

*Felix G. Rebitschek**

Kompetenzförderliche Entscheidungsunterstützung in unsicheren Verbraucherumwelten

Teil 1: Das Ausgangsproblem sind unsichere Verbraucherumwelten

Menschliche Entscheidungen, zum Beispiel für den Konsum von Waren oder Dienstleistungen, hängen von dem Suchen und Finden von qualitätsgesicherten, objektiv erforderlichen und subjektiv benötigten Informationen ab (Fritz & Thiess, 1986), die in ihrer Verbraucherumwelt platziert oder verborgen sind. Diese ist meist von einem Überangebot an Informationen gekennzeichnet (Lee & Lee, 2004). Solche Verbraucherumwelten sind instabil, da sie permanenten Modifikationen unterworfen sind. Eine für den Verbraucher bzw. die Verbraucherin unüberschaubare Anzahl von soziotechnischen Architekten kuratiert mit Hilfe von Algorithmen diese Informationsumgebungen (Friedewald, Lamla, & Roßnagel, 2017), fügt Bewertungssysteme ein (Lamla, 2021), und bildet dabei die Dynamik von Angebot und Nachfrage zu Informationsangeboten, Produkten und Dienstleistungen ab. Dabei ist die Marketing-getriebene Gestaltung dieser Verbraucherumwelten in vielen Fällen schlicht intransparent (Gigerenzer, Rebitschek, & Wagner, 2018) oder manipulativ (dark patterns, Mathur, Kshirsagar, & Mayer, 2021). Ein Beispiel ist der „Markt“ für digitale Gesundheitsinformationen, auf dem interessengeleitete (Lux et al., 2017), Falsch- und Desinformationen sowie qualitätsgerechte Informationen nach den Standards der evidenzbasierten Gesundheitskommunikation (Arbeitsgruppe GPGI, 2016; Lühnen et al., 2015) zusammentreffen. Dabei sind nicht nur abzubildenden Sachfragen oftmals unvermeidbar lückenhaft (epistemische Unsicherheiten) und sich schrittweise entwickelnde Erkenntnisse, wie in der Corona-Pandemie, sollten kommuniziert werden (Blastland, Freeman, van der Linden, & Marteau, 2020), z.B. um Vertrauensverlusten entgegenzuwirken (Dries, McDowell, Rebitschek, & Leuker, 2024). Auch die Auswahl und Auffindbarkeit der Gesundheitsinformationen grundsätzlich wird durch die privaten und öffentlichen Anbieter kontinuierlich verändert.

* Harding-Zentrum für Risikokompetenz, Fakultät für Gesundheitswissenschaften Brandenburg, Universität Potsdam, Potsdam, Deutschland. Max-Planck-Institut für Bildungsforschung, Berlin, Deutschland. Korrespondenzanschrift: rebitschek@uni-potsdam.de

In Summe besteht für den einzelnen Verbraucher bzw. die Verbraucherin eine erhebliche Unsicherheit darin, welches Angebot er oder sie wählen sollte und welches nicht.

Die Realität ist, dass die meisten Verbraucherentscheidungen von Natur aus Situationen sind, in denen die Entscheidungsträger und Entscheidungsträgerinnen mit radikaler Unsicherheit umgehen müssen, denn wissenschaftliche Evidenz über vergleichbare Konsequenzen der Nutzung von spezifischen Produkten, Marken und Dienstleistungen ist eher die Ausnahme. Daher sind auch nicht die Fähigkeiten, um die statistische Struktur des Risikos möglichst differenziert zu erfassen, ausschlaggebend. Um besser zu entscheiden, sind Fähigkeiten erforderlich, die einem helfen, Unsicherheit zu reduzieren und robuste Strategien einzusetzen. Robust bedeutet, dass sie gerade auch unter instabilen Entscheidungsbedingungen erfolgversprechend sind, wenn zum Beispiel früher gültige Zusammenhänge nicht mehr gültig sind.

