

Schriften zur Medienpädagogik 60

Un|Sichtbarkeiten?

Medienpädagogik, Intersektionalität und Teilhabe

Sabine Eder
Habib Güneşli
Renate Hillen
Claudia Wegener
Rebecca Wienhold (Hrsg.)

Schriften zur Medienpädagogik 60

Dem Bundesministerium für Familie, Senioren, Frauen und Jugend danken wir für die Förderung des vorliegenden Bandes.

Herausgeber

Gesellschaft für Medienpädagogik und Kommunikationskultur in der Bundesrepublik Deutschland (GMK) e. V.

Anschrift

GMK-Geschäftsstelle

Obernstr. 24a

33602 Bielefeld

Fon: 0521/677 88

Fax: 0521/677 29

E-Mail: gmk@medienpaed.de

Homepage: www.gmk-net.de

Für namentlich gekennzeichnete Beiträge sind die Autor*innen verantwortlich.

Redaktion: Sabine Eder, Habib Güneşli, Renate Hillen, Claudia Wegener, Rebecca Wienhold, Tanja Kalwar

Lektorat: Tanja Kalwar

Einbandgestaltung und Titelillustration: Katharina Künkel

© kopaed 2024

Arnulfstr. 205

80634 München

Fon: 089/688 900 98

Fax: 089/689 19 12

E-Mail: info@kopaed.de

Homepage: www.kopaed.de

ISBN 978-3-96848-752-6

Spätestens seit dem Launch von ChatGPT zeigt sich in der Öffentlichkeit und auch innerhalb der Medienpädagogik ein gesteigertes Interesse an Künstlicher Intelligenz (im Folgenden KI) – und das ist auch gut so. Denn die gesellschaftliche Bedeutung von KI steigt zunehmend. Für Einzelpersonen und Nutzer*innen digitaler Medien wird dies mit Diensten wie ChatGPT nun auch in ihrem (digitalen) Alltag erfahrbar. Eingesetzt wird KI bereits seit längerem in vielfältigen Bereichen wie etwa Gesundheit und Medizin, Arbeit, Sicherheit und Überwachung, Aktienhandel, Verwaltung oder Verkehr. Konkret geht es um Bewerbungsverfahren, Personalmanagement, Diagnoseverfahren, das Kuratieren von Inhalten auf Social-Media-Plattformen, Kameraüberwachung, vorhersagende Polizeiarbeit, Navigationsgeräte, autonomes Fahren oder autonome Waffensysteme und vieles mehr – wobei immer mehr Felder und konkrete Einsatzgebiete hinzukommen (vgl. AlgorithmWatch 2019). Kürzlich hat Google etwa angekündigt, Suchmaschinen zu launchen, die KI-basierte Antworten auf Suchanfragen geben (vgl. Wagner 2024).

Auch wenn KI viele Prozesse verschiedener Art vereinfachen kann, soll im Folgenden den Fragen nachgegangen werden, wie sie an der Produktion von Wissen und an der Konstruktion von Wirklichkeiten beteiligt ist und wie in diesen Prozessen gesellschaftliche Ungleichheiten (re-)produziert werden. Denn KI-basierte Aussagen über die Zukunft – etwa wer berechtigt ist, Sozialleistungen zu beziehen, wer kreditwürdig ist, wer geeignete Kandidat*innen für einen Job sind oder wie die Rückfallquoten von Straftäter*innen aussehen (für mehr Beispiele siehe AlgorithmWatch 2022, 2019) – können konkrete Folgen für die Lebensrealitäten von Menschen haben. Umso wichtiger ist es, die Funktionsweise von KI besser zu verstehen, um darauf aufbauend informierte Entscheidungen treffen zu können, wie ihre gesellschaftliche Bedeutung zu bewerten ist, wo sie (nicht) zum Einsatz kommen soll oder nur unter bestimmten Einschränkungen. Bevor die von mir definierten Problemfelder bezüglich des Einsatzes von KI dargelegt werden, wird im Folgenden eine Begriffsbestimmung vorgenommen und erläutert, warum vorzugsweise von algorithmischen Entscheidungssystemen (AES) statt von KI gesprochen werden sollte.

Vom Buzzword KI zu algorithmischen Entscheidungssystemen (AES)

In öffentlichen Diskussionen scheint der Begriff KI derzeit omnipräsent zu sein, häufig allerdings, ohne dass klar ist, was genau mit KI gemeint ist. Oftmals scheint KI eher als Aufmerksamkeit erregendes Buzzword zu fungieren und als Projektionsfläche für Hoffnungen und Möglichkeiten, welche die neuen technologischen Entwicklungen bieten, aber auch für diesbezügliche Ängste und Sorgen. Häufig wird KI dabei als etwas „Magisches“ beschrieben, das für „einfache“ Menschen ohne tiefergehende Programmierkenntnisse nicht zu verstehen ist und das übermenschliche Fähigkeiten entwickeln kann. Ein solcher Diskurs trägt allerdings dazu bei, KI als objektiv und präzise zu framen und führt weiter dazu, dass KI-basierte Vorhersagen schnell als „wahr“ akzeptiert werden, ohne dass hinterfragt wird, wie sie entstanden sind (vgl. Campolo/Crawford 2020). Auch die wichtige Frage nach der Verantwortung für die Folgen von KI-basierten Entscheidungen werden so irrelevant. KI ist aber keineswegs magisch. Kritische Stimmen weisen darauf hin, dass KI als Marketing-Begriff geprägt wurde, der bis heute Möglichkeiten verspricht, welche die dahinterstehenden Technologien bisher keineswegs einlösen konnten bzw. können (vgl. Whittaker 2024; Goodland 2023; Günther 2022: 47-86). Auch der Begriff Intelligenz lässt vermuten, dass KI die Fähigkeit besitze zu denken, eigenständig zu handeln und zu reflektieren. Tatsächlich wird „Intelligenz“ im Kontext von KI aber sehr eng verstanden, d.h. sehr rationalistisch und als Automatisierung kognitiver Prozesse, wie z.B. bei einem Schachcomputer (vgl. Günther 2022: 49-56; Crawford 2021: 7). Dass menschliche Intelligenz aber viel mehr als rationales Denken beinhaltet, bleibt hier unberücksichtigt.

