

Gerd Gigerenzer

1 Rationales Entscheiden unter Ungewissheit ≠ Rationales Entscheiden unter Risiko¹

*Truth is ever to be found in simplicity,
and not in the multiplicity and confusion of things.
Isaac Newton*

Zusammenfassung: Eine Entscheidung unter Risiko bedeutet, dass alle möglichen Ereignisse und deren Wahrscheinlichkeiten bekannt sind – wie bei einer Lotterie. In dieser Situation ist Wahrscheinlichkeitsrechnung ausreichend für rationales Entscheiden. Bei einer Entscheidung unter Ungewissheit, also in Situationen, die instabil oder neu sind, oder die Zukunft nicht wie die Vergangenheit ist, braucht man mehr: intelligente Heuristiken. Eine Heuristik sucht nach einer einfachen statt einer komplizierten Lösung und verkörpert die Kunst, sich auf das Wesentliche zu konzentrieren und den Rest zu ignorieren. In diesem Kapitel gebe ich eine Einführung in die wissenschaftliche Analyse von Heuristiken und die Frage, unter welchen Bedingungen weniger Information und Berechnung zu besseren Entscheidungen führen können. Die systematische Untersuchung von Heuristiken trägt dazu bei, besser zu verstehen warum es oft rational ist, einen Teil der Information zu ignorieren um damit schneller und sicherer entscheiden zu können.

Abstract: Making decisions under risk means that all possible events and their probabilities are known—as in a lottery. In such situations rational decisions can be made by calculating the probabilities. Making decisions under uncertainty, that is, in unstable or new situations where the future is not like the past, requires more, namely intelligent heuristics. A heuristic searches for a simple rather than complicated solution and embodies the art of concentrating on what is important and ignoring the rest. In this chapter I provide an introduction to the scientific analysis of heuristics and to the question of under what conditions less information and calculation can lead to better decisions. The systematic investigation of heuristics helps sheds light on why it is often rational to ignore part of the information in order to make rapid and reliable decisions.

Wie trifft man gute Entscheidungen? Wenn Sie ein Buch über rationales Entscheiden in der Ökonomie, in der Verhaltensökonomie, in der Psychologie oder Philosophie öffnen, dann werden Sie wahrscheinlich folgende Botschaft lesen: Rationale Ent-

¹ Editierte Transkription des aufgezeichneten Symposiumvortrages. Der Vortragssprechstil ist belassen worden.

scheidungen folgen den Gesetzen der Logik, dem Kalkulus der Wahrscheinlichkeitstheorie oder der Maximierung des erwarteten Nutzens. Heute ist die Gleichsetzung von rationalem Entscheiden mit diesen Prinzipien so stark wie nie zuvor.

Wahrscheinlichkeitstheorie ist eine schöne mathematische Theorie. Aber sie beschreibt nicht, wie die meisten von uns wichtige Entscheidungen treffen. Und auch nicht, wie jene Entscheidungen treffen, die diese Bücher schreiben, wie die folgende Geschichte illustriert: Ein Professor an der New Yorker Columbia University hatte einen Ruf von einer rivalisierenden Universität, es war Harvard, und er konnte sich nicht entscheiden – soll er gehen, soll er bleiben, soll er annehmen, soll er ablehnen? Ein Kollege nahm ihn beiseite und fragte, was denn sein Problem sei? „Maximiere doch ganz einfach den erwarteten Nutzen, das schreibst du doch immer in deinen Büchern.“ Erschöpft antwortete der Professor: „Hör auf damit, das ist jetzt ernst!“

Ich möchte Sie heute einführen in unsere Forschung am Max-Planck-Institut für Bildungsforschung: in die Wissenschaft der Entscheidungen. Insbesondere möchte ich einen Unterschied herausarbeiten, und zwar den, der im Titel steht: Rationales Entscheiden unter Ungewissheit ist nicht das Gleiche wie rationales Entscheiden unter Risiko. Wenn wir es mit Ungewissheit zu tun haben – und ich werde das noch definieren –, dann sollten wir nach einfachen Lösungen suchen. Haben wir es jedoch mit einer Welt von berechenbaren Risiken zu tun, dann sollten wir paradoxerweise nach komplizierten Lösungen suchen. *Fine-tuning* lohnt sich, wenn die Welt stabil ist, nicht aber unter Ungewissheit.

Die Unterscheidung zwischen stabilen Situationen mit berechenbaren Risiken auf der einen Seite und Ungewissheit auf der anderen Seite wird meist dem Ökonomen Frank Knight [1] zugeschrieben, sie findet sich aber auch in ähnlicher Form bei John Maynard Keynes [2] und Herbert A. Simon [3]. Ich definiere Situationen mit berechenbarem Risiko als jene, wo wir alle Alternativen und Konsequenzen kennen sowie auch die Wahrscheinlichkeiten sicher wissen. Wenn Sie heute Abend ins Kasino gehen und Roulette spielen, dann befinden Sie sich in der Welt von berechenbaren Risiken. Da können Sie sich ausrechnen, wie viel Sie verlieren werden auf lange Sicht. Bei berechenbaren Risiken braucht man keine Heuristiken, keine Intuition, nur zu rechnen. Ein großer Teil der Entscheidungstheorie befasst sich ausschließlich mit diesen Situationen wie Lotterien und experimentellen Spielen, in denen alle Alternativen, Konsequenzen und Wahrscheinlichkeiten festgelegt sind.