Die Unterscheidung zwischen Problemen des Risikos und der Unsicherheit wird in der Verbraucherforschung tatsächlich jedoch oft vernachlässigt, obwohl John Maynard Keynes und Frank Knight bereits 1921 in den Wirtschaftswissenschaften auf diese hinwiesen. Das Kontinuum, auf dem jedes Entscheidungsproblem angesiedelt werden kann, reicht von Risikoproblemen über Probleme der Mehrdeutigkeit bis hin zu Problemen radikaler Ungewissheit. Wenn alle Optionen und die Folgen des Verfolgens dieser Optionen bekannt sind – also die Wahrscheinlichkeiten des Eintretens dieser Folgen zumindest sehr zuverlässig geschätzt werden können – dann liegt ein Problem des Risikos vor. Diese wurden später auch als Wahlmöglichkeiten unter Risiko bzw. Entscheidungen unter Risiko beschrieben. Ein typisches Beispiel ist Roulette im Casino, in welchem die Gewinn- und Verlustchancen von Kombinationen von Farben und Zahlfeldern verhältnismäßig leicht bestimmt werden können.

Können die Eintrittswahrscheinlichkeiten hingegen nicht zuverlässig geschätzt werden oder sind Konsequenzen grundsätzlich nicht abschätzbar, liegt Unsicherheit vor. Ein deutliches Beispiel hierfür gibt die Anbahnung einer Paarbeziehung. Die Ungewissheit einer hypothetischen Beziehung mit dem unbekannten Menschen und zu vielen beachtenswerten Eigenschaften im Verhältnis zum möglichen eigenen Erfahrungsschatz erlauben keine echten Folgenabschätzungen oder differenzierte Gewichtungen.

Die konzeptionelle Unterscheidung von Risiko und Ungewissheit ist für die Darstellung und Behandlung von Entscheidungsproblemen, aber auch für die Ausbildung von geeigneten Kompetenzen von entscheidender Bedeutung. Die Anwendung eines zuverlässigen Risikomodells auf ein Problem mit radikaler Un-

gewissheit kann beispielsweise zu weitreichenden Analysefehlern führen (Neth et al., 2014). In der Forschungsliteratur der Psychologie (Gigerenzer & Selten, 2014) und den Wirtschaftswissenschaften und Verhaltensökonomie (Mousavi & Gigerenzer, 2014, 2017) wird die entscheidende Rolle der Unterscheidung reflektiert. Letztlich ist unvermeidbar: Eine erfolgreiche Entscheidungsfindung unter Ungewissheit hängt von der Anpassung der gewählten Entscheidungsstrategien an die Entscheidungsumwelt ab (Simon, 1990).

Teil 2: Entscheidungsstrategien für ungewisse Verbraucherumwelten

Wie wählen Verbraucher und Verbraucherinnen objektiv bedarfsgerechte, subjektiv bedürfnisgerechte und vor allem qualitätsgesicherte Informationen für ihre Entscheidungen unter Ungewissheit? Die Frage, die man für die Suche nach der Antwort, zuerst beantworten muss, lautet: Wie entscheiden Experten und Expertinnen kompetent unter Ungewissheit? Eine zentrale Rolle nehmen hier die Heuristiken ein, einfache Entscheidungsregeln, die eine schnelle Entscheidung ermöglichen und dabei als kognitive Strategien einen Teil der verfügbaren Informationen ignorieren. Sie haben einen festen Platz im methodischen Repertoire professioneller Entscheider und Entscheiderinnen (z.B. Artinger et al., 2015). Gerd Gigerenzer, Jochen Reb und Shenghua Luan (2022) haben dies am Beispiel der Personalrekrutierung zuletzt anschaulich illustriert. Hiernach setzten Elon Musk bzw. Jeff Bezos auf heuristische Hinweise auf außergewöhnliche Fähigkeiten bzw. zusätzlich persönliche Bewunderung und Team-Performance-Veränderung, um die Ungewissheit beim einzelnen Jobkandidaten zu reduzieren. Analog können Experten und Expertinnen für evidenzbasierte Gesundheitsinformationen eine digitale Angebotslage von Gesundheitsinformationen sehr gut und besonders schnell durchleuchten.

