

Warum erfolgreiche Prognosen einfach und unsicher sind

Von der Wahl des richtigen Werkzeugs für Wähler und die Wahlforschung

Hansjörg Neth · Wolfgang Gaissmaier

1 Einleitung: Keine Experimente?

„Das Problem freier Wahlen besteht darin, dass man nie weiß, wie sie ausgehen.“ Dieser oft dem sowjetische Staatschef Leonid Breschnew zugeschriebene Satz (Rees 2006, p. 441) stammt vermutlich schon von dem früheren Regierungschef Wjatscheslaw Molotow,¹ nach dem auch eine improvisierte Brandwaffe benannt ist. Ungeachtet ihrer Herkunft hat die Aussage einen wahren Kern, der derzeit vor allem für Demoskopien und Wahlforscher Brisanz und Zündstoff birgt. Denn spätestens seit den misslungenen Prognosen für das britische Brexit-Referendum und die US-amerikanische Präsidentschaftswahl im Jahr 2016 fragen sich viele Menschen, ob sie den Modellen von Meinungsforschern überhaupt noch trauen sollten.

Angesichts von Kriegen, Klimawandel und Flüchtlingskrise sehnen sich viele Bürgerinnen und Bürger im Hinblick auf die bevorstehende Bundestagswahl nach Stabilität und Sicherheit (Ipsos 2017). Zugleich wecken tatsächliche oder vermeintliche Ungerechtigkeiten, sowie Skandale wie Dieselgate, Cyberattacken und brennende Autowracks auch Wünsche nach politischem Wandel und nähren Sympathien für neue politische Strömungen. Bereits 1957 warb Konrad Adenauer mit dem Slogan „Keine Experimente!“ für die Bewahrung und Sicherung des erreichten Wohlstands und erzielte mit der unverhohlenen Warnung vor einer Abkehr von konservativen

¹ Wikiquote: Leonid Brezhnev. https://en.wikiquote.org/wiki/Leonid_Brezhnev#Misattributed (Zugriff am 31.07.2017).

Dr. H. Neth (✉) · Prof. Dr. W. Gaissmaier
Sozialpsychologie und Entscheidungsforschung, Fachbereich Psychologie, Universität Konstanz,
Postfach 43, 78457 Konstanz, Deutschland
E-Mail: h.neth@uni-konstanz.de

Prof. Dr. W. Gaissmaier
E-Mail: gaissmaier@uni-konstanz.de

Werten das bislang beste Ergebnis einer Partei (eine absolute CDU/CSU-Mehrheit von 50,2 %).

Für Entscheidungswissenschaftler sind Wahlen – ungeachtet aller Warnungen – ein großartiges und größenwahnsinniges Experiment. Während wir sonst das Entscheidungsverhalten von Individuen und Gruppen in kontrollierten Laborsituationen erforschen, werden bei Wahlen die Meinungen von Millionen Menschen über mehrere Monate systematisch manipuliert und dann ein bundesweites Aggregat ihrer Mehrfachauswahlentscheidungen gebildet, das die Zusammensetzung von Parlament und Regierung und damit die Politik der nächsten Jahre determiniert. Auch wenn das Experiment ethisch nicht unbedenklich und seine Aussagekraft in Ermangelung einer Kontrollgruppe erheblich eingeschränkt ist, finden sich auf der gesamtgesellschaftlichen Ebene viele Elemente wieder, deren Mechanismen wir im mikroskopischen Maßstab aus unseren Studien kennen.

Bezüglich der menschlichen Sehnsucht nach Sicherheit haben wir vor jeder Empirie schon eine schlechte Nachricht: „In dieser Welt ist nichts gewiss, außer dem Tod und den Steuern“, schrieb der US-Staatsmann Benjamin Franklin bereits 1789, am Vorabend der französischen Revolution. Da dies – mit Sicherheit – auch heute noch gilt, bleibt alles andere im Leben leider ungewiss. Fatalerweise fördern verständliche Ängste und die allgegenwärtige Sehnsucht nach Gewissheit nicht nur religiöse oder esoterische Tendenzen, sondern sie führen auch zu systematischem Fehlverhalten von Menschen in Risikosituationen. Beispielsweise forderte die Furcht vor und Vermeidung von Flugreisen im Anschluss an die Terroranschläge des 11. September 2001 allein in den USA etwa 1600 zusätzliche Verkehrstote durch vermehrte Autofahrten (Gaissmaier und Gigerenzer 2012). Ob analoge Verhaltenstendenzen bei der Bundestagswahl zur vermehrten Flucht in extreme oder extrem vereinfachte Positionen führen werden, ist leicht denkbar, aber schwer vorhersagbar.

Zugleich bieten Erkenntnisse aus der Entscheidungswissenschaft zumindest für die Erforschung von Wählerverhalten auch eine positive Perspektive: Robuste Vorhersagen komplexer Phänomene sind möglich, aber erfordern – vielleicht paradoxerweise – vor allem einfache Modelle. Im Folgenden führen wir daher ein Plädoyer für einfache Modelle der Entscheidungsfindung, auch und gerade zur Prognose komplexer Sachverhalte. Ausgehend von einer grundsätzlichen Unterscheidung von verschiedenen Arten von Unsicherheit (Abschn. 2) argumentieren wir, dass Wahlausgänge nicht riskant, sondern fundamental ungewiss sind, und daher schon aus statistischen Gründen einfache Werkzeuge erfordern (Abschn. 3). Wir skizzieren beispielhaft einige extrem einfache Modelle, die trotz ihrer vermeintlichen Naivität erstaunlich gute Vorhersagen erzielen. Da wir selbst keine Wahlprognosen erstellen und auch nicht beanspruchen können, aktuell gebräuchliche demoskopische Modelle im Detail zu verstehen, sind wir froh und dankbar, wenn unser Beitrag den Expertinnen und Experten als Diskussionsanreiz und Anlass für eine methodische Reflexion dienen kann.

2 Arten von Unsicherheit: Risiko vs. Ungewissheit

*Zweifel ist keine angenehme Voraussetzung,
aber Gewissheit ist eine absurde.*

Voltaire (1770/1919, p. 232)

Logik und Statistik gelten völlig zu Recht als maßgebliche Errungenschaften der abendländischen Kultur (Gigerenzer et al. 1990; Hacking 1990). Sie darum aber zum alleinigen Maßstab für die Rationalität menschlicher Entscheidungen oder die Güte mathematischer Modelle zu erheben, beruht auf mindestens zwei Missverständnissen. Das erste Missverständnis besteht in der Annahme, dass Logik und Statistik die *einzigsten* Werkzeuge für rationales Entscheiden und Handeln seien. Solange man nur einen Hammer hat, sieht alles wie ein Nagel aus (Maslow 1966, p. 15 f.). Allerdings finden Forscher, die Rationalität als logische Konsistenz verstehen bzw. durch den Grad der Übereinstimmung von Wahlverhalten mit den Axiomen der Wahrscheinlichkeitsrechnung messen, vorwiegend menschliche Mängel und systematische Verzerrungen (vgl. das Forschungsprogramm der *heuristics and biases*, Tversky und Kahneman 1974). Aber neben Logik und Statistik existieren weitere nützliche Werkzeuge, die unter Umständen auch rationale Entscheidungen und erfolgreiche Vorhersagen ermöglichen. Eine adaptive Werkzeugkiste an evolutionär und individuell erworbenen Methoden und Strategien (Gigerenzer et al. 1999) enthält auch Heuristiken und Intuitionen, die oft pauschal als unpräzise oder fehleranfällig verunglimpft werden. Ein wesentlicher Grund für die Geringschätzung intuitiver Heuristiken wurzelt in dem zweiten Missverständnis – der Annahme, Logik und Statistik seien auf *alle* Arten an Problemen anwendbar. Aber bevor man ein Werkzeug anwendet, sollte man prüfen, ob die Voraussetzungen seiner Anwendung überhaupt gegeben sind. Immanuel Kants erkenntnistheoretische Frage „Was kann ich wissen?“ verlangt aus Sicht einer adaptiven Werkzeugkiste die Unterscheidung von mindestens drei verschiedenen Wissensbereichen (Neth und Gigerenzer 2015): Da Logik – zumindest in ihrer klassischen, deduktiven Variante – die Wahrheit ihrer Prämissen voraussetzt, ist sie fundamental konservativ und in der realen Welt eher von theoretischem als praktischem Wert (z. B. als mächtiges Werkzeug der Argumentation und Beweisführung).

