



This book chapter was originally published by kopaed-Verlag as:  
Rebitschek, F. G. (2021). **Informiert mit Scoring-Systemen  
auseinandersetzen**. In H. Gapski, & S. Packard (Eds.), *Super-  
Scoring? Datengetriebene Sozialtechnologien als neue  
Bildungsherausforderung* (pp. 191-203). Düsseldorf: kopaed-  
Verlag.

**Terms of use:**



**Provided by:**

Max Planck Institute for Human Development  
Library and Research Information  
[library@mpib-berlin.mpg.de](mailto:library@mpib-berlin.mpg.de)

---

Harald Gapski / Stephan Packard (Hrsg.)

# **Super-Scoring?**

Datengetriebene Sozialtechnologien  
als neue Bildungsherausforderung

Düsseldorf – München  
[www.kopaed.de](http://www.kopaed.de)

---

---

**Felix G. Rebitschek**

## **Informiert mit Scoring-Systemen auseinandersetzen**

*Informierte Auseinandersetzung mit Scoring-Systemen bedeutet, dass jene Menschen, welche durch einen Algorithmus zum Zweck von Prognose oder Steuerung ihres Verhaltens vermessen werden, diesen verstehen und kritisch hinterfragen können. Dies impliziert nicht nur informierte Teilhabe an algorithmischen Entscheidungsumwelten, die einer Einzelperson im Rahmen individueller Wirkmöglichkeiten nützt, sondern auch informierte Teilhabe an einem gesellschaftlichen Diskurs, der entscheidungsbezogene Algorithmen- und Scoring-Systeme regulierbar macht. Für diese Auseinandersetzung können Bildungsinterventionen entwickelt werden. Zugleich lassen Indikatoren, wie das Bewusstsein für Qualitätsprobleme von Algorithmen, die Befähigung der Allgemeinbevölkerung in Deutschland zur informierten Auseinandersetzung mit Scoring-Algorithmen vielversprechend erscheinen. Verschiedene Einwände werden im Rahmen dieses Kapitels beleuchtet und ein Ausblick auf Forschungslücken gegeben.*

### **1 Einleitung**

Muss ich wissen, wie ein Bus funktioniert, um den Bus zu nehmen? Stellen Sie sich vor, Sie fahren mit einem ganz besonderen Bus, in dem der Busfahrer nur so lenkt, wie es der Bus vorgibt. Der Bus fährt Routen, die Sie nicht kennen. Sie sind der einzige Fahrgast. Und Sie wissen vielleicht schon, dass der Bus manchmal unerwartet ausfällt und sich auch öfter verfährt. Sie sollten besser wissen, wie der Bus funktioniert und das gesamte Bussystem – oder Sie vermeiden es, diesen Bus überhaupt zu nehmen. Es geht nicht darum, den richtigen Bus zu wählen. Es geht nicht darum, die Erwartungen an den Fahrgast zu erfüllen. Es geht um die informierte Auseinandersetzung der Bürger(innen) mit dem, was einen Bus ausmacht, sowie die gesellschaftliche Frage, wo und wie welche Busse eingesetzt werden. Das Streben nach informierter Auseinandersetzung mit Super-Scoring<sup>1</sup> bedeutet in gleicher Weise, Bürger(innen) zu befähigen, die sie umgebende Scoring-Umwelt zu beeinflussen bzw. zu gestalten.

Scoring lässt sich als das systematische Vermessen des Menschen zur Prognose und Steuerung seines Verhaltens verstehen (SVRV 2018). Beim Super-Scoring ver-

#### IV. Bildungsherausforderungen des Scorings

---

messen umfassende Scoring-Systeme menschliche Eigenschaften und Verhaltensweisen über Lebensbereiche hinweg. Ein Beispiel hierfür sind chinesische Social-Credit-System-Entwicklungen (Creemers 2016; Mac Síthigh/Siems 2019; vgl. die Beiträge von Chen, Backer und Ohlberg in diesem Band). Die Chancen und Risiken solcher Super-Scoring-Systeme werden im vorliegenden Band diskutiert. In Ergänzung zu dieser Diskussion betonen die folgenden Überlegungen, warum Interventionen relevant sind, welche eine informierte Auseinandersetzung von Betroffenen mit Scoring-Systemen ermöglichen und Risiken entgegenwirken.

Die informierte Einwilligung ist ein Grundkonzept der modernen gesundheitlichen Versorgung in westlichen Industrieländern<sup>2</sup> und wird durch zahlreiche Interventionen wie zum Beispiel Patient(inn)eninformationen adressiert (Stacey et al. 2017). In Deutschland ist ein Anspruch auf informiertes Entscheiden in das Gesetz zur Stärkung der Rechte von Patient(inn)en eingewebt. Informiert entscheidet der Einzelne, z. B. der/die Patient(in), genau dann, wenn er/sie mögliche Nutzen und Schäden medizinischer Interventionen auf Basis der besten verfügbaren Evidenz abwägen konnte. Das bedeutet, eine informierte Einwilligung gründet im Verständnis der möglichen Auswirkungen der Handlungsalternativen.

