



Hendrik Heuer

4. Wie kann die Funktionsweise dieser Systeme erklärt werden? Hier führt die Erklärungslücke dazu, dass wesentliche Aspekte nicht berücksichtigt, weil nicht verstanden oder von Nutzer:innen und Nutzern in ihrer Bedeutung falsch eingeschätzt werden.

5. Wie kann die Qualität von KI-Systemen verbessert werden? Vorgestellt wird ein halbautomatisiertes System, das die Zuverlässigkeit von KI-Systemen verbessert.

Zentral für die Entscheidung der Jury war die konsequente Einordnung von Machine-Learning-basierten Kuratierungssystemen in gesellschaftliche Kontexte, die eben nicht nur aus technischer Sicht, sondern vor allem in ihrem Zusammenhang mit den Menschen, die sie nutzen, und dem gesellschaftlichen Kontext zu betrachten sind. Eine Kernaussage ist, dass Machine-Learning-Systeme auch hier sozio-technische Systeme sind, die falsch oder

erschienen in der *Fiff-Kommunikation*,  
herausgegeben von *Fiff e. V.* - ISSN 0938-3476  
[www.fiff.de](http://www.fiff.de)

unzureichend trainiert werden können, wenn es hier überhaupt ein „richtig“ gibt. Dadurch ergibt sich eine Erweiterung der Perspektive von den Algorithmen hin zu den Daten, die nicht nur von der Maschine, sondern auch von den Menschen ausgewählt und interpretiert werden.

hervorragenden, originellen und gesellschaftlich hochrelevanten Beiträgen, die Begleitung dringend nötig, wofür hier ein wichtiger Baustein gelegt wurde. Wir verstehen den Preis auch als Empfehlung, welche Arbeit wir in diesem Jahr als besonders lesenswert erachten. Dies ist bei dieser Arbeit ohne Zweifel der Fall.

Herzlichen Glückwunsch, Hendrik Heuer, zum Weizenbaum-Studienpreis 2021.



## Warum YouTubes KI gefährlich ist und was wir dagegen tun können

### Zusammenfassung der Dissertation „Users & Machine Learning-based Curation Systems“



1. Preis

*Fake News, Verschwörungstheorien und Filterblasen sind gravierende gesellschaftliche Probleme. YouTube wird immer wieder eine Mitschuld an diesen Problemen gegeben. Mehr als zwei Milliarden Menschen nutzen YouTube jeden Monat und 70 % der dort konsumierten Videos werden von einem KI-System vorgeschlagen. Meine Dissertation untersucht, warum die Künstliche Intelligenz (KI) auf YouTube gefährlich ist und was man dagegen tun kann. Die Arbeit liefert die Grundlage für ein ganzheitliches Verständnis der Systeme, die Videos und Nachrichten empfehlen. Dazu kombiniere ich ein technisches Verständnis mit Einblicken in die Perspektiven der Nutzer:innen, der Entwickler:innen sowie die Perspektive jener, die Daten für solche Systeme liefern. Die Untersuchung zeigt, dass Erklärungen von KI-Systemen für Menschen nicht verständlich sind. Als Alternative dazu beschreibt die Arbeit Untersuchungsverfahren, die sicherstellen können, dass KI-Systeme im Interesse der Öffentlichkeit funktionieren.*