Jenseits garantiert wahrer Prämissen beginnt das Wagnis induktiver Inferenzen und damit das Reich der Statistik. Allerdings setzt auch die Wahrscheinlichkeitstheorie eine begrenzte und überschaubare Situation voraus. In seinen *Foundations of Statistics* betont Savage (1954, p. 16) explizit, dass seine Axiomatik für eine „small world“ ohne Überraschungen konzipiert sei und bereits die Planung eines Picknicks ihren Geltungsbereich überschreite. Natürlich hindert uns niemand daran, auch das Wetter, Aktienkurse oder Wahlausgänge mittels statistischer Methoden vorherzusagen, doch wir sollten uns bewusst sein, dass wir uns dabei auf unsicheres Terrain begeben, in dem die Gültigkeit der statistischen Axiome nicht mehr garantiert ist. Der bekannteste Versuch, diese Grenzüberschreitung begrifflich zu fassen, stammt von Knight (1921), der zwischen Risiko und Unsicherheit unterschied. Sind alle möglichen Ergebnisse einer Entscheidung und die Wahrscheinlichkeiten ihres Eintritts bekannt, liegt eine Situation *unter Risiko* vor. Hier lohnen sich der Einbezug

vieler Daten, statistisches Abwägen und komplexe Berechnungen mittels mathematischer Modelle.

2.1 Risiko ermöglicht Berechnung und erfordert Kompetenz als Schutz vor Manipulation

Ein prototypisches Beispiel für eine Alltagssituation, bei der Entscheidungen unter Risiko gefordert sind, ist der Arztbesuch. Wenn man ab einem Alter von 50 Jahren als Mann zum PSA-Test (zur Früherkennung von Prostatakrebs) oder als Frau zur Mammografie (zur Früherkennung von Brustkrebs) ermutigt wird, ermöglicht eine Fülle von Studien eine informierte Entscheidung über den Nutzen und Schaden dieser Verfahren. Obwohl es sich bei Fragen der Gesundheit um einen sensiblen und emotionalen Bereich handelt, tut man hier gut daran, dem Impuls zu blindem Vertrauen in ärztliche Kompetenz und die heilbringende Wirkung medizinischer Maßnahmen zu widerstehen. Denn während die Allgemeinbevölkerung den Nutzen von Früherkennung drastisch überschätzt (Gigerenzer et al. 2009), sind auch Ärzte meist nicht in der Lage, ihre tatsächlichen Chancen und Risiken zu verstehen und transparent zu kommunizieren (Wegwarth et al. 2012). Weil noch weitere Akteure – wie z. B. Krankenversicherungen und Pharmakonzerne – Interessen verfolgen, die nicht unbedingt denen der Patienten entsprechen, ist man als Betroffene/r einer verwirrenden Vielfalt an Einflüssen und Überzeugungsversuchen ausgesetzt (Gigerenzer et al. 2007). In diesem Dickicht verschiedenster Behauptungen, Meinungen und Manipulationen ist statistische Abstraktion sinnvoll, zumal hier belastbare Daten existieren. Im Fall des PSA-Tests und der Mammografie kommen nüchterne Abwägungen meist zu dem Schluss, dass der Schaden dieser Maßnahmen deren Nutzen übersteigt, sofern man keiner Risikogruppe angehört (Schröder et al. 2014; Gøtzsche und Jørgensen 2013).

Obwohl statistische Kompetenz eine zentrale Voraussetzung für informierte Entscheidungen mündiger Bürger ist, wird in Schule und Ausbildung noch immer vorrangig die Mathematik der Sicherheit gelehrt (Gigerenzer und Martignon 2015). Aber während wir als Erwachsene von Algebra bis Trigonometrie meist nur noch die Grundrechenarten brauchen, rächt sich der stiefmütterliche Unterricht in Statistik bereits, wenn man die Tagesnachrichten hört. Von der Schätzung eines Wahlausgangs, dem Risiko einer erneuten Finanzkrise, der vermeintlichen Sicherheit des Rentensystems bis zur morgigen Regenwahrscheinlichkeit stecken Medienberichte voller Statistiken, die Otto Normalverbraucher nur ansatzweise verstehen kann. Vor allem der Wechsel zwischen alternativen Darstellungsformaten bietet zahlreiche Möglichkeiten zur Manipulation von Botschaften. Wenn die Erhöhung eines absoluten Risikos (z. B. einer venösen Thromboembolie nach Einnahme der Antibabypille der 3. Generation) von 1 in 7000 auf 2 in 7000 alarmierend als „Verdopplung des Risikos“ oder „Steigerung um 100 %“ dargestellt wird oder die Weltgesundheitsorganisation WHO meldet, dass der tägliche Konsum von 50 g verarbeiteten Fleisches das Darmkrebsrisiko „um 18 %“ erhöhe (vgl. Bauer et al. 2014), darf man nicht nur unverantwortliche Journalisten rügen, die immerhin von derart verwurstelten Schlagzeilen leben, sondern muss sich auch fragen, warum nur ein Bruchteil der Bürger in der Lage ist diese statistischen Taschenspielertricks zu durchschauen.

Gesellschaftlich bedenklich wird statistische Ignoranz, wenn eine (zumindest aktuell in Europa) tatsächlich hohe bedingte Wahrscheinlichkeit p (Muslim | Terrorist) mit der umgekehrten und sehr geringen bedingten Wahrscheinlichkeit p (Terrorist | Muslim) vermischt oder verwechselt wird. Dabei würden die meisten Personen, die in Moscheen primär terroristische Brutstätten sehen, sofort verstehen, dass aus p (männlich | Bundespräsident) = 1 keineswegs folgt, dass auch p (Bundespräsident | männlich) = 1. Angesichts der aktuellen Diskrepanz zwischen dem vorhandenen Volumen und der angetroffenen Kompetenz im Umgang mit statistischen Informationen darf nicht verwundern, dass der Begriff „Risiko“ laut einer repräsentativen Umfrage zu 60 % als „unsympathisch“ empfunden wird (Allensbach 2015, p. 10).

2.2 Ungewissheit erfordert Heuristiken und Intuition

Wenn wir uns fragen, wen wir – zum Partner, als Politiker oder als Partei – wählen sollten und was die Zukunft wohl bringt, dann fehlen uns wichtige Informationen. Sind nicht alle verfügbaren Optionen sowie deren Wahrscheinlichkeiten und Konsequenzen bekannt und auch keine belastbaren Daten zur Schätzung unbekannter Variablen vorhanden, verlassen wir das Reich des Risikos und begeben uns in die viel weitläufigeren Gefilde der Ungewissheit. Da bereits Risiko einige Unbekannte enthält, lässt sich *Ungewissheit* auch als eine kontinuierliche Dimension denken, deren Pole von berechenbarem *Risiko* bis zur völligen *Ungewissheit* reichen (vgl. Abb. 1).