Informierte Auseinandersetzung mit Scoring-Systemen bedeutet demgegenüber, dass Menschen, welche durch einen Algorithmus zum Zweck von Prognose oder Steuerung ihres Verhaltens vermessen werden, diesen verstehen und kritisch hinterfragen können. Diese informierte Auseinandersetzung mit Scoring-Systemen unterscheidet sich von klassischer informierter, einmaliger Einwilligung in eine Handlungsalternative, weil sie eine kontinuierliche Interaktion mit einer Handlungsalternative darstellt, für die sich das Nutzen-Schaden-Verhältnis jederzeit ändert – durch interne (z. B. eigenes Verhalten) und externe Faktoren (z. B. das Modell wurde vom Anbieter modifiziert). Beim Umgang mit Scoring-Systemen wäre eine informierte Auseinandersetzung somit nicht nur daran erkennbar, Nutzen und Schaden des Eintritts bzw. Nicht-Eintritts in das System zu verstehen, sondern zu erfassen, wie sich das persönliche Nutzen-Schaden-Verhältnis dynamisch verändert.

Als weiterer Unterschied wirkt sich die soziale und gesellschaftliche Verbreitung eines Scoring-Systems auf die weiteren Lebensbedingungen aus. Zur Illustration denke man an die Herdenimmunität durch eine Impfung, welche indirekt alle Gesellschaftsmitglieder vor der Verbreitung eines Erregers schützt. Die Konsequenzen des Impf- bzw. Scoring-Handelns oder -Nichthandelns sind nicht nur persönlicher, sondern auch sozialer und gesellschaftlicher Natur. Scoring-Systeme determinieren dynamisch etwa Partizipationschancen für alle beteiligten Gesellschaftsmitglieder (Fourcade/Healy 2013). Dazu kommen Herausforderungen, deren Bewältigung

durch Individuen ausgeschlossen werden kann, wie im Fall von stratifizierten Informationsumwelten (Matz et al. 2017), die intransparent bleiben können, solange es keine regulatorische Initiative für systematische Prüfungen gibt (z. B. wer sieht welche politische Werbung). Der wahrgenommene Scoring-Veränderungsbedarf und eine aktive Diskursbeteiligung speisen sich in gewissem Maße aus persönlichen, sozialen und gesellschaftlichen Abwägungen durch die informierte Auseinandersetzung der Betroffenen mit dem System.

Die Vorstellung von einer informierten Auseinandersetzung von Bürger(inne)n mit algorithmenbasierten Scoring-Systemen lässt sich jedoch von Beginn an kritisch in Frage stellen. Wirksame Bildungsinterventionen (zum Beispiel Elements of AI, Universität Helsinki/Reaktor 2019) laufen Gefahr, sich in ihrem Erfolg auf privilegierte Bevölkerungsgruppen zu beschränken (Gemmell et al. 2019). Dem folgend bespricht dieser Beitrag mögliche Einwände gegen die Entwicklung von Interventionen zur Stärkung der Algorithmensouveränität der allgemeinen Bevölkerung. Im Einzelnen wären Einwände: mangelndes Bewusstsein für Algorithmenprobleme in der Bevölkerung (2.1), mangelndes Interesse der Bevölkerung an Algorithmen (2.2), mangelnde Informatikkenntnisse der Bevölkerung (2.3), mangelnde Relevanz der informierten Auseinandersetzung (2.4) und Schwächung regulatorischer Initiativen (2.5). Der Beitrag schließt mit einem Ausblick auf den Forschungsbedarf für mögliche Interventionsentwicklungen.

## 2 Streben nach Algorithmensouveränität

Eine klare Abgrenzung von anderen Konzepten hilft, Algorithmensouveränität im Kontext von Scoring zu verstehen. Algorithmensouveränität bedeutet nicht, die Souveränität als Nutzer(in) zu stärken, etwa durch eine verstärkte Selbstkontrolle bei der Nutzung digitaler Dienste (SVRV 2017). Es bedeutet auch nicht, die Datensouveränität zu stärken, etwa durch eine tatsächlich informierte Einwilligung in die Datenverarbeitung. Ferner ist Algorithmensouveränität auch von Informationssouveränität abzugrenzen, die vorliegt, wenn Menschen bedarfsgerechte und qualitätsgesicherte Informationen, analog wie digital, finden und nutzen können. Algorithmensouveränität ist dann erforderlich, wenn der oder die Einzelne Objekt algorithmischer Entscheidungsumwelten ist, wie zum Beispiel beim Scoring, damit er/sie Kontrolle über diese Umwelten erlangt, zum Beispiel durch Algorithmenkompetenz (Rainie/Anderson 2017).

### 2.1 Einwand: Mangelndes Bewusstsein für Algorithmenrisiken in der Bevölkerung

Ein Risiko von Scoring-Algorithmen basiert darauf – wie bei allen Tests, Modellen und Instrumenten zum Ziehen von Schlussfolgerungen –, dass sie niemals perfekt sind. Sie produzieren immer auch Fehler, beispielsweise bei der Klassifizierung Fehlschlüsse und Fehlalarme. In der Vergangenheit wurde die Illusion der Gewissheit, z. B. über klinische Testergebnisse, als Hürde für das Risikoverständnis der Bevölkerung erkannt (Gigerenzer 2014). Die Verbreitung dieser Illusion hat sich jedoch verändert. Eine quasi-repräsentative Interneterhebung im Projekt RisikoAtlas (2020) hat 2017 gezeigt, dass nur noch 18 % der erwachsenen Menschen in Deutschland das Ergebnis einer Krebsfrüherkennungsuntersuchung als sicher zutreffend erachten (Rebitschek, Jenny et al., in Vorbereitung).