KI ist ein wichtiges Teilgebiet der Informatik. Sie ermöglicht es Computern, Aufgaben zu erledigen, die normalerweise menschliche Intelligenz erfordern. Ein wichtiger Ansatz, der für viele der jüngsten Durchbrüche in der künstlichen Intelligenz verantwortlich ist, ist das so genannte Maschinelle Lernen. Anders als Logik-basierte KI-Ansätze versucht man beim Maschinellen Lernen, mittels statistischer Verfahren aus Daten zu lernen. Dank der Techniken des Maschinellen Lernens ist es mittlerweile möglich, Sätze von einer Sprache in eine andere zu übersetzen, Personen und Objekte in Bildern zu erkennen oder Autos autonom fahren zu lassen. Plattformen wie YouTube nutzen die Techniken des Maschinellen Lernens, um automatisiert Videos auszuwählen, die für Nutzer:innen besonders interessant sind. Im Jahr 2019 wurden durchschnittlich 500 Stunden an Inhalten pro Minute bei YouTube hochgeladen. Auf den Tag gerechnet sind das 82,2 Jahre Videomaterial. Für ein Team menschlicher Expert:innen wäre es unmöglich, diese von Nutzer:innen hochgeladenen Inhalte zu überprüfen und zu kategorisieren. Social Media-Plattformen setzen daher KI-Techniken wie Maschinelles Lernen ein, um Videos zu kategorisieren und zu empfehlen. Solche Empfehlungssysteme sind sehr erfolgreich. 70 % der Videos, die die zwei Milliarden Menschen gucken, die YouTube jeden Monat nutzen, werden von diesem KI-System ausgewählt.



Hendrik Heuer beim Vorstellen seiner Dissertation

YouTube wurde von Journalist:innen immer wieder beschuldigt, Fake News und Verschwörungstheorien zu verbreiten. Ein wichtiges Beispiel für diesen Vorwurf sind die rechtsradikalen Ausschreitungen in Chemnitz im Jahr 2018. Bei einer Auseinandersetzung im Rahmen des Chemnitzer Stadtfestes wurde ein Mann durch Messerstiche tödlich und zwei weitere Personen wurden schwer verletzt. Rechte und rechtsextreme Gruppen instrumentalisierten den Vorfall mit Blick auf die vermeintliche Herkunft des Täters und riefen zu Aufmärschen auf. Einem Bericht der



New York Times zufolge schlossen sich viele Bürger:innen den rechten Aufmärschen an, nachdem sie sich auf YouTube über die Geschehnisse informiert und vom ML-basierten Empfehlungssystem immer rechtsradikalere Videos empfohlen bekommen haben. Meine Doktorarbeit ist in mehrfacher Hinsicht durch diese Vorfälle und den politischen Schock motiviert, den sie ausgelöst haben. Die Vorfälle zeigen, dass es wichtig ist zu verstehen, ob sich die Nutzer:innen der Tatsache bewusst sind, dass sie es mit Empfehlungssystemen zu tun haben. Deshalb wollte ich untersuchen, ob und wie gut Nutzer:innen verstehen, wie solche Systeme funktionieren. Es ist außerdem wichtig zu untersuchen, wie und ob solche Systeme kontrolliert werden können.

Die Arbeit ist insbesondere deshalb relevant, da repräsentative Umfragen zeigen, dass mehr als 80 % der Menschen weltweit ihre Nachrichten online konsumieren. Soziale Medien werden von mehr als der Hälfte der Menschen als Nachrichtenquelle genannt. YouTube wird von jeder vierten Person weltweit genutzt, um Nachrichten zu schauen. Ein sozio-technisches Verständnis derartiger Systeme ist deshalb von gesamtgesellschaftlicher Bedeutung. Unternehmen wie Google, Facebook, Twitter, LinkedIn, Netflix, Amazon, Microsoft, Spotify und viele andere setzen derartige Systeme auf vielfältige Weise ein. Meine Ergebnisse stellen einen wichtigen Beitrag zur Erklärung dieser KI-Systeme dar.