Unter Ungewissheit helfen präzise Datenanalysen und statistische Berechnungen prinzipiell nicht weiter. Weil jede Berechnung mit zu vielen Unbekannten scheitern würde, verlangen ungewisse Situationen nach intuitiven Strategien, die auf Erfahrung basieren und gezielt Informationen auswählen. *Heuristiken* sind einfache Regeln, die Informationen ignorieren, um Entscheidungen schneller, sparsamer und mit größerer Genauigkeit zu treffen (Gigerenzer und Gaissmaier 2011). Der Zusatz der größeren Genauigkeit mag überraschen, denn Heuristiken werden oft als Abkürzungen dargestellt, die zwar Energie und Zeit sparen, aber zu systematischen Fehlern führen (z. B. Kahneman 2012). Doch dieser Generalverdacht gegenüber Heuristiken ist vorschnell und meist unbegründet, da die empirische Evidenz eher für die Überlegenheit von Heuristiken spricht (Gigerenzer et al. 2011) und die Voraussetzungen für alternative Strategien – also Sicherheit oder Risiko – im Alltag sowieso kaum gegeben sind.

Wie wir anderswo ausführlicher dargestellt haben (Gaissmaier und Neth 2016) hängt der Erfolg von Heuristiken vor allem von der *Passung* zwischen den Gegebenheiten einer Situation und den spezifischen Fähigkeiten und Fertigkeiten der sie anwendenden Person ab. Scheinbar primitive Strategien, wie etwa die Präferenz für wiedererkannte Objekte oder Personen, können sehr erfolgreich sein, wenn in der Umwelt, in der diese Strategie angewendet wird, Unwissen (also das Nichtwiedererkennen von Objekten) systematisch statt zufällig ist. Ein systematischer Zusammenhang zwischen Wiedererkennen und Erfolg existiert in vielen Bereichen, etwa bei sportlichen Wettbewerben und in ökonomischen Konkurrenzsituationen (vgl. Goldstein und Gigerenzer 2009; sowie Marewski et al. 2010, 2011).

Hat man sich erfolgreich von dem Leibnizschen Traum verabschiedet, dass es ein universelles Werkzeug für alle Arten von Entscheidungen gibt, dann besteht die

Theorie: Was kann ich wissen? In welcher Art von Situation befinde ich mich?

Risiko:

Alternativen, Konsequenzen und
Wahrscheinlichkeiten sind *bekannt*
stabile und vorhersagbare Welt
wenige Risikofaktoren
viele Daten

Ungewissheit:

Alternativen, Konsequenzen oder
Wahrscheinlichkeiten sind *unbekannt*
instabile, komplex vernetzte Welt
viele Risikofaktoren
wenige Daten

Kontinuum der *Unsicherheit*



Komplexe Modelle

statistisches Denken

Einfache Modelle

Heuristiken und Intuition

Praxis: Was soll ich tun? Welches Werkzeug und welche Strategien sind angemessen?

Abb. 1 Die Kunst guten Entscheidens und erfolgreicher Prognosen besteht in der Passung zwischen Theorie und Praxis und der Auswahl eines zur aktuellen Situation passenden Werkzeugs. Das Ausmaß an *Unsicherheit* (als Überbegriff von *Risiko* und *Ungewissheit*) ist als Kontinuum dargestellt, auf dem verschiedene Ausprägungsgrade möglich sind (nach Gigerenzer 2013)

Kunst guten Entscheidens vor allem in der erfolgreichen Bestimmung der eigenen Position entlang des Kontinuums an Unsicherheit und der Wahl des richtigen Werkzeugs, das für die aktuelle Umwelt angemessen ist. Die Passung zwischen Strategie, Umwelt und menschlichen Fähigkeiten wird als *ökologische Rationalität* (Todd et al. 2012) bezeichnet und offenbart in ihrem Zusammenspiel den eigentlichen Wert von Erfahrung. In einem adaptiven Lernprozess passen sich Menschen und ihre Methoden über Jahre oder gar Generationen so an ihre Umwelt an, dass eigentlich hochkomplexe Prozesse automatisch, einfach und intuitiv erscheinen. Verfügen Experten über einschlägige Erfahrung in einem Bereich, können sie selbst auf der Basis kleiner Informationsmengen sehr schnell entscheiden und dennoch erfolgreich handeln (Shanteau 1992; Sherbino et al. 2012).

Für die Verbesserung wissenschaftlicher Prognosen bietet die Perspektive ökologischer Rationalität nicht nur die negative Botschaft, dass es in der Regel unsinnig ist, eine Situation hoher Ungewissheit wie eine Situation unter Risiko zu behandeln und das geballte Instrumentarium der Statistik darauf anzuwenden. Stattdessen bietet die dynamische Interaktion von Strategien mit Umweltstrukturen aus gestalterischer Sicht auch Chancen für erfolgreiche Interventionen. Ist eine gezielte Veränderung der Umwelt nicht möglich, so lassen sich immerhin die verwendeten Verfahren so anpassen, dass sie den Strukturen der Umwelt besser entsprechen. Im folgenden Abschnitt fragen wir daher, welches Potential und welche möglichen Konsequenzen der Erfolg einfacher Strategien für die Verbesserung von Wahlprognosen bietet.

3 Wahlprognosen sind ungewiss und erfordern einfache Werkzeuge

When a rational model fails to describe behavior, a different rational model, not different behavior, might be called for.

McKenzie (2003, p. 405)

Weil Demoskopie und Wahlforschung meist eher als statistische Dienstleistungen anstatt als sozialwissenschaftliche Disziplinen betrachtet werden, begründen wir zunächst, warum wir diese Sicht für verkürzt halten. Danach skizzieren wir Ansätze einfacher Prognosemodelle, die der fundamentalen Ungewissheit ihres Gegenstandsbereichs eher entsprechen als komplexe statistische Modelle.

3.1 Von maximaler Akkuratheit zu realistischen Erwartungswerten

Da im Anschluss an die überraschenden Wahlausgänge des Jahres 2016 kein gutes Haar an den Wahlforschern gelassen wurde, sei betont, dass wir in die allgegenwärtige Polemik und das „zyklisch wiederkehrende Demoskopienbashing“ (Jung 2017, p. 40) nicht einstimmen werden. Anstatt Meinungs- und Wahlforscher pauschal zum Sündenbock für verfehlte Prognosen abzustempeln, erläutern wir die prinzipiellen Gründe für den Misserfolg ihrer Vorhersagen und leiten daraus eine alternative Zielsetzung für die Wahlforschung ab.

Bei aller Kritik muss man Demoskopien zugute halten, dass sie weniger anfällig für die statistische Chimäre einer guten Passung zwischen Modell und Daten sind als andere sozialwissenschaftliche Disziplinen. Während sich beispielsweise Psychologen und Ökonomen gern am *good fit* eines Modells berauschen und einen hohen Anteil erklärter Varianz mit hoher Vorhersagefähigkeit verwechseln (Soyer und Hogarth 2012), ist das Kriterium einer Wahlprognose in der Regel glasklar und durch die zukünftige Realität des Wahlergebnisses definiert. Post-hoc-Erklärungen sind leicht und billig, weshalb auch die „Analysen“ vermeintlicher „Experten“ am Aktienmarkt oder Fußballplatz meist langweilig sind. Während rückblickend jeder Stammtisch den Brexit, den Wahlsieg Donald Trumps und obendrein noch die Finanzkrise im Detail erklären kann, sagen Wahlforscher tatsächlich öffentlich *vorher* – und müssen *nachher* dafür gerade stehen. Ein Grund für die lautstarke Kritik nach Fehlprognosen ist auch, dass die scheinbare Präzision des statistischen Instrumentariums auch falsche Hoffnungen weckt. Beispielsweise kann die Hybris von Nachkommastellen für das Abschneiden von Parteien in einer noch mehrere Monate entfernten Wahl nur in Enttäuschung enden. Wer sich zum Propheten erhöht, darf sich nicht wundern, wenn er irgendwann einmal als Quacksalber und Scharlatan bezeichnet wird.