Jüngste bevölkerungsrepräsentative Untersuchungen zeigen, dass die allgemeine Bevölkerung in Deutschland durchaus Erwartungen hat, wie viele Fehler verschiedene Scoring-Algorithmen machen (Rebitschek, Gigerenzer et al., in Vorbereitung). Grob jede vierte bis fünfte Vorhersage wird als falsch eingeschätzt. Über die Themen Kreditwürdigkeitsprüfung, Rückfallprognose bei Straftäter(inne)n, Bewerber(innen)-analyse und Gesundheitsverhaltensbewertung und über die Fehlerarten (Übersehen, Fehlalarmieren) variieren die Algorithmenenerwartungen an die Fehlerraten und sie unterscheiden sich nicht so sehr von den Erwartungen an Expert(inn)en. Ferner sind die akzeptierten Fehlerraten viel niedriger als die erwarteten Raten. Das Bewusstsein um Qualitätsdefizite ist also mit noch höheren Qualitätsansprüchen verknüpft.

In der Medienöffentlichkeit hat sich eine Entwicklung in der Rezeption und Diskussion der Verlässlichkeit von wissenschaftlichen Schlussfolgerungen und die Art und Weise ihres Zustandekommens auf Basis von Daten vollzogen. Die *performance* bzw. die Qualität von Algorithmen ist ein Informationsbedürfnis (z. B. für personalisierte Medizin, Rebitschek et al. 2019), welches für eine informierte Auseinandersetzung zu adressieren ist.

### 2.2 Einwand: Mangelndes Interesse der Bevölkerung an Algorithmen

Nach Selbstauskunft wüsste nicht einmal jede(r) zehnte Erwachsene in Deutschland, was ein Algorithmus sei (Fischer/Petersen 2018). Im Kern jedes Scoring-Modells stecken jedoch Merkmale, auf deren Basis ein Algorithmus, der Scoring-Al-

gorithmus, operiert. Gerade in diesem Sinne hat die Allgemeinbevölkerung ein erhebliches Interesse an Algorithmen. In einer vom Sachverständigenrat für Verbraucherfragen in Auftrag gegebenen repräsentativen Befragung wurde erkannt, dass die meisten Bürger(innen) der deutschen Bevölkerung deutlich differenzierte Präferenzen bezüglich jener Merkmale haben, die in Scoring-Systeme eingehen: so insbesondere für telematische Fahrer(innen)-Scoring-Systeme und die Gesundheitsverhaltensbewertung (SVRV 2018). Die Merkmalsauswahl ist somit von Interesse. Ob die Merkmalsgewichte im Algorithmus von Interesse für die Allgemeinbevölkerung sind, bleibt abzuwarten.

Des Weiteren zeigte eine Gruppentestung fein differenzierte Reflexionen über Scoring-bezogene Risiken. Überwachung, persönliche Daten und Datenschutzbelange mit Missbrauchspotenzial wurden ebenso von den Teilnehmenden aufgeworfen wie Verhaltenskontrolle über Normen und Verhaltensstandardisierung, mit Verlust an Autonomie. Ferner wurden die Validität von Scoring-Ergebnissen, die Ökonomisierung mit Fehlanreizen und mögliche Solidaritätsverluste sowie das Potenzial für soziale Interaktionsstörungen kritisch wahrgenommen (Rebitschek et al. 2018). Das Interesse an potenziellen persönlichen, sozialen und gesellschaftlichen Algorithmenkonsequenzen dürfte jedoch über die hier stark selektierte Stichprobe hinausreichen, wenn auch für verschiedene Gruppen in verschiedenen Ausprägungen. Passagiere der Beförderungsplattform *Uber* sind beispielsweise besorgt, wenn sie die konkreten Auswirkungen von Fahrer(inne)n- bzw. Fahrtbewertungen innerhalb des Scoring-Systems und mögliche Reputationsauswirkungen auf sich selbst nicht nachvollziehen können (Moriuchi 2019).

Man stelle sich, etwas weitergedacht, beispielsweise vor, dass begehrte Marken wie Apple oder Louis Vuitton Verbraucher(innen)programme installieren, die ihre Exklusivität unterstreichen. Der Klimaschutz wäre hier ein hervorragendes Marketinginstrument, das es erlaubt, ein grünes Verbraucher(innen)scoring zu rechtfertigen, wonach nur jene Zugang zu hochwertigen Produkten hätten, die über viele Lebensbereiche hinweg hinreichend überprüfte klimafreundliche Aktivitäten zeigen. Das Interesse produktinteressierter Verbraucher(innen) an diesem Scoring-Algorithmus und daran, wie man ihn ausnutzt, wäre mutmaßlich sehr ausgeprägt.