## ML-basierte Empfehlungssysteme

Automatisierung ist ein Kernversprechen der künstlichen Intelligenz. Insofern stellt sich die Frage: Wenn Automatisierung das Ziel ist, warum müssen Nutzer:innen ML-basierte Empfehlungssysteme verstehen? Die erste Antwort auf diese Frage steht im Zusammenhang mit den Herausforderungen, die mit der Anwendung von Maschinellem Lernen verbunden sind. Wie in der Arbeit dokumentiert, neigen Maschinelle Lernsysteme dazu, zu unerwarteten Zeitpunkten und bei unvorhersehbaren Eingaben Fehler zu machen. Deshalb müssen Nutzer:innen Situationen erkennen können, in denen ein System nicht das gewünschte Ergebnis liefert. Die zweite Antwort bezieht sich auf den Anwendungsfall. Die Empfehlungen auf YouTube beeinflussen den Medienkonsum der Nutzer:innen. Deshalb müssen Nutzer:innen wissen, dass sie es mit einem KI-System zu tun haben, das aktiv versucht, ihre Empfehlungen zu personalisieren. Personalisierung heißt, dass die Empfehlungen genau auf die Vorlieben und Interessen der Nutzenden zugeschnitten werden.

Empfehlungssysteme für Nachrichten und Videos sind eine Weiterentwicklung von Empfehlungssystemen, wie sie auch für Produkte auf Amazon oder für Musik auf Spotify genutzt werden. Im Hinblick auf Musikempfehlungen kann es für eine Nutzerin oder einen Nutzer wünschenswert sein, wenn er oder sie Musik empfohlen bekommt, die genau der Musik entspricht, die sie bereits gehört haben. Im Musikkontext kann es positiv sein, dass jemandem, der Bob Dylan mag, zunehmend Folkmusik empfohlen wird. Dieses Szenario wird in der Fachliteratur auch Filterblase genannt. In Hinblick auf Nachrichten kann dies allerdings hochgradig problematisch sein. Nehmen wir folgendes Beispiel zur Illustration. Ein Nutzer könnte zufällig ein Video über einen Verbrecher mit Migrationshintergrund sehen. Das Empfehlungssystem könnte daraufhin weitere Videos über Verbrecher:innen

mit Migrationshintergrund empfehlen. Genauso wie das System jemandem, der gerne Bob Dylan hört, weitere Lieder von Bob Dylan empfehlen würde. Während dies bei Musik positiv und gewollt sein kann, ist dies in Hinblick auf Nachrichten ein ernstzunehmendes Problem. Der Nutzer könnte fälschlicherweise glauben, dass ein Empfehlungssystem eine „objektive Realität“ repräsentiert und dass Menschen mit Migrationshintergrund häufiger Verbrechen begehen. Dabei sind die Videos, die YouTube empfiehlt, nur das Ergebnis einer Koproduktion zwischen den Handlungen der Nutzer:innen und der Fähigkeit des Empfehlungssystems, Interessen zu bedienen.

Die Doktorarbeit im Forschungsfeld Mensch-Maschine-Interaktion zeigt, dass ein Empfehlungssystem mehr als ein Algorithmus ist. Die Arbeit untersucht Empfehlungssysteme als sozio-technische Systeme, die immer von und mit Nutzer:innen in bestimmten Kontexten verstanden und untersucht werden müssen. Vom Grundprinzip her sind Empfehlungssysteme Spam-Filtern sehr ähnlich. Spam-Filter erhalten Eingaben wie den Absender, den Betreff und den Text einer E-Mail und generieren daraus eine Ausgabe. Die Ausgabe ist beispielsweise die Einschätzung, ob eine E-Mail als Spam eingestuft wird oder nicht. Ein Empfehlungssystem entscheidet, ob eine Nachricht für die Nutzer:innen interessant ist oder nicht. Allerdings ist bislang wenig darüber bekannt, worauf diese Einschätzung basiert und inwiefern Nutzer:innen verstehen, warum sie bestimmte Empfehlungen bekommen. Meine Dissertation befasst sich deshalb mit dem Verständnis von ML-basierten Empfehlungssystemen. Startpunkt ist dabei, wie Expert:innen Machine Learning verstehen. Dazu wurden mehr als vierzig Anleitungen analysiert, in denen ML erklärt wird. Die Dissertation zeichnet sich hier besonders dadurch aus, dass ich Nutzer:innen mittleren Alters ohne technischen Hintergrund aus drei verschiedenen Ländern befragt habe. Neben Nutzer:innen aus Deutschland wurden auch Nutzer:innen aus Belgien und Costa Rica befragt. Dies ermöglicht ein Verständnis, das über die Kultur eines einzelnen Landes hinausgeht.

