, sondern eröffnen darüber hinaus selbst Möglichkeiten für die geisteswissenschaftliche Forschung. So wird in der *Digital Methods Initiative* (DMI) in Amsterdam mit digitalen Tools und Methoden experimentiert, um zu ergründen, wie diese für die Erforschung soziokultureller Fragestellungen eingesetzt werden können (Rogers 2019). Dies erfolgt beispielsweise durch Methoden der Datensammlung mit Hilfe von *Scraping* oder über offizielle APIs sowie den Einsatz von Datenvisualisierungen zur Darstellung von Problemen. Einsatz finden die digitalen Methoden zudem im *Reverse Engineering*, in Zuge dessen Forschende die Kriterien zur Informationsfilterung von Empfehlungssystemen nachzuvollziehen versuchen – z. B. in YouTubes Empfehlungssystem (Kaiser und Rauchfleisch 2020) oder auf der Musik-Streamingplattform Spotify (Tofalvy und Kontai 2021).

Mit empirischen Ansätzen dieser Art gibt es jedoch eine Anzahl von Problemen, die es zu berücksichtigen gilt. So wird suggeriert, die genauen algorithmischen Vorgehensweisen ergründen und verstehen zu können, was angesichts der Komplexität dieser Systeme kaum möglich ist. Des Weiteren laufen Projekte dieser Art Gefahr, digitale Methoden lediglich als *Tool* zu verstehen und somit den soziopolitischen Fokus zu verlieren (Engemann et al. 2019, S. 156). Dabei bietet gerade der Einsatz, aber auch die Entwicklung dieser Methoden die Möglichkeit zur kritischen Reflexion über ihre digitale Natur (Rieder und Borra 2014, S. 267) sowie die Herausforderungen und Grenzen, die diese mit sich bringen (Rieder und Röhle 2012).

Auch in den *Critical Code Studies*, wie Mark Marino (2020) sie vorschlägt, wird Wissen nicht nur *über* sondern gerade auch *mit* Code generiert (Kitchin 2017, S. 22). Der Fokus liegt dabei auf der praktischen Arbeit mit spezifischen Code-Segmenten und Algorithmen. Ein Beispiel liefert die Arbeit von Simon Crowe (2019a, b), der den Quellcode des Empfehlungssystems LightFM einer kritischen Untersuchung unterzogen und innerhalb eines größeren Machtgeflechts verortet hat. Adrian Mackenzie (2018) wiederum führt eine code-basierte Rekonstruktion des Tesco Online-Shopping-Empfehlungssystems durch, um zu verdeutlichen, dass die viel debattierte ‚Personalisierung‘ nur einer von vielen Aspekten ist, der heutige Empfehlungssysteme bestimmt.

Die Aneignung technischen Wissens spielt auch für uns eine entscheidende Rolle, da so algorithmische Anwendungen in ihren Mechanismen, aber auch epistemologischen Grundlagen nachvollzogen werden können. Allerdings liegt der Fokus von Analysen im Rahmen der *Critical Code Studies* sowie der *Digital Methods*, wie wir an den von uns beschriebenen Beispielen sehen können, auf sehr spezifischen algorithmischen Systemen und ihren jeweiligen Code-Segmenten. Größere technologische Zusammenhänge werden oftmals nicht genauer betrachtet. Zudem erlaubt die Untersuchung von Algorithmen und Empfehlungssystemen a posteriori zwar Schlussfolgerungen hinsichtlich ihrer technischen Funktionsweise, lässt aber die politischen Intentionen in ihrer Entwicklung und ihrem Design – sowie ihres Gebrauchs – außer Acht (kritisch hierzu: Kitchin 2017, S. 24).



Die ethnografische Untersuchung von Algorithmen bietet daher eine notwendige Ergänzung zur rein technisch-informierten Analyse. So ermöglicht sie einerseits den Einblick in ihre Produktion – als „objects of professional practice for computer scientists, software engineers, and system developers“ (Dourish 2016, S. 9) – andererseits aber auch in ihre Nutzung. Nick Seaver (2018) zeigt beispielsweise anhand von Interviews mit Entwickler\*innen, wie Empfehlungssysteme als ‚captivating traps‘ konzeptualisiert werden, die darauf ausgelegt sind, Nutzer\*innen auf den Plattformen zu halten. Taina Bucher (2016) erforscht mit Hilfe von Interviews und persönlicher Geschichten, wie Nutzer\*innen Algorithmen auf Plattformen erfahren und was für ein Verständnis diese von ihnen haben. Algorithmen werden in diesen ethnografischen Arbeiten als situierte (d. h. dynamische) Praktiken verstanden, als „culturally enacted by the practices people use to engage with them“ (Seaver 2017, S. 5). Sie sind demnach nicht allein Vermittler von ‚Kultur‘ zu verstehen, sondern vielmehr selbst kulturelle Artefakte, und dabei „multiple, like culture, because they are culture“ (Seaver 2017, S. 5).

Dieses Wechselverhältnis aus passivierenden und aktivierenden Aspekten ist gerade mit Blick auf Empfehlungssysteme von besonderem Interesse, da diese nicht alleine das Verhalten der User\*innen affizieren, sondern selbst von diesen affiziert werden. Während aber der Fokus bisheriger ethnografischer Forschung algorithmischer Systeme vor allem auf der Entwicklung spezifischer algorithmischer Systeme und ihrer sozio-ethischen Anwendung lag, konzentriert sich der von uns vorgeschlagene Ansatz auf die Etablierung größerer technologischer Konzepte in ihrer techno-politischen Konstitution.