### 2.3 Einwand: Mangelnde Informatikkenntnisse der Bevölkerung

Wenn man die Fortschritte bei der Förderung von Grundkenntnissen der Informatik (zum Beispiel einer Programmiersprache) in der Allgemeinbevölkerung zusammenfasst (Schubert/Schwill 2011), ist man versucht, anzunehmen, dass Bildungsvor-

#### IV. Bildungsherausforderungen des Scorings

---

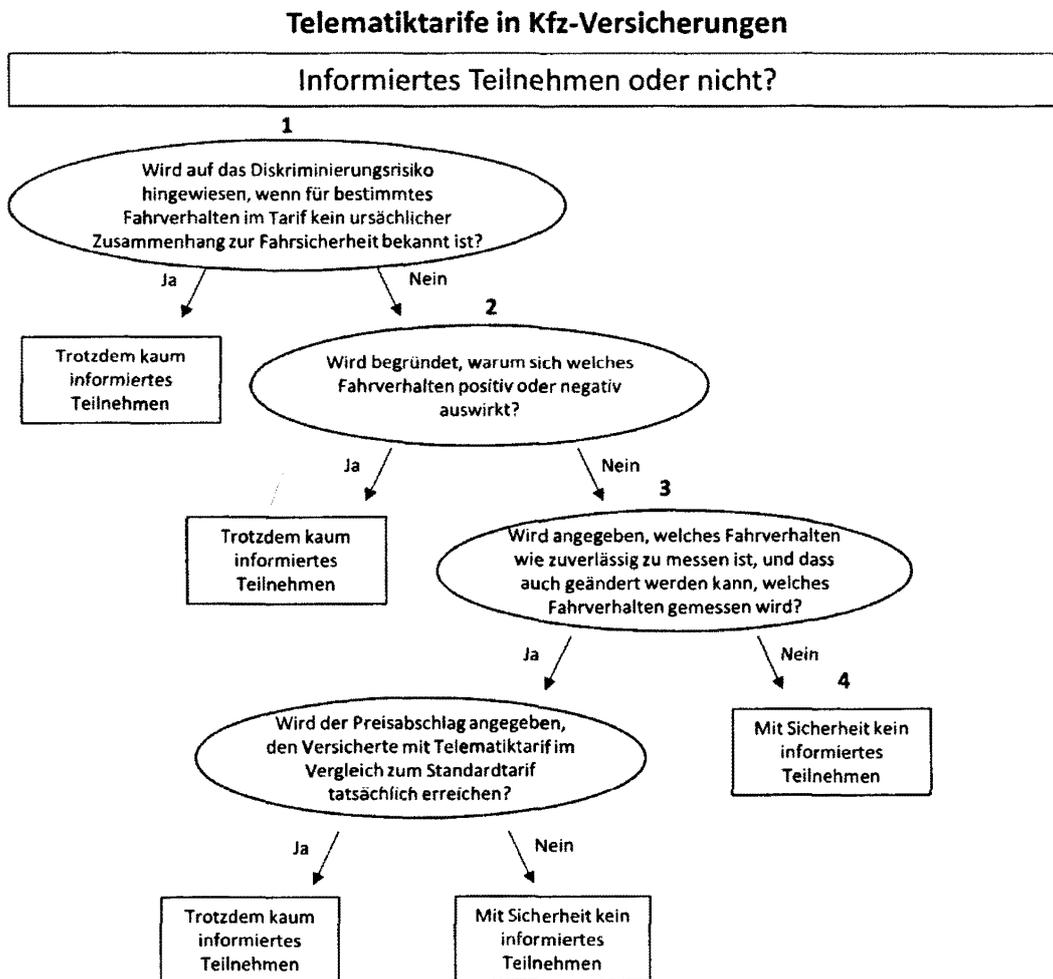
aussetzungen für eine informierte Auseinandersetzung mit Algorithmen fehlen. Algorithmen-souveränität kann sich jedoch in einem wirksamen Sinne ohne die Kenntnis von Programmiersprachen konstituieren, zum Beispiel durch das Zusammenspiel von Bildungsinterventionen zur Algorithmenkompetenz in Kombination mit regulatorischen Anforderungen an die verständliche Darstellung von Scoring-Systemen und von Algorithmenoutputs.

Interventionen zur Algorithmenkompetenz können sich auf die funktionalen Konzepte konzentrieren, auf denen die Algorithmen basieren. Das Ziel ließe sich wie folgt festlegen: Jede(r) Bürger(in) solle wissen, was er oder sie vor der Teilnahme an einem Scoring zu überprüfen hat, damit das direkte wie indirekte Nutzen-Schaden-Verhältnis für ihn/sie positiv ausfällt. Algorithmen-souveränität sollte daher vor allem dadurch erreicht werden, dass man in der Schule und in der Erwachsenenbildung lernt, was man fragen muss.

Die gesellschaftsbezogenen Fragen sind: Was ist der Zweck des jeweiligen Scoring-Algorithmus und wie ist dieser Zweck bisher erreicht worden? Welche Relevanz hat das prognostizierte Scoring-Ziel und welche Konsequenzen hat die Wahl dieses Ziels? Welcher mögliche Nutzen und Schaden für den Einsatz von Algorithmen wurden auf individueller, sozialer und gesellschaftlicher Ebene ermittelt? Gerade für die letzte Frage bestehen im Grunde nur Forschungslücken.