Basierend auf dem Verständnis von KI untersuche ich verschiedene Erklärungen, die die Funktionsweise von Empfehlungssystemen nachvollziehbar machen sollen. Ein zentrales Ergebnis dieser Untersuchung ist es, dass Erklärungen nur sehr wenig nützen. Keines der von mir entwickelten Werkzeuge konnte das Verständnis erhöhen. Ein wichtiger theoretischer Beitrag der Doktorarbeit ist die von mir erkannte „Erklärungslücke“ in Empfehlungssystemen. Als Alternative beschreibt und evaluiert die Arbeit Untersuchungsverfahren, mit denen solche Systeme dennoch kontrolliert werden können.

## ML-basierte Empfehlungssysteme verstehen

Der Beitrag meiner Doktorarbeit besteht darin, Machine Learning-basierte Empfehlungssysteme ganzheitlich sowohl in Hinblick auf ihre technische Funktionsweise als auch auf das Verständnis von Nutzer:innen zu beschreiben. Die beschriebenen theoretischen Grundlagen der Vorstellung von Nutzer:innen ermöglichen ein differenzierteres Verständnis von ML-basierten Empfehlungssystemen und ihren verschiedenen Komponenten. So können Expert:innen und Laien die verschiedenen Aspekte besser verstehen, die für die Untersuchung komplexer sozio-technischer ML-Systeme relevant sind. Basierend auf diesen



theoretischen Grundlagen gestalte und evaluiere ich konkrete Empfehlungen für die Erklärung derartiger Systeme. Die Doktorarbeit zeigt deutlich, dass selbst verhältnismäßig einfache Erklärungen für Nutzer:innen nicht hilfreich und verständlich sind. Als Alternative zu diesen für Nutzer:innen nicht verständlichen Erklärungen beschreibe ich systematische Untersuchungsverfahren mittels Bots. Bots sind Programme, die Nutzer:innen simulieren und Daten über das Verhalten eines Systems sammeln können. Die Arbeit zeigt, dass Expert:innen mittels solcher Verfahren ohne Zugang zum Quellcode eines Systems überprüfen können, ob das System politisch zunehmend radikalere Inhalte empfiehlt oder bestimmte Minderheiten systematisch benachteiligt, was insbesondere für den Fall in Chemnitz interessant ist.

Meine Dissertation liefert eine theoretische Grundlage dafür, zu verstehen, wie Nutzer:innen sich erklären, warum sie bestimmte Empfehlungen sehen. Die Ergebnisse zeigen, dass Nutzer:innen zwar annehmen, dass es ein System gibt, das ihre Empfehlung beeinflusst. Sie haben aber keine klare Vorstellung davon, warum sie die Empfehlungen sehen. Auch wenn ihnen Erklärungen zu einem ML-Modell präsentiert werden, verstehen sie das KI-System nicht besser, weil wenig darüber bekannt ist, wie die ML-basierten Empfehlungssysteme auf Plattformen wie YouTube funktionieren. Die Arbeit beschreibt, wie die Vorstellungen der Nutzer:innen genutzt werden können, um bessere und verständlichere Erklärungen für die Empfehlungen ML-basierter Systeme zu gestalten. Die Arbeit bietet außerdem wichtige Einblicke in das Verständnis der Expert:innen, die die Techniken des Maschinellen Lernens anwenden. Darüber hinaus offenbart die Arbeit wichtige Einschränkungen in der Fähigkeit von Nutzer:innen, qualitativ hochwertige Trainingsdaten für ML-basierte Systeme im Kontext von Fake News zu liefern.