Ein letztes, gerade für die diskursanalytische Betrachtung interessantes Forschungsfeld bieten verschiedene textliche Materialien rund um die Entwicklung von algorithmischen Systemen, wie beispielsweise technische Abhandlungen, Lehrbücher oder Online-Tutorials (siehe beispielsweise Amoores et al. 2023). Prey (2018) betrachtet insbesondere Patent- und Pressemitteilungen der Empfehlungssysteme Pandora Internet Radio und Spotify, um zu untersuchen, wie User\*innen in diesen konstituiert werden. Hallinan und Striplas (2014) analysieren Blogs und Foren, die rund um den *Netflix Prize*, einem vom Unternehmen initiierten Wettbewerb zur Verbesserung des Empfehlungsalgorithmus, entstanden sind. Eine tiefer gehende Betrachtung von Empfehlungssystemen bietet Wendy Hui Kyong Chun (2020) mit ihrer historischen Herleitung von wesentlichen Grundannahmen, wie z. B. der Homophilie, aus der Statistik, Urbanistik, aber auch der Eugenik. Solch eine ideologiekritische Herangehensweise scheint uns besonders fruchtbar, zeigt sie doch das Potenzial einer medienwissenschaftlichen Auseinandersetzung mit algorithmischen Systemen.

Wie die hier vorgenommene Kartierung zeigt, gibt es bereits viele Ansätze, um sich algorithmischen Systemen wie Empfehlungssystemen medienwissenschaftlich zu nähern. Wie Bernhard Rieder (2020, S. 98–100) betont, legen bisherige Untersuchungen allerdings allzu oft einen zu engen Fokus auf den Code – und vernachlässigen dabei größere Wissenskonzepte – oder aber sie konzentrieren sich zu sehr auf die sozialen Effekte – und verlieren damit die technischen Spezifika aus dem Blick. Wir schlagen daher einen Mittelweg vor, der sich nicht zuletzt der diskurs-

analytischen Betrachtungsweise bedient: um Empfehlungssysteme als techno-politische Objekte erforschen zu können, konzentrieren wir uns auf diejenigen Lehrmaterialien, die zu ihrer Entwicklung maßgeblich beitragen.

---

## 4 Neubestimmung von Empfehlungssystemen

### 4.1 Diskursfeld: Onlinekurse

Im Folgenden präsentieren wir einen *Mixed-Methods*-Ansatz aus der *Walkthrough*-Methode nach Light, Burgess und Duguay (2018) in Kombination mit diskursanalytischen Überlegungen. Dieser Ansatz erlaubt es uns, erstens, ein tiefer gehend technisches Verständnis zu erlangen; zweitens, Rückschlüsse auf die Ideen und Annahmen – wie etwa das Ähnlichkeitsprinzip – zu ziehen, welche die Arbeitsweise von Empfehlungssystemen vorstrukturieren; sowie drittens, eine kritische Einbettung dieser epistemologischen Konzepte innerhalb eines größeren diskursiven Feldes vorzunehmen. Heute beziehen angehende Datenwissenschaftler\*innen und Software-Entwickler\*innen ihr technisches Wissen vor allem aus Online-Ressourcen wie Tutorials, Blogs und Einstiegskursen (Heuer et al. 2021, S. 4; Stack Overflow 2021), was diese für eine medienwissenschaftliche Untersuchung algorithmischer Systeme und ihrer Anwendung in Empfehlungssystemen besonders ergiebig macht. Um unseren *Mixed-Methods*-Ansatz in all seinen Facetten darstellen zu können, nutzen wir Onlinekurse zur Einführung in maschinelles Lernen und künstliche Intelligenz als zu untersuchendes Diskursfeld.

Gerade große Technologieunternehmen spielen im Erlernen von *Machine Learning* eine wichtige Rolle. Mit ihrem Versprechen einer ‚Demokratisierung von Künstlicher Intelligenz‘ betätigen sie sich vermehrt im Bereich der Ausbildung potenzieller KI-Talente und prägen somit maßgeblich die Entwicklung algorithmischer Systeme (Luchs et al. 2023). So bieten Unternehmen wie Google (*Machine Learning Crash Course*) und IBM (*Machine Learning with Python*) kostenlose Einstiegskurse an, die eine Einführung in die theoretischen Konzepte des maschinellen Lernens geben und mit praktischen und anwendungsbezogenen Übungsaufgaben, nicht zuletzt mit Blick auf Empfehlungssysteme, kombiniert werden.