Konkreter sind die Fragen, die die Lernenden unmittelbar betreffen: Welche Eigenschaften des einzelnen Menschen werden in welchem Umfang berücksichtigt? Dieses Verständnis von Merkmalen und ihrer Gewichtung wird nach Cheng et al. (2019: 5) als Algorithmenverständnis bezeichnet, „if the human can see what attributes cause the algorithm’s action and can predict how changes in the situation can lead to alternative algorithm predictions“. Um umgekehrt als Entwickler(in) oder Anwender(in) eines Scoring-Algorithmus bei Betroffenen Verständnis dafür zu schaffen, woraus sich eine Algorithmenempfehlung speist, könnten Explorationsmöglichkeiten und Transparenz (in Form von *white boxes*) zu eingehenden Merkmalen, ihrer Gewichtung und der Algorithmen-schlussfolgerung einen Weg aufzeigen (Cheng et al. 2019).

Ebenso konkret sind Problemstellungen, die Lernende unmittelbar betreffen könnten, aber nicht notwendigerweise Effekte zeigen: Wie gut und repräsentativ waren die Daten, mit denen der Algorithmus ‚gebaut‘ wurde? Wie ist die Qualität der Daten, die der Scoring-Algorithmus verwendet? Wie hoch ist die Qualität und Zuverlässigkeit des Algorithmus im Durchschnitt und für Personen mit bestimmten Merkmalskombinationen? Wie werden die verschiedenen Arten von Algorithmenfehlern gewichtet



**Erläuterungen**

- 1) Damit prüfen Sie, ob der Anbieter die potenziell ungerechtfertigt diskriminierende Verwendung von Verhaltensweisen für die Tarifierung deutlich macht, für die ein Zusammenhang mit Fahrsicherheit beobachtet wird, aber kausal ungeklärt ist.
- 2) Damit prüfen Sie, wie sich die einzelnen Verhaltensweisen und Merkmale zur Berechnung der Fahrsicherheit auf den zu zahlenden Beitrag auswirken und wie sich das mit Blick auf die Fahrsicherheit wissenschaftlich begründet.
- 3) Damit prüfen Sie, ob der Anbieter deutlich macht, wie unterschiedlich zuverlässig die verschiedenen Verhaltensweisen im Tarif überhaupt gemessen werden können; dabei muss auch klar werden, dass diese sich in Zukunft auch ändern können.
- 4) Damit prüfen Sie, ob die versprochenen Ersparnisse durch realistisches Fahren, über viele Fahrer hinweg betrachtet, erreicht werden können.

Selbst bei Vorliegen der Information zeigt sich: Es bleibt ein erheblicher Mangel an wichtigen Informationen, wodurch eine informierte Teilnahme an Telematiktarifen grundsätzlich eher unwahrscheinlich bleibt. Sie können mögliche Vor- und Nachteile meist nicht abwägen.

Abbildung 1. *Fast-and-frugal tree* zur informierten Telematik-Tarifwahl, dessen Einsatz zur Prüfung eines Tarifangebots verdeutlicht, dass grundsätzliche Schlüsselinformationen bei realen Tarifangeboten fehlen. Der Baum wurde mithilfe von Expert(inn)eneinschätzungen entwickelt.

#### IV. Bildungsherausforderungen des Scorings

---

und inwieweit stimmen die Betroffenen mit dieser Gewichtung von möglichen Fehlerkonsequenzen überein? Welche Qualitäten von Fairness erfüllt der Algorithmus?

Nicht alle Fragen lassen sich durch die betroffenen Bürger(innen) prüfen. Für viele Fragen stehen jedoch zunehmend mehr Werkzeuge bereit, *boosts*, nicht-monetäre, nicht-regulatorische Interventionsansätze für gesellschaftliche Herausforderungen, deren Nutzung wissens- bzw. sogar kompetenzförderlich ist (Hertwig/Grüne-Yanoff 2017).

Um Verbraucher(innen) durch *boosts* zu stärken, zielte die Forschung im Projekt RisikoAtlas (2020) – gefördert vom Bundesministerium der Justiz und für Verbraucherschutz – auf eine Vielfalt von Verbraucher(innen)risiken ab. Mithilfe von Fachexpert(inn)en wurden Fragen untersucht, wie man eine informierte Scoring-System-Auswahl treffen kann (z. B. Telematik in der Kfz-Versicherung), wie man die Datenweitergabe für potenzielle Scoring-Systeme vermeiden kann (z. B. People Analytics) und wie man erkennen kann, wenn eine informierte Teilnahme verwehrt wird (z. B. Gesundheitsbonusprogramme). Verbraucher(innen), die mit *boosts* in Form von frugalen Entscheidungsbäumen (nicht-kompensatorische, lexikografische „fast-and-frugal trees“, die bis zur letzten Entscheidung nur „Exit“ oder „Weiter“ aufweisen, Martignon et al. 2008) ausgestattet sind, können es erkennen, wenn sie keine informierte Wahl treffen können (Rebitschek/Gigerenzer 2020), und sie verstehen, was sie tun können, um die persönliche Kontrolle über das Scoring zu erhöhen. Abbildung 1 zeigt ein Muster, wie ein Telematik-Tarif zum Fahrverhalten geprüft werden kann. Dabei ergaben die Expert(inn)enbefragungen, dass eine volle Nutzen-Schaden-Abwägung bei keiner gegenwärtig aufzufindenden Tarifpräsentation möglich wäre.