Zutreffender ist es daher, von algorithmischen (oder auch automatisierten) Entscheidungssystemen (AES) zu sprechen. Gemeint sind damit Entscheidungssysteme, die auf Algorithmen basieren und die automatisiert ausgeführt werden. Ein Algorithmus ist eine mathematische Handlungsanweisung, die Schritt für Schritt festlegt, wie eine bestimmte Aufgabe bearbeitet werden soll. Er erzielt ausgehend von einem bestimmten Input, einem Datensatz, einen beabsichtigten Output, z.B. eine sortierte Liste. D.h. der Input wird anhand der Handlungsanweisungen bearbeitet. Weiter ist in regelgeleitete und lernende Algorithmen (im Folgenden ALG) zu unterscheiden (vgl. AlgorithmWatch 2022; Fry 2019). Bei regelgeleiteten ALG sind die Handlungsanweisungen des ALG explizit festgelegt. Lernende ALG werden hingegen mit Datensätzen trainiert. Sie analysieren bestehende Datensätze, die sogenannten Trainingsdatensätze, und suchen nach

datenbasierten Mustern und Korrelationen innerhalb dieser Datensätze. Ihre Erkenntnisse können sie dann auf neue Datensätze anwenden. In AES werden ALG dann automatisiert ausgeführt.

Dabei sind es nicht AES selbst, die Entscheidungen treffen. Vielmehr sprechen sie Empfehlungen für Entscheidungen aus, wie etwa dazu, wer seinen Kredit am wahrscheinlichsten zurückzahlt, wer die wahrscheinlich kompetentesten Bewerber*innen sind, wer Anspruch auf Sozialleistungen hat, wer nach einer Straftat am wahrscheinlichsten rückfällig wird oder auch, wo mit einer hohen Wahrscheinlichkeit von einer Erkrankung an Brustkrebs auszugehen ist. Zu diesen Empfehlungen kommen AES, indem sie Wahrscheinlichkeiten berechnen, die sie aus den Input-, bzw. Trainingsdaten erlernt haben. Das heißt, sie sprechen keine Wahrheiten aus, sondern machen probabilistische Aussagen.

Das Ziel von AES ist es, realweltliche Problemstellungen zu lösen, wie etwa die oben genannten. Hierzu müssen diese Problemstellungen zunächst in computer- und maschinelesbare Codes übersetzt werden (vgl. Günther 2022: 43 ff.). Programmierer*innen schreiben also nicht „nur“ einen Code, sondern tragen im Rahmen ihrer konzeptionellen Arbeit auch zur Ausgestaltung von Systemen bei, welche hohe gesellschaftliche Relevanz besitzen (vgl. ebd.: 46-47). Das heißt auch, AES sind *soziotechnische Systeme*. Denn es sind immer noch Menschen, die definieren, mit welchen Aufgaben sich AES beschäftigen sollen, wie diese Aufgaben gelöst werden sollen und welche Daten hierzu geeignet sind. Gleichzeitig bringen AES natürlich auch eigene Affordanzen mit in den Prozess der Wissensproduktion ein; etwa die Tatsache, dass sie auf Basis von metrischen Daten operieren. Im Folgenden soll nun das Verhältnis von Ungleichheiten, Daten und AES anhand von vier von mir identifizierten Problemfeldern vorgestellt werden. In jedem Problemfeld wird ein exemplarisches Beispiel mit einbezogen, um die Argumente zu verdeutlichen.

Problemfeld 1: Repräsentativität von Daten

Das erste Problemfeld betrifft die Repräsentativität von Daten, das anhand des Beispiels der Gesichtserkennung und der Studie „Gender Shades“ von Joy Buolamwini und Timnit Gebru (2018) erläutert werden soll. Gesichtserkennung wird heute schon vielerorts eingesetzt, sei es zum Smartphone entsperren, in der Polizeiarbeit oder in Fotoautomaten (vgl. AW 2022, 2019). In der vielzitierten Studie zeigen die Autorinnen, dass Gesichtserkennung (geschlechtlich binär gedacht) bei ► **weißen Männern** am besten, bei ► **Schwarzen Frauen** und bei Frauen hingegen schlechter und bei Schwarzen Frauen

am schlechtesten funktioniert (vgl. Buolamwini/Gebru 2018). Begründet werden kann dies mit den Datensätzen, mit denen die AES, auf denen die Gesichtserkennung basiert, trainiert wurden. Zwar ist nicht immer einsehbar mit welchen Trainingsdatensätzen ALG trainiert wurden, aber es gibt sogenannte Benchmark Datensätze (vgl. Crawford 2021), die frei zugänglich sind und vielfach verwendet werden. Zwei von diesen Datensätzen haben die Autorinnen untersucht und festgestellt, dass in diesen nur 4,4 Prozent bzw. 7,4 Prozent Personen Schwarze Frauen sind. Weil sie so selten vorkommen, erzielen die Modelle für ihre Gesichter so schlechte Ergebnisse. ► **Nonbinäre** und ► **Transpersonen** kommen hingegen gar nicht vor bzw. sind nicht als solche gelabelt. Diese fehlende Repräsentativität von Schwarzen Frauen ist Ausdruck gesellschaftlicher Marginalisierung von Schwarzen Frauen und ihren Belangen insgesamt. Zwar ist die Frage der Repräsentativität von Daten keine neue, in AES kommt ihr aber eine besondere Bedeutung zu, da der Output von AES häufig als objektiv wahrgenommen wird und der Trainingsdatensatz dann beim Anwenden eines AES auf neue Daten unsichtbar erscheint.