Die Welt von berechenbaren Risiken ist relativ klein im Vergleich zu der Welt von Ungewissheiten. Der frühere Präsident der Bank von England, Mervyn King, sagte einmal, wenn die Banken im Kasino spielen würden, dann könnten wir das Risiko auch berechnen. Nur agieren die Banken in einer ungewissen Welt. In der Welt der Finanzen, der Gesundheit oder im Umgang mit Menschen gibt es verschiedene Arten von Ungewissheit. Man kann diese am besten daran erkennen, dass man die Zukunft nicht vorhersagen kann, da man alle Optionen und Konsequenzen nicht im Voraus wissen kann. Die meisten Probleme, mit denen wir konfrontiert sind, sind eine Mi-

schung aus Risiko und Ungewissheit: Einiges kann man berechnen, anderes bleibt ungewiss.

Jimmy Savage, der als Vater der modernen Bayesianischen Entscheidungstheorie bekannt ist, hat die Grenze zwischen Risiko und Ungewissheit mit zwei Beispielen markiert. Er sagte, es wäre *ridiculous*, seine Theorie außerhalb einer berechenbaren, bekannten Welt anzuwenden, und seine Beispiele für Ungewissheit waren „ein Picknick zu planen“ und „Schach“ [4]. Bei einem Picknick können unerwartete Dinge passieren, das heißt, dass die Menge aller Alternativen und Konsequenzen nicht vorhersehbar ist und man damit auch keine Wahrscheinlichkeitsverteilung angeben und den erwarteten Nutzen für jede Alternative bestimmen kann. Schach ist dagegen eine wohldefinierte Situation, in der alle Möglichkeiten bereits festgelegt sind und man auch weiß, dass eine optimale Zugfolge existiert. Nur kann kein Computer oder Schachgroßmeister diese bestimmen, da das Problem rechnerisch nicht bewältigt werden kann.

Dennoch beschränken sich viele Forscher auf die Analyse von Entscheidungen unter Risiko, und sie lassen Ungewissheit außen vor oder gehen sogar davon aus, dass alle Formen von Ungewissheit sich auf Risiko reduzieren lassen. Große Teile der Ökonomie und auch der Verhaltensökonomie definieren sich durch diese Einschränkung und wenden das bewährte methodische Instrumentarium von Savage gegen seinen Willen auf alle Probleme an.

Meine These ist dagegen, dass rationales Entscheiden unter Unsicherheit ein anderes methodisches Repertoire braucht als Entscheiden unter Risiko. Wahrscheinlichkeitstheorie und die Maximierung des erwarteten Nutzens reicht hier nicht aus. Wir brauchen andere Werkzeuge, welche mit Ungewissheit besser umgehen können: einfache, robuste Heuristiken. Da die meisten Situationen, wie bereits gesagt, eine Mischung von Risiko und Ungewissheit darstellen, braucht man am Ende beides: statistische und heuristische Methoden zur Entscheidung.

1 Bei Entscheidungen unter Unsicherheit gilt: Weniger kann mehr sein

Beginnen wir mit einem Beispiel [2]: In den öffentlichen Highschools in Chicago ist man über die steigenden Drop-out-Quoten besorgt. Man möchte wissen, wie man vorhersagen kann, welche von je zwei Schulen die höhere Drop-out-Quote haben wird. Zur Vorhersage sind die Werte auf 18 Variablen bekannt, wie die Klassengröße, der Anteil der Schüler afroamerikanischer und hispanischer Herkunft, das Einkommen der Lehrer und die Werte der Schüler auf standardisierten Tests. Die Frage ist, wie kann man mit diesen Variablen die beste Vorhersage treffen? Eine Standardmethode ist die multiple Regression. Wenn man diese auf den gesamten Datensatz anwendet und die sog. Beta-Gewichte fittet, dann kann man in 72% aller Fälle die Schule mit der höheren Drop-out-Quote korrekt bestimmen.

Nun kann man diese Frage auch einfacher angehen. Statt für jede der Variablen das Beta-Gewicht zu schätzen, kann man einheitliche Gewichte, also +1 oder -1, vergeben und dann einfach zählen, welche Schule die größere Summe hat. Diese Methode heißt im Englischen *Tallying* („Strichliste“) und ist eine Heuristik, da sie die Lösung des Problems vereinfacht. Wenn man *Tallying* anwendet, dann ist die Trefferquote 64 % statt 72 % bei multipler Regression [5]. Einfacher und daher weniger genau – das ist die übliche Interpretation von Heuristiken und soweit keine Überraschung.

Allerdings, wir haben bisher keine Vorhersagen getroffen, sondern die schon bekannten Daten „im Nachhinein erklärt“ – ein Prozess, den man als das *Fitten* von Parametern (wie Beta-Gewichte) bezeichnet. Vorhersage betrifft dagegen Daten, die noch nicht bekannt sind. Die einfachste Form heißt *Out-of-Sample*-Vorhersage, auch Kreuzvalidierung genannt. Hier werden die Daten zufällig in zwei Hälften geteilt, und Regression und *Tallying* lernen ihre Parameter (*Tallying* braucht nur das Vorzeichen der Variablen, plus oder minus, zu lernen) an der einen Hälfte und müssen dann die Daten in der anderen Hälfte vorhersagen. Um zufällige Schwankungen zwischen den zwei Stichproben (Hälften) auszugleichen, wurde die zufällige Aufteilung des Datensatzes 1.000 Mal wiederholt. Wie gut sind nun beide Methoden in der Vorhersage? Vorhersage ist schwieriger als *hind-sight* (Datenfitten), also wird die Genauigkeit sinken. Aber wie weit?