### 4.2 Mixed Methods: Walkthrough-Methode und kritische Diskursanalyse

Die *Walkthrough*-Methode hat verschiedene Ursprünge und Anwendungsbereiche wie beispielsweise in der Human-Computer-Interaction zur Verbesserung von Software (Light et al. 2018, S. 885–886). Light et al. verstehen ihre Methode zwar als Weiterführung bisheriger Ansätze, denken diese aber wesentlich neu, um sie so für die systematische Analyse von Software-Anwendungen als „soziotechnische Artefakte“ nutzbar zu machen (ibid., S. 886). Dabei geht es ihnen nicht darum zu evaluieren, ob Apps *richtig* oder *falsch* genutzt werden, sondern vielmehr diese

Nutzung auf Basis einer kulturellen Analyse zu beschreiben. Im Rahmen der *Walkthrough*-Methode werden die einzelnen Komponenten einer Software-App systematisch durchlaufen, um sie in ihren technischen Elementen, aber auch in ihrer Intentionalität zu betrachten. Zusätzlichen Kontext für diese Analyse bietet die Betrachtung von weiteren Informationen bezüglich der App – so beispielsweise ihre *Vision*, ihr *Betriebsmodell* und ihre *Governance* (Light et al. 2018, S. 882).

Als Teil unseres *Mixed-Methods*-Ansatzes schlagen wir die *Walkthrough*-Methode nach Light et al. (2018) vor: nicht alleine zur Analyse von Software-Applikationen, sondern auch für die Untersuchung technischer Ressourcen und Lehrmaterialien, wie z. B. die Online-Einführungskurse in das maschinelle Lernen von Google und IBM. An dieser Stelle knüpfen wir an der technisch-informierten Analyse algorithmischer Empfehlungssysteme – wie in den oben beschriebenen *Digital Methods* oder den *Critical Code Studies* – an. Mit der auto-ethnografischen Ausrichtung der *Walkthrough*-Methode wollen wir darüber hinaus allerdings eine kritische Reflexion der technischen Inhalte – beispielsweise in bestimmten Symbolen oder auch in forcierten Handlungs- und Interaktionsmustern – ermöglichen.

Die Kombination der *Walkthrough*-Methode mit der kritischen Diskursanalyse, wie sie sich gerade bei Onlinekursen anbietet, erlaubt des Weiteren eine stärker techno-politische Ausrichtung der Analyse, da sie es erlaubt, die Inhalte und Sprache des Forschungsgegenstands mit einzubeziehen. Entsprechend gehen wir mit der kritischen Diskursanalyse über ein rein technisches Verständnis hinaus, und öffnen die Forschung hin zu den in diesem Verständnis steckenden Narrativen und Grundannahmen. In dieser Hinsicht schließt unser Ansatz an ethnografischen Untersuchungen an, die ihren Fokus vor allem auf die soziokulturelle Dimension algorithmischer Systeme legen. Dabei geht es uns allerdings bewusst nicht um spezifische algorithmische Systeme, die bereits konkretisiert sind, sondern vielmehr um größere technologische und epistemologische Konzepte – oder, mit Rieder gesprochen um „algorithmische Techniken“ (Rieder 2020) – die in technischen Ressourcen wie Onlinekurse verhandelt werden.

Der *Mixed-Methods*-Ansatz, wie wir ihn hier vorstellen, eröffnet eine machtpolitische Dimension der Erforschung von Empfehlungssystemen, da er es erlaubt, Klassifikation und Kategorisierung als wesentliche Bestandteile der Realitätsbildung mitzudenken. Insofern lässt sich dieser an all jenen Orten einsetzen, an denen technisches Wissen (re-)produziert wird, wie in den Onlinekursen, aber auch anderen Ressourcen wie Lehrbüchern, Patenten oder auch Online-Tutorials und Blogs. Im Folgenden werden wir die einzelnen Elemente unseres Ansatzes am Beispiel ihrer Anwendung an Onlinekursen des maschinellen Lernens weiter verdeutlichen.

### **4.3 Beispielstudie: Anwendung der Methode an Onlinekursen des maschinellen Lernens**

Die Erforschung von Onlinekursen erlaubt nicht nur einen Einblick in die technischen Voraussetzungen und epistemologischen Konzepte des maschinellen Lernens und seinen verschiedenen Anwendungen, sondern auch in ihre diskursive

Darstellung. Entsprechend ermöglicht ihre Untersuchung eine Ergründung dessen, wie maschinelles Lernen durch Unternehmen, die diese Kurse anbieten, repräsentiert und verstanden wird. Angesichts der wirtschaftlichen Interessen der Kursanbieter\*innen wird zudem ein Einblick in die politisch-ökonomische Seite der Kurse geboten und die Frage aufgeworfen, inwiefern diese Unternehmen durch das Angebot, aber auch die Darstellung von maschinellem Lernen sowie dessen Einschreibung in Empfehlungssysteme, profitieren (Luchs et al. 2023).

Als Beispiel bietet sich der *Machine Learning Crash Course* von Google (MLCC: <https://developers.google.com/machine-learning/crash-course>) an. Der Kurs wird seit März 2018 auf der unternehmenseigenen Webseite kostenfrei angeboten und so öffentlich zugänglich gemacht. Beworben mit der Aussage, dass „KI die größten Auswirkungen haben [wird], wenn jeder Zugang zu ihr hat“ (Google AI 2022; eigene Übersetzung), ist es das proklamierte Ziel „Intuition zu fundamentalen Konzepten des maschinellen Lernens zu entwickeln“ (Rosenberg 2018; eigene Übersetzung). Der MLCC setzt sich aus 25 Lektionen und 15 h Lehrmaterial rund um ML-Konzepte wie *loss reduction*, *representation* und *generalization* sowie dem Training von Datensets zusammen und behandelt zudem spezifische ML-Modelle wie die lineare und logistische Regression sowie neurale Netze.