Advokaten und Apologeten der Wahlforschung betonen gern, dass die Vorhersagen der letzten Jahre gar nicht so falsch lagen, wie in der medialen Öffentlichkeit wahrgenommen und dargestellt (Jung 2017; Silver 2017). Tatsächlich gab es in Großbritannien und den USA zahlreiche Hinweise auf Unschärfen und Unsicherheiten, die von Demoskopien akkurat berichtet, aber von Strategen und Journalisten gleichermaßen ignoriert oder übersehen wurden. Obwohl es sinnvoll sein kann, auf Angriff und Offensive zu setzen, wenn andere eine Entschuldigung erwarten, wirken

pauschale Dementi (im Sinne von „wir waren es nicht“) oder Relativierungen (wir machten „the least inaccurate“ Vorhersage; Silver 2017) eher defensiv und kleinlaut. Eine alternative Strategie besteht darin, im Stile einer „Flucht nach vorn“ die enormen Schwierigkeiten und grundsätzlichen Barrieren zu vermitteln, die genauere Prognosen unweigerlich vereiteln. Tatsächlich ist das Ziel, ein zukünftiges Ereignis, das von Millionen von Menschen und wechselseitig verflochtenen Einflussfaktoren abhängt, mit hoher Präzision vorherzusagen, schon aus theoretischen Gründen kaum erreichbar. Da Wahlforschung meist auf (mehr oder weniger repräsentativen) Umfragen beruht, sind alle bekannten Fehlerquellen des *survey sampling*-Modells der Sozialforschung (z. B. Groves et al. 2011) sofort auf die Demoskopie übertragbar: mangelnde Reichweite bzw. Repräsentativität von Stichproben, unvollständige oder missverständliche Messinstrumente, unzureichende oder unzulässige Datenauswertung, unangemessene Interpretation, etc. Erschwerend kommt hinzu, dass Fragen nach politischen Sympathien und Wahlabsichten einen äußerst volatilen Gegenstandsbereich betreffen: Menschen sind unentschlossen, ändern ihre Meinung, verschleiern oder verweigern die Auskunft über ihre wahren Absichten, bekunden Wahlabsichten ohne zur Wahl zu gehen, und lassen sich – siehe FBI, Flüchtlingskrise, Fukushima – bis zum Wahltag massiv vom Tagesgeschehen beeinflussen, als würde die Wahl nur die nächsten Wochen statt Jahre betreffen. Zu diesen kurzfristigen Fluktuationen kommen noch langfristige Verschiebungen der Wahlpopulation (hinsichtlich Altersstruktur, Beruf, Bildung, Einkommen, Stadt-/Landanteil) und ein sich wandelndes Parteiengefüge (vgl. die Grünen, FDP, Piraten, AfD), das traditionelle Gleichungen (wie Arbeiter = SPD) in Frage stellt (Brenke und Kritikos 2017). Und obwohl diese kurz- und langfristigen Modulationen schon für hohe Unsicherheit sorgen, unterliegt der soziale Prozess der Meinungsbildung noch dynamischen Einflüssen, die zu systematischen Verzerrungen und plötzlich kippenden Rückkopplungseffekten führen können (vgl. Moussaïd et al. 2013, 2015). Wie instabil die Wählerwelt geworden ist, zeigt die sogenannte Sonntagsfrage der forsa (www.wahlrecht.de/umfragen/forsa.htm), in der die SPD in nur acht Wochen von Januar bis März 2017 von 20 % auf 32 % geklettert war, nur um danach wieder abzufallen. Aus der hohen Varianz wöchentlicher Wahlsimulationen abzuleiten, dass die Prognosefenster immer kürzer werden sollten, mag vielleicht den Umsatz von Umfrageinstituten fördern, verfehlt aber die Chance, ein sinnvollerer Ziel für Vorhersagen zu definieren. Angesichts fast schon paradoxer Auswüchse, wie der Werbung mit der „besten 18-Uhr-Prognose am Wahlabend“ (www.forsa.de/ueber-forsa/) oder der Klage, dass es zur österreichischen Bundestagswahl am 04.12.16 „keine aktuellen Umfragen“ gegeben habe, weil die letzte Umfrage in „großem zeitlichen Abstand“, nämlich „drei Wochen vor dem Wahlgang“ (Jung 2017, p. 43) durchgeführt worden sei, könnte man aber auch folgern, dass Demoskopie bald zur Saisonarbeit wird, die nur noch in der Wahlwoche nachgefragt wird.² Der verzweifelte Versuch, noch nach Läuten der Schlussglocke einer Wahl deren Ausgang „vorherzusagen“ gleicht dem

² Natürlich liegt es in der Natur von Wahlen, dass die Aussagekraft von und das Interesse an Wahlprognosen mit zeitlicher Nähe der Wahlentscheidung zunehmen. Auch üben Umfragen am Wahltag eine wichtige Kontrollfunktion aus.

Wettlauf von Hase und Igel, den der Hase bekanntlich trotz seiner überlegenden Schnelligkeit verliert, weil sich der Igel stets in einen anderen verwandelt.

Auf der Suche nach einem erreichbaren Ziel für Wahlvorhersagen muss man zunächst den frommen Wunsch nach maximaler Akkuratheit als Fata Morgana entlarven. Derselbe Mangel an realistischen Maßstäben ist uns aus der Erforschung menschlicher Rationalität bekannt, wo jede Abweichung von einer idealen Norm vorschnell als systematische Verfehlung (*bias*) gilt. Eine nüchterne Analyse eines Verhaltens oder Verfahrens fragt stattdessen zunächst nach einer angemessenen Untergrenze, die keinerlei Intelligenz oder Rationalität voraussetzt (Neth et al. 2016). Im Falle von Wahlvorhersagen könnte eine *lower benchmark* etwa in der Gleichverteilung aller Stimmen auf die verfügbaren Parteien oder dem Ergebnis der letzten Wahl bestehen. Verglichen hiermit sind die meisten Prognosen erstaunlich treffsicher, auch wenn sie dem eigentlichen Wahlergebnis nicht perfekt entsprechen. Der Perspektivwechsel von einer idealen und nur punktuellen Norm zu einem Kontinuum an Präzisionsgraden erlaubt es auch, den Wert einer Wahlvorhersage positiv zu definieren, anstatt nur negativ als Abweichung vom Wahlergebnis. Eine gute Vorhersage beschreibt die aktuelle Lage so akkurat, dass sie als Erwartungswert und Maßstab für zukünftige Entwicklungen dienen kann.

Um den hektischen Wettlauf mit volatilen Trends und sich trickreich „ein-igeln“ Wählern durch eine reifere und zugleich gelasseneren Sicht zu ersetzen, bedarf es auch einer besseren Kommunikation und eines reflektierten Umgangs mit Umfrageergebnissen. Wird eine Prognose zum Zeitpunkt T_x als solide Antwort auf die Frage „Was wäre gewesen, wenn sich seit T_x nichts mehr verändert hätte?“ verstanden, kann man nach der Wahl noch immer sinnvoll fragen, welche Entwicklungen und Faktoren für etwaige Abweichungen verantwortlich waren. Eine entspanntere Sicht auf das Ziel von Vorhersagen wäre auch kein Freibrief für methodischen Dilettantismus und Unprofessionalität: Als empirische Sozialwissenschaftler haben Demoskopien das Ziel, aus ihren Fehlern zu lernen und zukünftige Überraschungen nach bestem Wissen und Gewissen zu vermeiden.