Die multiple Regression erreichte in der Vorhersage nur noch 54 % Trefferquote statt 72 % beim Datenfitten. Die *Tallying*-Heuristik erreichte 62 % statt vorher 64 %. Das heißt, *Tallying* schnitt in der Vorhersage besser ab als multiple Regression. Der Grund liegt darin, dass multiple Regression die Daten zu gut „gefittet“ hat, was man als *overfitting* bezeichnet, während *Tallying* relativ robust war. Unter Ungewissheit kann es also sein, dass man mit weniger Aufwand zu besseren Vorhersagen kommt: Weniger ist mehr.

Abb. 1.1 zeigt, dass dieser Fall keine Ausnahme ist. Hier sind insgesamt 20 Studien zusammengefasst, eine davon die Drop-out-Quoten-Studie. Die anderen befassen sich mit der Vorhersage von Variablen aus der Gesundheit, Psychologie, Ökonomie, Biologie und anderen Bereichen, und die Datensätze sind zum großen Teil aus Statistiklehrbüchern entnommen, wo sie als gute Beispiele für Regressionsmethoden eingeführt wurden. Die Anzahl der Alternativen (Objekte) variiert zwischen 11 und 395 und die Anzahl der Variablen (Attribute) zwischen 3 und 18. Der Wert „7,7“ bedeutet, dass multiple Regression im Schnitt 7,7 Variablen zur Vorhersage verwendete, gemittelt über die 20 Studien, während etwa Take-the-Best nur 2,4 Variablen benötigte.

Auf der linken Seite („Fitting“) erkennt man, dass über alle Studien gemittelt multiple Regression mit 77 % am besten abschneidet, genau wie in der Drop-out-Quoten-Studie. Wenn man sich aber die Vorhersagen ansieht, findet man wiederum den gleichen Abfall: Mit nur 68 % ist multiple Regression am schlechtesten. *Tallying* erreicht dagegen in der Vorhersage 69 %. Eine zweite Heuristik, Take-the-Best [6], erreicht sogar 72 % korrekte Vorhersagen. Take-the-Best beruht auf einer anderen Logik als *Tallying*: Statt die Gewichte aller Variablen zu vereinfachen, ordnet es die




Abb. 1.1 Weniger kann mehr sein in Situationen von Ungewissheit. Gezeigt sind die gemittelten Ergebnisse von 20 Studien zur Vorhersage von psychologischen, ökonomischen und anderen Kriterien [2]. Zwei Heuristiken, Take-the-Best und Tallying, werden gegen multiple Regression getestet. Gibt es keine Ungewissheit („Fitting“), dann hat die multiple Regression, die Methode mit den meisten freien Parametern, den besten Fit. Unter Ungewissheit (Vorhersage mit Kreuzvalidierung) treffen die beiden einfachen Heuristiken bessere Vorhersagen als die multiple Regression.

Variablen und trifft die Vorhersage nur aufgrund der ersten Variable, und wenn diese keine Vorhersage erlaubt, dann aufgrund der zweiten Variable usw. Daher benötigt Take-the-Best auch nur einen Bruchteil der Variablen, welche die anderen beiden Methoden verwenden (im Schnitt 2,4 statt 7,7).

Die linke Seite von Abb. 1.1 („Fitting“) ist eine Situation, in der alle Daten bekannt sind, also ein Spezialfall von bekanntem Risiko. Fitting kennt keine Ungewissheit: Die Algorithmen bestimmen lediglich die Parameterwerte mit dem besten Fit, um die Daten im Nachhinein „vorherzusagen“. Die rechte Seite („Vorhersage“) ist dagegen eine Form von Ungewissheit – und zwar eine minimale Form, in der alle Alternativen (wie alle Highschools) sowie alle Variablen ebenfalls bekannt sind und darüber hinaus eine Zufallsstichprobe der Highschools mit deren Werten in allen Variablen bekannt ist. Die Ungewissheit liegt alleine in der anderen Hälfte der Daten, die nicht bekannt ist. Dennoch gilt bereits hier, dass die bessere Methode unter Risiko nicht immer die bessere Methode unter Ungewissheit ist.

Der Befund in Abb. 1.1 ist ein Existenzbeweis, dass einfache Heuristiken bessere Vorhersagen treffen *können*, nicht ein Beweis, dass Heuristiken *immer* bessere Vorhersagen treffen. Für diejenigen, welche komplexere Methoden als multiple Regressi-

on bevorzugen, sei hier angemerkt, dass ebenfalls gezeigt wurde, dass Take-the-Best oft genauso gute und auch manchmal bessere Vorhersagen als Classification-and-Regression Trees (CART) [7] und Support-Vektor-Maschinen (SVM) treffen kann [8] und das transparent und mit weniger Aufwand. CART sind komplexe Algorithmen welche Entscheidungsbäume erzeugen und SVM sind mathematische Verfahren der Mustererkennung aus dem Bereich des maschinellen Lernens. Damit stellt sich eine neue Frage: Wie können wir bestimmen, unter welchen Bedingungen derart einfache Heuristiken systematisch besser (oder schlechter) abschneiden als komplexe Methoden? Die Analyse der genauen Bedingungen, wann dies der Fall ist, ist Aufgabe der Studie der *ecological rationality* von Heuristiken (siehe unten). Die Bedingungen für Take-the-Best sind inzwischen bekannt [9],[10],[11].

2 Das Forschungsprogramm: Rationales Entscheiden unter Unsicherheit

Die erste Prämisse des Forschungsprogramms ist eine klare Unterscheidung zwischen Risiko und Ungewissheit. In Risikosituationen ist Logik und Wahrscheinlichkeitstheorie ausreichend für gute Entscheidungen. In Situationen von Ungewissheit können dagegen Heuristiken zu besseren Entscheidungen führen, die zugleich auch schneller und transparenter sind.