Problemfeld 2: Auslöschung von Abweichung – Reproduktion der Norm

Dieses Problemfeld knüpft direkt an das obige an. Als Beispiel soll hier das selbstfahrende Auto und seine Fähigkeit, Menschen zu erkennen, vorgestellt werden. Jutta Trevirani (2019) weist darauf hin, dass selbstfahrende Autos rückwärtsfahrende Rollstühle häufig nicht erkennen können. Insgesamt scheint es schwierig für selbstfahrende Autos, Menschen zu erkennen, die sich nicht entsprechend der Norm eines ► **abled bodies**, d.h. entsprechend eines „normalen“ und „gesunden“ Körpers bewegen. Das hat, wie oben bereits erläutert, einerseits damit zu tun, dass diese Menschen in Trainingsdaten häufig nicht bzw. nur sehr selten vorkommen. Andererseits – und hier geht es über die Frage von Repräsentativität hinaus – werden sie in den Datensätzen, die als Trainingsdaten genutzt werden, meist als Störung oder als Einzelfall herausgerechnet (häufig unter dem Stichwort Outlier-Bereinigung). Datensätze werden häufig auf eine solche Art bereinigt und kuratiert, dass alles, was sich an den Rändern befindet, was selten vorkommt, unsichtbar gemacht wird (vgl. Crawford 2021). Hier wird also eine bereits bestehende Norm reproduziert (vgl. Whittaker et al. 2019).

Auch im Kontext von bildgenerierenden Modellen zeigt sich besonders eindrücklich, wie bereits bestehende Normen und dominante Bilder von Menschen reproduziert werden. Denn diese Modelle haben z.B. (derzeit noch) große Schwierigkeiten, adäquate Bilder von ► **trans** Personen zu generieren. Mit AES produzierte Bilder von ihnen sind entweder entstellt oder sexualisiert

oder sie können gar nicht dargestellt werden (vgl. Ugless et al. 2023). Auch bei der Erzeugung von Bildern, in denen Schwarze Ärzt*innen weiße Kinder behandeln sollen, haben AES Probleme (vgl. Drahl 2023). Dies ist besonders brisant, weil bildgenerierende Modelle an der Produktion von Wissen beteiligt sind. Wenn AES zum Einsatz kommen, gilt es also immer zu fragen: Welche Normalitäten und Ausschlüsse werden mittel AES (re-)produziert?

Problemfeld 3: Discrimination-Feedback-Loop oder die Konstruktion von Ungleichheiten in Lebensrealitäten und Daten

Im dritten Problemfeld geht es darum, dass Daten in den Lebensrealitäten von Menschen erhoben werden. Diese Lebensrealitäten sind von Macht- und Ungleichheitsverhältnissen geprägt, d.h. es finden sich unterschiedliche Zugänge zu Ressourcen wie etwa Geld, Macht, Einfluss oder gesellschaftliche Mitbestimmung sowie hierarchisierende Zuschreibungen von Eigenschaften und Kompetenzen, die Personengruppen homogenisieren und voneinander unterscheiden. Dadurch zeigen sich tendenziell bereits in den Daten diese gesellschaftlich produzierten Ungleichheiten. Das nachfolgende Beispiel sind hier AES, die in einigen US-Bundesstaaten eingesetzt wurden, um Aussagen darüber zu machen, wie wahrscheinlich es ist, dass Angeklagte rückfällig werden. Solche AES sollen Richter*innen dabei unterstützen, für die Angeklagten möglichst „passende“ Urteile zu fällen. Ein Team von ProPublica, einer US-amerikanischen NGO für investigativen Journalismus, hat bereits 2016 recherchiert, dass die von dem AES ermittelten Risiko-Scores zur potenziellen Rückfälligkeit von Straftäter*innen erstens nur in etwas mehr als der Hälfte zutreffen, wenn man sie mit den darauffolgenden Jahren abgleicht, und zweitens, dass Schwarze Angeklagte gegenüber weißen Angeklagten durch das Modell fast doppelt so oft fälschlicherweise als zukünftig rückfällig bestimmt wurden (vgl. ProPublica 2016). Das Modell schreibt diese Scores dabei nicht anhand des Aussehens von Personen zu und operiert offen und eindeutig rassistisch. Vielmehr berechnet die Score sich aus einem Fragenkatalog von 137 Fragen, deren Antworten den Akten der Angeklagten entnommen oder erfragt werden (vgl. ebd.). Eine der Fragen, die die Entwickler*innen des Modells als relevant für die Errechnung der Scores ansehen, lautet etwa: „Was one of your parents ever send to jail?“ Hierzu ist zu beachten, dass in den Gefängnissen in den USA überproportional viele Schwarze Menschen und Menschen of Color sitzen (vgl. Nellis 2021; Alexander 2010), was von US-amerikanischen Forscher*innen sowie Aktivist*innen unter dem Stichwort *Prison Industrial Complex* diskutiert wird (vgl. Davis 2000; Wright/Herivel 2003; Muhammad 2019). Als Grund für diese Tatsache wird dabei insbe-

sondere struktureller Rassismus genannt, der sich z.B. in Diskriminierung im Gesundheitssystem, finanziell schlechteren Lebenslagen oder Zuschreibung von Kriminalität und Schwarze Menschen äußert.

