

Wie viel Personalisierung braucht der Bewegtbildmarkt aus Sicht der Zuschauer*innen?

Schaarschmidt, Christian

Veröffentlichungsversion / Published Version

Konferenzbeitrag / conference paper

Empfohlene Zitierung / Suggested Citation:

Schaarschmidt, C. (2022). Wie viel Personalisierung braucht der Bewegtbildmarkt aus Sicht der Zuschauer*innen? In H. Gundlach (Hrsg.), *Internet-Intermediäre und virtuelle Plattformen medienökonomisch betrachtet: Proceedings zur Jahrestagung der Fachgruppe Medienökonomie der Deutschen Gesellschaft für Publizistik- und Kommunikationswissenschaft 2021, Hamburg* (S. 18-28). Hamburg: Deutsche Gesellschaft für Publizistik- und Kommunikationswissenschaft e.V. <https://doi.org/10.21241/ssoar.78176>

Nutzungsbedingungen:

Dieser Text wird unter einer CC BY Lizenz (Namensnennung) zur Verfügung gestellt. Nähere Auskünfte zu den CC-Lizenzen finden Sie hier:
<https://creativecommons.org/licenses/by/4.0/deed.de>

Terms of use:

This document is made available under a CC BY Licence (Attribution). For more information see:
<https://creativecommons.org/licenses/by/4.0>

Wie viel Personalisierung braucht der Bewegtbildmarkt aus Sicht der Zuschauer*innen?

Christian Schaarschmidt

Universität zu Köln, Wirtschafts- und Sozialwissenschaftliche Fakultät

Zusammenfassung

*Algorithmenbasierte Empfehlungsdienste stellen Zuschauer*innen im nichtlinearen Streaming individuell audiovisuelle Inhalte in einer Vorauswahl zusammen, die potenziell ihren Präferenzen entsprechen. Um die Präferenzen der Zuschauer*innen zu ermitteln, müssen die Anbieter solcher Dienste personenbezogene Daten wie z. B. das Sehverhalten erheben und auswerten. Zuschauer*innen müssen bei der Wahl eines personalisierten Angebots daher den Nutzen der Personalisierung gegen die Bedrohung ihrer Privatsphäre abwägen. In diesem Beitrag wird dieses „Privatheitskalkül“ von Zuschauer*innen aus einer medienökonomischen Perspektive untersucht. Im Fokus steht die Fragestellung, wie viel Personalisierung aus Sicht der Zuschauer*innen optimal ist und welche Auswirkungen heterogene Sensibilitäten der Datenpreisgabe, die Systemeffizienz sowie Reputation der Anbieter im vertrauensvollen Umgang mit personenbezogenen Daten auf das Kalkül der Zuschauer*innen haben. Aus den Ergebnissen werden zudem Implikationen für Geschäftsmodelle abgeleitet.*

Dieser Beitrag wurde ebenfalls in der MedienWirtschaft veröffentlicht: Schaarschmidt, C. (2021). Wie viel Personalisierung braucht der Bewegtbildmarkt aus Zuschauersicht? 18 (4), 30-37.

Keywords: Personalisierung, Empfehlungsdienste, Privatheitskalkül, Datenökonomie, nicht-lineares Streaming

Summary

In non-linear streaming, algorithm-based recommendation services automatically highlight a preselection of audiovisual content options based on viewers' individual preferences. In order to determine these preferences, the providers of such services must collect and evaluate personal data, such as viewing behavior. Viewers must therefore weigh the benefit of personalization against the loss of privacy when using these services. This article examines this "privacy calculus" by viewers, as well as the associated business model implications for streaming services from a media-economic perspective. In particular, it analyzes how much personalization is optimal from the viewer's perspective and how heterogeneous sensitivities of data disclosure, system efficiency and the reputation of providers in a trustworthy handling of personal data effect the viewer's calculation.

*This article was also published in *MedienWirtschaft: Schaarschmidt, C. (2021). Wie viel Personalisierung braucht der Bewegtbildmarkt aus Zuschauersicht? 18 (4), 30-37.**

Keywords: personalization, recommendation services, privacy calculus, data economics, non-linear streaming

Einführung

Die Standpunkte-Serie der MedienWirtschaft „Personalisierung von Medienangeboten im Zeichen der digitalen Transformation“ umfasst Beiträge aus öffentlich-rechtlicher (Amlung, 2019), kommunikationswissenschaftlicher (Stark, 2019), rechtlicher (Helberger, 2019), technischer (Thürmel & Hess, 2020) und medienökonomischer Perspektive (Lobigs & Mündges, 2020). Die Beiträge verdeutlichen, dass sich auf Ebene der Nutzer*innen bei der algorithmischen Personalisierung zwei Effekte gegenüberstehen:

- Die algorithmische Personalisierung ist einerseits potenziell nutzenerhöhend, da sie zu einer höheren Präferenzentsprechung von Inhalten bzw. einer Abnahme von Suchaufwand nach passenden Inhalten führen kann.
- Andererseits reduziert die algorithmische Personalisierung den Nutzen, da zwangsläufig personenbezogene Daten verarbeitet werden müssen und die Preisgabe solcher Daten zu Risiken bzw. zu einer Bedrohung der Privatsphäre der Nutzer*innen führt.

Nutzer*innen müssen bei der Wahl eines personalisierten Angebots ein sogenanntes Privatheitskalkül vornehmen (Morlok et al., 2017), das heißt sie müssen abwägen, ob und inwieweit sie den Deal „Service gegen Daten“ (Buxmann & Wagner, 2018, S. 22) eingehen möchten. Diesbezüglich stellt sich die Frage, wie viel Personalisierung Nutzer*innen nachfragen bzw. für sie optimal ist.

Im vorliegenden Beitrag wird diese Fragestellung anhand von Empfehlungsdiensten virtueller Plattformen im nichtlinearen Streaming untersucht. Dabei werden drei Faktoren berücksichtigt, die das Privatheitskalkül der Zuschauer*innen beeinflussen:

- heterogene Sensibilitäten der Zuschauer*innen in der Preisgabe personenbezogener Daten,
- Effizienz der Empfehlungssysteme und
- Vertrauen in die Anbieter, das heißt Reputation im vertrauensvollen Umgang mit personenbezogenen Daten.

