

„Evaluation bayesianischer kognitiver Modelle in der
Vorhersage menschlichen Verhaltens“

„Evaluation of Bayesian Cognitive Models in the Prediction of Human Behavior“



Dissertation

zur

Erlangung eines Doktorgrades der Naturwissenschaft (Dr. rer. nat.)

am Fachbereich Humanwissenschaften der

Technischen Universität Darmstadt

Institut für Psychologie

Eingereicht von:

Tim Schürmann, M.Sc

Gutachter:

Prof. Dr. Joachim Vogt

Jun.-Prof. Dr.Ing. Philipp Beckerle

Darmstadt, November 2018

Schürmann, Tim: Evaluation bayesianischer kognitiver Modelle in der Vorhersage menschlichen Verhaltens

Darmstadt, Technische Universität Darmstadt

Jahr der Veröffentlichung auf TUprints: 2019

URN: [urn:nbn:de:tuda-tuprints-86016](https://nbn-resolving.org/urn:nbn:de:tuda-tuprints-86016)

Tag der mündlichen Prüfung: 28.01.2019

Nutzungsrechte gemäß CC BY-NC 4.0 International

Promotionsschrift von Tim Schürmann, M.Sc.

Erklärung gemäß §9 der Allgemeinen Bestimmungen der Promotionsordnung der Technischen Universität Darmstadt

Hiermit versichere ich, die vorliegende Arbeit ohne Hilfe Dritter nur mit den angegebenen Quellen und Hilfsmitteln angefertigt zu haben. Alle Stellen, die aus den Quellen entnommen wurden, sind als solche kenntlich gemacht worden. Diese Arbeit hat in gleicher oder ähnlicher Form noch keiner Prüfungsbehörde vorgelegen.

Darmstadt, den

.....
Unterschrift

Tim Schürmann

Landgraf-Philipps-Anlage 42-46

64283 Darmstadt

Wissenschaftlicher Werdegang

Name: Tim Schürmann
Geburtsdatum: 24.06.1989
Geburtsort: Frankfurt, Deutschland

Ausbildung

2011-2013 Studium der Psychologie (Master of Science) an der Technischen Universität Darmstadt
2008-2011 Studium der Psychologie (Bachelor of Science) an der Technischen Universität Darmstadt
2008 Abitur an der Ludwig-Erhard-Schule, Frankfurt

Arbeitserfahrung

Seit 2013 Wissenschaftlicher Mitarbeiter: Forschungsgruppe Arbeits- und Ingenieurpsychologie, Technische Universität Darmstadt
2017 Forschungsaufenthalt: Computational Cognition Lab, University of California, San Diego
2012-2013 Werkstudententätigkeit: Forschungsgruppe Arbeits- und Ingenieurpsychologie, Technische Universität Darmstadt
2010-2012 Werkstudententätigkeit: Frankfurter Allgemeine Zeitung

„I thought the meaning of people was somewhere in here. Then I looked inside Nicolas Cage and I found a secret – people are random and pointless.”

Abed Nadir, Community

Danksagungen

Mit dem Verfassen dieser Arbeit beende ich ein zweifellos ambitioniertes, aber zutiefst irrationales Vorhaben, das vor viel zu langer Zeit mit einer Frage seinen Lauf nahm: „wie machen wir das eigentlich?“. Auf die Frage, wie Menschen denken, bewegen, sprechen, wahrnehmen, sortieren, auswählen und daraus mal mehr, mal weniger für das nächste Mal mitnehmen, haben deutlich klügere Menschen als ich noch keine zufriedenstellende Antwort finden können, und diese Arbeit wird das auch nicht tun. Deshalb möchte ich mich zunächst bei Joachim Vogt und Philipp Beckerle bedanken, die mich in den vergangenen fünf Jahren auf dem Weg zu dieser Einsicht begleitet haben. Mein herzlicher Dank gilt auch den Kolleginnen und Kollegen im Graduiertenkolleg 2050 „Privatheit und Vertrauen für mobile Nutzer“. Geteiltes Leid ist halbes Leid, und auch wenn mir keine empirisch belastbaren Ergebnisse zum Zusammenhang zwischen der Anzahl an Doktoranden in einem Raum und dem subjektiven Bedarf an Self-Help Sessions bekannt sind, waren sie mir doch immer eine Freude. Durch das Graduiertenkolleg konnte ich zudem die Chance auf einen Forschungsaufenthalt wahrnehmen, der durch die Zusammenarbeit mit Ed und Lambda die lehrreichsten Wochen meiner Zeit als Doktorand ausmachte.

Ohne meine Kollegen in der Forschungsgruppe Arbeits- und Ingenieurpsychologie und im Graduiertenkolleg 2050 hätte ich diese Arbeit niemals abschließen können – ob das jetzt Fluch oder Segen ist, basiert auf den subjektiven Präferenzen und kognitiven Verzerrungen des Lesers. Ein besonderer Dank gilt Paul und Max, die die bei einem Journal eingereichte Fassung von Kapitel 4 auf Anraten von Reviewer 2 Probe lesen „durften“. Der Impuls des Lesers, sich beim Lesen der dortigen Modellbeschreibungen verwirrt den Kopf zu kratzen, hielt sich trotz ihrer besten Bemühungen wacker. Vielen Dank auch an all die tapferen Hiwis und Thesanden, die an den Projekten, aus denen diese Arbeit entstanden ist, mitgewirkt haben. Wir wissen immer noch nicht mit moralischer Sicherheit, ob die Würfel beim Cocktailwürfeln fair sind. Mehr Samples!

Zu guter Letzt vielen Dank und meine herzliche Entschuldigung an alle meine Freunde und Familienmitglieder, die eigentlich nur wissen wollten, „wie die Uni läuft“, und nicht, wie die Schwankungsanfälligkeit in der Schätzung der Erfolgswahrscheinlichkeit eines Bernoulli-Versuchs zum Abruf kontextsensitiv repräsentierter Präferenzen am besten algorithmisch umgesetzt werden kann. Ich gelobe feierlich, dass Erklärungen zu obskuren After-Credits-Szenen in Comicbuchverfilmungen ab jetzt wieder ihren verdienten Stammplatz als Hauptinhalt meiner Monologe einnehmen werden.

Inhaltsverzeichnis

Inhaltsverzeichnis	1
Zusammenfassung.....	3
Abstract	7
1. Einleitung.....	9
1.1. Geltungsbereich bayesianischer Modelle	12
1.2. Normativität, Rationalität und Entscheidungstheorie	15
1.3. Die Sampling-Hypothese	16
1.4. Entscheidungsverhalten und Präferenzentwicklung.....	21
1.5. Andere Arten kognitiver Modellierung	23
1.6. Struktur der vorliegenden Arbeit	25
2. Evaluationsmethodik kognitiver Modelle.....	27
2.1. Parameterschätzung.....	27
2.2. Modellvergleich.....	28
3. Empirische Anwendung: Auswirkungen eines informierten Priors auf die Vorhersage propriozeptiven Drifts im bayesianischen Modell für Kausalinferenz	31
3.1. Modellstruktur und Parameter	34
3.2. Empirische Stichprobe und deskriptive Datenanalyse	38
3.3. Ergebnisse.....	38
3.4. Diskussion	40
3.4.1. Modellverhalten	40
3.4.2. Einschränkungen.....	42
3.5. Schlussfolgerungen.....	43
4. Empirische Anwendung: Entscheidungsmodellierung für Optionen auf Basis mehrerer Attribute: Nutzung von Online-Diensten	45
4.1. Entscheidungsverhalten in Bezug auf Online-Services.....	45
4.2. Studiendesign und Stichprobe.....	46
4.3. Kognitive Modelle für Entscheidungen über Optionen mit mehreren Attributen.....	50
4.3.1. Rationales Prozessmodell (RPM)	50
4.3.2. Bayesianisches Modell (detBayes).....	52
4.3.3. Take-the-best-Heuristik (detTTB)	53
4.3.4. Probabilistische Take-the-best-Heuristik (probTTB).....	53
4.3.5. Begründung der Auswahl von Alternativmodellen.....	54
4.4. Ergebnisse.....	54

4.4.1. Modellvergleich	54
4.4.2. Verteilungen der Feature-Präferenzen.....	58
4.4.3. Probabilistische Regel zur Terminierung des Samplings	59
4.5. Diskussion	60
4.5.1. Konzeptioneller und empirischer Modellvergleich.....	60
4.5.2. Integration probabilistischer kognitiver Modellierung mit Forschung zum Nutzungsverhalten in Bezug auf Online-Privatsphäre.....	62
4.5.3. Einschränkungen.....	63
4.6. Schlussfolgerungen.....	64
4.6.1. Probabilistisches Entscheidungsverhalten, Präferenzen und das Offenlegen privater Informationen.....	64
4.6.2. Implikationen für die Steigerung von Verhalten zum Schutz privater Informationen	65
4.6.3. Zukünftige Forschung	65
5. Empirische Anwendung: Entscheidungsmodellierung für Optionen auf Basis eines Attributs: Wahrnehmung nonverbalen Flirtverhaltens	67
5.1. Studiendesign und Stichprobe.....	67
5.2. Formalisierung als rationales Prozessmodell	68
5.3. Alternativmodelle	69
5.3.1. Angleichungsmodell (probMatch)	69
5.3.2. Bayesianisches Modell (detBayes).....	70
5.4. Modellvergleich und Ergebnisse	70
5.5. Diskussion	76
5.5.1. Einschränkungen.....	77
5.6. Schlussfolgerungen.....	78
6. Diskussion	79
6.1. Zusammenfassung des Modellverhaltens	79
6.2. Parameterschätzung und die Formalisierung des rationalen Prozessmodells.....	82
6.3. Einheitliche Anforderungen an psychologisch plausible kognitive Modelle	83
6.4. Rationale Strategien oder rationale Strategieauswahl?.....	86
Literaturverzeichnis.....	89
Abbildungsverzeichnis.....	107
Tabellenverzeichnis	109
Anhang – Verbleibende Stimuli der Studien aus Kapitel 4.....	111

Zusammenfassung

Die vorliegende Arbeit befasst sich mit bayesianischer kognitiver Modellierung und ihrem Potential zur Erklärung und Vorhersage menschlichen Verhaltens. Kognitive Modellierung unterscheidet sich dabei von anderen in der psychologischen Forschung angewandten Modellierungsmethoden durch den Versuch, den Prozess der Informationsverarbeitung innerhalb eines Individuums formalisieren. Als Konsequenz sind psychologische Konstrukte in kognitiven Modellen oft präziser und weniger flexibel als in mathematischen oder verbal-theoretischen Modellen implementiert. Bayesianische kognitive Modelle betrachten beobachtbares menschliches Verhalten als Folge eines wahrscheinlichkeitsbasierten Prozesses. Sie folgen weiterhin der Annahme, dass die menschliche Wahrnehmung unsicherheitsbehaftet ist. Menschen, die etwas über den Zustand ihrer Umwelt lernen, schreiben deshalb ihren Annahmen über den Zustand ihrer Umwelt ein Ausmaß an Vertrauen zu, das als Wahrscheinlichkeit interpretiert werden kann. Des Weiteren können sie ihr Vertrauen in Annahmen über die Umwelt unter Berücksichtigung neuer Informationen verändern. Sie greifen dafür den Satz von Bayes auf, eine mathematische Regel zur Berechnung bedingter Wahrscheinlichkeiten. Hat ein Individuum beispielsweise eine Annahme über die eigene Umwelt, glaubt es eingangs zu einem bestimmten Ausmaß daran, dass diese Annahme zutrifft. Beobachtet es daraufhin Geschehnisse aus seiner Umwelt, dann beurteilt es die Wahrscheinlichkeit dieser Geschehnisse, das Zutreffen seiner Annahme vorausgesetzt. Der Satz von Bayes beschreibt, wie das Individuum sein Ausmaß an Vertrauen in seine Annahme in Relation dazu verändern sollte, wie wahrscheinlich die beobachteten Geschehnisse gegeben seiner Annahme sind. Bisherige Untersuchungen menschlichen Wahrnehmungs- und Entscheidungsverhaltens scheinen zwar in Konflikt mit der mathematisch rationalen Anwendung des Satzes von Bayes zu stehen. Durch die Berücksichtigung ressourcenbezogener Einschränkungen ist es jedoch gelungen, augenscheinlich irrationale Entscheidungsphänomene beim Menschen zu rationalisieren. So beschreibt die Sampling-Hypothese das Konzept, den Menschen nicht als vollends bayesianischen Agenten zu beschreiben, sondern ihn in Abhängigkeit verfügbarer Ressourcen nur Teilmengen seiner vorhandenen Informationen berücksichtigen zu lassen. Ihre Umsetzung in kognitiven Modellen ermöglicht dadurch die Erklärung ehemals als irrational deklarierten Verhaltens. Auf Basis dieser theoretischen Weiterentwicklung bayesianischer kognitiver Modellierung untersuche ich ihre Vorhersagequalität menschlichen Verhaltens in drei Domänen.

Zunächst greife ich ein existierendes Modell auf, das die Entstehung von Körperillusionen als rationale Integration mehrerer sensorischer Kanäle beschreibt. Bei Körperillusionen wird menschlichen Studienteilnehmenden durch eine Manipulation der sensorischen Kanäle der Eindruck vermittelt, dass sich ein eigenes Gliedmaß nicht dort befindet, wo es tatsächlich ist. Zwei bekannte Varianten solcher Illusionen sind als Rubber-Hand- beziehungsweise Rubber-Foot-Illusion bekannt. Das Modell wurde ehemals auf die Rubber-Hand-Illusion angewandt und war im Stande, qualitative Prognosen über das Zustandekommen der Illusion zu treffen. Es überschätzte jedoch ein quantitatives Kriterium einer erfolgreichen Körperillusion, den propriozeptiven Drift. In dieser Arbeit übertrage ich das komputationale Problem des Modells auf die Rubber-Foot-Illusion und zeige durch Neuauswertung eines bestehenden empirischen Datensatzes, dass die Überschätzung propriozeptiven Drifts von einem Teil des verwendeten Modells, des Priors, ausgeht. Bisherige Forschung hatte das Vorwissen menschlicher Studienteilnehmender als uniforme Verteilung modelliert, die statt der echten Position des menschlichen Gliedmaßes alle möglichen Positionen im Umfeld der Studienteilnehmenden als gleich wahrscheinlich darstellte. Durch die Verwendung von zwei Varianten eines informierten Priors,

der das echte Gliedmaß zu Beginn des Experiments dort verortet, wo es sich tatsächlich befindet, kann die Prognose propriozeptiven Drifts deutlich verbessert werden.

Das zweite Anwendungsfeld bayesianischer kognitiver Modellierung in dieser Arbeit betrifft menschliches Entscheidungsverhalten zwischen Optionen unter Berücksichtigung mehrerer Attribute je Option. Ich stelle zwei Studien vor, die sich inhaltlich mit dem Entscheidungsverhalten von Nutzenden von Online-Diensten befassen. Durch die mediale Berichterstattung über Datenlecks bei Konzernen, Wahlmanipulationsversuche und institutionelle Datensammlung mag der Eindruck entstehen, dass der Erhalt digitaler Privatsphäre im Fokus vieler Nutzenden stehen sollte. Dennoch berichtet die Forschungsliteratur vom sogenannten Privatsphären-Paradox: dem Umstand, dass Nutzende auf Nachfrage zwar Sorgen um den Verlust ihrer Privatsphäre äußern, aber dennoch dazu tendieren, Online-Dienste zu nutzen, die diesen Privatsphärenverlust ermöglichen. Mit Blick auf dieses Verhalten wird in der Literatur die Rationalität von Nutzenden angezweifelt. Stattdessen wird angenommen, dass Nutzende aufgrund begrenzter kognitiver Ressourcen eher auf Heuristiken statt auf Nützlichkeitsmaximierung im Sinne bayesianischer Entscheidungstheorie setzen. Es bedarf jedoch keiner Anwendung von Heuristiken, um das gezeigte Nutzungsverhalten zu erklären. Deshalb formalisiere ich ein rationales Prozessmodell, das Entscheidungen über die Nutzung hypothetischer Online-Dienste als Ergebnis eines Sampling-Prozesses von Präferenzen vorhersagt. Seine Leistung wird dabei mit zwei heuristischen und einer bayesianischen Variante ohne Sampling-Prozess verglichen. Die Modelle sagen die Anzahl an Entscheidungen für die Nutzung hypothetischer Online-Dienste auf Basis angegebener Präferenzen von Teilnehmenden in zwei Online-Studien vorher. Für die Mehrheit aller Stimuli stelle ich dabei fest, dass das rationale Prozessmodell die beste Vorhersagequalität bietet. Daraus leite ich Handlungsempfehlungen für die Gestaltung von Interventionen ab, die Nutzenden privatsphärenschützende Entscheidungsfindung ermöglichen sollen.

Zuletzt behandelt das dritte Anwendungsfeld dieser Arbeit die Modellierung menschlichen Entscheidungsverhaltens zwischen Optionen, die jeweils nur durch ein Attribut charakterisiert sind. Inhalt der Modellierung ist die Wahrnehmung nonverbalen Flirtverhaltens, die aufgrund seiner Prävalenz in vielen sozialen Kontexten unsicherheitsbehaftet ist. In einer Online-Studie wurden Teilnehmende gebeten, sich kurze Videoausschnitte anzusehen, in denen eine Schauspielerin verschiedene nonverbale Verhaltensweisen in zwei sozialen Kontexten darstellte. Für jedes gezeigte Verhalten sollten sie sich entscheiden, ob es eine Flirtintention ausdrücken sollte. Ob der Sampling-Prozess des rationalen Prozessmodells dieses Entscheidungsverhalten hinreichend besser vorhersagt als Alternativmodelle, wird in diesem Kapitel untersucht. Der Modellvergleich zwischen dem rationalen Prozessmodell, einem Angleichungsmodell und einem bayesianischen Modell ohne Sampling-Prozess zeigt, dass das Angleichungsmodell bessere Vorhersagen produziert, als beide anderen Modelle. Diesen Unterschied führe ich auf den jeweiligen Mechanismus zur Wissensrepräsentation beider Modelle zurück und diskutiere Erweiterungen der Modellstruktur.

Ich beende die Arbeit mit einer Einordnung des Verhaltens der verschiedenen betrachteten Modelle hinsichtlich psychologischer Plausibilität und lege dar, welche Eigenschaften das vorgestellte rationale Prozessmodell mit anderen empirisch erfolgreichen Modellierungsarten gemein hat. Diese einheitlichen Eigenschaften legen den Verdacht nahe, dass unterschiedliche Arten kognitiver Modellierung letzten Endes ähnliche Berechnungen in ihren jeweiligen Modellstrukturen abbilden und aufgrund dieser, nicht ihrer jeweiligen zugrundeliegenden Theorie, erfolgreich Vorhersagen über menschliches Verhalten treffen können. Als Konsequenz sollte zukünftige Forschung die

metakognitiven Systeme, die zur Entstehung dieser einheitlichen Eigenschaften psychologischer Prozesse führen, mitberücksichtigen.

Abstract

This dissertation addresses Bayesian cognitive modeling and its potential for the explanation and prediction of human behavior. Cognitive modeling differs from other modeling techniques in psychological research due to its attempt to formalize the process of information integration inside of an individual. Consequently, psychological constructs take a more precise and less flexible form in cognitive models compared to their implementation in mathematical or verbal-theoretical models. Bayesian cognitive models consider human behavior as the result of a probability-based process. They furthermore assume that human perception is subject to uncertainty. Humans learning about the state of their environment are assumed to assign degrees of belief to possible states that can be interpreted as probabilities that these states represent the truth. In addition, they are expected to reconsider their degrees of belief in environment states following the perception of new information. To do so, they apply Bayes' rule, a mathematical rule describing the calculation of conditional probabilities. When an individual holds an assumption about the state of their environment, they may believe that this assumption is true to a certain degree. Once the individual observes an event with relevance to the state of the environment, they judge the probability of observing that event given that the assumed state of the environment is correct. Bayes' rule specifies how to adjust the individual's degree of belief about the state of the environment in relation to the probability of the observed event. Previous investigations of human perception and decision making seem to indicate that it is not an accurate description of how humans process information about the state of their environment. By recognizing resource-related restrictions however, previous research was able to rationalize seemingly irrational phenomena in the description of human cognition. For example, the sampling hypothesis describes humans as using only parts of their available information about the world due to resource constraints, rather than as fully-fledged Bayesian agents. Its formalization as part of cognitive models therefore enables the rationalization of behavior that previously appeared irrational. Based on this theoretical advancement of Bayesian cognitive modeling, I investigate its quality of prediction concerning human behavior in three domains.

To begin with, I adopt an existing model that describes the emergence of body illusions as the rational integration of multiple sensory channels. Body illusions are elicited in human experiment participants by the manipulation of sensory channels so that they are under the impression that one of their actual limbs is not where it is physically located. Two typical experimental setups are the Rubber Hand Illusion and Rubber Foot Illusion. The model in question was previously used to predict the emergence of the Rubber Hand Illusion qualitatively. Quantitatively, however, it overestimated an empirical dependent variable known as proprioceptive drift. In this dissertation, I transfer the model's computational problem to the Rubber Foot Illusion and apply it to an existing empirical data set. I demonstrate that the overestimation of proprioceptive drift originates from a specific part of the model known as the prior. A previous study had modeled the prior knowledge of participants as a uniform distribution, making every possible position on a horizontal plane in front of them seem equally plausible as an estimate of the limb's position. By using two variants of an informed prior centered at the real physical position of the limb, the prediction of proprioceptive drift is shown to be improved significantly.

The second research area of this dissertation concerns human decisions between options described by multiple attributes. I present two original studies that focus on decision making of users regarding online services. Media coverage regarding commercial data leaks, attempted election manipulations and institutional data collection may give the impression that online privacy preservation should be on users' minds. Research has however identified a phenomenon called the privacy paradox: when

questioned, users do report concern about losing privacy and valuable data, but they still tend to use services that enable loss of privacy. This behavior and divergence from stated preferences leads scholars to question users' rationality. Instead, it is assumed that users rely on heuristics rather than subjective utility maximization as would be rational following Bayesian decision theory due to limited cognitive resources. However, applying heuristics is not required to produce the observed user behavior. To show this, I formalize a rational process model that predicts participant choices for or against the use of hypothetical online services as the result of sampling from their preferences. The model's performance is subsequently compared to two heuristic alternatives as well as a Bayesian model variant omitting the sampling process. The models aim to predict the number of use choices for the hypothetical online services based on stated preferences of participants in the two online studies. For the majority of investigated stimuli, the rational process model shows the best predictive quality. I derive recommendations for intervention design focused privacy protecting decision making.

Finally, the third research area of this dissertation focuses on modeling human decisions between options where each is described by a single attribute. I present a comparison between models that predict the perception of nonverbal flirt behavior, which is subject to uncertainty due to its prevalence in many social contexts. Participants in an online study were asked to view short video clips in which an actress performed several nonverbal behaviors in two social contexts. For every behavior shown, participants were asked to decide whether it expressed the intention to flirt. I investigate whether the rational process modeling approach produces sufficiently better predictions of said decisions than alternative models. The resulting comparison between the rational process model, a probability matching model and a Bayesian model omitting the sampling process shows that the probability matching model produces better predictions than both other models. I attribute the difference in predictive quality to the differing mechanisms of agent knowledge representation between models and discuss extensions to the respective model structures.

I conclude the dissertation by classifying the behavior of the proposed models regarding their psychological plausibility and point out similarities between the rational process model and other empirically successful forms of cognitive models. These similarities suggest that several different paradigms of cognitive modeling ultimately conduct similar computations in their respective model structures and that they, not the theories surrounding them, are important to arrive at successful predictions of human behavior. Consequently, future research should make efforts to consider the meta-cognitive systems that lead to these similar functions between modeling paradigms.

1. Einleitung

Die psychologische und kognitionswissenschaftliche Forschung beschäftigt sich mit der Frage, wie der Mensch auf Basis einer großen, aber unvollständigen und unsicheren Menge an Informationen seine täglich unter Beweis gestellte Fähigkeit zum Lernen und Schlussfolgern umsetzt. Die Fähigkeit beispielsweise, zwischen zwei verschiedenen Hunderassen zu unterscheiden, diese Hunderassen konzeptionell von anderen Säugetieren zu trennen und sie aufgrund ihrer Eigenschaft, auf vier Beinen zu stehen, nicht mit Stühlen oder Tischen zu verwechseln, wirkt intuitiv wie keine besonders aufwendige Leistung. Um diesen Prozess zu formalisieren, bedarf es tatsächlich jedoch eines ausführlichen theoretischen Fundaments hinsichtlich der menschlichen Generalisierungs- und Wahrnehmungsfähigkeiten (Xu & Tenenbaum, 2007). Ähnliches gilt für die menschliche Sensomotorik, die zwischen einem unbedachten Stolpern beim Laufen selbst auf ebenem Grund und sportlichen Weltrekorden erstaunlich vielseitiges Verhalten produzieren kann. Das Erkennen der Trajektorie eines Tennisballs und das Auslösen einer angebrachten motorischen Aktion zum Erzielen eines Punkts in einem Tennisspiel (Körding & Wolpert, 2006) erscheint auf den ersten Blick ebenfalls wie eine Leistung, die mit etwas Übung durchaus zu bewerkstelligen ist. Die im Hintergrund notwendigerweise ablaufenden Prozesse zur Integration verschiedener Sinneskanäle und zur Auswahl einer geeigneten motorischen Strategie scheinen formalisiert jedoch in keinem Verhältnis zu der Leichtigkeit zu stehen, mit der Menschen jeden Tag zahlreiche vergleichbare Aufgaben bewältigen. Für die solchen Phänomenen zugrundeliegenden Prozesse gibt es bislang keine einheitliche Theorie (Gigerenzer, 2010). Das liegt teilweise an der Vielfältigkeit des Forschungsgegenstands menschlichen Verhaltens, aber auch an der mangelnden Prävalenz von Theorie in der Psychologie (Beller & Bender, 2017). Während Beller und Bender (2017) den Werdegang der Psychologie als eigenständige Wissenschaft und ihr Selbstverständnis als solche aufzeigen, betrachten sie ihr Interesse an Theoriebildung und -entwicklung kritisch. Sie verstehen hierbei eine Theorie als eine systematische Beschreibung beobachtbarer Phänomene, die von größerem Ausmaß als diese Phänomene und Muster sei und versuche, deren Beziehungen untereinander und Ursprünge zu erklären. Eine solche fehle der Psychologie laut Gigerenzer (2010), sodass viele domänenspezifische Theorien an die Stelle einer übergreifenden Theorie träten. Beller und Bender (2017) untersuchten Referenzen zu spezifischen Theorien in 2046 im Journal *Frontiers in Psychology* veröffentlichten Artikeln aus dem Jahr 2015 und fanden solche nur in 10% aller Artikel. Darunter wurden selbst die am häufigsten erwähnten Theorien nur in jeweils 0,5% aller Artikel gefunden, was die geringe Prävalenz und domänenspezifische Diversität psychologischer Theorien unterstreicht. Es herrscht allerdings Unsicherheit darüber, ob dieser Umstand ein Problem für die Psychologie darstellt. Beller und Bender (2017) stellen ihrer Forderung nach stärkerer Einbindung von Theoriebildung in der Psychologie exemplarisch Simons (Simons, 2014) entgegen, der kumulative Wissenschaft und die Ermittlung reliabler Effekte zum wichtigeren Ziel der Psychologie erklärt, solange Theorien unvollständig und flexibel genug sind, um spontan ersetzt zu werden oder neue Vorhersagen nach Einsicht der Datenlage zu tätigen. Wie die Replikationskrise in der empirischen Forschung (Lilienfeld & Waldman, 2017; Open Science Collaboration, 2015; Trafimow, 2017) nahelegt, ist der neugefundene Fokus auf Replizierbarkeit von Effekten zwar von großer Relevanz für den Fortschritt und die Glaubwürdigkeit der Psychologie als Wissenschaft, jedoch sollte unterdessen die Entwicklung und Konsolidierung von Theorien nicht vernachlässigt werden. Durch ihre Fähigkeit zur Generalisierung über beobachtete Phänomene hinaus sind Theorien ein essentieller Bestandteil wissenschaftlicher Praxis – zumindest, solange sie oder ihre

Implementierungen hinreichend präzise sind, um die Möglichkeit zur Falsifizierung oder zum Vergleich mit anderen Theorien und deren Implementierungen zu ermöglichen.

