

betterplace

LAB

ALGORITHMEN GESELLSCHAFT &

ZUR ZUKUNFT SOZIALER TEILHABE IN DEUTSCHLAND



Vodafone Institut
für Gesellschaft
und Kommunikation

EXECUTIVE SUMMARY

Neue technologische Möglichkeiten zum Wohle aller zu gestalten ist eine gesamtgesellschaftliche Aufgabe. In Deutschland ist das Bewusstsein dafür bei allen zentralen Akteuren geschärft: Politik, Wirtschaft, Zivilgesellschaft. Doch im Hinblick auf Algorithmen dreht sich der öffentliche Dialog bislang vor allem darum, mögliche Risiken einzugrenzen. Dieser starke Fokus auf die Gefahren durch Algorithmen ist stark durch die Beobachtung der Entwicklungen in den USA geprägt, wo ein Beispiel nach dem anderen aufzeigt, dass Algorithmen zu sozialer Ungleichheit und Diskriminierung beitragen können. Doch in Deutschland existieren viele dieser automatisierten Systeme noch nicht. Und wir können Entwicklungen aus anderen Ländern nicht einfach auf Deutschland übertragen.


Denn, so unsere These: Algorithmen treffen immer auf einen gesellschaftlichen Kontext. In dieser Analyse blicken wir deshalb auf die ganz spezifischen Herausforderungen hier vor Ort.

Mit Beispielen aus den Bereichen Bildung, Arbeit und staatliche Leistungen zeigen wir schlaglichtartig, dass die Risiken von Algorithmen oftmals bereits darin stecken, für welchen Zweck ein datenbasiertes System entwickelt und eingesetzt wird: Die Kontrolle von Mitarbeiter*innen, die Automatisierung menschlicher Handlungen, die einseitige Allokation von Beratungsleistungen an gut vermittelbare Arbeitssuchende. Oft treibt der Wunsch nach Effizienz und Einsparung von Ressourcen die Entwicklung der Systeme voran. Und genau dieses Ziel ist fragwürdig, wenn Chancengerechtigkeit und gesellschaftliche Teilhabe von den algorithmischen Systemen berührt werden.

Die Beispiele zeigen andererseits aber auch, dass Algorithmen grundsätzlich einen Beitrag leisten könnten, um bestehende gesellschaftliche Herausforderungen anzugehen und zu überwinden: Die Begleitung von Studierenden aus unteren Einkommensschichten durchs Studium, die faire Bewertung der Arbeitsleistungen von Frauen, die individuelle Beratung von Arbeitssuchenden. Selten kann dies mittels eines einzigen technischen Systems erreicht werden, und oft braucht es orchestrierte Anstrengungen und substanzielle Ressourcen. Doch Daten und Algorithmen können eine entscheidende Rolle darin spielen, diese Ziele zu erreichen.

Algorithmen können als Waffe oder als Werkzeug eingesetzt werden. Es gilt deshalb klare Grenzen für ihren Einsatz zu setzen. Gleichzeitig müssen wir aber auch ihr Potenzial als Werkzeug für Chancengerechtigkeit und gesellschaftliche Teilhabe nutzen. Dafür braucht es in Deutschland zunächst einmal vor allem einen konstruktiven und ausgeglichenen Dialog über Algorithmen. Dazu wollen wir mit dieser Studie einen Beitrag leisten.

ÜBER DIE AUTOREN



Isabel Schünemann geht seit über 10 Jahren der Frage auf den Grund, wie digitale Innovationen zum Gemeinwohl beitragen können. Zurzeit ist sie McCloy Fellow an der John F. Kennedy School of Governance der Harvard University und arbeitet an der Gestaltung der Governance von künstlicher Intelligenz. Dort ist sie unter anderem Mitglied im Emerging Technology Policy Network am renommierten Belfer Center for Science and International Affairs und Teil der Ethical Tech Group des Berkman Klein Center for Internet and Society.



Yannick Lebert ist Tech-Experte mit sozialwissenschaftlichem Hintergrund. Im betterplace lab forscht und schreibt er zu unterschiedlichen Themenfeldern an der Schnittstelle zwischen Digitalisierung und Gemeinwohl.

INHALTSVERZEICHNIS

Executive Summary	3
Über die Autoren	4
Einleitung	7
1. Von der „Macht der Algorithmen“	8
1.1 Die gesellschaftliche Einbettung von Algorithmen	9
1.1.1 Diskriminierung mittels Algorithmen	10
1.1.2 Unterschiede in den Systemen	11
1.1.3 Wie amerikanische Beispiele den deutschen Dialog steuern	12
1.2 Über die Forderung nach Transparenz	13
1.2.1 Besseres Design statt falscher Ziele	14
1.2.2 Kausalitäten verstehen und Herausforderungen angehen	15
2. Algorithmen und gesellschaftliche Teilhabe in Deutschland	16
2.1 In der Bildung	17
2.1.1 Soziale Mobilität als Herausforderung in der Bildung	17
2.1.2 Algorithmen in der Bildung	19
2.1.2.1 Lernende mit Bildungsinstitutionen zusammenbringen	19
2.1.2.2 Bildungserfolg vorhersagen	22
2.2 In der Arbeitswelt	24
2.2.1 Diskriminierung und Geringverdiener am Arbeitsmarkt	25
2.2.2 Algorithmen in der Arbeitswelt	26
2.2.2.1 Automatisierung der Personalauswahl	27
2.2.2.2 Datenbasierte Leistungsbewertung	28
2.2.3 Algorithmen für mehr Fairness in der Arbeitswelt	30
2.3 In staatlichen Leistungen	31
2.3.1 Abhängig von staatlicher Unterstützung	31
2.3.2 Unterstützung von Arbeitssuchenden	32
3. Zusammenfassung und Handlungsempfehlungen	33
Literatur	37
Impressum	42

EINLEITUNG

Der Einsatz von Algorithmen sorgt in den USA immer wieder für Schlagzeilen: Ein unschuldiger junger Mann in New York wird von der Polizei überwacht und immer wieder grundlos befragt, nachdem das System ihn als potenziellen Kriminellen identifiziert hat. Eine Frau wird gerade operiert, als sie ihre Krankenversicherung verliert, weil der Algorithmus vermutet, sie sei eine Betrügerin. Bei ihr zuhause häufen sich unbezahlte Krankenhausrechnungen. Ein Mann wird von jedem Supermarkt, bei dem er sich um einen Job bewirbt, abgelehnt. Per Gesichtserkennung wurde er im Video als psychisch krank identifiziert. Rassismus und systematische Benachteiligung schleichen sich immer wieder in die vermeintlich neutralen algorithmischen Systeme und gefährden soziale Gerechtigkeit und Teilhabe. Entscheidungen, die Algorithmen vorbereiten oder treffen, haben heute bereits reale Konsequenzen im Leben der Betroffenen.

In Deutschland werden die gesellschaftlichen Folgen des Einsatzes von Algorithmen in den USA eng verfolgt. Entsprechend ist der deutsche Diskurs um künstliche Intelligenz häufig angstbesetzt: Medien machen die Fälle öffentlich. Stiftungen und Thinktanks mobilisieren zur Kontrolle von Algorithmen. Die Politik arbeitet an der Gestaltung und Umsetzung von Ethikrichtlinien und Transparenzforderungen. Die Wirtschaft hat sich vorsorglich schon einmal ethischen Mindeststandards verschrieben. Und das alles lange bevor die Technologie hierzulande wirklich Verbreitung gefunden hat. Vorsorgen ist besser als heilen.

Doch stehen uns in Deutschland tatsächlich ähnliche Entwicklungen bevor? Sind die Szenarien, die wir in den USA beobachten, wirklich auf den deutschen Kontext übertragbar? Welche Risiken ergeben sich aus derzeitigen Anwendungsbeispielen von Algorithmen für gesellschaftliche Teilhabe in Deutschland? Und welche Chancen ergeben sich womöglich, wenn wir die Technologie anders einsetzen?

Das vorliegende Papier geht einen ersten Schritt in der Beantwortung dieser Fragen. Es beginnt mit einer kritischen Reflexion, wie amerikanische

Entwicklungen den deutschen Dialog um Algorithmen beeinflussen und legt die Bedeutung der sozialen und geschichtlichen Einbettung von Algorithmen und künstlicher Intelligenz dar. Weiter stellt es infrage, ob die derzeitigen Anwendungsszenarien von Algorithmen, die uns besagte Negativschlagzeilen bringen, in Deutschland in ähnlicher Form erwartbar sind und zeigt auf, dass die Forderung nach Transparenz und Kontrolle dazu beitragen kann, diese Anwendungsszenarien gar zu akzeptieren.

Anschließend werden Potenziale und Herausforderungen algorithmischer Systeme für gesellschaftliche Teilhabe in Deutschland in drei Bereichen diskutiert: Bildung, Arbeit und staatliche Leistungen. Insbesondere wird der Frage nachgegangen, welche Risiken sich aus den derzeitigen Anwendungsszenarien von Algorithmen in den jeweiligen Feldern ergeben und welche alternativen Ansätze Chancen für die Förderung gesellschaftlicher Teilhabe bergen. Die abschließenden Handlungsempfehlungen richten sich vor allem an Entscheidungsträger*innen im öffentlichen Sektor. Sie zeigen erste wichtige Schritte auf, wie der Dialog um die Entwicklung von algorithmischen Systemen chancenorientiert gestaltet werden kann.

Szenarien, wie wir sie in den USA beobachten, sind in Deutschland keinesfalls unausweichlich. Während die Eindämmung von Risiken ein entscheidender Baustein in der Begleitung des zunehmenden Einsatzes von Algorithmen ist, müssen auch die Chancen in den neuen technischen Möglichkeiten gesucht und aktiv gestaltet werden. Algorithmen können Chancengerechtigkeit und gesellschaftliche Teilhabe gefährden, aber sie können auch eingesetzt werden, um bestehende Herausforderungen anzugehen und zu meistern. Statt Algorithmen für Diskriminierung und Benachteiligung verantwortlich zu machen, brauchen wir dafür die offene Anerkennung bestehender Missstände in unserem Land und den Mut, uns diesen mit neuen Lösungen anzunehmen. Das vorliegende Papier bemüht sich darin, einige dieser Möglichkeiten aufzuzeigen.

1. VON DER „MACHT DER ALGORITHMEN“

In Deutschland wird zunehmend ein öffentlicher Diskurs über die sozialen und gesellschaftlichen Folgen des Einsatzes von Algorithmen und künstlicher Intelligenz geführt. Das Stichwort „Ethik der künstlichen Intelligenz“ vereint Stiftungen, Thinktanks und die Politik, die sich diesem Feld verschreiben.¹ Deutsche Unternehmen verpflichteten sich jüngst den ethischen Grundsätzen der Entwicklung von Algorithmen und künstlicher Intelligenz.² Und auch öffentlich-medial wird zunehmend über die gesellschaftlichen Veränderungen durch den Einsatz von Algorithmen berichtet.³ Damit nehmen sich alle zentralen Akteure der gemeinsamen Gestaltungsaufgabe dieser nächsten Phase der technologischen Entwicklung an.⁴

Dabei fallen jedoch zwei Dinge auf: Zum einen ist der deutsche Dialog stark vom Blick über den Atlantik geprägt. In der Berichterstattung wie auch der Analyse der gesellschaftlichen Auswirkungen von Algorithmen wird meist auf US-amerikanische Beispiele verwiesen. Und es ist häufig der öffentliche Dialog in den USA, der steuert, wo der (potenzielle) Einsatz von Algorithmen in Deutschland kritisch beleuchtet wird. Dies liegt nicht zuletzt daran, dass datenbasierte Technologien und künstliche Intelligenz hierzulande bislang wenig Verbreitung finden. Doch stellt sich die Frage, inwiefern die beobachteten gesellschaftlichen Risiken algorithmischer Systeme in einem anderen Land auf die sozialen, rechtlichen und kulturellen Gegebenheiten in Deutschland übertragbar sind und welche spezifischen Chancen und Risiken sich darüber hinaus für Deutschland ergeben.

Zum anderen resultieren aus der Debatte über Algorithmen häufig Forderungen nach einem besseren Design sowie nach Transparenz und Kontrolle algorithmischer Systeme. Selten wird jedoch fundamentaler hinterfragt, wo und wie datenbasierte Technologien und Automatisierung überhaupt eingesetzt werden sollten. Ebenso wird kaum darüber gesprochen, wie die bestehenden gesellschaftlichen Herausforderungen,

die der Diskriminierung mittels Algorithmen zumeist vorausgehen, angegangen werden können. Der Diskurs läuft damit Gefahr, die technologische Entwicklung in dieser Form schlicht hinzunehmen.

1.1 Die gesellschaftliche Einbettung von Algorithmen

In kaum einem anderen demokratischen Land werden Algorithmen und künstliche Intelligenz so rapide entwickelt und eingesetzt wie in den USA. Vom Silicon Valley an der Westküste bis zu akademischen Einrichtungen in Neuengland lautet das Motto, neue Technologien möglichst zügig zu entwickeln und in die Anwendung zu bringen. So verfolgt Facebook bekanntermaßen das Ziel „Move fast and break things“, aber auch das bekannte MIT Media Lab des Massachusetts Institute of Technology arbeitet unter der Maxime „Deploy or Die“, anwenden oder sterben.⁵ In den letzten Jahren zeigten sich vermehrt die sozialen Folgen dieser Philosophie: Soziale Medien stehen immer wieder in der Kritik, Wahlmanipulation zu ermöglichen, Desinformationen zu verbreiten und Gewalt zu entfachen. Algorithmen in Gerichtsentscheidungen und der Polizeiarbeit verstetigen bestehende soziale Ungerechtigkeiten und Rassismus.⁶ Und die Automatisierung der Personalauswahl führte zu einer Fortsetzung der Diskriminierung von Frauen, Minderheiten und psychisch Kranken.⁷ Dies entfachte in den USA einen kritischen öffentlichen Dialog über den Einsatz von Algorithmen in sozialen Kontexten, der insbesondere von Thinktanks, Stiftungen, Aktivist*innen und Wissenschaftler*innen geführt wird.

Elemente dieses Diskurses finden sich auch in Deutschland wieder. Insbesondere rücken die Beispiele aus den USA hierzulande häufig die Ängste und Risiken um den Einsatz von Algorithmen in den Fokus: Immer wieder titeln Tages- und Wochenzeitungen, dass Algorithmen längst über unser Leben bestimmten und den Menschen versklavt hätten⁸, und auch Stiftungen und Thinktanks schreiben regelmäßig

1 Beispielsweise die Bertelsmann Stiftung, vgl. Müller-Eiselt & Hustedt (2019); die Stiftung Neue Verantwortung, vgl. Beining & Wohlfarth (2016); die politischen Stiftungen wie die KAS, vgl. Fetzer (2019); oder die Böckler Stiftung, vgl. Schmidt (2019); bis hin zur Gründung neuer Organisationen in diesem Bereich, wie AlgorithmWatch, vgl. Spielkamp (2019); oder das iRights Lab, vgl. iRights.Lab (2019). Die Bundesregierung greift das Thema in der KI-Strategie auf, vgl. Bundesregierung (2018); sowie in der Strategie zum autonomen Fahren, vgl. Bundesministerium für Verkehr und digitale Infrastruktur (2015); und hat mehrere Gremien, die sich mit Themen und Fragestellungen aus dem Feld beschäftigen, so die Enquete-Kommission des Bundestags, vgl. Deutscher Bundestag (2019); die Datenethikkommission des Innenministeriums, vgl. Datenethikkommission (2019); oder der Digitalrat der Kanzlerin, vgl. Merkel (2019). Die EU-Kommission hat eigens eine Kommission zur Entwicklung ethischer Richtlinien für KI eingesetzt, vgl. Europäische Kommission (2019)

2 vgl. Köver (2019)

3 Vor dem Hintergrund, dass die Mehrheit der EU-Bürger mit der Funktionsweise von Algorithmen nicht vertraut ist, kann dies nur als begrüßenswert gewertet werden, vgl. Bleiker (2019)

4 vgl. Brynjolfsson & McAfee (2014); vgl. Schwab (2015); vgl. Harari (2017); vgl. Minevich (2019)

5 vgl. Duvergne Smith (2014), wobei das Motto seither weiterentwickelt wurde und heute nur noch „deploy“ lautet

6 vgl. Corbett-Davies et al. (2016)

7 vgl. Vincent (2018)

8 vgl. Schlick (2019); vgl. Demling (2019); vgl. Bialek (2019); vgl. Sander (2019); vgl. Wieduwilt (2019); vgl. Kolmar & Binswanger (2019); vgl. FAZ (2018)



vom Kampf zur Kontrolle der Algorithmen.⁹ Allein unter dem Stichwort „die Macht der Algorithmen“ finden sich auf Google fast 20.000 Treffer, darunter Dokumentationen einschlägiger öffentlich-rechtlicher Medien, Zeitungsberichte und eine Vielzahl von öffentlichen Veranstaltungen und Publikationen der Zivilgesellschaft.

Der Blick über die nationalen Grenzen hinaus, insbesondere über den Atlantik, ist einerseits nachvollziehbar, denn in Deutschland gibt es bislang kaum Beispiele der Automatisierung menschlicher Entscheidungen an gesellschaftlich so zentralen Stellen, wie dies in den USA der Fall ist.¹⁰ Andererseits stellt sich die Frage, inwiefern amerikanische Beispiele und der dortige Diskurs auf den deutschen Kontext übertragbar sind. Denn bislang wird die gesellschaftliche Einbettung datenbasierter Systeme oftmals kaum berücksichtigt.

1.1.1 Diskriminierung mittels Algorithmen

Die Diskriminierung mittels Algorithmen stellt einen zentralen Teil des öffentlichen Dialogs um den Einsatz automatisierter Systeme dar. Immer wieder wird festgestellt, dass die Technologie nicht neutral ist, sondern menschliche Vorurteile und Diskriminierung in Algorithmen vielfach automatisiert und verstetigt werden. Das liegt daran, dass Algorithmen nicht die Zukunft repräsentieren, sondern die Vergangenheit.¹¹ Die Daten, auf denen sie beruhen, spiegeln historische Gegebenheiten und Entscheidungen wider und damit die gesellschaftlichen Zustände, in denen sie erhoben wurden.¹² Ihre geschichtliche und soziokulturelle Einbettung ist daher von besonderer Bedeutung.

⁹ So beginnt das Buch „Wir und die intelligenten Maschinen“ mit der Geschichte des New Yorker Bürgermeisters, der den Kampf um die Kontrolle der Algorithmen gewonnen hat, vgl. Dräger & Müller-Eiselt (2019); oder vgl. Krüger (2018)

¹⁰ Und wenn es sie doch gibt, werden sie zumeist als vorbildliche Beispiele genannt, vgl. z.B. Dräger; Müller-Eiselt (2019); außer der Schufa, vgl. Schnuck; Zierer (2018)

¹¹ vgl. Green (2019)

¹² Hardt (2014); Um das zu illustrieren, haben Wissenschaftler des MIT Media Labs 2018 einen Psychopathen-Bot für die Bilderkennung entwickelt: Trainiert wurde dieser mit Daten der bekanntermaßen häufig düsteren Plattform Reddit. Dort, wo ein normaler Bot beim Rorschachtest Vögel auf einem Ast erkennt, sieht der Psychopathen-Bot einen Mann, der auf dem elektrischen Stuhl hingerichtet wird, vgl. Norman AI (2019)

Dies gilt zwar insbesondere für maschinell trainierte Systeme, die auf großen Sätzen historischer Daten aufbauen und daraus selbständig Schlüsse ziehen.¹³ Menschliche Vorurteile und Benachteiligungen stecken hier häufig tief in den komplexen Strukturen der Daten. Auch wenn Faktoren wie Geschlecht oder ethnische Zugehörigkeit in algorithmischen Modellen nicht berücksichtigt werden, lassen andere Datenpunkte oft Rückschlüsse auf diese zu. Eine einfache Neutralisierung des Datensatzes ist daher oft kaum möglich. Aber auch regelbasierte Algorithmen, in denen die Abläufe und Schlussfolgerungen gänzlich vom Menschen festgesetzt werden, können in ihrer Gestaltung gesellschaftliche Zustände widerspiegeln. Im vorliegenden Papier sprechen wir daher allgemein von „Algorithmen“. Inhaltlich sind besonders jene Modelle relevant für Chancengerechtigkeit und Teilhabe, die menschliches Verhalten vorherzusagen versuchen und Entscheidungen automatisieren, die den weiteren Lebensweg der Menschen, um die es geht, beeinflussen.