Gemäß der *Walkthrough*-Methode wird von uns zunächst der Kontext des Onlinekurses etabliert (Light et al. 2018). Analysegegenstand ist dabei nicht nur der Kurs an sich, sondern auch die Hintergrundinformationen, welche die Anbieter\*innen auf ihren Webseiten und Plattformen zugänglich machen sowie die Kursbeschreibungen und Teilnahmevoraussetzungen. In diesem Sinne wird in unserer Analyse sowohl die Kursplattform selbst eingehend studiert als auch begleitende unternehmenseigene Webseiten wie Google's *Developer Blog*, der offizielle Webauftritt und der YouTube-Account von Google's KI-Abteilung. Die Analyse des Onlinekurses konzentriert sich dabei – gemäß Light et al. (2018) – auf die Komponenten *Vision*, *Betriebsmodell* und *Governance*:

- 1) Die *Vision* des Onlinekurses besteht in dem Vorhaben, welches das Unternehmen mit dem Angebot verfolgt. Dies umfasst die angegebenen Teilnahmevoraussetzungen, die Rückschlüsse auf die anvisierte Zielgruppe zulassen, sowie eine Auseinandersetzung mit den Versprechungen, die den Teilnehmer\*innen des Kurses gemacht werden. Informationen hierzu lassen sich der Kursbeschreibung entnehmen. Weitere Ressourcen sind die Firmenwebseite und -blogs, Werbematerialien oder andere Statements in Bezug auf den Kurs. Bei der Auswertung sind nicht nur die faktischen Informationen von Interesse, sondern vor allem auch die verwendete Sprache. Neben einer Auflistung der Teilnahmevoraussetzungen erfolgt im Rahmen dieses Analyseschrittes somit auch eine Auflistung verwendeter Narrative und Metaphern, mithilfe derer die Vision des Kurses beschrieben werden kann.

Vor allem die auf der Plattform gelisteten Teilnahmevoraussetzungen sowie das FAQ zum Kurs ermöglichen Schlüsse darauf, an wen sich der Kurs genau richtet. Doch auch Materialien, die über Google's *Developer Blog* zur Verfügung gestellt werden, sind hier von Interesse. Basierend auf diesen Quellen lässt sich

für den MLCC feststellen, dass dieser keinen Nutzer\*innen-Account voraussetzt. Vielmehr ist er offen zugänglich und wird als „self-study guide“ (Google MLCC 2021) beschrieben. Laut Google sind für den Kurs keine spezifischen Programmierkenntnisse erforderlich, als vielmehr ein „technical mind“ (Rosenberg 2018). Durch solche Narrative spricht der Kurs eine recht breite Zielgruppe an und vermittelt die Idee, dass jede\*r ohne Vorkenntnisse maschinelles Lernen erlernen kann. Der Kurs zieht somit ein großes Publikum an – was letztlich dem Interesse des Unternehmens dient, die im MLCC verwendete hausinterne Infrastruktur als Standard für maschinelles Lernen zu etablieren.

- 2) Das *Betriebsmodell* des Onlinekurses lässt Rückschlüsse auf mögliche ökonomische Interessen der Kursanbieter\*innen zu, die nicht selten in direkten Kontrast zur Vision stehen. In diesem Analyseschritt werden Unternehmensstrategien und Einkommensquellen im Zusammenhang mit den Onlinekursen analysiert. Direkte Einnahmen umfassen beispielsweise die Teilnahmekosten, aber auch kostenpflichtige Zertifikate, CPU- und Cloud-Kosten, die bei der Entwicklung von Programmen des maschinellen Lernens entstehen, sowie die Kosten weiterer Lehrinhalte. Auch indirekte Einnahmen werden hier berücksichtigt, wie zum Beispiel die Reichweite der unternehmenseigenen Produkte und die Ausbildung künftiger KI-Spezialist\*innen.

Technologieunternehmen wie Google und IBM haben ein großes Interesse an der Ausbildung und somit auch Gewinnung von KI-Spezialist\*innen, wozu ihnen die Etablierung ihrer eignen ML-Infrastrukturen dient. Aus diesem Grund haben wir uns mit Blick auf den MLCC vor allem der unternehmenseigenen Infrastrukturen (z. B. die Open-Source-Plattform TensorFlow oder die Programmierumgebung Google Colab) zugewandt. Im Gegensatz zu einer direkten Vermarktung der Onlinekurse, ihrer Zertifikate und der zur Erreichung kostenpflichtig zu nutzenden Plattform (siehe z. B. Coursera 2021), zeichnet sich Googles Modell durch eine indirekte Verbreitung seiner Produkte aus. Dabei stellt sich die Frage, inwiefern es bei der Kursteilnahme tatsächlich um ein bloßes Erlernen des technischen Wissens geht, oder vielmehr das Erlernen *anhand* spezifischer Produkte (z. B. TensorFlow) im Vordergrund steht.

- 3) Die Perspektive der *Governance* ermöglicht einen Einblick in die vorgegebene Struktur des Kurses und der Kursplattform, sowie die jeweiligen Handlungsmöglichkeiten, die sich für die Nutzer\*innen ergeben. Letztere lässt sich aus den Voraussetzungen herleiten, die erfüllt sein müssen, um teilnehmen zu dürfen, aber auch, wie offen die Kurse infrastrukturell gestaltet sind. In dieser Hinsicht ist es möglich, zu eruieren, ob die Plattformen den Nutzer\*innen Raum für die Entwicklung eigener Ideen und Erfahrungen geben oder ob diese im Gegenteil nur innerhalb der vorgegebenen Umgebung – und der damit vermittelten Inhalte und Methoden – lernen und handeln können.