Nicht nur Gerd Gigerenzer und Kollegen zeigten die wichtige Rolle einfacher Entscheidungsstrategien ausgebildeter Experten – doch wenn sie das Ergebnis tausender Stunden Erfahrung sind, wie können Laien davon profitieren? Zwingend sind Ansätze der institutionellen Bildung sowie klassische Förderansätze von Digital- und Medienkompetenzen bis hin zu digitaler Gesundheitskompetenz, wenn es um Verbraucherfragestellungen in der digitalen Welt geht. Einzuräumen ist jedoch auch, dass die Erreichbarkeit von Verbrauchern, die weder Bildungseinrichtungen besuchen noch Verbraucherbildungsformate aufsuchen, extrem begrenzt ist. Die Gruppe der 40 bis 60-Jährigen – von denen wiederrum die wenigsten studieren oder eine Volkshochschule besuchen – stellte 2022 etwa

den größten Anteil der Bevölkerung (Statistisches Bundesamt, 2024). Der einzelne Verbraucher bzw. Verbraucherin braucht die Unterstützung im Alltag.

Daraus ergibt sich der zentrale Lösungsvorschlag, langjährige Erfahrung von Experten und Expertinnen für eine kompetenzförderliche Entscheidungsunterstützung in den Verbraucherentscheidungen des Alltags nutzbar zu machen (Rebitschek, 2024).

Kompetenzförderliche Entscheidungsunterstützung lässt sich durch den Begriff des Boostings beschreiben, gemäß welchem transparente Werkzeuge die Handlungsfähigkeit des Verbrauchers bzw. der Verbraucherin erhöhen und zugleich im aktiven Handeln unterstützen (Herzog & Hertwig, 2019). Boosts zielen dabei auf die Kognition des bzw. der Einzelnen und/oder seine bzw. ihre Gestaltung der eigenen Entscheidungsumwelt (Hertwig & Grüne-Yanoff, 2017). Beispiele sind Entscheidungsbäume, natürliche Häufigkeitsbäume, Lesestrategien oder auch Faktenboxen (<https://www.scienceofboosting.org/tag/digital>). Würde man also mit Hilfe von erfahrenen Expertinnen und Experten solche Boosts entwickeln (z.B. wie im Verbraucherforschungsprojekt RisikoAtlas, Harding Center for Risk Literacy, 2020a) und diese den Verbrauchern und Verbraucherinnen zur Verfügung stellen (z.B. als App, Harding Center for Risk Literacy, 2020b), könnten sie von Entscheidungsunterstützung unter Ungewissheit profitieren. Erwarten lässt sich, dass transparente Werkzeuge schrittweise durch deren Anwendung verinnerlicht werden, sodass sie irgendwann gar nicht mehr in der aktiven Handlung aufgerufen werden müssen.

Nur welche Boosts sind geeignet, die Unsicherheit zu reduzieren? „Fast-and-frugal trees“: Eine Klasse von Algorithmen in Form schnell einsetzbarer und sparsamer Entscheidungsbäume (FFTs) (Martignon, Vitouch, Takezawa, & Forster, 2003). Diese Art von Algorithmus zielt darauf ab, einen Entscheidungsprozess auf eine Handvoll hoch prädiktiver Kombinationen von Hinweisen zu reduzieren, die als Cues bezeichnet werden. Verbraucherinnen und Verbraucher können Entscheidungsoptionen robust klassifizieren. Sie können zum Beispiel feststellen, ob ihnen mit Hilfe einer aufgefundenen Gesundheitsinformation eine informierte Entscheidung möglich ist (Rebitschek & Gigerenzer, 2020), indem sie das Vorhanden- oder Nichtvorhandensein bestimmter Hinweise überprüfen (zum Beispiel die Angabe von numerischer Evidenz). Jeder Hinweis führt entweder zum nächsten Hinweis oder zu einem Ausgang (zum Beispiel einer Entscheidung), der nicht wieder aufgehoben werden kann (nicht-kompensatorisches Modell). Die FFTs werden in feststehender Reihenfolge abgearbeitet (lexikographisch). Im Gegensatz zu Entscheidungsbäumen im Allgemeinen gibt es bei FFTs keine Verzweigungen – mit Ausnahme des letzten Hinweises, der in zwei Optionen verzweigt

(Martignon, Katsikopoulos, & Woike, 2008). Dementsprechend endet letztlich jeder FFT in Klassifizierungen, Entscheidungen oder Handlungsempfehlungen. FFTs beschränken sich auf ein Minimum an prädiktiven Hinweisen, was FFTs zu einer Art formaler Heuristik macht (Gigerenzer & Gaissmaier, 2011). In der Tat kann heuristisches Entscheiden von Experten und Expertinnen durch geeignete Verfahren analysiert und in FFTs formalisiert beschrieben werden (Keller et al., 2014).