Häufig schleichen sich Benachteiligungen und Diskriminierung in diese Systeme. Doch Aussagen wie „Algorithmen diskriminieren“, wie sie vielfach im öffentlichen Diskurs aufkommen, sind irreführend. Die Ursache der Diskriminierung liegt schließlich nie im Algorithmus, sondern immer beim Menschen, wie in den folgenden Beispielen deutlich wird. Selbstverständlich darf nicht hingegenommen werden, bestehende gesellschaftliche Diskriminierung in technischen Systemen zu verstetigen. Doch Algorithmen für Diskriminierung verantwortlich zu machen, lenkt den Fokus von einem gesellschaftlichen Problem auf einen technischen Fehler. Algorithmen sollten daher niemals ohne die gesellschaftlichen Zustände, in denen sie entwickelt und eingesetzt wurden, betrachtet werden.

1.1.2 Unterschiede in den Systemen

Wenn in Deutschland auf Beispiele aus den USA verwiesen wird, bleibt die Betrachtung der spezifischen sozialen und kulturellen Umstände in Deutschland oft aus. Dabei machen allein die rechtlichen und systemischen Unterschiede eine Übertragung einzelner Beispiele auf den deutschen Kontext schwer vorstellbar.¹⁴

Ein Beispiel sind sogenannte Risikoscores im amerikanischen Justizsystem: In einigen amerikanischen Staaten werden Algorithmen eingesetzt, um über die mögliche Untersuchungshaft von Angeklagten sowie die Höhe der Kaution für ihre vorübergehende Freilassung zu entscheiden. Auf Basis der persönlichen Daten der Angeklagten und möglicher Vorstrafen berechnet ein Computersystem einen Risikoscore. Dieser ist oft entscheidend dafür, ob Angeklagte die Wartezeit auf das Strafverfahren auf freiem Fuß oder hinter Gittern verbringen werden. Der Risikoscore kann auch die Höhe der Kaution beeinflussen. Da das Rechts-, Polizei- und Justizsystem der USA allerdings an vielen Stellen von der systematischen Diskriminierung von Minderheiten durchzogen ist, spiegelt sich diese auch in der vermeintlich neutralen Risikoberechnung wider: So wird Afroamerikaner*innen per se ein höheres Risiko zugeschrieben, erneut straffällig zu werden, als weißen Amerikaner*innen.¹⁵

Immer wieder taucht dieses Beispiel im deutschen Diskurs über die Risiken von Algorithmen und die Notwendigkeit von Kontrolle und Transparenz auf. Und doch ist dieser Fall kaum mit Deutschland vergleichbar: In den USA hat jeder dritte Bürger einen so genannten „criminal record“, ist also vorbestraft oder wurde zumindest schon einmal festgenommen.¹⁶ Dies entspricht in etwa der Zahl der Amerikaner*innen mit einem Hochschulabschluss. Das kommt auch daher, dass in den USA einfaches Fehlverhalten, wie Ruhestörungen oder das Fahren ohne Sicherheitsgurt, 80 % der verfolgten Kriminalfälle ausmachen.¹⁷ Damit stellen Fälle, die wir als Ordnungswidrigkeiten verstehen, die Mehrheit der Kautionsverfahren. Algorithmen helfen in den USA also in erster Linie dabei, die schiere Masse der Verfahren zu bewältigen. Eine Motivation, die so in Deutschland gar nicht vorliegt. Hier nämlich darf eine Untersuchungshaft für Straftatsvermutungen, die keine Haftstrafe nach sich ziehen, laut Strafprozessordnung gar nicht erst verhängt werden.¹⁸ Selbstverständlich dienen Risikoscores in den USA als Beispiel für mögliche soziale Folgen des Einsatzes von Algorithmen und Automatisierung. Doch lässt sich von dem Einsatz der Technologie in einem Land nicht auf

¹³ Eine gute Einführung in die Frage „Was ist Machine Learning?“ bietet folgender Artikel: vgl. Hao (2018)

¹⁴ Selbst et al. beschreiben, dass selbst die Übertragung bestimmter technischer Systeme innerhalb eines Rechts- bzw. Gesellschaftssystems herausfordernd sein kann, insbesondere wenn Diskriminierungsfreiheit und Fairness ein Teil der algorithmischen Modellierung sind, vgl. Selbst et al. (2018)

¹⁵ Der Faktor Hautfarbe musste dafür gar nicht im System berücksichtigt werden, da ausreichend andere demografische Daten, wie die Adresse, stellvertretend für die Hautfarbe stehen, vgl. Angwin & Larson (2016). Neue Studien zeigen im Übrigen, dass die Empfehlungen der Algorithmen durch Richter ungleich Anwendung finden: Zeigt das System einen niedrigen Risikowert für Afroamerikaner*innen, ist die Wahrscheinlichkeit deutlich höher, als bei weißen Angeklagten, dass der oder die Richter*innen dennoch eine Untersuchungshaft und höhere Kaution ansetzt, vgl. Albright (2019)

¹⁶ vgl. Fields & Emshwiller (2014)

¹⁷ vgl. Smith (2019)

¹⁸ Wobei bekanntermaßen Ausnahmen die Regel bestätigen

mögliche Konsequenzen in einem anderen Land schließen, ohne das gesellschaftliche System, das die Technologie umgibt, einzubeziehen.

1.1.3 Wie amerikanische Beispiele den deutschen Dialog steuern

Häufig geht es gar nicht darum, ob Beispiele aus den USA auch hierzulande Einzug halten werden. Vielmehr steuern amerikanische Beispiele den Fokus des öffentlichen Dialogs in Deutschland. Das zeigt das Beispiel des sogenannten „Predictive Policing“, des Einsatzes vorausschauender Algorithmen zur Steuerung der Polizeiarbeit: In den USA werden in vielen Gemeinden orts- wie auch personenbezogene Kriminalitätsvorhersagen gemacht.¹⁹ Ziel ist dabei eine akkurate Vorhersage, wo Straftaten auftreten werden, um die Polizei bereits präventiv dort (ortsbezogen) einzusetzen. Darüber hinaus werden im Rahmen von „Predictive Policing“ die Wahrscheinlichkeiten berechnet, mit denen bestimmte Personen in Zukunft kriminell werden, um daraus Schlussfolgerungen für den (personenbezogenen) Umgang mit diesen und ihre polizeiliche Beobachtung zu ziehen.

In den besonders segregierten Städten der USA zeigt die Polizei allerdings besonders in jenen Vierteln eine hohe Präsenz, wo Afroamerikaner*innen und jene mit lateinamerikanischen Wurzeln wohnen.²⁰ Diese werden dort anlasslos kontrolliert, und wo viel kontrolliert wird, werden auch Vergehen gefunden. Dabei handelt es sich häufig um den Besitz geringer Mengen an Drogen, wie Marihuana, oder um Ordnungswidrigkeiten. Minderheiten sind in der amerikanischen Kriminalitätsstatistik daher überproportional vertreten.²¹ Diese Statistik wiederum wurde nun für die Entwicklung von Algorithmen für „Predictive Policing“ genutzt. Es verwundert also kaum, dass der Einsatz der Technologie die Diskriminierung der Polizei fortführt und verstetigt.²²

Dabei ist die historische Einbettung von Diskriminierung in der Kriminalitätsstatistik wichtig, um den derzeitigen öffentlichen Aufschrei gegen „Predictive Policing“ in den USA zu verstehen: Denn der Verfassungszusatz, der Sklaverei und Menschenhandel in der Mitte des 19. Jahrhunderts offiziell beenden sollte, enthält noch heute den Nebensatz, dass Sklaverei zwar verboten sei, „außer

als Bestrafung für eine Straftat“. Das so genannte „Convict Leasing“, der Verleih von Strafgefangenen an Plantagenbesitzer, bestand noch lange nach dem formalen Ende der Sklaverei. Und die amerikanische Kriminalitätsstatistik entstand in ihrem Ursprung im 19. Jahrhundert in Teilen aus der direkten Motivation, nun datenbasiert und damit vermeintlich neutral nachzuweisen, dass Afroamerikaner*innen inhärent krimineller sind als weiße Amerikaner*innen. Der 11. Zensus 1830 erfasste daher erstmals die Kriminalitätsgeschichte aller befragten Bürger*innen, mit dem Ergebnis, dass Afroamerikaner*innen überproportional häufig straffällig geworden waren. Das war kaum verwunderlich, denn die ehemaligen Sklav*innen lebten damals unter den so genannten „Black Codes“. Diese Gesetze gewährten ihnen einerseits erstmals gewisse Rechte, wie privaten Besitz, aber schafften andererseits auch bestimmte Straftaten nur für Afroamerikaner*innen, beispielsweise Respektlosigkeit gegenüber Weißen.

In den darauffolgenden Jahren wurde dieser vermeintlich objektive Nachweis der erhöhten Kriminalität von Afroamerikaner*innen in der Statistik immer wieder politisch inszeniert. Und auf die Segregation von weißen und schwarzen Amerikaner*innen, die bis 1965 bestand, folgten bekanntlich die so genannten Jim-Crow-Gesetze, und der anschließende Ausbau der Strafverfolgung von Afroamerikaner*innen durch das Polizei- und Justizsystem, die schließlich zu den historischen Haftzahlen von heute führten: Eine*r von drei Afroamerikaner*innen wird heute einen Teil seines Lebens im Gefängnis verbringen.²³ Die Automatisierung der Polizeiarbeit wird heute daher als eine direkte Fortführung der Diskriminierung von Afroamerikaner*innen betrachtet, die bis zur Sklaverei zurückreicht. Wissenschaftler*innen wie auch Aktivist*innen stellen diesen Bezug immer wieder her und weisen darauf hin, wie algorithmische Systeme moderne Formen der Versklavung von Afroamerikaner*innen zu verstetigen drohen.²⁴

Betrachtet man also den historischen und gesellschaftlichen Kontext von „Predictive Policing“ in den USA, muss auffallen, dass die Polizeiarbeit und polizeiliche Diskriminierung dort kaum mit Deutschland vergleichbar sind. Und dennoch führte nicht zuletzt der öffentliche Aufschrei der Wissenschaft und Zivilgesellschaft gegen „Predictive Policing“ in den USA dazu, dass

19 vgl. Perry et al. (2013)

20 vgl. Williams & Eamadjomeh (2018)

21 vgl. Smith (2019)

22 vgl. Richardson et al. (2019)

23 vgl. Mauer (2011)

24 vgl. Noble et al. (2018); vgl. Muhammad (2011)



auch in Deutschland der Einsatz von Algorithmen in der Polizeiarbeit kritisch betrachtet wurde. Die Ausgangslage der lokalen Polizeiarbeit wurde bei diesen Untersuchungen häufig allerdings gar nicht erst in Betracht gezogen. Auch wurde dabei festgestellt, dass „das neue Konzept in der Bundesrepublik nicht mehr als ein halb aufgeblasener Testballon“ ist, „kein Potenzial dafür“ besteht und insgesamt „hierzulande sowohl auf Softwareanbieter- als auch auf Behördenseite ein erfreulich reflektiertes Vorgehen bei der Einführung von PP-Systemen zu konstatieren“ ist.²⁵ Und dennoch wird anhand teilweise dramatischer Beispiele aus den USA konstatiert, dass „nicht ausgeschlossen werden kann, dass auch die deutsche Polizei [...] in Zukunft“ so arbeiten wird. Allerdings fehlt eine kritische Darlegung dieser Aussage anhand der tatsächlichen Arbeit der Polizei in Deutschland

und der Kriminalfälle, mit denen sich diese vornehmlich beschäftigt.²⁶ So wird den Sicherheitsbehörden in diesem Zusammenhang mangelnder Auskunftswille und Transparenz vorgehalten.²⁷

Selbstverständlich können die Entwicklungen in anderen Ländern auf potenzielle Risiken in Deutschland hinweisen. Auch kann eine frühzeitige Identifizierung solcher Risiken die Entwicklungen in Deutschland entscheidend lenken. Doch müssen dabei die Unterschiede der Systeme und insbesondere die spezifische Ausgangslage in Deutschland noch stärker berücksichtigt werden, als dies bislang der Fall ist. Selten wird zu Anfang kritisch hinterfragt, wie realistisch und wahrscheinlich bestimmte Szenarien in Deutschland überhaupt sind, nicht nur technisch, sondern insbesondere gesellschaftlich, und auf welchen

25 vgl. Winter (2019); vgl. Knobloch (2018); vgl. Diehl & Kartheuser (2018)

26 So wird in einer gemeinsamen Veröffentlichung der Bertelsmann Stiftung und Stiftung Neue Verantwortung ein Fall des personenbezogenen „Predictive Policing“ als mögliches Szenario für Deutschland genannt, ohne jedoch einen umfangreichen Vergleich der Polizeiarbeit in Deutschland und den USA zu machen. Insbesondere fehlt die Analyse der Straftaten, welche die deutsche Polizei maßgeblich verfolgt, im Vergleich zu den USA. So ist beispielsweise die Mordrate in den USA, bezogen auf die Bevölkerungszahl, um das 22-Fache höher als in Deutschland, vgl. Wendt (2019); vgl. Washington Post (2019). Auch die Rate des tödlichen Schusswaffengebrauchs der US-amerikanischen Polizei liegt beim 13-Fachen der deutschen Polizei, vgl. Centers for Disease Control and Prevention (2019); Statista Research Department (2019). Es ist deshalb bereits im Ansatz fragwürdig, ob personenbezogenes predictive policing in Deutschland überhaupt Ähnlichkeit mit jenem in den USA hätte und welche spezifisch deutschen Herausforderungen bestehen würden, vgl. Knobloch (2018)

27 Dabei ist eine gewisse Zurückhaltung in der öffentlichen Kommunikation über Kriminalitätsvorhersagen nachvollziehbar, da diese obsolet werden, wenn auch Verbrecher*innen vorhersehen können, wie die Polizei arbeitet. Im Übrigen erfolgt die Kontrolle der Polizei durch die Gerichtsbarkeit. Ob diese dem technologischen Wandel angemessen ist, wurde bislang allerdings weniger hinterfragt.

sozialen Kontext die Beispiele hierzulande treffen würden.²⁸ Darüber hinaus sollten die Entwicklungen in anderen Ländern nicht den Fokus des deutschen Dialogs bestimmen: Denn nur mit einem gezielten Blick für die hiesigen Besonderheiten können wir die wirklichen Chancen und Risiken erkennen, die sich für Deutschland in Zukunft ergeben werden.

1.2 Über die Forderung nach Transparenz

Als Konsequenz für die beobachteten Risiken von Algorithmen wird immer wieder die öffentliche Kontrolle von automatisierten Systemen gefordert: von Transparenz-Standards bis zum Algorithmen-TÜV. Doch auch hier bleibt die kritische Reflexion der gesellschaftlichen Zustände noch zu oft aus. Statt breiter zu hinterfragen, wie und wofür Technologie überhaupt eingesetzt wird, steht die technische und gestalterische Umsetzung von Algorithmen oft im Vordergrund, die wiederum transparent und kontrollierbar sein soll. Dabei läuft diese technologiegetriebene Debatte Gefahr, einen Diskurs über bestehende Diskriminierung und Ungerechtigkeiten zu verdecken und die Potenziale, diese mithilfe von Daten anzugehen, gänzlich zu verpassen.

1.2.1 Besseres Design statt falscher Ziele

Wenn es darum geht, wie mit den Risiken durch Algorithmen umzugehen ist, steht häufig die Gestaltung von Algorithmen im Vordergrund. Das zeigt sich unter anderem an der Suche nach einem Schuldigen: Immer wieder wird festgehalten, dass Algorithmen immer vom Menschen gemacht sind und schlechte Daten oder schlechte Algorithmen für die beobachtbaren sozialen Konsequenzen ihres Einsatzes verantwortlich sind. Solche Versuche, die darauf abzielen, schlechte Daten, schlechte Algorithmen oder etwa unbewusste Vorurteile von Programmierer*innen zu identifizieren, verdecken den Bedarf, systematische Diskriminierung und soziale Ungerechtigkeiten in der Gesellschaft anzugehen:²⁹ „By narrowly framing the risks and benefits of artificial intelligence

in terms of bias and accuracy, we've overlooked more fundamental questions about how the introduction of automation, profiling software, and predictive models connect to outcomes that benefit society.”³⁰

Auch zeigt sich, dass Ethikrichtlinien für Algorithmen und künstliche Intelligenz oft jenen ähneln, die wir aus der Geschäftswelt kennen. So steht auch bei der Frage nach gutem unternehmerischen Handeln das „wie“ im Mittelpunkt – und nicht das „ob“ oder „wozu“. Risiken entstehen in dieser Logik durch eine fehlerhafte Umsetzung, nicht durch die grundsätzliche Handlung selbst. Die unternehmerische Tätigkeit wird nicht per se infrage gestellt, sondern es wird lediglich auf den Einhaltung bestimmter Standards gepocht. Ähnlich wird auch in Ethikrichtlinien für Algorithmen der Einsatz der Technologie gewissermaßen als moralischer Imperativ betrachtet, deren fehlerhafte Umsetzung verbessert werden muss. Die Möglichkeit, Technologien aufgrund ihrer Risiken an bestimmten Stellen womöglich komplett zu bannen – oder zumindest für andere Zwecke einzusetzen –, wird hingegen selten in Betracht gezogen. Als Konsequenz scheint „better building“ der einzige Weg für die Zukunft zu sein.³¹

Die Ziele und Zwecke der Automatisierung grundsätzlicher infrage zu stellen, steht daher im Zentrum der blinden Flecken in der Entwicklung von Algorithmen.³² Zu selten wird hinterfragt, wo eine Automatisierung durch Algorithmen überhaupt zur Erreichung der Ziele beiträgt. So wird ihr Einsatz zwar häufig mit dem Potenzial begründet, Prozesse zu verbessern und Ressourcen zu sparen. Doch zeigt sich beispielsweise im „Predictive Policing“, dass der qualitative Zugewinn durch den Einsatz der Technologie im besten Fall marginal ist.³³ Und obschon die Automatisierung menschlicher Entscheidungen womöglich zu Effizienzgewinnen führt, liegen die großen Hebel zur Steigerung der Effizienz zumeist noch in der Verbesserung und Automatisierung aufwendiger Verwaltungsprozesse.