Das heißt, bereits existierende gesellschaftliche Ungleichheiten drücken sich in den Lebensrealitäten und damit natürlich auch in den dazugehörigen Daten aus. In dem hier genannten Beispiel wird davon ausgegangen, dass Personen mit Elternteilen, die im Gefängnis waren oder sind, dazu neigen, selbst kriminell zu werden, während gleichzeitig nicht reflektiert wird, dass Schwarze Menschen und Menschen of Color überproportional oft Gefängnisstrafen auferlegt bekommen. In der menschlich getroffenen Entscheidung, welche Daten in das AES fließen, finden sich also bereits inhaltliche Setzungen, die dazu führen, dass bereits bestehende Ungleichheiten bestätigt und dadurch verstärkt werden. In der Berechnung der Rückfallwahrscheinlichkeit von Angeklagten durch das hier vorgestellte AES wird die Annahme, „Personen mit Elternteilen, die im Gefängnis waren/sind, neigen zu Kriminalität“ verabsolutiert und zur Realität gemacht, indem entsprechenden Personen nun selbst höhere Rückfallquoten zugeschrieben werden, die dann höhere Strafen bedeuten. Es handelt sich um einen selbstverstärkenden Zirkel mit wirklichkeitserzeugenden Effekten oder, wie West et al. (2019: 15) es nennen: einen „Discrimination-Feedback-Loop“.

Problemfeld 4: Datenfundamentalismus und die ausschnittshafte Realität von Daten

Im vierten Problemfeld geht es um Datenfundamentalismus (vgl. Crawford 2013) und die Datafizierung des Sozialen (vgl. Houben/Prietzl 2018). Hierbei ist zu beachten, dass AES als „Datentechnologien“ (Prietzl 2023: 67) erstens immer mit Daten operieren und dass Daten zweitens nicht neutral sind. Vielmehr stellen sie immer nur einen Ausschnitt von Wirklichkeit dar und werden immer produziert. Gerade metrische Daten können viele Phänomene des menschlichen Miteinanders nur unzureichend abbilden. Daniel Houben und Bianca Prietzl (2018: 16-17) heben hervor, dass „Daten *eher erfunden und generiert*, denn einfach nur gefunden und gesammelt werden, und folglich nie in einem exakten Abbildungsverhältnis zu einer wie auch immer verstandenen Realität stehen. Entgegen der alltagsweltlichen Repräsentationsthese ist vielmehr festzuhalten, dass Daten die von ihnen vorgeblich nur beschriebene soziale Wirklichkeit als solche erst mit hervorbringen“.

Im Kontext von AES werden Datensätze zudem in der Regel kuratiert, bevor sie als Trainingsdatensätze verwendet werden (Stichwort Outlier-Bereinigung), wobei Klassifizierungen und Labels in den Trainingsdatensätzen

manuell zugeordnet werden (vgl. Crawford 2021; Prietl 2023). Wird ein Label nicht zugeordnet, kommt es im Trainingsdatensatz nicht vor. Kate Crawford (2021) erläutert anschaulich die Entstehungsgeschichte verschiedener Benchmark-Datensätze und damit verknüpfte inhaltliche Setzungen innerhalb dieser Datensätze. Verbunden mit der Produktion von Datensätzen ist zudem die Frage relevant, zu wem die extrahierten und in den Datensatz eingefügten Daten eigentlich gehören und ob diese Personen ihren Konsens zur Weiterverarbeitung der Daten gegeben haben.

Trotz dieses Wissens um die Begrenztheit und Konstruiertheit von Daten herrscht in Data Analytics und im Tech-Bereich vielerorts das vor, was Crawford (2013) als Datenfundamentalismus beschreibt. Datenfundamentalismus meint die Annahme, dass Daten ein reiner Ausdruck von Realität seien und mittels ihrer Analyse daher zutreffende Aussagen über Realität getroffen werden könnten. Das kann soweit gehen, dass eine Abkehr von theoretisch informiertem, verstehendem und reflektierendem Erkenntnisgewinn gefordert wird und Wahrheit bzw. Erkenntnisgewinn ausschließlich in Daten verortet wird (vgl. Crawford 2012, 2021). Es wird damit eine mechanische oder datafizierte Objektivität deklariert. Kurz: Die Wahrheit liegt in den Daten und ihren Korrelationen. Inwiefern diese Denkweise gesellschaftliche Ungleichheiten verstärkt, wurde bereits dargelegt. Was in diesem Blick zudem negiert und unsichtbar gemacht wird, ist die innerhalb der Sozialwissenschaften etablierte Erkenntnis, dass Wirklichkeiten fortlaufend konstruiert und ausgehandelt werden, inklusive hierarchisierender Normierungen, Ordnungen, Strukturen. Es wird ein Ist-Zustand als gegeben akzeptiert, während Prozesse der Herstellung von Wirklichkeiten und die Situiertheit des eigenen Wissens und des eigenen Blicks unreflektiert bleiben.

Dies zeigt sich auch im Umgang mit Geschlecht in Data Analytics. Geschlecht wird in AES in der Regel binär codiert, wie auch in der Studie von Buolamwini und Gebu (2018). Generell wird Geschlecht dabei als Merkmal behandelt, das Menschen haben und das einfach erhoben werden kann – und entsprechend sieht dann der dazugehörige Output aus. Das hat einerseits zur Folge, dass alle Menschen, die in diese engen statischen Kategorien nicht hineinpassen, unsichtbar gemacht werden. Andererseits wird die sozialwissenschaftlich anerkannte Annahme, dass Zweigeschlechtlichkeit und Geschlechterdifferenzen und -hierarchien keineswegs Merkmale sind, sondern in sozialen Prozessen fortlaufend hergestellt werden, nicht anerkannt und unsichtbar gemacht. Dies betrifft auch das Wissen, dass Zweigeschlechtlichkeit mit der bürgerlich-kapitalistischen Gesellschaft festgeschrieben und gesellschaftlich verankert wurde und dass gesellschaftliche Geschlechterordnungen und -normen existieren, die Menschen überhaupt erst sozial rele-