Forschungen im Finanzwesen (Aikman et al., 2014), in der Medizin (Green & Mehr, 1997), in der Psychiatrie (Jenny, Pachur, Williams, Becker, & Margraf, 2013) und zu militärischen Fragestellungen (Keller, Czienkowski, & Feufel, 2014) haben gezeigt, dass FFTs schnelle und zuverlässige Entscheidungen ermöglichen – sie schneiden ähnlich gut ab wie komplexere Modelle (z.B. logistische Regression, Random Forest Tree und Support Vector Machine). Am Beispiel der Gesundheitsinformationen für eine informierte Gesundheitsentscheidung wurde etwa gezeigt, dass eine beschränkte Prüfung von maximal vier Hinweisen ausreicht, um neun von zehn nicht-informierende Angebote auszusortieren (vor der Corona-Pandemie, welche die Informationslandschaft im deutschsprachigen Markt für Gesundheitsinformationen veränderte); obwohl immer auch informierende Angebote Gefahr laufen, falschlicherweise aussortiert zu werden, Rebitschek & Gigerenzer, 2020. Wichtiger statt solcher Gütenachweise in Form von Akkurateität ist allerdings die Wirksamkeit (effectiveness). Ein Laborexperiment mit 204 Teilnehmern und Teilnehmerinnen, die im Mittel 40 Jahre alt waren (16 Jahre Standardabweichung), zeigt, dass drei beauftragte Internetrecherchen zu Antibiotika bei Erkältungen, Eierstockkrebsvorsorge und zur Impfung gegen Masern, Mumps und Röteln deutlich erfolgreicher hinsichtlich qualitätsgesicherter Informationen waren, wenn Teilnehmenden ein Fast-and-frugal tree gegeben wurde. Damit hatten diese die Unsicherheit um die Ergebnistreffer ihrer Recherche reduzieren können (Rebitschek, 2024).

Entscheidender für den Erfolg dieser Methode sind jedoch wahrscheinlich weniger die Güteeigenschaften als die verständliche Transparenz des Werkzeugs selbst. Als interpretierbare Modelle, die transparent sind und diejenigen, die sie verwenden, aufklären, unterstützen Fast-and-Frugal Trees eigenverantwortliches Handeln von Verbrauchern und Verbraucherinnen. Sie können als grafisch aufbereitete Baumstruktur sowohl digital in Apps, auf Websites als auch analog auf Plakaten und Broschüren verwendet werden. Sie können einfach weitergegeben, Schülerinnen und Schülern erklärt und vom einzelnen Anwender bzw. der Anwenderin erinnert werden.

Auf den Punkt gebracht: Fast-and-Frugal-Trees vermitteln den Blick des Experten bzw. der Expertin auf ein unsicheres Problem, indem sie die Erfahrung und Intuition langjähriger Experten kondensieren und formalisieren. Sie bieten eine heuristisch hoch valide und zugleich verständliche Prüfkombination, mit der Verbraucher und Verbraucherinnen die Spreu vom Weizen trennen können und zugleich ihre Kompetenzen stärken, auch ohne das Werkzeug zukünftig so zu handeln. Dem folgend stellt sich die Frage, was erforderlich ist, damit eine systematische Verbraucherschutzstrategie entwickelt und auf nationaler Ebene implementiert werden kann.

Teil 3: Assistierte Unsicherheitsreduktion als Verbraucherschutzstrategie mit Hilfe von KI realisieren

Die Modellierung von präskriptiven Modellen, deren Einsatz hilft, die Unsicherheit um Optionen zu reduzieren, setzt einen Datensatz mit Probleminstanzen, Entscheidungshinweisen und Zielvariablen (z.B. unproblematische und problematische Gesundheitsinformationen) voraus. Bei der Entscheidungsfindung von Verbrauchern sind nutzbare und vor allem repräsentativ valide Datensätze in hochdynamischen und algorithmengesteuerten Entscheidungsumgebungen die Ausnahme. Alternativ müssen Entwickler also Problemfälle aus der Umgebung entnehmen, Entscheidungshinweise auf der Grundlage von Experten und Literatur auswählen und Zielvariablen sammeln oder untersuchen (Keller et al., 2014).