28 Vergleiche mit anderen Ländern werden deutlich seltener für Regulierungsforderungen herangezogen. So wird das Scoring-System in China zwar immer wieder mahnend als Dystopie des technologischen Fortschritts genannt, doch halten sich die Forderungen nach präventiver Regulierung vor dem Hintergrund dieser Möglichkeit bislang in Grenzen

29 vgl. Hoffmann (2018)

30 Ito (2018)

31 vgl. Greene et al. (2019)

32 vgl. Calderon et al. (2019)

33 Für die USA vgl. Hvistendahl (2016) und für Deutschland vgl. Knobloch (2018)

1.2.2 Kausalitäten verstehen und Herausforderungen angehen

Die Ziele zu hinterfragen, die hinter der Entwicklung und dem Einsatz von algorithmischen Systemen liegen, sollte deshalb als Kern des Diskurses um die Ethik von Algorithmen gelten. Diskriminierung oder Gerechtigkeit sind eben keine Kategorien von Technologie, sondern von Gesellschaft: „Fairness and justice are properties of social and legal systems like employment and criminal justice, not properties of the technical tools within. To treat fairness and justice as terms that have meaningful application to technology separate from a social context is therefore to make a category error, or as we posit here, an abstraction error.“³⁴

Während Effizienzgewinne häufig an anderen Stellen von Arbeitsprozessen mit geringeren Risiken erreicht werden können, sollte mit Blick auf die Automatisierung von Entscheidungen, die Menschen betreffen, daher die Frage im Zentrum stehen, wo technische Lösungen überhaupt angebracht und möglich sind.³⁵ Welche Herausforderung soll Technologie überhaupt lösen? Auf welches gesellschaftliche Umfeld würde ein Algorithmus treffen? Rechtfertigt die oft nur marginale Wirksamkeit die möglichen Risiken eines automatisierten Systems? Wo könnten womöglich Ressourcen effektiv freigesetzt werden, ohne diese Risiken einzugehen? Und wie können größere Datenmengen und Algorithmen dabei helfen, bestehende gesellschaftliche Herausforderungen besser zu verstehen oder diese gar anzugehen, statt menschliche Entscheidungen einfach zu automatisieren?³⁶

34 vgl. Selbst et al. (2018)

35 vgl. ebd.

36 vgl. Ito (2018)



2. ALGORITHMEN UND GESELLSCHAFTLICHE TEILHABE IN DEUTSCHLAND

In Deutschland werden Algorithmen bislang nur spärlich für Vorhersagen menschlichen Verhaltens und die Automatisierung menschlicher Entscheidungen eingesetzt. Der bekannteste Fall ist wohl der Schufa-Score, der immer wieder kontrovers diskutiert wird. Denn er ist mittlerweile von entscheidender Bedeutung für Miet- und Kreditverträge, doch ist häufig unklar, wie er zustande kommt. Untersuchungen zeigen immer wieder, dass auch Menschen mit exzellenter Kreditwürdigkeit einen schlechten Schufa-Score haben können.³⁷ Im Justizwesen, der Bildung und vielen anderen Bereichen, die für gesellschaftliche Teilhabe relevant sind, werden datenbasierte Systeme in Deutschland allerdings noch kaum eingesetzt.

Doch Diskriminierung mittels Algorithmen entsteht dort, wo bereits ohne die Technologie Benachteiligungen bestimmter Gruppen existieren. Der folgende Abschnitt findet seinen Ausgangspunkt daher in bereits bestehenden gesellschaftlichen Herausforderungen für Teilhabe und Chancengerechtigkeit und betrachtet die Schnittstellen zum Einsatz von Algorithmen. Konkret werden in den Bereichen Bildung, Arbeit und staatliche Leistungen anhand von Beispielen die Mechanismen des bisherigen Einsatzes von Algorithmen sowie deren Potenziale und Risiken erläutert. Anschließend werden mögliche Chancen aufgezeigt, die sich in den jeweiligen Feldern bei einem alternativen Einsatz von Algorithmen ergeben.

2.1 In der Bildung

Kaum etwas ist so entscheidend für gesellschaftliche Teilhabe wie Bildung. Sie ist nicht nur im klassischen Sinne zentral für die volle Teilhabe eines oder einer Bürger*in an der Gesellschaft. Denn von der formalen Bildung hängen vor allem auch Berufs- und Einkommenschancen ab. Doch obwohl Bildung in Deutschland staatlich kostenfrei bereitgestellt wird und das staatliche Bildungssystem an vielen Stellen durchlässig ist, zählt chancengerechte Bildung zu den größten sozialen Herausforderungen in Deutschland.

Weltweit ist zu beobachten, dass Algorithmen immer weiter ins Lehren und Lernen eindringen. Doch welche Risiken stecken im Einsatz von künstlicher Intelligenz in der Bildung in Deutschland? Und welche Möglichkeiten ergeben sich für mehr Chancengerechtigkeit? Im Folgenden erläutern wir die Ausgangslage der Herausforderung chancengerechter Bildung in Deutschland und stellen anschließend zwei Beispiele von Algorithmen in der Bildung vor: die Zuteilung von Schulplätzen und die Vorhersage von Bildungserfolg. Für beide Beispiele diskutieren wir die Risiken und Chancen der Verwendung von Daten für die jeweilige Zielsetzung.

2.1.1 Soziale Mobilität als Herausforderung in der Bildung

Eine der größten Herausforderungen des deutschen Bildungssystems ist die Verbesserung der Chancengerechtigkeit. Deutschland steht in der sozialen Mobilität in den untersten Rängen der OECD-Länder, noch hinter den USA, trotz der dortigen hohen privaten Kosten für Bildung.³⁸ Von 100 Kindern aus Nichtakademikerfamilien beginnen in Deutschland nur 21 ein Studium, von denen wiederum acht am Ende einen Masterabschluss erlangen. Statistisch wird eines promovieren. Von 100 Kindern, deren Eltern über einen Hochschulabschluss verfügen, graduieren 45 mit einem Masterabschluss, von denen wiederum zehn erfolgreich promovieren.³⁹

Betrachtet man nicht das Bildungsniveau, sondern das Einkommen der Eltern, ist die Diskrepanz noch eklatanter:⁴⁰ So hat sich der Anteil der Studierenden aus Familien der oberen Einkommensschicht von 1982 bis 2006 mehr als verdoppelt. Im gleichen Zeitraum ging der Anteil Studierender aus der unteren Einkommenshälfte der Gesellschaft von 23 % auf 13 % zurück.⁴¹ Inwieweit sich dieser Trend seither fortgesetzt hat, ist schwer nachvollziehbar, da die Erfassung des sozioökonomischen Hintergrunds anhand des elterlichen Einkommens mit der Sozialerhebung des Deutschen Studentenwerks 2007 eingestellt wurde.⁴² Mittelbar kann die Beobachtung,

37 vgl. Schnuck & Zierer (2018)

38 OECD (2018a): Häufig wird angeführt, dass das deutsche Bildungssystem aufgrund seiner spezifischen Eigenschaften (insbesondere der Berufsausbildung, die es in vielen anderen Ländern so nicht gibt), nur schwer international vergleichbar ist. Die OECD bemisst soziale Mobilität jedoch vornehmlich anhand des sozioökonomischen Status eines jungen Menschen im Vergleich zu den Eltern und relativ zu Gleichaltrigen. Bildungsabschlüsse sind in diesem Modell daher nur mittelbar relevant. Vielmehr geht es darum, mit welcher Wahrscheinlichkeit es ein Kind aus der unteren Schicht in Zukunft in eine höhere Schicht schafft

39 vgl. Krempkow (2017)

40 vgl. El-Mafaalani (2016)

41 vgl. BMBF (2007)

42 Stattdessen wird nur noch der Bildungshintergrund der Eltern erfasst. Obwohl dieser auch bedeutsam ist, zeigte die Sozialerhebung vor der Umstellung, dass es so gut wie kein Kind aus der untersten Gesellschaftsschicht zum Studium schaffte, hingegen jedoch fast alle Kinder der obersten Schicht. Mögliche Verzerrungen liegen darin, dass das Kind eines Meisters mit einem eigenen Unternehmen in der neuen Statistik ein „Arbeiterkind“ ist, während ein Kind einer arbeitslosen, aber studierten Alleinerziehenden als „Akademikerkind“ gezählt wird. Der höchste Bildungsabschluss ist daher nicht bedingungslos aussagekräftig über den sozioökonomischen Hintergrund eines Kindes. So zählten sich beispielsweise im Jahr 2008 8 % der Deutschen mit höchstens einem Realschulabschluss zur Oberschicht, vgl. Weick (2011)



dass bei stetig steigenden Studierendenzahlen die Zahl der BAföG-Empfänger*innen zurückgeht, zumindest ein Hinweis darauf sein, dass der Anteil Studierender aus den untersten Einkommensschichten weiterhin sinkt.⁴³ Damit ist kein anderer Faktor in Deutschland so aussagekräftig über den Bildungserfolg eines Kindes wie dessen soziale Herkunft.

Die Herkunft schlägt sich in vielen Aspekten des Bildungswegs nieder: von der Wahl und Qualität der Schule über die Unterstützung der Eltern beim Lernen und die Verfügbarkeit außerschulischer Nachhilfe bis zur Frage, ob das Kind Abitur macht und anschließend ein Studium aufnimmt und abschließt. Auch entscheidet die soziale Herkunft oft über den Wohnort und damit, auf welche Grundschule ein Kind geht. Dies gilt insbesondere in Großstädten, in denen eine zunehmende Segregation zu

beobachten ist und wo arme Kinder mehrheitlich leben.⁴⁴ Schon die Grundschule kann richtungsweisend für den Bildungserfolg sein, denn bereits in der Grundschule wird fast ein Drittel der Unterschiede in der Lesefähigkeit von Schülern einzig über die konkrete Schule erklärt, auf die ein Kind geht.⁴⁵ In der neunten Klasse liegen Jugendliche aus benachteiligten Milieus in ihrer Lesekompetenz schließlich zwei volle Jahre hinter jenen aus privilegierten Familien zurück.⁴⁶

Darüber hinaus verlassen Kinder aus bildungsfernen Familien und unteren Schichten die Schule oder Hochschule überproportional häufig ohne Abschluss. Auch hier hat Deutschland in den letzten Jahren keine nennenswerten Fortschritte gemacht. Im Gegenteil: Seit 2012 ist eine steigende Anzahl an Schulabbrecher*innen zu verzeichnen.⁴⁷ In Berlin stieg deren Anzahl im Jahr 2019

43 vgl. Selbst et al. (2018): Die Gesamtzahl der BAföG-Empfänger*innen sinkt nicht zuletzt durch die lange Zeit nicht angepasste Einkommensgrenze. Damit fallen also jedes Jahr Studierende aus der unteren Mittelschicht aus der Förderung. Der Anteil derjenigen Studierenden, die eine Vollförderung erhalten, ist anteilig an der Gesamtzahl der BAföG-Empfänger*innen allerdings trotz der sinkenden Gesamtzahl nicht nennenswert gestiegen, vgl. Bundesregierung (2017); vgl. Statistisches Bundesamt (2019)

44 vgl. Helbig; Jähnen (2018)

45 vgl. Chzhen et al. (2018)

46 vgl. Hollenbach-Biele (2017)

47 vgl. Heublein; Schmelzer (2018)

im Vergleich zu den Vorjahren gar um 40 %.⁴⁸ Dabei sind schlechte Leistungen einer der stärksten und stabilsten Marker für einen Schulabbruch.⁴⁹ Die Zahl derer, die ein Studium abbrechen, liegt aktuell bei rund einem Drittel der Studierenden.⁵⁰ Dieser Wert ist seit Jahren konstant. Obschon sich aus der Statistik nicht ergibt, wer von ihnen anschließend ein Studium in einem anderen Fach erfolgreich abschließt, zeigen Befragungen, dass fast drei Viertel der Studienabrecher*innen die Hochschule (erst einmal) verlassen.⁵¹ Sie beginnen in der Folge eine Berufsausbildung oder sind anderweitig erwerbstätig. Wie auch in der Schule sind mangelnde Leistungen der Studierenden der häufigste Grund für den Studienabbruch.⁵² An zweiter Stelle steht die Unzufriedenheit mit der Wahl des Studiengangs.

2.1.2 Algorithmen in der Bildung

Die ersten und vermutlich immer noch am weitesten verbreiteten Algorithmen in der Bildung wurden nicht etwa entwickelt, um den Lernerfolg von Schüler*innen oder Studierenden zu verbessern, sondern um die Einnahmen von Hochschulen zu maximieren.⁵³ Viele Hochschulen in den USA decken ihre gesamten Kosten durch Studiengebühren. Ihr Ziel ist es daher, diejenigen unter den qualifizierten Bewerber*innen auszuwählen, die die hohen Studiengebühren tragen können. Und sie haben oft die Daten der Zulassungsverfahren der letzten Jahre, um diese zu identifizieren. Mithilfe von Algorithmen wurden nun qualifizierte Bewerber*innen zum Studium zugelassen, die die Studiengebühren in voller Höhe tragen oder mit dem Erlass eines geringen Teils der Studiengebühren die restlichen Kosten übernehmen konnten. Die begrenzten finanziellen Ressourcen, die der Hochschule für den Erlass von Gebühren beziehungsweise Stipendien zur Verfügung stehen, wurden damit zunehmend so eingesetzt, dass die Einnahmen maximiert wurden. Das kann bedeuten, dass mehrere qualifizierte Bewerber*innen einen geringen Gebührenerlass bekommen, statt einem oder einer höchst talentierten Bewerber*in aus der unteren Einkommensschicht die Gebühren komplett zu erlassen.

Dass dieser Einsatz von Algorithmen ein Bildungssystem nicht fairer macht, ist eindeutig. Doch für das weitestgehend gebührenfreie deutsche Bildungssystem sind diese Vorhersagesysteme kaum relevant. Aber es gibt auch andere Beispiele des Einsatzes automatisierter Systeme: So werden Schüler*innen und Studierende zum einen immer häufiger mithilfe von Algorithmen Bildungsinstitutionen zugewiesen. Zum anderen werden Risikovorhersagen entwickelt, die frühzeitig eine Gefährdung des Lernerfolgs in Schule und Studium erkennen sollen. Welche Chancen und Risiken bergen diese zwei Beispiele vor dem Hintergrund der skizzierten Herausforderungen für chancengerechte Bildung in Deutschland?

2.1.2.1 Lernende mit Bildungsinstitutionen zusammenbringen

Die Wahl der richtigen Schule oder des passenden Studiengangs ist immer eine Herausforderung für Schüler*innen, Eltern und Studierende. Aber auch Schulämter und Hochschulverwaltungen hält die Frage der Passung von Schüler*innen und Studierenden auf Trab. Und tatsächlich kann die Qualität der Grundschule den Bildungserfolg eines Kindes substanziell beeinflussen, und fast die Hälfte der Studienabrecher*innen gibt an, den Leistungsanforderungen in ihrem Fach nicht gewachsen zu sein oder sich zu wenig mit diesem zu identifizieren.⁵⁴ Entsprechend wichtig ist die Passung von Lernenden und Bildungsangeboten.

Um ein solches Passungsverhältnis herzustellen, werden immer häufiger Algorithmen eingesetzt. Zum einen soll dies die Arbeit der Schulämter erleichtern, die häufig Tausende von Kindern unter Berücksichtigung einer Vielzahl von Kriterien an die staatlichen Schulen der Region verteilen müssen. Aber auch die individuelle Passung von Studieninteressierten und Hochschulen übernehmen zunehmend Algorithmen.

48 vgl. Berliner Morgenpost (2019)

49 vgl. Gaupp et al. (2011)

50 vgl. Heublein & Schmelzer (2018)

51 vgl. FAZ (2017)

52 vgl. Heublein et al. (2017)

53 vgl. McGrath (2014)

54 vgl. Heublein & Schmelzer (2018)

In New York unterstützen Algorithmen bereits seit 2004 die Stadtverwaltung bei der Verteilung von High-School-Plätzen. Die Herausforderung: 75.000 Schüler*innen und Schüler müssen auf 426 Schulen verteilt werden. Vor dem Einsatz des Systems endeten jedes Jahr Tausende von ihnen an einer Schule, die sie zuvor nicht als eine ihrer Wunschschulen angegeben hatten. Spieltheorie-Expert*innen von Eliteuniversitäten unterstützten bei der Entwicklung des Algorithmus. Einem von ihnen, Professor Alvin E. Roth von der Stanford University, brachte dieser 2012 gar einen Nobelpreis ein. Der neue Algorithmus basiert einzig auf der Wahl der Schüler*innen und optimiert die Zuweisung nach ihren Präferenzen für alle: Besser als jeder Mensch kann er das komplexe Unterfangen lösen, alle Präferenzen der Schüler*innen zu berücksichtigen und dabei eine volle Auslastung der Schulen herzustellen. Die Hälfte von ihnen landet nun an der Schule ihrer Wahl, ein weiteres Drittel an der Schule, die ihre zweite oder dritte Präferenz war. Die Zahl derer, die schlussendlich auf keine Schule ihrer Wahl gehen, fiel von 31.000 im Jahr 2003 auf circa 3.000.⁵⁵

Aus Deutschland ist ein ähnlicher Fall bekannt. So hat der Berliner Stadtbezirk Tempelhof-Schöneberg im Jahr 2017 erstmals mithilfe eines Algorithmus die Zuweisung von Kindern zu Grundschulen unternommen, die bis dato händisch in komplexen Excel-Tabellen vollzogen werden musste.⁵⁶ Wie auch in New York geht es dabei nicht um die individuelle Passung eines Kindes zu einer Schule. Der Algorithmus unterstützt stattdessen dabei, die unterschiedlichen Kriterien, die die Ämter in ihre Entscheidungen einbeziehen, besser zu berücksichtigen. Insbesondere darf der Schulweg keines Kindes länger als zwei Kilometer sein, während alle Schulen ihre Kapazitäten voll ausschöpfen müssen. Außerdem soll die soziale Zusammensetzung der Schülerschaft verbessert werden. Das verwendete System hilft dem Schulamt vor allem dabei, die Auswirkungen unterschiedlicher Gestaltungsmöglichkeiten der Einzugsgebiete zu verstehen.

Wie wirkt sich die Verschiebung eines Straßenzugs auf die Auslastung und Zusammensetzung der Schulen aus? Und wie sähen, statistisch gesehen, ideale Einzugsgebiete aus? Mithilfe dieser Unterstützung gestaltet das Schulamt schließlich Schuleinzugsgebiete, die eine höhere Auslastung der Schulen sowie eine bessere soziale Durchmischung erwirken können, aber für Eltern noch nachvollziehbar sind.⁵⁷

Das New Yorker Beispiel zeigt eindringlich, wie wichtig diese soziale Durchmischung in der Grundschule für den weiteren Bildungsweg ist. Denn während die Wahrscheinlichkeit, an die weiterführende Schule der Wahl zu kommen, für jene Schüler*innen von schlechteren Schulen und aus benachteiligten Milieus gar etwas höher ist als für diejenigen aus gutem Elternhaus und von guten Grundschulen, gehen jene aus benachteiligten Schichten immer noch häufiger auf schlechte High Schools. Dies liegt vor allem daran, dass jene von „low-performing“ Mittelschulen eben auch schlechtere High Schools als ihre erste Präferenz angeben. Ein Phänomen, dass wir auch aus Deutschland kennen, obschon das deutsche System anders funktioniert: Kinder aus niedrigeren Schichten bekommen bei gleichen Leistungen seltener eine Gymnasialempfehlung, und jene, die sie bekommen, folgen der Empfehlung seltener als Oberschichtkinder.⁵⁸ Diese gehen gar häufiger aufs Gymnasium, als Lehrer*innen ihnen diesen Pfad empfehlen.