### Empfehlungssysteme erklären und kontrollieren

Die Dissertation zeigt, dass verschiedene einfache, intuitive und interaktive Erklärungen selbst Journalist:innen nicht helfen, besser zu verstehen, warum ihnen bestimmte Nachrichten empfohlen werden. Meine Forschungsergebnisse beschreiben eine „Erklärungslücke“ zwischen dem, was zur Erklärung ML-basierter Empfehlungssysteme zur Verfügung steht, und dem, was Nutzer:innen zum Verständnis brauchen. Die Dissertation macht deutlich, dass die Entwicklung und Bewertung der Erklärungen ML-basierter Empfehlungssysteme komplex ist. Aus der Erklärungslücke lassen sich zwei Dinge ableiten: (1) die technischen Mittel zur Erklärung ML-basierter Systeme müssen verbessert werden, und (2) das Verständnis der Nutzer:innen für solche

Systeme muss verbessert werden. Meine Dissertation zeigt außerdem, wie entscheidend es ist, ML-Erklärungen in Studien zu evaluieren. Die Ergebnisse werfen die Frage auf, ob ML-basierte Entscheidungen überhaupt auf eine Weise erklärt werden können, die für Nutzer:innen zugänglich ist.

Die Erklärungslücke hat mich dazu motiviert, alternative Lösungen zu suchen, um ML-basierte Systeme transparent zu machen. Meine Forschung zeigt, dass eine gründliche Analyse der Empfehlungen mittels systematischer Untersuchungsverfahren sinnvoll ist. Dazu werden Videoempfehlungen systematisch heruntergeladen und analysiert. Sie lassen sich dann so anpassen, dass Videos aller Menschen – unabhängig von Ethnie, Geschlecht oder politischer Meinung – empfohlen werden. So haben auch Minderheiten eine Chance, auf YouTube wahrgenommen zu werden. Die Doktorarbeit zeigt, dass solche Verfahren die Unzulänglichkeit der Erklärungen überwinden und das gesellschaftliche Vertrauen in Empfehlungssysteme erhöhen können. Dieses Vertrauen ist notwendig angesichts des sozialen, politischen und wirtschaftlichen Einflusses, den ML-basierte Empfehlungssysteme auf das Leben von Milliarden von Menschen haben. Da die Bedeutung von solchen Empfehlungssystemen in Zukunft nur noch zunehmen wird, wird die Erklärung und Prüfung von ML-basierten Empfehlungssystemen noch wichtiger werden.

Die Doktorarbeit veranschaulicht, wie Untersuchungsverfahren genutzt werden können, um zu untersuchen, ob YouTube wirklich systematisch politisch radikalere Inhalte empfiehlt, wie von der New York Times im Fall Chemnitz angenommen. Die Arbeit untersucht die Empfehlungen, die YouTube für eine Vielzahl politisch relevanter Themen macht. Für die Fälle, die ich analysiere, werden die Empfehlungen nicht radikaler. Vielmehr empfiehlt YouTube systematisch populärere Inhalte, gemessen an den Aufrufen und den Likes der Videos. Gleichzeitig zeigt meine Untersuchung, dass YouTube Empfehlungssystem keinen Minderheitenschutz gewährleistet, wie ihn deutsche Gesetze wie der Rundfunkstaatsvertrag fordern. Insgesamt zeigt meine Arbeit, dass das Risiko von Filterblasen möglicherweise nicht die größte Gefahr darstellt. Vielmehr ist die mögliche Unterdrückung von Minderheitsmeinungen ein akuteres Problem für die demokratische Meinungsbildung. Die Ergebnisse der Arbeit illustrieren, wie die von mir vorgestellten Untersuchungsverfahren systematische Verzerrungen aufdecken können. Solche Verzerrungen können die politischen Überzeugungen und Handlungen von Menschen beeinflussen, was sich negativ auf das demokratische Gemeinwesen auswirken kann. Deshalb schließe ich die Arbeit mit einer Skizze einer Institution des öffentlichen Rechts, die