Ein expertenbasierter Entwicklungsprozess nach dem Vorbild des Projekts RisikoAtlas, welches Verbraucherschutzorganisationen Methoden und Instrumente zur Unterstützung der Verbraucher und Verbraucherinnen unter Risiko und Unsicherheit an die Hand gibt (Harding Center for Risk Literacy, 2020a; Rebitschek, 2024) lässt sich heute durch die Fortschritte bei den generativen Modellen (z.B. ChatGPT), konkret mit Hilfe der large language models (LLM) zur Analyse von Textdaten bzw. Webseiten-Daten (Chew et al., 2023; Tai et al., 2024) einrichten und implementieren. Folgende Teilprozesse gehören dazu:

- Prozesse der Problemdefinition, auf die eine Entscheidungsunterstützung angewendet werden soll, sowie zur Feststellung des Charakters der Ausgabe der Entscheidungsunterstützung, d.h. Empfehlung oder Anweisung, z.B. konkrete Verbrauchersituationen und Entscheidungsprobleme; u.a. mit Hilfe von Expertenworkshops

- Prozesse der Auswahl und Operationalisierung von Zielvariablen und ihrer wünschenswerten Ausprägungen, z.B. leitlinienbasierte Qualitätsvorgabe, u.a. mit Hilfe von Expertenworkshops
- Repräsentative Sampling- und Vermessungsprozesse für die Entscheidungsfälle und ihre Entscheidungsumwelten; welche Regelmäßigkeiten gibt es; hierbei erlauben LLMs zum einen mittels Schnittstellen ein Crawling und Charakterisieren von digitalem Material (z.B. Text- zu Tabulardaten) und zum anderen Analysen, welche Hinweise wie oft und gemeinsam auftreten
- Ermittlung von Kandidaten-Hinweisen durch systematische Recherche prozesse in Fachliteratur, grauer Literatur und spezifischer Experten-Workshop-Formate
- Prozesse zur Überprüfbarkeit und Verständlichkeit von Hinweisen aus Laiensicht
- Prozesse, um jeden Hinweis-Status (Vorhandensein, Abwesenheit, ggf. Abstufung) für jeden beobachteten Fall zu kodieren; dies ist ein zentraler Anwendungsfall von LLM, welche eine qualitative Kodierung von beliebigen digitalen Materialien ermöglichen einschließlich Ton- und Videoaufnahmen
- Statistische Auswahl von prädiktiven Hinweisen
- Prozesse zur Feststellung der Qualität eines jeden beobachteten Falls anhand der wünschenswerten Ausprägungen, z.B. mit Hilfe von Expertenworkshops
- Modellierungs- und Validierungsprozesse, z.B. mit Hilfe von Algorithmen für maschinelles Lernen (Phillips et al., 2017).
- Fehlerkostenanalyse-Prozesse, gemäß welcher festgestellte werden muss, welche Stakeholder-Gruppen von Fehlklassifikationen in welcher Weise betroffen sein könnten; z.B. mit Hilfe von Expertenworkshops
- Wirksamkeitstestungen in Form randomisiert-kontrollierter Experimente mit den geplanten Nutzerinnen und Nutzern

LLM sind ein einzigartiger Hebel, um eine ökonomisch effiziente Surveillance der verbraucherrelevanten Angebotsmärkte zu leisten. So ließen sich zum Beispiel die Verteilungen von Hinweisen auf Internetseiten oder in Videos mit Bezug zu einer bestimmten Qualitätsrichtlinie verfolgen. Ein theoretisches Beispiel wäre es, zu messen, wie viele Informationsseiten zu einem bestimmten Zeitpunkt auf ausgewählte Falschinformationen verweisen. In Verbindung mit spezifischen Experten-Konsultationsprozessen (Harding Center Risk Literacy, 2020a) sind kontinuierliche Modellierungen von präskriptiven Unterstützungswerkzeugen für bestimmte Verbraucherfragestellungen möglich.