Die „bessere soziale Durchmischung“ der Berliner Grundschulen hat allerdings einen Haken. Denn eine Brennpunktschule wird nicht anhand der Qualität der Schule oder der Unterstützung, die Schüler*innen dort erfahren, definiert, sondern einzig anhand des Anteils der Kinder aus armen Verhältnissen an der Schülerschaft: Sobald mindestens acht von zehn Kindern aus armen Verhältnissen stammen, bekommen Schulen per se das Stigma „Brennpunktschule“, ganz gleich wie gut oder schlecht die Unterrichtsqualität ist. Werden diese Kinder nun durch einen Algorithmus anderen Grundschulen zugewiesen, bekommen sie dort also nicht notwendigerweise besseren Unterricht oder eine umfangreichere Unterstützung, die für ihren Bildungserfolg entscheidend wäre.

55 vgl. Tullis (2014)

56 vgl. Anders (2016)

57 vgl. von Büнау (2018)

58 vgl. El-Mafaalani (2016)



Das Ziel einer besseren sozialen Durchmischung könnte nach der aktuellen Definition einer Brennpunktschule gar dazu führen, dass mithilfe von Algorithmen nun Brennpunktschulen abgeschafft werden können, und das ganz ohne dass Kinder aus bildungsfernen und armen Schichten bessere Unterstützung erfahren.

Was heißt das nun für den Einsatz von Algorithmen in der Zuweisung von Schulplätzen? Wie in beiden Beispielen deutlich gemacht, können Algorithmen dabei unterstützen, die Komplexität der Schulzuweisung zu senken. So können mehr Schüler*innen ihre Wunschschule besuchen beziehungsweise kann eine Vielzahl von Kriterien einfacher und schneller berücksichtigt werden. Doch solange die Wahl der Schule einzig von individuellen Präferenzen oder der Empfehlung von Lehrer*innen abhängt, bleiben soziale Ungleichheiten bestehen. Und auch die erhöhte soziale Durchmischung der Grundschulen in Berlin hat seine Grenzen. Zum einen, da eine Grundschule nah am Wohnort des Kindes gelegen sein muss und sich die Qualität der Schulen vornehmlich anhand der Stadtteile entscheidet,⁵⁹ zum

anderen, weil bekannt ist, dass Kinder aus bildungsfernen und armen Verhältnissen eine andere Unterstützung im Lernen brauchen und unklar ist, wo sie diese eigentlich bekommen. Die oben besprochenen Formen von Algorithmen können daher vor allem dabei helfen, Komplexität zu reduzieren und den Mangel besser zu verwalten. Soziale Ungleichheiten bleiben aber bestehen.

Zu beachten ist, dass weder in Berlin noch in New York personenbezogene Daten, die sich auf die individuellen Schüler*innen beziehen, genutzt werden. Doch könnten gerade diese Daten dabei helfen, bestehende Benachteiligungen im System zu verstehen: Welche Schüler*innen haben auf welchen Schulen den größten Erfolg und warum? Was haben diese Schulen oder diese Kinder gemeinsam? Verändert sich der langfristige Bildungserfolg jener armen Kinder, die nun auf „bessere“ Schulen gehen? Was geschieht mit denen, die nach alten Einzugsgebieten auf andere Schulen gegangen wären und jetzt vielleicht auf eine Brennpunktschule gehen?

⁵⁹ So lehren an Berliner Brennpunktschulen überproportional viele Quereinsteiger*innen und weniger gelernte Pädagog*innen als an anderen Schulen, vgl. Vieth-Entus (2019)



Welche Muster lassen sich im Bildungserfolg eines Landes-
schulsystems erkennen? Wie können die Kausalitäten da-
hinter noch besser erforscht und wirksame Interventionen
gestaltet werden?

Dafür müssten allerdings nicht nur, und daran hapert es
im deutschen Bildungssystem, mehr Daten erfasst werden.
Sondern es muss auch ein politischer Wille bestehen,
die Qualität der Schulen anhand des Lernfortschritts
der Schüler*innen zu bemessen und nicht anhand ihres
sozioökonomischen Hintergrunds.

2.1.2.2 Bildungserfolg vorhersagen

Beim vorangegangenen Beispiel ging es vor allem um
Institutionen: Auf welche Schule geht eine Schülerin oder
spätere Studentin? Im folgenden Beispiel geht es um die
Individuen: Wie stehen die Chancen eines Einzelnen,
bestimmte Meilensteine im Bildungsweg zu erklimmen,
also die 8. Klasse erfolgreich zu überstehen oder ein
Hochschulstudium abzuschließen?

An immer mehr Bildungseinrichtungen weltweit
werden datenbasierte Systeme eingesetzt, um solche
Vorhersagen zu machen. Ziel ist es, die Gefährdung
des Schul- und Studienerfolgs frühzeitig zu erkennen

und jenen Lernenden zielgerichtet Unterstützungs-
angebote zu unterbreiten. Selbstverständlich zählen
akademische Leistungen und Testergebnisse zum Kern
solcher Vorhersagen, doch darüber hinaus werden oft
eine Vielzahl demografischer Faktoren und Indikatoren
berücksichtigt, von Geschlecht und Adresse über die
Anzahl der Verspätungen, Fehltage und Schulverweise
bis hin zum sozioökonomischen Status der Familie oder
beispielsweise der Frage, ob ein oder eine Schüler*in
neu an einer Schule ist. Komplexe Algorithmen lösen
hierbei oft die traditionelle Beobachtung und Bewertung
von Schüler*innen durch Lehrer*innen ab, die in
Deutschland vornehmlich anhand von Noten erfolgt.
Denn Noten alleine reichen oft nicht aus, um die
Gefährdung des Bildungserfolgs frühzeitig zu erkennen:
So zeigte etwa eine Studie mit 200.000 amerikanischen
High-School-Schüler*innen, dass das hier angewendete
Vorhersagesystem bei Schüler*innen und Schülern
aus unteren Einkommensschichten mit guten Noten in
Mathematik und Naturwissenschaften das Risiko eines
Schulabbruchs strukturell unterschätzt.

Gute Noten überdecken häufig andere Herausforderungen, beispielsweise im privaten Umfeld. Diese Beobachtung spricht also grundsätzlich für die weitere Untersuchung und die Entwicklung besserer Vorhersage- und Unterstützungswerkzeuge.

Die Georgia State University (GSU) wendet ein solches System bereits an.⁶⁰ Die Universität ist für ihre diverse Studierendenschaft bekannt und dafür, dass jene aus unteren Einkommensschichten, Nichtakademikerkinder und „students of color“ hier überdurchschnittlich erfolgreich sind. Dies liegt nicht zuletzt an den Bemühungen, die die Hochschule unternimmt, um diese zu unterstützen. Mit dem Ziel einer individuellen Unterstützung identifiziert das System bereits bei der Zulassung zum Studium jene Studierenden, die beim Studienstart und im weiteren Studienverlauf potenziell Schwierigkeiten erleben könnten. Dies passiert auf Basis von Testergebnissen, Noten und dem individuellen Hintergrund der Studierenden. Über 2,5 Millionen Datenpunkte von Studierenden der vorangegangenen zehn Jahre wurden analysiert, um zu verstehen, welche Faktoren einen Studienabbruch beeinflussen. Die Erkenntnisse der Untersuchung flossen zum einen in die Entwicklung des Algorithmus, zum anderen in die Weiterentwicklung der Unterstützungsstrukturen. Das System begleitet die Studierenden während des gesamten Studienverlaufs und schickt Benachrichtigungen an ihre jeweiligen Betreuer*innen, wenn die Noten ungenügend sind, sie im Curriculum hinterherhinken oder Kurse belegen, die ihren Studienverlauf gefährden könnten. Der Algorithmus steht dabei aber nicht allein: Gemeinsam mit dem System wurde die Studienberatung deutlich ausgebaut und neu aufgestellt. Alleine in einem Studienjahr kamen mithilfe der technischen und individuellen Unterstützung 43.000 Treffen zwischen Studierenden und ihren jeweiligen Betreuer*innen zustande. Und der Georgia State University gelingt, was vor ihr noch keine öffentliche Hochschule in den USA geschafft hat: die Kluft im Studienerfolg zwischen Studierenden aus wohlhabenden Akademikerfamilien und jenen aus unteren Einkommensschichten, Minderheiten und Studierenden der ersten Generation zu schließen.

Der Erfolg eines solchen Systems hängt offensichtlich nicht (nur) vom Algorithmus ab, sondern ebenso von den universitären Unterstützungsstrukturen und den finanziellen Ressourcen, die die Hochschule für diese zur Verfügung stellt. Denn Systeme, wie jenes an der Georgia State University, limitieren häufig die Zahl der Studierenden, die individuelle Unterstützung bekommen, um die verfügbaren Ressourcen zielgerichtet für jene einzusetzen, die sie am meisten benötigen.⁶¹ Doch bei unzureichenden Mitteln kann ein solches System Fragen der Fairness aufwerfen: Wenn bei 60.000 Studierenden 5 % Risikokandidat*innen individuelle Unterstützung bekommen, sind das gerade einmal 3.000 Studierende. Doch was passiert mit den Studierenden Nummer 3.001 und 3.002 auf der Risikoskala?

In Deutschland kommentiert man solche Algorithmen immer wieder damit, dass man keine deterministischen Vorhersagen für den Studienerfolg Einzelner wolle. Niemand sollte gesagt bekommen, dass seine oder ihre Chance, ein Studium erfolgreich zu absolvieren, beispielsweise nur bei 23 % läge.⁶² Doch Beispiele wie die Georgia State University zeigen, dass es darum gar nicht geht. Vielmehr können solche Systeme zum zielgerichteten Einsatz von Ressourcen und Förderinstrumenten führen und vor allem dazu, das Problem des Studienabbruchs proaktiv anzugehen.

Das Karlsruher Institute of Technology (KIT) zeigte 2018, dass deutsche Hochschulen grundsätzlich dazu in der Lage wären, solche Vorhersagesysteme zu entwickeln und einzusetzen.⁶³ Auf Basis der Noten und des Prüfungsverhaltens der ersten Semester kann der Algorithmus bereits nach dem ersten Semester mit einer Wahrscheinlichkeit von 85 % jene Studierenden identifizieren, deren Studienerfolg gefährdet ist. Nach dem dritten Semester sind es 95 %. Im Vergleich zu Algorithmen, die bereits Studienanwärter*innen einschätzen, ist das allerdings reichlich spät. Es markiert entsprechend nur mangelnde Leistungen als Risiko für den Studienabbruch und trägt daher nicht dazu bei, besser zu verstehen, warum manche Studierende den Anforderungen nicht gewachsen sind oder wie sie besser unterstützt werden können, bevor sich dies in den Leistungen niederschlägt. Im Gegensatz zum amerikanischen Beispiel kommt der Algorithmus jedoch ganz ohne persönliche Daten der Studierenden aus. Das KIT zeigt damit, dass es, wie auch bei der Georgia State

60 vgl. Ekowo & Palmer (2016)

61 vgl. Lakkaraju et al. (2015)

62 vgl. Wiarda (2018)

63 vgl. Kemper (2018)

University, am Ende nicht auf das technisch Mögliche ankommt, sondern auf das Gesamtziel der Hochschule und den Willen, sich dem Thema ganzheitlich anzunehmen.

Dass für die frühzeitige Unterstützung der Studierenden personenbezogene Daten gar nicht immer notwendig sind, zeigt ein anderes Beispiel der Georgia State University.⁶⁴ Da der Studienstart insbesondere für junge Menschen aus unteren Einkommensschichten und solche aus Nichtakademikerfamilien eine Herausforderung darstellt, werden Studienanwärter*innen seit einigen Jahren von einem automatisierten System darin unterstützt, den Weg ins Studium zu navigieren. „Pounce“, benannt nach dem Maskottchen der Universität, hilft ihnen dabei, alle administrativen und akademischen Aufgaben bis zum Studienbeginn zu erfüllen, sich also beispielsweise um finanzielle Unterstützung und Stipendien zu bewerben und sich erfolgreich zu immatrikulieren. Angehende Studierende werden dort abgeholt, wo sie im Prozess stehen. Sie erhalten individuelle Hinweise, Erinnerungen und Schritt-für-Schritt-Anleitungen und werden automatisch an Mitarbeiter*innen der Hochschule vermittelt, sollten dennoch Herausforderungen bestehen. Das System lernt dabei stets dazu: über die Studierenden und über die Hilfestellung, die es gibt. Der Einsatz führte dazu, dass die Studienanwärter*innen alle notwendigen Schritte zur Immatrikulation bis zum Studienstart nun zu 21 % häufiger erfolgreich abschließen.

Darüber hinaus erwirkte Pounce, dass die Hochschule nicht mehr nur reaktiv agiert, sondern proaktiv auf Studierende zugeht. Diese wiederum fühlen sich dadurch besser betreut. Aber auch die Studierenden starten mithilfe von Pounce proaktiver ins Studium. Sie stellen mehr Fragen und lösen Herausforderungen schneller, bevor sie zu großen Problemen werden. Nicht zuletzt schuf Pounce freie Ressourcen an der Hochschule, mit denen Einzelfälle und besondere Fragen nun individuell geklärt werden können.

Grundsätzlich wäre ein solches Unterstützungssystem auch in Deutschland denkbar. Insbesondere für Studierende der ersten Generation könnte die automatisierte Unterstützung beim Start ins Studium und darüber hinaus ein Zugewinn sein, der ihre deutlich höheren Abbruchquoten senken könnte. Sie könnte ihnen dabei helfen, die Komplexität des Hochschulalltags zu meistern. Pounce baut dabei nicht auf personenbezogene Daten, wie den sozioökonomischen Hintergrund der Studierenden, sondern einzig auf ihre Aktivitäten innerhalb des Verwaltungssystems der Hochschule. Diese werden allerdings nachverfolgt, und selbstverständlich müsste die vertrauensvolle Sicherung

und zeitnahe Löschung dieser Daten sichergestellt sein. Um Studierende dem nicht verpflichtend auszusetzen, können solche Systeme immer auch nur auf freiwilliger Basis eingesetzt werden.

Zum heutigen Zeitpunkt dürfte ein solches Szenario an vielen deutschen Hochschulen allerdings an der mangelnden digitalen Infrastruktur der Hochschulverwaltung scheitern. Digital unterstützen kann nur, wer die dahinterliegenden Prozesse auch digitalisiert hat. Doch in Deutschland stellen manche Universitäten gar noch Scheine aus Papier aus, die Studierende bis zum Ende des Studiums aufbewahren müssen. Darüber hinaus bräuchte es für wirksame Interventionen eine noch genauere Erforschung der Ursachen für Studienabbrüche. Denn akademische Leistungen sind oft nur ein Symptom für dahinterliegende Umstände. Worin unterscheiden sich also jene, die erfolgreich durchs Studium kommen und jene, die vorzeitig abbrechen? Warum haben es Nichtakademiker*innen an manchen Hochschulen schwerer als an anderen? Und wie können sie auf dem Weg zum Studium frühzeitig und wirksam begleitet werden?

Datenbasierte Vorhersagesysteme sind in der Bildung also keinesfalls in ihrer Gänze zu verteufeln. Stattdessen sollte mit Blick auf die Herausforderungen des deutschen Bildungssystems in Deutschland mutiger gefragt werden, wie wir Daten einsetzen können, um die digitale Zukunft der Bildung endlich chancengerechter zu gestalten.

2.2 In der Arbeitswelt

Im Gegensatz zur Bildung, wo algorithmische Systeme in Deutschland bislang kaum eingesetzt werden, finden diese in der Arbeitswelt bereits heute Verbreitung. Ob in der Personalauswahl und Bewertung von Arbeitsleistungen, in der Einteilung von Schichtarbeit oder der verteilten Arbeit auf Plattformen, immer häufiger werden Prozesse, an deren Ende Menschen in ihrem Job stehen, mithilfe von Algorithmen automatisiert. Auf welche Herausforderungen treffen diese neuen technologischen Möglichkeiten in Deutschland?

Der folgende Abschnitt findet seinen Ausgangspunkt in der bestehenden Benachteiligung und Diskriminierung bestimmter Gruppen am Arbeitsmarkt und dem wachsenden Niedriglohnsektor. Anschließend werden zwei Beispiele von Algorithmen in der Arbeitswelt, insbesondere der Personalarbeit, vorgestellt und diskutiert: die Automatisierung von Bewerbungsverfahren und Algorithmen in der Leistungsbewertung.

64 vgl. Page & Gehlbach (2018)



2.2.1 Diskriminierung und Geringverdiener*innen am Arbeitsmarkt

Die Herausforderungen auf dem deutschen Arbeitsmarkt sind vielseitig: Fachkräftemangel, regionale Strukturunterschiede, Langzeitarbeitslosigkeit. Doch wenn es um Fairness, Chancengerechtigkeit und soziale Teilhabe an der Schnittstelle zu Algorithmen geht, fällt in Deutschland der Fokus vor allem darauf, dass nicht alle Teilnehmer*innen auf dem Arbeitsmarkt gleich behandelt werden und dass eine stagnierende Anzahl von Arbeitnehmer*innen von der Grundsicherung abhängt.

Vom Einstellungsverfahren über die Höhe des Gehalts bis hin zu Karriereverläufen werden insbesondere Frauen und Menschen mit Migrationshintergrund immer noch häufig benachteiligt. Dies belegt eine Vielzahl von Studien. So zeigen Untersuchungen, dass Bewerber*innen mit ausländisch klingendem Namen seltener zum persönlichen Gespräch eingeladen werden als jene mit einem

deutschsprachigen Namen. Und nach einer Elternzeit werden, bei identischen Bewerbungsunterlagen, Frauen seltener als ihre männlichen Mitbewerber für ein Auswahlgespräch eingeladen. Umgekehrt kann Kinder kriegen die männliche Karriere gar belohnen.⁶⁵ Neben Einstellungsverfahren zeigt sich die Benachteiligung, insbesondere von Frauen, auch in der Leistungsbewertung. Dort beeinflussen unbewusste Vorurteile nachhaltig ihre Karriereverläufe.⁶⁶ Beispielsweise bewerten Männer wie auch Frauen die Leistungen von Frauen grundsätzlich schlechter als jene von Männern, individuell und in Teams.

Nicht zuletzt die unterbewussten Benachteiligungen von Frauen führen dazu, dass diese in der deutschen Führungsebene im internationalen Vergleich deutlich unterrepräsentiert sind.⁶⁷ Deutschland liegt hier unter dem Durchschnitt der OECD-Länder, in denen häufig bereits mehr Engagement für das Thema aufgebracht wurde, andere soziale Normen herrschen oder schlicht Quoten

65 vgl. Llewellyn Smith (2013); vgl. Fuegen et al. (2004); vgl. Correll et al. (2007)

66 vgl. Heilmann (2012); vgl. Martha (1996); vgl. Golden & Rouse (1997); vgl. Heilmann & Haynes (2005); vgl. Hipp (2018)

67 vgl. Abel-Koch (2019);



eingeführt wurden.⁶⁸ In Schweden beispielsweise sitzen doppelt so viele Frauen in Vorstandspositionen wie in Deutschland.

Jenseits der Benachteiligungen bestimmter Gruppen ist die Ausweitung des Niedriglohnsektors eine Herausforderung für gesellschaftliche Teilhabe in Deutschland. Im Osten des Landes arbeiteten im Jahr 2014 über 40 % der Beschäftigten für einen Lohn unterhalb der Niedriglohnschwelle. Im Westen waren es zuletzt 13 %, doch steigt dieser Wert seit Jahren.⁶⁹ Dies betrifft häufig Berufsgruppen wie Friseur*innen, aber auch Kraftfahrer*innen, Lagerarbeiter*innen, Beschäftigte in chemischen Reinigungen und Wäschereien und jene in der Hotelbranche. Geringverdiener*innen mangelt es allerdings zumeist nicht nur am Einkommen, sondern sie arbeiten oft auch unter schlechten Arbeitsbedingungen. Wie wir im Folgenden aufzeigen, unterliegen viele dieser Berufe heute einer steigenden Kontrolle durch Algorithmen.