Die breite, wenn auch in aktueller Forschung nur selten herangezogene theoretische Landschaft ist von besonderer Relevanz, weil komputationale Psychologie und Kognitionswissenschaft den Einsatz von Modellen zur Erklärung beobachtbarer Phänomene nutzen. Zunächst stellt Stafford (2009) den Zusammenhang zwischen Theorien und Modellen her: „Models do the work of theories. If this is accepted, then, like theories, models provide explanations“. Er vertritt die Ansicht, dass sich Modellierung als Aktivität ausschließlich durch ihre Beziehung zur Erklärung des modellierten Phänomens rechtfertigen lässt. Um unterschiedliche Arten von Modellen als Implementierungen von Theorien zu differenzieren, bediene ich mich der Kategorisierung von Sun (2008a), der Modelle in komputationale, mathematische und verbal-konzeptionelle Arten einteilt. Komputationale Modelle zeichnen sich laut ihm durch ihre Repräsentation des modellierten Prozesses durch algorithmische Beschreibungen aus, während mathematische Modelle die Beziehung zwischen Variablen durch Gleichungssysteme beschreiben. Die in der empirischen Forschung verbreitete Inferenzstatistik und datenanalytische Methoden fallen also in diese Kategorie an Modellen und unterscheiden sich durch ihre Perspektive von komputationalen Modellen. Verbal-konzeptionelle Modelle können zwar dasselbe Phänomen beschreiben wie Modelle auf den anderen Ebenen, sie verwenden aber üblicherweise informelle natürliche Sprache anstelle von algorithmischer oder mathematischer Spezifikation. Es ist das benötigte Ausmaß an Formalisierung und Präzision eines komputationalen Modells, die Anwender dieser Kategorie an Modellen zum Schluss führt, die vielversprechendste der hier vorgestellten Modellierungsarten für die Implementierung ihrer Theorie gewählt zu haben (Farkaš, 2012; Sun, 2008a). Murphy (2011) argumentiert, dass modellierende Forschende expliziter in Hinblick auf ihre zugrundeliegende Theorie sein müssen, um ihr Modell anzuwenden, als es ein verbal-konzeptionelles Modell notwendig machen würde. Hiermit verlören sie den Spielraum, Prozesse vage oder mehrdeutig zu definieren und Aspekte des Modells nach einer Falsifizierung unterschiedlich zu interpretieren als vorher. Die Allgegenwärtigkeit von komputationalen Modellen kann aufgrund verschiedener Argumente kritisch beäugt werden, wie Murphy (2011) ausführt. So gäbe es bei ersten Forschungskontakten mit einer neuen Domäne schlichtweg nicht genug Informationen, um direkt auf eine formalisierbare Theorie zurückgreifen zu können. Er stellt klar, dass der Entwicklung einer Theorie, die zum Modell verarbeitet werden könne, zunächst eine akkurate Beschreibung empirischer Beobachtungen vorangehen muss. Ein zweites Argument zur Skepsis gegenüber komputationalen Modellen sei die häufig beobachtbare Fokussierung auf Teilbereiche menschlicher Kognition, obwohl das modellierte Phänomen möglicherweise die Zusammenarbeit verschiedener Teilsysteme erfordere. Zuletzt legt er dar, dass komputationale Modelle als üblicherweise sehr zeit- und arbeitsintensive Erzeugnisse beteiligter Forscher die Gefahr mit sich bringen, sich zu sehr mit der Theorie des Modells zu identifizieren und dabei den kumulativen Aspekt der Modellbildung aus dem Blick zu verlieren. Dieser Aspekt baut auf einem häufig verwendeten Zitat auf, das auch für die spätere Beurteilung der präsentierten Modelle dieser Arbeit von Relevanz sein wird: „Alle Modelle sind falsch, aber manche sind nützlich“ (original: „All models are wrong, but some are useful“; Box & Draper, 1987)

Durch die Formalisierung komputationaler Modelle erreichen sie also eine Präzision in ihren Vorhersagen, die verbal-konzeptionelle Modelle nicht erreichen. Hierbei ist unter Präzision noch nicht die Vorhersagequalität in Bezug auf gesammelte Daten zu verstehen, sondern ein Mangel an Ambivalenz in der Prozessbeschreibung zwischen Eingangsdaten und Modellausgabe. Nach der Datenerhebung kann die Vorhersage eines komputationalen Modells auf Basis verschiedener Kriterien

mit der empirischen Beobachtung auf der einen und plausiblen Modellalternativen auf der anderen Seite verglichen werden. Chown (2014) betont, dass es keine nachweislich richtigen Algorithmen für komputationale Modelle gibt. Modelle würden kontinuierlich vorgeschlagen und abgelehnt, und man hoffe darauf, die den Modellen zugrundeliegenden Beobachtungen mit jeder Iteration genauer vorhersagen zu können. Unter dieser Betrachtungsweise lässt sich zumindest für den Augenblick ein Modell finden, das das beobachtbare Verhalten am besten erklärt, solange man der Interpretation Staffords (2009) von Modellen als Implementierungen von Theorien folgt. Deshalb ist die Präzision der Vorhersage einer Theorie und dem Modell, das sie implementiert, für seine Evaluation und den Vergleich zu Alternativmodellen relevant. Popper (2005) stellt in Bezug auf die Vorhersageflexibilität einer Theorie fest: „A theory that can explain everything explains nothing“. Hieran lässt sich erneut ein Vorteil komputationaler gegenüber verbal-theoretischer Modelle aufzeigen, denn durch die notwendige Formalisierung kann präziser bestimmt werden, ob ein Modell das beobachtbare Verhalten tatsächlich vorhersagen kann oder ob es außerhalb der Vorhersage liegt. Gleichzeitig ist die Präzision einer Vorhersage nicht das einzige Kriterium, das bei der Differenzierung der Modellkategorien nach Sun (2008) beachtet werden sollte. Er stellt am Beispiel des Behaviorismus dar, dass die Vernachlässigung generativer Prozesse und Mechanismen bei der Beobachtung menschlichen Verhaltens problematisch sein kann. So sei es seiner Aussage nach ebenso schwierig, beispielsweise ein komplexes Computersystem rein auf der Basis seines Verhaltens zu verstehen, ohne Vorwissen über die interne Funktionsweise und theoretische Natur des Systems zu besitzen. Dieser Argumentation folgend kann also auch ein mathematisches Modell, das einen beliebigen Datensatz sehr gut vorhersagt, einem komputationalen Modell unterlegen sein, wenn es um das Verständnis generativer Prozesse geht. In dieser Dissertation nutze ich bayesianische komputationale Modelle, um die interne Funktionsweise ausgewählter menschlicher Verhaltensphänomene und ihren generativen Prozess darzustellen.

Bayesianische komputationale Modelle setzen voraus, dass menschliche kognitive Prozesse unsicherheitsbehaftet sind. Sie stellen den Prozess der bayesianischen Inferenz als möglichen Mechanismus dar, um mit besagter Unsicherheit umzugehen. Anwendung fanden die Modelle beispielsweise zur Erklärung von Phänomenen in den Bereichen der Kategorisierung (Tenenbaum & Griffiths, 2001), des Lernens (Kruschke, 2008), der visuellen Wahrnehmung (Weiss, Simoncelli, & Adelson, 2002; Yuille & Kersten, 2006), sensomotorischen Verhaltens (Körding & Wolpert, 2006; Orbán & Wolpert, 2011), des Spracherwerbs und -verständnisses (Goodman & Stuhlmüller, 2013; Xu & Tenenbaum, 2007) oder sozialer Kognition (Baker & Tenenbaum, 2014; Jara-Ettinger, Gweon, Schulz, & Tenenbaum, 2016). Die beschriebenen Modelle unterscheiden sich durch ihre Perspektive von der Art bayesianischer Inferenz, die zusehends in mathematischen beziehungsweise datenanalytischen Modellen Anwendung findet. Für eine Zusammenfassung dieses Anwendungsfeldes verweise ich Leserinnen und Leser auf Kruschke (2010). Anders als für die objektive, externale Beschreibung der Beziehung zwischen Variablen genutzt, wird bayesianische Inferenz in bayesianischen komputationalen Modellen als adäquate Beschreibung des Prozesses gesehen, der das beobachtete menschliche Verhalten erzeugt. Stellt ein Modell dabei den individuellen Verarbeitungsprozess von Informationen dar, wird das repräsentierte Individuum als Agent bezeichnet. Bayesianische komputationale Modelle gehören der Familie der probabilistischen Modelle an. Sie folgen der Annahme, dass ein zu modellierender Agent verschiedene Hypothesen über seine Umwelt aufstellt und deren Wahrscheinlichkeit nach dem Erhalten neuer Informationen entsprechend des Satzes von Bayes aktualisiert. Gleichung 1.1 beschreibt diesen Vorgang.

$$p(h_i|d) = \frac{p(d|h_i)p(h_i)}{\sum_{h \in \mathcal{H}} p(d|h)p(h)} \quad (1.1)$$

$p(h_i)$ beschreibt den Prior. Er definiert die Wahrscheinlichkeit der Hypothese h_i vor dem Sammeln weiterer Informationen. Der Prior wird im Zähler der Gleichung mit $p(d|h_i)$ multipliziert, der Likelihood. Sie beschreibt, wie wahrscheinlich beobachtete neue Informationen gegeben der Annahme sind, dass h_i zutrifft. Sie werden zur Normalisierung im Nenner durch die Summe der Produkte aus Prior und Likelihood für alle Hypothesen geteilt. Daraus ergibt sich $p(h_i|d)$, der Posterior. Er beschreibt die Wahrscheinlichkeit der Hypothese h_i nach Beobachtung und Integration neuer Informationen. Die beschriebenen Wahrscheinlichkeiten entsprechen hierbei keiner streng frequentistischen Interpretation, sondern dem Ausmaß, mit dem der Agent an das Eintreten eines Ereignisses oder das Zutreffen einer Hypothese glaubt (Perfors, Tenenbaum, Griffiths, & Xu, 2011). Da sowohl die Wahrscheinlichkeit des Zutreffens einer Hypothese als auch die Beweiskraft neuer Informationen unsicherheitsbehaftet sind, ist der Satz von Bayes die mathematisch rationale Methode, die Wahrscheinlichkeit des Zutreffens einer Hypothese nach der Integration mit neuen Informationen zu beurteilen. Über die Anwendung des Satzes von Bayes ist es dem Agenten möglich, aufgrund der von ihm beobachteten Datenlage Rückschlüsse auf die Wahrscheinlichkeit von Hypothesen zu ziehen. Der sequentielle Charakter des Satzes von Bayes ermöglicht an jedem Zeitschritt den Einbezug neuer Informationen, das Updating. So kann der Agent zu jedem Zeitpunkt aufhören, neue Informationen zu sammeln und herauszufinden, welche Hypothese h_i über seine Umwelt am ehesten zutrifft. Ein voreiliges Einstellen der Suche nach neuen Informationen kann jedoch zu einer falschen Schlussfolgerung führen. Unabhängig davon, ob der Agent auf Basis der aktuellen Informationslage zum richtigen Schluss über die zutreffende Hypothese h_i kommt, hat er mit dem Satz von Bayes dennoch die mathematisch rationale Art gewählt, um die bedingte Wahrscheinlichkeit des Posteriors $p(h_i|d)$ zu ermitteln. Während der Satz von Bayes und seine Anwendung zum Aktualisieren von Wahrscheinlichkeiten mathematisch unstrittig sind, wird seine Implementierung in komputationalen Modellen intensiv diskutiert. In den folgenden zwei Teilkapiteln stelle ich die zwei Ursachen für diese Diskussion dar.

1.1. Geltungsbereich bayesianischer Modelle

Der erste von zwei Diskussionspunkten betrifft den Geltungsbereich, den Forscher dem Satz von Bayes in komputationalen Modellen zuschreiben. So können unterschiedlich starke Annahmen darüber getroffen werden, ob bayesianische Inferenz nur als adäquate Beschreibung eines beobachteten Verhaltens dient oder tatsächlich Teil der Berechnungen ist, die der Agent durchführt. Jones und Love (2011) betiteln die Perspektive, dass menschliches Verhalten durch bayesianisch-rationale Analyse ohne Einbezug von prozessbezogenen Spezifikationen wie Knappheit kognitiver Ressourcen oder neuronaler Implementierung hinreichend erklärbar sei, als „bayesianischen Fundamentalismus“ (Original: „bayesian fundamentalism“). Sie kritisieren diese Perspektive aufgrund ihrer Konzentration auf eine von mehreren Analyseebenen, von denen aus man komputationale Modelle und die modellierten Systeme betrachten kann. Marr (1982) definiert drei solcher Ebenen: zunächst die komputationale Ebene, deren Betrachtungsgegenstand der Inhalt einer Berechnung ist. Die Logik und Struktur eines Problems werden hier erfasst. Die der Berechnung zugrundeliegenden Prozesse und

Repräsentationen werden auf der algorithmischen Ebene beschrieben. Zuletzt ist die biologische oder mechanische Umsetzung in Lebewesen oder künstlichen Agenten Gegenstand der Implementierungsebene. Anders ausgedrückt bezeichnet die komputationale Ebene, warum ein kognitives System welches Problem löst, die algorithmische Ebene hingegen, wie das System vorgeht, und die Implementierungsebene, wo im physischen System dieser Vorgang realisiert wird (Zednik & Jäkel, 2014). Zu Beginn der Arbeit habe ich von komputationalen Modellen geschrieben, um sie von mathematischen und verbal-theoretischen Modellen abzugrenzen. Aufgrund der semantischen Überschneidung mit Marrs komputationaler Ebene schreibe ich fortan von kognitiven Modellen, weil diese alle drei Ebenen Marrs berücksichtigen können. Ein Kritikpunkt von Jones und Love (2011) gegenüber dem bayesianischen Fundamentalismus ist also der mangelnde Kontakt zu mehr als nur der komputationalen Ebene von Marr. Im Kontrast dazu steht ihrer Ansicht nach die „bayesianische Aufklärung“ (Original: „bayesian enlightenment“). Diese Perspektive zeichne sich dadurch aus, dass sie die Verbindung zwischen komputationaler und algorithmischer Ebene suche und dadurch eine Verbindung zur größtenteils auf letzterer stattfindenden psychologischen Forschung und Theorie herstelle. Ein weiterer kritischer Unterschied sei jedoch auch, dass bayesianische Aufklärung die Elemente eines bayesianischen kognitiven Modells als Bestandteile psychologischer Prozesse und Repräsentationen betrachte, statt als rein mathematische Komponenten ohne psychologische Relevanz. Dennoch beschränkten sich viele Beispiele bayesianischer Modellierung auf den Bereich bayesianischen Fundamentalismus, tätigten also auch keine Aussage zum Geltungsbereich ihrer Bestandteile.

Eine ähnliche Kategorisierung wird von Bowers und Davis (2012) vorgenommen. Sie unterteilen bisherige Anwendungen bayesianischer Modelle in extreme, methodische und theoretische Ansätze. Der extreme Ansatz stimmt insofern mit dem von Jones und Love (2011) erwähnten bayesianischen Fundamentalismus überein, als dass er die algorithmische Ebene bewusst ausklammert und sich Erkenntnis aus der Anwendung rationaler Analyse auf der komputationalen Ebene verspricht. Der methodische Ansatz verwendet bayesianische Modelle als Werkzeuge, um die Nähe menschlichen Verhaltens zu optimalem Verhalten zu evaluieren. Aus dieser Perspektive sei die approximative Optimalität menschlichen Verhaltens zwar bemerkenswert. Sie lege aber nur nahe, dass die vom Menschen verwendeten Algorithmen imstande seien, solches Verhalten zu erzeugen und nicht etwa notwendigerweise bayesianische Elemente beinhalten. So ließe der methodische Ansatz Spielraum für die Möglichkeit, dass der menschliche Verstand klar nicht-bayesianische Berechnungen durchführe, um trotzdem Bayes-optimalem Verhalten zu ähneln. Zuletzt stimme der theoretische Ansatz mit dem methodischen darin überein, dass Modelle auf der komputationalen Ebene sinnvolle Einschränkungen für die Theoriebildung auf der algorithmischen Ebene liefern können, behaupte aber explizit, dass der menschliche Verstand zur Bewältigung der modellierten Probleme bayesianische Inferenz anwende. Dies bedeute, dass der menschliche Verstand Priors in Form von Wahrscheinlichkeitsverteilungen speichere, die Likelihood wahrgenommener Daten beurteile, Priors und Likelihoods multipliziere und diesen Prozess für zumindest einige, wenn nicht alle verfügbaren Hypothesen wiederhole, um zum Posterior zu gelangen. Während die Unterscheidung zwischen methodischem und theoretischem Ansatz prinzipiell klar seien, würde sie praktisch durch zwei problematische Aspekte erschwert. Zunächst seien viele Probleme auf dem komputationalen Level nur schwer analytisch lösbar, sodass Approximationen gesucht werden müssten, die auf dem algorithmischen Level eine Unterscheidung zu anderen Theorien wie ökologischer Rationalität (Goldstein & Gigerenzer, 2002) oder dem Verzerrungs- und heuristischen Paradigma (Kahneman & Tversky, 1979) erschwerten. Darüber hinaus

drückten sich viele Forscher in Bezug auf ihre Position zwischen den von Bowers und Davis (2012) postulierten Ansätzen unklar oder widersprüchlich aus.

In Bezug auf den Geltungsbereich bayesianischer kognitiver Modelle bezüglich der Analyseebenen nach Marr (1982) sehen Jones und Love (2011) sowie Bowers und Davis (2012) also einen zu starken Fokus auf die komputationale Ebene und rationale Analyse bei bayesianischen Fundamentalisten oder Theoretikern. Dadurch verlören die modellierenden Forscher den Bezug zu Prozesstheorien und algorithmischen Spezifikationen und gingen mit ihrer eigenen Positionierung bezüglich des Geltungsbereiches ihrer Modelle zu flexibel um. Beide Quellen heben zudem hervor, dass der Bezug zu mehr als der komputationalen Ebene schon allein aufgrund der analytischen Komplexität (Original: „intractability“) bayesianischer Probleme in der realen Welt notwendig sei. So kann ein Lehrbuchbeispiel zu bayesianischer Inferenz zwischen wenigen Hypothesen zwar noch nachvollziehbar sein, reale Fragestellungen erweitern aber den Hypothesenraum und erhöhen die analytische Komplexität eines Problems massiv. Während die analytische Komplexität bayesianischer Probleme in realen Szenarien unstrittig ist, weisen einige Vertreter bayesianischer kognitiver Modellierung den Vorwurf der Beschränkung auf die komputationale Ebene bei gleichzeitiger Generalisierung ihrer Ergebnisse auf andere Ebenen jedoch zurück (Chater et al., 2011; Griffiths, Chater, Norris, & Pouget, 2012). Sie argumentieren, dass die tatsächlich schwer vertretbaren Generalisierungen des bayesianischen Fundamentalismus (M. Jones & Love, 2011) und des theoretischen Ansatzes (Bowers & Davis, 2012) durchaus verurteilenswert seien, wenn sie denn existierten. Tatsächlich seien die bayesianische Aufklärung und der methodische Ansatz die gängige Vorgehens- und Interpretationsweise bayesianischer Modelle, die auf der komputationalen Ebene konstruiert seien. Als Beleg hierfür ziehen sie Arbeiten heran, die aus den empirischen Erfolgen bayesianischer Modelle auf der komputationalen Ebene Restriktionen für die algorithmische Ebene ableiten (Shi, Griffiths, Feldman, & Sanborn, 2010; Vul, Goodman, Griffiths, & Tenenbaum, 2014). Dabei steht der von Bowers und Davis (2012) erwähnte bayesianische Algorithmus, also das explizite Speichern von Priors in Form von Wahrscheinlichkeitsverteilungen und die Multiplikation und Normalisierung mit der Likelihood der Daten über verschiedene Hypothesen hinweg, explizit nicht im Fokus solcher Erweiterungen auf die algorithmische Ebene. Stattdessen beinhalten die erwähnten Algorithmen Funktionen, die auf komputationaler Ebene den Nutzen von beispielsweise Likelihood-Funktionen erfüllen, aber eng mit psychologischen Dimensionen wie Gedächtniskapazität (Vul et al., 2014) oder Stimulusähnlichkeit (Shi et al., 2010) zusammenhängen.

In dieser Arbeit schließe ich mich der Interpretation von Chater et al. (2011) sowie Griffiths et al. (2012) bezüglich des Geltungsbereichs bayesianischer kognitiver Modelle an. Eine Begrenzung auf die komputationale Ebene ist für Beispiele realen Ausmaßes aufgrund steigender analytischer Komplexität nicht sinnvoll, jedoch sind auch Generalisierungen von rein komputationalen Modellen auf Prozess- oder Implementierungsebene nicht üblich. So wäre es vereinfachend, beispielsweise auf neuronaler Ebene nach Implementierungen von Priors und Likelihoods zu suchen. Gleichzeitig scheint die nah-optimale Leistung von Menschen in sensomotorischen Experimenten durch probabilistische Eigenschaften von Neuronen ermöglicht zu werden, die mathematisch exakt diese Funktionen übernehmen (Doya, 2011; Knill & Pouget, 2004; Ma, Beck, Latham, & Pouget, 2006). Ein entscheidendes Argument für eine Integration mehrerer Analyseebenen im Sinne des methodischen Ansatzes von Bowers und Davis (2012) ist zudem die Entwicklung von Restriktionen auf einer Modellierungsebene, die durch Erkenntnisse auf einer anderen Ebene notwendig wurden. Dieser iterative Charakter unterstützt den Anspruch kognitiver Modellierung, sukzessiv genauer in der

Vorhersage menschlichen Verhaltens zu werden und schwächt die Tendenz ab, Modellvergleiche als einen Konflikt um Deutungshoheit zwischen Forschungsparadigmen zu betrachten.

1.2. Normativität, Rationalität und Entscheidungstheorie

Der zweite Diskussionspunkt bayesianischer kognitiver Modelle bezieht sich auf den normativen Charakter des Satzes von Bayes und seinen Bezug zur Entscheidungstheorie. Letztere kann in deskriptive und normative Betrachtungsweisen unterteilt werden (Peterson, 2009). Während deskriptive Entscheidungstheorie beschreibt, wie Menschen sich tatsächlich entscheiden, postuliert die normative Entscheidungstheorie Prinzipien, anhand derer die Rationalität des Entscheidenden beurteilt werden kann. Da viele Entscheidungsszenarien, vor die menschliche Agenten im Alltag gestellt werden, risiko- oder unsicherheitsbehaftet sind, gibt es seit jeher einen starken Bezug zwischen den Prinzipien der Wahrscheinlichkeitsrechnung und normativer Entscheidungstheorie. Der Satz von Bayes als Mittel zur Berechnung bedingter Wahrscheinlichkeiten bildet also die normative Grundlage, um Risiken und Informationen in unsicherheitsbehafteten Szenarien zu integrieren. An dieser Stelle sei erneut darauf hingewiesen, dass die erwähnten Wahrscheinlichkeiten in bayesianischer kognitiver Modellierung als Ausmaß des Vertrauens in das Zutreffen von Hypothesen interpretiert werden können (original: „degrees of belief“; Perfors et al., 2011). Die Wahrscheinlichkeit, dass eine beliebige Hypothese über den Zustand der Umwelt des Agenten zutrifft, ist als vom Agenten postulierte subjektive Wahrscheinlichkeit zu interpretieren. Zweifellos räumen „degrees of belief“ losgelöst von frequentistischen Beobachtungen der Umwelt dem bayesianischen Agenten zusätzliche Freiheitsgrade ein. So können sich die Wahrscheinlichkeiten, die dem Zutreffen einer Hypothese zugeschrieben werden, zwischen Agenten und zwischen verschiedenen Zeitpunkten unterscheiden, unabhängig davon, ob der Inhalt der Hypothese objektiv häufiger oder seltener zu beobachten ist. Trotz dieser subjektiven Interpretation von Wahrscheinlichkeiten produziert der Satz von Bayes die normative Lösung für das Ermitteln bedingter Wahrscheinlichkeiten im Posterior. Ein Agent, der seine subjektiven Wahrscheinlichkeiten unabhängig ihrer objektiven Korrektheit über den Satz von Bayes integriert, handelt demnach rational. Auf Entscheidungsszenarien übertragen spricht man von Rationalität, wenn der Agent bei der Wahl zwischen zwei unsicherheitsbehafteten Optionen den erwarteten Nutzen maximiert (Morgenstern & Von Neumann, 1953), also bei gleichen ausstehenden Belohnungen die Option wählt, die mit höherer Wahrscheinlichkeit zu einer Belohnung führt. Bayesianische Entscheidungstheorie integriert den Prozess des Updatings der Wahrscheinlichkeit einer Hypothese über den Satz von Bayes mit der Wahl zwischen Hypothesen (Peterson, 2009). Hat der Agent beobachtete Informationen aus der Umwelt zu einem subjektiven Posterior über die Wahrscheinlichkeit der berücksichtigten Hypothesen verarbeitet und soll sich zwischen Hypothesen entscheiden, sollte er diejenige wählen, die den erwarteten Nutzen auf Basis seines Posteriors maximiert.

Dieser normativen Argumentation zum Trotz verweist ein wesentlicher Teil der psychologischen Forschung seit Jahrzehnten auf Abweichungen menschlichen Verhaltens von rationalen Maßstäben. Beispielsweise scheinen Menschen Basisraten, wie sie im bayesianischen Prior erfasst wären, zu ignorieren (Eddy, 1982), Wahrscheinlichkeiten nichtlinear zu gewichten (Kahneman & Tversky, 1979), diverse nicht bayesianische Heuristiken anzuwenden (Domurat, Kowalczyk, Idzikowska, Borzymowska, & Nowak-Przygodzka, 2015) oder die erwartbare Nützlichkeit in der Wahl zwischen Optionen nicht zu maximieren (Shanks, Tunney, & McCarthy, 2002). Es sind diese empirischen Befunde, die

bayesianische Fundamentalisten laut Jones und Love (2011) ignorieren und nicht zur Restriktion kognitiver Modelle einbeziehen würden, weil ihre Berücksichtigung die Betrachtung eines kognitiven Systems auf mehr als der komputationalen Ebene benötigen würde. Die systematischen Abweichungen von bayesianischer Entscheidungstheorie stellen deshalb ein Problem dar, weil sie in Frage stellen, ob der menschliche Verstand rationalen Prinzipien folgt. Folgt er ihnen nicht, können auf ihrer Basis keine einheitlichen Gesetze der Funktionsweise von menschlicher Kognition abgeleitet werden und eine Generalisierung von erhobenen Daten zu zugrundeliegenden Phänomenen wird erschwert (Lieder, Griffiths, M. Huys, & Goodman, 2017).

Die im vorherigen Teilkapitel erwähnte Überbrückung von Betrachtungsebenen kognitiver Systeme kann jedoch genutzt werden, um empirisch validierte Abweichungen menschlichen Verhaltens von normativen Prinzipien zur Restriktion kognitiver Modelle zu nutzen. Tatsächlich schlagen Vertreter bayesianischer kognitiver Modellierung Wege vor, wie empirische Befunde zur Verletzung rationaler Prinzipien mit einer Erweiterung bayesianischer Modelle auf die algorithmische Betrachtungsebene vereinbar sind (Bonawitz, Denison, Gopnik, & Griffiths, 2014; Gershman, Horvitz, & Tenenbaum, 2015; Griffiths, Lieder, & Goodman, 2015; Lieder et al., 2017; Lieder, Hsu, & Griffiths, 2014; Sanborn, Griffiths, & Navarro, 2010; Srivastava & Vul, 2015; Tenenbaum, Kemp, Griffiths, & Goodman, 2011). Diese Modellvorschläge setzen voraus, dass die komputationale Kapazität des Agenten in die Definition und Evaluation von Rationalität einbezogen wird, die von ihm erwartet wird (Lieder et al., 2017). Konzeptionell ähneln sie daher dem Begriff der begrenzten Rationalität (original: „bounded rationality“; Simon, 1955), nutzen diese aber nicht als Argument für die Entstehung von Heuristiken als adaptivem Werkzeugkasten für die Lösung kognitiver Probleme (Gigerenzer & Selten, 2002). Stattdessen formalisieren sie den Zielkonflikt zwischen Dauer und Genauigkeit beim Lösen eines komputationalen Problems und zeigen auf, dass der Hang eines Agenten zu logik- oder wahrscheinlichkeitstheoretischen Prinzipien kein alleiniger Indikator von Rationalität ist. So sprechen Griffiths et al. (2015) von ressourcenbezogener Rationalität (original: „resource rationality“), während Vul et al. (2014) das Konzept globale Rationalität (original: „global rationality“) nennen. Alle drei Bezeichnungen haben gemein, dass sie dem Agenten Kosten für die Verwendung kognitiver Ressourcen unterstellen, sodass er in Abhängigkeit des zu lösenden Problems intrinsisch motiviert ist, lokal suboptimales Verhalten zu tolerieren, um einen global rationalen Ressourcenhaushalt zu gewährleisten. Modelle, die dieses Agentenverhalten implementieren, werden als rationale Prozessmodelle bezeichnet (Griffiths, Vul, & Sanborn, 2012).

1.3. Die Sampling-Hypothese

Sanborn und Chater (2016) stellen einen Ansatz vor, mit dessen Hilfe bayesianische Modellierung und oftmals gegenläufig scheinende empirische Befunde konsolidiert werden können. Sie beschreiben den bayesianischen Ansatz als geeignetes formales Rahmenwerk für menschliche Aktionsauswahl in einer unsicherheitsbehafteten Umwelt. Um dieses Rahmenwerk umzusetzen, müsse das menschliche Gehirn jedoch keine expliziten Wahrscheinlichkeiten berechnen oder auch nur repräsentieren. Stattdessen fungiere das Gehirn als bayesianischer Sampler. Es nutze somit die Tatsache aus, dass die Repräsentation kompletter Wahrscheinlichkeitsverteilungen zwar schwierig sei, die Generierung von Samples aus solchen Verteilungen allerdings nicht. Sampling benötige kein Wissen über die komplette Verteilung, sondern könne auf einen lokalen Eindruck relativer Posterior-Wahrscheinlichkeiten vertrauen. Das hier beschriebene Sampling ist als mathematische Repräsentation des Abrufens von

gesammeltem Wissen aus dem eigenen Gedächtnis zu verstehen. Es handelt sich nicht um sequentielles Sampling aus dem Forschungsparadigma „decision from experience“ (Hertwig, Barron, Weber, & Erev, 2004), in dem Probanden beobachtbare Handlungen wiederholt ausführen, um die Eigenschaften ihrer Umwelt oder experimenteller Stimuli zu erlernen.

Als Beispiel stellen Sanborn und Chater (2016) eine Studie von Tversky und Kahneman (1983) vor, in der letztere ihre Teilnehmerinnen und Teilnehmer bitten, die relative Häufigkeit einzuschätzen, aus einem beliebigen Roman zufällig Wörter auszuwählen, die einem spezifischen Muster entsprechen. In diesem Fall bestand das Muster aus einer Wortlänge von sieben Buchstaben, deren sechster Buchstabe ein „n“ sein sollte. Sanborn und Chater (2016) erläutern, dass eine explizite bayesianische Berechnung des Problems drei Schritte umfasse: erstens die Berechnung der Posterior-Wahrscheinlichkeit, mit der jedes der ungefähr 600000 Wörter im englischen Sprachgebrauch in Romanen zu finden ist, zweitens die Auswahl der dem beschriebenen Muster entsprechenden Wörter und drittens die Summierung aller Posterior-Wahrscheinlichkeiten. Anhand von Beispielen wie diesem wird schnell klar, warum die Erwartung unplausibel ist, dass das menschliche Gehirn auch nur Teilschritte dieser Berechnung explizit ausführt. Werden Teilnehmenden allerdings einige Beispiele auf das Muster zutreffender Wörter gezeigt, wie „nothing“ und „capping“, fällt ihm laut Sanborn und Chater (2016) nicht nur die Einschätzung der relativen Posterior-Wahrscheinlichkeiten dieser beiden Wörter, sondern auch das Generieren weiterer Beispiele von Wörtern leicht, die auf „-ing“ enden. Ohne die gesamte Verteilung über den kompletten Hypothesenraum zu kennen, sei es durch eine relativ kleine Anzahl an Samples möglich, einen lokalen Eindruck des relevanten Hypothesenraums zu erhalten. Mit einer steigenden Anzahl Samples könnten Teilnehmende zwar beliebige Wahrscheinlichkeitseinschätzungen im Bereich des kompletten Hypothesenraums treffen, würden aber im Bereich eingeschränkter Sample-Anzahlen systematische Schätzfehler aufzeigen. Dabei sei die konzeptionelle Nähe zu Tversky und Kahnemans Verfügbarkeitsheuristik (1973) auffällig.

Auf der Annahme aufbauend, dass das menschliche Gehirn als bayesianischer Sampler funktioniert und so Wahrscheinlichkeitsverteilungen über mögliche Zustände seiner Umwelt approximiert, finden Sanborn und Chater (2016) mögliche Erklärungen für diverse bekannte systematische Denkfehler. Ihr Zustandekommen sei beispielsweise von der Anzahl erzeugter Samples oder der Startposition des Samplingvorgangs im Hypothesenraum abhängig. Als Metapher für diese Abhängigkeit stellen sie einen Androiden vor, der die „Landschaft“ von Wahrscheinlichkeitsverteilungen auskundschaftet. In Abbildung 1 hat der Android zur Aufgabe, eine bimodale Verteilung nach bestem Wissen und Gewissen zu beschreiben, ohne Kenntnis über die Anzahl und Position ihrer Spitzen zu haben. Der Android kann die Landschaft der Wahrscheinlichkeitsverteilung nicht sehen, sondern nur über das Abfließen des Untergrunds erahnen. Wird er an einem beliebigen Punkt der Verteilung abgesetzt, macht er so lange einen Schritt nach dem anderen, bis er ein Gefälle bemerkt, an dem also die Wahrscheinlichkeitsdichte der Verteilung geringer wird. Sobald er das Gefälle bemerkt, kehrt er um, weil er auf der Suche nach dem Punkt oder den Punkten mit der höchsten Wahrscheinlichkeitsdichte ist. Wird der Android nun wie in Abbildung 1 auf dem linken Hügel an Wahrscheinlichkeitsdichte abgesetzt, läuft er metaphorisch betrachtet seine Oberfläche ab und produziert so Samples der Verteilung. Sobald er den Rand des Hügels registriert, kehrt er um, bis er am gegenüberliegenden Rand des Hügels ankommt. Unabhängig von der Anzahl seiner Schritte wird er auf Basis dieses simplen Suchverhaltens den rechten Hügel niemals bemerken und hinterlässt als Histogramm seiner Schrittpositionen nur eine Approximation des linken Hügels. Umgekehrt würde er beim Start auf dem rechten Hügel den linken Hügel übersehen. Demnach ist die verzerrte Perspektive des Androiden auf die Form der Wahrscheinlichkeitsverteilung

abhängig von seiner Ausgangsposition. Je nach Form der Verteilung, die der Android erkunden soll, können Restriktionen der Anzahl möglicher Schritte oder der Startposition zu unterschiedlichen Verzerrungen führen.