Eine Heuristik kann man allgemein dadurch definieren, dass sie einen Teil der Information ignoriert. Bspw. ignoriert Tallying die Gewichte der Variablen, indem es alle gleich gewichtet (abgesehen vom Vorzeichen); Take-the-Best trifft Entscheidungen nur aufgrund einer einzigen Variable und ignoriert alle anderen, die nachgeordnet sind.

Es wird oft unterstellt, dass wir einen Teil der Information ignorieren, weil wir kognitiv etwas beschränkt sind (z. B. [12]). Das ist so nicht richtig – es gibt gute Gründe dafür, unter Ungewissheit zu ignorieren. Eine Heuristik ignoriert einen Teil der Information und kann dadurch Schätzfehler reduzieren, etwa bei der Schätzung der Gewichte, und in dieser Fehlerreduktion liegt eine der Erklärungen, warum Heuristiken unter Ungewissheit erfolgreich sind. Heuristiken sind nicht einfach zweitklassig oder nur darin zu begründen, dass man damit weniger Aufwand hat, sondern sie können zu Weniger-ist-mehr-Effekten wie in Abb. 1.1 führen.

Die zweite Prämisse ist die Unterscheidung von Prozessmodellen und Als-ob-(*as-if*)-Modellen. Eine Heuristik ist ein Modell des Entscheidungsprozesses, also etwa, dass schlicht gezählt wird, für welche Alternative mehr Gründe sprechen (wie Tallying), oder dass man nach dem besten Grund entscheidet (wie bei Take-the-Best) und alle anderen ignoriert. Es gibt eine Vielzahl von experimentellen Studien, die zeigen, dass Take-the-Best und andere Heuristiken gute Modelle von Entscheidungsprozessen vieler Menschen sind – insbesondere in Situationen, wo die Heuristik ökologisch rational ist (z. B. [13],[14],[15],[16]). Ein Als-ob-Modell ist dagegen ein „beha-

vioristisches“ Input-Output-Modell und hat nicht den Anspruch, den Prozess der Entscheidung zu modellieren, sondern lediglich das Ergebnis vorherzusagen. Multiple Regression oder Algorithmen wie Support-Vektor-Maschinen sind nicht als Prozessmodelle menschlichen Urteilens gedacht, sondern nur um Ergebnisse zu liefern. Ein Prozessmodell kann nicht nur an der Vorhersage getestet werden, sondern auch im Prozess – etwa, ob nur ein Grund das Urteil bestimmt [14].

Das Forschungsprogramm baut auf diesen beiden Prämissen auf und hat drei Teile: Die empirische Untersuchung der Adaptiven Werkzeugkiste (*adaptive toolbox*), die mathematische und statistische Studie der ökologischen Rationalität von Heuristiken (*ecological rationality*) und die Anwendung der Ergebnisse beider Teile auf das Design von intuitiven Entscheidungssystemen und Entscheidungsumgebungen (*intuitive design*).

Adaptive Toolbox

Der Begriff der „adaptive toolbox“ betont, dass menschliches Entscheiden nicht durch ein einziges Werkzeug geschieht, sondern durch mehrere. Es gibt eine Reihe von psychologischen Theorien, welche explizit oder implizit annehmen, dass es nur ein universelles rationales Werkzeug gäbe, wie etwa Bayes'sche Inferenz oder die Maximierung des erwarteten Nutzens. Das ist das Gegenteil vom Toolbox-Ansatz. Man kann jedoch zeigen, dass das Gehirn keine Bayesianische Inferenzmaschine sein kann, weil es dann nicht mit Ungewissheit umgehen könnte. Um bspw. eine A-priori-Verteilung von subjektiven Wahrscheinlichkeiten zu konstruieren, muss man alle Alternativen und deren Konsequenzen kennen, wie schon Jimmy Savage [4] betont hat (siehe oben). Wir wissen jedoch bei vielen wichtigen Problemen gar nicht, was die Alternativen und deren Folgen sind. Die Metapher der adaptiven Werkzeugkiste betont dagegen die Notwendigkeit multipler Werkzeuge, die an unterschiedliche Problemklassen angepasst sind, wie Hammer für Nägel und Schraubenzieher für Schrauben geeignet sind.

Heuristiken kann man in Bausteine zerlegen, etwa in Suchregeln, Stoppregeln und Entscheidungsregeln. Bspw. sucht Take-the-Best durch die Variablen in einer bestimmten Ordnung (definiert durch „Validität“), stoppt die Suche, nachdem die erste Variable gefunden ist, welche eine Entscheidung erlaubt und entscheidet für die Alternative mit dem höchsten Wert auf dieser Variable. Die Bausteine benutzen wiederum kognitive Kapazitäten wie Langzeitgedächtnis, Ordnen und Zählen. Zu den am besten untersuchten Heuristiken gehören neben Take-the-Best die *Recognition-Heuristik* [17],[18],[19], die *Fluency-Heuristik* [20], *Fast-and-Frugal Trees* [21],[22] und soziale Heuristiken wie Imitation [23]. Ein Überblick findet sich in [24].

Ecological Rationality

Die Analyse der *ecological rationality* von Heuristiken ist präskriptiv, während die Studie der „adaptive toolbox“ deskriptiv ist. Die Frage ist, in welchen Situationen wird eine Heuristik erfolgreicher sein als eine komplexere Methode und wo wird es umgekehrt sein? Diese Frage wurde bisher kaum gestellt, da man im früheren *Heuristics-and-Biases*-Programm [12] davon ausging, dass Heuristiken immer zweitklassig seien und das Ignorieren von Information die Qualität der Entscheidung reduzieren würde – oder zumindest nicht verbessern kann. Dies ist jedoch nur korrekt in Situationen von bekanntem Risiko. In Situationen von Ungewissheit hat sich diese Auffassung jedoch als Irrtum herausgestellt.