Für die Analyse wird ein Nutzenmodell von Lehrer et

al. (2010) verwendet, das in der MedienWirtschaft bereits auf die Personalisierung von Webseiten angewendet wurde. Somit ergänzt dieser Beitrag das allgemeine Nutzenmodell um eine weitere praktische Anwendung.

Mit dem Fokus auf Empfehlungsdienste im nichtlinearen Streaming schließt sich der vorliegende Artikel zudem an den medienökonomischen Beitrag der Standpunkte-Serie der MedienWirtschaft an, in dem der Fokus auf der algorithmischen Personalisierung deutscher journalistischer Digitalangebote von Zeitungsverlagen liegt (siehe Lobigs & Mündges, 2020).

Im Folgenden wird zunächst das Privatheitskalkül abgebildet und der optimale Personalisierungsgrad aus Sicht der Zuschauer*innen ermittelt. Im Anschluss wird betrachtet, wie die drei zuvor genannten Faktoren das Kalkül und den optimalen Personalisierungsgrad verändern. Aus den Ergebnissen werden zudem Implikationen für Geschäftsmodelle und den Wettbewerb abgeleitet. Der Beitrag schließt mit einem Fazit.

Das Privatheitskalkül im Bewegtbildmarkt

Nutzen personalisierter Empfehlungen

Infolge der Digitalisierung und der Konvergenz der Medien steht auf Portalen von Streaming-Anbietern (z. B. Netflix, Amazon Prime Video und Disney+), in Mediatheken von Rundfunkanbietern (z. B. von ARD, ZDF, RTL, Pro7) sowie auf Videoplattformen (z. B. YouTube) eine hohe Anzahl an audiovisuellen Inhalten zur Verfügung. Diese können von den Zuschauer*innen zeitunabhängig ausgewählt und konsumiert werden (nichtlineares Streaming). Allerdings führt die nahezu unbegrenzte Anzahl an Inhalten zu einem hohen Suchaufwand für Zuschauer*innen in Form von Zeit für die Suche nach passenden Inhalten und kognitivem Aufwand für die Entscheidungsfindung. Zuschauer*innen ist es aufgrund des hohen Suchaufwands nicht möglich, alle im Bewegtbildmarkt verfügbaren Alternativen zu vergleichen. Es besteht ein sogenannter „Information Overload“ (Wellbrock, 2020; Thürmel & Hess, 2020; Henning-Thurau et al., 2019).

Empfehlungsdienste stellen Zuschauer*innen automatisch aus der Vielzahl aller verfügbaren Inhalte eines Anbieters solche Inhalte individuell in einer

Vorauswahl zusammen, die potenziell ihren jeweiligen aktuellen Präferenzen entsprechen. Damit reduzieren diese Dienste bei einer zutreffenden Zusammenstellung von Inhalten den Suchaufwand der Zuschauer*innen, der für das Überblicken aller verfügbaren Inhalte eines Anbieters entstehen würde (Wellbrock, 2020; Thürmel & Hess, 2020). Beispielsweise bieten Netflix, Amazon Prime Video, Disney+, YouTube und das ZDF (unter „Mein ZDF“) solche personalisierten Zusammenstellungen an (Henning-Thurau et al., 2019).

Am Beispiel von Netflix stellen Henning-Thurau et al. (2019) die hohe Bedeutung der personalisierten Empfehlungen dar:

„Netflix weiß nicht nur, was Sie letzten Donnerstag geschaut und bei welcher Szene Sie abgeschaltet haben, sondern auch, was andere Zuschauer, die ganz ähnliche Vorstellung von guter Unterhaltung haben wie Sie, gerne schauen, Sie aber bisher noch nicht entdeckt haben: Nichtlineares Streaming ist das Medium der individualisierten Empfehlungen. Das algorithmenbasierte Verstehen einzelner Zuschauer und die darauf aufbauende Schaffung individualisierter ‚Programmschemata‘ bieten dem Zuschauer ein großes Nutzenpotenzial: Bei Netflix gehen mehr als 6 von 10 Sehstunden auf eine personalisierte Empfehlung zurück“ (Henning-Thurau et al., 2019, S.18).

In Abbildung 1 wird der Nutzen (U) von personalisierten Empfehlungen in Abhängigkeit vom Personalisierungsgrad (PG) dargestellt (vgl. Lehrer et al., 2010). U umfasst hierbei nur den reinen Nutzen der Personalisierung („Bruttonutzen“) ohne Berücksichtigung der Nutzenreduktion durch die Preisgabe von personenbezogenen Daten. $PG = 0$ stellt dar, dass keine Personalisierung erfolgt, so dass alle Zuschauer*innen die gleiche Vorauswahl erhalten. Wenn die Vorauswahl nicht personalisiert ist, liegt auch kein (Brutto-)Nutzen der Personalisierung vor. Es gilt: $U(PG = 0) = 0$.

Es wird angenommen, dass der Bruttonutzen bei einem relativ geringen PG durch eine Erhöhung des PG relativ stark steigt, da anfänglich den Präferenzen der einzelnen Zuschauer*innen in hohem Maße besser entsprochen wird: Irrelevante Inhalte werden zunehmend aus der Vorauswahl entfernt und durch besser passende Inhalte ersetzt. Ebenso wird angenommen, dass der Bruttonutzen bei einem relativ hohen PG durch eine weitere Erhöhung des PG nur relativ gering steigt, da den Präferenzen der Zuschauer*innen bereits stark entsprochen wird und

eine weitere Erhöhung des PG nur noch einen geringen positiven Effekt hat: Bereits gut passende Inhalte müssen durch noch besser passende Inhalte ersetzt werden. Ökonomisch ausgedrückt sinkt der Grenz-Bruttonutzen der Personalisierung mit steigendem PG aufgrund sinkender Skalenerträge der Personalisierung. Aufgrund dieser Annahmen wird U degressiv steigend abgebildet.