vant in zwei hierarchisierte Geschlechter einteilen (vgl. Gildemeister 2008; Maihofer 1995). Solche Zuschreibungen können dann z.B. dazu führen, dass Mädchen und Frauen bezüglich technischer Aufgaben und in technisch konnotierten Berufen Abwertung erfahren und daher noch immer eher andere Berufsfelder wählen, obwohl dieser Bereich sehr gut bezahlt ist. Diese Prozesse der Konstruktion von Geschlecht finden alle *nicht* Eingang in den oben beschriebenen Blick auf Geschlecht als Merkmal. Die Datafizierung des Sozialen teilt soziale Phänomene und Lebensrealitäten in kleine, fein voneinander abgrenzbare, statische Elemente ein, während die gesellschaftlichen und sozialen Prozesse, mit denen diese Lebensrealitäten zusammenhängen, abgeschnitten werden. Das bedeutet nicht, dass AES insgesamt zu verwerfen sind. Um differenzierte und ethisch reflektierte Entscheidungen über den Einsatz von AES treffen zu können, ist es aber zentral zu verstehen, wie sie funktionieren und welcher Blick auf Welt und Wirklichkeit ihnen innewohnt.

Weitere Problemfelder: Datenkapitalismus, Ungleichheiten in der Tech-Branche, Ausbeutung natürlicher Ressourcen und Arbeitskraft

Ungleichheiten in AES betreffen nicht nur die verwendeten Daten. Vielmehr gibt es noch viele weitere Problemfelder, die im Folgenden nur kurz skizziert werden sollen. Ein erstes weiteres Problemfeld betrifft das Thema Marktmacht und Datenkapitalismus. Hier geht es darum, wer eigentlich Zugang zu Daten, zu Infrastrukturen und zu Ressourcen hat, um AES entwickeln und trainieren zu können: Wer bestimmt darüber, zu welchen Zwecken AES entwickelt und eingesetzt werden und wer profitiert von AES und wer nicht (vgl. Vipra/West 2023; Crawford 2021)? Eines der größten Einsatzgebiete für AES ist etwa noch immer der Werbemarkt, d.h. personalisiertes Microtargeting und Ad Tech – ein Bereich, von dem das Gemeinwohl wenig profitiert. Insgesamt liegt die meiste Gestaltungsmacht im Kontext von AES bei nur einigen wenigen großen Unternehmen aus den USA und China, den sogenannten Big Tech (vgl. Crawford 2021).

Bezüglich der Reproduktion von Ungleichheiten in AES ist weiter die Frage relevant, wer eigentlich im Tech-Bereich arbeitet und welches Wissen zu Prozessen der Reproduktion von Ungleichheiten mittels AES besteht. West et al. (2019: 5) sprechen von einer „Diversity Crisis in the AI Industry“ und kritisieren eine fehlende Diversität und eine Dominanz von weißen ►cis Männern innerhalb der großen Tech-Unternehmen (siehe auch Weber/Prietzl 2020).

Ein letzter relevanter Punkt betrifft die Ausbeutung von natürlichen Ressourcen und Arbeitskraft. Denn viele der Arbeiten, die noch immer manuell ausgeführt werden müssen, werden von schlecht bezahlten Klick-Workern im

globalen Süden erledigt (vgl. Vipra/West 2023; Crawford 2021). Weiter (ver-)brauchen AES natürliche Ressourcen. Es ist oft unsichtbar, aber AES und Digitalität insgesamt benötigen Chips, Leitungen, Batterien etc., die meist im globalen Süden unter schwierigen Arbeitsbedingungen abgebaut und in einem neokolonialen Wirtschaftssystem gehandelt werden (vgl. Crawford 2021).

Ausblick: Debatten starten und bereits bestehende Erkenntnisse nutzen

Abschließend stellt sich die Frage, wie mit den bis hier entfalteten Erkenntnissen nun umzugehen ist und welche Schlüsse insbesondere für die Medienpädagogik hieraus zu ziehen sind? Auch wenn die Antworten darauf keine einfachen sind und gemeinsame Anstrengungen benötigen, sollen im Folgenden zumindest einige Impulse gegeben werden.

Erstens und grundlegend bedürfte es mehr Möglichkeiten der gemeinschaftlichen und gemeinwohlorientierten Gestaltung und Anwendung von AES. Zweitens braucht es mehr kollektives Wissen und Reflexion darüber, wo und wie AES derzeit zur Anwendung kommen oder kommen sollen bzw. nicht sollen und wer darüber bestimmen kann. Zu diesen Fragen arbeiten bereits zahlreiche NGOs (im deutschsprachigen Raum etwa Algorithm Watch, im englischsprachigen Raum AI Now Institute), die hierzu regelmäßig Materialien und Analysen veröffentlichen. Drittens braucht es mehr Wissen und Reflexion darüber, wie gesellschaftliche Ungleichheiten und Herrschaftsverhältnisse unsere Wirklichkeiten prägen und wie sie in Technologien und AES eingelagert sind und mittels dieser verstärkt werden. Da diese Themen größtenteils nicht neu sind, gibt es auch hierzu bereits viel Wissen. Zu empfehlen sind Arbeiten aus den feministischen oder auch postkolonialen Science und Technology Studies zum Verhältnis von Technik, Technologien und Macht (vgl. etwa Haraway 2017 [1995]; Hicks 2017; Harding 2011; Cockburn/Ormrod 1997). Viertens braucht es daran anknüpfend im Sinne einer Data Literacy (die es in Bezug auf AES weiter auszuarbeiten gilt) mehr Wissen und Reflexion zu Daten und zu ihrem konstruierten und wirklichkeitserzeugenden Charakter (vgl. Ahlborn et al. 2021; Barberi et al. 2021; Dander 2014). Wichtig ist fünftens, dass wir Berührungspunkte mit dem Thema abbauen und dem Mythos der Magie und der Übermacht von KI nicht unreflektiert nachgeben. Auch wenn keine Programmierkenntnisse bestehen und einzelne Schritte in der Anwendung von AES möglicherweise nicht bis ins Detail nachvollzogen werden können, ist es möglich, die grundlegende Funktionsweise von AES zu verstehen. Hierzu kann Medienpädagogik einen wesentlichen Beitrag leisten.