Die *Governance* des Kurses wird vor allem durch ein initiales Durchschreiten der Plattform deutlich. So lässt sich für den MLCC feststellen, dass dieser die Kursinhalte vor allem anhand dreier Formate vermittelt: kurze, aufgezeichnete Videovorträge, die einen ersten Einblick in die Inhalte bieten; detailliert ausgeführte Textsegmenten mit Illustrationen und kleinen Abfragesegmenten; und

letztlich praxisorientierte Programmieraufgaben in *Google Colab* sowie eine Aufarbeitung der technischen Themen mithilfe der grafischen Benutzeroberfläche *TensorFlow Playground*. Diese Zusammensetzung bietet eine erste Idee davon, auf welche Art und Weise Wissen innerhalb des MLCC vermittelt wird. So zeigt sich, dass es sich bei dem Kurs im Wesentlichen um einen Frontalunterricht handelt, der – trotz seiner anwendungsorientierten Vermittlung – kaum Interaktion zulässt.

Zusammengenommen erlauben die in den drei Aspekten *Vision*, *Betriebsmodell* und *Governance* gewonnenen Erkenntnisse erste Annahmen in Bezug auf die polit-ökonomischen Voraussetzungen des Forschungsobjektes zu treffen; sie bilden die Grundlage für einen anschließenden, technischen *Walkthroughs*. Der technische *Walkthrough* bietet einen sehr viel detaillierteren Einblick in die Struktur und den Inhalt des Kurses. Indem man die Position des\*der Nutzer\*in einnimmt, bewegt man sich durch die Online-Umgebung und identifiziert die Schlüsselkomponenten und Narrative des Kurses. Um diesen auto-ethnografischen Durchgang zu strukturieren, lässt sich die Analyse auf fünf Hauptkategorien begrenzen: technologische Konzepte, Beispiele, Narrative, Lernziele sowie Verweise auf externes Material bzw. theoretische Ideen. Der *Walkthrough* ist ein nützliches Mittel, um so viele Daten wie möglich über den Forschungsgegenstand zu sammeln. Mit diesen Daten ist es möglich mehr Wissen über die technologischen Konzepte selbst, aber auch über die narrativen Elemente und Repräsentationen, die für ihre Darstellung verwendet werden, zu generieren und zugänglich zu machen.

Im Zuge unserer Analyse des MLCC wurden Informationen zum einen tabellarisch nach den oben genannten Kategorien deskriptiv gesammelt; zum anderen waren wir als Forschende selbst Teilnehmende des Kurses, wodurch extensive Feldnotizen entstanden sind. Somit konnte das im Kurs vermittelte Wissen kritisch reflektiert und ein technisches Verständnis desselben erarbeitet werden (Luchs et al. 2023). Eine solcherart praktische Auseinandersetzung ermöglichte es uns zudem ein besseres Verständnis der Lerndimensionen, sowie eine tiefer gehende Einsicht in die Annahmen und Vorstellungen, die die Entwicklungspraxis beinhaltet (wie beispielsweise die eingeschriebene homophile Annahme in Empfehlungssysteme, Abb. 1 und 2), zu erhalten.

Im Anschluss an den technischen *Walkthrough* wird eine kritische Diskursanalyse durchgeführt. Wie bereits im ersten Abschnitt ausgeführt, liegen Empfehlungssystemen bestimmte Annahmen zu Grunde, welche die Art und Weise, wie Klassifikationen durchgeführt werden, wesentlich anleiten (z. B. das Prinzip der Homophilie). Da Onlinekurse als Lehrmaterial für die Erstellung von Empfehlungssystemen fungieren, wird das in ihnen präsentierte Wissen – und damit die vorherrschenden Grundannahmen zur Klassifikation – durch die Aneignung von Kursteilnehmer\*innen in ihrer Anwendung weiter verfestigt und reproduziert. Die kritische Diskursanalyse erlaubt es an dieser Stelle, die Diskurse, die in den Onlinekursen rund um Empfehlungssysteme geführt werden, zu identifizieren und die ihnen unterliegenden Machtverhältnisse aufzudecken und kritisch zu hinterfragen. Entsprechend werden im Anschluss des *Walkthroughs* sich wiederholende diskursive Elemente identifi-