3.2 Einfache Werkzeuge für erfolgreiche Prognosen

Die Gründe für die unvermeidliche Ungenauigkeit von Wahlvorhersagen im vorigen Abschnitt haben gezeigt, dass es sich hier um eine Situation unter fundamentaler Ungewissheit statt unter Risiko handelt (vgl. Abb. 1). Dennoch kann man fragen, welche methodischen Innovationen geeignet wären, um die Güte von Umfrageergebnissen zu verbessern.

Ähnlich wie in der Finanzmathematik oder der Klimaforschung bietet die Komplexität ihres Gegenstandsbereichs der Wahlforschung geradezu unbegrenzten Spielraum für statistische Raffinesse. Stellt man beispielsweise fest, dass weiße Befürworter Donald Trumps ohne Universitätsabschluss überproportional häufig in sogenannten *swing states* wohnen (Silver 2017) oder dass sich Anhänger der AfD seltener zu ihren politischen Präferenzen bekennen (Jung 2017, p. 44), so kann man entsprechende Dunkelziffern schätzen und als Parameter in Modelle einfließen lassen. Dass man etwas tun kann, garantiert leider nicht, dass dies auch immer angemessen und sinnvoll ist. Beispielsweise hat uns die mathematische Finesse von

Banken und Versicherungen bei der Konzeption komplexer Finanzprodukte nicht vor der Finanzkrise bewahrt, sondern diese eher noch befeuert (Neth et al. 2014). Dass mehr und detailliertere Informationen die Vorhersagen von Demoskopern ebenfalls nicht verbessern würden, lässt sich anhand eines Gedankenexperiments zeigen: Wenn wir nicht nur die Absichten, sondern auch das tatsächliche Verhalten aller Wahlberechtigten zum Zeitpunkt T_x mit hoher Präzision kennen würden, würde das unsere Vorhersagen verbessern? Auch wenn es so scheint, lässt sich leicht zeigen, dass der Eindruck trügt. Denn tatsächlich haben wir diese Daten direkt im Anschluss jeder Wahl ja zumindest auf Wahlkreisebene, ohne dass dadurch die Vorhersage der *nächsten* Wahl viel leichter oder gar trivial werden würde.

Angesichts der Einsicht, dass Wahlen fundamental ungewiss sind, reagieren gerade mathematisch geschulte Menschen mit dem „rationalen Reflex“, nach mehr Daten und noch komplexeren Analysemodellen zu verlangen um ja keinen möglicherweise relevanten Aspekt zu übersehen. Theoretisch klingt der Wunsch nach „mehr fundierten Informationen“ meist gut, aber in der Praxis garantiert die Verkomplizierung und Verschleppung des Problems oft nur, dass weitere Ressourcen – an Geld, Personal, Rechenkapazität oder Zeit – verschlungen werden (Neth 2014). Ein Grund für die eskalierende Komplexitätsspirale wissenschaftlicher Modelle ist das tief verwurzelte Misstrauen gegenüber einfachen Modellen (Goldstein und Gigerenzer 2009). Dabei ist Statistikern längst bewusst, dass eine hohe Anzahl freier Parameter ihre Modelle auch fehleranfälliger macht und robuste Vorhersagen eher einfache Modelle erfordern (Geman et al. 1992). Erkennt man den Nutzen eines Modells auch darin, die Mechanismen eines Gegenstandsbereichs besser zu verstehen, so rückt die Genauigkeit von Vorhersagen in den Hintergrund zugunsten des Ziels, die *wesentlichen* Aspekte zu erkennen und treffend abzubilden.

Unsere Hinweise auf den erstaunlichen Erfolg von Heuristiken im Fall von ökologischer Rationalität haben bereits angedeutet, dass einfache Modelle keineswegs naiv oder minderwertig sein müssen. Wie in Abschn. 2.2 dargestellt, hat sich das Prinzip des Wiedererkennens bzw. *Rekognitionsprinzip* in Umwelten bewährt, in denen Wissen und Unwissen systematisch statt zufällig verteilt ist. Im Kontext von Wahlen vertrauen Menschen darauf, dass ein Politiker, dessen Namen sie schon einmal gehört haben, auch viele Stimmen bekommen wird, selbst wenn sie wissen, dass dieser Politiker einer kleinen Partei angehört (Marewski et al. 2009). Dasselbe Rekognitionsprinzip lässt sich auch verwenden, um den Rangplatz von Parteien bei Wahlen vorherzusagen (Gaissmaier und Marewski 2011). Hierzu wurden Probandinnen und Probanden schlicht gefragt, von welcher der zur Wahl stehenden Parteien sie bereits gehört haben. Das bloße Wiedererkennen des Parteinamens ist hier ausreichend und keinerlei weiteres Wissen erforderlich. Diese Rekognitionsurteile werden dann aggregiert und eine Rangreihe der Parteien gemäß der Häufigkeit ihrer Wiedererkennung gebildet. Während die Rangvorhersagen für kleinere und Kleinstparteien erstaunlich trennscharf sind, erlaubt dieses Verfahren keine Differenzierung zwischen den großen Parteien, weil diese von allen wiedererkannt werden. Hier kann das Prinzip der *Weisheit der Vielen* (Surowiecki 2004) Abhilfe schaffen: Dazu werden Versuchspersonen gebeten, sich selbst als Wahlvorhersagende zu betätigen und für jede Partei vorherzusagen, welchen Rangplatz diese bei der jeweiligen Wahl belegen wird. Diese Urteile werden dann ebenfalls aggregiert, und die mittleren