Literatur

- AlgorithmWatch (2022): *Automatisierte Entscheidungssysteme und Diskriminierung. Ursachen verstehen, Fälle erkennen, Betroffene unterstützen*. Berlin. Abrufbar unter: https://algorithmwatch.org/de/wp-content/uploads/2022/06/AutoCheck-Ratgeber_ADM_Diskriminierung_DE-AlgorithmWatch_Juni_2022.pdf [Stand: 08.07.2024].
- AlgorithmWatch (2019): *Atlas der Automatisierung. Automatisierte Entscheidungen und Teilhabe in Deutschland*. Berlin. Abrufbar unter: https://atlas.algorithmwatch.org/wp-content/uploads/2019/07/Atlas_der_Automatisierung_von_AlgorithmWatch.pdf [Stand: 08.07.2024].
- Alexander, Michelle (2010): *The New Jim Crow: Mass Incarceration in the Age of Colorblindness*. New York: New Press.
- Ahlborn, Juliane/Verständig, Dan/Stricker, Janne (2021): *Embracing Unfinishedness: Kreative Zugänge zu Data Literacy*. In: *Medienimpuls*, Jg. 59, Nr. 3, 1-42.
- Barberi, Alessandro/Grabensteiner, Caroline/Himpsl-Gutermann, Klaus (2021) (Hrsg.): *Data Literacy – Datenkompetenz – Datenbildung*. In: *Medienimpulse*, Jg. 59, Nr. 3.
- Bender, Emily M./Gebru, Timnit/Major-McMillan, Angelina/Chmitchnell, Shmargaret (2021): *On the Dangers of Stochastic Parrots: Can Language Models Be Too Big?* In: *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency (FAcT '21)*. Association for Computing Machinery. New York, NY, 610-623. DOI: <https://doi.org/10.1145/3442188.3445922>.
- Buolamwini Joy/Gebru, Timnit (2018): *Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification*. In: *Conference on Fairness, Accountability and Transparency (New York, 2018)*, 77-9. Abrufbar unter: <http://proceedings.mlr.press/v81/buolamwini18a.html> [Stand: 08.07.2024].
- Campolo, Alexander/Crawford, Kate (2020): *Enchanted Determinism: Power without Responsibility in Artificial Intelligence*. In: *Engaging Science, Technology, and Society*, Nr. 6 (2020), 1-19.
- Cockburn, Cynthia/Ormrod, Susan (1997): *Wie Geschlecht und Technologie in der sozialen Praxis ‚gemacht‘ werden*. In: *Dölling, Irene/Krais, Beate (Hrsg.): Ein alltägliches Spiel. Geschlechterkonstruktionen in der sozialen Praxis*. Frankfurt am Main: Suhrkamp, 17-47.
- Crawford, Kate (2021): *Atlas of AI*. New Haven and London: Yale University Press.
- Crawford, Kate (2013): *The Hidden Bias in Big Data*. *Harvard Business Review*. Abrufbar unter: <https://hbr.org/2013/04/the-hidden-biases-in-big-data> [Stand: 08.07.2024].
- Dander, Valentin (2014): *Von der ‚Macht der Daten‘ zur ‚Gemachtheit von Daten‘. Praktische Datenkritik als Gegenstand der Medienpädagogik*. In: *Mediale Kontrolle unter Beobachtung*, Ausgabe 3.1, 1-21. Abrufbar unter: <https://mediarep.org>.

- org/server/api/core/bitstreams/f222597f-b6e0-4106-bd23-479c151296d8/content [Stand: 08.07.2024].
- Davis, Angela Y. (2000): *Masked Racism: Reflections on the Prison Industrial Complex; and Introduction: Race, Prison and Politics in Australia.*
- Drahl, Carmen (2023): AI was asked to create images of Black African docs treating white kids. How'd it go? Abrufbar unter: www.npr.org/sections/goatsandsoda/2023/10/06/1201840678/ai-was-asked-to-create-images-of-black-african-docs-treating-white-kids-howd-it- [Stand: 08.07.2024].
- Fry, Hannah (2019): *Hello world: Was Algorithmen können und wie sie unser Leben verändern.* München: C.H. Beck.
- Goodlad, Lauren M. E. (2023): Editor's Introduction: Humanities in the Loop. In: *Critical AI*, Jg. 1, Nr. 1-2, ohne Seiten.
- Günther, Elisabeth (2022): *Topic Modeling. Algorithmische Themenkonzepte in Gegenstand und Methodik der Kommunikationswissenschaft.* Köln: Herbert von Halem Verlag.
- Haraway, Donna (2017 [1995]): *Situiertes Wissen. Die Wissenschaftsfrage im Feminismus und das Privileg einer partialen Perspektive.* In: Bauer, Susanne/Heinemann, Torsten/Lemke, Thomas (Hrsg.): *Science and Technology Studies. Klassische Positionen und aktuelle Perspektiven.* Berlin: Suhrkamp, 369-403.
- Harding, Sandra (2011): *The Postcolonial Science and Technology Studies Reader.* Durham: Duke University Press.
- Hicks, Mar (2017): *Programmed Inequality. How Britain Discarded Women Technologists and Lost Its Edge in Computing.* Cambridge and London: MIT Press.
- Houben, Daniel/Prietl, Bianca (Hrsg.) (2018): *Datengesellschaft. Einsichten in die Datafizierung des Sozialen.* Bielefeld: transcript.
- Muhammad, Khalil Gibran (2019): *The Condemnation of Blackness. Race, Crime, and the Making of Modern Urban America, With a New Preface.* Cambridge/London: Harvard University Press.
- Nellis, Ashley (2021): *The Coloring of Justice. Racial and Ethnic Disparity in State Prisons.* Report by The Sentencing Project. Research and Advocacy for Reform. Washington D.C. Abrufbar unter: www.sentencingproject.org/app/uploads/2022/08/The-Color-of-Justice-Racial-and-Ethnic-Disparity-in-State-Prisons.pdf [Stand: 24.08.2024].
- Prietl, Bianca (2023): *Das Geschlecht der Datafizierung: MachtWissen im digitalen Zeitalter.* In: *Journal Frauen- und Geschlechterforschung NRW*, 51, 67-72.
- ProPublica (2016): *Machine Bias. There's software used across the country to predict future criminals. And it's biased against blacks.* Abrufbar unter: www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing [Stand: 08.07.2024].