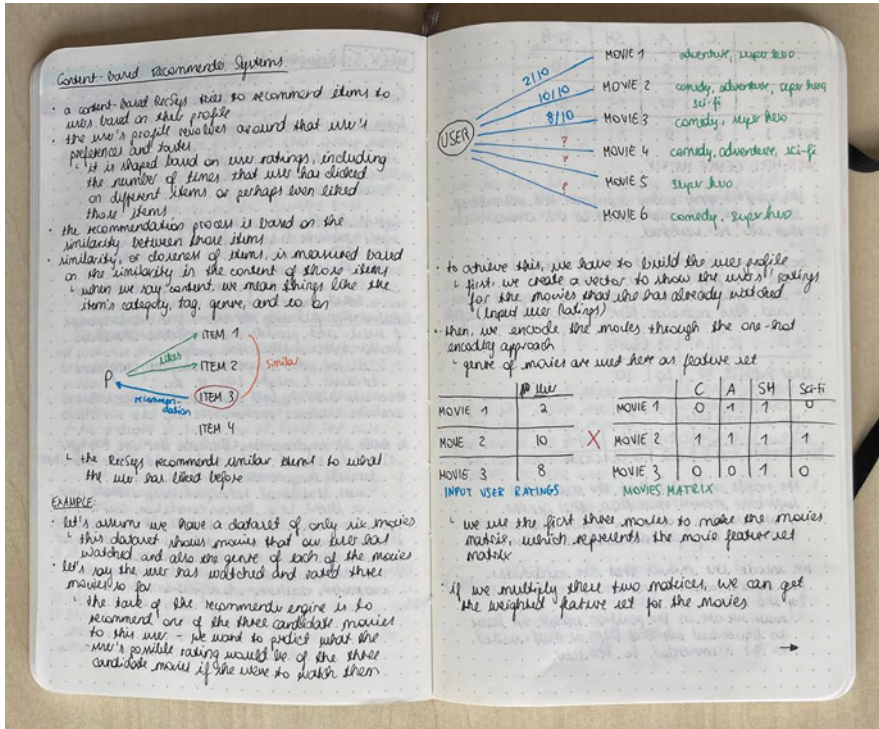


Abb. 1 und 2 Funktionsweise inhaltsbasierter Empfehlungssysteme. Notizen der Co-Autorin (I. Luchs), erstellt während der Teilnahme an dem IBM-Onlinekurs *Machine Learning with Python*

ziert, die in einem nächsten Schritt dann für jeden Kurs separat kategorisiert werden. Die hier identifizierten Narrative in der Darstellung von maschinellem Lernen zeigen weiter auf, wie diese durch die Position des Unternehmens sowie dessen ökonomische Interessen beeinflusst werden, aber auch, wie diese selbst die weitere Entwicklung und Erforschung von Empfehlungssystemen beeinflussen.

Neben dem umfassenden Einblick in die Narrative und Klassifikationen, die das maschinelle Lernen in der KI-Industrie umgibt, erlaubt die Anwendung der *Walkthrough*-Methode im Bereich von Onlinekursen auch den Erwerb technischen Wissens über diese Technologien sowie ihrer Anwendung in Empfehlungssystemen. So kann der\*die Forschende durch das auto-ethnografische Durchschreiten des Kurses die Funktionsweise und Anwendung von Algorithmen für die Klassifikation erlernen und sie im Rahmen von Empfehlungssystemen anwenden. Hier wird er\*sie – ganz im Sinne des *Reverse Engineering* – nicht nur dazu befähigt, über alternative Wege der Klassifikation und somit alternative Konstruktionen von Empfehlungssystemen nachzudenken, sondern auch, diese konkret in die Tat umzusetzen und durch die Anwendungspraxis neue Erkenntnisse zu ziehen.

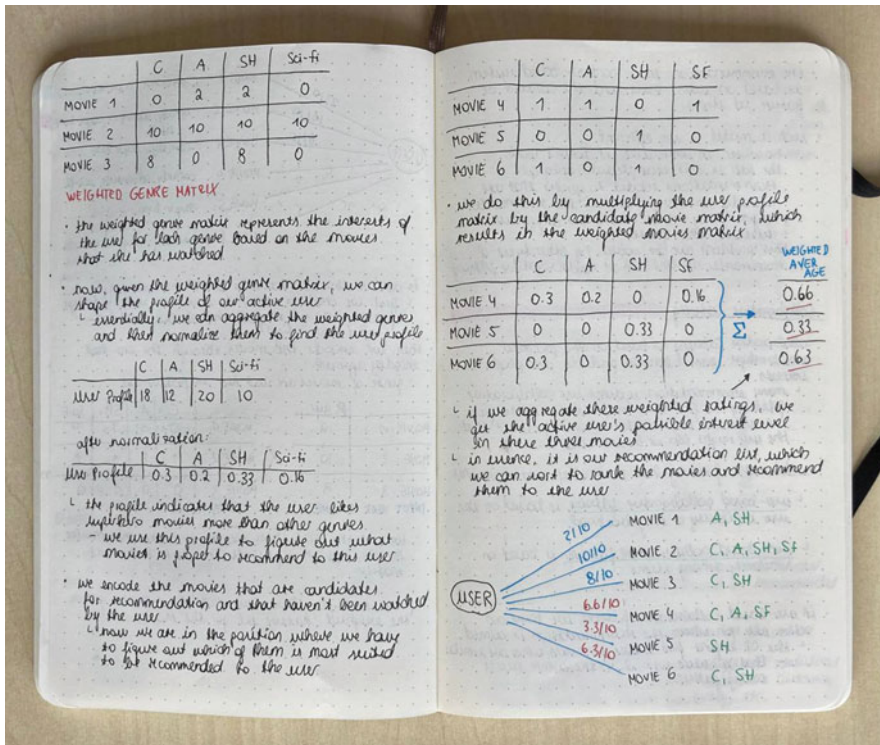


Abb. 1 und 2 (Fortsetzung)