In Situationen von Risiko kann man den Fehler in der Vorhersage durch zwei Komponenten beschreiben:

$$\text{Fehler} = \text{Bias} + \varepsilon, \quad (1)$$

wobei Bias die systematische Differenz zwischen der (durchschnittlichen) Vorhersage und dem wahren Wert ist und ε ein unsystematischer Fehler ist (also mit dem Bias unkorreliert und mit einem Mittelwert von null). Gleichung (1) ist implizit in den Argumenten im *Heuristics-and-Biases*-Programm, dass das Problem von Heuristiken lediglich ihr Bias sei und man daher den Bias auf null reduzieren sollte, um den Fehler zu reduzieren.

In Situationen von Ungewissheit sieht es jedoch anders aus [25]. Betrachten wir eine *Out-of-Sample*-Vorhersage wie in Abb. 1.1. Jede von S Stichproben ($s = 1, \dots, S$) generiert eine Schätzung x_s . Die Variabilität dieser x_s um ihren Mittelwert \bar{x} heißt Varianz und ist neben dem Bias eine zweite systematische Quelle von Fehlern. Die Varianz reflektiert die Abhängigkeit der Vorhersagen von den unterschiedlichen Stichproben aus der gleichen Population. Der Fehler der Vorhersage (die Summe der quadrierten Fehler) ist damit:

$$\text{Fehler} = (\text{Bias})^2 + \text{Varianz} + \varepsilon, \quad (2)$$

wobei

$$\text{Bias} = \bar{x} - \mu,$$

das heißt, die durchschnittliche Abweichung des Mittelwerts \bar{x} der Vorhersagen vom wahren Wert μ , und

$$\text{Varianz} = \frac{1}{S} \sum (x_s - \bar{x})^2$$

das heißt, die durchschnittliche Abweichung der Schätzungen der einzelnen Stichproben von ihrem Mittelwert \bar{x} .



Abb. 1.2 Eine Veranschaulichung der beiden systematischen Fehlerquellen von Vorhersagen: Bias und Varianz (siehe Text).

Abb. 1.2 zeigt eine Veranschaulichung von Bias und Varianz. Der Punkt in der Mitte der Dart-Zielscheiben steht für den wahren Wert und jeder Dart für den Schätzwert einer Stichprobe. Mr. Bias, dessen Darts auf der linken Scheibe landeten, zeigt einen systematischen Bias – zu weit links und oben –, aber kaum Varianz. Mr. Varianz, dessen Darts auf der rechten Scheibe landeten, hat keinen Bias, weil der Mittelwert seiner Darts genau im Zentrum der Scheibe liegt. Aber er zeigt eine hohe Varianz und damit ein insgesamt schlechteres Ergebnis. Das heißt, ein moderater Bias mit kleiner Varianz (links) kann zu besseren Ergebnissen führen als kein Bias und hohe Varianz. Unter Ungewissheit geht es nicht einfach darum, den Bias zu reduzieren, sondern Bias und Varianz zugleich.

Die Dart-Analogie in Abb. 1.2 erfasst jedoch nicht, dass typischerweise ein *Trade-off* zwischen Bias und Varianz besteht. Wenn man eine Methode komplexer macht, indem man mehr freie Parameter einführt, wie wenn man bspw. die Theorie des erwarteten Nutzens durch die Prospekt-Theorie ersetzt, dann wird man wahrscheinlich den Bias reduzieren, aber die Varianz erhöhen. Wenn man dagegen die Zahl der freien Parameter reduziert, etwa indem man die Theorie des erwarteten Nutzens durch die Theorie des Erwartungswerts ersetzt, dann passiert wahrscheinlich das Gegenteil: Die Varianz wird auf null reduziert (da die Theorie des Erwartungswerts keine freien Parameter hat), aber der Bias wird steigen. Die Varianz wird auch kleiner, je größer die Stichproben sind. Eine Heuristik ignoriert Information und versucht weniger Parameter zu schätzen und reduziert damit die Varianz-Komponente des Fehlers. Damit kann man analytisch verstehen, dass weniger oft mehr sein kann.

Intuitives Design

Schließlich verwenden wir die Erkenntnisse aus den ersten beiden Teilen, um Experten zu helfen, bessere und schnellere Entscheidungen zu treffen. Dazu nimmt man die Struktur der Heuristiken, welche Menschen intuitiv verwenden, und die Erkenntnisse zur ökologischen Rationalität, um diese auch adaptiv einzusetzen.

Viele deskriptive Studien zeigen, dass Menschen Entscheidungen oft sequenziell treffen, das heißt zuerst den wichtigsten Grund überlegen und wenn dieser keine Entscheidung ermöglicht zum zweitwichtigsten Grund übergehen und so weiter. Dies ist die Logik von Take-the-Best bei der Wahl zwischen Alternativen, aber auch von Heuristiken wie *Fast-and-Frugal Trees*, welche Personen (Objekte) zwei oder mehr Klassen zuordnen. Ein Beispiel: In England entscheiden Magistrate darüber, ob ein Angeklagter bis zur Gerichtsverhandlung auf freien Fuß gesetzt wird (*bail*), ob er Auflagen wie eine Kautionszahlung erhält oder ob er gar in Untersuchungshaft kommt (*jail*). Abb. 1.3 rechts zeigt, wie Magistrate in London diese Entscheidungen über „bail“ und „jail“ treffen [26]. Es gibt nur $n = 3$ binäre Variablen oder Fragen, und schon die erste Frage kann zur Entscheidung „jail“ führen. Diese Heuristik ist ein Beispiel für einen Fast-and-Frugal Tree, der dadurch definiert ist, dass er genau $n + 1$ Entscheidungen (*exits*) erlaubt, wohingegen ein vollständiger Entscheidungsbaum 2^n vorsieht. Nun kann man die gleiche Struktur nehmen, die Menschen intuitiv anwenden, um Entscheidungsalgorithmen in anderen Gebieten intuitiver, transparenter und effizienter zu machen.