#### 2.4 Einwand: Mangelnde Relevanz der informierten Auseinandersetzung

Man könnte sich auf den Standpunkt stellen, dass die Verbesserung der Algorithmen-Kompetenz der allgemeinen Bevölkerung weitgehend irrelevant ist, da es Fachexpert(inn)en sind, die sich mit diesen Bewertungssystemen befassen müssen: Entwickler(innen), Fachanwender(innen) und Regulierungsbehörden. Die Verbesserung der Kompetenzen derjenigen, die von Scoring-Programmen betroffen sind, ist jedoch eine wesentliche Voraussetzung für positive Nutzen-Schaden-Verhältnisse, wenn Algorithmensysteme implementiert werden (Gigerenzer et al. 2018). Denn wie bei medizinischen Interventionen in der gesundheitlichen Versorgung stößt auch der beabsichtigte Einfluss von Scorings, der sich unter kontrollierten Bedingungen zeigt, bei der realen Implementierung an seine Grenzen. Statt geplanter Wirkungsstärken werden Nebeneffekte auftreten (zum Beispiel Ausspielen des Al-

gorithmus bzw. *gaming*, Schwarzmärkte, soziale Interaktionsstörungen), die viele Bürger(innen) stark betreffen und kaum kontrollierbar sind. Die Chance auf ein positives Nutzen-Schaden-Verhältnis ist just an die Fähigkeit der bewerteten Personen gebunden, kritische Beobachtungen und Erfahrungen auf den implementierten Algorithmus zurückzuführen, zu bewerten und, falls erforderlich, zu korrigieren. Hier kommt nicht nur die Algorithmen-, sondern auch die Risikokompetenz ins Spiel (Gigerenzer 2014): eine Reihe von Merkmalen und Fähigkeiten, die es dem Individuum ermöglichen, auf Probleme der Unsicherheit wirksam zu reagieren, so dass ein positives Nutzen-Schaden-Verhältnis für die eigene Lebensführung erreicht wird. Die Relevanz der informierten Auseinandersetzung liegt in persönlicher Schadensvermeidung und persönlichem Nutzen trotz eines nicht perfekten Systems. Die informierte Auseinandersetzung erfolgt dabei aus einer Algorithmensouveränität heraus, die sich nicht nur auf algorithmenspezifische Kompetenzen gründet, sondern auch Ausdruck von Risikokompetenz ist.

## 2.5 Einwand: Schwächung regulatorischer Initiativen

Primär ist es keine Frage von Kompetenz oder Transparenz – selbst wenn man damit die Verständlichkeit oder Nachvollziehbarkeit von Scores aus Sicht von Laien meint – warum ein bestimmter Output durch einen Scoring-Algorithmus produziert wird, wenn dieser eine/n Bürger(in) beeinträchtigt. Es ist eine Frage des rechtlichen Rahmens. Selbst wenn sie/er zugrundeliegende Daten teilt und diesen Grundrechtseingriff ermächtigt, hatte sie/er zu dem Zeitpunkt zum Beispiel nicht in eine später resultierende Verletzung seiner/ihrer Rechte einwilligen können (SVRV 2018). Verschärfend kommt hinzu, dass das Potenzial der Daten zum Zeitpunkt der Einwilligung oft nicht bekannt ist. Da Super-Scoring das Potenzial besitzt, zu bestimmen, in welchem Umfang betroffene Personen an Wirtschaft und Gesellschaft teilnehmen, ist zu erwarten, dass die Regulation hier Grundrechte verteidigen wird.

Bildungsinitiativen, die auf die Befähigung bzw. Ermächtigung des/r Einzelnen abzielen, sollten hier als Komplement verstanden und eben nicht als Substitut von Regulation verdächtigt werden. Entgegen dem Einwand, das ermächtigte Individuum wäre nur Kosmetik, um nicht die Scoring-Verhältnisse antasten zu müssen, werden Regulierungsinitiativen erst durch informierte Bürger(innen) und Wähler(innen) gestärkt. Es ist genau jene kompetenzbasierte Algorithmensouveränität der Bürger(innen), die gebraucht wird, wenn der öffentliche Diskurs nicht nur Kosmetik sein soll, um zu unterscheiden, wo Regulation für eine bessere Kontrolle und Umgestaltung der algorithmischen Scoring-Umwelten erforderlich ist.

### 3 Ausblick

Mit Blick auf die Perspektive einer hochinnovativen Nation wie Deutschland könnte die Frage der informierten Auseinandersetzung mit Scoring-Algorithmen zu einer Frage der Forschungsstrategie werden. Wenn man an die ersten Jahre des Internets in Deutschland denkt, so floss ein Großteil der Forschungsmittel in die Datensicherheit und *usability*. Seit Beginn des 21. Jahrhunderts sind die Präferenzen der Menschen in Bezug auf Algorithmen in den Fokus der Forschung gerückt: Meinungen und Bewertungen. Und in den letzten drei Jahren wurde der Wissenserwerb wichtiger, ebenso wie das Bewusstsein und das Wissen über Algorithmen (Fischer/Petersen 2018).