Abbildung 1. Metapher eines Samples produzierenden Androiden nach Sanborn und Chater (2016). Der Android erzeugt abhängig von seiner Startposition auch nach einer großen Anzahl produzierter Samples keine adäquate Approximation der bimodalen Verteilung.

Unabhängig davon, dass sich solche systematischen Denkfehler mit entsprechend fortschrittlichen Sampling-Algorithmen vermeiden ließen, scheinen sich Menschen jedoch auf eines oder wenige Samples zu verlassen (Goodman, Tenenbaum, Feldman, & Griffiths, 2008). Auf den ersten Blick scheint dieses Verhalten in Konflikt mit der Annahme zu stehen, dass menschliches Verhalten als bayesianisch beschrieben werden kann. Vul et al. (2014) bringen jedoch das Konzept der globalen Rationalität mit der optimalen Anzahl an Samples in Zusammenhang, die ein Agent zur Lösung eines komputationalen Problems produzieren sollte. Sie führen für das Szenario einer notwendigen Entscheidung zwischen zwei Optionen („Two-Alternative Forced Choice“, kurz 2AFC) vor, dass ein der bayesianischen Entscheidungstheorie folgender Agent die Option wählen sollte, die die erwartete Nützlichkeit unter Berücksichtigung der Posterior-Verteilung des Agenten maximiert. Soll sich beispielsweise ein Autofahrer bei der Wahl seiner Route zwischen Option A über eine Brücke und Option B durch einen Tunnel für die schnellere Option entscheiden, beschreiben Vul et al. (2014) die Wahl als Ausgang eines Bernoulli-Versuchs. Die Wahrscheinlichkeit, dass Option A schneller zum Ziel führt, gilt dabei als p und liegt für dieses Beispiel zwischen 0.5 und 1. Die Wahrscheinlichkeit einer schnelleren Option B ist $1 - p$. Der komplett bayesianische Agent sollte immer Option A wählen, da p größer als 0.5 ist. Damit wählt er die zum Zeitpunkt der Entscheidung richtige Option mit einer Wahrscheinlichkeit von p .

Ein sampling-basierter Agent produziert laut Vul et al. (2014) zunächst Samples über mögliche Zustände der Umwelt und trifft daraufhin seine Entscheidung auf Basis der betrachteten möglichen Zustände. Er sollte demnach wie der komplett bayesianische Agent deterministisch die Option wählen, die in seiner Teilmenge an betrachteten Umweltzuständen am wahrscheinlichsten das Nützlichkeitskriterium erfüllt. Durch die Varianz des Sampling-Prozesses entspricht die Schätzung des Agenten über p jedoch nicht zwangsläufig p . Abhängig von der Anzahl produzierter Samples k wählt der sampling-basierte Agent Option A mit Wahrscheinlichkeit q , aufgeführt in Gleichung 1.2.

$$q = 1 - \theta_{CDF}\left(\left\lfloor \frac{k}{2} \right\rfloor, p, k\right) \quad (1.2)$$

θ_{CDF} beschreibt die binomiale kumulative Dichtefunktion. Sie führt dazu, dass der sampling-basierte Agent wahrscheinlicher Option A wählt, je mehr Samples k er produziert oder je höher die Wahrscheinlichkeit p ist, dass Option A schneller zum Ziel führt. Im Gegensatz zum komplett bayesianischen Agenten, der immer Option A wählt und damit mit Wahrscheinlichkeit p richtig liegt, wählt der sampling-basierte Agent Option A mit Wahrscheinlichkeit q . Die Wahrscheinlichkeit, dass er damit die richtige Wahl trifft, beträgt $qp + (1 - q)(1 - p)$. Um hinreichende Sicherheit über die tatsächliche Erfolgswahrscheinlichkeit eines Bernoulli-Versuchs zu haben, führen Vul et al. (2014) aus, dass laut Stigler (2000) über 25000 Samples benötigt werden. Sie stellen klar, dass deutlich kleinere Sample-Zahlen mit größeren Schätzfehlern einhergehen und umso stärker von komplett bayesianischen Lösungen abweichen. Die Auswirkung dieser Schätzfehler auf die Entscheidungsqualität in einem 2AFC-Szenario sei aber weniger offensichtlich. Gewissen Annahmen bezüglich der kognitiven Kosten des Produzierens eines Samples folgend stellen sie fest, dass ein beziehungsweise wenige Samples je Entscheidung den erwarteten Nutzen über mehrere Entscheidungen maximieren, obwohl die Wahrscheinlichkeit einer richtigen Wahl für einzelne Entscheidungssituationen für den sampling-basierten Agenten geringer als für den komplett bayesianischen Agenten ist.

Um den beschriebenen Samplingvorgang in einem kognitiven Modell algorithmisch umzusetzen, ist eine Regel zum Anhalten des Samplings notwendig. In einem 2AFC-Szenario, in dem der Agent die Erfolgswahrscheinlichkeit p ermitteln soll, bieten sich zwei Variablen als Indikatoren für eine Halteregel an: der erwartete Wertunterschied zwischen beiden Optionen und die beobachtete Schwankungsanfälligkeit der Schätzung von p (Srivastava, Müller-Trede, Schrater, & Vul, 2016). Der erwartete Wertunterschied bezieht sich dabei auf den durchschnittlichen Unterschied zwischen Erfolgs- und Misserfolgswahrscheinlichkeit aller Samples. Beträgt eine geschätzte Erfolgswahrscheinlichkeit p also beispielsweise 70%, ist die korrespondierende Misserfolgswahrscheinlichkeit $1 - p$ gleich 30%. Der Wertunterschied beträgt dabei 40%. Gemittelt über alle produzierten Samples wird dieser Indikator größer, je deutlicher der Unterschied zwischen Erfolgs- und Misserfolgswahrscheinlichkeit ist. Bemerkt der Agent diesen Unterschied, sind weitere Samples für ihn weniger informativ als im Fall eines kleineren erwarteten Wertunterschieds. Umgekehrt wirkt die Schwankungsanfälligkeit der Schätzung von p als Indikator dafür, dass der Agent weitere Samples produzieren sollte. Sie besteht aus der Differenz zwischen der Schätzung von p im vorherigen und aktuellen Sample. Beginnt der Agent seinen Samplingvorgang, führt jeder Ausgang des Bernoulli-Versuchs zu einer starken Schwankung in der Schätzung von p . Hat der Agent bereits mehrere Samples produziert und die Schätzung pendelt sich mit kleiner werdenden Schwankungen ein, werden weitere Samples für ihn weniger informativ. Ein großer erwarteter Wertunterschied bei geringer Schwankungsanfälligkeit sollte also zur Terminierung des Samplingvorgangs führen, während ein geringer Wertunterschied bei großer Schwankungsanfälligkeit dem Agenten signalisiert, dass weitere Samples informativ sein könnten. Die Formalisierung dieser Halteregel nutze ich in den sampling-basierten kognitiven Modellen der folgenden Kapitel.

Die Sampling-Hypothese (Sanborn & Chater, 2016; Vul et al., 2014) wurde zwar erst kürzlich für die algorithmische Ebene bayesianischer kognitiver Modelle formalisiert, jedoch finden sich in der psychologischen Forschung verwandte Konzepte und Theorien zum menschlichen Wahrnehmungs-

und Entscheidungsverhalten. Eine davon, das Angleichen an Wahrscheinlichkeiten (original: „probability matching“; Shanks et al., 2002), beschreibt die menschliche Tendenz, auf spezielle Art gegen das Prinzip der Nützlichkeitsmaximierung zu verstoßen. Dabei wählt der angleichende Agent im Gegensatz zum bayesianischen Agenten nicht immer diejenige von zwei Optionen mit der höheren Erfolgswahrscheinlichkeit. Stattdessen wählt er die Optionen proportional zu ihrer Erfolgswahrscheinlichkeit. Angleichen des Entscheidungsverhaltens an Wahrscheinlichkeiten gilt ohne Berücksichtigung von Ressourcenrationalität als irrational, weil sich der bayesianische Agent mit höherer Wahrscheinlichkeit für die bessere Option entscheidet. Vul (2010) betrachtet das Angleichen an Wahrscheinlichkeiten im Rahmen der Sampling-Hypothese als Sonderfall. Der sampling-basierte Agent gleicht unter Berücksichtigung eines einzigen Samples seine Wahl den Erfolgswahrscheinlichkeiten der Optionen an, maximiert bei unendlich vielen Samples und zeigt im Bereich dazwischen Verhalten, das mit steigender Anzahl an Samples Nützlichkeitsmaximierung ähnelt. Die Sampling-Hypothese beinhaltet also eine mögliche Erklärung für die Tendenz des Angleichens (Vul, 2010).

Vul (2010) stellt auch das Entscheidungsaxiom nach Luce (1959) in engen Bezug zur Sampling-Hypothese. Das Axiom besagt, dass Menschen Optionen in Relation zur Stärke einer internen Repräsentation wählen, sodass die Wahlwahrscheinlichkeit einer Option a aus dem in Gleichung 1.3 beschriebenen Verhältnis hervorgeht.

$$p(a) = \frac{v(a)}{\sum_b v(b)} \quad (1.3)$$

Die Stärke dieser Repräsentation der Option a sei gleich $v(a) = p(a)^L$, wobei $p(a)^L$ die Posterior-Wahrscheinlichkeit dieser Option potenziert mit L entspricht. Dieser Exponent spiegelt nach Vul (2010) die Funktion wider, die die Anzahl an produzierten Samples in der Sampling-Hypothese hat: er justiert das Verhalten eines Agenten zwischen Wahrscheinlichkeitsangleichen und Nützlichkeitsmaximierung. In ihrer Funktion auf der algorithmischen Ebene sind sich ein sampling-basierter Agent und ein das Entscheidungsaxiom anwendender Agent also ähnlich. Letzterer basiert jedoch auf keiner spezifischen Annahme in Bezug auf die komputationale Ebene.

Als weiteren vergleichbaren Modellansatz zur algorithmischen Spezifikation der Sampling-Hypothese führt Vul (2010) die Gruppe der Diffusion-Modelle (Bitzer, Park, Blankenburg, & Kiebel, 2014; Busemeyer & Townsend, 1993; Ratcliff, Smith, Brown, & McKoon, 2016) an. Diese Modellfamilie repräsentiert Entscheidungsfindung als stochastische Akkumulation von Informationen, die nach dem Überschreiten einer Evidenzgrenze eine Entscheidung für die Option auslöst, für die ausreichend Evidenz gesammelt wurde. Der Ansatz der Evidenzakkumulation durch sequentielles Sampling ist also ebenfalls funktional der Sampling-Hypothese ähnlich, insbesondere, weil auch hier die Abwägung zwischen Schnelligkeit und Genauigkeit einer Entscheidung im Fokus liegt. Einzelne Ableger der Modellfamilie unterscheiden sich beispielsweise in ihren Annahmen darüber, ob die Grenze notwendiger Evidenzakkumulation mit der Zeit sinkt oder ob die Einflussrate einzelner Samples auf den Akkumulationsprozess konstant oder variabel betrachtet wird (Ratcliff et al., 2016). Solange sie die Sample-Produktion auf Gedächtnisinhalte statt auf externe Eigenschaften der Umwelt des Agenten

beziehen, sind die Diffusion-Modelle der sampling-basierten bayesianischen Inferenz formal ähnlich (Vul, 2010).

1.4. Entscheidungsverhalten und Präferenzentwicklung

In den vorherigen Unterkapiteln waren die Konzepte von Rationalität und Entscheidung eng mit dem Begriff der Nützlichkeit verbunden. Die Rationalität eines Agenten wurde daran evaluiert, ob sein Wahlverhalten der Maximierung einer nicht näher definierten Nützlichkeit entsprach, und beobachtbare menschliche Abweichungen von Maximierungsverhalten wurden auf algorithmischer Ebene mit der Sampling-Hypothese erklärt. Dabei bezieht sich der Begriff Nützlichkeit auf die Assoziation zwischen einer subjektiven Wertigkeit und dem Eintreten eines Ereignisses. Diese subjektive Wertigkeit basiert auf Präferenzen, die üblicherweise als statisch betrachtet werden und deren Entwicklung selten näher untersucht wird (Srivastava & Schrater, 2015). Gängige Entscheidungstheorien versuchen stattdessen, über eine Präferenzfunktion den zur Wahl stehenden Optionen numerische Werte zuzuordnen, die die Ordnung der Präferenzen eines Individuums widerspiegeln. Damit diese Präferenzfunktion einen über Entscheidungssituationen oder Individuen generalisierbaren Mehrwert und eine interne logische Konsistenz hat, wird sie anhand mehrerer entscheidungstheoretischer Axiome evaluiert (Eisenfuh, Weber, & Langer, 2010; Peterson, 2009; Srivastava & Schrater, 2015). Peterson (2009) erwähnt als die drei wichtigsten Axiome normativer Entscheidungstheorie die Eigenschaften Transitivität, Vollständigkeit und Unabhängigkeit.

Transitivität beschreibt die Präferenzrelation mehrerer Entscheidungsalternativen zueinander. Gilt für den betrachteten Agenten die Präferenzrelation $x > y$ sowie $y > z$, dann ist Transitivität unter der Bedingung $x > z$ gegeben. Vollständigkeit beschreibt das Vorhandensein einer Präferenzrelation zwischen zwei Entscheidungsalternativen, sodass entweder $x > y$, $y > x$ oder $x \sim y$ gilt. Unabhängigkeit beschreibt die Beständigkeit der Präferenzrelation $x > y$, wenn die Entscheidungsalternativen Teil eines ansonsten konstanten Gewinnspiels sind. Gilt für den Agenten $x > y$, so gilt für ihn auch $xpz > ypz$. Diese Notation eines Gewinnspiels bedeutet den Erhalt von x beziehungsweise y mit Wahrscheinlichkeit p und den Erhalt von z mit Wahrscheinlichkeit $1 - p$ (Peterson, 2009). Das Unabhängigkeitsaxiom hängt eng mit dem Konzept der Unabhängigkeit von irrelevanten Alternativen (Tversky & Simonson, 1993) zusammen. Dieses besagt, dass eine Präferenzrelation $x > y$ aus der Menge an Optionen $\{x, y\}$ auch in der Menge $\{x, y, z\}$ erhalten bleiben und sich nicht zu $y > x$ umkehren darf.

Srivastava und Schrater (2015) stellen jedoch klar, dass axiomatische Nützlichkeitsmaximierung keine angebrachte Beschreibung menschlichen Entscheidungsverhaltens ist. Diese Schlussfolgerung basiert auf empirisch beobachteten Abweichungen von den als Voraussetzung für rationales Entscheiden geltenden Axiomen. Diese Abweichung tritt besonders deutlich bei der Umkehr von Präferenzen hervor (Lichtenstein & Slovic, 1971; Tversky & Simonson, 1993; Tversky, Slovic, & Kahneman, 1990). Menschen zeigen eine Abhängigkeit ihrer Wahl zwischen Optionen von der dargebotenen Menge an Optionen (Vlaev, Seymour, Dolan, & Chater, 2009), wie sie bei geltender Unabhängigkeit von irrelevanten Alternativen nicht auftreten sollte. Srivastava und Schrater (2015) führen als anekdotisches Beispiel das Gedankenexperiment des wählerischen Restaurantgasts an (Luce & Raiffa, 2012). Besagter Restaurantgast wählt zunächst zwischen den Hauptgerichtoptionen Lachs und Steak den Lachs, wechselt aber zum Steak, als er erfährt, dass auch Froschschenkel zur Auswahl stehen. Mit der Annahme subjektiver, optionsspezifischer Präferenzen und axiomatischem Umgang mit diesen

Präferenzen sei solches Verhalten nicht zu vereinbaren. Srivastava und Schrater (2015) formalisieren unter anderem mit dem Ziel, Präferenzumkehr zu rationalisieren, eine Theorie zu kontextsensitivem Präferenzlernen. Diese beschreibt die aktuelle Begehrtheit einer Option $R(x)$ innerhalb der aktuell dargebotenen Teilmenge verfügbarer Optionen o als gewichtetes Mittel ihrer Begehrtheit in verschiedenen Kontexten c , formalisiert in Gleichung 1.4:

$$R(x) = p(r|x, o) = \frac{\sum_c p(r|x, c)p(x|c)p(c|o)}{\sum_c p(x|c)p(c|o)} \quad (1.4)$$

Der Agent schreibt der Option demnach in verschiedenen Kontexten c , also bei der Wahl aus verschiedenen Teilmengen o , unterschiedliche Begehrtheit zu. Dabei stellt das Element $p(r|x, c)$ den Anteil an Fällen dar, in denen die Option in der Vergangenheit gewählt wurde. Gleichzeitig schlussfolgert er durch $p(c|o)$ anhand der vorliegenden Teilmenge an Optionen, zu welcher Wahrscheinlichkeit er sich in welchem Kontext befindet. So kann er die erlangte Posterior-Wahrscheinlichkeit über die Kontextzugehörigkeit der aktuell dargebotenen Teilmenge nutzen, um in der nächsten Entscheidungssituation seinen Prior über die Auftretenswahrscheinlichkeit verschiedener Kontexte zu aktualisieren. Auf Basis seines bisherigen Entscheidungsverhaltens in der Vergangenheit und der Nähe der aktuellen Teilmenge zu bisher beobachteten Kontexten schlussfolgert er bayesianisch die relative Begehrtheit der aktuell zur Wahl stehenden Optionen. Innerhalb eines fixierten Kontexts beschreiben Srivastava und Schrater (2015) die Berechnung der relativen Begehrtheit einer Option als äquivalent zu einer Präferenzfunktion, zumindest in Bezug auf Vollständigkeit. In Abhängigkeit der Entscheidungshistorie des Agenten kann auch Transitivität zwischen Kontexten erreicht werden, ist aber für die Theorie oder die Beurteilung ihres normativen Charakters in Bezug auf Rationalität irrelevant. Im Fall des wählerischen Restaurantgasts kann die Präferenzrelation $Lachs > Steak$ aus dem Kontext c_1 mit der Teilmenge $\{Steak, Lachs\}$ in dem Kontext c_2 , der der Teilmenge $\{Steak, Lachs, Froschschenkel\}$ entspricht, ohne weiteren Konflikt zu $Steak > Lachs$ verkehrt werden. Die relative Begehrtheit von Lachs unter Berücksichtigung von c_1 konnte entsprechend Gleichung 1.5 berechnet werden:

$$R(Lachs) = \frac{p(r|Lachs, c_1)p(Lachs|c_1)p(c_1)}{p(Lachs|c_1)p(c_1)} \quad (1.5)$$

Im Vergleich dazu ermittelt der Agent die relative Begehrtheit von Lachs unter Berücksichtigung beider Kontexte in Gleichung 1.6:

$$R(Lachs) = \frac{p(r|Lachs, c_1)p(Lachs|c_1)p(c_1) + p(r|Lachs, c_2)p(Lachs|c_2)p(c_2)}{p(Lachs|c_1)p(c_1) + p(Lachs|c_2)p(c_2)} \quad (1.6)$$

Eine bestimmte Entscheidungshistorie und entsprechendes Verhältnis von Vertrauen in das Zutreffen von Kontext 1 beziehungsweise 2 vorausgesetzt, findet zwischen Gleichung 1.5 und 1.6 die

beschriebene Präferenzumkehr statt. Bis zu diesem Punkt beschränkt sich die beschriebene Theorie zu kontextsensitivem Präferenzlernen jedoch auf die komputationale Ebene. Während das Beispiel des wählerischen Restaurantgasts noch leicht mathematisch durchzuspielen ist, dürfte ein Agent in der realen Umwelt Schwierigkeiten haben, eine erschöpfende Liste an möglichen Kontexten zu generieren oder sich an alle Situationen zu erinnern, in denen ihm eine bestimmte Option zur Wahl angeboten wurde. Srivastava und Vul (2015) integrieren die bestehende Theorie für kontextsensitives Präferenzlernen mit einem Sampling-Modell, um die bisherige analytische Komplexität auf algorithmischer Ebene zu lösen. Sie lassen den Agenten nicht die gesamte Verteilung an Kontexten $p(c|o)$ nutzen, sondern sampeln berücksichtigte Kontexte und die für sie geltenden Entscheidungshistorien episodisch. Dadurch gelten für die kontextsensitive Präferenzentwicklung und Entscheidung dieselben Grundsätze wie für die im vorherigen Teilkapitel beschriebene Sampling-Hypothese (Vul et al., 2014). Mehr produzierte Samples reduzieren den Schätzfehler im Vergleich zu weniger produzierten Samples, aber ein Agent ist mit Hinblick auf seinen Ressourcenverbrauch besser damit beraten, nur wenige Samples zu produzieren.

Im Rahmen der vorgestellten Theorie lässt sich zeigen, dass empirisch beobachtbare Effekte wie unterschiedliche Entscheidungsdauer zwischen hedonischen und utilitaristischen Entscheidungen (Srivastava & Vul, 2015) oder die Auswirkung verschiedener Marketingtechniken auf Konsumenten (Srivastava & Vul, 2017a) als natürliche Konsequenzen kontextsensitiver Präferenzentwicklung entstehen. Durch ihre algorithmische Spezifikation bleibt die Theorie analytisch simpel genug, um der vorgestellten Kritik an bayesianischen komputationalen Modellen zu entgehen. In den folgenden Kapiteln verwende ich sie deshalb als Grundlage für die dort beschriebenen kognitiven Modelle. Dennoch ist die Theorie der kontextsensitiven Präferenzentwicklung nicht der einzige Ansatz, der beispielsweise Präferenzumkehr und Kontexteffekte erklären kann. Vertreter der im vorherigen Unterkapitel angesprochenen Diffusion-Modellfamilie besitzen diese Eigenschaft ebenso (Tsetsos, Usher, & Chater, 2010).

1.5. Andere Arten kognitiver Modellierung

Bayesianische kognitive Modellierung ist der Familie probabilistischer kognitiver Modelle zugehörig. Während diese durch ihren Bezug zur Wahrscheinlichkeitstheorie als synonym mit bayesianischen Modellen verstanden werden kann, ist die Formalisierung probabilistischer Modelle ohne eine spezifisch bayesianische Vorgehensweise möglich. So wird beispielsweise in Kapitel 4 dieser Arbeit ein Modell mit probabilistischem Verhalten formalisiert, das zwar Wahrscheinlichkeiten als Ausmaß des Vertrauens in das Zutreffen von Hypothesen interpretiert, Entscheidungen jedoch auf Basis einer Heuristik trifft. Die probabilistische Modellfamilie ist allerdings nur ein möglicher Ansatz zur kognitiven Modellierung.

Zunächst ist der Symbolismus ein Modellierungsparadigma, das davon ausgeht, dass der menschliche Verstand mit symbolischen Repräsentationen seiner Umwelt Berechnungen durchführt. Deren Implementierung wird hierbei nicht näher betrachtet. Die menschliche Kognition kann aus der Perspektive des Symbolismus mit der Funktionalität eines Computers verglichen werden, ohne dabei die Implementierungsebene und die Rolle von Neuronen als Basis dieser Funktionalität einzubeziehen (Sun, 2008b). Während der Symbolismus Vergleiche menschlicher Kognition mit Computerprogrammen nahelegt, bezieht der Konnektionismus die Implementierungsebene mit ein und beinhaltet biologisch inspirierte Methoden Lernens wie künstliche neuronale Netze (Farkaš, 2012).

Der dynamische Ansatz legt den Fokus auf den zeitlichen Verlauf kognitiver Aktivität und die sequentielle Verarbeitung von Informationen, weshalb hier üblicherweise die Vorhersage von Reaktionszeiten in den Fokus der Modellierung rückt (Farkaš, 2012). Die Decision Field-Theorie (Busemeyer & Townsend, 1993) nutzt diese dynamische Perspektive, um Entscheidungsfindung als sequentielles Sampling von externen oder mentalen Informationen zu modellieren. Die Einordnung in den dynamischen Ansatz würde hier aber zu kurz greifen, weil es beispielsweise auch explizit konnektionistische Interpretationen der Decision Field-Theorie gibt (Busemeyer & Johnson, 2008) und sie als Vertreter der Ansätze sequentiellen Samplings einen thematischen Zusammenhang mit der Sampling-Hypothese (Sanborn & Chater, 2016; Vul et al., 2014) beinhaltet. Die explizite Trennung verschiedener Ansätze kognitiver Modellierung ist in manchen Fällen offensichtlicher als in anderen. Wichtiger als eine hohe Trennschärfe dieser Ansätze ist jedoch die Tatsache, dass sie sich in ihren Schwerpunktgebieten überschneiden können und zu vergleichbaren Erklärungsansätzen für beobachtbare empirische Phänomene kommen. So ermöglicht die Decision Field-Theorie beispielsweise eine Erklärung paradoxen menschlichen Entscheidungsverhaltens und Präferenzumkehr (Busemeyer & Johnson, 2008), die sich zwar ihrer eigenen theoretischen Grammatik bedient, aber inhaltlich Gemeinsamkeiten mit der in dieser Arbeit vorgestellten algorithmischen Erweiterung bayesianischer kognitiver Modellierung aufweist.

Ein in den letzten Jahren an Relevanz gewinnender Ansatz der kognitiven Modellierung ist das Predictive Processing, auch als Predictive Coding bekannt (Clark, 2013). Predictive Processing basiert auf der Annahme, dass das Gehirn kontinuierlich Vorhersagen über eintreffende Signale erzeugt und die Reduktion von Schätzfehlern dieser Vorhersagen seine Hauptaufgabe ist. Durch komplexe hierarchische Strukturen sei es dem Gehirn so möglich, bei zutreffenden Vorhersagen über sensorische Signale diese Informationen komputational zu unterdrücken und nur höhere Ebenen in weitere Berechnungen einzubeziehen. Erst sollte es stattdessen zu großen Schätzfehlern kommen, passe das Verfahren die Parameter niedrigerer hierarchischer Ebenen an, um in Zukunft wieder ausschließlich mit der Berücksichtigung höherer hierarchischer Ebenen auszukommen. Durch die Anforderung an den Organismus, Schätzfehler so weit wie möglich zu reduzieren, besteht ein Zusammenhang zwischen Predictive Processing und bayesianischer Inferenz. Die Vorhersagen auf den verschiedenen hierarchischen Ebenen des kognitiven Systems können als Prior verstanden werden, deren Parameterwerte bei ausreichend unterschiedlicher Abweichung der eintreffenden sensorischen Signale – der Likelihood – im Posterior angepasst werden. Um aus eintreffenden sensorischen Signalen die meiste Information zur Anpassung des Priors zum Posterior zu erhalten, bietet sich demnach die Verwendung des Satzes von Bayes an. Der Ansatz des Predictive Processing steht in engem Zusammenhang zu den Schlagworten der aktiven Inferenz und dem Free Energy-Prinzip (Friston & Stephan, 2007) sowie der Bayesian Brain-Hypothese (Knill & Pouget, 2004). Eine Verortung auf den Analyseebenen nach Marr (1982) oder innerhalb der hier vorgestellten probabilistischen, symbolischen, konnektionistischen oder dynamischen Modellfamilien ist nur bedingt möglich. Auf der einen Seite ist die Grundidee vereinbar mit einer probabilistischen Umsetzung auf der komputationalen Ebene, auf der anderen Seite legt die thematische Nähe zu neuronaler Verarbeitung den Einbezug konnektionistischer Ansätze und der Implementierungsebene nahe. Der Einbezug vieler Modellierungsfamilien und Analyseebenen dürfte ein so umfassendes theoretisches Rahmenwerk wie Predictive Processing jedoch dabei unterstützen, ausreichend theoretisch eingeschränkt zu bleiben, um zielführend auf Fragestellungen der komputationalen Psychologie angewandt zu werden.

1.6. Struktur der vorliegenden Arbeit

Die Hauptziele dieser Arbeit sind erstens die Identifizierung von Forschungsthemen, die von den im bisherigen Kapitel beschriebenen Fortschritten bayesianischer kognitiver Modellierung inhaltlich profitieren können, und zweitens die Evaluation der darauf angewandten Modelle. Deshalb stelle ich in Kapitel 2 zunächst gängige Evaluations- und Vergleichsmethoden kognitiver Modelle vor. Im Hauptteil der Arbeit stelle ich drei Forschungsschwerpunkte vor, für die ich entweder erstmalig kognitive Modelle formalisiere oder bestehende kognitive Modelle mit dem Ziel überarbeite, ihre Grundannahmen und darauf basierende fehlerhafte Vorhersagen zu korrigieren. In Kapitel 3 betrachte ich ein komputationales Modell der multisensorischen Integration und seine Leistung in der Vorhersage der Effekte einer Wahrnehmungsillusion in den unteren Gliedmaßen. Kapitel 4 beschäftigt sich mit dem Feld der Online-Privatsphärenforschung. Hier steht das Verhalten der Nutzenden von Online-Diensten traditionell eng mit der Frage heuristischer oder rationaler Entscheidungsfindung in Verbindung. Aus diesem Grund betrachte ich die Argumentationen verschiedener Ansätze zur Beschreibung des Nutzungsverhaltens und formalisiere sie in vier kognitiven Modellen, darunter in einer multiattributiven Variante des rationalen Prozessmodells. Kapitel 5 implementiert ein rationales Prozessmodell für die Wahrnehmung nonverbalen Flirtverhaltens. Das Thema dient als Anwendungsbeispiel des rationalen Prozessmodells für Entscheidungen auf Basis eines Attributes. Gleichzeitig führe ich einen Modellvergleich mit einem Angleichungsmodell und einem komplett bayesianischen Modell durch, um die Auswirkung der Flexibilität des rationalen Prozessmodells einzuordnen. Während die inhaltlichen Konsequenzen der Forschungsschwerpunkte in ihren jeweiligen Kapiteln besprochen werden, findet die allgemeine Diskussion zu bayesianischer kognitiver Modellierung und ihrer Relevanz für wissenschaftlichen Erkenntnisgewinn in Kapitel 6 statt.