Es stellt sich die kritische Frage, ob ein steigender PG nicht zu zunehmend eintönigen Vorschlägen führt. Dies würde einer Nutzensteigerung durch Personalisierung entgegenstehen. Beim klassischen „Greedy“-Ansatz besteht diese Gefahr, da die Personalisierung nur auf bestehendem Wissen zu Präferenzen erfolgt. Neuere Personalisierungssysteme verwenden allerdings den „Exploration-Exploitation“-Ansatz, mit dem eine Veränderung der Präferenzen berücksichtigt werden kann. Dazu werden auch potenziell nicht passende oder zufällige Inhalte mit in die Empfehlung aufgenommen (siehe z. B. ZDF, 2019). Das Empfehlungssystem lernt im Anschluss mithilfe einer Feedback-Schleife, inwieweit diese Inhalte konsumiert werden und passt zukünftige Vorschläge entsprechend an (siehe dazu ausführlich Thürmel & Hess, 2020).

Zudem zeigt das zuvor dargestellte Zitat von Henning-Thurau et al. (2019), dass Zuschauer*innen bei Netflix auch weiterhin Inhalte konsumieren, die nicht auf einer personalisierten Empfehlung basieren (bis zu 4 von 10 Sehstunden). Die Auswertung dieses von Empfehlungsdiensten unabhängigen Sehverhaltens bietet ebenfalls die Möglichkeit einer dynamischen Anpassung der Personalisierung.

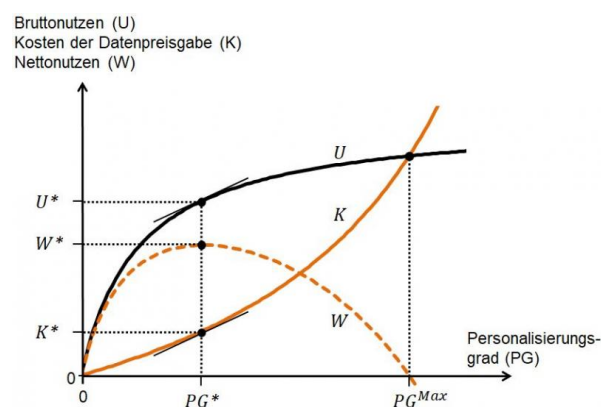


Abb. 1: Privatheitskalkül bei personalisierten Empfehlungen

Quelle: Eigene Darstellung in Anlehnung an Lehrer et al. (2010)

Kosten der Datenpreisgabe

Zur Bereitstellung von personalisierten Empfehlungen müssen zuerst Informationen über die Zuschauer*innen in Form von Daten gesammelt und verarbeitet werden. Im Anschluss werden aus den Daten Rückschlüsse auf die aktuellen Präferenzen der jeweiligen Zuschauer*innen gezogen. Insbesondere können Daten des digitalen Profils von Zuschauer*innen (z. B. Alter, Wohnort, Geschlecht), Daten des Verhaltens der Zuschauer*innen (z. B. Historie konsumierter audiovisueller Inhalte, Sehverhalten, positive Bewertungen wie „Likes“) und Daten des temporären Nutzungskontexts der Zuschauer*innen (z. B. aktueller Aufenthaltsort, Zeit, Aktivität) verwendet werden. Zudem kann erfasst werden, inwieweit die Zuschauer*innen den angebotenen Empfehlungen folgen. Diese Feedback-Schleife ermöglicht es, zukünftige Vorschläge sowie den gesamten Personalisierungsprozess zu optimieren (Thürmel & Hess, 2020).

Beispielsweise gibt Netflix an, folgende personenbezogenen und nicht-personenbezogenen Daten zur Personalisierung zu verwenden: Interaktionen mit dem Dienst (z. B. konsumierte Titel und Bewertungen der Titel), das Verhalten anderer Nutzer*innen mit ähnlichen Präferenzen, Informationen zu den Titeln (z. B. Genre, Schauspieler*in, Erscheinungsjahr) sowie die Tageszeit, das verwendete Endgerät und die Nutzungsdauer von Netflix (Konsumzeit). Zudem setzt Netflix eine Feedback-Schleife ein. Demografische Informationen wie das Geschlecht oder das Alter werden nicht verwendet (Netflix, 2021).

Zuschauer*innen können durch das Erheben, Speichern und Verarbeiten von personenbezogenen Daten jedoch eine Bedrohung ihrer Privatsphäre bzw. einen Kontrollverlust empfinden, so dass ein Nutzenverlust resultiert (Lehrer et al., 2010; Buxmann, 2018; Dinev & Hart, 2006; Laufer & Wolfe, 1977). Dieser Nutzenverlust wird im Folgenden als „Kosten der Datenpreisgabe“ bezeichnet (ähnlich „Preis des Kostenlosen“; Buxmann, 2018, S. 18). In Abbildung 1 werden die Kosten der Datenpreisgabe (K) einer Zuschauerin / eines Zuschauers in Abhängigkeit vom PG dargestellt.

Der Verlauf der Kostenkurve wird exponentiell steigend abgebildet, da anzunehmen ist, dass für einen steigenden PG zunehmend mehr und auch zunehmend kritischere personenbezogene Daten erhoben sowie aus

verschiedenen Quellen kombiniert werden müssen (Buxmann, 2018; Thürmel & Hess, 2020; Hosseini & Schmidt, 2018). Buxmann (2018) stellt beispielsweise dar, dass der Privatsphäreneingriff umso gravierender ist, je mehr Daten gesammelt werden.

Nachfrage nach personalisierten Empfehlungen

Bei der Wahl eines personalisierten Angebots müssen Zuschauer*innen den Bruttonutzen der Personalisierung (U) gegen die Kosten der Datenpreisgabe (K) abwägen und somit ein Privattheitskalkül vornehmen (vgl. Morlok et al., 2017; Laufer & Wolfe, 1977). Dabei werden vorerst Verzerrungen im Markt nicht berücksichtigt, so dass angenommen wird, dass Zuschauer*innen bei ihrem Kalkül rationale Entscheidungen treffen.

Das Privattheitskalkül einer Zuschauerin / eines Zuschauers wird in Abbildung 1 in Abhängigkeit vom PG dargestellt: Die Differenz aus dem Bruttonutzen (U) und den Kosten (K) ergibt den Nettotonutzen W ($W = U - K$) der Zuschauerin / des Zuschauers. Diese Kurve stellt dar, inwieweit personalisierte Empfehlungen einen Wert (W) für die Zuschauerin / den Zuschauer haben. Somit bildet diese Kurve die Nachfrage der Zuschauerin / des Zuschauers nach Personalisierung in Abhängigkeit vom PG ab.