## 5 Fazit und Ausblick

Wie die von uns vorgenommene Kartierung zeigt, können algorithmische Empfehlungssysteme anhand einer Vielzahl an Perspektiven untersucht werden. Während sich die bisherige Forschung vor allem auf sozio-ethische Betrachtungen konzentrierte – so beispielsweise hinsichtlich der gesamtgesellschaftlichen Auswirkungen von bestimmten Empfehlungssystemen in ihrer Produktion und Anwendung – schlagen wir mit diesem Beitrag eine Ergänzung vor, die sich vor allem auf die technologischen Voraussetzungen dieser Systeme im Zusammenspiel mit machtpolitischen Interessen konzentriert. Eine solche Analyse ermöglicht es, Empfehlungssysteme sowohl in ihrer technischen Funktion ernst zu nehmen als auch diese in ihrem Werden – in den Ideen und Wissenskonzepten, die sich in ihnen verfestigen – zu untersuchen. Der von uns hervorgebrachte *Mixed-Methods*-Ansatz aus einem *Walkthrough* von Onlinekursen sowie einer kritischen Diskursanalyse ermöglicht somit ein tiefgreifendes technisches Verständnis derjenigen Konzepte, die unsere heutigen Empfehlungssysteme wesent-



lich bestimmen und eine kritische Betrachtung dessen, welche Wissenskonzepte sich hier manifestieren und welche Parteien daran ein besonderes Interesse haben.

Unser Vorschlag unterliegt dabei einer Reihe von Einschränkungen. So wird in dieser Herangehensweise die Nutzer\*innenperspektive weitgehend außer Acht gelassen: Wie rezipieren Nutzer\*innen die Kurse, wie sieht ihre Praxis aus und was für eine Form der Reflexion findet statt? Und welche anderen Materialien nutzen die Kursteilnehmer\*innen für ihre Ausbildung in der Entwicklung algorithmischer Systeme? Fragen wie diese sollten durch eine ergänzende, nicht-autoethnografische Forschung weiterverfolgt werden. Auch sind Onlinekurse nicht der einzige Forschungsgegenstand, der für die von uns vorgeschlagene Methode von Interesse sein kann. So gibt es eine Reihe anderer Bildungsressourcen im Rahmen des maschinellen Lernens, die ebenfalls für einen *Walkthrough* von Interesse sein könnten, wie beispielsweise traditionelle Einstiegsliteratur (z. B. Bishop 2006; Russel und Norvig 2016; Géron 2019) oder Online-Tutorials (siehe Heuer et al. 2021). Sie bieten für die zukünftige Erforschung von maschinellen Lernverfahren im Allgemeinen und algorithmischen Empfehlungssystemen im Besonderen eine reichhaltige Ressource.

---

## Literatur

- Amoore, L., A. Campolo, B. Jacobsen, und L. Rella. 2023. Machine learning, meaning making: On reading computer science texts. *Big Data & Society* 10(1): 1–13.
- Apprich, C., W.H.K. Chun, F. Cramer, und H. Steyerl. 2018. *Pattern discrimination*. Lüneburg/Minneapolis: Meson Press/University of Minnesota Press.
- Arguedas, R., T. Robertson, R. Fletcher, und R.K. Nielsen. 2022. Echo chambers, filter bubbles, and polarisation: A literature review. *Reuters Institute*. <https://reutersinstitute.politics.ox.ac.uk/echo-chambers-filter-bubbles-and-polarisation-literature-review>. Zugegriffen am 11.06.2024.
- Berry, D. 2013. *Understanding digital humanities*. London: Palgrave Macmillan.
- Bishop, C.M. 2006. *Pattern recognition and machine learning*. New York: Springer.
- Bucher, T. 2016. The algorithmic imaginary: Exploring the ordinary affects of Facebook algorithms. *Information, Communication & Society* 20(1): 30–44.
- Cheney-Lippold, J. 2017. *We are data: Algorithms and the making of our digital selves*. New York: NYU Press.
- Chun, W.H.K. 2011. On soucery and source codes. In *Programmed visions. Software and memory*, 19–54. Cambridge: MIT Press.
- . 2020. Filter system. In *Oxford handbook of media, technology, and organization*, Hrsg. T. Beyes, R. Holt, und C. Pias, 238–245. Oxford: Oxford University Press.
- . 2021. *Discriminating data. Correlation, neighborhoods, and the new politics of recognition*. Cambridge: MIT Press.
- Coursera. 2021. IBM data science professional certificate. *Coursera Official Website*. <https://www.coursera.org/professional-certificates/ibm-data-science>. Zugegriffen am 11.06.2024.
- Crowe, S. 2019a. Micropolitics of a recommender system – Source code. *spheres – Journal for Digital Cultures* 5. <https://spheres-journal.org/contribution/micropolitics-of-a-recommender-system-source-code/>. Zugegriffen am 11.06.2024.
- . 2019b. Micropolitics of a recommender system – Machine learning and the machinic unconscious. *spheres – Journal for Digital Cultures* 5. <https://spheres-journal.org/contribution/micropolitics-of-a-recommender-system-machine-learning-and-the-machinic-unconscious/>. Zugegriffen am 11.06.2024.
- Dourish, P. 2016. Algorithms and their others: Algorithmic culture in context. *Big Data & Society* 3:1–11.