Alle Feststellungen in diesem Kapitel laufen auf die Frage hin, welche Organisationen bzw. welches Netzwerk die „assistierte Unsicherheitsreduktion“ als Ver-

braucherschutzstrategie realisieren könnten. Potenzielle Multiplikatoren, welche Verbraucher und Verbraucherinnen erreichen, sollten Strategien für das Deployment bzw. die Dissemination solcher Werkzeuge entwickeln. Das schließt auch konkrete Evaluationsstudien vor- und nach Einführung ein. Wenn es gelingt, eine systematische Produktion (Entwicklung, Pilotierung, Validierung, Evaluation) von Unsicherheit-reduzierenden Assistenzwerkzeugen in Form eines wiedererkennbaren Formats zu den Verbraucherinnen und Verbrauchern zu bringen, würde das gravierende Verbesserungen bedeuten. Man würde die dominanten Ansätze der Verbraucherinformation, die vor allem versuchen, schlechten Informationen gute entgegenzusetzen, vorzugsweise auf eine neue Schutzebene überführen, die auf Unsicherheitskompetenzen als spezifische zu adressierende Herausforderung für den Verbraucheralltag fokussiert.

Limitationen. Wie alle Werkzeuge, die man entwickelt, um in instabilen Umwelten zu navigieren, können auch kompetenzfördernde Algorithmen immer nur von begrenzter Gültigkeit sein. Die Verbraucherumwelten sind wie oben ausgeführt dynamisch und die verwendeten Hinweise verlieren mit der Zeit ihre prädiktive Gültigkeit, die Spreu und den Weizen voneinander zu unterscheiden. Zum einen haben die Menschen in Deutschland Erwartungen und Wünsche an die Güte von Algorithmen, die der Entscheidungsunterstützung dienen (Rebitschek, Gigerenzer, & Wagner, 2021). Zum anderen können transparente Instrumente zur Entscheidungsunterstützung Opfer von manipulativen Strategien werden, welche das Instrument auszuspielen gedenken. Das bedeutet, wenn Informationsanbieter bzw. Entscheidungsarchitekten (Münscher, Vetter, & Scheuerle, 2016) lediglich die Erfüllung eines gewünschten Hinweises in Betracht ziehen (z.B. das Angeben von Quellen), ohne die Angebote tatsächlich zu verbessern. Infolgedessen sei an dieser Stelle eine abschließende Anmerkung gestattet: Diejenigen, welche Entscheidungsunterstützungen für Verbraucher und Verbraucherinnen entwickeln, sollten anstreben, nur Hinweise einzubeziehen, deren Erfüllung nicht nur prädiktiv, sondern kausal zwingend für zu erkennende Qualität ist. Jeder Versuch, von einem solchen Unterstützungsinstrument nicht aussortiert zu werden, kann dann nur noch darin bestehen, tatsächlich bessere Qualität anzubieten. Insofern könnten letztlich transparente Modelle wie die angestrebten Unterstützungsinstrumente performativ auf den Markt einwirken. Dies ist ein lohnender Untersuchungsgegenstand für die Verbraucherforschung in Deutschland.

Danksagungen

Teile der Forschung wurden im Rahmen des Projektvorhabens RisikoAtlas durchgeführt. Die Förderung dieses Vorhabens erfolgte aus Mitteln des Bundesministeriums der Justiz und für Verbraucherschutz (BMJV) aufgrund eines Beschlusses des deutschen Bundestages. Die Projektträgerschaft erfolgte über die Bundesanstalt für Landwirtschaft und Ernährung (BLE) im Rahmen des Programms zur Innovationsförderung. Ich danke Katharina Sawade für das Gelegenlesen des Manuskripts. Meine Dankbarkeit gilt ferner meinem verstorbenen Kollegen Professor Gert G. Wagner, welcher diese Verbraucherforschung auf ihrem Weg unterstützt hat.