⁶⁸ vgl. OECD Stat (2019)

⁶⁹ vgl. Bundesregierung (2016)

⁷⁰ vgl. Thomas (2013)

2.2.2 Algorithmen in der Arbeitswelt

Algorithmen in der Arbeitswelt beeinflussen die Chancengerechtigkeit auf dem Arbeitsmarkt und Teilhabe an der Gesellschaft. Und sie werden heute bereits eingesetzt, insbesondere in der Personalauswahl und im Personalmanagement. Von der automatisierten Personalsuche auf Karriereplattformen über die Analyse der Wechselwilligkeit von Arbeitnehmer*innen bis zu Videointerviews mit Gesichtserkennung kommen immer mehr Angebote auf den Markt, die Bewerbungsprozesse automatisieren. Und auch im Management von Arbeitnehmer*innen halten Algorithmen immer häufiger Einzug: von der Optimierung der Personalplanung bei Schichteinsätzen bis zur Leistungsbewertung.

Diskriminierung und Missbrauch sind jedoch auch hier nicht weit: So setzen Unternehmen in den USA Algorithmen ein, um zu verhindern, sich an der sozialen Absicherung ihrer Mitarbeiter*innen zu beteiligen.⁷⁰ Denn das müssen sie erst dann, wenn ihre Mitarbeiter*innen mehr als 29 Stunden pro Woche arbeiten. Was früher

ein komplexes rechnerisches Unterfangen war, wird heute mittels Algorithmus automatisiert durchgeführt: die Schichten aller Angestellten so koordinieren, dass einerseits alle Schichten abgedeckt sind und andererseits keiner der Mitarbeiter*innen über die Schwelle zur Sozialversicherungspflicht tritt.

Doch auch bei besten Absichten zeigt sich wieder einmal, dass sich Diskriminierung und Benachteiligung in algorithmische Systeme einschleichen können. Dies gilt insbesondere für die Automatisierung der Personalauswahl und die Leistungsbewertung von Mitarbeiter*innen.⁷¹

2.2.2.1 Automatisierung der Personalauswahl

Die Automatisierung der Personalauswahl ist ein beliebtes Beispiel für die Gefahren des Einsatzes von Algorithmen. Immer wieder zeigt sich, dass die Automatisierung der Auswahlprozesse auf Basis vergangener Auswahlverfahren bestehende Benachteiligungen und Formen von Diskriminierung übernimmt und damit verstetigt. So sorgte zuletzt Amazon für Aufsehen, als der Konzern publik machte, dass seine Recruiting-Algorithmen Frauen strukturell benachteiligen.⁷² Bereits im Jahr 2014 wurden Entwickler*innen bei Amazon damit beauftragt, ein System zu entwickeln, das die Unterlagen von Bewerber*innen scannt und vielversprechende Bewerber*innen identifiziert. Doch der Algorithmus lernte von den vergangenen Entscheidungen der Personaler*innen und sortierte Frauen häufiger aus als Männer. Zwar wurde auch hier das Geschlecht der Bewerber*innen nicht berücksichtigt, doch genügte das Wort ‚Frau‘ im Lebenslauf, beispielsweise wenn eine Bewerberin einen Verein für Frauen führte oder einen Abschluss von einer Hochschule hatte, an der nur Frauen studieren. Amazon verwarf das System, als es auf die systematische Benachteiligung aufmerksam wurde.

Die Automatisierung der Personalauswahl wurde in den USA nicht nur entwickelt, um Effizienzgewinne zu erzielen. Mit über 4.000 Hochschulen und einer Vielzahl außerhochschulischer Qualifizierungsangebote ist es dort schwieriger als in Deutschland, die Qualität eines Abschlusses oder eines Zertifikats einzuschätzen. Fähigkeiten und Fachwissen von Bewerber*innen sind daher nicht zwangsläufig an einen Abschluss gekoppelt. Die Automatisierung der Sichtung von Bewerbungen hilft daher auch dabei, sich von formalen Qualifizierungen zu lösen und auf Basis historischer Einstellungsverfahren Merkmale, die jenseits von Zertifikaten liegen, für möglichst erfolgreiche Bewerber*innen zu identifizieren.

Dies kann mit einem Algorithmus einfacher sein. Denn häufig wissen Unternehmen gar nicht so genau, woran sie gute zukünftige Mitarbeiter*innen identifizieren können. So versuchte Google vor einigen Jahren herauszufinden, welche Elemente seines umfangreichen Auswahlverfahrens die größte Aussagekraft darüber haben, wer später Leistungsträger*in im Unternehmen wird. Ebenso wollten sie wissen, welche Interviewer*innen besonders häufig Bewerber*innen auswählen, die später bei Google erfolgreich sind. Das Ergebnis war allerdings ernüchternd: Nur ein einziger leitender Angestellter stellte regelmäßig gute Bewerber*innen ein. Und dieser war der weltweit führende Experte in einem kleinen Feld der Mathematik und interviewte ausschließlich Bewerber*innen in diesem Feld. Darüber hinaus zeigte sich vor allem, dass weder die gefürchteten „Brain Teaser“ im Auswahlverfahren noch das Kriterium, einen Hochschulabschluss vorzuweisen, Einfluss auf den späteren Erfolg bei Google hatten. Daraufhin wurde das gesamte Auswahlverfahren des Internetriesen umgestellt, weitestgehend auf persönliche Interviews, in denen Bewerber*innen dazu angehalten sind, ihre Berufserfahrung zu reflektieren.

Den Rückschluss, den Google nach der umfangreichen Analyse des Auswahlprozesses zog, zeigt eine der grundsätzlichen Gefahren der Automatisierung der Personalauswahl auf. Denn es handelt sich bei statistischen Regressionen, wie sie zumeist für algorithmische Vorhersagen genutzt werden, immer um Korrelationen, nicht um Kausalitäten. Und bei der Automatisierung der Sichtung der Bewerbungsunterlagen werden nur Datenpunkte im Lebenslauf berücksichtigt. Bei ähnlichen Lebensläufen würde ein Algorithmus ähnliche Erfolgchancen für Bewerber*innen errechnen. Doch können zwei Bewerber*innen mit ähnlichen Stationen im Lebenslauf ganz unterschiedliche Erfahrungen gemacht haben und diese anders reflektieren. Eine Automatisierung kann also immer nur Kriterien berücksichtigen, die sich in den Daten widerspiegeln.

Daher stellt sich die Frage, ob eine Automatisierung der Verfahren wirklich eine zukunftsweisende Lösung ist. Bestehende Benachteiligungen und Diskriminierung bestimmter Gruppen, die oft weit über das Recruiting hinaus reichen, werden hierbei nicht adressiert. Spielen Leistungsbewertungen und Karriereverläufe innerhalb der Organisation auch eine Rolle bei der automatisierten Personalauswahl, schlägt sich die strukturelle Benachteiligung bestimmter Gruppen nun zusätzlich im

⁷¹ vgl. Vincent (2018)

⁷² vgl. Goodman (2018)

Bewerbungsverfahren nieder. Darüber hinaus ist heute klar, dass Diversität in Teams und Organisationen einen positiven Effekt auf den Erfolg der Organisation hat. Und die Automatisierung von Auswahlverfahren sorgt vor allem für eines: dass immer die Gleichen ausgewählt werden.

Eine große Menge an Bewerbungen zu bearbeiten steht für deutsche Unternehmen häufig auch gar nicht an oberster Stelle der zu bewältigenden Herausforderungen. Im Gegenteil: Viele berichten heute gar von einem Mangel an Bewerbungen und dem starken Wettbewerb um die besten Talente. Dass eine Automatisierung des Auswahlverfahrens die besten Talente identifiziert und an eine Organisation bindet, scheint erstmal ungewiss. Zum einen sind dies womöglich gerade jene Bewerber, die nicht ins Schema eines Algorithmus passen. Zum anderen sind es viel häufiger Faktoren wie Schnelligkeit und Ansprechbarkeit im Auswahlverfahren und der Aufbau einer persönlichen Bindung, eines „personal fit“, der vielfach umworbene Talente schließlich dazu bewegt, sich für eine Organisation zu entscheiden. Die Automatisierung von Verwaltungsprozessen ist nicht zuletzt daher oft der bessere Einsatz der Technologie: Er setzt bei den Mitarbeiter*innen im Personalwesen wichtige Ressourcen frei, die diese für die persönliche Begleitung der Bewerber*innen nutzen können.

Dem Problem der Benachteiligung und Diskriminierung in der Personalauswahl kommt man damit noch nicht bei. Doch gibt es technische Lösungen, die dabei unterstützen können, diesem entgegenzuwirken. So zeigen beispielsweise Studien, dass Frauen sich durch eine andere Begriffswahl in Stellenausschreibungen angesprochen fühlen als Männer. Und dass Ausschreibungen, insbesondere für Führungspositionen, mit den dort gewählten Schlagworten eben eher Männer als Frauen adressieren. Doch Algorithmen können heute Ausschreibungen auf ihre Sprache analysieren und Begriffe, die traditionell Männer ansprechen, durch neutrale Worte ersetzen.⁷³ Damit bewerben sich oft mehr Frauen auf ausgeschriebene Posten, als dies zuvor der Fall war. Das Beispiel zeigt aber auch, dass ein neutrales Auswahlverfahren allein nicht zwangsläufig dazu führt, dass das Problem der Benachteiligung bestimmter Gruppen behoben wird. Wie im Bildungsbereich bereits gezeigt wurde, müssen solche Ziele innerhalb der Organisation breit angegangen und mit Strukturen und Ressourcen unterlegt werden.

Selbst der neutralste Algorithmus kann eben nur unter denen auswählen, die sich überhaupt angesprochen fühlen und bewerben.

2.2.2.2 Datenbasierte Leistungsbewertung

Der zweite Fall von Algorithmen in der Arbeitswelt betrifft die Kontrolle und Bewertung der Arbeit von Angestellten. Einerseits wissen wir, dass sich in die Mitarbeiterbewertung häufig unterschwellige Diskriminierung und Benachteiligungen einschleichen. Andererseits, dass immer häufiger automatisierte Systeme die Arbeitsleistung überwachen. Vom Paketpacken bis zum Verkauf von Online-Werbung wird Arbeit zunehmend live verfolgt, sodass Mitarbeiter*innen nicht mehr nur jährlich oder halbjährlich Feedback bekommen, sondern wöchentlich, täglich oder gar sofort. Mit Konsequenzen für bestimmte Gruppen an Arbeitnehmer*innen.

Der Einsatz von Algorithmen in der Leistungsbewertung bei Amazon wurde ebenfalls jüngst lautstark in der Presse diskutiert.⁷⁴ Ein System überwacht jeden Schritt von Lagerarbeiter*innen. Die Daten werden wöchentlich ausgelesen. Wer nicht effizient genug arbeitet, erhält automatisch eine Kündigung, obschon Amazon darauf besteht, dass hier immer noch ein Mensch die finale Entscheidung trifft. Bis zu zehn Prozent der Belegschaft wird so jährlich ausgetauscht. Und auch in Deutschland, wo der Betriebsrat einer solchen Überwachung der Belegschaft stets zustimmen muss, berichten Gewerkschaften von Fällen, in denen Lagerarbeiter*innen großer Versandhäuser für kurze Untätigkeit und zu viele Toilettengänge abgemahnt werden.

Doch die Kontrolle der Arbeit durch automatisierte Systeme betrifft nicht nur den Online-Handel: Lieferdienste, Kundenservice und die Personenbeförderung werden heute bereits mithilfe von Algorithmen gesteuert, verfolgt und ausgewertet. Automatisierte Systeme verteilen die Aufgaben, messen die Performance, optimieren laufend die Prozesse und bewerten die Leistungen des Einzelnen im Vergleich zum Rest der Belegschaft. Mitarbeiter*innen stehen im konstanten Wettbewerb zueinander und sind häufig einer dauerhaften Kontrolle ausgesetzt. Oft gibt es keine Möglichkeit, sich dem System zu entziehen oder Einwände aufzubringen. So beklagen Fahrer*innen verschiedener Transport- und Lieferdienste immer wieder die erratisch scheinende Zuteilung von Aufträgen und Fahrten der Plattformen.⁷⁵

⁷³ vgl. Töpper (2016)

⁷⁴ vgl. Lecher (2019)

⁷⁵ vgl. Möhlmann & Zalmanson (2017); vgl. Möhlmann & Henfridsson (2019); vgl. Irish Examiner (2019); Dickey (2019)



Auch bei Schwierigkeiten können sich beispielsweise Uber-Fahrer*innen nicht einfach an ihren persönlichen Vorgesetzten wenden, sondern müssen einen „Community Service“ kontaktieren, eine Art interner Kundenservice, der häufig automatisiert und unpersönlich wirkt.

Automatisierte Systeme dieser Art werden häufig dort eingesetzt, wo Leistungen gut messbar und kontrollierbar sind. Ganz anders sieht der Einsatz von Algorithmen jedoch in Berufen aus, in denen Arbeit deutlich schwieriger quantifizierbar ist: Während für Postbot*innen und Lagerarbeiter*innen konkrete Kennzahlen genutzt werden können, um festzusetzen, wie viel Leistung pro Stunde erbracht werden muss, ist dies beispielsweise für Mitarbeiter*innen im Marketing, Projektmanager*innen, Journalist*innen oder Jurist*innen oft deutlich schwieriger. Entsprechend sind nicht Algorithmen, sondern Mitarbeitergespräche noch weit verbreitet, vom kleinen Familienbetrieb bis in die Großkonzerne. Gemeinsam legen Mitarbeiter*innen und Vorgesetzte Ziele für das Jahr fest, die es zu erreichen gilt. Idealerweise sollten diese quantifizierbar sein, aber viele Berufe lassen

dies nur bedingt zu. Nicht selten liegt es daher bei den Vorgesetzten, die Leistung von Mitarbeiter*innen zu bewerten. Und hier schleichen sich unbewusste Vorurteile ein. So wird beispielsweise die Leistung von Frauen nach ihrer Rückkehr aus der Elternzeit häufig schlechter bewertet als vorher.

Hier kommen die Chancen von Algorithmen ins Spiel: Denn automatisierte Hinweise können diesen Vorurteilen entgegenwirken. Ein Prototyp von SAP zeigt, wie das gehen könnte: So zeigt das System der Mitarbeiterbewertungen zum einen die Verteilung von Männern und Frauen innerhalb der unterschiedlichen Bewertungskategorien. Manager*innen können damit auf einen Blick sehen, ob Frauen in ihrem Team beispielsweise schlechter bewertet werden als Männer. Darüber hinaus wurde aber auch ein Hinweissystem entwickelt, dass historische Mitarbeiterbewertungen zu Rate zieht und automatisch hinterfragt, ob sich womöglich unterbewusste Vorurteile in die Bewertung eingeschlichen haben könnten.⁷⁶ Studien zeigen, dass schlichte Hinweise häufig bereits ausreichen, um unterbewusste Vorurteile zu beseitigen.⁷⁷

⁷⁶ vgl. Burlacu & Fletcher (2017)

⁷⁷ vgl. Kray et al. (2002)



Betrachtet man die Breite der Einsatzszenarien von Algorithmen in der Leistungsbewertung, fällt allerdings auf, dass ihre Chancen und Risiken ungleich verteilt sind: Im Niedriglohnsektor führen sie häufig zu Entmenslichung und Überwachung und bieten umgekehrt kaum Chancen für die Mitarbeiter*innen. In Berufsfeldern mit komplexen Aufgaben können sie hingegen dafür eingesetzt werden, bestehenden Vorurteilen und Diskriminierung entgegenzuwirken. Im Gegensatz zu anderen Beispielen, wo Chancen und Risiken je nach Ziel oft zwei Seiten einer Medaille sein können, scheinen sie hier allerdings stärker voneinander getrennt: Dort wo Arbeit quantifizierbar und messbar ist, spielen menschliche Vorurteile in der Leistungsbewertung eine geringere Rolle. Ein algorithmisches Computerprogramm, das auf diese hinweist, scheint weitestgehend obsolet, wenn es nur darum geht, dass ein oder eine Mitarbeiter*in eine bestimmte Anzahl von Paketen pro Stunde packt. In vielen Bereichen des Niedriglohnssektors bestehen daher fast nur Risiken für den Einsatz von Algorithmen in der Leistungsbewertung und kaum Chancen.

2.2.3 Algorithmen für mehr Fairness in der Arbeitswelt

Die Beispiele zeigen ein vielseitiges Einsatzprofil von Daten, Algorithmen und Automatisierung in der Arbeitswelt. Während sich bestehende Muster der Benachteiligung bestimmter Gruppen in der Automatisierung von Prozessen und Entscheidungen oft widerspiegeln, bestehen vielseitige Möglichkeiten, Algorithmen zu entwickeln und einzusetzen, um menschlichen Vorurteilen in der Arbeitswelt entgegenzuwirken. Immer wieder wird die Automatisierung von Entscheidungen mit potenziellen Effizienzgewinnen begründet, doch auch in der Arbeitswelt, insbesondere in der Personalauswahl, stellt sich die Frage, ob die Effizienzgewinne nicht auch hier in der Automatisierung von Verwaltungsprozessen liegen und neue Einsatzszenarien von Algorithmen für die Lösung anderer Herausforderungen eingesetzt werden sollten: Talente an sich binden, Diversität, Gender-Gerechtigkeit.

Während in vielen Beispielfällen des Einsatzes von Algorithmen die Chancen und Risiken jeweils vom Einsatzszenario und Ziel des Systems abhängen, ist die Leistungsbewertung ein interessanter Fall, in dem Chancen und Risiken auf unterschiedliche Gruppen verteilt zu sein

scheinen. In der Personalauswahl kann ein Algorithmus zur Automatisierung der Auswahlentscheidung genutzt werden oder zur Identifizierung von Benachteiligungen in den Entscheidungen. Doch in der Leistungsbewertung scheinen höherqualifizierte Arbeitnehmer*innen potenziell von Algorithmen profitieren zu können, die Benachteiligungen bestimmter Gruppen erkennen können. Risiken liegen hingegen in vielen Branchen des Niedriglohnssektors, wo Algorithmen zur Kontrolle von Arbeitsleistungen eingesetzt werden. Für Geringverdiener*innen hat die Automatisierung der Leistungsbewertung vornehmlich Risiken und kaum Chancen. In einem solchen Fall stellt sich tatsächlich die Frage, ob der Gesetzgeber diesen Risiken Einhalt gebieten sollte.

2.3 In staatlichen Leistungen

Auch im öffentlichen Sektor halten Algorithmen und Automatisierung zunehmend Einzug. Eingesetzt werden sie vor allem zur besseren Analyse komplexer öffentlicher Herausforderungen und der Steuerung von Ressourcen: So kann etwa heute mithilfe großer Datenmengen besser vorhergesagt werden, welche Gebäude Brandrisiken ausgesetzt sind, sodass diese in der Brandschau priorisiert werden. Ebenso lässt sich die Einhaltung von Hygienestandards kontrollieren und überwachen. In Entwicklungsländern, wo traditionelle Daten häufig fehlen, kann die Wohlstandsentwicklung besser beobachtet und begleitet werden.⁷⁸ Diese und weitere Einsatzszenarien liegen zumeist fern von Chancengerechtigkeit und gesellschaftlicher Teilhabe. Doch Algorithmen werden mittlerweile auch eingesetzt, um potenziellen Kindesmissbrauch frühzeitig zu erkennen oder Versicherungsbetrug aufzudecken und damit an Stellen, die enorm relevant für die Betroffenen sind.⁷⁹

In der deutschen Verwaltung, die in der Digitalisierung bekanntlich hinterherhinkt, findet Automatisierung von Prozessen und Entscheidungen bislang kaum Verbreitung. Datenbasierte Vorhersagen werden zwar für das Wirtschaftswachstum, den Lehrerberuf an Schulen oder die Beobachtung des Arbeitsmarkts gemacht, aber selten automatisiert und auf individueller Ebene einzelner Bürger*innen.⁸⁰ Doch mit der Größe des Sozialstaats gibt es ausreichend potenzielle Berührungspunkte zwischen Bürger*innen, Staat und Algorithmen.