- Engell, L., und B. Siegert. 2010. „Editorial“, *Zeitschrift für Medien- und Kulturforschung* 1. Hamburg: Felix Meiner.
- Engemann, C., T. Heilmann, und F. Sprenger. 2019. Wege und Ziele. Die unstete Methodik der Medienwissenschaft. *Zeitschrift für Medienwissenschaft* 20:151–161.
- Fairclough, N. 2001. *Language and power*. London: Longman.
- Foucault, M. 1996. *Diskurs und Wahrheit. Berkley-Vorlesungen 1983*. Berlin: Merve.
- Fuller, M. 2008. *Software studies. A lexicon*. Cambridge: MIT Press.
- Géron, A. 2019. *Hands-on machine learning with Scikit-Learn, Keras & TensorFlow*. Sebastopol: O'Reilly.
- Google AI. 2022. Tools. *Google AI*. <https://ai.google/tools/>. Zugegriffen am 09.03.2022.
- Google Machine Learning Crash Course (MLCC). 2021. Machine learning crash course with TensorFlow APIs. *Machine Learning Crash Course*. <https://developers.google.com/machine-learning/crash-course>. Zugegriffen am 09.03.2022.
- Hallinan, B., und T. Striphas. 2014. Recommended for you: The Netflix Prize and the production of algorithmic culture. *New Media & Society* 18(1): 117–137.
- Heuer, H., J. Jarke, und A. Breiter. 2021. Machine learning in tutorials – Universal applicability, underinformed application, and other misconceptions. *Big Data & Society* 8(1): 1–13.
- Hodge, R., und G. Kress. 1993. *Language as ideology*. London: Routledge.
- Jäger, S. 2001. Diskurs und Wissen Theoretische und methodische Aspekte einer Kritischen Diskurs- und Dispositivanalyse. In *Handbuch Sozialwissenschaftliche Diskursanalyse*, Hrsg. R. Keller, A. Hirsland, W. Schneider, und W. Viehöver, 81–112. Opladen: Leske + Budrich.
- Kaiser, J., und A. Rauchfleisch. 2020. Birds of a feather get recommended together: Algorithmic homophily in YouTube's channel recommendations in the United States and Germany. *Social Media & Society* 6(4): 1–15.
- Kitchin, R. 2017. Thinking critically about and researching algorithms. *Information, Communication & Society* 20(1): 14–29.
- Kurgan, L., D. Brawley, B. House, J. Zhang, und W.H.K. Chun. 2019. Homophily: The urban history of an algorithm. *e-flux Journal*. <https://www.e-flux.com/architecture/are-friends-electric/289193/homophily-the-urban-history-of-an-algorithm>. Zugegriffen am 11.06.2024.
- Light, B., J. Burgess, und S. Duguay. 2018. The walkthrough method: An approach to the study of apps. *New Media & Society* 20:881–900.
- Luchs, I., C. Apprich, und M. Broersma. 2023. Learning machine learning. On the political economy of big tech's AI online courses. *Big Data & Society*. <https://doi.org/10.1177/205395172311153>.
- Mackenzie, A. 2018. Personalization and probabilities: Impersonal propensities in online grocery shopping. *Big Data & Society* 5:1–15.
- Manovich, L. 2002. *The language of new media*. Cambridge: MIT Press.
- . 2013. *Software takes command*. New York: Bloomsbury.
- Marino, M.C. 2020. *Critical code studies*. Cambridge/London: MIT Press.
- Pariser, E. 2011. *The filter bubble: How the new personalized web is changing what we read and how we think*. New York: Penguin Press.
- Potter, J. 1996. *Representing reality: Discourse, rhetoric and social construction*. London: Sage Publications.
- Prey, R. 2018. Nothing personal: Algorithmic individuation on music streaming platforms. *Media, Culture & Society* 40(7): 1086–1100.
- Rieder, B. 2020. *Engines of order. A mechanology of algorithmic techniques*. Amsterdam: Amsterdam University Press.
- Rieder, B., und E. Borra. 2014. Programmed method. Developing a toolset for capturing and analyzing tweets. *Aslib Journal of Information Management* 66(3): 262–278.
- Rieder, B., und T. Röhle. 2012. Digital methods: Five challenges. In *Understanding digital humanities*, Hrsg. D. Berry, 67–84. London: Palgrave Macmillan.
- Rogers, R. 2019. *Doing digital methods*. London: SAGE.
- Rosenberg, B. 2018. Machine learning crash course. *Google Developers Blog*, 02.03.2018. <https://developers.googleblog.com/2018/03/machine-learning-crash-course.html>. Zugegriffen am 11.06.2024.

- Russel, S., und P. Norvig. 2016. *Artificial intelligence. A modern approach*. Essex: Pearson.
- Schrage, M. 2020. *Recommendation engines*. Cambridge: MIT Press.
- Seaver, N. 2017. Algorithms as culture: Some tactics for the ethnography of algorithmic systems. *Big Data & Society* 4(2): 1–12.
- . 2018. Captivating algorithms: Recommender systems as traps. *Journal of Material Culture* 24(4): 421–436.
- Stack Overflow. 2021. *2021 Developer survey*. <https://insights.stackoverflow.com/survey/2021>. Zugegriffen am 11.06.2024.
- Tofalvy, T., und J. Kontai. 2021. ‚Splendid isolation‘: The reproduction of music industry inequalities in Spotify’s recommendation system. *New Media & Society* 25:1–25.