Ich gebe als Beispiel eine Standardsituation in der Medizin: Ein Mann wird mit starken Herzbeschwerden in die Notaufnahme gebracht. Die Ärzte müssen eine Entscheidung über Leben und Tod treffen, nämlich ob die Person in die Herz-Intensivstation gebracht oder in ein reguläres Bett mit Telemetrie gelegt werden soll. Wenn die Person einen Herzinfarkt hat oder bekommt, sollte sie in der Intensivstation sein, wenn nicht, dann besser nicht. In einem Krankenhaus in Michigan hatten die Ärzte 90 % aller Patienten in die Intensivstation geschickt, obwohl nur 15 % einen Herzinfarkt hatten. Diese Entscheidungen führten dazu, dass die Intensivstation überfüllt wurde, die Qualität nach unten ging und die Kosten nach oben. Der Grund für diese Entscheidung ist defensive Medizin: Der Arzt schützt sich selbst vor einer gerichtlichen Klage und gefährdet damit den Patienten [27]. Ärzte laufen Gefahr verklagt zu werden, wenn sie einen Patienten in ein reguläres Bett einweisen, der dann einen Herzinfarkt bekommt. Was tun?

Die erste Idee war: komplexes Problem, komplexe Lösung. Eine Gruppe von medizinischen Wissenschaftlern aus der Universität Michigan führte eine solche Lösung ein, nämlich eine Karte mit ungefähr 50 Wahrscheinlichkeiten und einem Taschenrechner, in den eine logistische Regression einprogrammiert war. Der Arzt gibt für jeden Patienten die relevanten Parameter ein und dann errechnet das Programm eine Wahrscheinlichkeit. Wenn diese über einer Schwelle liegt, dann ist die Entscheidung „Intensivstation“, ansonsten das reguläre Bett. Dieser Algorithmus war zwar besser

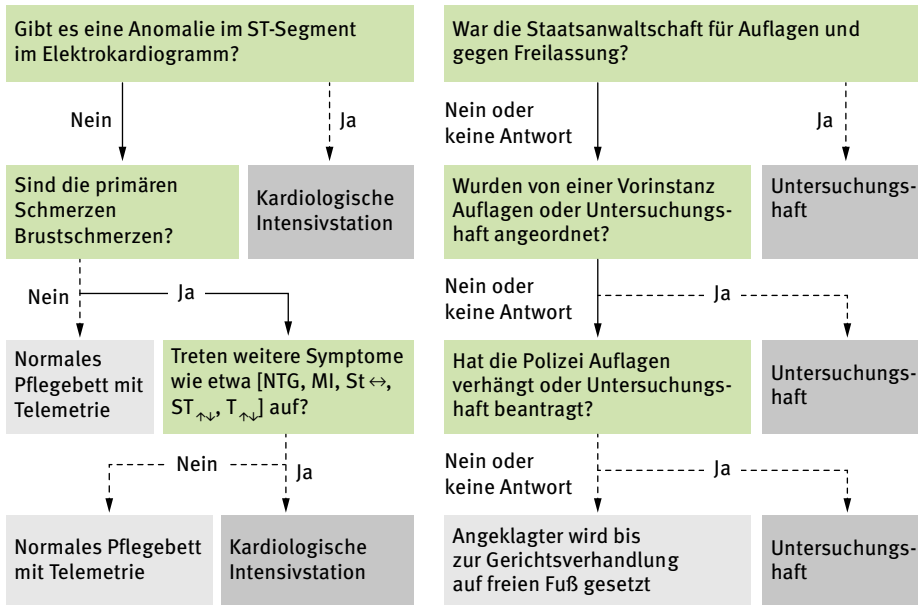


Abb. 1.3 Der Fast-and-Frugal Tree links ist ein Beispiel für intuitives Design. Er hilft Ärzten in der Notaufnahme zu entscheiden, ob ein Patient mit schweren Herzbeschwerden in die Herz-Intensivstation („Coronary Care Unit“) oder in ein reguläres Bett mit Telemetrie („Regular Nursing Bed“) eingewiesen wird [28]. Der Fast-and-Frugal Tree rechts ist ein Beispiel für ein deskriptives Modell über den Entscheidungsprozess von Magistraten (Laienrichtern) in London. Sie entscheiden darüber, ob ein Angeklagter bis zur Gerichtsverhandlung freikommt („auf freien Fuß“) oder in Untersuchungshaft kommt bzw. andere Auflagen wie Kaution erhält („Untersuchungshaft“) [26]. Abbildung adaptiert von [22].

als die defensive Medizin, aber nicht intuitiv verständlich – sobald die Wissenschaftler die Klinik verließen, gingen die Ärzte zurück zur defensiven Medizin.

In dieser Situation hörte der PI (*principal investigator*) des Teams der Universität von Michigan von unseren Arbeiten über Heuristiken und konstruierte einen Fast-and-Frugal Tree für die Entscheidung über die Einweisung in die Intensivstation (Abb. 1.3 links). Wiederum kann nach jeder Frage eine Entscheidung getroffen werden. Die erste Frage lautet, gibt es eine Anomalie im ST-Segment im Elektrokardiogramm? Wenn ja, dann sofort in die Intensivstation. Wenn nicht, geht man zur zweiten Frage. Sind die primären Schmerzen Brustschmerzen? Wenn nicht, dann kommt der Patient in ein reguläres Bett. Und so weiter. Die Heuristik ist transparent, schnell und kann einfach gelernt werden.