2.3.1 Abhängig von staatlicher Unterstützung

Im Gegensatz zu den vorangegangenen Bereichen Bildung und Arbeit geht es bei staatlichen Leistungen nicht um die Ungleichbehandlung oder Benachteiligung bestimmter Gruppen. Vielmehr erfahren Menschen, die auf staatliche Unterstützung angewiesen sind, häufig tiefe Einschnitte in ihre gesellschaftliche Teilhabe.

Vom Mutterschaftsurlaub über Kinder- und Elterngeld, Unterhaltsvorschuss, Arbeitslosenversicherung und Hartz 4 bis zu BAföG und Rentenzuschüssen – der Staat bietet eine Vielzahl finanzieller Unterstützungsformen für Millionen von Bürger*innen. Über 15 Millionen Kinder werden mit Kindergeld unterstützt. Fast acht Millionen Deutsche sind auf die staatliche Mindestsicherung angewiesen, meistens durch Arbeitslosengeld, Hartz 4 oder Zuschüsse zur Rente. Damit erhalten fast 10 % der Bevölkerung staatliche Unterstützung bei der Sicherung ihres Lebensunterhalts.

In der Bereitstellung von Leistungen begeht der Staat einen Spagat zwischen der Vereinfachung administrativer Prozesse, sodass mehr Menschen die Leistungen erhalten, die ihnen zustehen, und der Verhinderung von Betrug. Ist die Beantragung von Leistungen zu kompliziert, schwer verständlich und langwierig, stellt dies insbesondere für Menschen mit niedrigem Bildungsgrad, mangelnden Deutschkenntnissen oder in psychischen und familiären Notsituationen eine zusätzliche Hürde dar. Gleichzeitig müssen ausreichend Informationen und Zeit zur Verfügung stehen, um Anträge sorgfältig zu prüfen.

In einigen Ländern werden Algorithmen zur Erkennung von Sozialbetrug eingesetzt. Teilweise funktioniert dies gar automatisiert, sodass die Verweigerungen von Leistungen und Schreiben an die Betroffenen selbstgesteuert versandt werden.⁸¹ So wurden in Australien fälschlicherweise Betrugsbescheide und hohe Rückforderungen staatlicher Leistungen an Bedürftige, Studierende oder Rentner*innen geschickt. Manchmal wurden gar Schuldeneintreiber*innen beauftragt. Selbstverständlich werden auch in Deutschland die Daten der Sozialsysteme genutzt, um Betrüger*innen zu identifizieren. Eine so weitreichende Automatisierung der Prozesse wie in Australien steht hierzulande jedoch nicht an.

⁷⁸ vgl. Glaeser et al. (2016); vgl. Kang et al. (2013)

⁷⁹ vgl. Liu & Mchangama (2018)

⁸⁰ Das BAMF nutzt bekanntermaßen ein sprachbiometrisches Assistenzsystem, das Asylentscheider*innen bei der Identifizierung verschiedener Dialekte unterstützt, vgl. BAMF (2018)

⁸¹ vgl. Eubanks (2018)

Im folgenden Abschnitt geht es daher um den bedeutenden Fall der Unterstützung von Arbeitssuchenden. Wie in den vorangegangenen Kapiteln diskutieren wir die Chancen und Risiken von Algorithmen in diesem Bereich.

2.3.2 Unterstützung von Arbeitssuchenden

Ein gesichertes Einkommen ist immer noch der beste Schutz vor der Abhängigkeit von staatlichen Leistungen. Darüber hinaus bedeutet Arbeit für Menschen mehr als nur ein Einkommen: Es geht um gesellschaftliches Ansehen und Teilhabe, Selbstrespekt, Eigenständigkeit und Identität. Bei Verlust der Beschäftigung ist die zügige Reintegration in den Arbeitsmarkt daher von entscheidender Bedeutung. Je länger ein Mensch arbeitslos ist, desto geringer die Chancen der Reintegration.⁸²

Nationale Arbeitsagenturen bemühen sich darum, Arbeitssuchende möglichst individuell dabei zu unterstützen. Dabei ergeben Ausbildung, berufliche Erfahrungen, Geschlecht und Alter, private und familiäre Umstände sowie die Entwicklungen im Arbeitsmarkt in den unterschiedlichen Berufsfeldern zusammen ein individuelles Profil eines jeden Arbeitssuchenden. Diesem stehen jeweils Beratungsleistungen und Förderinstrumente zur Reintegration in den Arbeitsmarkt gegenüber. Heute werden zunehmend algorithmenbasierte Computersysteme eingesetzt, um diese individuellen Profile von Arbeitssuchenden zu erstellen und mit passenden Maßnahmen zu unterlegen.

Das so genannte Profiling von Arbeitssuchenden ist dabei auf keinen Fall neu: Bereits in den 1990er Jahren wurde in den USA ein operatives System eingesetzt, das Arbeitssuchende auf Basis statistischer Vorhersagen bestimmten Profilen zuordnete. Und auch in Europa ist die Methode grundsätzlich weit verbreitet. Schließlich lernen die Verwaltungseinrichtungen, welche Beratungsleistungen und Fördermaßnahmen für welche Arbeitssuchenden besonders wirksam sind und welche eher schlecht funktionieren. Darauf bauen die Einrichtungen ihre weitere Arbeit auf und lernen kontinuierlich dazu. Sie verbessern ihre Unterstützungsangebote und sparen Ressourcen. In dieser Hinsicht ist der Ausbau der datenbasierten Unterstützung von Arbeitssuchenden wünschenswert, so die OECD.⁸³

Neu ist heute die Automatisierung der Prozesse und ein gestiegenes Bewusstsein dafür, wie sich gesellschaftliche Benachteiligung in den Daten widerspiegelt, die für diese genutzt werden. Das zeigt ein derzeit laufender Test beim österreichischen Arbeitsmarktservice (AMS), dem Äquivalent zur deutschen Bundesagentur für Arbeit:⁸⁴ Ein Algorithmus teilt Arbeitssuchende nach ihren Chancen zur Integration in den Arbeitsmarkt in drei Gruppen ein. Frauen, älteren Menschen und Menschen mit außereuropäischem Migrationshintergrund schreibt der Algorithmus allerdings schlechtere Chancen zu, schnell zu einer neuen Beschäftigung zu finden. Personen mit diesen Merkmalen finden sich daher mit höherer Wahrscheinlichkeit in der Gruppe der schwer vermittelbaren Arbeitssuchenden wieder. Ob es sich dabei um Diskriminierung handelt oder nicht, wird öffentlich diskutiert. Die Macher jedenfalls wehren sich gegen den Vorwurf: Nicht sie, nicht der Algorithmus, sondern der Arbeitsmarkt diskriminiere diese Gruppen. Und eine „Abbildung der Realität kann keine Diskriminierung sein“.⁸⁵

Entscheidend ist nun aber gar nicht, wer in welcher Gruppe landet, sondern welche Konsequenzen dies nach sich zieht, also welche Unterstützungsangebote wem zustehen beziehungsweise aufgrund der Zuteilung zu einer bestimmten Gruppe verweigert werden. Im Fall des österreichischen AMS ist unklar, wie viele Ressourcen und welche Unterstützungsleistungen der Gruppe C mit den schlechtesten Chancen zur Reintegration in den Arbeitsmarkt überhaupt noch zustehen. Die Agentur schweigt dazu weitestgehend.⁸⁶ Doch in Polen verlief der Fall eines algorithmischen Systems zur Sortierung von Arbeitssuchenden ganz ähnlich. Wer hier in der dritten Gruppe der schwer vermittelbaren Arbeitssuchenden landet, erhält in der Mehrheit der Fälle gar keine Unterstützung mehr.⁸⁷

Wie auch im Fall der Benachteiligung in Einstellungsverfahren zeigt das Beispiel, dass datenbasierte Systeme erst einmal dahingehend neutral sind, dass sie die Realität abbilden und die Diskriminierung, wie sie bereits vor dem algorithmischen System bestand. Und wie im Bildungsbereich und der Arbeitswelt ist der Umgang einer Organisation mit dieser Diskriminierung entscheidender als die eigentliche Technologie. Arbeitssuchende entsprechend ihrer realen Chancen auf dem Arbeitsmarkt zu klassifizieren,

82 vgl. DGB Abteilung Arbeitsmarktpolitik (2015)

83 vgl. OECD (2018b)

84 vgl. Holl et al. (2018)

85 vgl. Dornis (2018)

86 vgl. Wimmer (2018)

87 vgl. Jędrzej (2018)

um passende Unterstützungsangebote zu machen, ist das Ziel einer jeden Arbeitsagentur. Doch welche Verantwortung hat der Staat, sich aktiv gegen Benachteiligungen und Diskriminierung auf dem Markt einzusetzen?

Darüber hinaus deuten die Beispiele auch auf eine einseitige Betrachtung der Möglichkeiten des Einsatzes von Algorithmen hin. So scheint die Einteilung von Arbeitssuchenden in nur drei Kategorien eher grob. Der fehlende Umgang mit Grenzfällen zeigt eine reine Fortführung früherer Logiken, in denen Arbeitssuchenden breit angelegte und generalisierte Eigenschaften zugeschrieben werden. Obwohl in Österreich und auch in Polen innerhalb der unterschiedlichen Gruppen wiederum individuelle Beratungs- und Förderangebote gemacht werden, stellt sich die Frage, ob wir mithilfe historischer Daten nicht eigentlich passgenauere und individuellere Unterstützung bieten können.

Ein Ziel der Systeme ist außerdem schlicht die schnellere Zuteilung von Arbeitssuchenden zu Serviceangeboten der Arbeitsagenturen. So sollen begrenzte Ressourcen möglichst zielgerichtet eingesetzt werden. Wenn es aber um die Freisetzung von Ressourcen geht, lassen sich in der öffentlichen Verwaltung oft Arbeitsschritte finden, deren Digitalisierung oder gar Automatisierung mehr Ressourcen freisetzen würden als die oft höchst nuancierte Beratung von Arbeitssuchenden. Sich der Vereinfachung aller Verwaltungsprozesse anzunehmen, würde daher

potenziell Ressourcen freisetzen, die Mitarbeiter*innen der Verwaltung für die individuelle Begleitung der Reintegration von Arbeitssuchenden nutzen könnten.

Durchaus denkbar wären aber auch andere Zielsetzungen innerhalb des gegebenen Rahmens: Wie wirksam sind welche Interventionen wirklich für welche Arbeitssuchenden? Was haben jene Personen gemeinsam, denen bestimmte Fördermaßnahmen helfen beziehungsweise diese in einem ersten Schritt erst einmal annehmen? Was können wir daraus für die Zukunft lernen? Wie können Interventionen passgenauer auf die individuelle Situation von Arbeitssuchenden zugeschnitten werden, um wirklich jene zu erreichen, die auch in der groben Zuteilung in die drei Gruppen durchs Raster fallen? Oder auch: Können wir Sanktionen vorbeugen und unterstützen statt zu bestrafen?

Dass für die Beantwortung all dieser Fragen entsprechende Daten notwendig sind, ist selbstredend. Teilweise liegen diese vor, doch in vielen Fällen reichen sie nicht aus. Inwiefern der Staat die Sammlung und Nutzung von Daten hier erweitern kann und sollte, ist durchaus umstritten. Denn in vielen anderen Ländern zeigt sich, dass der „gläserne Bürger“ vor allem jener ist, der am meisten auf den Staat angewiesen ist.

Dennoch zeigt das Beispiel wiederholt, dass die Risiken der Algorithmen vor allem in der schlichten Automatisierung menschlicher Handlungen und Entscheidungen liegen. Alternative Einsatzszenarien hingegen bieten häufig Chancen, bestehende Herausforderungen besser zu verstehen und neue Möglichkeiten, ihnen zu begegnen.

3. ZUSAMMENFASSUNG UND HANDLUNGSEMPFEHLUNGEN

Neue technologische Möglichkeiten zum Wohle aller zu gestalten, ist eine gesamtgesellschaftliche Aufgabe. In Deutschland ist das Bewusstsein dafür bei allen zentralen Akteuren geschärft: Politik, Wirtschaft, Zivilgesellschaft. Doch im Hinblick auf Algorithmen dreht sich der öffentliche Dialog bislang vor allem darum, mögliche Risiken einzugrenzen. Es soll verhindert werden, dass bestehende Benachteiligungen und Diskriminierung mittels Algorithmen verstetigt oder gar verstärkt werden. Dieser starke Fokus auf die Gefahren durch Algorithmen ist unter anderem durch die Beobachtung der jüngsten Entwicklungen in den USA geprägt, wo ein Beispiel nach dem anderen öffentlich wird, in dem Ungleichheit und Diskriminierung mittels Algorithmen automatisiert wurden. Doch in Deutschland existieren viele dieser automatisierten Systeme noch nicht.

Die hier aufgezeigten Beispiele aus den Bereichen Bildung, Arbeit und staatliche Leistungen zeigen schlaglichtartig, dass der Einsatz von Algorithmen, wie er zurzeit (vornehmlich in den USA) praktiziert wird, auch in Deutschland auf Herausforderungen treffen würde. Risiken bestünden insbesondere mit Blick auf Chancengerechtigkeit und gesellschaftliche Teilhabe. Transparenz und Kontrolle sollen diese Gefahren zumindest eindämmen.

Doch die Beispiele machen einerseits deutlich, dass die Risiken oftmals bereits darin stecken, für welchen Zweck ein algorithmisches System entwickelt und eingesetzt wird: die Allokation von Beratungsleistungen an jene Arbeitssuchende mit den höchsten Chancen zur Reintegration in den Arbeitsmarkt, die Automatisierung menschlicher Handlungen, die Kontrolle der Mitarbeiter*innen. Oft treibt der Wunsch nach Effizienz und Einsparung von Ressourcen die Entwicklung der Systeme voran. Und genau dieses Ziel ist fragwürdig, wenn Chancengerechtigkeit und gesellschaftliche Teilhabe von den algorithmischen Systemen berührt werden.

Die Beispiele zeigen andererseits aber auch, dass Algorithmen grundsätzlich einen Beitrag leisten könnten, um bestehende gesellschaftliche Herausforderungen anzugehen und zu überwinden: die Begleitung von Studierenden aus unteren Einkommensschichten durchs Studium, die faire Bewertung der Arbeitsleistungen von Frauen, die individuelle Beratung von Arbeitssuchenden. Selten kann dies mittels eines einzigen technischen Systems erreicht werden, und oft braucht es orchestrierte Anstrengungen und substanzielle Ressourcen. Doch Daten und Algorithmen können eine entscheidende Rolle darin spielen, diese Ziele zu erreichen.

Um den Perspektivwechsel von der Risiko- zur Chancenorientierung zu begehen, braucht es vor allem einen konstruktiven und ausgeglichenen Dialog über Algorithmen in Deutschland. Vielfach sind Einsatzszenarien, wie wir sie in den USA beobachten, aus den unterschiedlichsten Gründen in Deutschland unwahrscheinlich bis unmöglich. Vielfach mangelt es an Daten und der Dateninfrastruktur, um chancenorientierte Einsatzszenarien zu ermöglichen. Wo wir in Zukunft Grenzen setzen und wo Möglichkeitsräume schaffen wollen, muss gleichermaßen Teil eines öffentlichen Dialogs über die Zukunft von Algorithmen und Automatisierung in Deutschland sein. Algorithmen können als Waffe oder als Werkzeug eingesetzt werden, und es gilt, nicht nur die Gefahren der Algorithmen als Waffe einzudämmen, sondern auch die Potenziale von Algorithmen als Werkzeug für mehr Chancengerechtigkeit und gesellschaftliche Teilhabe zu nutzen.

Die folgenden fünf Handlungsempfehlungen können dabei als Leitplanken für die Gestaltung des Dialogs dienen:

Sozialen Fortschritt in den Mittelpunkt stellen

Wenn Algorithmen zu Benachteiligung und Diskriminierung führen, ist das kein technisches Problem. Vielmehr werden Automatisierung und Algorithmen oft für fragwürdige Zwecke eingesetzt und das oft dort, wo bereits gesellschaftliche Herausforderungen bestehen. Sie zeigen damit soziale Probleme auf und können als solche keine technische Lösung haben. Algorithmen können aber ein Teil der gesellschaftlichen Lösung dieser Herausforderungen sein. Dafür müssen Chancengerechtigkeit und Teilhabe als zentrales Ziel des Einsatzes von Algorithmen ein Teil der Gleichung werden. Zwar herrschen überall finanzielle Einschränkungen und der Wunsch nach Effizienz, doch erst, wenn wir Chancengerechtigkeit und Teilhabe als Ziel mit aufnehmen, können wir mögliche Zielkonflikte öffentlich und gewinnbringend lösen.

Automatisierung für risikoarme Prozesse nutzen

Immer wieder wird der potenziell enorme Effizienzgewinn als Argument dafür aufgebracht, Entscheidungen zu automatisieren. Doch wenn Effizienz das Ziel ist, zeigt sich immer wieder, dass die Automatisierung von

Verwaltungsprozessen oft deutlich wirkungsvoller ist als jene von Entscheidungen. Und das oftmals ohne substanzielle Risiken für die Menschen, um die es geht: Schüler*innen, Bewerber*innen, Arbeitssuchende. Insbesondere an Stellen, an denen über Menschen entschieden wird, wie in den Bereichen Bildung, Arbeit und staatliche Leistungen, empfinden es Mitarbeiter*innen außerdem häufig als Entlastung, einfache Verwaltungsschritte und -prozesse nicht mehr durchführen zu müssen und stattdessen wieder mehr Zeit für das Wesentliche zu haben: die Begleitung und Unterstützung der Menschen in ihrem Lebensweg.

Chancen systematisch angehen

Die Chancen für den Einsatz von Algorithmen entstehen dort, wo bestehende gesellschaftliche Probleme mithilfe der Technologie besser verstanden werden. In der Folge lassen sich wirksame Interventionen entwickeln und testen. Doch keine gesellschaftliche Herausforderung hat eine einfache technische Lösung. Datenbasierte Systeme müssen daher in einen ganzheitlichen Ansatz zur Lösung gesellschaftlicher Probleme eingebettet und oft mit substanziellen finanziellen Ressourcen unterlegt sein. Die Maßnahmenpakete ergeben sich dabei aus der Herausforderung, nicht aus dem, was technisch möglich ist.

Grenzen setzen

Der Dialog über Algorithmen dreht sich immer wieder um die Risiken der Technologie, über Kontrolle und Transparenz. Selten werden echte Grenzen gesetzt, wie dies beispielsweise bei der Gesichtserkennung in den USA der Fall ist, wo immer mehr Städte und Staaten die Technologie verbieten. Obwohl Kontrolle und Transparenz wichtige

Governance-Elemente einer jeden Technologie sind, lässt sich mithilfe dieser Kategorien nicht thematisieren, ob der Einsatz einer Technologie grundsätzlich angemessen ist oder nicht. Sobald es um Kontrolle und Transparenz geht, ist der grundsätzliche Einsatz der Technologie bereits akzeptiert: Mit Kontrolle und Transparenz fordert man einen Airbag, setzt aber keine Geschwindigkeitsbegrenzung oder Leitplanken. Doch sollten wir den Dialog breiter aufmachen, und zwar nicht nur in Richtung der Chancen, sondern auch in Richtung der Grenzen: Dort, wo bei hohen Risiken kaum Chancen für die Menschen bestehen, die vom Einsatz der Technologie betroffen sind, sollten wir nicht davor zurückschrecken, Algorithmen und Automatisierung gänzlich zu verbieten.