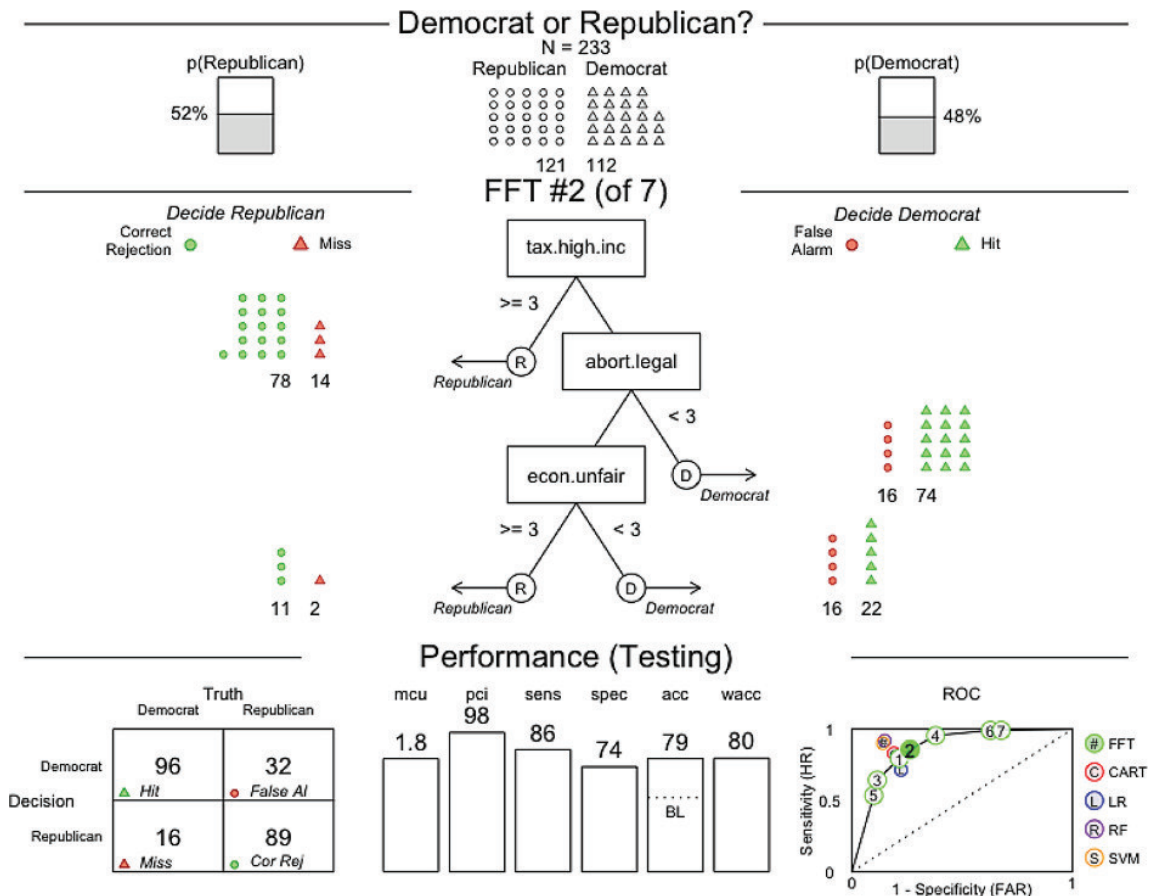


Abb. 2 Beispiel eines *fast-and-frugal tree* (FFT), der für eine Teilstichprobe von $N = 233$ US-Amerikanern vorhersagt, ob die befragte Person Demokrat oder Republikaner ist. Während der Datensatz 77 Variablen enthält, verwendet der FFT durchschnittlich nur 1,8 davon (mcu steht für „mean cues used“), erreicht eine Genauigkeit von 80 % (acc bzw. wacc) und dominiert damit die logistische Regression (LR). (Vgl. Phillips et al. 2017; für Details und die verwendete Software.)

vorhergesagten Rangplätze mit den tatsächlich erzielten Rangplätzen verglichen. In unserer Studie zeigte sich eine hohe Übereinstimmung, die in vielen Fällen mit Befragungen von 1000 Personen einer perfekt repräsentativen, simulierten Stichprobe mithalten konnte. Erstaunlich ist dies, weil unsere Vorhersagen auf nur lächerlich kleinen und keineswegs repräsentativen Studierendenstichproben (mit 34 bis 172 Teilnehmenden) beruhen. Für „klassische“ Umfragen nach der Wahlabsicht wären unsere Stichproben daher gänzlich ungeeignet gewesen (und hätten beispielsweise einen Anteil von 44 % für die Grünen ergeben). Aber das Rekognitionsprinzip wie auch das Prinzip der Weisheit der Vielen erwiesen sich trotz miserabler Stichprobengröße und Repräsentativität als äußerst robust und vorhersagekräftig – gerade wegen ihrer Einfachheit.

Binäre Klassifikationsentscheidungen – wie beispielsweise „links oder rechts?“ oder „CDU oder SPD?“ – lösen statistisch versierte Sozialwissenschaftler meist mithilfe von logistischen Regressionsmodellen (LR). Eine einfache Alternative hierzu ist ein schneller und sparsamer Entscheidungsbaum (*fast-and-frugal tree*, FFT; Martignon et al. 2008); der ein Minimum an Ja-Nein-Fragen in einer festen Reihenfolge stellt und dann eine Entscheidung auf Basis eines guten Grundes trifft. Abb. 2 zeigt einen FFT, der mittels Daten einer repräsentativen Telefonumfrage in den USA

(Jones und Cox 2012) exemplarisch vorhersagt, ob die befragte Person Demokrat oder Republikaner ist. Nach Entfernen von zirkulären Variablen und Fällen mit mehr als 20 % fehlenden Werten blieb ein Datensatz mit $N = 465$ Personen übrig, die jeweils 77 Fragen beantworten. Wie viele dieser 35.805 Informationseinheiten braucht ein Modell zur Vorhersage der Parteipräferenz? Die LR erzielt bei dieser Datenfülle eine perfekte Passung (*fit*) von 100 %. Das ändert sich jedoch drastisch, wenn man eine zufällige Hälfte der Daten ($N_{fit} = 232$) zur Passung eines Modells verwendet und mit diesem Modell dann die andere Hälfte ($N_{test} = 233$) vorhersagt: Die LR-Prognosegenauigkeit sinkt auf unter 80 %. In der Regel wird man dies noch immer als ein erfolgreiches (und statistisch hoch signifikantes) Modell werten, zumal die Basisrate für die Parteizugehörigkeit im Bereich eines Münzwurfs (48 % Demokraten, 52 % Republikaner) lag. Allerdings liefert der in Abb. 2 dargestellte FFT eine einfachere und elegantere Lösung, indem er das Ausmaß an Ablehnung oder Zustimmung zu maximal drei Fragen erwägt: „Sollten hohe Einkommen (mehr als \$1 Mio./Jahr) höher besteuert werden?“ (tax.high.inc), „Sollte Abtreibung legal oder illegal sein?“ (abort.legal), und „Favorisiert das ökonomische System Reiche auf unfaire Weise?“ (econ.unfair). Die Reduktion auf maximal drei Fragen bedeutet, dass hier 98 % der eigentlich verfügbaren Daten komplett ignoriert werden. Interessanterweise erreicht der FFT eine Vorhersagegenauigkeit von 80 %, was etwas präziser als die LR und in Reichweite weit aufwändigerer Modelle (*random forests*, RF, und *support vector machines*, SVM) ist. Da es eher die Regel als eine Ausnahme ist, dass die Vorhersagen einfacher FFTs jene von weit datenintensiveren Modellen erreichen oder schlagen (vgl. Phillips et al. 2017; für eine Analyse von 10 Datensätzen), ist eine generelle Vorliebe für komplexere Modelle rational schwer begründbar.

Auch andere Modelle aus der Wählerforschung verwenden das übergeordnete Prinzip der Einfachheit, um gute Vorhersagen zu treffen. Graefe und Armstrong (2012) greifen beispielsweise die Beobachtung auf, dass viele Wählerinnen und Wähler ihre Wahlentscheidung letztlich nur aufgrund des für sie wichtigsten Themas treffen, anstatt die verschiedenen Parteien bzw. Kandidaten hinsichtlich ihrer Standpunkte zu vielen Themen zu vergleichen. Aber kann man am Zutrauen in Bezug auf ein einziges Thema Wahlen vorhersagen? Man kann: Anhand dieses einfachen Modells konnten die Autoren in 97 % aller Vorhersagen korrekt bestimmen, welcher Kandidat bei US-amerikanischen Wahlen insgesamt mehr Stimmen bekam. Auch konnte ihr Modell hinsichtlich seiner Vorhersagegenauigkeit mit einer Reihe sehr viel komplexerer (z. B. ökonometrischer) Modelle mithalten, die substantiell mehr Informationen berücksichtigten.