Es wird deutlich, dass die Zuschauerin / der Zuschauer im Bereich 0 bis PG^{Max} Personalisierung nachfragt, da in diesem Bereich der Bruttonutzen die Kosten der Datenpreisgabe übersteigt ($U > K$), so dass der Nettotonutzen positiv ist ($W > 0$). Ab PG^{Max} übersteigen die Kosten den Bruttonutzen ($U < K$), so dass der Nettotonutzen negativ wird ($W < 0$) und die Zuschauerin / der Zuschauer das Angebot ablehnt. Der optimale PG liegt aus Sicht der Zuschauerin / des Zuschauers bei PG^* , bei dem sie / er das Netto-Nutzenmaximum W^* sowie den Bruttonutzen U^* erzielt. Bei PG^* entspricht der marginale Bruttonutzengewinn der Personalisierung genau dem marginalen Nutzenverlust aus der Datenpreisgabe. Im Optimum muss der Grenz-Bruttonutzen der Personalisierung den Grenzkosten aus der Preisgabe personenbezogener Daten entsprechen (--> *Optimalitätsbedingung 1a*).

Das Angebot eines höheren PG führt daher nicht grundsätzlich zu einer Nutzenerhöhung für Zuschauer*innen (vgl. dazu auch Lehrer et al., 2010). Für Anbieter ist es demzufolge nicht optimal eine maximale Menge von Daten zu sammeln. Es besteht die Gefahr, dass Zuschauer*innen abgeschreckt werden

und das Angebot nicht nutzen oder alternative Anbieter wählen (vgl. dazu auch Buxmann, 2018). Für Anbieter besteht diesbezüglich das Risiko eines Verlusts von Erlösen bzw. Marktanteilen (vgl. Morlok et al., 2017).

Heterogene Sensibilitäten der Preisgabe personenbezogener Daten

Im vorherigen Abschnitt wurde das Privatheitskalkül einer Zuschauerin / eines Zuschauers betrachtet, ohne die Sensibilität der Datenpreisgabe zu differenzieren. In diesem Abschnitt wird berücksichtigt, dass Zuschauer*innen heterogen in Bezug auf die Sensibilität der Datenpreisgabe sind (Buxmann, 2018). Beispielsweise zeigen Buxmann und Wagner (2018) anhand einer Studie, dass die Bedeutung der Privatsphäre mit dem Alter zunimmt. Ältere Teilnehmer*innen der Studie haben demnach eine höhere Sensibilität der Preisgabe von personenbezogenen Daten als jüngere Teilnehmer*innen. Darüber hinaus sind die Teilnehmer*innen der Studie in ihrer Akzeptanz von Geschäftsmodellen, die personenbezogene Daten verarbeiten, ebenso heterogen.

Um Aussagen über unterschiedlich hohe Sensibilitäten der Datenpreisgabe treffen zu können, werden in Abbildung 2 eine Zuschauerin / ein Zuschauer (N) mit niedriger und eine Zuschauerin / ein Zuschauer (H) mit hoher Sensibilität der Datenpreisgabe unterschieden. Die Verläufe der Kostenkurven werden mit K_N und K_H dargestellt, wobei K_H aufgrund der höheren Sensibilität steiler verläuft als K_N . Die Kurven W_N und W_H in Abbildung 2 stellen wie zuvor die Differenz zwischen dem Bruttonutzen der Personalisierung von Empfehlungen (U) und den Kosten der Datenpreisgabe (K_N bzw. K_H) dar. Es gilt: $W_N = U - K_N$ und $W_H = U - K_H$.

Für Zuschauer*in H ist der Bereich 0 bis PG_H^{Max} und für Zuschauer*in N der Bereich 0 bis PG_N^{Max} nutzenstiftend. Zuschauer*innen mit einer niedrigeren Sensibilität der Datenpreisgabe fragen demzufolge einen deutlich größeren Bereich an Personalisierung nach als Zuschauer*innen mit einer höheren Sensibilität der Datenpreisgabe. Der optimale PG für Zuschauer*in H ist PG_H^* , bei dem die Zuschauerin / der Zuschauer das Netto-Nutzenmaximum W_H^* erzielt. Der optimale PG für Zuschauer*in N liegt bei PG_N^* , bei dem die Zuschauerin / der Zuschauer das Netto-Nutzenmaximum W_N^* erzielt. Zuschauer*innen mit einer niedrigeren Sensibilität der Datenpreisgabe erzielen demzufolge einen höheren Nettonutzen ($W_N >$

W_H) und können ein höheres Netto-Nutzenmaximum erreichen ($W_N^* > W_H^*$) als Zuschauer*innen mit einer höheren Sensibilität der Datenpreisgabe.

Es wird deutlich, dass im Bewegtbildmarkt aus Sicht der Zuschauer*innen nicht *ein* PG optimal ist. Vielmehr fragen heterogene Zuschauer*innen unterschiedliche PG nach, so dass *individuelle* PG optimal sind. Im Optimum muss daher der Grenz-Bruttonutzen der Personalisierung den Grenzkosten der Preisgabe personenbezogener Daten der *jeweiligen* Zuschauer*innen entsprechen (--> *Optimalitätsbedingung 1b*).

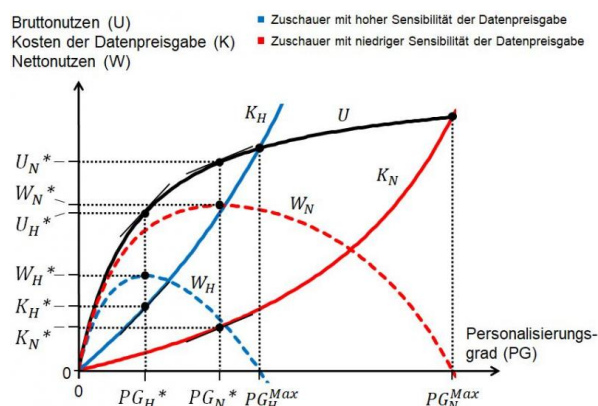


Abb. 2: Wirkung heterogener Sensibilitäten der Datenpreisgabe auf das Privatheitskalkül

Quelle: Eigene Darstellung in Anlehnung an Lehrer et al. (2010)

Die Anbieter audiovisueller Inhalte im nichtlinearen Streaming stehen somit vor der Herausforderung, Zuschauer*innen individuelle PG bereitzustellen. Eine Möglichkeit dazu ist, den Zuschauer*innen Kontrolle über die Verwendung von Algorithmen sowie über die gespeicherten Daten anzubieten, so dass diese selbstständig den für sie optimalen PG festlegen können (Helberger, 2019; Beule et al., 2020). Beule et al. sprechen diesbezüglich davon „Verantwortung“ auf die Nutzer*innen zu übertragen (Beule et al., 2020, S. 36).