Dieser einfache Entscheidungsbaum ist schnell und transparent. Aber wie gut ist er? Eine Studie an der Klinik zeigte, dass er eine höhere Sensitivität (der Anteil an den Patienten mit Infarkt, die richtig in die Intensivstation gesandt wurden) hatte als das komplexe Diagnosesystem und auch als die defensiven Entscheidungen der

Ärzte. Die Falsch-positiv-Quote (der Anteil an den Patienten ohne Infarkt, die fälschlicherweise in die Intensivstation gesandt wurden) war ebenfalls deutlich besser, was man an der sog. ROC-Kurve sehen konnte [28]. Also haben wir wieder einen Weniger-ist-mehr-Effekt.

In der Notaufnahme haben wir es nicht mehr mit minimaler Unsicherheit (Out-of-Sample-Vorhersage) zu tun, wo wir eine Population haben und Zufallsstichproben daraus ziehen wie in Abb. 1.1, sondern mit einer *Out-of-Population-Vorhersage*. Die originale Studie, welche die empirischen Daten und die logistische Regression lieferte, wurde in Boston durchgeführt, die Anwendung ist aber in Michigan, und wir wissen nicht, wie sich die beiden Populationen von Patienten unterscheiden. Und der Punkt ist ja auch nicht in jedem Krankenhaus eine neue Studie zu machen, sondern Methoden zu entwickeln, die robust – und darüber hinaus auch intuitiv verständlich – sind.

3 Ungewissheit ernst nehmen

Die These dieses Vortrags ist: Entscheidung unter Risiko ist nicht das Gleiche wie Entscheidung unter Ungewissheit. Dies steht im Gegensatz zu einer Tradition in Psychologie, Verhaltensökonomie und Neurowissenschaften [29], die sich auf Situationen von bekannten Risiken beschränkt oder sogar annimmt, dass sich alle Formen von Ungewissheit auf Wahrscheinlichkeiten reduzieren lassen würden. Damit hat man eine Entscheidungstheorie geschaffen, die sich derart beschränkt, dass sie von wenig Nutzen für die wirkliche Welt ist.

Die Konzepte der adaptiven Toolbox, „ecological rationality“ und des intuitiven Designs erlauben eine Alternative, welche Ungewissheit ernst nimmt und systematisch Heuristiken untersucht, die damit umgehen können. Heuristiken sind nicht die einzigen Werkzeuge für Ungewissheit. Dazu gehören auch Szenarien wie sie etwa die Hamburger Feuerwehr verwendet (siehe Kapitel 6 in diesem Buch) und Narrative, welche Entscheidungen beeinflussen, bspw. das Narrativ vom Equilibrium und der Optimierung, das trotz der letzten Finanzkrise weiterhin vorherrscht [30].

Und am Ende ist die Methodologie wichtig. Hier möchte ich drei Prinzipien hervorheben: (1) formale Modelle von Heuristiken, (2) kompetitiver Test von Modellen und (3) Tests in der Vorhersage. Die Studien in Abb. 1.1 illustrieren diese Prinzipien. Erstens, Tallying, Take-the-Best und Fast-and-Frugal Trees sind formale Modelle, für die man testen kann, wie gut sie menschliche Entscheidungen vorhersagen können, aber auch, wie gut sie als diagnostische Techniken sind. All das kann man mit rein verbalen Labels wie *availability heuristic* oder *affect heuristic* oder unklaren Dichotomien wie „System 1 versus System 2“ nicht leisten ([31],[32]). Zweitens, ein Modell einer Heuristik sollte kompetitiv getestet werden gegen die besten Alternativen, nicht einfach nur gegen eine Nullhypothese. Und schließlich müssen wir klar unterscheiden zwischen einem guten Fit und einer guten Vorhersage. Einen guten Fit kann man

durch das bloße Hinzufügen von freien Parametern erreichen, aber das ist eben kein guter Modelltest.

Am Ende geht es darum, Situationen von Ungewissheit ernst zu nehmen statt so zu tun, als ob es ein einziges Werkzeug gäbe – etwa die Wahrscheinlichkeitstheorie –, das uns für alle Spielvarianten von Risiko und Ungewissheit immer die besten Entscheidungen liefert. Weder Logik noch Heuristik sind immer rational; wir sollten daher mehr über ihre „ecological rationality“ nachdenken. Unsicherheit charakterisiert nicht nur ärztliche Diagnose oder richterliches Urteil (wie in Abb. 1.3), sondern auch die Wissenschaften. Georg Polya hat über Heuristiken in der Mathematik geschrieben, also etwa Methoden um einen Beweis zu finden (nicht zu prüfen, hier braucht man Logik), und Albert Einstein hat den Begriff „heuristisch“ in den Titel seines Nobelpreis-gekrönten Artikel über Quantenphysik gesetzt. Für die Psychologie geht es darum, jene Heuristiken, welche Menschen verwenden, ernst zu nehmen und systematisch zu untersuchen, statt sie a priori als Quelle von Fehlern zu interpretieren. Ich hoffe, dass dieser kleine Ausflug in die Wissenschaft von Entscheidungen gezeigt hat, dass rationales Entscheiden unter Risiko nicht das Gleiche ist wie rationales Entscheiden unter Ungewissheit.