2. Evaluationsmethodik kognitiver Modelle

In Kapitel 1 wurde der Bezug zwischen wissenschaftlichen Theorien, Modellen als Implementierungen von Theorien und ihrem Potential zur Erklärung beobachteter Phänomene besprochen (Stafford, 2009). Komputationale Modellierung wurde dort laut Sun (2008) als vielversprechende Modellkategorie dargestellt, die aufgrund der notwendigen Formalisierung präzisere Vorhersagen ermöglichen, als es bei anderen Modellierungsarten der Fall sei. Oft besitzen komputationale Modelle psychologischer Theorien Variablen, die das Modellverhalten und die daraus folgende Vorhersage beeinflussen. Im Kontext komputationaler Modellierung spricht man von Parametern, die als Drehknöpfe eines Modells verstanden werden können. Eine geeignete Analogie sind die Bedienelemente eines Autoradios: das Radio besitzt eine spezifische Architektur, um eine Funktion zu erfüllen, aber die Regler für Lautstärke und Empfangsfrequenz beeinflussen sein Verhalten (Farrell & Lewandowsky, 2018). Diese Parameter sind in manchen Modellen frei einstellbar. Sowohl in mathematischen als auch in komputationalen Modellen (Sun, 2008a) erfolgt die Parameterschätzung mit dem Ziel, den Vektor am besten passender Werte zu bestimmen, der das Modellverhalten so nah wie möglich an empirisch beobachtbares Verhalten heranführt. Neben freien Parametern existieren in komputationaler Modellierung auch fixierte Parameter – Eigenschaften des modellierten Vorgangs, von denen vermutet wird, dass sie individuen- oder stichprobenübergreifend nicht nennenswert variieren.

2.1. Parameterschätzung

Methoden der Parameterschätzung sind Forschern in der Psychologie üblicherweise aus der akademischen Ausbildung bekannt. Neben den zwei etablierten Methoden der Least Squares- und Maximum Likelihood-Schätzung (Farrell & Lewandowsky, 2018) findet bayesianische Parameterschätzung in immer mehr Forschungsfeldern auch außerhalb der Psychologie Anklang (Kruschke, Aguinis, & Joo, 2012). Hierbei wird der Satz von Bayes auf die Ermittlung wahrscheinlicher Parameterwerte unter Berücksichtigung beobachteter Daten und Vorwissen über plausible Werte besagter Parameter angewandt. Mathematisch unterscheidet sich die Anwendung nicht von Gleichung 1.1 in Kapitel 1 dieser Arbeit, bezieht sich jetzt jedoch statt auf die Zuschreibung von Wahrscheinlichkeiten zu Hypothesen aus Sicht eines modellierten Agenten auf die Zuschreibung von Wahrscheinlichkeiten zu Parameterwerten aus Sicht von Anwenderinnen und Anwendern der statistischen Methode. Dabei ist der Prozess der Parameterschätzung ähnlich wie die bislang angesprochenen Anwendungsfelder bayesianischer Modellierung unsicherheitsbelastet. Ein Forscher hat eingangs möglicherweise eine vage Vorstellung über das Ausmaß des Einflusses einer unabhängigen auf eine abhängige Variable, die er durch die Sammlung empirischer Daten anpassen, präzisieren oder mit größerer Sicherheit als zuvor einem wissenschaftlich skeptischen Publikum kommunizieren möchte (Kruschke, 2015). Wie in der Anwendung in der kognitiven Modellierung ist die Spezifikation eines informierten Priors, also der Vorauswahl plausiblerer Parameterwerte im Vergleich zu anderen, möglich, sollte aber mit Vorsicht durchgeführt und wissenschaftlich gerechtfertigt sein. Nach der Beobachtung empirischer Daten wird ihre Wahrscheinlichkeit gegeben einzelner Parameterwerte über den Satz von Bayes mit dem Prior integriert, der die Wahrscheinlichkeit der Parameterwerte angibt. Die Posterior-Verteilung beinhaltet die gesamte Information bezüglich glaubwürdiger Parameterwerte, die aus den empirischen Daten gezogen werden kann und ist als

Wahrscheinlichkeitsverteilung interpretierbar. Dadurch unterscheidet sie sich von frequentistischen Maßen wie Schätzwerten oder Konfidenzintervallen (Kruschke et al., 2012).

In Kapitel 1 wurde als Kritik gegenüber komputational bayesianischen Modellen angeführt, dass ihre analytische Komplexität außerhalb simpler Beispiele zu hoch sei, um als realistisches Sinnbild menschlicher Informationsverarbeitung zu gelten. Tatsächlich ist diese analytische Komplexität auch der Grund, warum bayesianische Methoden selbst in der Datenanalyse erst seit ungefähr 30 Jahren verlässlich Anwendung finden: die Evaluation aller möglichen Kombinationen an Parameterwerten war in vielen praktisch relevanten Modellen schlicht zu aufwändig für damalige Computer (Rouder, Morey, & Pratte, 2013). Moderne Sampling-Algorithmen umgehen jedoch die Notwendigkeit der Berechnung des Posteriors und approximieren ihn stattdessen. Auf diese Weise kann bayesianische Parameterschätzung unabhängig von der Parameteranzahl des Modells durchgeführt werden, um beispielsweise den Bereich der wahrscheinlichsten Parameterwerte eines Regressionsgewichts in einem datenanalytischen Modell zu bestimmen.

2.2. Modellvergleich

Parameterschätzung bietet in der Anwendung auf einen gegebenen Datensatz einen deskriptiven Nutzen. Beinhaltet ein Modell beispielsweise einen Parameter, der die Impulsivität des modellierten Agenten repräsentiert, lässt sich nach der Schätzung eine Aussage über die Ausprägung des Impulsivitätsparameters im gegebenen Datensatz treffen. Oft ist die reine Beschreibung eines Datensatzes im Rahmen einer Modellstruktur aber nicht das wissenschaftliche Ziel. Haben sich beispielsweise zwei theoretische Interpretationen desselben Phänomens etabliert und man ist daran interessiert, welche der beiden Interpretationen die bessere Erklärung des Phänomens ist, bietet sich ein Modellvergleich an. Hierbei spielt die Menge an freien Parametern in einer Modellstruktur eine entscheidende Rolle, weil mit einer uneingeschränkten Menge an freien Parametern jedes beliebige Datenmuster approximiert werden kann (Roberts & Pashler, 2000). Man spricht von Overfitting, wenn ein Modell nach der Parameterschätzung an einem Datensatz dessen Trends zwar gut darstellen kann, übertragen auf einen inhaltlich ähnlichen, aber neuen Datensatz jedoch eine deutlich schlechtere Beschreibung der Daten produziert (Farrell & Lewandowsky, 2018). Ist ein Modell durch die Anzahl seiner freien Parameter sehr flexibel, produziert es je nach gewählten Parameterwerten stark unterschiedliche Verhaltensweisen. Diese Flexibilität steht in engem Zusammenhang mit dem Potential zur Erklärung eines beobachteten Phänomens, denn eine Abwandlung des Zitates von Popper (2005) aus Kapitel 1 dieser Arbeit von Lee und Wagenmakers (2013) lautet: „A model that predicts everything predicts nothing“.

Aus dem problematischen Aspekt der Modellflexibilität motiviert sich die Entwicklung diverser Methoden und Kriterien zur Modellevaluation, die mehr als den reinen Fit zu einem Datensatz betrachten. Eine Familie verschiedener Informationskriterien (Gelman, Hwang, & Vehtari, 2014), also mathematischer Indikatoren der Passung eines Modells zu einem Datensatz, korrigiert diese beispielsweise, indem sie einen Strafterm entsprechend der Anzahl freier Parameter in der Modellstruktur abziehen. Auf diese Weise können Modelle anhand ihrer erwarteten Vorhersagequalität für hypothetische neue Daten beurteilt werden. Methoden der Kreuzvalidierung, bei der ein Teil des Datensatzes aus der Parameterschätzung ausgeschlossen wird, um dann die Vorhersagequalität für diesen Teil zu bestimmen und den Vorgang mit mehreren weiteren Partitionen des Datensatzes zu wiederholen, sind ebenfalls etabliert (Vehtari, Gelman, & Gabry, 2017).

Die in dieser Arbeit angewandte Methode des Modellvergleichs ist der Bayes Factor. Hierbei wird nicht wie in den bisher beschriebenen Methoden die bestmögliche Passung eines Modells abzüglich eines bestrafenden Faktors für freie Parameter berechnet. Stattdessen ist der Bayes Factor die Relation der marginalen Likelihood zweier Modelle, wobei die marginale Likelihood die durchschnittliche Passung eines Modells widerspiegelt (Farrell & Lewandowsky, 2018; Lee & Wagenmakers, 2013). In Kapitel 2.1 wurde der Satz von Bayes zur Parameterschätzung genutzt. Dabei wurde der Prior über mögliche Parameterwerte etabliert, auf dessen Basis gemeinsam mit der Likelihood der Daten unter gegebenen Parameterwerten der Posterior der Parameterwerte berechnet wurde. Zur Berechnung des Bayes Factors wird für jeden möglichen Parameterwert im Prior die Likelihood der Daten evaluiert und mit der Wahrscheinlichkeit dieses Wertes im Prior gewichtet. Daraus ergibt sich die marginale Likelihood der Daten für ein Modell. Die Relation dieser marginalen Likelihoods von Modell i zu Modell j ist im Bayes Factor in Gleichung 2.1 ausgedrückt.

$$BF_{ij} = \frac{p(D|M_i)}{p(D|M_j)} \quad (2.1)$$

Die Nutzung der marginalen Likelihood führt dazu, dass das Prinzip der Sparsamkeit in die Evaluation eines Modells einbezogen wird (Farrell & Lewandowsky, 2018). Aufgrund der Tatsache, dass die Likelihood der Daten über alle im Prior gewichteten Parameterwerte gemittelt wird, ist die durchschnittliche Likelihood der Daten gegeben des Modells niedriger, je komplexer das Modell a priori ist. Die Passung eines Modells mit vielen freien Parametern muss demnach über deutlich mehr Parameterkombinationen evaluiert werden, die nicht mit den Daten übereinstimmen. Die marginale Likelihood repräsentiert also einen Kompromiss zwischen der Modellkomplexität und Passung zu den Daten. Ähnlich wie Informationskriterien ist auch ein numerischer Wert der marginalen Likelihood für sich allein nicht interpretierbar. In Relation zur marginalen Likelihood eines zweiten Modells jedoch entsteht ein stetiges Maß der Evidenz dafür, dass ein Modell dem anderen vorzuziehen ist. Jeffreys (1998) schlägt eine Kategorisierung der Größenordnung von Bayes Factors vor, die zwar für das Maß selbst nicht notwendig ist, aber als Heuristik für Leserinnen und Leser nützlich sein kann. Ich übernehme in Tabelle 1 für die Bewertung der relativen Evidenz in Modellvergleichen diese Kategorisierung, jedoch mit den von Lee und Wagenmakers (2013) vorgeschlagenen präziseren Bezeichnungen.

Tabelle 1.

Unterteilung von Bayes Factors in Kategorien nach Jeffreys (1998) mit Interpretationen nach Lee und Wagenmakers (2013).

Bayes Factor BF_{ij}			Kategorie
	>	100	Extreme Evidenz für M_i
30	-	100	Sehr starke Evidenz für M_i
10	-	30	Starke Evidenz für M_i
3	-	10	Moderate Evidenz für M_i
1	-	3	Anekdotische Evidenz für M_i
	1		Keine Evidenz
1/3	-	1	Anekdotische Evidenz für M_j
1/10	-	1/3	Moderate Evidenz für M_j
1/30	-	1/10	Starke Evidenz für M_j
1/100	-	1/30	Sehr starke Evidenz für M_j
	<	1/100	Extreme Evidenz für M_j

3. Empirische Anwendung: Auswirkungen eines informierten Priors auf die Vorhersage propriozeptiven Drifts im bayesianischen Modell für Kausalinferenz

Die in Kapitel 1 vorgestellten Entwicklungen bayesianischer kognitiver Modellierung bezogen sich durch ihren Bezug zur Entscheidungstheorie und Rationalität oft auf Entscheidungen zwischen diskreten Optionen. Ein weiterer Bereich psychologischer Forschung, der in der Vergangenheit von bayesianischer kognitiver Modellierung profitieren konnte, betrifft jedoch die verschwommene Grenze zwischen sensorischer Wahrnehmung und motorischer Handlungsinitiierung. Diverse psychologische Prozesse wie die visuelle Wahrnehmung (Neupärtl & Rothkopf, 2018; Weiss et al., 2002), Sprachverständnis (Frank & Goodman, 2014), die Selektion motorischer Handlungen (Körding & Wolpert, 2006) oder multimodale sensorische Integration (Deneve & Pouget, 2004; Körding et al., 2007; Orbán & Wolpert, 2011) können beschrieben und vorhergesagt werden, als folgten sie bayesianischen Prinzipien. Viele dieser Themen haben gemein, dass sie durch ihre gleichzeitige Betrachtung mehrerer Signalquellen mit unterschiedlichen Ausmaßen an Präzision starke konzeptionelle Überschneidungen mit dem bayesianischen Verständnis von Unsicherheit zeigen.

Selbst alltägliche Handlungen wie das Greifen nach einem Glas Wasser erfordern vom handelnden Agenten einen formalisierten Prozess zum Umgang mit verschiedenen unsicheren Informationen. Die Position des Glases, verarbeitet vom visuellen System, muss zum Zweck der optimalen Bewegungsauswahl mit der Position des eigenen Armes in Verbindung gebracht werden. Hat der Agent dabei die Möglichkeit, seinen eigenen Arm zu sehen, erhält er Rückmeldungen vom visuellen und propriozeptiven System. Ansonsten beschränkt sich die Information auf den ungenaueren propriozeptiven Kanal. Der Agent hat zudem keine präzise Information darüber, wie groß oder schwer das Glas sein wird und wieviel Kraft benötigt wird, um es anzuheben. Eine angemessene Menge an Kraft einzusetzen, wird umso schwerer, wenn der Agent kein Glas, sondern ein undurchsichtiges Behältnis anheben soll. Bayesianische Inferenz, wie sie in Kapitel 1 vorgestellt wurde, beschreibt den mathematisch rationalen Weg, um bereits vorhandenes Wissen über den eigenen Bewegungs- und Kraftspielraum des Agenten, die Position des Glases im dreidimensionalen Raum und gegenwärtige sensorische Informationen so zu integrieren, dass die verbleibende Unsicherheit minimiert wird. Durch dieses Beispiel wird auch der Bezug zu Entscheidungstheorie und (Ressourcen-)Rationalität aus Kapitel 1 offensichtlich: ein Agent, dessen Bewegungen Energie kosten und der aus verschiedenen motorischen Optionen zur Erreichung eines Ziels auswählen kann, sollte diejenige Option wählen, die einen Zielkonflikt zwischen Energiehaushalt und der Wahrscheinlichkeit der Zielerfüllung optimal löst. Auf wahrnehmungsbezogene Fragestellungen angewandt werden bayesianische Lösungen üblicherweise mit dem Begriff Ideal-Observer-Modellierung assoziiert (Daunizeau et al., 2010; Knill & Richards, 1996).

Die Rubber-Hand-Illusion (RHI) beschreibt das Gefühl, ein künstliches Körperteil als dem eigenen Körper zugehörig zu empfinden. Abbildung 2 zeigt einen exemplarischen Aufbau für eine Variation des Experiments. Studienteilnehmerinnen und -teilnehmer sitzen dabei üblicherweise an einem Tisch, auf dem durch eine Vorrichtung die Sicht auf ihr eigenes Gliedmaß verdeckt ist. Stattdessen sehen sie ein künstliches Gliedmaß vor sich. In der Abbildung ist die echte Hand der Studienteilnehmerin unter dem Vorhang auf der linken Seite der Abbildung verborgen, während die künstliche Hand sichtbar ist. Bei

passiven Varianten werden beide Hände gleichzeitig oder mit zeitlicher Verzögerung taktil stimuliert, während die künstliche Hand bei aktiven Varianten die Bewegung der echten Hand durch beispielsweise einen Sensorhandschuh imitiert. Alle Varianten der Illusion haben gemein, dass sie auf eine Integration des visuellen Kanals und des propriozeptiven Kanals setzen, um das Gefühl zu erzeugen, dass das künstliche Gliedmaß vor den Studienteilnehmenden ihr echtes Gliedmaß sei.



Abbildung 2. Aufbau einer aktiven Variation der RHI mit einer beweglichen Roboterhand. Die echte Hand der Versuchsperson trägt einen Sensorhandschuh und wird unter einer Abdeckung aus Karton und einer Decke verdeckt und ist aus ihrer Perspektive nicht sichtbar. Die Roboterhand ahmt dabei Bewegungen der echten Hand nach.

Die RHI wurde umfangreich beschrieben und in verschiedenen sensomotorischen, kontextuellen und stimulationsspezifischen Konfigurationen untersucht (Botvinick & Cohen, 1998; Christ & Reiner, 2014) und wird für die Forschung an medizinischen Rehabilitationsrobotern als besonders relevant beurteilt (Beckerle et al., 2017; Moseley, Gallace, & Spence, 2012). Es besteht die Möglichkeit, dass das Erzeugen der RHI die Aufnahme künstlicher Prothesen in das Körperschema von Patienten mit Amputationen der oberen Gliedmaßen unterstützen kann (Ehrsson et al., 2008). Darüber hinaus wurden Ansätze für Human-in-the-Loop-Experimente vorgeschlagen, die ähnliche Effekte mit Rubber-Limb-Illusionen sowohl für obere als auch untere Extremitäten ermöglichen (Beckerle, De Beir, Schürmann, & Caspar, 2016; Schürmann, Overath, Christ, Vogt, & Beckerle, 2015). Diverse Faktoren wie die anatomisch plausible Position oder Farbe des künstlichen Körperteils wurden in bisheriger Forschung als relevant für das Auftreten der Illusion etabliert (Tsakiris & Haggard, 2005) und sind theoretisch kompatibel mit der Hypothese, dass die Illusion auch als Konsequenz bayesianischer Inferenz eintritt. Hat ein künstliches Gliedmaß im peripersonalen Raum des Agenten beispielsweise eine andere Hauttextur als die eigene, hat er Grund zu der Annahme, dass das besagte Gliedmaß nicht zu ihm gehört.

Um die wahrgenommenen Informationen über das künstliche Gliedmaß mit der experimentellen Stimulation zu integrieren, kann das bayesianische Modell für Kausalinferenz (Berniker & Kording, 2011) herangezogen werden. Damit kann die Wahrscheinlichkeit einer gemeinsamen Ursache für die

sensorischen Informationen ermitteln werden, die der Agent während einer körperlichen Illusion wahrnimmt. Über dieses Modell kann beispielsweise die unterschiedliche Farbe des künstlichen Gliedmaßes formalisiert einbezogen und selbst bei synchroner Stimulation das Nichtauftreten einer Illusion vorhergesagt werden. Für die Distanz zwischen künstlichem und realem Gliedmaß oder die zeitliche Verzögerung zwischen visueller und taktiler Stimulation während des Experiments (Shimada, Fukuda, & Hiraki, 2009) lassen sich ähnliche komputationale Umsetzungen finden. Tatsächlich wurde ein bayesianisches Modell für Kausalinferenz bereits auf die RHI angewandt (Samad, Chung, & Shams, 2015). Es berechnet die Wahrscheinlichkeit, dass ein künstliches Körperteil zum Agenten zugehörig ist, und berücksichtigt dabei die Distanz zum natürlichen Körperteil und die visuotaktile Verzögerung. Das Ziel der Autoren war dabei, die von Studienteilnehmenden berichtete gefühlte Position ihres Gliedmaßes nach der experimentellen Stimulation vorherzusagen. Die Differenz zwischen der nach der Stimulation berichteten Position des Gliedmaßes und seiner tatsächlichen Position ist als propriozeptiver Drift bekannt und gilt als ein Indikator für eine erfolgreich induzierte Illusion. Während das berichtete Modell von Samad et al. (2015) qualitativ konsistente Vorhersagen mit empirischen Daten produzierte, wurde der erzeugte propriozeptive Drift stark überschätzt. Der mittlere propriozeptive Drift der Modellvorhersage beträgt dabei ungefähr 17 Zentimeter und liegt damit weit über dem Ausmaß an Drift, der empirisch beobachtet werden kann (Christ & Reiner, 2014).

Konzeptionell ist davon auszugehen, dass der von Samad et al. (2015) vorgeschlagene komputationale Ansatz sowohl für die RHI als auch für ihr Äquivalent der unteren Extremitäten, die Rubber-Foot-Illusion (RFI) angebracht ist. Dieses Kapitel nutzt zunächst das von Samad et al. (2015) als Ausgangspunkt, um das bayesianische Modell für Kausalinferenz von der RHI auf die RFI zu generalisieren. Während Flögel, Beckerle und Christ (2014) die Auswirkung der Übertragung der Illusion auf die Füße bereits empirisch untersucht haben, wurde vor der Arbeit von Samad et al. (2015) keine Version der Illusion komputational untersucht. Samad et al. (2015) stellen fest, dass ihr Modell verlässlich die Entstehung der Illusion durch die Integration von Vorwissen über die Position des Gliedmaßes und aktuelle visuelle, taktile und propriozeptive Informationen vorhersagte, die alle mit individuellen Mengen an sensorischer Unsicherheit repräsentiert waren. Das Modell sagte korrekt vorher, dass die Illusion auch ohne taktile Stimulation entstehen kann und dass ihre Entstehungswahrscheinlichkeit durch synchrone Stimulation erhöht wird. Es erzeugt zwei gewichtete Schätzungen der Gliedmaßposition des Agenten – eine, die durch die Integration visueller und propriozeptiver Informationen entsteht und eine zweite, die auf der Basis getrennter sensorischer Kanäle ermittelt wird. Diese Positionsschätzungen wurden danach gewichtet, wie wahrscheinlich es war, dass visuelle und propriozeptive Informationen von einer gemeinsamen oder zwei getrennten Quellen verursacht wurden. Beispielsweise wurde bei asynchroner visuotaktile Stimulation, bei der das echte und künstliche Gliedmaß mit leichter Verzögerung berührt werden, eine höhere Wahrscheinlichkeit für getrennte Quellen der sensorischen Eindrücke angenommen. Mit Bezug auf die im System repräsentierte Unsicherheit konnte auch erklärt werden, warum es schon ausreicht, ein künstliches Gliedmaß nah an ein reales zu legen, um die Illusion auszulösen: war die Distanz klein genug, überlappten visuelle und propriozeptive Unsicherheit auch ohne Stimulation und lösten eine schwächere, aber vorhandene Illusion aus. Wurden das künstliche und echte Gliedmaß weiter voneinander entfernt positioniert, bestand Sicherheit darüber, dass visuelle und propriozeptive Information nicht von derselben Quelle stammen konnten.

Die grundsätzlichen Annahmen des bayesianischen Modells für Kausalinferenz sollten von der RHI auf die RFI übertragbar sein. In diesem Kapitel überprüfe ich aber zusätzlich, ob die Überschätzung des

propriozeptiven Drifts in der Implementierung von Samad et al. (2015) von ihrer Annahme über das Vorwissen des modellierten Agenten abhängt. Sie verwenden eine uniforme Verteilung über den Prior möglicher Gliedmaßpositionen im peripersonalen Raum des Agenten. Dies kommt der Annahme gleich, dass jede mögliche Position des Gliedmaßes gleich wahrscheinlich ist. Im weiteren Verlauf des Kapitels erläutere ich den komputationalen Prozess, der von der Nutzung eines uniformen Priors zur Überschätzung des propriozeptiven Drifts führt. Uniforme Prior-Verteilungen sind in bayesianischer Datenanalyse üblich (Kruschke, Aguinis, & Joo, 2012), müssen aber auf Plausibilität geprüft werden, wenn sie zur Quantifizierung von Vorwissen aus der Perspektive eines kognitiven Systems herangezogen werden. Ich folge der Annahme, dass eine informierte Prior-Verteilung über die bisherige Position des Gliedmaßes vor Beginn der experimentellen Stimulation angebracht ist und eine realistischere Schätzung des propriozeptiven Drifts mit sich bringt. An dieser Stelle ist anzumerken, dass das bayesianische Modell für Kausalinferenz ausschließlich auf der komputationalen Ebene arbeitet und keine algorithmischen oder Implementierungsspezifikationen beinhaltet. Bisherige Forschung legt nahe, dass menschliches Verhalten in sensomotorischen Szenarien komputational bayesianischer Optimalität deutlich eher entspricht, als es für Verhalten außerhalb sensomotorischer Fragestellungen der Fall ist (Vul, 2010). Deshalb sind die algorithmischen Spezifikationen, die in Kapitel 1 für 2AFC-Entscheidungen eingeführt wurden, in diesem Modell nicht integriert. Dieses Kapitel stellt die Berechnung des bayesianischen Modells für Kausalinferenz vor und passt die notwendigen Modellparameter von der Anwendung auf die RHI für die RFI an. In einem anschließenden Modellvergleich überprüfe ich, ob ein auf diese Art angepasstes Modell mit dem vorgeschlagenen informierten Prior besser von einem bestehenden Datensatz zur RFI unterstützt wird, als der von Samad et al. (2015) vorgeschlagene uniforme Prior.

3.1. Modellstruktur und Parameter

Bayesianische kognitive Modelle wie das Modell für Kausalinferenz repräsentieren sensorische Informationen und die mit sensorischen Kanälen assoziierte Unsicherheit durch Wahrscheinlichkeitsverteilungen. Im Fall von Gaussverteilungen drückt die Standardabweichung diese Unsicherheit aus – je größer die Standardabweichung, desto mehr Werte gelten als plausibel. Während einige Parameterwerte für das hier vorgestellte Modell von Samad et al. (2015) übernommen werden konnten, mussten andere aufgrund des Wechsels von der RHI zur RFI angepasst werden. Die folgenden Parameter sind Teile des Modells und mit Ausnahme der binären Variable C Gaussverteilungen, sind also durch Mittelwerte und Standardabweichungen parametrisiert.

- Prior-Wahrscheinlichkeit einer gemeinsamen Ursache $p(C = 1)$ beziehungsweise separater Ursachen $p(C = 2)$
- Prior-Verteilung der Lokalisierung des Gliedmaßes $p(X)$
- Prior-Verteilung der visuotaktilen Information $p(T)$
- Likelihood der visuellen Information in Bezug auf die Lokalisierung des Gliedmaßes $p(X_v)$
- Likelihood der propriozeptiven Information $p(X_p)$
- Likelihood der visuellen Information in Bezug auf die zeitliche Dimension taktilen Feedbacks $p(T_v)$
- Likelihood der taktilen Information in Bezug auf die zeitliche Dimension taktilen Feedbacks $p(T_t)$

X_v und X_p beschreiben die räumliche Position der visuellen und propriozeptiven Empfindungen in Zentimetern und T_v und T_t repräsentieren eine zeitliche Diskrepanz zwischen der visuellen und taktilen Empfindung bei taktiler Stimulation in Millisekunden.

Gleichung 3.1 nutzt den Satz von Bayes zur Generierung einer Schätzung für die Posterior-Wahrscheinlichkeit einer gemeinsamen Ursache der wahrgenommenen sensorischen Informationen.

$$p(C = 1 | X_v, X_p, T_v, T_t) = \frac{p(X_v, X_p, T_v, T_t | C=1) p(C=1)}{p(X_v, X_p, T_v, T_t | C=1) p(C=1) + p(X_v, X_p, T_v, T_t | C=2) (1-p(C=1))} \quad (3.1)$$

Die Variabilität des visuellen Systems wird auf ungefähr 0.36 Grad geschätzt (van Beers, Sittig, & Denier van der Gon, 1998), was ungefähr einem Millimeter für die Distanz zwischen dem menschlichen Auge und den Händen in sitzender Position entspricht. Berücksichtigt man die größere Distanz zwischen den Augen und Füßen, muss man hingegen von einer größeren Variabilität ausgehen. Die Standardabweichungen der visuellen und taktilen Information in Bezug auf die zeitliche Dimension werden auf ca. 20 Millisekunden geschätzt (Hirsh & Sherrick, 1961). Die propriozeptive Präzision wurde für die Hände auf eine Standardabweichung von 15 Millimetern geschätzt (Jones, Cressman, & Henriques, 2010). Samad et al. (2015) nutzten die hier genannten Werte zur Parametrisierung der Likelihoods der verschiedenen sensorischen Informationen. Sie kombinierten diese mit einem uniformen Prior über eine begrenzte Fläche innerhalb des peripersonalen Raums vor dem Agenten. Dieser Prior beschreibt identische Wahrscheinlichkeiten für alle möglichen Positionen des berücksichtigten Gliedmaßes. Gleichermaßen blieb der Prior der visuotaktilen Information uniform, sodass der Agent keine Vorerfahrung hinsichtlich der Synchronität der Stimulation auf echtem und künstlichem Gliedmaß hat. Weil der Agent außerdem keine Information über die Natur der folgenden Stimulation haben sollte, beträgt sein Prior der Wahrscheinlichkeit einer gemeinsamen Ursache 50%.

Um die Vorhersage extremer Werte für propriozeptiven Drift an empirisch beobachtbare Ausmaße anzunähern, nutze ich statt des uniformen Priors der Lokalisierung des Gliedmaßes einen informierten Prior. Dieser nimmt die Form einer Gaussverteilung an. Die Parametrisierung des informierten Priors kann dabei auf zwei Arten durchgeführt werden:

- Konzeptionell informiertes Modell: Der Mittelwert des Priors liegt genau auf der physischen Position des echten Gliedmaßes und seine Standardabweichung beträgt entsprechend propriozeptiver Präzision 15 Millimeter.
- Empirisch informiertes Modell: Die Standardabweichung des Priors beträgt weiterhin 15 Millimeter, aber sein Mittelwert wird aus einer Hyperverteilung gezogen, deren Parameter durch die Lokalisierungsmessungen vor einer Stimulation aus einem zweiten, unabhängigen Datenset bestimmt werden.

Die aufgeführten Varianten des informierten Priors sind deshalb angemessenere Formen als die uniforme Variante (Samad et al., 2015), weil der menschliche Agent zu Beginn einer Studie zu RHI oder RFI am Experimentalaufbau Platz nimmt, aber vor Beginn der Stimulation kontinuierlich unbeeinflusste propriozeptive Informationen über sein verdecktes Gliedmaß erhält. Die einfachste Implementierung dieses Umstands ist das konzeptionell informierte Modell. Dieses ignoriert jedoch die inter-individuelle

Varianz, die in der Messung von Lokalisierungen vor einer Stimulation empirisch oft beobachtet werden kann (Christ, Elger, Schneider, Rapp, & Beckerle, 2013). Um diese Varianz zu berücksichtigen, vertraut das empirisch informierte Modell auf ein zusätzliches Datenset (Flögel, Kalveram, Christ, & Vogt, 2015). Dieses Datenset wurde auf Basis desselben experimentellen Setups gesammelt, auf dem auch das modellierte Datenset beruht. Die Lokalisierungsdaten vor der experimentellen Stimulation in der synchronen Bedingung der RFI dieses Artikels (Flögel et al., 2015) nutze ich für die Parametrisierung der Hyperverteilung, aus der individuelle Mittelwerte des informierten Priors im empirisch informierten Modell gezogen werden. Diese Verteilung besitzt einen Mittelwert von 49.06 Zentimetern und eine Standardabweichung von 5.37 Zentimetern. Außerdem passe ich die Likelihood visueller Information in Bezug auf die Lokalisierung des Gliedmaßes an die größere Distanz zwischen den Augen und den Füßen an. Van Beers et al. (1998) berichten Schwankungen der visuellen Präzision von bis zu 0.6 Grad. Auf die durchschnittlichen 112.5 Zentimeter Distanz der im nächsten Teilkapitel vorgestellten empirischen Studie bezogen ergibt sich eine Standardabweichung von 1.2 Zentimetern um die Position des künstlichen Gliedmaßes. Die propriozeptive Präzision verändert sich durch die erhöhte Distanz nicht und wird weiterhin durch eine Standardabweichung von 15 Millimetern parametrisiert. Durch die ausschließlich synchrone Stimulation in der empirischen Studie kürzt sich der Einfluss der Likelihoods in Bezug auf die zeitliche Dimension aus und ihre Parametrisierung ist überflüssig.