Beispielsweise bietet YouTube die Möglichkeit an, Einstellungen zur Preisgabe von personenbezogenen Daten festzulegen und somit den Grad der Personalisierung selber zu bestimmen. So kann u. a. eingestellt werden, in welchem Umfang bzw. wie lange die zuletzt konsumierten Inhalte gespeichert und zur Personalisierung verwendet werden sollen (Google, 2021).

Ein ähnliches Beispiel stellt Amlung für das ZDF dar: „Wir machen unseren Nutzern ein Angebot. Wer den vollen Komfort der Personalisierung nutzen will, muss sich auf unseren Websites anmelden. Wer sich nicht anmeldet, bekommt weniger gute Empfehlungen. Und wer auf Empfehlungen komplett verzichten will, kann in seinem Browser die entsprechenden Techniken blockieren“ (Amlung 2019, S. 10).

Solche Maßnahmen erhöhen entsprechend die Souveränität heterogener Zuschauer*innen in Bezug auf ihr individuelles Privatheitskalkül.

Effizienz der Empfehlungssysteme

Der Bruttonutzen der Personalisierung ist nicht nur vom Umfang der von den einzelnen Zuschauer*innen erhobenen Daten abhängig. Vielmehr hängt der Bruttonutzen auch von der Effizienz der Empfehlungssysteme ab. Diese ist erstens technisch bedingt und wird von der Qualität der eingesetzten Algorithmen beeinflusst. Zweitens hängt sie davon ab, inwieweit eine Plattform überhaupt über potenziell passende Inhalte wie z. B. Eigenproduktionen verfügt, so dass diese durch das Empfehlungssystem auch vorgeschlagen werden können. Drittens ist sie davon abhängig, inwieweit auch Daten über das Verhalten anderer Zuschauer*innen genutzt werden können, das heißt Vergleichsdaten für Ähnlichkeitsanalysen zur Verfügung stehen (Thürmel & Hess, 2020; Hindman, 2018, S. 40-53; Wellbrock, 2020; Henning-Thurau et al., 2019).

In Abbildung 3 wird dargestellt, dass ein Anbieter die Effizienz seines Empfehlungssystems steigern kann, so dass ein höherer Bruttonutzen resultiert ($U \rightarrow U'$). Der Effekt einer höheren Effizienz des Empfehlungssystems wird am Beispiel einer Zuschauerin / eines Zuschauers mit dem in Abbildung 3 dargestellten Verlauf der Kosten der Datenpreisgabe K betrachtet.

Infolge des gestiegenen Bruttonutzens resultiert für die Zuschauerin / den Zuschauer ein höherer Verlauf des Nettonutzens (W) und es steigen sowohl der für sie/ihn optimale PG ($PG^* \rightarrow PG'^*$) als auch ihr/sein maximal erreichbarer Nettonutzen ($W^* \rightarrow W'^*$). Zudem wird der Bereich größer, in dem die Zuschauerin / der Zuschauer Personalisierung nachfragt ($PG^{Max} \rightarrow PG'^{Max}$).

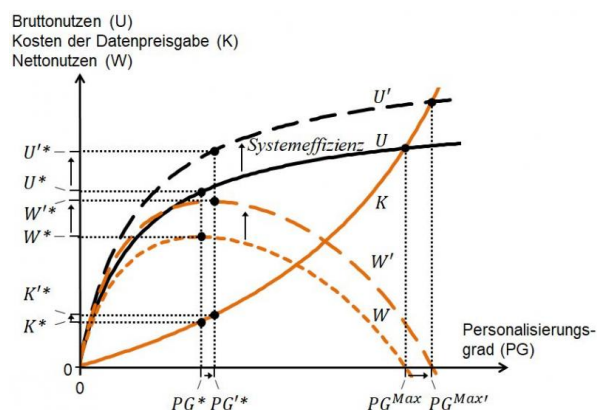


Abb. 3: Wirkung der Steigerung der Systemeffizienz auf das Privatheitskalkül

Quelle: Eigene Darstellung in Anlehnung an Lehrer et al. (2010)

Es wird deutlich, dass Anbieter zur Erhöhung des Nutzens der Zuschauer*innen den Anreiz haben, die Effizienz ihres Empfehlungssystems zu steigern. Dabei lassen sich für Anbieter personalisierter Empfehlungen drei Wettbewerbsfaktoren ableiten:

- die technische Kompetenz in der Optimierung von Algorithmen,
- die Möglichkeit passende audiovisuelle Inhalte (u. a. Eigenproduktionen) anzubieten und
- der Zugang zu einer hohen Anzahl an Vergleichs-Datensätzen von Zuschauer*innen.

In Bezug auf diese Faktoren verfügen die großen Streaming-Plattformen (wie Netflix, Amazon Prime Video, Disney+ und YouTube) über Wettbewerbsvorteile, da sie, relativ betrachtet, höhere Beträge in die Weiterentwicklung der Algorithmen investieren können und auf eine hohe Anzahl unterschiedlicher Inhalte zugreifen können. Zudem können Anbieter wie Netflix, Amazon oder Disney relevante Inhalte für ihre Zuschauer*innen auch zielgerichtet eigenständig produzieren. Darüber hinaus stehen den Anbietern aufgrund der hohen Anzahl an Kund*innen bzw. Nutzer*innen viele Vergleichs-Datensätze zur Verfügung (Dewenter, 2018; Wellbrock, 2020; Wambach, 2018; Henning-Thurau et al., 2019 & 2021; Hindman, 2018, S. 40-53; MedienWirtschaft, 2019; Hosseini & Schmidt, 2018).