Eine ausgewogene Sprache finden

Der Blick über den Atlantik regt immer wieder einen angstbesetzten Dialog über Algorithmen in Deutschland an, obschon viele der US-amerikanischen Szenarien in Deutschland weder existieren noch unmittelbar bevorstehen. Wie jede neue Technologie bergen Algorithmen und künstliche Intelligenz gleichermaßen Chancen und Risiken. Sie können eben Werkzeug oder Waffe sein. Und sie sind ein Spiegel der Gesellschaft: Algorithmen dürfen daher nicht für gesellschaftliche Missstände verantwortlich gemacht werden, die sich in ihnen widerspiegeln. Sie halten uns diese vor. Die Chancen der Technologie können wir nur nutzen, wenn wir die Sprache um die Macht der Algorithmen und den Kampf um deren Kontrolle ablegen und die bestehenden sozialen Herausforderungen zurück in den Mittelpunkt rücken. Solange wir über Algorithmen als Waffe sprechen, werden wir sie nur schwer als Werkzeuge nutzen können.

LITERATUR

- Abel-Koch, Jennifer (2019): Frauen in Führungspositionen – im internationalen Vergleich hinkt Deutschland hinterher. In: KfW Research, Band 173, Februar 2019, URL: <https://www.kfw.de/PDF/Download-Center/Konzernthemen/Research/PDF-Dokumente-Volkswirtschaft-Kompakt/One-Pager-2019/VK-Nr.-173-Februar-2019-Unternehmerinnen-weltweit.pdf> [Zugriff: 2.8.2019]
- Albright, Alex (2019): If You Give a Judge a Risk Score: Evidence from Kentucky Bail Decisions, 29.5.2019, URL: http://www.law.harvard.edu/programs/olin_center/Prizes/2019-1.pdf [Zugriff: 23.7.2019]
- Anders, Florentine (2016): Neue Software verteilt Berlins Grundschulplätze - Berlin - Aktuelle Nachrichten. In: Berliner Morgenpost, 17.6.2016, URL: <https://www.morgenpost.de/berlin/article210936373/Neue-Software-verteilt-Berlins-Grundschulplaetze.html> [Zugriff: 28.8.2019]
- BAMF (2018): Digitale Unterstützer im Asylverfahren. URL: <http://www.bamf.de/DE/Service/Top/Presse/Interviews/20181008-interview-cyber-security-report/interview-cyber-security-report-node.html> [Zugriff: 8.9.2019]
- Beining, Leonie; Wohlfarth, Anna (2016): Algorithmen fürs Gemeinwohl. 13.7.2016, URL: <https://www.stiftung-nv.de/de/projekt/algorithmen-fuers-gemeinwohl> [Zugriff: 7.9.2019]
- Berliner Morgenpost (2019): Mehr Jugendliche in Berlin verlassen Schule ohne Abschluss - Berlin - Aktuelle Nachrichten. In: Berliner Morgenpost, 11.1.2019, URL: <https://www.morgenpost.de/berlin/article216187961/Mehr-Jugendliche-in-Berlin-verlassen-Schule-ohne-Abschluss.html> [Zugriff: 18.8.2019]
- Bialek, Catrin (2019): Kommentar: Wirkstoff gegen die Allmacht der Algorithmen benötigt! In: Handelsblatt, 17.7.2019, URL: <https://www.handelsblatt.com/meinung/kommentare/kommentar-wir-brauchen-dringend-einen-wirkstoff-gegen-die-allmacht-der-algorithmen/24595410.html?ticket=ST-6195339-aLZoKe2Pg05CicZFZKJl-ap4> [Zugriff: 29.8.2019]
- Bleiker, Carla (2019): Hälfte aller EU-Bürger weiß nicht, was Algorithmen sind. 6.2.2019, URL: <https://www.dw.com/de/h%C3%A4lfte-aller-eu-b%C3%BCrger-wei%C3%9F-nicht-was-algorithmen-sind/a-47372697> [Zugriff: 1.9.2019]
- BMBF (2007): Die wirtschaftliche und soziale Lage der Studierenden in der Bundesrepublik Deutschland 2006. Berlin, Bonn: , URL: http://www.sozialerhebung.de/download/18/Soz18_Kurzfassung.pdf [Zugriff: 11.9.2019]
- Brynjolfsson, Erik & McAfee, Andrew (2014): The Second Machine Age. W. W. Norton & Company, URL: <http://secondmachineage.com/> [Zugriff: 10.9.2019]
- von Büna, Paul (2018): Die Sehnsucht nach Transparenz ist eine Sehnsucht nach Begründung. Warum Algorithmen lernen sollten, eine Geschichte zu erzählen. 16.7.2018, URL: <https://idalab.de/blog/data-science/die-sehnsucht-nach-transparenz-ist-eine-sehnsucht-nach-begrundung-warum-algorithmen-lernen-sollten-eine-geschichte-zu-erzaehlen> [Zugriff: 13.9.2019]
- Bundesministerium für Verkehr und digitale Infrastruktur (2015): Strategie automatisiertes und vernetztes Fahren. September 2015, URL: https://www.bmvi.de/SharedDocs/DE/Publikationen/DG/broschuere-strategie-automatisiertes-vernetztes-fahren.pdf?__blob=publication-file [Zugriff: 17.8.2019]
- Bundesregierung (2016): Niedriglöhne in der Bundesrepublik Deutschland. URL: <http://dip21.bundestag.de/dip21/btd/18/105/1810582.pdf> [Zugriff: 6.9.2019]
- Bundesregierung (2017): Einundzwanzigster Bericht nach § 35 des Bundesausbildungsförderungsgesetzes zur Überprüfung der Bedarfssätze, Freibeträge sowie Vomhundertsätze und Höchstbeträge nach § 21 Absatz 2. Deutscher Bundestag, URL: <http://dip21.bundestag.de/dip21/btd/19/002/1900275.pdf> [Zugriff: 8.9.2019]
- Bundesregierung (2018): Strategie Künstliche Intelligenz der Bundesregierung. URL: https://www.bmbf.de/files/Nationale_KI-Strategie.pdf [Zugriff: 3.9.2019]
- Burlacu, Gabriela & Fletcher, Patricia (2017): Develop a More Diverse and Inclusive Workforce Using SAP SuccessFactors Solutions to Move Your Business Beyond Bias. 2017, S. 97
- Calderon et al. (2019): Calderon, Ania; Taber, Dan; Qu, Hong; Wen, Jeff: AI Blindspot: A Discovery Process for preventing, detecting, and mitigating bias in AI systems. 2019, URL: <http://aiblindspot.media.mit.edu/> [Zugriff: 12.9.2019]
- Centers for Disease Control and Prevention (2019): Assault or Homicide. 4.7.2019, URL: <https://www.cdc.gov/nchs/fastats/homicide.htm> [Zugriff: 2.9.2019]
- Chzhen et al. (2018): Chzhen, Yekaterina; Rees, Gwyther; Gromada, Anna; Cuesta, José A; Bruckauf, Zlata; Drohan, Madelaine; UNICEF; Office of Research: An unfair start: inequality in children's education in rich countries. URL: https://www.unicef-irc.org/publications/pdf/an-unfair-start-inequality-children-education_37049-RC15-EN-WEB.pdf [Zugriff: 16.8.2019]
- Corbett-Davies et al. (2016): Corbett-Davies, Sam; Pierson, Emma; Feller, Avi; Goel, Sharad: A computer program used for bail and sentencing decisions was labeled biased against blacks. It's actually not that clear. In: Washington Post, 17.10.2016, URL: <https://www.washingtonpost.com/news/monkey-cage/wp/2016/10/17/can-an-algorithm-be-racist-our-analysis-is-more-cautious-than-pro-publicas/> [Zugriff: 19.8.2019]
- Correll et al. (2007): Correll, Shelley J.; Benard, Stephen: Getting a Job: Is There a Motherhood Penalty? In: American Journal of Sociology, Band 112, Ausgabe 5, 2007, S. 1297–1338
- Datenethikkommission (2019): Datenethikkommission. 12.9.2019, URL: http://www.bmi.bund.de/DE/themen/it-und-digitalpolitik/datenethikkommission/datenethikkommission-node.html;jsessionid=41A4A6D-6371C395E2B6E0B6DD52291FD.2_cid364 [Zugriff: 12.9.2019]

- Demling, Alexander (2019): Wie soziale Medien Nutzer zu Sklaven des Algorithmus machen. 16.7.2019, URL: <https://www.handelsblatt.com/technik/digitale-revolution/digitale-revolution-wie-soziale-medien-nutzer-zu-sklaven-des-algorithmus-machen/24595688.html?ticket=ST-1684247-xgQ7dcr4O1l1CrqYd9m-ap3> [Zugriff: 12.8.2019]
- Deutscher Bundestag (2019): Deutscher Bundestag - Enquete-Kommission „Künstliche Intelligenz“. 8.9.2019, URL: https://www.bundestag.de/ausschuesse/weitere_gremien/enquete_ki [Zugriff: 8.9.2019]
- DGB Abteilung Arbeitsmarktpolitik (2015): Beschäftigungschancen von Langzeitarbeitslosen im Hartz-IV-System nicht verbessert. In: arbeitsmarkt aktuell, 2.2015, URL: <https://www.dgb.de/themen/++co++57c76ea6-aaf4-11e4-b505-52540023ef1a> [Zugriff: 22.8.2019]
- Dickey, Megan Rose (2019): Postmates workers want minimum delivery guarantees and at least \$15 per hour. In: TechCrunch. 21.5.2019, URL: <https://techcrunch.com/2019/05/20/postmates-workers-want-minimum-delivery-guarantees-and-at-least-15-per-hour/?guccounter=1> [Zugriff: 27.8.2019]
- Diehl, Jörg & Kartheuser, Boris (2018): Kriminalität in Deutschland: Polizei setzt auf Computer-Vorhersagen. 27.1.2018, URL: <https://www.spiegel.de/panorama/justiz/kriminalitaet-in-deutschland-polizei-setzt-auf-computer-vorhersagen-a-1188350.html> [Zugriff: 27.8.2019]
- Dornis, Valentin (2018): Arbeit aus dem Automaten. In: Süddeutsche.de, 22.10.2018, URL: <https://www.sueddeutsche.de/digital/digitalisierung-arbeitslosigkeit-jobcenter-1.4178635> [Zugriff: 18.8.2019]
- Dräger, Jörg & Müller-Eiselt, Ralph (2019): Wir und die intelligenten Maschinen. München.
- Duffin, Erin (2019): Percentage of the U.S. population who have completed four years of college or more from 1940 to 2018. Februar 2019, URL: <https://www.statista.com/statistics/184272/educational-attainment-of-college-diploma-or-higher-by-gender/> [Zugriff: 4.9.2019]
- Duvergne Smith, Nancy (2014): Deploy or Die—Media Lab Director's New Motto. 29.7.2014, URL: <https://alum.mit.edu/slice/deploy-or-die-media-lab-directors-new-motto> [Zugriff: 8.9.2019]
- Ekowo, Manuela & Palmer, Iris (2016): The Promise and Peril of Predictive Analytics in Higher Education. 24.10.2016, URL: <https://www.newamerica.org/education-policy/policy-papers/promise-and-peril-predictive-analytics-higher-education/> [Zugriff: 7.9.2019]
- El-Mafaalani, Aladin (2016): Armut und Begabung - Vortrag zum Impulsabend von Prof. Dr. Aladin El-Mafaalani. , URL: <https://www.youtube.com/watch?v=9KvDU89SBZw&t=1308s> [Zugriff: 6.9.2019]
- Eubanks, Virginia (2018): Automating Inequality. How High-Tech Tools Profile, Police, and Punish the Poor.
- Europäische Kommission (2019): Ethics guidelines for trustworthy AI | Digital Single Market. 8.4.2019, URL: <https://ec.europa.eu/digital-single-market/en/news/ethics-guidelines-trustworthy-ai> [Zugriff: 6.9.2019]
- FAZ (2017): Neue Studie: Zahl der Studienabbrecher steigt an. In: FAZ, 1.6.2017, URL: <https://www.faz.net/aktuell/politik/inland/neue-studie-zahl-der-studienabbrecher-steigt-an-15042502.html> [Zugriff: 25.8.2019]
- FAZ (2018): Studie: Algorithmen bestimmen zunehmend über unser Leben. In: FAZ, 23.5.2018, URL: <https://www.faz.net/aktuell/gesellschaft/studie-algorithmen-bestimmen-zunehmend-ueber-unser-leben-15602803.html> [https://www.faz.net/aktuell/gesellschaft/studie-algorithmen-bestimmen-zunehmend-ueber-unser-leben-15602803.html] [Zugriff: 29.8.2019]
- Fetzer, Joachim (2019): Algorithmen entscheiden nicht, und sie werden es auch niemals. 27.6.2019, URL: <https://www.kas.de/analysen-und-argumente/detail/-/content/algorithmen-entscheiden-nicht-und-sie-werden-es-auch-niemals> [Zugriff: 9.9.2019]
- Fields, Gary & Emshwiller, John R. (2014): As Arrest Records Rise, Americans Find Consequences Can Last a Lifetime. In: The Wall-Street Journal, 18.8.2014, URL: <https://www.wsj.com/articles/as-arrest-records-rise-americans-find-consequences-can-last-a-lifetime-1408415402> [Zugriff: 9.9.2019]
- Foschi, Martha (1996): Double Standards in the Evaluation of Men and Women. In: Social Psychology Quarterly, Band 59, Ausgabe 3, 1996, S. 237–254
- Fuegen et al. (2004): Fuegen, Kathleen; Biernat, Monica; Haines, Elizabeth; Deaux, Kay: Mothers and Fathers in the Workplace: How Gender and Parental Status Influence Judgments of Job-Related Competence. In: Journal of Social Issues, Band 60, Ausgabe 4, 2004, S. 737–754
- Gaupp et al. (2011): Gaupp, Nora; Geier, Boris; Lex, Tilly; Rei, Birgit; Stamm, Margrit; Kost, Jacob; Suter, Peter; Holzinger-Neulinger, Melanie; Safi, Netke; Stroezel, Holger; Schmidt, Bernhard; Heublein, Ulrich: Schulabbruch: Ursachen - Entwicklung - Prävention. Ergebnisse US-amerikanischer und deutscher Forschungen. In: Zeitschrift für Pädagogik, Band 57, Ausgabe 2, 2011, S. 26
- Glaeser et al. (2016): Predictive cities crowdsourcing city government: Using tournaments to improve inspection accuracy. In: Am. Econ. Rev., Ausgabe 106, 2016, S. 114–118
- Golden, Claudia & Rouse, Cecilia (1997): Orchestrating Impartiality: The Impact of „Blind“ Auditions on Female Musicians. In: National Bureau of Economic Research, Band NBER Working Paper, Ausgabe No. 5903, 1997
- Goodman, Rachel (2018): Why Amazon's Automated Hiring Tool Discriminated Against Women. 10.2018, URL: <https://www.aclu.org/blog/womens-rights/womens-rights-workplace/why-amazons-automated-hiring-tool-discriminated-against> [Zugriff: 23.9.2019]
- Green, Ben (2019): The Just City: Machine Learning's Social and Political Foundations · The Smart Enough City. 29.3.2019, URL: <https://smartenoughcity.mitpress.mit.edu/pub/vmj18djz> [Zugriff: 12.9.2019]
- Greene et al. (2019): Greene, Daniel; Hoffmann, Anna Lauren; Stark, Luke: Better, Nicer, Clearer, Fairer: A Critical Assessment of the Movement for Ethical Artificial Intelligence and Machine Learning. , URL: <http://hdl.handle.net/10125/59651> [Zugriff: 21.8.2019]
- Groll, Tina (2019): Bundesverfassungsgericht: Kippt jetzt Hartz IV? In: Die Zeit, 15.1.2019, URL: <https://www.zeit.de/wirtschaft/2019-01/bundesverfassungsgericht-hartz-iv-sanktionen-strafen-verfassungswidrigkeit-faq> [Zugriff: 16.8.2019]