Der Prozess der Informationsintegration ist in Tabelle 2 dargestellt. Sie zeigt das durchschnittliche Modellverhalten unter Berücksichtigung der uniformen und informierten Priors. Ausgehend von gleichen Wahrscheinlichkeiten für eine gemeinsame oder zwei separate Ursachen der Stimulation werden visuelle und propriozeptive Informationen genutzt, um einen Posterior über die Ursachenwahrscheinlichkeit zu ermitteln. Außerdem bestimmt ein weiterer Posterior die Lokalisierung des Gliedmaßes, welcher von der Wahl des Priors beeinflusst wird. Es ist zu beachten, dass das Verhalten der konzeptionell und empirisch informierten Modelle hier in derselben Spalte zusammengefasst ist, weil ihr Verhalten bei konstant gehaltenem Prior identisch ist. Erst bei der Betrachtung mehrerer individueller Studienteilnehmender macht sich die Variabilität des empirisch informierten Modells bemerkbar. Die informierten Priors führen dazu, dass die Posterior-Lokalisierung näher an der tatsächlichen Position des echten Gliedmaßes verortet ist, als unter einem uniformen Prior. Für den im nächsten Teilkapitel vorgestellten Datensatz wurde die Positionierung ausgehend von der Körpermitte bestimmt, sodass das künstliche Gliedmaß bei 30 Zentimetern und das echte Gliedmaß bei 50 Zentimetern verortet waren.

Tabelle 2.

Prozess der Informationsintegration für das uniforme und die informierten Modelle. Die konzeptionell und empirisch informierten Modelle sind in der rechten Spalte der Tabelle zusammengefasst.

Wahrscheinlichkeit einer gemeinsamen Ursache ($C = 1$)		
	Uniformes Modell	Informierte Modelle
Vor Stimulation	$p = 0.5$	$p = 0.5$
Nach Stimulation	$p = 0.95$	$p = 0.95$
Durchschnittliche Lokalisierung des Gliedmaßes		
	Uniformes Modell	Informierte Modelle
Vor Stimulation	Uniform	50 Zentimeter
Nach Stimulation	38 Zentimeter	41 Zentimeter

Anmerkung. Dargestellt sind die Inferenz einer gemeinsamen Ursache der sensorischen Informationen und die durchschnittliche Lokalisierung (Distanz von der Körpermitte in Zentimeter) des Gliedmaßes vor und nach der experimentellen Stimulation.

Nachdem die Modelle die Posterior-Wahrscheinlichkeit einer gemeinsamen Ursache der Stimulation ermittelt haben, berechnen sie eine Schätzung der wahrscheinlichsten Position des Gliedmaßes. Diese Berechnung ist in Gleichung 3.2 beschrieben.

$$\hat{X}_p = p(C = 1 | X_v, X_p, T_v, T_t) \hat{X}_{p,C=1} + (1 - p(C = 1 | X_v, X_p, T_v, T_t)) \hat{X}_{p,C=2} \quad (3.2)$$

Die dafür notwendigen Schätzungen für $\hat{X}_{v,C=1} = \hat{X}_{p,C=1}$ beziehungsweise $\hat{X}_{v,C=2}$ und $\hat{X}_{p,C=2}$ werden in den Gleichungen 3.3, 3.4 und 3.5 berechnet.

$$\hat{X}_{v,C=1} = \hat{X}_{p,C=1} = \frac{\frac{X_v}{\sigma_v^2} + \frac{X_p}{\sigma_p^2} + \frac{\mu_X}{\sigma_X^2}}{\frac{1}{\sigma_v^2} + \frac{1}{\sigma_p^2} + \frac{1}{\sigma_X^2}} \quad (3.3)$$

$$\hat{X}_{v,C=2} = \frac{\frac{X_v}{\sigma_v^2} + \frac{\mu_X}{\sigma_X^2}}{\frac{1}{\sigma_v^2} + \frac{1}{\sigma_X^2}} \quad (3.4)$$

$$\hat{X}_{p,C=2} = \frac{\frac{X_p}{\sigma_p^2} + \frac{\mu_X}{\sigma_X^2}}{\frac{1}{\sigma_p^2} + \frac{1}{\sigma_X^2}} \quad (3.5)$$

3.2. Empirische Stichprobe und deskriptive Datenanalyse

Um die Vorhersagen der Modelle mit menschlichem Verhalten zu vergleichen, nutze ich einen publizierten Datensatz (Christ et al., 2013). Die Studie wurde durchgeführt, um zu untersuchen, ob unterschiedliche Stärken der RFI über die Stimulation von hoch und niedrig auflösenden haptischen Pfaden auf dem Fuß erzielt werden können. Dieser Ansatz führte zu keinem signifikanten Unterschied zwischen den Gruppen mit unterschiedlichen haptischen Pfaden. Der propriozeptive Drift der hochauflösenden Gruppe betrug im Mittel -2.30 Zentimeter bei einer Standardabweichung von 2.48 Zentimetern, während er in der niedrigauflösenden Gruppe im Mittel -2.65 Zentimeter bei 3.43 Zentimeter Standardabweichung betrug. Die experimentelle Stimulation erzeugte also einen negativen propriozeptiven Drift. Dieser Umstand ist ungewöhnlich, aber für die Betrachtung im bayesianischen Modell für Kausalinferenz unerheblich. Beide Experimentalgruppen berichteten im Vergleich zu einer Kontrollgruppe keine signifikant unterschiedlichen Werte an propriozeptivem Drift. Der Datensatz bestand aus 19 Studienteilnehmenden (58% weiblich, Alter $M = 24$ Jahre, $SD = 4.5$ Jahre), die zufällig unterschiedlichen Folgen an Konditionen zugeteilt wurden. Da die ursprüngliche Analyse keinen signifikanten Effekt der haptischen Pfade auf den propriozeptiven Drift zeigte, wurden die Bedingungen für die weitere Analyse gemeinsam analysiert. Der kombinierte propriozeptive Drift betrug im Mittel -2.47 Zentimeter bei einer Standardabweichung von 2.96 Zentimetern für 38 Datenpunkte. Es sei darauf hingewiesen, dass dieses Ausmaß an Drift niedriger als das von Samad et al. (2015) für die RHI berichtete und das einer Vergleichsstudie zwischen RHI und RFI (Flögel et al., 2015) ist.

3.3. Ergebnisse

Die Varianten des bayesianischen Modells für Kausalinferenz mit einem uniformen beziehungsweise den informierten Priors wurden einem Modellvergleich mittels Bayes Factor unterzogen. Die Herleitung und Anwendung der Evaluationsmethodik ist in Kapitel 2 dieser Arbeit beschrieben. Abbildung 3 zeigt die Schätzungen für die Position des echten Gliedmaßes aller Modelle zusammen mit den empirischen Daten. Die Vorhersage des Modells mit empirisch informiertem Prior (gestrichelte grüne Linie) approximiert zwar die empirisch beobachtete Varianz, überschätzt jedoch immer noch das Ausmaß an propriozeptivem Drift. Die Vorhersage der Positionsschätzung im uniformen Modell (rot) fällt durch ihre geringe Varianz und größere Distanz zur empirischen Verteilung auf. Daraus resultiert ein positiv unendlicher Bayes Factor zugunsten des Modells mit dem empirisch informierten Prior. Das konzeptionell informierte Modell approximiert den Mittelwert der empirisch informierten Vorhersageverteilung, ihm fehlt jedoch die erlaubte inter-individuelle Varianz des empirisch informierten Modells. Aus dem Vergleich zwischen dem empirisch und konzeptionell informierten Modell ergibt sich ein unendlich positiver Bayes Factor zugunsten des empirisch informierten Modells. Der Vergleich zwischen dem konzeptionell informierten Modell und dem uniformen Modell erzeugt keinen Bayes Factor, weil das Produkt jeder marginalen Likelihood Null approximiert und die Division für den Bayes Factor daher mathematisch undefiniert ist. Es kann aufgrund der Daten keine Aussage über den Vergleich der prognostischen Qualität dieser beiden Modelle getroffen werden.




Abbildung 3. Modellvorhersagen und empirische Positionsangaben des echten Gliedmaßes nach der experimentellen Stimulation. Steigende Werte auf der x-Achse repräsentieren die horizontale Ebene von links nach rechts vor Studienteilnehmenden.

Anstelle der Positionsschätzungen betrachtet Abbildung 4 den propriozeptiven Drift, also die Differenz zwischen der Positionsschätzung vor und nach der Stimulation. Hierfür wurde die x-Achse invertiert. Während in Abbildung 3 höhere Werte auf der x-Achse Werte weiter rechts auf der horizontalen Ebene vor den Studienteilnehmenden darstellten, stehen steigende Werte in Abbildung 4 für einen größeren Drift in Richtung des künstlichen Gliedmaßes. Der Bayes Factor zwischen empirisch informiertem Modell und uniformem Modell ist positiv unendlich, genau wie der Bayes Factor zwischen empirisch informiertem und konzeptionell informiertem Modell. Ähnlich der Vorhersage der Positionsangabe nach der experimentellen Stimulation kann auch für den propriozeptiven Drift kein Bayes Factor zwischen konzeptionell informiertem und uniformem Modell berechnet werden, da beide Modelle annähernd keine Evidenz durch die empirischen Daten erhalten.

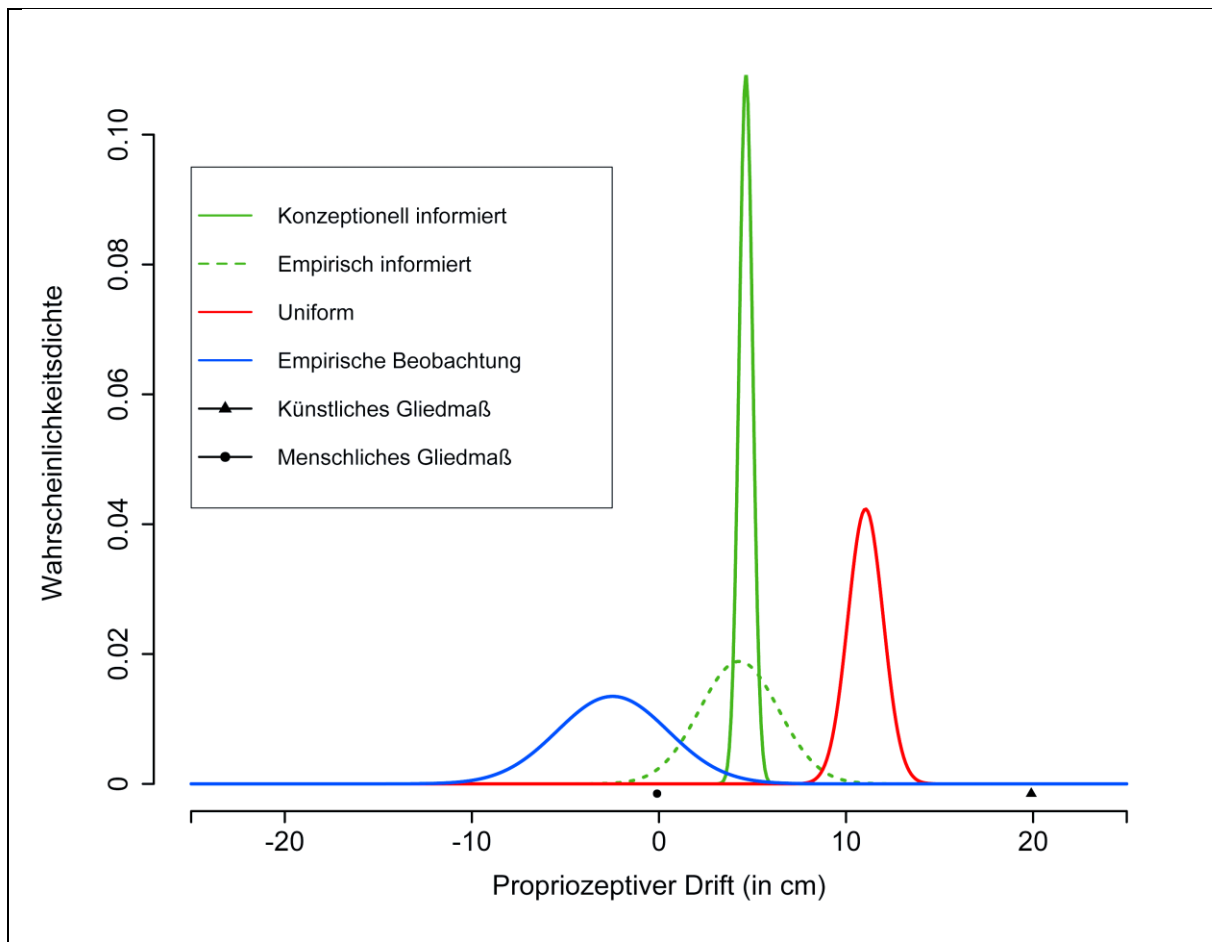


Abbildung 4. Modellvorhersagen und empirischer propriozeptiver Drift. Positive Werte stehen für einen Drift von der Position des echten zum künstlichen Gliedmaß.

3.4. Diskussion

Das Ziel der in diesem Kapitel aufgezeigten Modellierung ist es, quantitative Vorhersagen menschlicher Körperwahrnehmung zu generieren. Der Einsatz des bayesianischen Modells für Kausalinferenz ermöglicht einen Einblick in den multisensorischen Integrationsprozess auf der komputationalen Ebene (Marr, 1982), der maßgeblich zum Umgang mit unsicherheitsbehafteten Zuständen im sensomotorischen System beiträgt. Die vorgestellten Modellvarianten unterscheiden sich in der Motivation und Parametrisierung ihrer jeweiligen Priors, ihr Vergleich führt jedoch zu einer klaren Bevorzugung des empirisch informierten Modells. Die Tatsache, dass die Spezifikation des Priors das Ergebnis der Datenanalyse beeinflusst, ist dabei ein wünschenswerter Effekt des bayesianischen Paradigmas und nicht etwa eine nachträgliche Anpassung an die Datenlage. Kruschke (2015) stellt an die Definition eines informierten Priors nur die Anforderung, dass er dem Urteil eines skeptischen wissenschaftlichen Publikums standhalten muss. Die Wahl des empirisch informierten Priors in diesem Kapitel scheint aus dieser Perspektive intuitiv plausibel, allerdings deckt sie im Modellvergleich einen problematischeren Aspekt des uniformen Modells auf.

3.4.1. Modellverhalten

Das Verhalten der vorgestellten Modelle unterscheidet sich in zwei Aspekten von dem von Samad et al. (2015) eingesetzten. Zunächst sorgen Anpassungen der Parameterwerte aller Modelle für eine

Generalisierung auf den Experimentalaufbau der RFI. Außerdem führt die Aufnahme eines informierten Priors zu einer veränderten Lokalisierung des Gliedmaßes vor der Stimulation. Diese Änderung formalisiert die Intuition, dass Studienteilnehmende vor Beginn der Stimulation sehr wohl eine ungefähre Aussage zur Position ihres Gliedmaßes treffen können. Diese mag je nach Experimentalaufbau durch einen abgedunkelten Raum oder visuelle Hindernisse eingeschränkt sein. Dass sie aber einer uniformen Verteilung über die azimutale Ebene gleichkommt, ist anzuzweifeln. Das Modell mit dem empirisch informierten Prior wird gegenüber dem ursprünglichen Modell und einer einfacheren Implementierung des informierten Priors im konzeptionell informierten Modell sowohl auf Basis der absoluten Positionsschätzungen als auch auf Basis propriozeptiver Driftwerte durch den Bayes Factor extrem bevorzugt.

Abbildung 4 zeigt, dass alle Modelle den propriozeptiven Drift in den empirischen Daten überschätzen. Betrachtet man nur dieses Maß, fallen keine weiteren Besonderheiten im Modellverhalten auf. Unter Berücksichtigung des propriozeptiven Drifts und der absoluten Positionsschätzungen in Abbildung 3 hingegen wird deutlich, dass das konzeptionell informierte und das uniforme Modell Positionsschätzungen erzeugt, die sehr eng um eine Position liegen. Die sehr geringe Varianz dieser Werte ist auch in diversen Abbildungen von Samad et al. (2015; Abbildungen 2a und 4) erkenntlich, sodass ein Fehler in der Umsetzung ihres Modells ausgeschlossen werden kann. Im Fall des uniformen und konzeptionell informierten Modells wird der Mittelwert individueller Priors auf die physische Position des Gliedmaßes der Teilnehmenden fixiert. Während das empirisch informierte Modell diese Einschränkung aufhebt, teilt es eine Eigenschaft mit dem konzeptionell informierten Modell: die Veränderung des Mittelwerts des Priors schlägt sich in der Positionseinschätzung nach der experimentellen Stimulation nieder. Aufgrund des Priors konnte das uniforme Modell diese Information nicht einbeziehen und gab eine Positionsschätzung ab, die hauptsächlich durch die relativen Präzisionen des visuellen und propriozeptiven Kanals beeinflusst wurde. Dadurch, dass die sensorischen Präzisionen in den Modellen als fixiert und interindividuell identisch behandelt wurden, machte das uniforme Modell annähernd identische Positionsvorhersagen für alle Studienteilnehmenden und ignorierte ihre Positionsangaben komplett. Die Darstellung der Vorhersagen über den propriozeptiven Drift in Abbildung 4 allein würde diese Charakteristik des uniformen Modells nicht offenlegen, weil diese Vorhersagen auf den ersten Blick überschätzt, aber plausibel wirken. Das uniforme Modell hält zwar qualitativen Untersuchungen seines Verhaltens stand, beispielsweise einer geringeren Wahrscheinlichkeit einer gemeinsamen Ursache bei steigender Distanz zwischen echtem und künstlichem Gliedmaß (Samad et al., 2015). Abbildung 3 zeigt jedoch, dass die Verwendung eines uniformen Priors nicht nur unrealistische Grundannahmen über plausible Positionsschätzungen trifft. Sie führt außerdem dazu, dass das bayesianische Modell zur Kausalinferenz nichts weiter tut, als das Signalverhältnis zwischen dem visuellen und propriozeptiven Kanal als Vorhersage auszugeben. Dieses unplausible Verhalten erhielt im Modellvergleich richtigerweise keine Unterstützung durch die empirischen Daten.

Das konzeptionell informierte Modell teilt das problematische Verhalten des uniformen Modells, indem es ebenfalls Vorhersagen von Lokalisierungseinschätzungen nach der experimentellen Stimulation abgibt, die eng um einen spezifischen Wert liegen. Der Mittelwert dieser Schätzungen liegt mit 45 Zentimetern zwar näher an den empirischen Daten als das uniforme Modelle, aber die fehlende Fähigkeit zur Modellierung inter-individueller Varianz führt zu einer noch stärkeren Kompression der Lokalisierungseinschätzung. Die Tatsache, dass das konzeptionell informierte Modell zumindest Änderungen im Mittelwert seines Priors darstellen kann, ist zwar erstrebenswert. Sie kann aber nicht

darüber hinwegtäuschen, dass beide Modelle ähnlich geringe Unterstützung durch die empirischen Daten finden.

Das empirisch informierte Modell besitzt ebenfalls die Fähigkeit, Parameteränderungen im Prior in seinen Vorhersagen zu zeigen. Dieser Umstand führt dazu, dass die Vorhersagen mehr als eine reine Signalrelation zwischen sensorischen Kanälen sind. Das Modell legt außerdem die Annahme fixierter Prior-Mittelwerte auf die physische Gliedmaßposition ab. Teilnehmende in Studien zur RHI oder RFI zeigen sowohl vor, als auch nach der Stimulation ein gewisses Ausmaß an inter-individueller Varianz (Christ et al., 2013; Flögel et al., 2015). Das empirisch informierte Modell erzeugt durch die Erlaubnis solcher Varianz plausiblere Vorhersagen als beide anderen Modelle. Allerdings zeigt die grafische Inspektion in den Abbildungen 3 und 4, dass der Mittelwert der Modellvorhersagen annähernd identisch mit dem des konzeptionell informierten Modells ist. Trotz der Tatsache, dass ein negativer propriozeptiver Drift wie im hier vorliegenden empirischen Datenset an sich problematisch ist, kann auch die größere Komplexität des empirisch informierten Modells diese negative Tendenz nicht ohne Hinzunahme weiterer Parameter vorhersagen.

3.4.2. Einschränkungen

Die Anwendung von Bayes Factors als Evaluationsmethode kognitiver Modelle zeigt nur die bessere Alternative auf und trifft keine Aussage über die generelle Vorhersagequalität eines einzelnen Modells. Eine graphische Überprüfung der Abbildung 3 zeigt daher, dass das empirisch informierte Modell zwar bessere Vorhersagen als die beiden anderen Modelle erzeugt, aber Raum für Verbesserungen offenlässt. Ein offensichtlicher Ansatzpunkt für solche Verbesserungen ist die Anpassung der Präzisionsparameter von der Anwendung auf die RHI zur Anwendung auf die RFI. Meines Kenntnisstandes nach gibt es keine Forschungsliteratur, die eine Alternative zu linearer Erhöhung der Standardabweichung vorschlägt. Existierende Literatur zur propriozeptiven Präzision bezieht sich nicht auf die azimuthale Ebene, die für die Positionsbestimmung in RHI- und RFI-Paradigmen relevant ist (Robbins, Waked, Allard, McClaran, & Krouglicof, 1997; Robbins, Waked, & McClaran, 1995).

Intuitiv scheint eine geringere propriozeptive Präzision für die Füße in Relation zu den Händen sinnvoll, weil die Geschicklichkeit im Umgang mit den Händen im Alltag eine höhere Präzision benötigt. Zur Heranführung der Modellprognose an die empirische Datenlage trägt diese Anpassung allerdings nicht bei, weil sie den propriozeptiven Drift erhöhen statt verringern würde. Die einzige plausible Anpassung der Parameterwerte, die in der aktuellen Modellstruktur zu einer Verbesserung der Vorhersagequalität führen würde, wäre eine größere Erhöhung der Likelihood visueller Informationen. Mir ist jedoch keine vorherige Forschungsliteratur bekannt, die mehr als die hier angewandte lineare Erhöhung rechtfertigen würde.

Das vorliegende Kapitel berücksichtigt ausschließlich die synchrone Stimulationsbedingung der RFI. Vorherige Forschungsliteratur mit datenanalytischem Fokus hat sich darauf konzentriert, die Bedingungen zur Erzeugung einer Körperillusion zu untersuchen und auszuweiten (Christ & Reiner, 2014; Crea, D'Alonzo, Vitiello, & Cipriani, 2015; Lenggenhager, Hilti, & Brugger, 2015). Diese Bedingungen komputational abzubilden und damit empirische Beobachtungen vorherzusagen, sollte zwar möglich sein. Der Fokus des Kapitels lag aber zunächst auf der Evaluation der Auswirkung eines plausiblen Priors auf das Verhalten des bayesianischen Modells für Kausalinferenz.

3.5. Schlussfolgerungen

Die Mechanismen zu verstehen, die zu Körperillusionen führen, ist nicht nur für die Psychologie (Christ & Reiner, 2014; Giummarra, Gibson, Georgiou-Karistianis, & Bradshaw, 2008), sondern auch für die Ingenieurwissenschaften von enormer Relevanz (Beckerle et al., 2017; Caspar et al., 2015; Tim Schürmann, Mohler, Peters, & Beckerle, 2019). Beispielsweise können verlässliche Modelle menschlicher Kognition neue Strategien zur Mensch-Maschine-Interaktion ermöglichen, indem sie Schnittstellen durch kontinuierliche Nutzendenmodellierung anpassen. Um die Vorhersagekraft solcher Modelle an beobachtbare Daten zu verbessern, habe ich in diesem Kapitel zwei Implementierungsmöglichkeiten eines informierten Priors für die Lokalisierung des Gliedmaßes vorgeschlagen. Der Modellvergleich via Bayes Factors fällt dabei klar zugunsten des empirisch informierten Modells aus und eine graphische Überprüfung offenbart erhebliche Mängel der Vorhersageplausibilität des konzeptionell informierten und des uniformen Modells.

Die Parametrisierung der sensorischen Unsicherheit, die für die Anwendung der vorgestellten Modelle nötig ist, ist auf valide Grundlagenforschung angewiesen. Die Definition von visueller und propriozeptiver Präzision sollte daher von speziell mit dem Hintergrund komputationaler Parametrisierung betriebener empirischer Messung unterstützt werden. Dieses Argument betrifft auch die Annahme eines uniformen Priors über die Wahrscheinlichkeit einer gemeinsamen Ursache. Diese Wahrscheinlichkeit dürfte für jemanden, der a priori Kenntnis über den Inhalt von RHI- und RFI-Experimenten hat, nicht mehr 50% betragen. Durch die Akquise von Studienteilnehmenden aus dem Kreis Studierender der Psychologie könnte diese Annahme also gefährdet sein und eine Replikation mit nachweislich naiven Studienteilnehmenden wäre angebracht. Ich gehe davon aus, dass die Berücksichtigung dieser Schritte in der weiteren Entwicklung von kognitiven Modellen sensomotorischer Prozesse zielführend für die Nutzungsakzeptanz und Körperschemaintegration von technischen Assistenzsystemen sein kann.

4. Empirische Anwendung: Entscheidungsmodellierung für Optionen auf Basis mehrerer Attribute: Nutzung von Online-Diensten

Die Allgegenwärtigkeit mobiler Geräte, Hacking-Angriffe und diverser politischer Skandalfälle haben die Datensammlung im Online-Kontext zu einem Thema großer gesellschaftlicher Relevanz werden lassen. Die umfangreiche Sammlung und Verknüpfung von Daten aus verschiedenen Quellen erlaubt auf der einen Seite die Entstehung vieler benutzungsfreundlicher Features in modernen Online-Services. Gleichzeitig stellt sie jedoch ein massives Risiko für die Privatsphäre dieser Nutzenden dar. Obwohl viele Nutzenden auf Nachfrage Sorgen um einen Verlust ihrer Privatsphäre durch diese umfangreiche Datensammlung angeben, tendieren sie dennoch dazu, sie in großem Maße online preiszugeben. Dieses Verhalten wurde unter dem Namen Privatsphären-Paradox in der Forschungsliteratur bekannt (Norberg, Horne, & Horne, 2007). Es wurde zwar in der Psychologie (Dienlin & Trepte, 2015), den Wirtschaftswissenschaften (Acquisti, 2009) und verwandten Disziplinen (Lutz & Strathoff, 2014) intensiv untersucht, aber es besteht kein akademischer Konsens über seine Entstehung. Ich nutze hier die in Kapitel 1 beschriebenen Entwicklungen im Bereich der kognitiven Modellierung, um das Entscheidungsverhalten in Bezug auf Online-Services als domänenspezifisches Beispiel generellen Entscheidungsverhaltens zu untersuchen. Dafür stelle ich zunächst den Stand der Forschung im Bereich des Umgangs mit Online-Privatsphäre dar. Daraufhin zeige ich auf, warum bayesianische kognitive Modellierung unter Berücksichtigung der algorithmischen Ebene offene Fragen in der Literatur beantworten kann und stelle zwei empirische Studien vor, die die Vorhersagen von vier kognitiven Modellen mit Nutzungsverhalten vergleichen. In diesen Studien werden Teilnehmende vor die Wahl gestellt, ob sie gezeigte fiktive Smartphone-Apps installieren möchten oder nicht. Dabei handelt es sich demnach um ein 2AFC-Szenario.

4.1. Entscheidungsverhalten in Bezug auf Online-Services

In der bisherigen Forschung wurden mehrere mögliche Antworten auf die Frage vorgeschlagen, warum das Verhalten der Nutzenden von Online-Services im Widerspruch zu ihren dargelegten Präferenzen steht (Hoffmann, Lutz, & Ranzini, 2016; Kehr, Wentzel, & Kowatsch, 2014; Krasnova, Kolesnikova, & Günther, 2009; H. Lee, Park, & Kim, 2013; Norberg et al., 2007). Selbst ob das gezeigte Verhalten überhaupt als widersprüchlich zu verstehen ist, wird in jüngerer Forschung noch debattiert (Dienlin & Trepte, 2015; Lutz & Strathoff, 2014). Norberg et al. (2007) interpretieren das gezeigte Nutzungsverhalten als Diskrepanz zwischen den eigenen Verhaltensintentionen und dem tatsächlichen Verhalten. Andere Ansätze unterscheiden stattdessen zwischen allgemeinen Einstellungen und situationsspezifischen Faktoren (Kehr et al., 2014), sodass die Diskrepanz eher zwischen Einstellungen und Verhaltensintentionen statt Intentionen und Verhalten angesiedelt sei. Ein Forschungsfeld, das das gezeigte Verhalten als quasi-rationale Erwägung zwischen wahrgenommenen Risiken und Vorteilen versteht, ist unter dem Namen Privatsphären-Calculus etabliert (Dinev & Hart, 2006). Dieses Forschungsfeld basiert auf der Theorie der erwarteten Nützlichkeit (Morgenstern & Von Neumann, 1953), die in der Einleitung dieser Arbeit in Bezug auf die Rationalität menschlicher Entscheidungen besprochen wurde. Ein Forschungsüberblick (Kokolakis, 2017) stellt jedoch heraus, dass die meisten Erklärungsansätze des Privatsphären-Paradox die Annahme rationaler Entscheidungsfindung bei

Nutzenden von Online-Services anzweifeln. Als Grundlage dieser Zweifel werden üblicherweise zwei Argumentationslinien angeführt. Erstens, dass Entscheidungen in Bezug auf die Online-Privatsphäre von kognitiven Verzerrungen beeinflusst sind (Acquisti & Grossklags, 2005) und zweitens, dass menschliche Entscheidungsfindung aufgrund der Knappheit kognitiver Ressourcen nur begrenzt rational sein kann (Simon, 1955). Das Argument der kognitiven Verzerrungen baut dabei auf der Prospect-Theorie auf (Kahneman & Tversky, 1979), die als Erweiterung der Theorie der erwarteten Nützlichkeitsgewichtungparameter für die Wahrnehmung von Wahrscheinlichkeiten vorsieht. Damit ist sie imstande, Agentenverhalten zu erzeugen, das kleine Wahrscheinlichkeiten über- und große Wahrscheinlichkeiten unterschätzt. Zudem kann der Agent über eine nichtlineare Wertefunktion eine Tendenz zur Verlustaversion ausdrücken.