Literatur

- [1] Knight FH. Risk, uncertainty and profit. Boston: Houghton Mifflin, 1921.
- [2] Keynes JM. The general theory of employment, interest and money. London: Macmillan, [1936].
- [3] Simon HA. Invariants of human behavior. In: Annual Review of Psychology. 1990;41:1–19.
- [4] Savage LJ. The foundations of statistics. New York: Wiley, 1954. 16.
- [5] Czerlinski J, Gigerenzer G, Goldstein DG. How good are simple heuristics? In: Gigerenzer G, Todd PM, the ABC Research Group. Simple heuristics that make us smart. New York: Oxford University Press, 1999. 97–118.
- [6] Gigerenzer G, Goldstein DG. Betting on one good reason: The Take The Best heuristic. In: *ibid.* 75–95.
- [7] Brighton H, Gigerenzer G. Bayesian brains and cognitive mechanisms: Harmony or dissonance? In: Chater N, Oaksford M (eds.). The probabilistic mind: Prospects for Bayesian cognitive science. New York: Oxford University Press, 2008. 189–208.
- [8] Brighton H, Gigerenzer G. Are rational actor models “rational” outside small worlds? In: Okasha S, Binmore K (eds.). Evolution and rationality: Decisions, co-operation and strategic behavior. Cambridge / MA: Cambridge University Press, 2012. 84–109.
- [9] Baucells M, Carrasco JA, Hogarth RM. Cumulative dominance and heuristic performance in binary multi-attribute choice. 2006 (Available at SSRN: <http://ssrn.com/abstract=962652>).
- [10] Gigerenzer G. Towards a rational theory of heuristics. In: Frantz R, Marsh L (eds.). Minds, models, and milieu: Commemorating the centennial of the birth of Herbert Simon. New York: Palgrave Macmillan, 2016. 34–59.
- [11] Martignon L, Hoffrage U. Fast, frugal, and fit: Simple heuristics for paired comparison. In: Theory and Decision. 2002;52:29–71 (doi:10.1023/A:1015516217425).
- [12] Kahneman D. Thinking fast and slow. London: Allen Lane, 2011.

- [13] Bergert FB, Nosofsky RM. A response-time approach to comparing generalized rational and take-the-best models of decision making. In: *Journal of Experimental Psychology: Learning, Memory and Cognition*. 2007;331:107–129.
- [14] Bröder A. The quest for take-the-best. In: Todd PM, Gigerenzer G, the ABC Research Group. *Ecological rationality: Intelligence in the world*. New York: Oxford University Press, 2012. 216–240.
- [15] Nosofsky RM, Bergert FB. Limitations of exemplar models of multi-attribute probabilistic inference. In: *J Exp Psychol: Learn Mem Cogn*. 2007;33:999–1019.
- [16] Rieskamp J, Hoffrage U. Inferences under time pressure: How opportunity costs affect strategy selection. In: *Acta Psychol*. 2008;127:258–276.
- [17] Gigerenzer G, Goldstein DG. The recognition heuristic: A decade of research. In: *Judgment and Decision Making*. 2011;6:100–121.
- [18] Pachur T, Todd PM, Gigerenzer G, Schooler L, Goldstein DG. The recognition heuristic: A review of theory and tests. In: *Frontiers in Cognitive Science*. 2011;2:147 (doi:10.3389/fpsyg.2011.00147).
- [19] Marewski JN, Gaissmaier W, Schooler LJ, Goldstein DG, Gigerenzer G. From recognition to decisions: Extending and testing recognition-based models for multi-alternative inference. In: *Psychonomic Bulletin & Review*. 2010;17:287–309 (doi:10.3758/PBR.17.3.287).
- [20] Schooler LJ, Hertwig R. How forgetting aids heuristic inference. In: *Psychol Rev*. 2005;112:610–628.
- [21] Martignon L, Vitouch O, Takezawa M, Forster M. Naive and yet enlightened: From natural frequencies to fast and frugal decision trees. In: Hardman D, Macchi L (eds.). *Thinking: Psychological perspectives on reasoning, judgment, and decision making*. Chichester UK: Wiley, 2003. 189–211.
- [22] Luan S, Schooler L, Gigerenzer G. A signal detection analysis of fast-and-frugal trees. In: *Psychological Review*. 2011;118:316–338 (doi:10.1037/a0022684).
- [23] Hertwig R, Hoffrage U, the ABC Research Group. *Simple heuristics in a social world*. New York: Oxford University Press, 2013.
- [24] Gigerenzer G, Hertwig R, Pachur T (eds.). *Heuristics: The foundations of adaptive behavior*. New York: Oxford University Press, 2011.
- [25] Geman S, Bienenstock E, Doursat R. Neural networks and the bias/variance dilemma. In: *Neural Computation*. 1992;4:1–58.
- [26] Dhami MK. Psychological models of professional decision making. In: *Psychol Sci*. 2003;14:175–180.
- [27] Gigerenzer G. *Risiko: Wie man die richtigen Entscheidungen trifft*. München: Bertelsmann, 2013.
- [28] Green L, Mehr DR. What alters physicians' decisions to admit to the coronary care unit? In: *J Fam Pract*. 1997;45:219–226.
- [29] Volz KG, Gigerenzer G. Cognitive processes in decision under risk are not the same as in decisions under uncertainty. In: *Frontiers in Decision Neuroscience*. 2012;6:105 (doi:10.3389/fnins.2012.00105).
- [30] Tuckett D. *Minding the markets: An emotional finance view of financial instability*. London: Palgrave Macmillan, 2011.
- [31] Gigerenzer G. On narrow norms and vague heuristics: A reply to Kahneman and Tversky. In: *Psychological Review*. 1996;103:592–596.
- [32] Kruglanski A, Gigerenzer G. Intuitive and deliberate judgments are based on common principles. In: *Psychological Review*. 2011;118:97–109 (doi:10.1037/a0020762).