- Hao, Karen (2018): What is machine learning? In: MIT Technology Review, 17.11.2018, URL: <https://www.technologyreview.com/s/612437/what-is-machine-learning-we-drew-you-another-flowchart/> [Zugriff: 7.8.2019]
- Harari, Yuval Noah (2017): Homo Deus: Eine kurze Geschichte von morgen.
- Hardt, Moritz (2014): How big data is unfair. , URL: <https://medium.com/@mrtz/how-big-data-is-unfair-9aa544d739de> [Zugriff: 26.8.2019]
- Heilmann, Madeleine E. (2012): Gender Stereotypes and Workplace Bias. In: Research in Organizational Behaviour, Ausgabe 32, 2012, S. 113-135
- Heilmann, Madeleine E. & Haynes, Michelle C. (2005): No Credit Where Credit Is Due: Attributional Rationalization of Women' Success in Male-Female Teams. In: Journal of Applied Psychology, Band 90, Ausgabe 5, 2005, S. 905-916
- Helbig, Marcel & Jähnen, Stefanie (2018): Wie brüchig ist die soziale Architektur unserer Städte? URL: <https://bibliothek.wzb.eu/pdf/2018/p18-001.pdf> Zugriff: 16.8.2019]
- Heublein et al. (2017): Heublein, Ulrich; Ebert, Julia; Hutzsch, Christopher; Isleib, Sören; König, Richard; Richter, Johanna; Woisch, Andreas: Zwischen Studierenerwartungen und Studienwirklichkeit - Ursachen des Studienabbruchs, beruflicher Verbleib der Studienabbrecherinnen und Studienabbrecher und Entwicklung der Studienabbruchquote an deutschen Hochschulen. Hannover: Deutsches Zentrum für Hochschul- und Wissenschaftsforschung GmbH, URL: http://www.dzhw.eu/pdf/pub_fh/fh-201701.pdf [Zugriff: 2.9.2019]
- Heublein, Ulrich & Schmelzer, Robert (2018): Die Entwicklung der Studienabbruchquoten an den deutschen Hochschulen. URL: https://www.dzhw.eu/pdf/21/studienabbruchquoten_absolventen_2016.pdf [Zugriff: 3.9.2019]
- Hipp, Lena (2018): Damned if you do, damned if you don't? Experimental evidence on hiring discrimination against parents with differing lengths of family leave. 27.8.2018, URL: <https://osf.io/preprints/socarxiv/qsm4x/> [Zugriff: 17.8.2019]
- Hoffmann, Anna Lauren (2018): Where fairness fails: data, algorithms, and the limits of antidiscrimination discourse: 17.9.2018, URL: <https://www.tandfonline.com/doi/full/10.1080/1369118X.2019.1573912> [Zugriff: 17.7.2019]
- Holl et al. (2018): Holl, Jürgen; Kernbeiß, Günter; Wagner-Pinter, Michael: Das AMS-Arbeitsmarkt- chancen-Modell. Oktober 2018, URL: http://www.forschungsnetzwerk.at/downloadpub/arbeitsmarktchancen_methode_%20dokumentation.pdf [Zugriff: 2.9.2019]
- Hollenbach-Biele, Nicole (2017): Chancenspiegel Schule: Bessere Chancen für Schüler, aber Unterschiede zwischen den Bundesländern. Gütersloh: Bertelsmann Stiftung, URL: https://www.bertelsmann-stiftung.de/fileadmin/files/BSt/Publikationen/GrauePublikationen/Factsheet_IB_Chancenspiegel_Schule_2017.pdf [Zugriff: 4.9.2019]
- Hvistendahl, Mara (2016): Can 'predictive policing' prevent crime before it happens? 28.9.2016, URL: <https://www.sciencemag.org/news/2016/09/can-predictive-policing-prevent-crime-it-happens> [Zugriff: 12.8.2019]
- iRights.Lab (2019): iRights.Lab | Think Tank für die digitale Welt. 25.8.2019, URL: <https://irights-lab.de/> [Zugriff: 25.8.2019]
- Irish Examiner (2019): Slave to the Algorithm? What it's really like to be a Deliveroo rider. In: Irish Examiner, 20.2.2019, URL: <https://www.irishexaminer.com/breakingnews/lifestyle/features/slave-to-the-algorithm-what-its-really-like-to-be-a-deliveroo-rider-905680.html> [Zugriff: 2.9.2019]
- Ito, Joi (2018): AI isn't a crystal ball, but it might be a mirror. 9.5.2018, URL: <https://www.media.mit.edu/articles/ai-isn-t-a-crystal-ball-but-it-might-be-a-mirror/> [Zugriff: 22.8.2019]
- Jędrzej, Niklas (2017): Can an algorithm hurt? Polish experiences with profiling of the unemployed – Centre for Internet & Human Rights. März 2017, URL: <https://cihr.eu/can-an-algorithm-hurt/> [Zugriff: 23.9.2019]
- Julia Angwin, Jeff Larson (2016): Machine Bias. 23.5.2016, URL: <https://www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing> [Zugriff: 23.9.2019]
- Kang et al., J.S. (2013): Where not to eat? Improving public policy by predicting hygiene inspections using online reviews. In: Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing, 2013, S. 1443-1448
- Kemper, Lorenz (2018): Predicting Student Dropout: a Machine Learning Approach. Februar 2018, URL: https://www.researchgate.net/publication/322919234_Predicting_Student_Dropout_a_Machine_Learning_Approach [Zugriff: 26.8.2019]
- Knobloch, Tobias (2018): Vor die Lage kommen: Predictive Policing in Deutschland. August 2018, URL: <https://www.stiftung-nv.de/sites/default/files/predictive.policing.pdf> [Zugriff: 16.8.2019]
- Kolmar, Martin & Binswanger, Johannes (2019): Algorithmen: Sie entscheiden über unsere Leben. In: Die Zeit, 29.7.2019, URL: <https://www.zeit.de/wirtschaft/2019-07/algorithmen-facebook-google-datensicherheit> [Zugriff: 9.9.2019]
- Köver, Chris (2019): Firmen verleihen sich selbst ein Gütesiegel für Künstliche Intelligenz. In: [netzpolitik.org](https://netzpolitik.org/2019/firmen-verleihen-sich-selbst-ein-guetesiegel-fuer-kuenstliche-intelligenz/), 27.3.2019, URL: <https://netzpolitik.org/2019/firmen-verleihen-sich-selbst-ein-guetesiegel-fuer-kuenstliche-intelligenz/> [Zugriff: 1.9.2019]
- Kray et al. (2002): Kray, Laura J.; Galinsky, Adam D.; Thompson, Leigh: Reversing the gender gap in negotiations: An exploration of stereotype regeneration. In: Organizational Behavior and Human Decision Processes, Band 87, Ausgabe 2, 2002, S. 386-409
- Krempkow, René (2017): Herausforderung Bildungschancen: Von der Grundschule bis zur Promotion. 20.11.2017, URL: <https://scilogs.spektrum.de/wissenschaftssystem/herausforderung-bildungschancen/> [Zugriff: 28.8.2019]
- Krüger, Julia (2018): Wie der Mensch die Kontrolle über den Algorithmus behalten kann. 19.1.2018, URL: <https://netzpolitik.org/2018/algorithmen-regulierung-im-kontext-aktueller-gesetzgebung/> [Zugriff: 10.9.2019]

- Lakkaraju et al. (2015): Lakkaraju, Himabindu; Aguiar, Everaldo; Shan, Carl; Miller, David; Bhanpuri, Nasir; Ghani, Rayid; Addison, Kecia L.: A Machine Learning Framework to Identify Students at Risk of Adverse Academic Outcomes. Sydney, NSW, Australia: ACM Press, URL: <http://dl.acm.org/citation.cfm?doid=2783258.2788620> [Zugriff: 20.9.2019]
- Lecher, Colin (2019): How Amazon automatically tracks and fires warehouse workers for 'productivity'. 25.4.2019, URL: <https://www.theverge.com/2019/4/25/18516004/amazon-warehouse-fulfillment-centers-productivity-firing-terminations> [Zugriff: 14.8.2019]
- Liu, Hin-Yan & Mchangama, Jacob (2018): The Welfare State Is Committing Suicide by Artificial Intelligence. URL: <https://foreignpolicy.com/2018/12/25/the-welfare-state-is-committing-suicide-by-artificial-intelligence/> [Zugriff: 23.9.2019]
- Llewellyn Smith, Julia (2013): Warning: maternity leave can damage your career. In: The Telegraph. 21.7.2013, URL: <https://www.telegraph.co.uk/women/10192274/Warning-maternity-leave-can-damage-your-career.html> [Zugriff: 12.8.2019]
- Mauer, Marc (2011): Addressing Racial Disparities in Incarceration. In: The Prison Journal, Band 91, Ausgabe 3. September 2011, S. 87-101
- McGrath, Maggie (2014): The Invisible Force Behind College Admissions. 30.7.2014, URL: <https://www.forbes.com/sites/maggiemcgrath/2014/07/30/the-invisible-force-behind-college-admissions/#659ea51b70a5> [Zugriff: 15.8.2019]
- Merkel, Angela (2019): Digitalrat gibt wichtige Ratschläge. URL: <https://www.bundesregierung.de/breg-de/mediathek/die-kanzlerin-direkt/merkel-digitalrat-gibt-wichtige-ratschlaege-1593188> [Zugriff: 20.8.2019]
- Minevich, Mark (2019): Japan's 'Society 5.0' initiative is a road map for today's entrepreneurs. 2.2.2019, URL: <https://techcrunch.com/2019/02/02/japans-society-5-0-initiative-is-a-roadmap-for-todays-entrepreneurs/?guccounter=1> [Zugriff: 8.8.2019]
- Möhlmann, Mareike; Henfridsson, Ola (2019): What People Hate About Being Managed by Algorithms, According to a Study of Uber Drivers. In: Harvard Business Review, 30.8.2019, URL: <https://hbr.org/2019/08/what-people-hate-about-being-managed-by-algorithms-according-to-a-study-of-uber-drivers> [Zugriff: 15.8.2019]
- Möhlmann, Mareike & Zalmanson, Lior (2017): Hands on the wheel: Navigating algorithmic management and Uber drivers' autonomy. Dezember .2017, URL: https://www.researchgate.net/publication/319965259_Hands_on_the_wheel_Navigating_algorithmic_management_and_Uber_drivers'_autonomy [Zugriff: 21.8.2019]
- Muhammad, Khalil Gibran (2011): The Condemnation of Blackness: Race, Crime, and the Making of Modern Urban America. 30.11.2011, URL: <https://www.hup.harvard.edu/catalog.php?isbn=9780674062115> [Zugriff: 29.8.2019]
- Müller-Eiselt, Ralph & Hustedt, Carla (2019): Ethik der Algorithmen. URL: <https://www.bertelsmann-stiftung.de/de/unsere-projekte/ethik-der-algorithmen/> [Zugriff: 3.9.2019]
- Noble et al. (2018): Noble, Dr. Safiya U.; Roberts, Dr. Sarah T.; Hicks, Dr. Marie; Muhammad, Khalil: Before Algorithms: A History of Bias and Oppression in Computing. URL: <https://vimeo.com/300987273> [Zugriff: 8.9.2019]
- Norman AI (2019): NORMAN - World's first psychopath AI. 12.9.2019, URL: <http://norman-ai.mit.edu/> [Zugriff: 12.9.2019]
- OECD (2018a): A Broken Social Elevator? How to Promote Social Mobility. OECD, URL: https://www.oecd-ilibrary.org/social-issues-migration-health/broken-elevator-how-to-promote-social-mobility_9789264301085-en [Zugriff: 21.8.2019]
- OECD (2018b): Profiling tools for early identification of jobseekers who need extra support. In: Policy Brief on Activation Policies, Reihe OECD Publishing, 12.2018, URL: <http://www.oecd.org/els/emp/OECD-Profiling-policy-brief-DEC-18.pdf> [Zugriff: 10.9.2019]
- OECD Stat (2019): Employment: Female share of seats on boards of the largest publicly listed companies. 12.8.2019, URL: <https://stats.oecd.org/index.aspx?queryid=54753> [Zugriff: 12.8.2019]
- Page, Lindsay C. & Gehlbach, Hunter (2017): How an Artificially Intelligent Virtual Assistant Helps Students Navigate the Road to College. In: AERA Open, Band 3, Ausgabe 4, 1.10.2017
- Page, Lindsay & Gehlbach, Hunter (2018): How Georgia State University Used an Algorithm to Help Students Navigate the Road to College. In: Harvard Business Review, 16.1.2018, URL: <https://hbr.org/2018/01/how-georgia-state-university-used-an-algorithm-to-help-students-navigate-the-road-to-college> [Zugriff: 16.8.2019]
- Perry, Walter L.; McInnis, Brian; Price, Carter C.; Smith, Susan C.; Hollywood, John S. (2013): Predictive policing: the role of crime forecasting in law enforcement operations. Santa Monica, CA: RAND, URL: https://www.rand.org/content/dam/rand/pubs/research_reports/RR200/RR233/RAND_RR233.pdf [Zugriff: 19.8.2019]
- Reynolds, Matt (2018): Biased policing is made worse by errors in pre-crime algorithms. 27.4.2018, URL: <https://www.newscientist.com/article/mg23631464-300-biased-policing-is-made-worse-by-errors-in-pre-crime-algorithms/> [Zugriff: 11.9.2019]
- Richardson et al. (2019): Richardson, Rashida; Schultz, Jason; Crawford, Kate: Dirty Data, Bad Predictions: How Civil Rights Violations Impact Police Data, Predictive Policing Systems, and Justice. In: New York University Law Review Online, 5.3.2019, URL: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3333423 [Zugriff: 16.8.2019]
- Richter, Markus (2018): Interview Dr. Richter. 8.10.2018, URL: <http://www.bamf.de/DE/Service/Top/Presse/Interviews/20181008-interview-cyber-security-report/interview-cyber-security-report-node.html> [Zugriff: 26.8.2019]
- Sander, Matthias (2019): Die Macht der Algorithmen – und die ihrer Macher. In: Neue Zürcher Zeitung, 27.6.2019, URL: <https://www.nzz.ch/feuilleton/die-macht-der-algorithmen-und-die-ihrer-macher-ld.1491847> [Zugriff: 9.9.2019]

- Schlick, Leonie (2019): Buchrezension: Wie Künstliche Intelligenz unser Leben steuert. In: Capital, 27.8.2019, URL: <https://www.capital.de/wirtschaft-politik/wie-kuenstliche-intelligenz-unser-leben-steuert> [Zugriff: 4.9.2019]
- Schmidt, Florian Alexander (2019): Crowdwork: Menschen trainieren Algorithmen - für ein bis zwei Euro die Stunde. 16.5.2019, URL: https://www.boeckler.de/14_120138.htm [Zugriff: 17.8.2019]
- Schnuck, Oliver & Zierer, Maximilian (2018): Erhöhtes Risiko. 28.11.2018, URL: <https://web.br.de/interaktiv/erhoehtes-risiko/index.html> [Zugriff: 20.8.2019]
- Schwab, Klaus (2015): The Fourth Industrial Revolution: What It Means and How to Respond. 12.12.2015, URL: <https://www.foreignaffairs.com/articles/2015-12-12/fourth-industrial-revolution> [Zugriff: 24.8.2019]
- Selbst et al. (2018): Selbst, Andrew D.; Boyd, Danah; Friedler, Sorelle; Venkatasubramanian, Suresh; Janet Vertesi: Fairness and Abstraction in Sociotechnical Systems. Rochester, NY: Social Science Research Network, URL: <https://papers.ssrn.com/abstract=3265913> [Zugriff: 24.8.2019]
- Smith, Jordan (2019): How Misdemeanors Turn Innocent People Into Criminals. 13.01.2019, URL: <https://theintercept.com/2019/01/13/misdemeanor-justice-system-alexandra-natapoff/> [Zugriff: 5.9.2019]
- Spielkamp, Matthias (2019): AlgorithmWatch. 9.9.2019, URL: <https://algorithmwatch.org> [Zugriff: 9.9.2019]
- Statista Research Department (2019): Anzahl der Mordopfer in Deutschland von 2000 bis 2018. April 2019, URL: <https://de.statista.com/statistik/daten/studie/2229/umfrage/mordopfer-in-deutschland-entwicklung-seit-1987/> [Zugriff: 29.8.2019]
- Statistisches Bundesamt (2019): Anzahl der Studierenden an Hochschulen in Deutschland in den Wintersemestern von 2002/2003 bis 2018/2019. 2019, URL: <https://de-statista-com.ezp-prod1.hul.harvard.edu/statistik/daten/studie/221/umfrage/anzahl-der-studenten-an-deutschen-hochschulen> [Zugriff: 23.8.2019]
- Thomas, Philip I. (2013): Scheduling Algorithm with Optimization of Employee Satisfaction. Mai 2013, URL: <https://scheduling.philipithomas.com/scheduling.pdf> [Zugriff: 20.8.2019]
- Töpper, Verena (2016): Die Frauenfänger-Software. In: Spiegel Online , 14.9.2016, URL: <https://www.spiegel.de/karriere/sap-software-sucht-nach-maennlichen-woertern-in-stellenanzeigen-a-1111153.html> [Zugriff: 29.8.2019]
- Tullis, Tracy (2014): How Game Theory Helped Improve New York City's High School Application Process. In: The New York Times, 5.12.2014, URL: <https://www.nytimes.com/2014/12/07/nyregion/how-game-theory-helped-improve-new-york-city-high-school-application-process.html> [Zugriff: 26.8.2019]
- Vallas, Rebecca & Dietrich, Sharon (2015): Americans with Criminal Records. The Sentencing Project, URL: <https://www.sentencingproject.org/wp-content/uploads/2015/11/Americans-with-Criminal-Records-Poverty-and-Opportunity-Profile.pdf> [Zugriff: 12.9.2019]
- Vieth-Entus, Susanne (2019): Trotz Zulage: Lehrer haben keine Lust auf Brennpunktschulen. In: Tagesspiegel, 2.8.2019, URL: <https://www.tagesspiegel.de/berlin/trotz-zulage-lehrer-haben-keine-lust-auf-brennpunktschulen/24862776.html> [Zugriff: 11.8.2019]
- Vincent, James (2018): Amazon reportedly scraps internal AI recruiting tool that was biased against women. 10.10.2018, URL: <https://www.theverge.com/2018/10/10/17958784/ai-recruiting-tool-bias-amazon-report> [Zugriff: 12.9.2019]
- Washington Post (2019): Fatal Force - 992 people have been shot and killed by police in 2018. In: Washington Post, 31.3.2019, URL: <https://www.washingtonpost.com/graphics/2018/national/police-shootings-2018/> [Zugriff: 20.8.2019]
- Weick, Stefan (2011): Schichtzugehörigkeit nicht nur vom Einkommen bestimmt - Analysen zur subjektiven Schichteinstufung in Deutschland. In: ISI45, Ausgabe 45, Februar 2011, URL: <https://www.gesis.org/fileadmin/upload/forschung/publikationen/zeitschriften/isi/isi-45.pdf> [Zugriff: 28.8.2019]
- Wendt, Rainer (2019): Polizei schoss 2018 auf weniger Menschen als im Vorjahr. In: Zeit Online, 24.7.2019, URL: <https://www.zeit.de/gesellschaft/zeitgeschehen/2019-07/polizei-gewalt-waffen-schusswaffen-statistik> [Zugriff: 1.9.2019]
- Wiarda, Dr. Jan-Martin (2018): Algorithmus-Enthusiasmus - Hilft es Studenten, wenn man ihnen bescheinigt, dass sie mit 95-prozentiger Wahrscheinlichkeit ihr Studium nicht schaffen? 21.6.2018, URL: <http://www.jmwiarda.de/2018/06/21/algorithmus-enthusiasmus/> [Zugriff: 7.9.2019]
- Wieduwilt, Hendrik (2019): Algorithmen: Auch in Europa entscheiden längst Maschinen. In: FAZ, 29.1.2019, URL: <https://www.faz.net/aktuell/wirtschaft/diginomics/algorithmen-auch-in-europa-entscheiden-laengst-maschinen-16012852.html> [Zugriff: 8.9.2019]
- Williams, Aaron & Eramdjomeh, Armand (2018): America is more diverse than ever — but still segregated. In: Washington Post, 10.5.2018, URL: <https://www.washingtonpost.com/graphics/2018/national/segregation-us-cities/?noredirect=on> [Zugriff: 13.8.2019]
- Wimmer, Barbara (2018): Der AMS-Algorithmus ist ein „Paradebeispiel für Diskriminierung“. 17.10.2018, URL: <https://futurezone.at/netzpolitik/der-ams-algorithmus-ist-ein-paradebeispiel-fuer-diskriminierung/400147421> [Zugriff: 23.9.2019]
- Winter, Sabrina (2019): „Predictive Policing“: Polizei verzichtet auf Verbrechens-Prognosen. 22.4.2019, URL: <https://www.welt.de/regionales/hamburg/article192258075/Predictive-Policing-Polizei-verzichtet-auf-Verbrechens-Prognosen.html> [Zugriff: 25.8.2019]
- Wissenschaftliche Dienste (2017): Auswirkungen von Sanktionen im SGB II. Überblick über qualitative Studien in Deutschland. Deutscher Bundestag 2017, URL: <https://www.bundestag.de/blob/497906/f2a6382d0a8b3d3afb9bb4dffdabc59/wd-6-004-17-pdf-data.pdf> [Zugriff: 12.9.2019]

IMPRESSUM

Autoren

Isabel Schünemann

Yannick Lebert

Korrektorat

Christina Wegener

Unterstützung

Yagmur Cay

Jan-Phillip Wagner

Eine Studie des betterplace lab in Kooperation mit dem Vodafone Institut für Gesellschaft und Kommunikation.

Das Projekt wird inhaltlich vom Carr Center for Human Rights unterstützt.

Das betterplace lab ist ein digital-sozialer Think-und-Do-Tank. Wir sind die Schwester von betterplace.org, Deutschlands größter Online-Spendenplattform. Wir wollen die Digitalisierung sozial gestalten und für das Gemeinwohl nutzbar machen. Dazu forschen und experimentieren wir in innovativen Projekten.

Das Vodafone Institut ist Vodafones europäischer Think-Tank. Wir analysieren die Potentiale digitaler Technologien und deren verantwortungsvolle Nutzung für Innovation, Wachstum und nachhaltige gesellschaftliche Wirkung. Mit Hilfe von Studien und Veranstaltungen bieten wir eine Plattform für den Dialog von Vordenkern aus Wissenschaft, Wirtschaft und Politik.

Oktober 2019

Eine Studie des betterplace LAB in Kooperation mit:



**Vodafone Institut
für Gesellschaft
und Kommunikation**