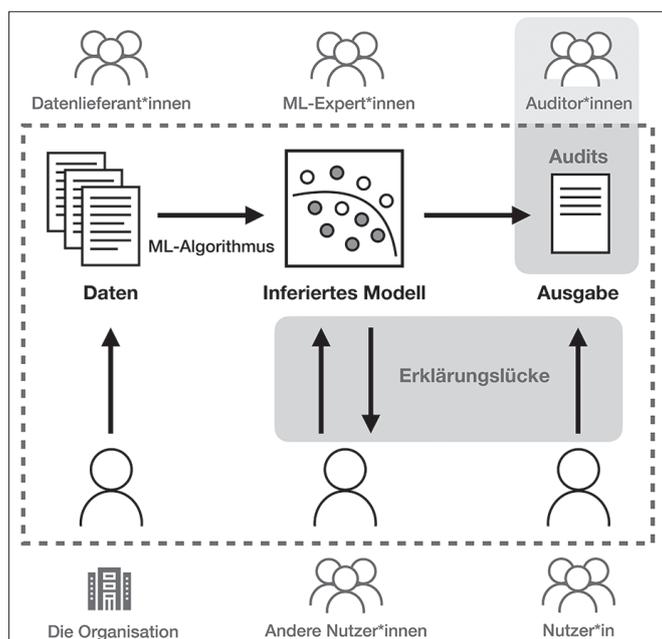
**Hendrik Heuer**



Foto Cosima Hanebeck

**Hendrik Heuer**, Dr.-Ing., ist wissenschaftlicher Mitarbeiter am Institut für Informationsmanagement Bremen (ifib) und Zentrum für Medien-, Kommunikations- und Informationsforschung (ZeMKI) an der Universität Bremen. Seine Forschungsschwerpunkte sind Mensch-Computer-Interaktion und Maschinelles Lernen. Derzeit arbeitet er an Möglichkeiten zur Bekämpfung von Desinformation. Darüber hinaus versucht er Texte für Menschen mit Behinderungen zugänglicher zu machen. Er hat Digitale Medien, Mensch-Computer-Interaktion und Maschinelles Lernen in Bremen, Buffalo, Stockholm, Helsinki und Amsterdam studiert.

analog zu TÜV und Stiftung Warentest sicherstellt, dass zentrale ML-basierte Empfehlungssysteme im Interesse des demokratischen Gemeinwohls agieren. Diese Institution soll Expert:innen zusammenbringen, die Anforderungen an ein ML-basiertes System sammeln. Durch die von mir beschriebenen Untersuchungsverfahren lässt sich feststellen, wo ein System den Anforderungen entspricht und wo nachgebessert werden muss.



Ein sozio-technisches Modell eines ML-basierten Kurierungssystems. Das Modell stellt die in dieser Arbeit erkannten Akteur:innen und die Erklärungslücke und Audits dar. Das Icon für die Organisation stammt von Freepik und [www.flaticon.com](http://www.flaticon.com)

Die Abbildung bietet eine Übersicht über die Akteur:innen, die für die Untersuchung von ML-basierten Kurierungssystemen relevant sind. Neben den Nutzer:innen, den Daten, dem ML-Algorithmus, dem inferierten Modell und der Ausgabe des ML-Systems werden in meiner Dissertation fünf weitere Akteur:innen beschrieben, die ML-basierte Kurierungssysteme beeinflussen:

- die Organisation, die das System betreibt
- andere Nutzer:innen, z. B. in den sozialen Medien
- Datenlieferanten, die die Eingabe-Daten für das Training der ML-Systeme liefern
- ML-Praktiker:innen, die das ML-basierte System entwickeln und evaluieren
- Auditor:innen, die die Ausgabe von ML-basierten Systemen systematisch überprüfen.