Das Prinzip der einfachen Addition von Punkten macht sich Lichtman (2008) mit seinem Modell der Schlüssel zum Weißen Haus („Keys to the White House“) zunutze: Statt auf nur ein zentrales Thema zu setzen, berücksichtigt er in seinen Vorhersagen 13 Aussagen zu wichtigen Themen, die schlicht aufsummiert werden ohne sie unterschiedlich zu gewichten, was eine erhebliche Vereinfachung gegenüber sonst üblichen Regressionsmodellen darstellt. Jede Aussage ist dabei so formuliert, dass sie nur die Werte „wahr“ oder „falsch“ annehmen kann, wobei „wahr“ jeweils die Partei favorisiert, die aktuell an der Macht ist, und „falsch“ die herausfordernde Partei. Solange höchstens fünf der 13 Aussagen als „falsch“ eingestuft werden, lau-

tet die Vorhersage, dass die aktuell die Macht innehabende Partei erneut gewinnt; ab sechs als „falsch“ eingestuften Aussagen lautet die Vorhersage, dass die herausfordernde Partei gewinnt. Das völlig ungewichtete Modell mag primitiv erscheinen, konnte aber rückwirkend den Gewinner aller Präsidentschaftswahlen zwischen 1860 und 1980 korrekt ermitteln, sowie prospektiv alle Gewinner der Präsidentschaftswahlen zwischen 1984 und 2012 vorhersagen. Als eines der wenigen Prognosemodelle hat es sogar den Sieg von Donald Trump im November 2016 korrekt vorhergesagt (Stevenson 2016).

4 Fazit: Mehr Experimente und mehr Einfachheit wagen!

*To endure uncertainty is difficult,
but so are most of the other virtues.*

Bertrand Russell (1950, p. 27)

Unser Plädoyer für die Intelligenz einfacher Entscheidungsregeln und die Rehabilitation und Weiterentwicklung einfacher Modelle ist nicht idealistisch oder naiv, sondern wurzelt in Respekt vor unvermeidlicher Unsicherheit und allgegenwärtiger Ungewissheit. Während wir unter Risiko gern alle Konsequenzen von Entscheidungen nach allen Regeln der statistischen Kunst bis ins letzte Detail berechnen, sind komplexe Modelle unter Ungewissheit weder angemessen noch sinnvoll. Anstatt nach fehlerhaften Vorhersagen ein Wettrüsten immer komplizierterer Verfahren zu starten, sollten wir privat und professionell den Umgang mit Unsicherheit als Auftrag, Herausforderung und Tugend üben.

Angewandt auf die Bedürfnisse von Wählern und die methodischen Werkzeuge der Wahlforschung haben wir zwei Botschaften. Für die vor eine Wahl gestellten Bürgerinnen und Bürger sind demokratische Wahlen ein Entscheidungsproblem, das als Bedrohung oder Chance wahrgenommen werden kann. Während die sprichwörtliche Qual der Wahl immer auch eine Quelle von Instabilität und Unsicherheit ist, bietet sie als elementarer Akt politischer Partizipation auch eine Schnittstelle zwischen Individuum und Institutionen, die Hoffnung auf Wandel und Besserung ermöglicht. Versprechen Parteien allzu einfache Antworten, so ist diesen zu misstrauen, wenn hinter ihren pauschalen Parolen nicht einmal die Suche nach konkreten Lösungsansätzen sichtbar wird. Zugleich ist ein generelles Misstrauen gegenüber einfachen Lösungen ebenso falsch und voreilig. Der scheinbare Widerspruch zwischen gefährlicher und gebotener Einfachheit löst sich auf, wenn man die Hintergrundannahmen mit berücksichtigt und das Ausmaß an Unsicherheit der jeweiligen Entscheidungssituation bestimmt: Sind Situationen sicher oder riskant – also alle Optionen und ihre Wahrscheinlichkeiten und Konsequenzen bekannt oder schätzbar –, so können und sollten Lösungen im Detail geplant und berechnet werden. Wenn in einer Situation hingegen hohe und unvermeidliche Ungewissheit herrscht, sind Optimierungsversuche nicht sinnvoll und stattdessen Erfahrung, Intuition und Mut für beherzte Entscheidungen und verantwortungsvolles Handeln gefragt.

Für Demoskopen und Wissenschaftler, die gesellschaftliche Prozesse besser verstehen und vorhersagen wollen, sind Wahlen ein Experiment des Lebens, das es

produktiv zu nutzen gilt. Anstatt auf Überraschungen und Rückschläge mit vermeintlich rationalen Reflexen und der Flucht in immer kompliziertere Verfahren zu reagieren, sollten wir mehr Experimente und mehr Einfachheit wagen. Statt dem Ziel maximal präziser Wahlvorhersagen erscheint uns der bescheidenere Anspruch eines akkuraten Stimmungsbildes sinnvoller, sofern dieses später die Bewertung von Wahlergebnissen auf Basis guter Erwartungswerte ermöglicht. Zugleich sollte der Wert von Modellen weniger an der Präzision ihrer Prognosen gemessen werden, sondern mehr an ihrem Potential, die wesentlichen Faktoren und Mechanismen der zugrundeliegenden Prozesse identifizieren und begreifen zu können. Die Tugend der Einfachheit ermöglicht nicht nur Robustheit, sondern auch Transparenz. Wie eine Maschine mit wenigen bewegten Teilen sind einfache Modelle nicht nur leichter anzuwenden und zu verstehen, sondern auch leichter zu diagnostizieren, korrigieren und reparieren, wenn uns die Launen der Natur oder die Bauchentscheidungen beherzter oder besorgter Wähler mal wieder einen Strich durch die Berechnung machen sollten.

Literatur

- Allensbach. 2015. *Zwischen Sicherheitsbedürfnis und Risikobereitschaft (Bericht)*. Radolfzell: Allensbach Institut.
- Bauer, Thomas, Gerd Gigerenzer, und Walter Krämer. 2014. *Warum dick nicht doof macht und Genmais nicht tötet: Über Risiken und Nebenwirkungen der Unstatistik*. Frankfurt a.M.: Campus.
- Brenke, Karl, und Alexander S. Kritikos. 2017. Wählerstruktur im Wandel. *DIW Wochenbericht* 84(29): 595–606.
- Gaissmaier, Wolfgang, und Gerd Gigerenzer. 2012. 9/11, Act II: A fine-grained analysis of regional variations in traffic fatalities in the aftermath of the terrorist attacks. *Psychological Science* 23(12):1449–1454.
- Gaissmaier, Wolfgang, und Julian N. Marewski. 2011. Forecasting elections with mere recognition from small, lousy samples: A comparison of collective recognition, wisdom of crowds, and representative polls. *Judgment and Decision Making* 6(1):73–88.
- Gaissmaier, Wolfgang, und Hansjörg Neth. 2016. Die Intelligenz einfacher Entscheidungsregeln in einer ungewissen Welt. *Controller Magazin* 41(2):19–26.
- Geman, Stuart, Elie Bienenstock, und René Doursat. 1992. Neural networks and the bias/variance dilemma. *Neural Computation* 4(1):1–58.
- Gigerenzer, Gerd. 2013. *Risiko: Wie man die richtigen Entscheidungen trifft*. München: Bertelsmann.
- Gigerenzer, Gerd, und Wolfgang Gaissmaier. 2011. Heuristic decision making. *Annual Review of Psychology* 62(1):451–482.
- Gigerenzer, Gerd, Wolfgang Gaissmaier, Elke Kurz-Milcke, Lisa Schwartz, und Steven Woloshin. 2007. Helping doctors and patients make sense of health statistics. *Psychological Science in the Public Interest* 8(2):53–96.
- Gigerenzer, Gerd, Ralph Hertwig, und Thorsten Pachur (Hrsg.). 2011. *Heuristics: The foundations of adaptive behavior*. New York: Oxford University Press.
- Gigerenzer, Gerd, und Laura Martignon. 2015. Risikokompetenz in der Schule lernen. In *Lernen und Lernstörungen*. Bern: Hogrefe.
- Gigerenzer, Gerd, Jutta Mata, und Ronald Frank. 2009. Public knowledge of benefits of breast and prostate cancer screening in Europe. *Journal of the National Cancer Institute* 101(17):1216–1220.
- Gigerenzer, Gerd, Zeno Swijtink, Lorraine J. Daston, Theodore Porter, Lorenz Kruger, und John Beatty. 1990. *The empire of chance: how probability changed science and everyday life*. Cambridge: Cambridge University Press.
- Gigerenzer, Gerd, Peter M. Todd, und ABC Research Group. 1999. *Simple heuristics that make us smart*. New York: Oxford University Press.
- Goldstein, Daniel G., und Gerd Gigerenzer. 2009. Fast and frugal forecasting. *International Journal of Forecasting* 25(4):760–772.