Während die vorgestellten Forschungsfelder unterschiedliche Ansätze verfolgen, um privatsphärenbezogenes Verhalten zu erklären, haben die meisten gemein, dass sie den Entscheidungsprozess über das Offenlegen privater Informationen als unsicherheitsbehaftet ansehen. Sie schlagen jedoch keinen formalen Weg vor, wie diese Unsicherheit Nutzungsentscheidungen beeinflusst oder wie sich individuelle Präferenzentwicklung auf das Entscheidungsverhalten auswirkt. Demnach sind diese Forschungsfelder in der verbal-konzeptionellen oder mathematischen Modellkategorie der Klassifizierung von Sun (2008) anzusiedeln. Der daraus resultierende Mangel an prozessbezogenen Spezifikationen und präzisen Vorhersagen dieser Modellkategorien (Murphy, 2011) könnte dazu beitragen, dass sich mehrere, teils widersprüchliche Erklärungen für das beobachtete Nutzungsverhalten gebildet haben. Gleichzeitig gibt es keinen Anlass, zu vermuten, dass sich der Entscheidungsprozess über spezifisch privatsphärenbezogene Inhalte von generellen unsicherheitsbehafteten Entscheidungsprozessen unterscheidet. Deshalb formalisiere ich in den folgenden Unterkapiteln nach der Vorstellung des Studiendesigns kognitive Modelle, die auf Basis verschiedener Grundannahmen unterschiedliche Vorhersagen über zu beobachtendes Nutzungsverhalten treffen.

4.2. Studiendesign und Stichprobe

Beide Studien wurden als Online-Studien auf der Umfrageplattform www.socisurvey.de realisiert. Alle Teilnehmenden gaben in Übereinstimmung mit der Deklaration von Helsinki schriftlich ihre Einverständniserklärung zur Teilnahme an der Studie sowie der Datenspeicherung und anonymisierten Veröffentlichung der Ergebnisse. Nach der Angabe demographischer Informationen wurden den Teilnehmenden Features, also Aspekte des Funktionsumfangs, von Smartphone-Apps vorgestellt. Die jeweils relevanten Features für Studie 1 beziehungsweise Studie 2 sind in Tabelle 3 beziehungsweise 4 aufgeführt.

Tabelle 3.

Beschreibung und Feature-Stufen der Stimuli in Studie 1.

Feature	Stufen	Beschreibung
Preis	0.00€ / 2.99€	Kaufpreis der App
Preisalarm	Ja / Nein	Benachrichtigung der App bei günstigen Buchungspreisen
Rezensionsstyp	Kund*innenbewertung / Expert*innenbewertung	Verfassende von Hotelrezensionen
Ortungsdaten	Zugriff / Kein Zugriff	Zugriffsberechtigung auf Ortungsdaten
Kalender	Zugriff/ Kein Zugriff	Zugriffsberechtigung auf Kalenderdaten
Rabatte	Ja / Nein	Preisnachlass bei Buchung über die App

Tabelle 4.

Beschreibung und Feature-Stufen der Stimuli in Studie 2.

Feature	Stufen	Beschreibung
Preis	0.00€ / 2.99€	Kaufpreis der App
Nutzendenbewertung	2.7 Sterne / 4.5 Sterne	Nutzendenbewertungen auf einer fünfstufigen Skala
Verschlüsselung	Ja / Nein	Ende-zu-Ende-Verschlüsselung von Nachrichten
Verfügbarkeit	Ja / Nein	Verfügbarkeit für eines oder mehrere gängige mobile Betriebssysteme
Kontaktdaten	Zugriff / Kein Zugriff	Zugriffsberechtigung auf Kontaktdaten
Telefonzugriff	Zugriff / Kein Zugriff	Zugriffsberechtigung auf den Telefonstatus und die Identität

Für jede Paarkombination an Features wurden die Teilnehmenden gebeten, die vier möglichen Kombinationen von An- und Abwesenheit der Features nach ihrer wahrgenommenen Begehrtheit aufzustellen. Ein Beispiel für diese Aufgabe ist in Abbildung 5 aufgeführt. Die vier Feature-Kombinationen auf der linken Seite der Online-Umfrage konnten über ein Eingabegerät oder per Berührungssteuerung auf die Rangfelder auf der rechten Seite bewegt werden. Die marginalisierte Anzahl der Situationen, in denen die Anwesenheit eines Features gegenüber seiner Abwesenheit bevorzugt wurde, ergab die Begehrtheitsquote des Features. Diese Quote je Feature wurde in eine Wahrscheinlichkeit umgerechnet und als Ausmaß der Präferenz bezüglich des Features interpretiert. Nachdem diese Feature-Präferenzen erhoben waren, wurden den Teilnehmenden mehrere fiktive Angebote für Smartphone-Apps gezeigt, die in ihrer visuellen Darstellung den App Stores mobiler Betriebssysteme nachempfunden waren. In der ersten Studie sahen Teilnehmende drei, in der zweiten

Studie zwei solche fiktiven Angebote. Abbildung 6 zeigt exemplarisch je einen Stimulus aus Studie 1 und 2. Die restlichen Stimuli sind in Anhang A zu finden.

soSci
oFb - der onlineFragebogen

15% ausgefüllt

Der hier abgebildete Vergleich bezieht sich auf die App-Features

Preis: Kosten, die entstehen, um die App installieren zu können.

Preisalarm: gibt Empfehlungen, ob man ein Hotel jetzt buchen oder noch warten sollte.

Bitte ordnen Sie die einzelnen Kombinationen an Features der Apps nach Ihrer persönlichen Einschätzung von „am besten“ (Rang 1) zu „am schlechtesten“ (Rang 4), wie Sie sie für Apps mit dem Zweck des Findens und Buchens von Hotels einschätzen würden.

Preis 2,99€, kein Preisalarm	Preis 2,99€ und Preisalarm	Preis 0,00€ und Preisalarm	1
			2
			3
			4

Abbildung 5. Aufgabe der Rangfolgenpositionierung zur Identifizierung von Feature-Präferenzen. Das dargestellte Beispiel wurde zur Präferenzermittlung in Studie 1 verwendet.

Die Art der Darbietung blieb zwischen beiden Studien unverändert. Jedoch wurde die Darstellung des Angebots, im Vergleich zur Darstellung in realen App Stores, absichtlich so angepasst, dass eine geringere Menge an Informationen als üblich dargestellt war. Dies diente der Einschränkung möglicher entscheidungsrelevanter Aspekte auf die jeweils 6 definierten Features, aus denen ein Stimulus bestehen konnte. Die Stimuli unterschieden sich in ihrer Verteilung vorhandener Features, repräsentierten aber alle Teilmengen der Feature-Auflistungen in Tabelle 3 beziehungsweise 4. Die Teilmengen an Features pro Stimulus sind in Tabelle 5 und 6 aufgeführt. Inhaltlich zeigten die Stimuli in Studie 1 Apps zum Buchen von Urlaubsreisen, während die Stimuli in Studie 2 Messenger-Apps zur Online-Kommunikation mit anderen Nutzenden zeigten. Teilnehmende entschieden sich bei jedem Stimulus für oder gegen eine Nutzung, also eine hypothetische Installation auf ihrem Smartphone, basierend auf ihrer Präferenz für die gezeigten Features. Dabei wurden sie angewiesen, die Stimuli als unabhängig zu betrachten, sodass die Wahl eines Stimulus die Wahl eines weiteren nicht beeinflussen sollte.

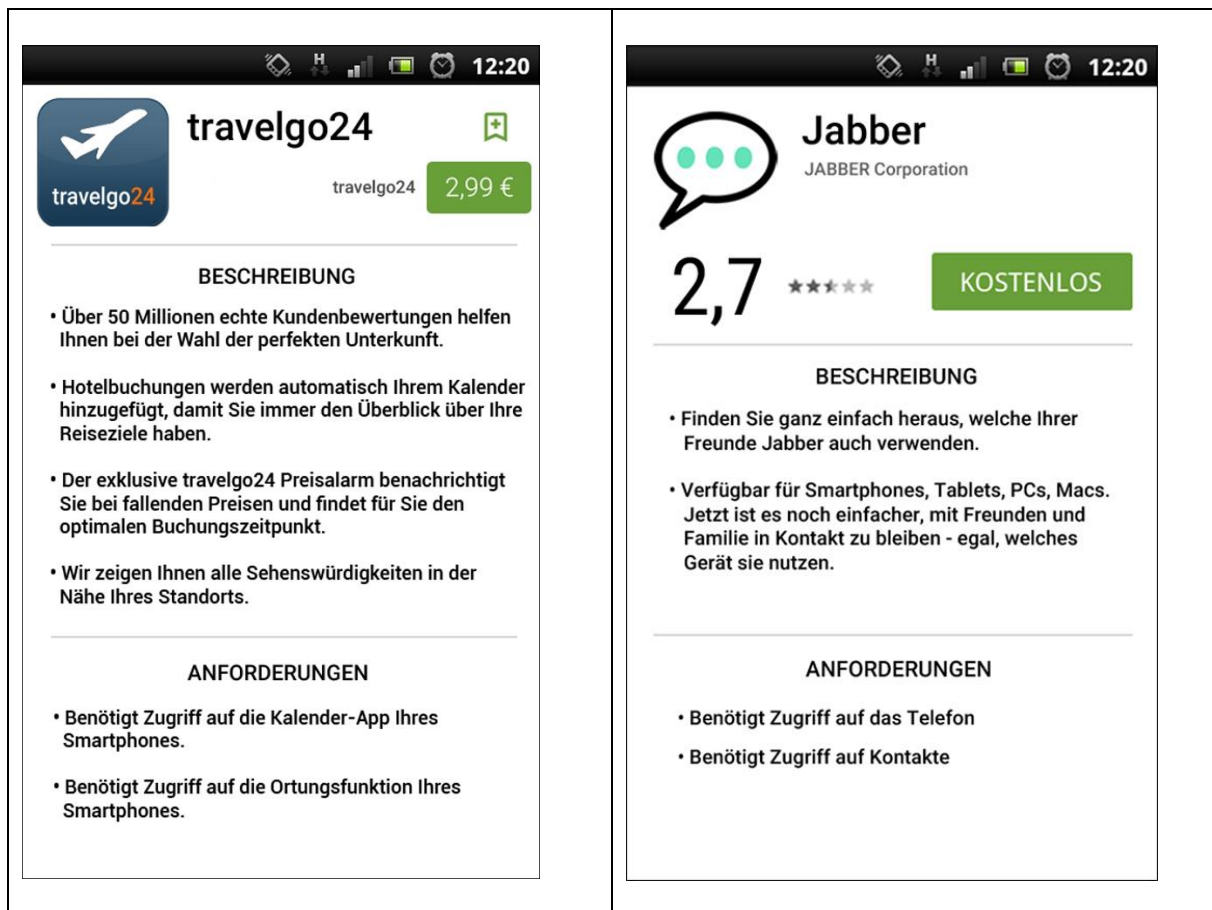


Abbildung 6. Beispiele der verwendeten Stimuli in Studie 1 und 2.

Tabelle 5.

Liste der Feature-Stufen für jeden Stimulus in Studie 1.

Stimulus	Features					
	Preis	Preisalarm	Rezensionstyp	Ortungsdaten	Kalender	Rabatte
App 1	2.99€	Ja	Expert*in	Zugriff	Kein Zugriff	Ja
App 2	0.00€	Nein	Kund*in	Zugriff	Zugriff	Ja
App 3	2.99€	Ja	Kund*in	Zugriff	Zugriff	Nein

Tabelle 6.

Liste der Feature-Stufen für jeden Stimulus in Studie 2.

Stimulus	Features					
	Preis	Nutzenden- bewertung	Verschlüsselung	Verfügbarkeit	Kontaktdaten	Telefon
App 1	0.00€	2.7	Nein	Ja	Zugriff	Zugriff
App 2	2.99€	4.5	Ja	Ja	Zugriff	Kein Zugriff

103 der insgesamt 115 Teilnehmenden (63% weiblich, Alter $M = 31.5$, $SD = 11.8$) schlossen die erste Online-Studie ab. Um diese Studie zu replizieren, wurden in einer zweiten Online-Studie 113 Teilnehmende rekrutiert, die die Studie alle abschlossen (46% weiblich, Alter $M = 29.8$, $SD = 5.7$). Hier wurde ein Teilnehmer von der Datenanalyse ausgeschlossen, weil sein Antwortmuster in zwei der vier im nächsten Unterkapitel vorgestellten kognitiven Modelle keine evaluierbaren Vorhersagen ergeben hätte. In beiden Studien gab es keine demographischen Einschluss- oder Ausschlusskriterien. Die Datenanalyse fand in Rstudio 1.0.153 (RStudio Team, 2015) und R 3.4.1 (R Core Team, 2017) statt. Zusätzlich wurden die Pakete *combinat* (Chasalow, 2012) und *poibin* (Hong, 2013b) verwendet.

4.3. Kognitive Modelle für Entscheidungen über Optionen mit mehreren Attributen

Ein großer Teil vorheriger Forschungsliteratur beschreibt privatsphärenbezogenes Nutzungsverhalten als begrenzt rational und heuristikbasiert (Kokolakis, 2017). Diese Perspektive scheint zunächst schwer vereinbar mit bayesianischer kognitiver Modellierung zu sein, die Entscheidungsverhalten auf komputationaler Ebene als subjektiv rationale Nützlichkeitsmaximierung beschreibt. Die als rationale Prozessmodelle (Lieder et al., 2017) zusammengefasste Modellfamilie ist durch ihre Umsetzung sampling-basierter bayesianischer Inferenz jedoch imstande, empirisch beobachtete Effekte zu rationalisieren, die ehemals ebenfalls als Konsequenz der Anwendung von Heuristiken verstanden wurden (Lieder et al., 2014; Sanborn & Chater, 2016; Vul et al., 2014). Das erste kognitive Modell, mit dem ich versuche, die Diskrepanz zwischen ausgedrückten Präferenzen und tatsächlichem Verhalten bei Online-Nutzenden zu erklären, ist demnach ein rationales Prozessmodell.

4.3.1. Rationales Prozessmodell (RPM)

Das RPM verbindet bayesianische Inferenz auf der komputationalen Ebene (Marr, 1982) mit den algorithmischen Anpassungen von Vul et al. (Vul et al., 2014) und nutzt die Theorie kontextsensitiven Präferenzlernens (Srivastava & Schrater, 2015) als Modell für die Entstehung der Präferenzen der Studienteilnehmenden. Damit folgt das Modell der Annahme, dass Präferenzen aus der Entscheidungshistorie abgeleitet werden, ohne dabei statische, optionsspezifische Nützlichkeiten zu repräsentieren (Srivastava & Vul, 2015). Ein dem RPM folgender Agent ermittelt die relative Begehrtheit einer Option als die Rate, mit der diese Option in einer Teilmenge bisheriger

Entscheidungssituationen vorgezogen wurde. Die stochastische Zusammenstellung dieser berücksichtigten Teilmenge an Entscheidungssituationen ist im RPM die hauptsächliche Erklärung für Verhalten, das von früheren ausgedrückten Präferenzen abweicht.

Wenn der Agent die vorhandenen Features eines App-Stimulus beobachtet und sich für oder gegen die Nutzung der App entscheiden soll, produziert er Samples der Begehrtheit der Features aus dem Gedächtnis. Die Begehrtheit des Features ist als Bernoulli-Versuch implementiert, sodass die Erfolgswahrscheinlichkeit die Rate widerspiegelt, mit der Optionen mit diesem Feature in der berücksichtigten Teilmenge vergangener Entscheidungssituationen gewählt wurden. Anders formuliert repräsentiert die Erfolgswahrscheinlichkeit die Intention, die App auf Basis des Vorhandenseins des Features zu nutzen. Die Gegenwahrscheinlichkeit wiederum beschreibt die Intention, die App auf Basis des Vorhandenseins des Features nicht zu nutzen. Als bayesianische Inferenz ausgedrückt sind die Entscheidungen zur Nutzung oder Nichtnutzung die Hypothesen, deren Posterior-Wahrscheinlichkeit nach Berücksichtigung der vorhandenen Features ermittelt werden soll. Erfolgswahrscheinlichkeit und Gegenwahrscheinlichkeit fungieren als Likelihoods zur Aktualisierung der beiden Hypothesen. Demnach liegen sie zwischen 0 und 1 und ergeben summiert 1.

Wenn der Agent die Begehrtheit eines App-Stimulus ermitteln möchte, beginnt er mit der Produktion von Samples der Begehrtheit der einzelnen Features. Eine Hauptkomponente des RPM ist die Formalisierung der Frage, wie viele Samples der Agent produzieren sollte. Der Agent verlässt sich auf zwei in Kapitel 1.3 beschriebene Indikatoren, um die Eindeutigkeit bisheriger Samples und somit den Bedarf für weitere Samples zu ermitteln: den erwarteten Wertunterschied (EVD_t) zwischen den Hypothesen zum Zeitpunkt t im Samplingprozess und die Schwankungsanfälligkeit (V_t) der Schätzung der Erfolgswahrscheinlichkeit. Dieses Verhalten fußt auf der Intuition, dass ein Bernoulli-Versuch über ein begehrenswertes Feature, also eines mit hoher Erfolgswahrscheinlichkeit, schnell und verlässlich Erfolge produziert. Ist die Begehrtheit eines Features jedoch unklarer, wechseln Samples häufiger zwischen Erfolgen und Misserfolgen und die geschätzte Erfolgswahrscheinlichkeit schwankt im Umfeld von 50%, statt deutlicher in die Extrembereiche der Prozentskala zu wandern. Je mehr Samples produziert werden, desto weniger Einfluss hat jedoch jedes einzelne Sample auf die geschätzte Erfolgswahrscheinlichkeit. Dieses Verhalten ist in Gleichung 4.1 formalisiert, die die Wahrscheinlichkeit des Agenten repräsentiert, die Produktion von Samples für das aktuelle Feature einzustellen:

$$p(stop) = \left(\frac{1}{T} \sum EVD_t\right) - V_t \quad (4.1)$$

Nach der Produktion eines Samples berechnet der Agent demnach den erwarteten Wertunterschied EVD_t und subtrahiert die Schwankungsanfälligkeit V_t . Mit der resultierenden Wahrscheinlichkeit führt der Agent einen weiteren Bernoulli-Versuch durch, bei dem ein Erfolg das Ende des Sampling-Vorgangs auslöst. Die Schätzung der Begehrtheit eines Features verfolgt der Agent über eine Beta-Verteilung, die allen möglichen Wahrscheinlichkeitswerten eine Wahrscheinlichkeitsdichte zuweist. Sie wird beschrieben durch die Parameter a und b . Der Agent startet einen Updating-Prozess mit einer Prior-Verteilung von $beta(a = 1, b = 1)$, was den Erwartungswert der Beta-Verteilung als Schätzer der Erfolgswahrscheinlichkeit auf 50% setzt (Kruschke, 2015). Dabei steigt der Parameter a jedes Mal um 1, wenn die Sampling-Prozedur einen Erfolg generiert, und der Parameter b , wenn ein Misserfolg

entsteht. Generiert der Agent beispielsweise ein erstes Sample der Begehrtheit eines Features, registriert einen Erfolg und beschließt dann über Gleichung 4.1, das Sampling zu beenden, aktualisiert er die Beta-Verteilung auf $beta(a = 2, b = 1)$ mit einem Erwartungswert von 67%. Sobald das Sampling beendet ist, errechnet der Agent die Wahrscheinlichkeit q gemäß Gleichung 1.2 aus Kapitel 1.3, wobei p für den Erwartungswert der aktuellen Betaverteilung und k für die Anzahl der produzierten Samples steht. Die Integration der geschätzten Begehrtheit aller Features über den Satz von Bayes resultiert in der Posterior-Begehrtheit des App-Stimulus. Dafür werden in Gleichung 1.1 die geschätzten Begehrtheitswerte für alle bei dieser App vorhandenen Features im Zähler multipliziert und im Nenner mit sich selbst und ihren Gegenwahrscheinlichkeiten normalisiert.

Der vorgeschlagene Sampling-Mechanismus des Agenten im RPM lässt einige Annahmen über sein Verhalten zu. Die probabilistische Regel zur Terminierung des Sampling-Prozesses in Gleichung 4.1 sorgt dafür, dass der Agent nur ein Sample wie von Vul et al. (2014) vorgeschlagen nutzen oder bei schwankungsanfälligen Präferenzen deutlich länger Samples produzieren kann. Wenn der Agent die Begehrtheit eines Features mit nur einem Sample beurteilt, approximiert er Angleichungsverhalten (Shanks et al., 2002). Die Produktion weiterer Samples lässt ihn hingegen mit höherer Wahrscheinlichkeit die beste Option wählen, während er bei einer theoretisch unbegrenzten Menge Samples deterministisch die beste Option wählt. Das RPM erzeugt als Ergebnis des Sampling-Prozesses für alle vorhandenen Features und der darauffolgenden Integration über den Satz von Bayes einen einzelnen Wahrscheinlichkeitswert für die hypothetische Nutzung der vorgestellten App. Tabelle 7 stellt die Funktionsweise des RPM in Pseudocode dar.

Tabelle 7.

Beschreibung des rationale Prozessmodells in Pseudocode.

Algorithmus 1 Sampling-Prozess zum Abruf von Präferenzen aus dem Gedächtnis.

```

1: For 1:N Teilnehmende
2:   For 1:M Features
3:     Initialisierung einer Betaverteilung mit  $beta(a = 1, b = 1)$ 
4:     Repeat
5:       Bernoulli-Versuch mit Erfolgswahrscheinlichkeit gleich der Feature-Präferenz  $m_n$ 
6:       Update der Betaverteilung
7:       Bestimmung von  $V$  und  $EVD$  zum Zeitschritt  $t$ 
8:       Bernoulli-Versuch zur Terminierung des Sampling-Prozesses mit
         Erfolgswahrscheinlichkeit gleich dem Ergebnis aus Gleichung 4.1
9:     Until Erfolg des Bernoulli-Versuchs zur Terminierung des Sampling-Prozesses

```

4.3.2. Bayesianisches Modell (detBayes)

Als erstes Alternativmodell führe ich einen rein auf komputationaler Ebene (Marr, 1982) agierenden bayesianischen Agenten an. Der Agent produziert keine Samples von Präferenzverteilungen. Stattdessen integriert er die von Studienteilnehmenden angegebenen Feature-Präferenzen direkt über den Satz von Bayes. Daraufhin wählt er deterministisch die Option mit der höheren Posterior-

Wahrscheinlichkeit. detBayes stellt den Sonderfall des RPM dar, in dem der Agent eine unendliche Anzahl Samples produziert. Bisherige Forschungsliteratur (Acquisti, 2004; Acquisti & Grossklags, 2005) unterstreicht die Annahme, dass der komputational bayesianische Agent das beobachtete Verhalten von Studienteilnehmenden nicht adäquat beschreiben dürfte. Auf verbal-theoretischem Niveau wurde die Überlegenheit anderer Entscheidungsregeln für die Domäne der Privatsphärenforschung hinreichend diskutiert (Acquisti, 2004). Dennoch wurde ein komplett bayesianischer Agent meines Wissens nach bisher nicht formal implementiert und empirisch evaluiert. Das bayesianische Modell produziert auf Basis der beiden Posterior-Wahrscheinlichkeiten eine binäre Vorhersage über die hypothetische Nutzung oder Ablehnung der vorgestellten App. Hierbei handelt es sich jedoch nicht um die Vorhersage, dass der Agent mit einer Wahrscheinlichkeit proportional zum Posterior agiert, sondern deterministisch. Das bedeutet, dass der Agent immer und ohne Ausnahme die Option wählt, die im Posterior eine höhere Wahrscheinlichkeit hat. Den Posterior als direkte Wahrscheinlichkeit der Wahl einer Option ohne die Anwendung bayesianischer Entscheidungstheorie (Peterson, 2009) zu interpretieren, würde detBayes zu einem Angleichungsmodell (Shanks et al., 2002) machen.

4.3.3. Take-the-best-Heuristik (detTTB)

Das zweite berücksichtigte Alternativmodell formalisiert die Take-the-best-Heuristik als Entscheidungsregel (Gigerenzer, 2008; Graefe & Armstrong, 2012). Es unterscheidet sich von den zwei vorherigen Modellen dadurch, dass ein der Heuristik folgender Agent seine Entscheidung nicht aufgrund aller verfügbaren Informationen, sondern auf Basis eines einzelnen Aspekts trifft. Der Agent geht die in den App-Stimuli enthaltenen Features geordnet nach ihrer Validität durch. Sobald er ein Feature findet, das zwischen den Optionen differenziert, wählt er deterministisch die Option, die ein begehrtes Feature beinhaltet oder der ein unbegehrtes Feature fehlt. Für einen unveränderten Vektor an Präferenzen und einen unveränderten App-Stimulus sollte der Agent also immer identisches Verhalten zeigen. Die Validität, nach der die Features gereiht werden, leitet sich aus der absoluten Differenz der Präferenz von 50% ab. Besitzt der Agent also eine Präferenz von 95% für Feature 1 und eine Präferenz von 4% für Feature 2, sollte er Feature 2 vor Feature 1 auf Diskriminierung zwischen den Optionen prüfen. Ähnlich wie detBayes produziert detTTB eine binäre Vorhersage basierend auf dem ersten diskriminierenden Feature, das der Agent betrachtet.

4.3.4. Probabilistische Take-the-best-Heuristik (probTTB)

Während detTTB einer anderen Entscheidungsregel als RPM und detBayes folgt, hat es mit letzterem zumindest eine Gemeinsamkeit: es verhält sich deterministisch. Deshalb bietet sich als drittes Alternativmodell eine probabilistische Implementierung der Take-the-best-Heuristik an, die ich von Bergert und Nosofsky (2007) übernehme. In diesem Modell wird die Reihenfolge der Feature-Berücksichtigung nicht deterministisch von der Feature-Validität vorgegeben. Stattdessen werden zu berücksichtigende Features aus einer Verteilung gezogen, wobei die Wahrscheinlichkeit des Ziehens eines Features proportional zu seiner relativen Validität ist. Innerhalb einer Feature-Reihenfolge ist die Wahl einer Option mit höherem Präferenzwert für ein diskriminierendes Feature jedoch weiterhin deterministisch. Tabelle 8 beschreibt die Funktionsweise des probTTB-Modells in Pseudocode.

Tabelle 8.

Beschreibung des probTTB in Pseudocode.

Algorithmus 2 Entscheidungsprozess für die Probabilistische Take-the-best-Heuristik.

- 1: **For 1:N Teilnehmende**
 - 2: Bestimmung von Feature-Gewichten aufgrund ihrer Präferenzen
 - 3: **Repeat**
 - 4: Sampling eines Features mit Erfolgswahrscheinlichkeit entsprechend seines Gewichts
 - 5: Prüfung der Diskriminierungsfähigkeit des gesampten Features
 - 6: **Until** Feature kann zwischen Optionen diskriminieren
 - 7: Option mit höherem Präferenzwert für diskriminierendes Feature wählen
-

4.3.5. Begründung der Auswahl von Alternativmodellen

Die Take-the-best-Heuristik wurde als Grundlage zweier Alternativmodelle einbezogen, da sie ähnlich wie die bayesianischen Modelle RPM und detBayes in deterministischer (detTTB) und probabilistischer Variante (probTTB) existiert. So unterscheiden sich die vier Modelle auf zwei Dimensionen: der Anzahl der entscheidungsrelevanten Aspekte und der Art ihrer Entscheidungsregel. In der Literatur zu Privatsphärenforschung ist es zudem üblich, bayesianische und heuristische Ansätze zumindest verbaltheoretisch gegenüberzustellen und dabei auf psychologische Entscheidungsforschung zu verweisen (Acquisti, 2004). Jedoch wurde bislang meines Wissens nach keine Formalisierung beider Ansätze unternommen, was dazu führt, dass ohne weitere Spezifikationen auf der algorithmischen Ebene von deterministischem Verhalten des modellierten Agenten ausgegangen werden muss. Dieser Aspekt dürfte weder von Fürsprechern noch Gegnern bayesianisch motivierter Entscheidungstheorie in der Privatsphärenforschung als realistisch betrachtet werden. Die Aufnahme der deterministischen Alternativmodelle dient in dieser Arbeit dem Zweck, die Konsequenzen eines Mangels an algorithmischer Spezifikation aufzuzeigen. Im weiteren Kontext bayesianischer kognitiver Modelle unterstreicht die Strenge der deterministischen Entscheidungsregeln ebenso die Notwendigkeit, Modellverhalten auf der algorithmischen Ebene zu spezifizieren.

4.4. Ergebnisse

Zur Darstellung der Ergebnisse der Studien stelle ich zunächst den Modellvergleich vor, beschreibe dann deskriptiv die Verteilungen beobachteter Feature-Präferenzen und betrachte zuletzt das Verhalten des sampling-basierten Agenten im RPM genauer.

4.4.1. Modellvergleich

Die Möglichkeiten zur Evaluation kognitiver Modelle wurden in Kapitel 2 vorgestellt. Um die Modellvorhersagen untereinander zu vergleichen, bietet sich hier der Bayes Factor an. Jedes Modell produziert eine Erfolgswahrscheinlichkeit pro Studienteilnehmenden und Stimulus, die als Wahrscheinlichkeit der hypothetischen Nutzung der dargestellten App zu sehen ist. Da diese Erfolgswahrscheinlichkeit zwischen Studienteilnehmenden und Stimuli schwanken darf, wird die Wahrscheinlichkeit der empirisch beobachteten Entscheidungen zur Nutzung der Apps durch die Poisson-Binomial-Verteilung (Hong, 2013a) beschrieben. Dadurch erhalten die Vorhersagen von RPM

und probTTB eine visuell glockenförmige Verteilung über die möglichen Verhältnisse von Nutzungs- und Nichtnutzungsentscheidungen. Die deterministischen Modelle konnten aufgrund ihrer Funktionsweise hingegen nur eine Erfolgswahrscheinlichkeit von 0% oder 100% vorhersagen, was dazu führt, dass die gesamte Wahrscheinlichkeitsmasse ihrer Vorhersagen auf exakt einem Verhältnis von Nutzungs- und Nichtnutzungsentscheidungen liegt. Demnach schrieben die deterministischen Modelle allen anderen möglichen Entscheidungsverhältnissen eine Wahrscheinlichkeitsmasse von 0 zu. Diese Problematik war in einem Fall nicht nur auf die deterministischen Modelle beschränkt. Für den ersten Stimulus der zweiten Studie lag die Vorhersage von probTTB so weit von der empirischen Beobachtung entfernt, dass es dem beobachteten Verhältnis ebenfalls eine Wahrscheinlichkeitsmasse von 0 zuschrieb. Einen Bayes Factor zu berechnen, wenn die Modell-Likelihood eines der beteiligten Modelle gleich 0 ist, könnte aufgrund der arithmetisch undefinierten Division durch 0 auf Kritik stoßen. Da der Bayes Factor für die relative Vorhersagequalität der Modelle genutzt wird und ein Modell mit einer Likelihood von 0 einem Modell mit einer Likelihood von mehr als 0 unterlegen ist, verfare ich hier nach den implementierten Berechnungsregeln in R und behandle das Ergebnis als positiv unendlich. Somit wird ein solcher Bayes Factor zugunsten des Modells mit Likelihood über 0 ausgelegt.