Es ist wichtig, diese verschiedenen Akteure, ihre Verantwortlichkeiten und ihre Ziele zu untersuchen, um ihre Handlungsmacht (Agency) zu erkennen und um zu verstehen, wie ML-basierte Kurierungssysteme erklärt und kontrolliert werden können und sollten.

## Fazit

Die Doktorarbeit bietet eine ganzheitliche sozio-technische Perspektive auf ML-basierte Empfehlungssysteme. Sie stellt theoretische Grundlagen zur Verfügung, um die Besonderheiten des Maschinellen Lernens kritisch zu reflektieren. Die Dissertation zeigt, dass *der Algorithmus*, der in der bisherigen Forschung eine wichtige Rolle spielt, nur Teil eines größeren sozio-technischen Systems ist. Zu diesem System gehört auch der Einfluss der Nutzer:innen, der Daten, des ML-Modells und der Benutzungsschnittstelle. Darüber hinaus spielt auch die Organisation eine wichtige Rolle, die das ML-basierte Empfehlungssystem betreibt. Meine Forschung zeigt, dass auch andere Nutzerinnen und Nutzer einer Social-Media-Seite sowie die Datenzulieferer, die Trainingsdaten für die KI bereitstellen, einen wichtigen Einfluss haben. Darüber hinaus untersucht die Arbeit die Rolle der ML-Expert:innen, die die Systeme trainieren. In der Dissertation erkläre ich im Detail, warum es wichtig ist, diese verschiedenen Akteure, ihre Verantwortlichkeiten und ihre Ziele zu verstehen. Ich biete außerdem konkrete Empfehlungen, wie ML-basierte Empfehlungssysteme erklärt und kontrolliert werden sollten.

Die Arbeit zeigt, warum YouTubes Möglichkeit zur Beeinflussung von Nutzer:innen eine Gefahr darstellt. Dies ist insbesondere für diejenigen wichtig, denen nicht bewusst ist, dass sie Empfehlungen bekommen. Es richtet sich aber auch an Nutzer:innen, die nicht verstehen, warum sie bestimmte Empfehlungen bekommen. Da sich Erklärungen der KI als nur bedingt hilfreich erwiesen haben, zeigt die Arbeit, wie derartige Systeme durch die systematische Analyse von Empfehlungen kontrolliert werden können. Meine Untersuchungen zeigen, dass die von mir beschriebenen Untersuchungsverfahren ein Weg sind, um Rechenschaftspflicht für Künstliche Intelligenz durchzusetzen. So kann sichergestellt werden, dass ML-basierte Systeme diskriminierungsfrei und zum Wohle aller arbeiten.

Die Arbeit wurde von Andreas Breiter (Universität Bremen) und Elena L. Glassman (Harvard University) betreut. Sie können die Arbeit über die Staats- und Universitätsbibliothek Bremen kostenlos als eBook herunterladen (Open Access): Heuer, H., 2020. Users & Machine Learning-Based Curation Systems (Universität Bremen). <https://media.suub.uni-bremen.de/handle/elib/4444>

## Referenzen

- Alvarado O, Heuer H, Vanden Abeele V, Breiter A, Verbert K (2020) Middle-Aged Video Consumers' Beliefs About Algorithmic Recommendations on YouTube. Proceedings of the ACM on Human-Computer Interaction, 4(CSCW2).
- Heuer H, Breiter A (2018) Trust in news on social media. Proceedings of the 10th Nordic conference on human-computer interaction (pp. 137-147).
- Heuer H, Hoch H, Breiter A, Theocharis Y (2021) Auditing the Biases Enacted by YouTube for Political Topics in Germany. Mensch und Computer 2021.
- Heuer H, Jarke J, Breiter A (2021) Machine learning in tutorials—Universal applicability, underinformed application, and other misconceptions. Big Data & Society.
- Heuer H (2021) The Explanatory Gap in Algorithmic News Curation. MIS-DOOM 2021.