Literaturverzeichnis

- Aikman, D., Galesic, M., Gigerenzer, G., Kapadia, S., Katsikopoulos, K., Kothiyal, A., ... & Neumann, T. (2021). Taking uncertainty seriously: simplicity versus complexity in financial regulation. *Industrial and Corporate Change*, 30(2), 317–345.
- Arbeitsgruppe GPGI (2016). Gute Praxis Gesundheitsinformation, Zeitschrift für Evidenz, Fortbildung und Qualität im Gesundheitswesen, 110–111, 85–92.
- Artinger, F., Petersen, M., Gigerenzer, G., & Weibler, J. (2015). Heuristics as adaptive decision strategies in management. *Journal of Organizational Behavior*, 36(SI), S33–S52.
- Blastland, M., Freeman, A. L., van der Linden, S., Marteau, T. M., & Spiegelhalter, D. (2020). Five rules for evidence communication. *Nature*, 587(7834), 362–364.
- Chew, R., Bollenbacher, J., Wenger, M., Speer, J., & Kim, A. (2023). LLM-assisted content analysis: Using large language models to support deductive coding. *arXiv preprint arXiv:2306.14924*.
- Dries, C., McDowell, M., Rebetschek, F. G., & Leuker, C. (2024). When evidence changes: Communicating uncertainty protects against a loss of trust. *Public Understanding of Science*, 09636625241228449.
- Friedewald, M., J. Lamla, and A. Roßnagel, Informationelle Selbstbestimmung im digitalen Wandel. 2017: Springer.
- Fritz, W., & Thiess, M. (1986). Das Informationsverhalten des Konsumenten und seine Konsequenzen für das Marketing. In F. Unger (Ed.), *Konsumentenpsychologie und Markenartikel* (pp. 141–176). Heidelberg: Physica-Verlag HD.
- Gigerenzer, G., Reb, J., & Luan, S. (2022). Smart heuristics for individuals, teams, and organizations. *Annual Review of Organizational Psychology and Organizational Behavior*, 9, 171–198.
- Gigerenzer, G., Rebetschek, F. G., & Wagner, G. G. (2018). Eine vermessene Gesellschaft braucht Transparenz. *Wirtschaftsdienst*, 98(12), 860–866.
- Gigerenzer, G., & Selten, R. (Eds.). (2002). *Bounded Rationality: The Adaptive Toolbox*. MIT press.
- Green, L., & Mehr, D. R. (1997). What alters physicians' decisions to admit to the coronary care unit?. *Journal of Family Practice*, 45(3), 219–227.