Die Abbildungen 7 bis 11 zeigen eine grafische Übersicht der Vorhersagen aller Modelle sowie des empirisch beobachteten Entscheidungsverhältnisses für jeden Stimulus. Auf der x-Achse ist dabei die Anzahl an Entscheidungen für die Nutzung einer App abgetragen. Die y-Achse zeigt die Wahrscheinlichkeitsdichte für diese Anzahl an Entscheidungen unter Annahme einzelner Modelle. Die empirisch beobachteten Nutzungsentscheidungen sind als schwarze vertikale Linie in den Abbildungen eingetragen. Dabei fällt mit Ausnahme von Abbildung 11 auf, dass alle Modelle die Anzahl an Nutzungsentscheidungen überschätzt haben. Je höher die Wahrscheinlichkeitsmasse der jeweiligen Modelle an diesen Punkten ist, desto genauer ist deren Vorhersage. Für die numerische Interpretation der Bayes Factors übernehme ich die konventionelle Interpretation von Jeffreys (1998), die in Kapitel 2 eingeführt wurde. Wie in Abbildung 11 zu sehen ist, hat detTTB mit seiner Vorhersage für das Nutzungsverhalten der zweiten App der zweiten Studie das exakte empirisch beobachtete Verhältnis getroffen. In allen anderen Modellvergleichen schreiben die deterministischen Modelle der empirischen Beobachtung eine Wahrscheinlichkeitsmasse von 0 zu und die Vergleiche bevorzugen daher die probabilistischen Modelle, unabhängig von ihrer eigentlichen Distanz zur empirischen Beobachtung. Für die besagte zweite App der zweiten Studie resultiert ein Vergleich des RPM mit dem detTTB in einem Bayes Factor von 0.09, während der Vergleich zwischen probTTB und detTTB einen Bayes Factor von 0.05 ergibt. Beide Fälle legen eine bessere Vorhersage des detTTB nahe. Alle anderen Vergleiche zwischen einem probabilistischen und einem deterministischen Modell bevorzugen das probabilistische Modell mit einem positiv unendlichen Bayes Factor. Die Vergleiche zwischen RPM und probTTB für alle App-Stimuli sind mit ihrer zugehörigen Interpretation in Tabelle 9 zu finden. Zusätzlich zum Modellvergleich über Bayes Factors zeigt Tabelle 10 die Rate korrekter Klassifizierungen für die deterministischen Modelle. Über alle Stimuli gemittelt liegt die Rate korrekter Klassifizierungen, also von Treffern und korrekten Ablehnungen, bei 62.85% für detTTB und 66.86% für detBayes. Da die probabilistischen Modelle keine Klassifizierungen im üblichen Sinne treffen, sondern proportional zu ihren Wahrscheinlichkeiten beide Entscheidungsoptionen pro Studienteilnehmenden zulassen, können ihre Vorhersagen nicht entsprechend des Klassifikationssystems in Tabelle 10 interpretiert werden.




Abbildung 7. Modellvorhersagen und empirische Beobachtung der Anzahl an Nutzungsentscheidungen für den ersten Stimulus aus Studie 1.




Abbildung 8. Modellvorhersagen und empirische Beobachtung der Anzahl an Nutzungsentscheidungen für den zweiten Stimulus aus Studie 1.




Abbildung 9. Modellvorhersagen und empirische Beobachtung der Anzahl an Nutzungsentscheidungen für den dritten Stimulus aus Studie 1.




Abbildung 10. Modellvorhersagen und empirische Beobachtung der Anzahl an Nutzungsentscheidungen für den ersten Stimulus aus Studie 2.




Abbildung 11. Modellvorhersagen und empirische Beobachtung der Anzahl an Nutzungsentscheidungen für den zweiten Stimulus aus Studie 2.

Tabelle 9.

Bayes Factors für den Modellvergleich zwischen RPM und probTTB für alle Stimuli. Die Bayes Factors nutzen die marginale Likelihood des RPM im Zähler.

Stimulus	Bayes Factor	Evidenzniveau
Studie 1, App 1	0.43	Keine gerichtete Evidenz
Studie 1, App 2	354153.40	Extreme Evidenz für RPM
Studie 1, App 3	51809.12	Extreme Evidenz für RPM
Studie 2, App 1	$+\infty$	Extreme Evidenz für RPM
Studie 2, App 2	1.87	Anekdotische Evidenz für RPM

Tabelle 10.

Klassifikationsergebnisse der Modelle detBayes und detTTB aggregiert über alle Stimuli (in Prozent, gerundet auf ganze Zahlen).

Modell	Treffer	Verpasser	Falsche Alarme	Korrekte Ablehnungen
detBayes	32%	6%	27%	35%
detTTB	26%	12%	25%	37%

4.4.2. Verteilungen der Feature-Präferenzen

Die Tabellen 11 und 12 zeigen deskriptive Daten bezüglich der Ausprägung und Schwankung der Feature-Präferenzen, die zur Vorhersage des Verhaltens von Studienteilnehmenden genutzt wurden. In Studie 1 zeigten Features, die monetäre Vorteile beinhalteten (Kaufpreis, Preisalarm und Preisersparnis), die niedrigste Variabilität in der Beurteilung ihrer Begehrtheit und wurden generell den übrigen Features gegenüber vorgezogen. Im Gegenzug dazu wurden Features, die nicht mit monetären Vorteilen assoziiert waren, deutlich variabler beurteilt. In Studie 2 waren die vorhandenen Features nicht so deutlich in Features mit und ohne monetäre Vorteile einzuordnen. Die Variabilität der Beurteilungen von Features mit Bezug zu Datenfreigabe (Zugriff auf das Kontakteverzeichnis und den Telefonstatus) ähnelte jedoch der von Features mit Datenfreigabebezug in Studie 1.

Tabelle 11.

Durchschnittliche Feature-Präferenzen (Standardabweichung in Klammern) als Ergebnis der Rangfolgenpositionierung für Studie 1 (in Prozent, gerundet auf ganze Zahlen).

Feature	Referenzierte Stufe	Präferenzwerte
Preis	0.00€	85% (17%)
Preisalarm	Ja	81% (19%)
Rezensionstyp	Kund*innenbewertung	52% (31%)
Ortungsdaten	Zugriff	43% (36%)
Kalender	Zugriff	44% (37%)
Rabatte	Ja	90% (11%)

Tabelle 12.

Durchschnittliche Feature-Präferenzen (Standardabweichung in Klammern) als Ergebnis der Rangfolgenpositionierung für Studie 2 (in Prozent, gerundet auf ganze Zahlen).

Feature	Referenzierte Stufe	Präferenzwerte
Preis	0.00€	87% (10%)
Nutzendenbewertung	4.5 Sterne	83% (22%)
Verschlüsselung	Ja	84% (15%)
Verfügbarkeit	Ja	80% (13%)
Kontaktdaten	Zugriff	28% (30%)
Telefon	Zugriff	23% (27%)

4.4.3. Probabilistische Regel zur Terminierung des Samplings

In Bezug auf vorherige Forschung zur Approximation bayesianischer Inferenz durch Sampling (Srivastava et al., 2016; Vul et al., 2014) habe ich das Verhalten des sampling-basierten Agenten im RPM untersucht. Die Verteilung der von der probabilistischen Terminierungsregel produzierten Anzahl an Samples ist in Abbildung 12 zu finden. Es wurden am häufigsten zwei Samples produziert, bevor die Regel zur Terminierung des Sampling-Prozesses ausgelöst wurde. Insgesamt machten Durchgänge mit fünf oder weniger Samples für 78.85% der durchgeführten Sampling-Prozesse aus.

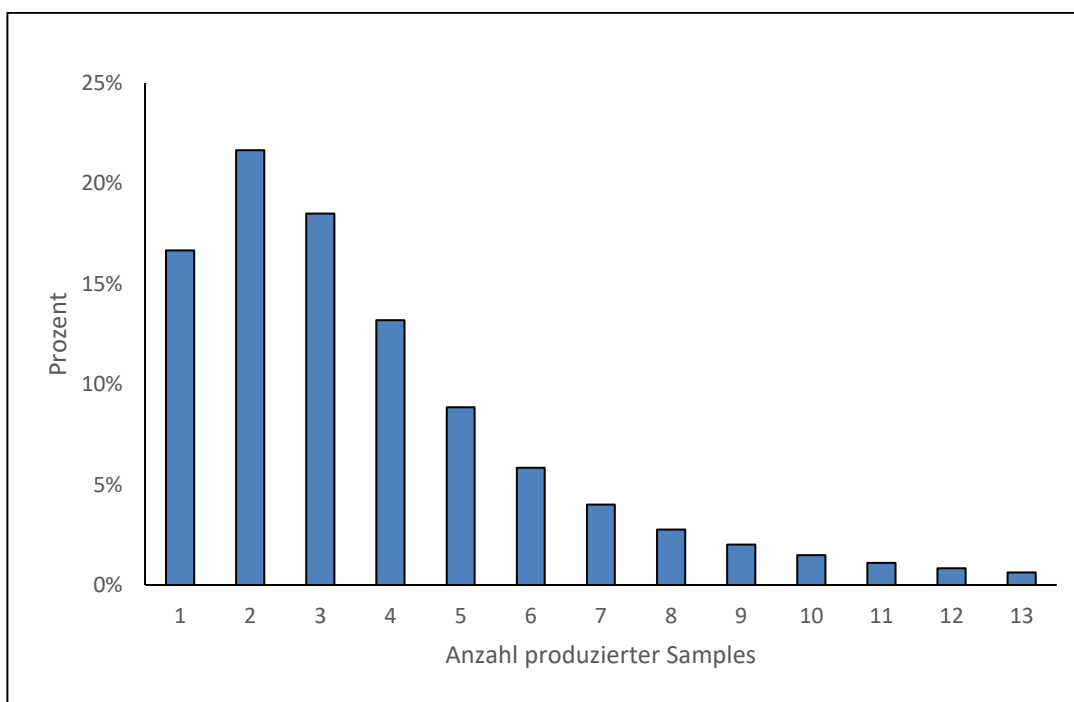


Abbildung 12. Verteilung der durchschnittlichen Anzahl produzierter Samples (in Prozent).

4.5. Diskussion

In Kapitel 4 dieser Arbeit wurde auf Basis der Sampling-Hypothese (Sanborn & Chater, 2016; Vul et al., 2014) und der Theorie kontextsensitiven Präferenzlernens (Srivastava & Schrater, 2015; Srivastava & Vul, 2015) ein rationales Prozessmodell (RPM) zur Vorhersage der Wahl zur Nutzung von Smartphone-Apps vorgestellt. Der Modellvergleich mit im Kontext der Forschungsliteratur zu Online-Privatsphäre angemessenen Alternativmodellen zeigt, dass das RPM zu besseren Vorhersagen als ein rein komputational bayesianes Modell (detBayes) führt. Dessen deterministische Vorhersage schrieb allen empirisch beobachteten Entscheidungsverhältnissen eine Wahrscheinlichkeitsdichte von 0 zu, was im Vergleich mit dem RPM zu einem unendlich positiven Bayes Factor zugunsten des RPM führte. Dasselbe gilt für die Relation zwischen probTTB und detBayes. Gleichzeitig übertrifft das RPM mit einer Ausnahme auch die Performanz des heuristischen deterministischen Modells detTTB. Verglichen mit der probabilistischen Version der Take-the-best-Heuristik (probTTB) zeigten die Bayes Factors in drei Fällen eine extreme Überlegenheit des RPM, eine anekdotische Überlegenheit des RPM in einem und keine Überlegenheit in jedweder Richtung in ebenfalls einem Fall. Die Diskussion dieser Ergebnisse befasst sich zunächst mit dem Modellverhalten und den Modellvorhersagen. Daraufhin stelle ich die Vorteile heraus, die formale kognitive Modellierung für die Forschung zur Online-Privatsphäre bietet. Zuletzt diskutiere ich die Einschränkungen des Studiendesigns hinsichtlich der Verallgemeinerbarkeit der Ergebnisse.

4.5.1. Konzeptioneller und empirischer Modellvergleich

Die gleichzeitige Berücksichtigung der komputationalen und algorithmischen Ebene in der Beschreibung kognitiver Systeme durch vorangegangene Forschung (Griffiths et al., 2015) hat dazu geführt, dass bayesianische kognitive Modellierung diverse Hürden hinsichtlich ihrer psychologischen Plausibilität und komputationalen Komplexität überwinden konnte. Bisherige Forschungsliteratur hat die notwendigen komputationalen Spezifikationen herausgestellt, die notwendig waren, um rationale Prozessmodelle zu implementieren (Srivastava et al., 2016; Srivastava & Schrater, 2014; Vul et al., 2014) und ihre Vorhersagen mit empirischer Datenlage verglichen (Bonawitz et al., 2014; Sanborn et al., 2010). Dieses Kapitel hat rationale Prozessmodellierung auf Entscheidungsverhalten im Kontext der Nutzung von Online-Services angewandt. Entscheidungsverhalten in dieser Domäne war traditionell als begrenzt rational und heuristikbasiert beschrieben worden (Acquisti, 2004; Kokolakis, 2017). Die namensgebende Begrenzung dieser Rationalitätsdefinition lässt sich vereinfacht so zusammenfassen, dass Menschen unter den kognitiven Einschränkungen, denen sie unterliegen, ihr Bestmögliches leisten. Ob man sich dieser Interpretation oder dem Konzept globaler Rationalität anschließt, das lokal irrationales Verhalten als natürliche Konsequenz von Sampling versteht, dürfte in Bezug auf beobachtetes Verhalten eine Unterscheidung ohne Unterschied sein. In beiden Fällen produzieren Menschen variables, inkonsequentes und scheinbar irrationales Verhalten. Im Versuch, dieses Verhalten zu reproduzieren, baute der Sampling-Prozess im RPM auf einer probabilistischen Regel zur Terminierung des Samplings auf. Diese produzierte durchschnittlich vier Samples und ließ den modellierten Agenten so eine Tendenz zu Angleichungsverhalten zeigen. Sowohl die niedrige Anzahl an Samples als auch die Flexibilität, zwischen Angleichungs- und Maximierungsverhalten zu variieren, stimmen mit bisherigen Forschungsergebnissen überein (Srivastava & Vul, 2015; Vul et al., 2014). Das RPM nutzte individuelle Feature-Präferenzen, die durch eine Aufgabe zur Sortierung von Feature-Kombinationen zu Rangfolgen ermittelt wurden. Diese Sortierungsaufgabe legte eine vergleichsweise höhere Präzision in der Präferenz von Features offen, die mit monetären Vorteilen in

Verbindung standen (vgl. Tabelle 11 und 12). Gleichzeitig wurden potenziell invasive Funktionalitäten wie der Zugriff auf Ortungs- oder Kalenderdaten zwar weniger, aber auch variabler bewertet.

RPM und detBayes wurden als Vertreter eines rationalen Ansatzes der Entscheidungsforschung ausgewählt, weil sie alle verfügbaren Informationen in ihre Entscheidungsfindung einbeziehen. detTTB und probTTB sind traditionell mit dem Konzept begrenzter Rationalität assoziiert. Die Take-the-best-Heuristik repräsentiert dabei die Entscheidungsfindung auf Basis einzelner Informationen (Gigerenzer & Todd, 2001). Das bewusste Ignorieren eines Großteils verfügbarer Informationen wird hier implementiert, um einer Überbeanspruchung kognitiver Ressourcen vorzubeugen und sich an Umwelten anzupassen, in denen ein einzelner Aspekt die Qualität einer Entscheidung hinreichend vorhersagt. Trotz seines unterschiedlichen Mechanismus in der Entscheidungsfindung zeigte das detTTB eine ähnliche Rate korrekter Klassifizierungen wie detBayes. Durch ihre Entscheidungsregeln war unwahrscheinlich, dass die deterministischen Modelle in der Evaluation über Bayes Factors gegenüber den probabilistischen Modellen bevorzugt würden, denn dafür hätten sie das Präzise Verhältnis an Nutzungsentscheidungen treffen müssen. Obwohl detTTB gerade diese Treffsicherheit für die zweite App der zweiten Studie gezeigt hat, ist dieses Ergebnis eher dem Zufall zuzuschreiben, statt als Indiz für die Angemessenheit seiner Entscheidungsregel gesehen zu werden.

Im Vergleich der beiden probabilistischen Modelle zeigt sich eine extreme Unterstützung des RPM durch die Datenlage in drei von fünf Fällen, während die restlichen zwei Vergleiche keine beziehungsweise schwache Evidenz für die Überlegenheit des RPM liefern. Während die Ursache der letzteren zwei Ergebnisse unklar ist, weist eine Inspektion der Abbildungen 7 bis 11 auf einen wichtigen Aspekt des Modellvergleichs hin: dass ein Modell das beste in der Teilmenge betrachteter Modelle ist, bedeutet nicht, dass es ein hinreichend gutes Modell des betrachteten Verhaltens ist. Die Evidenz für die Überlegenheit eines Modells in einem Vergleich mittels Bayes Factors kann ausschließlich in Relation zum betrachteten Alternativmodell beurteilt werden. Während die Datenlage mehr Evidenz für das RPM als das probTTB zeigte, haben alle berücksichtigten Modelle die empirisch beobachtete Nutzungsbereitschaft überschätzt, mit der Ausnahme der zweiten App in Studie 2.

Das Verhalten des probTTB war unter speziellen Bedingungen auffällig, denn in Abhängigkeit spezieller individueller Präferenzverteilungen und verfügbaren Features war es für das probTTB möglich, eine Wahrscheinlichkeit von 100% in Richtung einer Option als Antwort zu produzieren. In schätzungsweise 11.6% der modellierten Entscheidungen prognostizierte das probTTB die Wahl einer Option mit hundertprozentiger Sicherheit. In dieser Teilmenge lag es in 37% falsch. Für diese Fälle war eine Abweichung von der Modellvorhersage nicht durch erwartetes stochastisches Verhalten erklärbar, weil alle möglichen Sequenzen der Berücksichtigung von Features in der Wahl einer spezifischen Option hätten enden müssen. Auch wenn das Modell diese Fälle über alle Studienteilnehmenden hinweg kompensieren konnte, ist ihre Existenz konzeptionell schwierig zu rechtfertigen. Das RPM, das die Integration mehrerer sampling-basierter Präferenzen über den Satz von Bayes vorsieht, produziert selbst für extreme Präferenzkombinationen eine Wahrscheinlichkeit für die Wahl einer Option über 0% und unter 100%. Dieser Nachteil für das probTTB entsteht aus der Annahme, dass es deterministisch die Option wählt, die nach einer probabilistisch festgelegten Betrachtungssequenz als erste positiv bewertet ist. Deterministisches Verhalten nach dem Auffinden eines zwischen den Optionen diskriminierenden Features scheint die etablierte Entscheidungsregel für Take-the-best-Modelle zu sein, unabhängig davon, ob ihre Betrachtungssequenzen deterministisch (Gigerenzer & Todd, 2001) oder probabilistisch (Bergert & Nosofsky, 2007) sind. Zusammengefasst haben beide probabilistischen Modelle ihre deterministischen Varianten im Modellvergleich übertroffen und die

Prognosequalität des RPM übertrifft die des probTTB in der Mehrheit aller betrachteten Fälle. Eine grafische Betrachtung der Modellprognosen durch die Abbildungen 7 bis 11 zeigt jedoch, dass alle Modelle zu einer Überschätzung des Verhältnisses zwischen Nutzungs- und Nichtnutzungsentscheidungen neigten.

4.5.2. Integration probabilistischer kognitiver Modellierung mit Forschung zum Nutzungsverhalten in Bezug auf Online-Privatsphäre

Das RPM bietet durch seine probabilistischen Komponenten die Möglichkeit der Rationalisierung von Verhaltensweisen, die maßgeblich zum Bild von irrationalen, den eigenen Präferenzen widersprechenden Nutzenden beigetragen haben. Dabei unterscheidet es sich von bisherigen Ausrichtungen in der Privatsphärenforschung, die auf einer Abwägung zwischen Vorteilen und Risiken basieren (Dinev & Hart, 2006; Kehr, Kowatsch, Wentzel, & Fleisch, 2015; Kehr et al., 2014) und dabei explizit oder implizit von rationalen Grundtendenzen ausgehen. Der Privatsphären-Calculus bedient sich dabei üblicherweise statistischer Datenanalyse statt kognitiver Modellierung. Jones (2016) beschreibt den Unterschied zwischen beiden Ausrichtungen als den Versuch letzterer, den Verstand zu verstehen. Parameter in kognitiven Modellen reflektieren seiner Aussage nach hypothetische kognitive Prozesse oder Repräsentationen wie Aufmerksamkeit, Erinnerungsvermögen oder Entscheidungsschwellen im Gegensatz zu den abstrakten Parametern eines Regressionsmodells. Die Nutzung datenanalytischer Methoden zur Schätzung des Einflussgewichts des wahrgenommenen Vorteils der Nutzung eines Online-Dienstes lässt den Privatsphären-Calculus zwar kognitiver Modellierung ähneln, hält ihn aber weiterhin abstrakt. So ermöglicht er zwar eine statistische Vorhersage von Verhalten, bringt aber keine prozessbezogene Erklärung des Verhaltens mit sich.

Ausrichtungen der Privatsphärenforschung, die privatsphärenbezogenes Verhalten als begrenzt rational beschreiben, stehen oft in einem theoretischen Bezug zur Prospect-Theorie (Kahneman & Tversky, 1979). Sie beschreibt menschliche Wahrscheinlichkeitsgewichtung als verzerrt, was insbesondere für den bayesianischen Ansatz mit seiner Nähe zur Wahrscheinlichkeitstheorie problematisch ist. Ihr fehlt jedoch eine formale Perspektive der Ursachen dieser Verzerrungen, sodass sie letzten Endes eine Beschreibung beobachteter Phänomene ohne Theorie zu ihrer Entstehung bleibt. Im Gegenteil dazu bietet rationale Prozessmodellierung und ihr theoretisches Fundament eine psychologische und ressourcenbezogene Erklärung dieser Phänomene, die beispielsweise die Ankerheuristik (Lieder et al., 2017) oder subjektive Wahrscheinlichkeitsverzerrungen (Srivastava & Vul, 2017b) komputational erklären können. In Fällen, in denen heuristische Entscheidungsfindung als Erklärung für die Nutzung von Online-Diensten und die Preisgabe privater Informationen herangezogen wurde, wurde sie meines Wissens nach nicht als formales kognitives Modell implementiert. Daraus folgt ein Mangel an präzisen, falsifizierbaren Vorhersagen über Verhalten, das durch die Verwendung von Heuristiken erklärt werden kann. Als Beispiel der theoretischen Einsicht, die durch formale Modellierung generiert werden kann, zeigen die in diesem Kapitel durchgeführten Studien, dass weder die deterministische Take-the-best-Heuristik noch ein rein komputationaler bayesianischer Ansatz für die Vorhersage von Entscheidungsverhalten über die Nutzung von Online-Diensten geeignet ist. Auch wenn beide Ansätze in der Privatsphärenforschung als gegensätzliche Theorien zur Erklärung von Nutzungsverhalten angeführt wurden, sind sie mit Hinblick auf die Variabilität des zu modellierenden Verhaltens unterspezifiziert. Um den eigenen Präferenzen

scheinbar widersprechendes Verhalten erklären oder vorhersagen zu können, ist daher mehr als ein rein deskriptiver Ansatz vonnöten.

4.5.3. Einschränkungen

Die vorgestellten Studien wurden in Form von Online-Umfragen durchgeführt. Die Ergebnisse der ersten Studie wurden mit einer zweiten Stichprobe repliziert und über Kategoriegrenzen von Smartphone-Apps hinweg generalisiert. Dennoch stellt die Beschränkung auf die hypothetische Nutzung fiktiver Apps insbesondere deshalb eine klare Einschränkung der Studien dar, weil vorherige Privatsphärenforschung eine Diskrepanz zwischen Verhaltensintentionen und echtem Verhalten als mögliche Ursache für das Privatsphären-Paradox identifiziert hat (Norberg et al., 2007). Der hypothetische Charakter des Studiendesigns könnte erklären, warum alle berücksichtigten Modelle die Anzahl an Nutzungsentscheidungen überschätzt haben. Diese Diskrepanz könnte einem Mangel intrinsischen Verlangens nach Apps der gezeigten Kategorien zugeschrieben werden. Generell entschieden sich wenige Studienteilnehmende, die Apps zu nutzen, wie in Abbildungen 7 bis 11 ersichtlich. Jedoch wären die Entwicklung und Einführung einer realen App für ein existierendes mobiles Betriebssystem mit Hinblick auf die Menge an dargebotenen Informationen nicht kontrollierbar gewesen. Die hier präsentierten Studien stellen einen Kompromiss zwischen dem Realismus der Entscheidungssituation und der Kontrolle der Darbietung ausgewählter Features dar. Durch die Kontrolle der Darbietung wurde jedoch die Sortierungsmethode der Feature-Kombinationen zu Beginn der Studiendurchführung ermöglicht. Unter der Annahme, dass Studienteilnehmende bei der Entscheidung für oder gegen die Nutzung einer App Samples aus ihrer Entscheidungshistorie produzieren, stand hinter der Sortierungsmethode die Idee, ihnen möglichst viele Entscheidungen abzugewinnen. Die resultierenden Präferenzverteilungen sind für die dargebotene Auswahl an Features zwar hilfreich, sind aber nicht statisch und können nicht auf andere Teilmengen möglicher Features übertragen werden. Dies ist auf der einen Seite ein Nachteil der Methodik, ergibt sich auf der anderen Seite aber auch aus der Theorie kontextsensitiven Präferenzlernens (Srivastava & Vul, 2015). Eine weitere Einschränkung des Studiendesigns äußert sich in der mangelnden Interpretierbarkeit der probabilistischen Modellprognosen für individuelle Studienteilnehmende. Durch die Auffassung des gezeigten Entscheidungsverhaltens als Ergebnis eines sampling-basierten Bernoulli-Versuchs beziehungsweise als Ergebnis einer spezifischen Betrachtungssequenz im heuristischen Fall verlieren einzelne Datenpunkte ihre Interpretierbarkeit. Vul et al. (2014) basieren ihre Annahmen über die Relevanz der Sampling-Hypothese auf der Beobachtung, dass Menschen im Durchschnitt optimal und in einzelnen Situationen lokal suboptimal agieren. Die Vorhersage des RPM empirisch prüfen zu können bedarf deshalb entweder vieler Datenpunkte einzelner Studienteilnehmender oder der Aggregation weniger Datenpunkte je Studienteilnehmenden. Die Stimuli der vorgestellten Studien können jedoch nur in gewissem Ausmaß variiert werden, bevor entweder Duplikate vorheriger Stimuli entstehen oder die Teilmenge betrachteter Features erweitert werden müsste. Die Implikationen des RPM in einer Domäne zu überprüfen, in der mit weniger Aufwand größere Mengen an Stimuli produzierbar sind, wäre demnach zwar interessant. Der Fokus auf die entscheidungstheoretische Diskussion in der Privatsphärenforschung würde jedoch darunter leiden.

4.6. Schlussfolgerungen

In diesem Kapitel wurde ein RPM über Entscheidungen zur hypothetischen Nutzung oder Nichtnutzung fiktiver Smartphone-Apps formalisiert. Damit beleuchtet es einen wichtigen Aspekt der Privatsphärenforschung, nämlich den Zusammenhang zwischen Präferenzen und Entscheidungen bei der Auswahl von Online-Diensten. Features der hier präsentierten Apps, die mit monetären Vorteilen verknüpft waren, erhöhten die Wahrscheinlichkeit einer Nutzungsentscheidung stark. Privatsphäreninvasive Features senkten diese Wahrscheinlichkeit zwar, wurden aber in ihrem relativen Einfluss von den vorteilhaften Features übertroffen. Die beschriebenen Präferenzen über den Satz von Bayes zu integrieren und die Option mit der höheren Posterior-Wahrscheinlichkeit zu wählen, würde der Verhaltensweise eines rationalen Agenten entsprechen. Vorherige Literatur in der Privatsphärenforschung folgte der Annahme, dass dieser Ansatz Nutzerverhalten nicht adäquat beschreiben würde (Acquisti & Grossklags, 2005; Acquisti, 2004). Tatsächlich produzierte ein kognitives Modell, das diese Strategie umsetzte (detBayes), keine adäquate Vorhersage des Verhaltens der Studienteilnehmenden. Jedoch wurden auch zwei Varianten einer heuristischen Entscheidungstheorie, die üblicherweise als bessere Beschreibung von Nutzungsverhalten angesehen wurde (detTTB und probTTB), in der Mehrheit aller Modellvergleiche vom RPM in ihrer Vorhersagequalität übertroffen.

4.6.1. Probabilistisches Entscheidungsverhalten, Präferenzen und das Offenlegen privater Informationen

Aus diesen Ergebnissen lassen sich einige Überlegungen über das Offenlegungsverhalten von Nutzenden bezüglich privater Daten ableiten. Zunächst repräsentieren im vorgestellten Modellierungsansatz Risiken für die Privatsphäre und positive Aspekte eines Online-Dienstes keine prinzipiell unterschiedlichen Einflüsse auf das Verhalten. Die Mechanismen für das Erlernen einer Präferenz für monetäre Vorteile sollten für das Erlernen einer Abneigung gegen privatsphäreninvasive Features prinzipiell ebenso gelten. Es ist jedoch unrealistisch, zu erwarten, dass privatsphäreninvasive Features mit derselben Frequenz und Intensität als Kernaspekte des jeweiligen Dienstes angepriesen werden, wie seine augenscheinlichen Vorteile. Dies führt in der Theorie des kontextsensitiven Präferenzlernens (Srivastava & Vul, 2015) zu einer Verschiebung der Kontextwahrscheinlichkeiten. Ist der Agent nicht häufig genug einem Feature ausgesetzt, weil er seine Anwesenheit durch geschickte Interfacegestaltung oder irreführende Beschreibung schlicht übersieht, wird er den mit der Anwesenheit des Features assoziierten Kontext nur mit niedriger Wahrscheinlichkeit sampeln. Unter der Annahme, dass Entscheidungen über die Nutzung von Online-Diensten eher impulsiv getätigt werden, bedienen sich Nutzende nur einer geringen Menge an Samples. Als Konsequenz dieser beiden Aspekte ist es leicht vorstellbar, dass unerfahrene Nutzende einen Kontext, in dem sensible Daten relevant sind und daher invasive Features zu starker Ablehnung führen sollten, schlichtweg nicht sampeln oder ihn noch nie als eigenständigen Kontext etablieren. Stattdessen wird eine Entscheidung auf Basis weniger Samples durch leicht erreichbare Kontexte dominiert, also jene Teilmengen an Features, deren Vorteilen Nutzende häufiger ausgesetzt sind. Die geringe Menge produzierter Samples wirkt sich selbst unter der Annahme einer privatsphärensensiblen Entscheidungshistorie auf die Entscheidungsqualität. Gezeigtes Verhalten ist näher an Angleichungsverhalten als an Maximierungsverhalten zu verorten, was durch die Diskrepanz der Vorhersagen des detBayes-Modells und den empirischen Daten ersichtlich ist. Ohne Berücksichtigung der probabilistischen Eigenschaften des Entscheidungsprozesses mag der Eindruck irrationalen Nutzungsverhaltens entstehen. Das

Problem liegt jedoch nicht in der Annahme, dass Nutzende die Risiken potenziell invasiver Features prinzipiell nicht berücksichtigen. Sie verwenden eher zu wenige Ressourcen auf den Entscheidungsprozess, um Features nahezu deterministisch zu vermeiden, denen sie selten merklich ausgesetzt sind.