- Treviranius, Jutta (2019): The Value of Being Different. W4A '19: Proceedings of the 16th International Web for All Conference, May 2019, 1-7. DOI: <https://dl.acm.org/doi/10.1145/3315002.3332429>.
- Ugless, Eddie L./ Ross, Björn/Lauscher, Anne (2023): Stereotypes and Smut: The (Mis)representation of Non-cisgender Identities by Text-to-Image Models. In: Findings of the Association for Computational Linguistics: ACL 2023. Toronto, Canada, 7919-7942.
- Vipra, Jai/West, Sarah Myers (2023): Computational Power and AI. AI Now Institute. Abrufbar unter: <https://ainowinstitute.org/publication/policy/compute-and-ai#h-what-does-the-supply-chain-for-ai-hardware-look-like> [Stand: 08.07.2024].
- Wagner, Lukas (2024): Google verändert Suchmaschine: Wie wir bald mit KI googeln werden. Abrufbar unter: www.zdf.de/nachrichten/wirtschaft/unternehmen/ki-google-chatgpt-open-ai-suchmaschine-bing-100.html [Stand: 08.07.2024].
- West, Sarah Myers/Whittaker, Meredith/Crawford, Kate (2019): Discriminating Systems. Gender, Race, and Power in AI. AI Now Institut. Abrufbar unter: <https://ainowinstitute.org/publication/discriminating-systems-gender-race-and-power-in-ai-2> [Stand: 02.12.2024].
- Whittaker, Meredith/Alper, Meryl/Bennett, Cynthias L./Hendren, Sara/Kaziunas, Liz/Mills, Mara/Ringel Morris, Meredith/Rankin, Joy/Rogers, Emily/Salas, Marcel/West, Sarah Myers (2019): Disability, Bias, and AI. Abrufbar unter: <https://ainowinstitute.org/publication/disabilitybiasai-2019> [Stand: 08.07.2024].
- Whittaker, Meredith (2024): The AI fairytale. In: ZEIT Online. Abrufbar unter: www.zeit.de/digital/internet/2024-06/artificial-intelligence-meredith-whittaker-progress-surveillance-english/komplettansicht [Stand: 08.07.2024].
- Wright, Paul/Herivel, Tara (2002): Prison Nation: The Warehousing of Vermica's Poor. New York and London: Routledge.
- Zweig, Katharina (2019): Ein Algorithmus hat kein Taktgefühl. München: Heyne.

Lizenz

Der Artikel steht unter der Creative Commons Lizenz **CC BY-SA 4.0**. Der Name des Urhebers soll bei einer Weiterverwendung genannt werden. Wird das Material mit anderen Materialien zu etwas Neuem verbunden oder verschmolzen, sodass das ursprüngliche Material nicht mehr als solches erkennbar ist und die unterschiedlichen Materialien nicht mehr voneinander zu trennen sind, muss die bearbeitete Fassung bzw. das neue Werk unter derselben Lizenz wie das Original stehen. Details zur Lizenz: <https://creativecommons.org/licenses/by-sa/4.0/legalcode>.

Einzelbeiträge werden unter www.gmk-net.de/publikationen/artikel veröffentlicht.

Glossar

Abled bodied

Kann mit „leistungs- oder arbeitsfähig“ übersetzt werden. Able-bodied bezeichnet die gesellschaftlich privilegierte Position von Menschen, die keine Behinderung haben.

Agender

Mit dem Begriff bezeichnen sich Menschen, die kein Geschlecht haben, sich keinem Geschlecht zugehörig fühlen oder mit dem Konzept von Geschlecht nichts anfangen können.

Be_hindert

Der Unterstrich wird häufig im aktivistischen Bereich eingesetzt, um zu zeigen: Behindert ist man nicht – behindert wird man. Er soll zeigen, dass Behinderung durch äußere Umstände und Barrieren im Alltag produziert wird und nicht der Körper einer Person das Problem ist.

BIPoC/PoC

BIPOC steht für Black, Indigenous, People of Color (Schwarz, indigen, People of Color). Diese Abkürzung wird oftmals verwendet, um die Diskriminierungserfahrungen von Schwarzen Menschen als auch indigenen Gruppen besonders hervorzuheben.

Cis (gender)

„Cis“ ist das Gegenstück zu „trans“. „Cis“ wird benutzt, um auszudrücken, dass eine Person das Geschlecht hat, dem sie bei der Geburt aufgrund der Genitalien zugewiesen wurde und sich entsprechend identifiziert. Als Beispiel: Eine cis Frau ist eine Person, die bei der Geburt dem weiblichen Geschlecht zugewiesen wurde und sich auch als Frau identifiziert.