- Harding Center for Risk Literacy. (2020a). Projekt "RisikoAtlas". <https://www.risikoatlas.de/de/das-risikoatlas-projekt/forschung>
- Harding Center for Risk Literacy. (2020b). RisikoKompass. <https://www.risikoatlas.de/de/werkzeuge-und-methoden/informierte-informationssuche/app-zur-entscheidungsunterstuetzung/risikokompass?view=methode>
- Hertwig, R., & Grüne-Yanoff, T. (2017). Nudging and boosting: Steering or empowering good decisions. *Perspectives on Psychological Science*, 12, 973–986.
- Herzog, S. M. & Hertwig, R. (2019). Kompetenzen mit »Boosts« stärken. In C. Bala, M. Buddensiek, P. Maier & W. Schuldzinski (Hrsg.), *Verbraucherbildung: Ein weiter Weg zum mündigen Verbraucher* (S. 19–40). Verbraucherzentrale.
- Jenny, M. A., Pachur, T., Williams, S. L., Becker, E., & Margraf, J. (2013). Simple rules for detecting depression. *Journal of Applied Research in Memory and Cognition*, 2(3), 149–157.
- Keller, N., Czienkowski, U., & Feufel, M. A. (2014). Tying up loose ends: A method for constructing and evaluating decision aids that meet blunt and sharp-end goals. *Ergonomics*, 57, 1127–1139.
- Keynes, J. M. (1921). A treatise on probability. *Economic Journal*, 49, 558–568.
- Knight, F. H. (1921). *Risk, uncertainty, and profit*. Boston: Houghton Mifflin.
- Lamla, J. (2021). Kritische Bewertungskompetenzen. Selbstbestimmtes Verbraucherverhandeln in KI-gestützten IT-Infrastrukturen. Expertise für das Projekt „Digi tales Deutschland“ von JFF-Jugend, Film, Fernsehen eV, 31, 2021.
- Lee, B. K., & Lee, W. N. (2004). The effect of information overload on consumer choice quality in an on-line environment. *Psychology & Marketing*, 21(3), 159–183.
- Lühnen, J., Albrecht, M., Hanßen, K., Hildebrandt, J., & Steckelberg, A. (2015). Leitlinie evidenzbasierte Gesundheitsinformation: Einblick in die Methodik der Entwicklung und Implementierung. *Zeitschrift für Evidenz, Fortbildung und Qualität im Gesundheitswesen*, 109(2), 159–165.
- Lux, T., Breil, B., Dörries, M., Gensorowsky, D., Greiner, W., Pfeiffer, D., ... & Wagner, G. G. (2017). Digitalisierung im Gesundheitswesen—zwischen Datenschutz und moderner Medizinversorgung. *Wirtschaftsdienst*, 97(10), 687–703.
- Martignon, L., Katsikopoulos, K. V., & Woike, J. K. (2008). Categorization with limited resources: A family of simple heuristics. *Journal of Mathematical Psychology*, 52(6), 352–361.
- Martignon, L., Vitouch, O., Takezawa, M., & Forster, M. R. (2003). Naive and yet enlightened: From natural frequencies to fast and frugal decision trees. *Thinking: Psychological perspectives on reasoning, judgment and decision making*, 189–211.
- Mathur, A., Kshirsagar, M., & Mayer, J. (2021). What makes a dark pattern... dark? Design attributes, normative considerations, and measurement methods. *Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems*, 360, 1–18.
- Mousavi, S., & Gigerenzer, G. (2014). Risk, uncertainty, and heuristics. *Journal of Business Research*, 67(8), 1671–1678.
- Mousavi, S., & Gigerenzer, G. (2017). Heuristics are tools for uncertainty. *Homo Oeconomicus*, 34, 361–379.
- Münscher, R., Vetter, M., & Scheuerle, T. (2016). A review and taxonomy of choice architecture techniques. *Journal of Behavioral Decision Making*, 29(5), 511–524.

- Neth, H., Meder, B., Kothiyal, A., & Gigerenzer, G. (2014). Homo heuristicus in the financial world: From risk management to managing uncertainty. *Journal of Risk Management in Financial Institutions*, 7(2), 134–144.
- Phillips, N. D., Neth, H., Woike, J. K., & Gaissmaier, W. (2017). FFTrees: A toolbox to create, visualize, and evaluate fast-and-frugal decision trees. *Judgment and Decision Making*, 12(4), 344–368.
- Rebitschek, F. G., & Gigerenzer, G. (2020). Einschätzung der Qualität digitaler Gesundheitsangebote: Wie können informierte Entscheidungen gefördert werden?. *Bundesgesundheitsblatt-Gesundheitsforschung-Gesundheitsschutz*, 63, 665–673.
- Rebitschek, F. G. (2024). Boosting consumers: Algorithm-supported decision-making under uncertainty to (learn to) navigate algorithm-based decision environments. In *Knowledge and digital technology* (pp. 63–77). Cham: Springer Nature Switzerland.
- Rebitschek, F. G., Gigerenzer, G., & Wagner, G. G. (2021). People underestimate the errors made by algorithms for credit scoring and recidivism prediction but accept even fewer errors. *Scientific reports*, 11(1), 20171.
- Simon, H. A. (1990). Invariants of human behavior. *Annual review of psychology*, 41(1), 1–20.
- Statistisches Bundesamt (2024). Bevölkerung nach Altersgruppen. <https://www.destatis.de/DE/The men/Gesellschaft-Umwelt/Bevoelkerung/Bevoelkerungsstand/Tabellen/bevoelkerung-altersgruppen-deutschland.html>
- Tai, R. H., Bentley, L. R., Xia, X., Sitt, J. M., Fankhauser, S. C., Chicas-Mosier, A. M., & Monteith, B. G. (2024). An Examination of the Use of Large Language Models to Aid Analysis of Textual Data. *International Journal of Qualitative Methods*, 23, 16094069241231168.