Forschungsprojekte über interpretierbare Algorithmen gehen jener Forschung voraus, die zu ergründen sucht, wie digitale Umwelten so gestaltet werden können, dass sie das Nutzen-Schaden-Verhältnis für die Gesellschaft, aber auch die Autonomie des Einzelnen erhöhen (Kozyreva et al. 2019). Auch wenn sie unterschiedliche Voraussetzungen in der digitalen und analogen Umwelt identifizieren, sind selbst diese Ansätze immer noch begrenzt, wenn sie den kritischen Unterschied ignorieren, dass man eine algorithmische Umwelt weit flexibler umkehren, ablehnen oder ersetzen kann. Menschen müssen algorithmische Systeme und Maschinen, anders als Lebensformen, nicht als gegeben verstehen, reflektieren (für eine entgegengesetzte Annäherung, siehe Rahwan et al. 2019) und ihnen dadurch Akzeptanz verleihen. Jene sind vielmehr entwickelt worden, weil sie vorhandene Bedürfnisse von Einzelnen, Gruppen oder der Gesellschaft als Ganzem funktional erfüllen (Nassehi 2019). Diese Bedürfnisse werden wiederum in der gesellschaftlichen Interaktion konstruiert. Daraus ergibt sich ein Bedarf danach, zu untersuchen, inwieweit man Bürger(innen) mit Bildung, verhaltenswissenschaftlich validierten Werkzeugen wie *boosts* und technischen Hilfsmitteln dazu befähigen kann, algorithmische Umwelten als Ganze in Frage zu stellen, digitalisierungsbezogene Bedürfnisse (z. B. Komfort) im gesellschaftlichen Diskurs zu hinterfragen und politischen Druck zu erzeugen, der unerwünschte Umwelten weit mehr reguliert, einschränkt oder korrigiert als es der oder die informierte Einzelne vermag.

### 4 Danksagungen

Der Autor wurde im Rahmen des Projekts RisikoAtlas gefördert. Dieses Projekt wurde mit Mitteln des Bundesministeriums der Justiz und des Verbraucherschutzes (BMJV) aufgrund eines Beschlusses des Parlaments der Bundesrepublik Deutschland über die Bundesanstalt für Landwirtschaft und Ernährung (BLE) im Rahmen des Innovationsförderungsprogramms gefördert.

## Literaturangaben

- Cheng, Hao-Fei; Wang, Ruotong; Zhang, Zheng; O'Connell, Fiona; Gray, Terrance; Harper, F. Maxwell; Zhu, Haiyi (2019): Explaining Decision-Making Algorithms through UI: Strategies to Help Non-Expert Stakeholders. In: Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems. <https://doi.org/10.1145/3290605.3300789> <Zugriff 08.03.2020>
- Creemers, Rogier (2016): Opinions concerning accelerating the construction of credit supervision, warning and punishment mechanisms for persons subject to enforcement for trust-breaking [Inoffizielle Übersetzung der Direktive der Zentralen Volksregierung]. <https://chinacopyrightandmedia.wordpress.com/2016/09/25/opinions-concerning-accelerating-the-construction-of-credit-supervision-warning-and-punishment-mechanisms-for-persons-subject-to-enforcement-for-trust-breaking/> <Zugriff 02.03.2020>
- Fischer, Sarah; Petersen, Thomas (2018): Was Deutschland über Algorithmen weiß und denkt. Ergebnisse einer repräsentativen Bevölkerungsumfrage. In: Impuls Algorithmenethik #7. [https://www.bertelsmann-stiftung.de/fileadmin/files/BSt/Publikationen/GrauePublikationen/Was\\_die\\_Deutschen\\_ueber\\_Algorithmen\\_denken.pdf](https://www.bertelsmann-stiftung.de/fileadmin/files/BSt/Publikationen/GrauePublikationen/Was_die_Deutschen_ueber_Algorithmen_denken.pdf) <Zugriff 08.03.2020>
- Fourcade, Marion; Healy, Kieran (2013): Classification situations: Life-chances in the neo-liberal era. In: Accounting, Organizations and Society 38/8. S. 559-572.
- Gemmell, Laura; Wenham, Lucy; Hauert, Sabine (2019): Leaving No One Behind: Educating Those Most Impacted by Artificial Intelligence. In: Artificial Intelligence in Education. Oth International Conference, AIED 2019, Chicago, IL, USA, June 25-29, 2019, Proceedings, Part II. Hrsg. v. S. Isotani et al. Wiesbaden. S. 344-349.
- Gigerenzer, Gerd (2014): Risiko: Wie man die richtigen Entscheidungen trifft. München.
- Gigerenzer, Gerd; Rebitschek, Felix G.; Wagner, Gert G. (2018): Eine vermessene Gesellschaft braucht Transparenz. In: Wirtschaftsdienst 98/12. S. 860-868. <https://doi.org/10.1007/s10273-018-2378-4> <Zugriff 30.09.2020>
- Hertwig, Ralph; Grüne-Yanoff, Till (2017): Nudging and boosting: Steering or empowering good decisions. In: Perspectives on Psychological Science 12(6). S. 973-986.
- Kozyreva, Anastasia; Lewandowsky, Stephen; Hertwig, Ralph (2019): Citizens versus the internet: Confronting digital challenges with cognitive tools. In: PsyArXivPreprints. <https://psyarxiv.com/ky4x8/> <Zugriff 08.03.2020>
- Mac Síthigh, Daithí; Siems, Mathias (2019): The Chinese social credit system: A model for other countries? In: The Modern Law Review, 82/6, S. 1034-1071.