- Götzsche, Peter C., und Karsten J. Jørgensen. 2013. Screening for breast cancer with mammography. *The Cochrane Library* 2013:CD1877.
- Graefe, Andreas, und J. Scott Armstrong. 2012. Predicting elections from the most important issue: a test of the take-the-best heuristic. *Journal of Behavioral Decision Making* 25(1):41–48.
- Groves, Robert M., Floyd J. Fowler Jr, Mick P. Couper, James M. Lepkowski, Eleanor Singer, und Roger Tourangeau. 2011. *Survey methodology*. Bd. 561. New York: Wiley.
- Hacking, Ian. 1990. *The taming of chance*. Cambridge: Cambridge University Press.
- Ipsos. 2017. *Die Sorgen der Deutschen im Wahljahr 2017 (Bericht)*. Hamburg: Ipsos Public Affairs.
- Jones, Robert P., und Daniel Cox. 2012. *Race, class, and culture survey 2012 (Bericht und Daten)*. University Park, PA: Association of Religion Data Archives (ARDA).
- Jung, Matthias. 2017. Stopp dem Demoskopenbashing! Warum Umfrageergebnisse doch nicht so schlecht sind. *Die Politische Meinung* 543:40–45.
- Kahneman, Daniel. 2012. *Schnelles Denken, langsames Denken*. München: Siedler.
- Knight, Frank H. 1921. *Risk, uncertainty and profit*. Chicago: University of Chicago Press.
- Lichtman, Allan J. 2008. The keys to the White House: An index forecast for 2008. *International Journal of Forecasting* 24(2):301–309.
- Marewski, Julian N., Wolfgang Gaissmaier, Lael J. Schooler, Daniel G. Goldstein, und Gerd Gigerenzer. 2009. Do voters use episodic knowledge to rely on recognition? In *Proceedings of the 31st Annual Meeting of the Cognitive Science Society*, Hrsg. Niels Taatgen, und Heddrick van Rijn, 2232–2237. Austin: Cognitive Science Society.
- Marewski, Julian N., Rüdiger F. Pohl, und Oliver Vitouch. 2010. Recognition-based judgments and decisions: Introduction to the special issue (Vol. 1). *Judgment and Decision Making* 5(4):207–215.
- Marewski, Julian N., Rüdiger F. Pohl, und Oliver Vitouch. 2011. Recognition-based judgments and decisions: Introduction to the special issue (Vol. 2). *Judgment and Decision Making* 6(1):1–6.
- Martignon, Laura, Konstantinos V. Katsikopoulos, und Jan K. Woike. 2008. Categorization with limited resources: A family of simple heuristics. *Journal of Mathematical Psychology* 52(6):352–361.
- Maslow, Abraham H. 1966. *The psychology of science*. New York: Harper & Row.
- McKenzie, Craig R.M. 2003. Rational models as theories – not standards-of behavior. *Trends in Cognitive Sciences* 7(9):403–406.
- Moussaïd, Mehdi, Henry Brighton, und Wolfgang Gaissmaier. 2015. The amplification of risk in experimental diffusion chains. *Proceedings of the National Academy of Sciences* 112(18):5631–5636.
- Moussaïd, Mehdi, Juliane E. Kämmer, Pantelis P. Analytis, und Hansjörg Neth. 2013. Social influence and the collective dynamics of opinion formation. *PLoS One* 8(11):e78433.
- Neth, Hansjörg. 2014. Warum Controller auf Heuristiken setzen sollten. *Controlling & Management Review* 58(3):22–28.
- Neth, Hansjörg, und Gerd Gigerenzer. 2015. Heuristics: Tools for an uncertain world. In *Emerging trends in the social and behavioral sciences*, Hrsg. R. Scott, und S. Kosslyn. New York: Wiley.
- Neth, Hansjörg, Björn Meder, Amit Kothiyal, und Gerd Gigerenzer. 2014. *Homo heuristicus* in the financial world: From risk management to managing uncertainty. *Journal of Risk Management in Financial Institutions* 7(2):134–144.
- Neth, Hansjörg, Chris R. Sims, und Wayne D. Gray. 2016. Rational task analysis: A methodology to benchmark bounded rationality. *Minds and Machines* 26(1–2):125–148.
- Phillips, Nathaniel D., Hansjörg Neth, Jan K. Woike, und Wolfgang Gaissmaier. 2017. FFTrees: A toolbox to create, visualize, and evaluate fast-and-frugal decision trees. *Judgment and Decision Making* 12(4):344–368.
- Rees, Nigel. 2006. *Brewer's famous quotations: 5000 quotations and the stories behind them*. London: Cassell.
- Russell, Bertrand. 1950. *Unpopular essays. (Chapter 2: Philosophy for Laymen)*. London: Routledge.
- Savage, Leonard J. 1954. *The foundations of statistics*. New York, NY: Dover Publications.
- Schröder, Fritz H., Jonas Hugosson, et al, 2014. Screening and prostate cancer mortality: Results of the European randomised study of screening for prostate cancer (ERSPC) at 13 years of follow-up. *The Lancet* 384(9959):2027–2035.
- Shanteau, James. 1992. How much information does an expert use? Is it relevant? *Acta Psychologica* 81(1):75–86.
- Sherbino, Jonathan, Kelly Dore, Timothy Wood, Meredith Young, Wolfgang Gaissmaier, Sharyn Krueger, und Geoffrey Norman. 2012. The relation between processing speed and diagnostic errors. *Academic Medicine* 87(6):785–791.
- Silver, Nate. 2017. The real story of 2016. <http://fivethirtyeight.com/features/the-real-story-of-2016>. Zugriffen: 31. Juli 2017.

- Soyer, Emre, und Robin M. Hogarth. 2012. The illusion of predictability: How regression statistics mislead experts. *International Journal of Forecasting* 28(3):695–711.
- Stevenson, Peter W. (2016). Professor who predicted 30 years of presidential elections correctly called a Trump win in September. *The Washington Post* (11. Sept. 2016).
- Surowiecki, James. 2004. *The wisdom of crowds*. New York: Doubleday.
- Todd, Peter M., Gerd Gigerenzer, und ABC Research Group. 2012. *Ecological rationality: Intelligence in the world*. New York: Oxford University Press.
- Tversky, Amos, und Daniel Kahneman. 1974. Judgment under uncertainty: Heuristics and biases. *Science* 185(4157):1124–1131.
- Voltaire, alias François-Marie Arouet. 1919. Letter to Frederick William, Prince of Prussia (28.11. 1770). In *Voltaire in his letters*, Hrsg. S.G. Tallentyre. New York: Putnam's Sons.
- Wegwarth, Odette, Lisa M. Schwartz, Steven Woloshin, Wolfgang Gaissmaier, und Gerd Gigerenzer. 2012. Do physicians understand cancer screening statistics? *Annals of Internal Medicine* 156(5):340–349.