Die Studie von Henning-Thurau et al. (2019) zeigt diesbezüglich, dass die großen Streaming-Plattformen

in der Kategorie „technologische Distributionskompetenz“ (bzw. „großartige Streaming-Erfahrung“) deutlich positiver bewertet werden als die Mediatheken der linearen Rundfunkanbieter. Ebenfalls werden die „Attraktivität der Inhalte insgesamt“ und die „Attraktivität der Eigenproduktionen“ bei den großen Streaming-Plattformen deutlich positiver bewertet (Henning-Thurau et al., 2019, S. 26-31). Das spricht dafür, dass die Empfehlungssysteme der großen Streaming-Plattformen in der Wahrnehmung der Zuschauer*innen einen deutlich höheren Nutzen bieten können.

Für ARD und ZDF dürfte sich die aktuelle Verknüpfung der Mediatheken positiv auswirken. Durch die damit verbundene Zusammenlegung des Empfehlungssystems ist zu erwarten, dass bei der Weiterentwicklung ihres Algorithmus Synergien erzielt und monetäre Mittel gebündelt werden können. Zudem können die Sender durch die Zusammenlegung der Konten der Zuschauer*innen (ARD-Konto und „Mein ZDF“) ihre Datenbasis erhöhen. So können zum einen übergreifende Verhaltensdaten der einzelnen Zuschauer*innen verwendet und zum anderen mehr Vergleichsdaten anderer Zuschauer*innen genutzt werden. Darüber hinaus können Inhalte aus beiden Mediatheken empfohlen werden, was die Qualität der Empfehlungen zusätzlich erhöhen sollte. Der Ausblick auf die Einbindung weiterer öffentlich-rechtlicher Angebote (wie ARTE, Phoenix und Deutschlandradio) bietet diesbezüglich weiteres Potenzial (ZDF, 2021).

Reputation im vertrauensvollen Umgang mit personenbezogenen Daten

Bislang wurde davon ausgegangen, dass keine Verzerrungen im Markt bestehen und Zuschauer*innen rationale Entscheidungen treffen können. Allerdings können begrenzte Transparenz der Datenverwendung, Wahrnehmungsverzerrungen sowie fehlendes Wissen über Algorithmen und Datenschutz dazu führen, dass Zuschauer*innen die wahren Kosten der Datenpreisgabe nicht zutreffend bestimmen können (Buxmann, 2018; Buxmann & Wagner, 2018; Dewenter 2018; Barley, 2018; Bertelsmann Stiftung, 2019). Empirisch stellen Norberg et al. (2007) dar, dass vielen Individuen einerseits der Schutz ihrer Privatsphäre wichtig ist (*Intention*), sie jedoch andererseits kein entsprechendes Schutzverhalten umsetzen (*tatsächliches Verhalten*). Diesen Effekt bezeichnen die Autoren als „Privacy-Paradox“.

Aufgrund solcher Verzerrungen besteht für

Zuschauer*innen das Risiko, dass sie die Kosten der Datenpreisgabe über- bzw. unterschätzen. Infolgedessen wählen sie ein zu niedriges oder zu hohes Niveau der Datenpreisgabe. Dabei besteht auch die Gefahr, dass sie ein Angebot komplett ablehnen, welches sie ohne Verzerrungen gewählt hätten oder umgekehrt, dass sie ein Angebot wählen, welches sie ohne Verzerrungen abgelehnt hätten. Bei fehlerhafter Entscheidung der Zuschauer*innen drohen entsprechend Nutzenverluste.

Anbieter können durch die Schaffung von Transparenz und durch den Aufbau von Vertrauen, das heißt Reputation im vertrauensvollen Umgang mit personenbezogenen Daten, diesen Nutzenverlusten entgegenwirken. Durch Schaffung von Transparenz wird zum einen gefördert, dass Zuschauer*innen ihre Kosten der Datenpreisgabe korrekt einschätzen können. Zum anderen werden durch den Aufbau von Reputation die Risiken der Zuschauer*innen und somit die Kosten der Datenpreisgabe reduziert (Culnan & Armstrong, 1999; Chellappa & Sin, 2005; Dinev & Hart, 2006; Krasnova et al., 2010; Buxmann, 2018).

Zur Darstellung der Wirkung der Kostenreduktion durch den Reputationsaufbau werden in Abbildung 4 zwei Kostenkurven unterschieden. Wie zuvor wird das Privatheitskalkül einer Zuschauerin / eines Zuschauers betrachtet. K stellt die Kostenkurve der Zuschauerin / des Zuschauers bei einem Anbieter ohne Reputation und K' die Kostenkurve der Zuschauerin / des Zuschauers bei dem Anbieter mit aufgebaute Reputation dar.

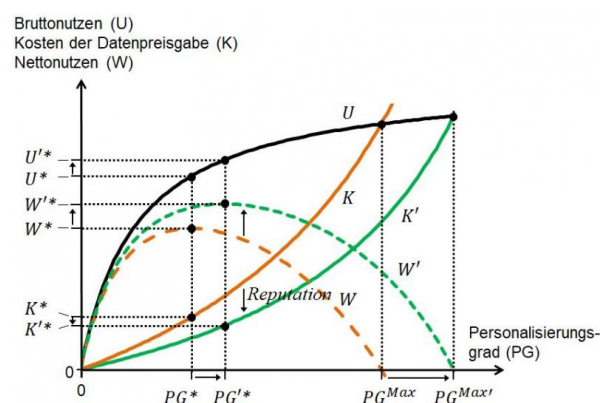


Abb. 4: Wirkung des Aufbaus von Reputation im vertrauensvollen Umgang mit personenbezogenen Daten auf das Privatheitskalkül

Quelle: Eigene Darstellung in Anlehnung an Lehrer et al. (2010)

Es wird deutlich, dass durch den Reputationsaufbau bzw. durch die Kostenreduktion für die Zuschauerin / den Zuschauer ein höherer optimaler PG (PG^{*}) und optimaler Nettonutzen (W^{*}) resultiert. Zudem fragt die Zuschauerin / der Zuschauer in einem größeren Bereich Personalisierung nach ($PG^{Max} \rightarrow PG^{*}$).