#### IV. Bildungsherausforderungen des Scorings

---

- Martignon, Laura; Katsikopoulos, Konstantinos; Woike, Jan K. (2008): Categorization with limited resources: A family of simple heuristics. In: *Journal of Mathematical Psychology* 52/6. S. 352-361.
- Matz, Sandra C.; Kosinski, Michal; Nave, Gideon; Stillwell, David J. (2017): Psychological targeting as an effective approach to digital mass persuasion. In: *Proceedings of the National Academy of Sciences* 114/48. S. 12714-12719.
- Moriuchi, Emil (2019): "Social credit effect" in a sharing economy: A theory of mind and prisoner's dilemma game theory perspective on the two-way review and rating system. In: *Psychology & Marketing*. <https://doi.org/10.1002/mar.21301> <Zugriff 08.03.2020>
- Nassehi, Armin (2019): *Muster: Theorie der digitalen Gesellschaft*. München.
- Rahwan, Iyad; Cebrian, Manuel; Obradovich, Nick; Bongard, Josh; Bonnefon, Jean-Francois; Breazeal, Cynthia; Wellmann, Michael et al. (2019): Machine Behaviour. In: *Nature* 568/7753. S. 477-486.
- Rainie, Lee; Anderson, Janna (2017): Code-Dependent: Pros and Cons of the Algorithm Age. In: Pew Research Center. <https://www.pewresearch.org/internet/2017/02/08/code-dependent-pros-and-cons-of-the-algorithm-age/> <Zugriff 15.01.2020>
- Rebitschek, Felix G.; Gigerenzer, Gerd (2020): Einschätzung der Qualität digitaler Gesundheitsangebote: Wie können informierte Entscheidungen gefördert werden? In: *Bundesgesundheitsblatt – Gesundheitsforschung – Gesundheitsschutz*, 63(6). S. 665-673. <https://doi.org/10.1007/s00103-020-03146-3> <Zugriff 08.9.2020>
- Rebitschek, Felix G.; Gigerenzer, Gerd; Wagner, Gert G. (in Vorbereitung): People underestimate the errors by algorithms for credit scoring and recidivism but tolerate even fewer errors: A representative study in Germany.
- Rebitschek, Felix G.; Groß, Christian; Keitel, Ariane; Brümmer, Martin; Gigerenzer, Gerd; Wagner, Gert G. (2018): Dokumentation einer empirischen Pilotstudie zum Wissen über und zur Bewertung von Verbraucher-Scoring. Arbeitspapier des Sachverständigenrats für Verbraucherfragen. Berlin.
- Rebitschek, Felix G.; Jenny, Mirjam A.; McDowell, Michelle (in Vorbereitung): Risikokompetenz in sechs europäischen Ländern.
- Rebitschek, Felix G.; Reisel, Daniel; Lein, Ines; Wegwarth, Odette (2019): Epigenetic Risk Assessment of Female Cancers: Women's Information Needs and Attitudes. In: *Public Health Genomics* 22/1-2. S. 46-57.
- RisikoAtlas (2020): Ein Forschungsprojekt zur Förderung der Risikokompetenz. <https://www.risikoatlas.de> <Zugriff 15.01.2020>

Universität Helsinki; Reaktor (2019): Elements of AI. <https://www.elementsofai.de/> <Zugriff 15.01.2020>

Schubert, Sigrid; Schwill, Andreas (2011): Didaktik der Informatik. Heidelberg.

Stacey, Dawn; Légaré, France; Lewis, Krystina; Barry, Michael J.; Bennett, Carol L.; Eden, Karen B.; Trevena, Lyndal et al. (2017): Decision aids for people facing health treatment or screening decisions. In: Cochrane Database of Systematic Reviews 4. [https://cccr.org.cochrane.org/sites/cccr.org.cochrane.org/files/public/uploads/decision\\_aids\\_february\\_2018.pdf](https://cccr.org.cochrane.org/sites/cccr.org.cochrane.org/files/public/uploads/decision_aids_february_2018.pdf) <Zugriff 08.03.2020>

SVRV (2017): Digitale Souveränität. Gutachten des Sachverständigenrats für Verbraucherfragen. Berlin. [https://www.svr-verbraucherfragen.de/wp-content/uploads/Gutachten\\_Digitale\\_Souveränität\\_.pdf](https://www.svr-verbraucherfragen.de/wp-content/uploads/Gutachten_Digitale_Souveränität_.pdf) <Zugriff 08.03.2020>

SVRV (2018): Verbrauchergerechtes Scoring. Gutachten des Sachverständigenrats für Verbraucherfragen. Berlin. <https://www.svr-verbraucherfragen.de/dokumente/verbrauchergerechtes-scoring/> <Zugriff 08.03.2020>

## Anmerkungen

- <sup>1</sup> Das Konzept wird aus Gründen der Vereinfachung an dieser Stelle von den Herausgebern übernommen.
- <sup>2</sup> Der Rechtsbegriff zur informierten Einwilligung in Geschäftsbedingungen im Sinne von Verträgen wird an dieser Stelle nicht diskutiert, da sich die vorgestellten Konzepte nicht an der Durchsetzung bestehender und an anpassungsbedürftiger Regulation zum Scoring (SVRV 2018) orientieren, sondern am Ziel informierter Bürger(innen), die zukünftig auf Regulation einzuwirken vermögen.