Cisnormativität

Cisnormativität ist ein Teil von Heteronormativität. Es wird davon ausgegangen, dass alle Menschen cisgeschlechtlich sind, womit trans Personen abgewertet und unsichtbar gemacht werden.

Endogeschlechtlich

Der Begriff „endogeschlechtlich“ oder „endo“ (griech. „éndon“: innen, innerhalb) beschreibt Menschen, die nicht inter* sind, das heißt, deren Kör-

per sich nach medizinischen Normen vermeintlich eindeutig als nur weiblich oder nur männlich einordnen lassen.

FLINTA/MINTA

FLINTA steht für Frauen, Lesben, inter, nicht-binäre, trans und agender Personen. Bei der Abkürzung MINTA wird das F und das L mit dem M für Mädchen getauscht, um gezielt ein jüngeres Publikum anzusprechen.

Fremdouting

Bezeichnet die (absichtliche oder unabsichtliche) unfreiwillige Offenlegung der sexuellen Orientierung oder Geschlechtsidentität einer Person durch eine dritte Person. Ein bekanntes Beispiel ist das Fremdouting der beiden Prominenten Hape Kerkeling und Alfred Biolek im Jahre 1991.

Gender

Der englische Begriff „gender“ bezeichnet das durch Gesellschaft und Kultur geprägte soziale Geschlecht in Abgrenzung zum biologischen Geschlecht. Gemeint sind damit Erwartungen, Rollen und Werte, die an das bei der Geburt zugewiesene Geschlecht geknüpft sind.

Heteronormativität

Der Begriff bezieht sich auf die Annahme, dass es grundsätzlich nur zwei Geschlechter (weiblich und männlich) gäbe, die sich gegenseitig sexuell begehren. Menschen, die nicht in die zweigeschlechtliche Ordnung passen, weil sie sich zum Beispiel als trans* identifizieren, werden als „anders“ wahrgenommen, weil sie von der Norm abweichen.

LGBTQIA*

Steht für Lesbian (Lesbisch), Gay (Schwul), Bisexual (Bisexuell), Transgender, Queer, Intersex (Intergeschlechtlich) und Asexual (Asexuell) und umfasst verschiedene sexuelle Orientierungen und geschlechtliche Identitäten.

Misgendern

Bedeutet, über eine Person mit falschen Pronomen oder falsch gegenderten Begriffen zu sprechen oder eine falsche Anrede zu verwenden, die nicht dem Geschlecht der Person entspricht. Das passiert zum Beispiel, wenn eine nichtbinäre Person mit „Frau“ angeredet wird. Personen können absichtlich oder unabsichtlich eine Person misgendern.

Nonbinär

Als nonbinär können sich Menschen bezeichnen, die nicht (oder nicht zu 100%) Mann oder Frau sind. Stattdessen ist ihr Geschlecht beispielsweise beides gleichzeitig, zwischen männlich und weiblich, oder weder männlich noch weiblich. Manche nichtbinäre Menschen verorten sich ganz außerhalb des binären Systems, manche haben gar kein Geschlecht (agender) oder haben eine Geschlechtsidentität, die sich immer wieder ändert (genderfluid).

Queer

Der Begriff wird zum einen als Überbegriff für Menschen verwendet, die nicht in die geschlechtliche und/oder sexuelle Norm (hetero) passen. Zudem wird der Begriff auch als Selbstbezeichnung von Menschen verwendet, um eine Offenheit für die sexuelle und geschlechtliche Vielfalt zu zeigen.

Schwarz/weiß

Schwarz ist eine Selbstbezeichnung, die Menschen mit afrikanischer, karibischer und afroamerikanischer Herkunft verwenden. Es wird großgeschrieben, weil es dabei nicht um die Hautpigmentierung geht, sondern um ein soziales und politisches Konstrukt. Auch beim Begriff *weiß* geht es nicht um die Hautfarbe, sondern um eine gesellschaftspolitische Norm und Machtposition. Deshalb wird dieser Begriff in (wissenschaftlichen) Text oft klein und kursiv geschrieben.

TINA*

TINA* steht für trans, inter, nichtbinär und agender und umfasst eine vielfältige Gruppe an Menschen, die nichtbinär cis geschlechtlich sind. TINA* grenzt sich dabei besonders von FLINTA* ab, welches cis Frauen beinhaltet.

Trans

Ein breiter Sammelbegriff für Menschen, die über die traditionellen Geschlechtsgrenzen hinausgehen und solche, dessen Identität nicht zu dem bei der Geburt zugeordneten Geschlecht passt.

Transmaskulin & trans Mann

Menschen, denen bei der Geburt nicht das männliche Geschlecht zugewiesen wurde, die aber männlich oder teilweise männlich sind, können sich als transmaskulin bezeichnen.

Ein Mann, dem bei der Geburt nicht das männliche Geschlecht zugewiesen wurde, ist ein trans Mann.

Quellen des Glossars

Queer-Lexikon (o.J.): Glossar. Abrufbar unter: <https://queer-lexikon.net/glossar/> [Stand: 24.07.2024].

Neue deutsche Medienmacher (o.J.): Glossar. Abrufbar unter: <https://glossar.neue-medienmacher.de/glossar/> [Stand: 24.07.2024].

An alle gedacht?! – GAmM-Broschüre zu Intersektionalität in der Medienpädagogik. Abrufbar unter: www.digitale-chancen.de/materialien/detail/an-alle-gedacht-gamm-broschuere-zu-intersektionalitaet-in-der-medienpaedagogik [Stand: 24.07.2024].

Pertsch, Sebastian (Hrsg.) (2023): Vielfalt. Das andere Wörterbuch. 100 Wörter – 100 Menschen – 100 Beiträge. Berlin: Dudenverlag.

Awareness Sankt Pauli (o.J.). Abrufbar unter: <https://awareness-stpauli.de/begriffs-erklarungen/> [Stand 28.08.2024].