Es zeigt sich, dass Anbieter durch den Aufbau von Reputation im vertrauensvollen Umgang mit personenbezogenen Daten den Nutzen der Zuschauer*innen und die Nachfrage nach Personalisierung erhöhen können. Das Privatheitskalkül verändert sich zugunsten eines höheren PG und einer höheren Bereitschaft der Datenpreisgabe. Der Aufbau und der Erhalt von Reputation im vertrauensvollen Umgang mit personenbezogenen Daten ist somit eine wichtige Maßnahme für Anbieter (siehe auch Thürmel & Hess, 2020; Buxmann, 2018; Henning-Thurau et al., 2019; Barley, 2018; Krasnova et al., 2010).

Die Studie von Hennig-Thurau et al. (2019) stellt dar, dass Netflix hinsichtlich der Vertrauenswürdigkeit die „Benchmark“ (Henning-Thurau et al., 2019, S. 33) bildet, gefolgt mit nur wenig Abstand von Amazon. Besonders deutlich wird der Vertrauensvorsprung von Netflix, Amazon und YouTube, wenn man nur die jungen Zuschauer*innen im Alter von 16 bis 29 Jahre betrachtet. Dementsprechend wichtig ist es für Wettbewerber, wie z. B. für die Anbieter von Mediatheken, ihre Reputation im vertrauensvollen Umgang mit personenbezogenen Daten zu erhöhen.

Fazit

In diesem Beitrag wurde die Fragestellung untersucht, wie viel Personalisierung im Bewegtbildmarkt aus Sicht der Zuschauer*innen optimal ist. Zur Beantwortung der Frage wurde im Rahmen eines Nutzenkalküls der optimale Personalisierungsgrad aus Perspektive der Zuschauer*innen abgeleitet. Dazu wurden dem Nutzen der Personalisierung die Kosten der Preisgabe von personenbezogenen Daten der Zuschauer*innen gegenübergestellt. Für dieses „Privatheitskalkül“ der Zuschauer*innen gilt, dass im Optimum der marginale Nutzengewinn der Personalisierung den marginalen Kosten der Datenpreisgabe entsprechen muss.

Die Betrachtung unterschiedlicher Sensibilitäten der Datenpreisgabe hat gezeigt, dass nicht das Angebot eines Personalisierungsgrads, sondern das Angebot *individueller* Personalisierungsgrade optimal ist. Um

Zuschauer*innen individuelle Personalisierungsgrade bereitzustellen, sollten Anbieter den Zuschauer*innen Kontrolle über die Verwendung von Algorithmen sowie über die gespeicherten Daten anbieten, so dass diese selbstständig den für sie optimalen Personalisierungsgrad festlegen können.

Zudem wurde deutlich, dass Anbieter das Privatheitskalkül der Zuschauer*innen positiv beeinflussen können, indem sie die Effizienz ihrer Empfehlungssysteme erhöhen. Als wichtige Wettbewerbsfaktoren wurden diesbezüglich die technische Kompetenz in der Optimierung von Algorithmen, die Möglichkeit des Angebots passender audiovisueller Inhalte (u. a. Eigenproduktionen) und der Zugang zu einer hohen Anzahl an Vergleichs-Datensätzen von Zuschauer*innen identifiziert.

Darüber hinaus wurde die Wirkung von Verzerrungen im Bewegtbildmarkt betrachtet. Diese führen dazu, dass Zuschauer*innen die wahren Kosten der Datenpreisgabe nicht zutreffend bestimmen können. Anbieter können durch den Aufbau von Reputation im vertrauensvollen Umgang mit personenbezogenen Daten den Zuschauer*innen Sicherheit bieten, so dass die Risiken der Zuschauer*innen reduziert werden, und somit die Nachfrage nach Personalisierung erhöhen.

Insgesamt verdeutlicht dieser Beitrag somit wichtige Maßnahmen für Anbieter personalisierter Empfehlungen im nichtlinearen Streaming: Anbieter sollten individuelle Personalisierungsgrade bereitstellen, eine hohe Effizienz ihrer Empfehlungssysteme sicherstellen und eine hohe Reputation im vertrauensvollen Umgang mit personenbezogenen Daten aufbauen bzw. bestehende Reputation aufrechterhalten.

Unter Berücksichtigung von empirischen Studien wurde deutlich, dass die großen Streaming- und Videoplattformen (Netflix, Amazon Prime Video und YouTube) insbesondere aufgrund ihrer hohen Systemeffizienz und Reputation über Wettbewerbsvorteile verfügen. Anbietern mit geringerer Größe (z. B. den Anbietern von Mediatheken) stellt sich im Wettbewerb daher die Herausforderung mit der hohen Personalisierungsleistung der Streaming- und Videoplattformen mitzuhalten. Die Strategie der Vernetzung von Mediatheken, wie sie aktuell z. B. von ARD und ZDF vorgenommen wird, bietet diesbezüglich das Potential die Systemeffizienz zu steigern. Begleitet werden sollten solche Maßnahmen

von einer Strategie der Erhöhung der Reputation der Anbieter im vertrauensvollen Umgang mit personenbezogenen Daten.

Bei dem Thema dieses Beitrags stellt sich auch die Frage, wie viel Personalisierung bei algorithmischen Empfehlungsdiensten aus gesellschaftlicher Sicht optimal ist, wie z. B. unter Berücksichtigung der Gefahr einer politischen Beeinflussung von Zuschauer*innen oder eventuellen Filterblasen bzw. Echokammern. Zu einer umfassenden Betrachtung dieses Themas aus gesellschaftlicher Sicht sei auf die Beiträge von Helberger (2019) und Stark (2019) verwiesen.

Literatur

- Amlung, R. (2019). Personalisierung und Empfehlung im Rahmen eines öffentlich-rechtlichen Medienangebots am Beispiel des ZDF. *MedienWirtschaft*, 16 (2), 6-11.
- Barley, K. (2018). Big Data als Geschäftsmodell: Wie mit der Macht der Internetfirmen umgehen? *Ifo-Schnelldienst*, München: Institut für Wirtschaftsforschung, 71 (10), 3-5.
- Bertelsmann Stiftung (2019, 2. Februar). Was Europa über Algorithmen weiß und denkt - Ergebnisse einer repräsentativen Bevölkerungsumfrage. Bertelsmann Stiftung, Gütersloh. <https://www.bertelsmann-stiftung.de/fileadmin/files/BSSt/Publikationen/GrauePublikationen/WasEuropaUEberAlgorithmenWeissUndDenkt.pdf>
- Beule, V., Hirschmeier, S., & Schoder, D. (2020). *Der digitale Wandel im Hörfunk*. *MedienWirtschaft*, 17 (1), 29-37.
- Buxmann, P. (2018). Der Preis des Kostenlosen: das Spannungsfeld zwischen dem Wert von Daten und der Privatsphäre von Nutzern. *Ifo-Schnelldienst*, München: Institut für Wirtschaftsforschung, 71 (10), 18-21.
- Buxmann, P., & Wagner A. (2018). Datenökonomie und Privatsphäre – Ergebnisse von drei empirischen Untersuchungen. *MedienWirtschaft*, 15 (3), 20-28.
- Chellappa, R. K., & Sin, R. G. (2005). Personalization versus Privacy: An Empirical Examination of the Online Consumer's Dilemma. *Information Technology and Management*, 6 (2-3), 181-202.
- Culnan, J., Armstrong, P. K. (1999). Information Privacy Concerns, Procedural Fairness and Impersonal Trust: An Empirical Investigation. *Organization Science*, 10 (1), 104-115.
- Dewenter, R. (2018). Welche Regulierung datenbasierter Plattformen ist tatsächlich notwendig? *Ifo-Schnelldienst*, München: Institut für Wirtschaftsforschung, 71 (10), 9-11.
- Dinev, T., & Hart, P. (2006). An Extended Privacy Calculus Model for E-Commerce Transactions. *Information Systems Research*, 17 (1), 61-80.
- Helberger, N. (2019). Personalisierung der Medien – Juristische Aspekte des Datenschutzes und der Plattformregulierung aus europäischer Sicht. *MedienWirtschaft*, 16 (3), 11-15.
- Henning-Thurau, T., Schauerte, R., Herborg, N., & Wiechmann, D. (2019). *Quo vadis, deutsche Medien? Zur Zukunft deutscher Fernsehanbieter in digitalen Streaming-Zeiten*. Westfälische Wilhelms-Universität Münster, Münster.
- Henning-Thurau, T., Schauerte, R., Herborg, N., Schneid, V., & Wiegand, D. (2021). *Angriff aus Hollywood – Was es für den deutschen Streaming- und Fernsehmarkt bedeutet, wenn Hollywood-Studios zu Konkurrenten werden*. Westfälische Wilhelms-Universität Münster, Münster.
- Hindman, M. (2018). *The Internet Trap. How the Digital Economy Builds Monopolies and Undermines Democracy*. Princeton University Press, Princeton.
- Hosseini, H., & Schmidt, H. (2018). Daten als Geschäftsmodell: Wie mit der Macht der digitalen Ökonomie umgehen? *Ifo-Schnelldienst*, München: Institut für Wirtschaftsforschung, 71 (10), 11-14.
- Krasnova, H., Spiekermann, S., Koroleva, K., & Hildebrand, T. (2010). Online Social Networks: Why We Disclose. *Journal of Information Technology*, 25 (2/2010), 109-125.
- Lauffer, R. S., & Wolfe, M. (1977). Privacy as a Concept and a Social Issue: A Multidimensional Developmental Theory. *Journal of Social Issues*, 33 (3), 22-42.
- Lehrer, C., Hess, T., Rauscher, B., & Höhne, E. (2010). Je individueller, desto besser? – Ein Ansatz zur Bestimmung des angemessenen

- Individualisierungsgrades digitaler Medienprodukte. *MedienWirtschaft*, 7 (1), 10-18. empfehlungen-100.html
- Lobigs, F., & Mündges, S. (2020). Zaungäste der Plattform-Tektonik – Für die journalistischen Verlage ist die Personalisierung vor allem ein weiteres Problem der digitalen Transformation. *MedienWirtschaft*, 17 (2-3), 28-35.
- ZDF (2021, 21. Juni). *Gemeinsames Streaming-Netzwerk - ZDF und ARD bauen großen Inhalte-Kosmos*. <https://www.zdf.de/nachrichten/digitales/zdf-ard-mediathek-streaming-netzwerk-100.html>
- MedienWirtschaft (2019). Interview mit Dr. Pierre-Nicolas Schwab, RTBF, Chairman der Big Data Initiative (BDI) der European Broadcasting Union (EBU). *MedienWirtschaft*, 16 (2), 12-15.
- Morlok, T., Matt, C., Hess, T. (2017). Privatheitsforschung in den Wirtschaftswissenschaften, Entwicklung, Stand und Perspektiven. *Arbeitsbericht 1/2017, Ludwig-Maximilians-Universität München, München*.
- Netflix (2021). *Wie funktioniert das Empfehlungssystem von Netflix?* <https://help.netflix.com/de/node/100639>
- Norberg, P. A., Horne, D. R., & Horne, D. A. (2007). The Privacy Paradox: Personal Information Disclosure Intentions versus Behaviors. *The Journal of Consumer Affairs*, 41 (1), 100-126.
- Stark, B. (2019). Mythos „Filterblase“ – Fiktion oder Realität? Der Stand der Forschung aus kommunikationswissenschaftlicher Perspektive. *MedienWirtschaft*, 16 (3), 6-10.
- Thürmel, V., & Hess, T. (2020). Technische Lösungen für die Personalisierung von Medienangeboten: Stand und reale Perspektiven. *MedienWirtschaft*, 17 (1), 20-28.
- Wambach, A. (2018). Wettbewerbsregeln an die Digitalökonomie anpassen. *Ifo-Schnelldienst, München: Institut für Wirtschaftsforschung*, 71 (10), 6-8.
- Wellbrock, C. M. (2020). Plattformökonomik, Bundling und Marktpotential – eine ökonomische Perspektive auf ein „Spotify für Journalismus“. *MedienWirtschaft*, 17 (2-3), 6-17.
- Google (2021). Meine Google-Aktivitäten. <https://myactivity.google.com/myactivity>
- ZDF (2019, 25. November). *Wie Algorithmen die ZDFmediathek persönlicher machen*. [https://www.zdf.de/service-und-hilfe/wie-entstehen-persoenliche-](https://www.zdf.de/service-und-hilfe/wie-entstehen-persoenliche-empfehlungen-100.html)