4.6.2. Implikationen für die Steigerung von Verhalten zum Schutz privater Informationen

Staatliche Institutionen, Arbeitgeber, Lehrer, Eltern und andere Stakeholder, denen die digitale Entscheidungsqualität ihrer Zielgruppen wie Bürgern, Angestellten, Schülern und Kindern am Herzen liegt, benötigen Interventionsansätze zur Verbesserung von Nutzungsentscheidungen. Ein möglicher Ansatzpunkt hierfür greift die Charakteristiken der Sampling-Hypothese auf, in der mehr Samples zu einer stärkeren Tendenz zu Maximierungsverhalten führen. Die Notwendigkeit von mehr Samples könnte beispielsweise bereits durch ein erneutes Bestätigen einer Datenanfrage operationalisiert werden. Müssen Nutzende mehrmals suboptimale Entscheidungen treffen, ist die Wahrscheinlichkeit, dass ihr durchschnittliches Verhalten ihren bekundeten Präferenzen entspricht, höher. Das Konzept hinderlichen Interface-Designs (Storer et al., 2013) ist ein Beispiel dafür, wie Ansätze des Resampling in der Praxis implementiert sein können.

Tatsächlich würde Resampling jedoch nur zu privatsphärenschtzendem Verhalten, also der Nichtnutzung von Diensten mit potentiell invasiven Features, führen, wenn Nutzende tatsächlich eine niedrige Präferenz zu invasiven Features entwickelt haben. Ist die Anwesenheit eines solchen Features jedoch mit einer hohen Präferenz assoziiert, weil Nutzende kein Fachwissen über die invasiven Auswirkungen des Features besitzen, dann könnte Resampling die Wahrscheinlichkeit der Nutzung eines Dienstes sogar erhöhen. In diesem Fall wären edukative Interventionsansätze empfehlenswert. Diese lassen sich jedoch nicht nahtlos in die hier vorgeschlagenen kognitiven Modelle integrieren, die sich mit dem Abrufen bestehender Informationen statt der Speicherung neuer Informationen beschäftigen.

4.6.3. Zukünftige Forschung

Während die Idee hinderlichen Interface-Designs aus einer komputationalen Perspektive Sinn ergibt, dürfte sie bei alltäglichen Nutzenden auf wenig Beliebtheit stoßen. Um sicherzustellen, dass Warnsignale auch dauerhaft die Aufmerksamkeit von Nutzenden binden, sollte der hier vorgestellte Ansatz kognitiver Modellierung mit existierender Forschung zu Interventionen im Kontext der Cybersicherheit (Kolb, Bartsch, Volkamer, & Vogt, 2014) integriert werden. Gleichzeitig ignorieren die hier vorgestellten Modelle bislang bewusst affektive Komponenten einer Entscheidung oder implementieren sie bestenfalls in der Höhe einer Präferenz gegenüber einem Feature. Srivastava und Vul (Srivastava & Vul, 2017b) haben beispielsweise gezeigt, dass Überraschung zur Zeit des Erhaltens einer Information einen Einfluss auf die Wahrscheinlichkeit hat, diese Information aus dem Gedächtnis abzurufen. Dementsprechend könnte komputationale Modellierung die Auswirkung von Interventionen, die Nutzenden gezielt verärgern, auf das Sampling privatsphärenspezifischer Kontexte untersuchen. Zunächst schlage ich jedoch eine Generalisierung der Ergebnisse weg von Smartphone-Apps und hin zu allgemeinen Online-Diensten vor. Dafür ist insbesondere die Operationalisierung eines Wahrnehmungsprozesses vorhandener Features notwendig, da abseits von Angeboten in gängigen

App Stores die Eigenschaften von Online-Diensten selten klar aufgelistet sind. Um privatsphärenbezogenes Offenlegungsverhalten außerhalb der strikten Grenzen der hier genutzten Stimuluskategorie zu untersuchen, sollte daher ein Metaprozess zur Suche nach entscheidungsrelevanten Features der Erinnerung an Präferenzen gegenüber diesen Features vorgeschoben werden.

5. Empirische Anwendung: Entscheidungsmodellierung für Optionen auf Basis eines Attributs: Wahrnehmung nonverbaler Flirtverhaltens

In Kapitel 1 wurde der Zusammenhang zwischen menschlichem Verhalten, normativer Entscheidungstheorie und bayesianischer kognitiver Modellierung dargelegt. In diesem Kapitel betrachte ich die Wahrnehmung von Flirtverhalten als unsicherheitsbehaftetes Entscheidungsproblem, das sich für den Prozess der Formalisierung als rationales Prozessmodell eignet. Flirten ist als Verhalten definiert, das dem Gegenüber romantisches oder sexuelles Interesse ausdrücken soll (Hall, Carter, Cody, & Albright, 2010). Frauen und Männer zeigen eine große Anzahl unterschiedlicher verbaler als auch nonverbaler Verhaltensweisen, um dieses Interesse zu kommunizieren (Moore, 1985; Renninger, Wade, & Grammer, 2004). Das Erkennen einer Flirtintention kann aufgrund der Vielseitigkeit von Verhaltensweisen mit dieser Intention allerdings ein Problem darstellen. So wird beispielsweise die Anwesenheit von Verhaltensweisen, die explizit keine Flirtintention nahelegen, präziser wahrgenommen als die Anwesenheit von Verhaltensweisen mit zugrundeliegender Flirtintention (Hall, Xing, & Brooks, 2015). Flirtintentionen mit unterschiedlichen implizierten Konsequenzen (Henningsen, 2004) oder der gegenwärtige Beziehungsstatus des Beobachters von Flirtverhalten (O'Farrell, Rosenthal, & O'Neal, 2003) beeinflussen ebenfalls die Präzision, mit der Flirtverhalten erkannt wird. Das Schlussfolgern der Wahrscheinlichkeit einer vorliegenden Intention aufgrund der Beobachtung eines bestimmten Verhaltens ist aufgrund der potenziellen Mehrdeutigkeit des Verhaltens ein Problem, dem sich zwar viele Menschen im Verlauf ihres Lebens ausgesetzt sehen. Wie sich diese Mehrdeutigkeit und ihr Einfluss auf das Entscheidungsverhalten von Beobachtern in einem kognitiven Modell formalisieren und vorhersagen lassen, war bisher jedoch kein Schwerpunkt sozialpsychologischer Erforschung.

5.1. Studiendesign und Stichprobe

Um die Reaktion auf Verhalten zu evaluieren, das potenziell Flirtintentionen kommuniziert, wurde über www.socsisurvey.de eine Online-Studie mit 106 Teilnehmenden durchgeführt. Davon waren 46% weiblich, der Altersdurchschnitt lag bei 27.54 Jahren und die Standardabweichung des Alters bei 10.80 Jahren. Alle Teilnehmenden gaben in Übereinstimmung mit der Deklaration von Helsinki schriftlich ihre Einverständniserklärung zur Teilnahme an der Studie sowie der Datenspeicherung und anonymisierten Veröffentlichung der Ergebnisse. Zunächst gaben die Studienteilnehmenden danach Angaben zu demographischen Variablen an. Dann sahen sie in randomisierter Reihenfolge zehn Videoaufnahmen von jeweils wenigen Sekunden Dauer, die verschiedene nonverbale Verhaltensweisen mit unterschiedlich starker Assoziation zu Flirtintentionen darstellten. Diese Videoaufnahmen wurden mit einer Schauspielerin mit Theatererfahrung als Darstellerin speziell für diese Studie aufgenommen. Das Einverständnis der Schauspielerin, Standbilder der Videoaufnahmen in dieser Arbeit zu veröffentlichen, liegt bedauerlicherweise nicht vor. Deshalb sind die verwendeten Stimuli in Tabelle 13 verbal beschrieben. Es handelt sich um fünf individuelle Verhaltensweisen, die mit Flirtintentionen assoziiert sind (Moore, 1985), sowie zwei als Kontrollstimuli implementierte Verhaltensweisen, die ausdrücklich keine Flirtintention kommunizieren dürften. Diese Stimuli wurden in zwei verschiedenen sozialen Kontexten aufgenommen: tagsüber an einer Bushaltestelle und abends in einer Bar. Weil drei

der Verhaltensweisen mit implizierter Flirtintention in beiden sozialen Kontexten dargestellt wurden, ergab sich so eine Gesamtanzahl von zehn zu bewertenden Stimuli.

Tabelle 13.

Behaviorale Beschreibung der verwendeten Stimuli nach Moore (1985). Sozialer Kontext in Klammern.

Stimulus	Behaviorale Beschreibung
Stimulus 1	Flüchtiger Blickkontakt mit Empfänger (Bushaltestelle).
Stimulus 2	Offenes Lächeln während anhaltendem Blickkontakt (Bushaltestelle).
Stimulus 3	Kontrollstimulus. Schauspielerin betrachtet ihr Smartphone (Bushaltestelle).
Stimulus 4	Schüchternes Lächeln bei gesenktem Blick (Bushaltestelle).
Stimulus 5	Schauspielerin lässt lächelnd ihre Finger durch die Haare gleiten (Bushaltestelle).
Stimulus 6	Schauspielerin öffnet ihren Mund etwas und befeuchtet die Lippen (Bar).
Stimulus 7	Flüchtiger Blickkontakt mit Empfänger (Bar).
Stimulus 8	Kontrollstimulus. Schauspielerin wirft Empfänger irritierten Blick zu (Bar).
Stimulus 9	Schauspielerin lässt lächelnd ihre Finger durch die Haare gleiten (Bar).
Stimulus 10	Schüchternes Lächeln bei gesenktem Blick (Bar).

Die Studienteilnehmenden wurden gebeten, anzugeben, ob das jeweils im Videoabschnitt gezeigte Verhalten Flirtintentionen repräsentiere, oder nicht. Im Anschluss wurden ihnen vollständige Paarvergleiche der Stimuli in randomisierter Reihenfolge gezeigt und sie wurden gebeten, den Stimulus zu identifizieren, der wahrscheinlicher als der andere Flirtintentionen kommunizieren würde. Die Bewertung der Stimuli in Paarvergleichen diente der Ermittlung der Wahrscheinlichkeit, mit der ein Stimulus Flirtintentionen kommuniziert. Die marginalisierte Anzahl der Situationen, in denen ein Stimulus als wahrscheinlicher Flirtintentionen ausdrückend als der andere Stimulus beurteilt wurde, wurde zusammen mit der marginalisierten Anzahl an gegenteiligen Urteilen zu einer Quote verrechnet. Diese Quote je Stimulus wurde in eine Wahrscheinlichkeit umgerechnet und als Ausmaß der Wahrscheinlichkeit interpretiert, dass der Stimulus eine Flirtintention ausdrückt. Die Datenanalyse fand in Rstudio 1.0.153 (RStudio Team, 2015) und R 3.4.1 (R Core Team, 2017) statt. Zusätzlich wurden die Pakete *combinat* (Chasalow, 2012) und *poibin* (Hong, 2013b) verwendet.

5.2. Formalisierung als rationales Prozessmodell

Zur Vorhersage der Wahrscheinlichkeit, mit der ein Agent nach Betrachten eines Stimulus von einer Flirtintention ausgeht, formalisiere ich seinen Entscheidungsprozess als RPM. Es verhält sich entsprechend den Darstellungen zur Sampling-Hypothese (Vul et al., 2014) und der Theorie des kontextsensitiven Präferenzlernens (Srivastava & Schrater, 2015) in Kapitel 1 und verbindet damit sein bayesianisches Fundament auf der komputationalen Ebene mit ressourcenbedingten Einschränkungen auf der algorithmischen Ebene. Während die modellierte Annahme, dass es sich beim gezeigten Verhalten um den Ausdruck einer Flirtintention handelt, strenggenommen keine Präferenz darstellt, ist die Theorie des kontextsensitiven Präferenzlernens (Srivastava & Schrater, 2015) auch auf die allgemeine Kontextabhängigkeit von Kausalzuschreibungen übertragbar und deshalb angebracht. Es

wird zunächst angenommen, dass der Agent keine spezifische Überzeugung zur Wahrscheinlichkeit einer Flirtintention der Schauspielerin besitzt, sodass für ihn die Hypothesen der An- und Abwesenheit einer Flirtintention a priori uniform verteilt sind. Der Agent beobachtet daraufhin das im Stimulus gezeigte Verhalten und produziert Samples aus seinem Gedächtnis, um die Bedeutung des gezeigten Verhaltens hinsichtlich einer möglichen Flirtintention zu evaluieren. Im Satz von Bayes nimmt diese Bedeutung die Position der Likelihood ein. Die Produktion der Samples ist als Bernoulli-Versuch implementiert, dessen Erfolgswahrscheinlichkeit der Wahrscheinlichkeit des gezeigten Verhaltens bei unterstellter Anwesenheit einer Flirtintention entspricht. Die Gegenwahrscheinlichkeit im Bernoulli-Versuch beschreibt folglich die Wahrscheinlichkeit, das gezeigte Verhalten ohne vorhandene Flirtintention zu beobachten. Der Agent produziert so lange Samples, bis ihm eine probabilistische Regel zur Terminierung des Sampling-Prozesses vermittelt, dass weitere Samples nur noch wenig neue Informationen mit sich bringen. Das Verhalten der Regel zur Terminierung des Sampling-Prozesses wird in Kapitel 4.3.1 ausführlich beschrieben. Der Agent folgt in Kapitel 4 und 5 denselben komputationalen und algorithmischen Prinzipien, weshalb hier auf eine wiederholte Beschreibung verzichtet wird. Nach der Berechnung der Wahrscheinlichkeit q gemäß Gleichung 1.2 in Kapitel 1.3 integriert der Agent die aus dem Sampling-Prozess generierte Likelihood über den Satz von Bayes mit seinem Prior, um die Posterior-Wahrscheinlichkeit einer Flirtintention aus dem beobachteten Verhalten zu schlussfolgern. Da in diesem Kapitel angenommen wird, dass der Agent einen uniformen Prior über die beiden Hypothesen vertritt und er seine Entscheidung im Gegensatz zum Szenario in Kapitel 4 auf der Grundlage eines Attributs trifft, entspricht sein Posterior seiner aus dem Sampling-Prozess generierten Likelihood.

5.3. Alternativmodelle

Die in Kapitel 1 beschriebenen Erweiterungen bayesianischer Entscheidungstheorie waren nötig, um bekannte empirische Abweichungen vom Verhalten komputational bayesianischer Agenten erklären und rationalisieren zu können. Das RPM positioniert sich dadurch in Abhängigkeit der Anzahl produzierter Samples zwischen dem Maximierungsverhalten eines bayesianischen Agenten und dem Angleichungsverhalten eines Agenten, der die wahrscheinlichere Option proportional zu ihrer Wahrscheinlichkeit wählt (Vul, 2010). Ob die durch den Sampling-Prozess hinzugefügten Freiheitsgrade des Modells jedoch notwendig zur Beschreibung menschlichen Entscheidungsverhaltens sind, überprüfe ich durch den Vergleich mit den beiden angesprochenen Polen, zwischen denen sich das Verhalten des RPM bewegt: einem Angleichungsmodell und einem komputational bayesianischen Modell.

5.3.1. Angleichungsmodell (probMatch)

Das Angleichungsmodell beinhaltet keinen algorithmischen Prozess zum Abruf der Likelihood eines Stimulus aus dem Gedächtnis. Sie wird stattdessen als dem Agenten zugänglich angenommen. Die Wahrscheinlichkeit, mit der der Agent also die Option der Anwesenheit einer Flirtintention wählt, entspricht der Wahrscheinlichkeit, dass der gezeigte Stimulus eine Flirtintention ausdrückt.

5.3.2. Bayesianisches Modell (detBayes)

Das bayesianische Modell beinhaltet ebenfalls keinen algorithmischen Prozess zum Abruf der Likelihood eines Stimulus. Es entspricht in seiner Funktionsweise dem in Kapitel 4.3.2 vorgestellten bayesianischen Modell bis auf die Tatsache, dass es seine Vorhersage in diesem Kapitel auf Basis eines Attributs anstelle der Integration mehrerer Attribute trifft. Es wird davon ausgegangen, dass der Agent einen uniformen Prior über die Hypothesen der An- und Abwesenheit einer Flirtintention verwendet. Deshalb entspricht der Posterior der Likelihood und der Agent wählt diejenige Hypothese mit der höheren Likelihood deterministisch. Das Modell generiert also keine Wahlwahrscheinlichkeit, sondern eine binäre Vorhersage der Wahl.

5.4. Modellvergleich und Ergebnisse

Entsprechend der Darstellung unterschiedlicher Methoden zum Vergleich der Vorhersagequalität kognitiver Modelle aus Kapitel 2 berechne ich Bayes Factors, um das Ausmaß an Evidenz zugunsten eines der verglichenen Modelle zu ermitteln. Die Modelle RPM und probMatch produzieren pro Studienteilnehmenden und Stimulus eine Erfolgswahrscheinlichkeit. Die erwartbare Menge an Entscheidungen für die Anwesenheit einer Flirtintention folgt für diese Modelle einer Poisson-Binomial-Verteilung (Hong, 2013a). Graphisch ähneln die Vorhersagen von RPM und probMatch demnach einer Glockenform. detBayes als deterministisches Modell hingegen schreibt den Antworten einzelner Studienteilnehmender je Stimulus nur 0% oder 100% Wahrscheinlichkeit zu, sodass es graphisch die gesamte verfügbare Wahrscheinlichkeitsmasse an der Position anbringt, die der Anzahl aller individuellen Vorhersagen mit 100% entspricht. Alle anderen möglichen Anzahlen an Studienteilnehmenden, die sich für die Anwesenheit einer Flirtintention entschieden haben könnten, erhalten demnach eine Wahrscheinlichkeitsdichte von 0. Beim Vergleich mit detBayes muss für die Berechnung eines Bayes Factors also durch 0 geteilt werden, solange die empirisch beobachtete Anzahl nicht exakt der vorhergesagten Anzahl entspricht. Die Division durch 0 ist zwar arithmetisch undefiniert, wird aber in dieser Arbeit entsprechend der implementierten Berechnungsregeln in R als positiv unendlich interpretiert. Das bedeutet, dass ein Vergleich, bei dem die Likelihood eines Modells 0 beträgt, zugunsten des anderen Modells ausgelegt wird. In den Abbildungen 13 bis 22 sind die Vorhersagen aller Modelle und das empirisch beobachtete Entscheidungsverhältnis für jeden Stimulus graphisch dargestellt. Auf der x-Achse ist dabei die Anzahl an Entscheidungen für das Vorhandensein einer Flirtintention abgetragen. Die y-Achse zeigt die Wahrscheinlichkeitsdichte für diese Anzahl an Entscheidungen unter Annahme einzelner Modelle. Die schwarze vertikale Linie markiert die Anzahl der Studienteilnehmenden, die sich für die Anwesenheit einer Flirtintention entschieden haben. Je höher die Wahrscheinlichkeitsmasse der jeweiligen Modelle am Schnittpunkt mit dieser Linie ist, desto genauer ist ihre Vorhersage.




Abbildung 13. Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den ersten Stimulus.




Abbildung 14. Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den zweiten Stimulus.

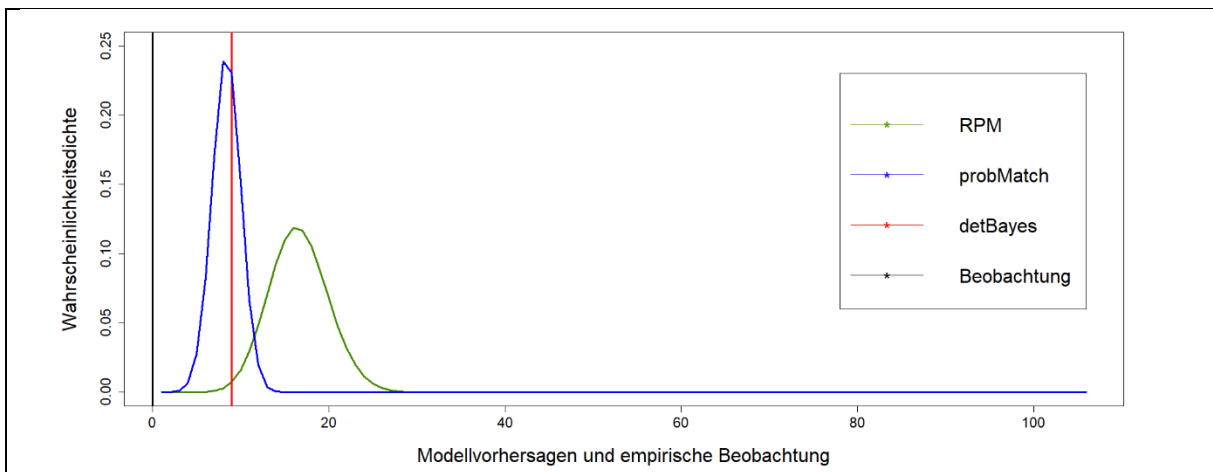


Abbildung 15. Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den dritten Stimulus.




Abbildung 16. Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den vierten Stimulus.




Abbildung 17. Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den fünften Stimulus.

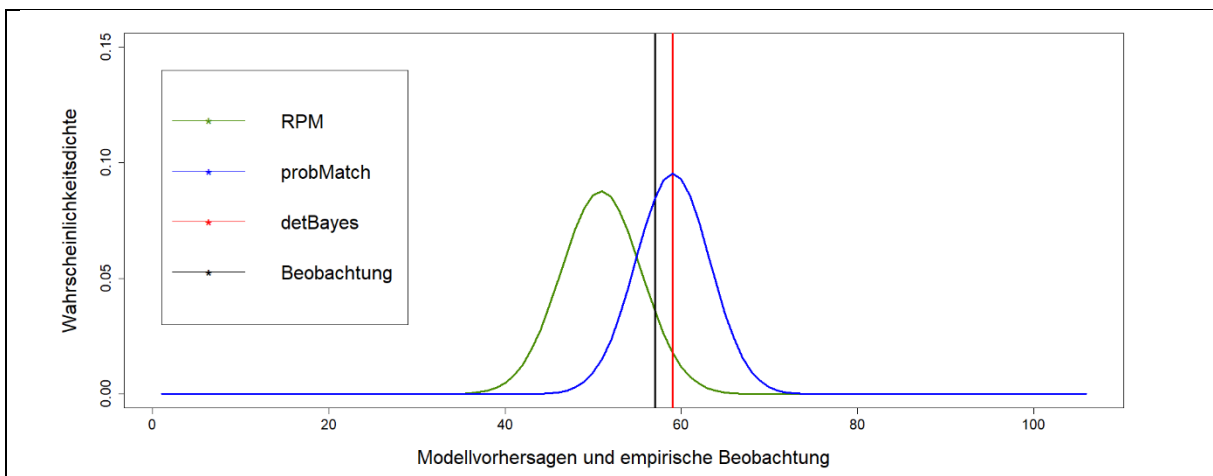


Abbildung 18. Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den sechsten Stimulus.




Abbildung 19. Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den siebten Stimulus.




Abbildung 20. Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den achten Stimulus.




Abbildung 21. Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den neunten Stimulus.




Abbildung 22. Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den zehnten Stimulus.

Im graphischen Vergleich in den Abbildungen 13 bis 22 fällt zunächst auf, dass die bessere Vorhersagekraft von probMatch nicht auf einer Vorhersageverteilung mit deutlich geringerer Varianz basiert, sondern auf einer besseren Positionierung der Verteilung auf der x-Achse. Spezifisch für die Stimuli 2, 3, 4 und 8 ist zu beobachten, dass die empirische Beobachtung an Wahrnehmungen einer Flirtintention zu den Extremen der x-Achse tendiert, probMatch dieses Verhalten besser vorhersagt und die Prognose des RPM oftmals nicht weit genug von der Mitte der x-Achse, also einer Wahrnehmungsrate von 50%, entfernt liegt.

In Tabelle 14 finden sich die Bayes Factors für den Modellvergleich zwischen RPM und probMatch aller Stimuli. Weil detBayes als deterministisches Modell die beobachtete Menge an Entscheidungen für die Anwesenheit einer Flirtintention für alle Stimuli verfehlt hat, zeigen alle Bayes Factors zwischen RPM beziehungsweise probMatch und detBayes unendlich positive Unterstützung für das jeweils erste Modell. Die numerische Interpretation der Bayes Factors findet in Anlehnung an Jeffreys (1998) wie in Kapitel 2 beschrieben statt.

Tabelle 14.

Bayes Factors für den Modellvergleich zwischen RPM und probMatch für alle Stimuli. Die Bayes Factors nutzen die marginale Likelihood des RPM im Zähler.

Stimulus	Bayes Factor	Evidenzniveau
Stimulus 1	0.61	Anekdotische Evidenz für probMatch
Stimulus 2	< 0.01	Extreme Evidenz für probMatch
Stimulus 3	0.03	Sehr starke Evidenz für probMatch
Stimulus 4	< 0.01	Extreme Evidenz für probMatch
Stimulus 5	< 0.01	Extreme Evidenz für probMatch
Stimulus 6	0.19	Starke Evidenz für probMatch
Stimulus 7	3.34	Moderate Evidenz für RPM
Stimulus 8	0.22	Starke Evidenz für probMatch
Stimulus 9	< 0.01	Extreme Evidenz für probMatch
Stimulus 10	< 0.01	Extreme Evidenz für probMatch

Tabelle 15 stellt die durchschnittliche Wahrscheinlichkeit der Anwesenheit einer Flirtintention dar, die aus den Paarvergleichen ermittelt wurden. Für die beiden als Kontrollstimuli verwendeten Verhaltensweisen 3 und 8 wurden wie erwartet niedrige Likelihood-Werte ermittelt, sie zeigen jedoch eine ähnlich hohe Standardabweichung wie andere Stimuli, die im Mittel deutlich wahrscheinlicher als Ausdruck einer Flirtintention aufgefasst wurden. Die zugehörigen Abbildungen 15 und 20 zeigen die empirischen Entscheidungsverhältnisse. Dabei ist auffällig, dass die extreme Anzahl an Entscheidungen gegen das Vorliegen einer Flirtintention noch deutlicher ausfällt, als die Ermittlung der Wahrscheinlichkeit der Anwesenheit einer Flirtintention in Tabelle 15 suggerieren würde.

Die Wahrscheinlichkeiten der Anwesenheit einer Flirtintention in Tabelle 15 können zur Untersuchung möglicher Kontextabhängigkeiten für identische Verhaltensweisen genutzt werden. Für das Stimuluspaar 1 und 7 ist ein kontextabhängiger Anstieg der Likelihood vom Aufnahmeort der Bushaltestelle hin zur Bar ersichtlich, der sich jedoch für die Stimuluspaare 4 und 10 beziehungsweise 5 und 9 nicht zeigt.

Tabelle 15.

Durchschnittliche Wahrscheinlichkeit der Anwesenheit einer Flirtintention (Standardabweichung in Klammern) als Ergebnis der Paarvergleiche (in Prozent, gerundet auf ganze Zahlen).

Stimulus	Wahrscheinlichkeit der Anwesenheit einer Flirtintention
Stimulus 1	20% (23%)
Stimulus 2	72% (29%)
Stimulus 3	8% (22%)
Stimulus 4	73% (26%)
Stimulus 5	69% (28%)
Stimulus 6	56% (29%)
Stimulus 7	42% (31%)
Stimulus 8	16% (30%)
Stimulus 9	81% (28%)
Stimulus 10	69% (31%)

Tabelle 16 zeigt die Klassifikationsraten des Modells detBayes. Die probabilistischen Modelle treffen keine Klassifizierungen im üblichen Sinne und ihre Vorhersagen sind aus diesem Grund nicht in der Tabelle aufgeführt.

Tabelle 16.

Klassifikationsergebnisse des Modelle detBayes aggregiert über alle Stimuli (in Prozent, gerundet auf ganze Zahlen).

Modell	Treffer	Verpasser	Falsche Alarmer	Korrekte Ablehnungen
detBayes	36%	16%	10%	38%

5.5. Diskussion

In diesem Kapitel wurde ein RPM zur Vorhersage der Wahrnehmung einer Flirtintention aufgrund von beobachteten nonverbalen Verhaltensweisen genutzt und mit einem Angleichungsmodell (probMatch) und einem komputational bayesianischen Modell (detBayes) verglichen. Dies diente vorrangig zwei Zielen: erstens sollte untersucht werden, ob RPMs über inhaltliche Domänen generalisiert geeignet sind, menschliches Verhalten in unsicherheitsbehafteten Entscheidungssituationen vorherzusagen. Zweitens sollte evaluiert werden, ob die durch die algorithmische Spezifikation entstandene Komplexität des RPM im Vergleich zu den komputationalen Alternativmodellen durch eine bessere Vorhersage gerechtfertigt wird. Dabei unterscheidet sich die

modellierte Entscheidungssituation im Vergleich zu Kapitel 4 durch die Struktur der betrachteten Stimuli, die statt mehrerer Attribute nur durch ein Attribut, nämlich die dargestellte Verhaltensweise, repräsentiert sind. Der Modellvergleich unterstützt mit der Ausnahme von Stimulus 7 einheitlich probMatch. Wie im grafischen Vergleich in Kapitel 5.4 beschrieben, kann dieses Ergebnis mit einer extremeren Positionierung der Vorhersagen von probMatch auf der x-Achse erklärt werden. Die weniger extreme Positionierung des RPM könnte durch seine algorithmische Spezifikation erklärt werden, die im laufenden Sampling-Prozess den aktuellen Erwartungswert der Erfolgswahrscheinlichkeit des Bernoulli-Versuchs als Erwartungswert einer Beta-Verteilung modelliert. Das bedeutet, dass die Ermittlung der Erfolgswahrscheinlichkeit im Sampling-Prozess bei 50% startet ($\text{beta}(a = 1, b = 1)$) und sich entsprechend des Erwartungswertes der aktualisierten Beta-Verteilung anpasst. So wird die Erfolgswahrscheinlichkeit im hier formulierten RPM nach einem erfolgreichen Sample mit $\text{beta}(a = 2, b = 1)$ auf 67% geschätzt. Ein Agent, der vollständiges Angleichungsverhalten zeigen und auf die Produktion eines Samples beschränkt sein soll, besitzt diese Repräsentation der Erfolgswahrscheinlichkeit nicht. Er produziert stattdessen ein Sample und vertraut daraufhin je nach Ausgang des Bernoulli-Versuchs mit 100% oder 0% in das Zutreffen einer Hypothese. Diese extremere Repräsentation der Erfolgswahrscheinlichkeit im Vergleich zum RPM ermöglicht probMatch die Vorhersage extremerer Entscheidungsverhältnisse. detBayes erzeugt aufgrund seiner Entscheidungsregel erneut binäre Vorhersagen des beobachteten Verhaltens. Tabelle 16 zeigt hierfür eine ähnliche Verteilung an korrekten und inkorrekten Klassifikationen wie in Kapitel 4.

5.5.1. Einschränkungen

Über den Paarvergleich zweier Stimuli wurde die verwendete Likelihood je Stimulus für individuelle Studienteilnehmende geschätzt. Tabelle 15 zeigt hierfür eine deskriptive Zusammenfassung. Ein Problem mit dieser Methode wird aber bei Betrachtung der Kontrollstimuli 3 und 8 deutlich. Die gezeigten Verhaltensweisen repräsentierten für die Studienteilnehmenden eindeutig keine Flirtintention, aber Werte von exakt 0% oder 100% waren über die Paarvergleichsmethode nicht zu erreichen. Spätestens im Paarvergleich zwischen beiden Kontrollstimuli mussten sie einen der beiden als wahrscheinlicher eine Flirtintention ausdrückend angeben, was zu einer verringerten Passung der Modellvorhersagen zum gezeigten Verhalten führte.

Darüber hinaus ermöglicht die inhaltliche Domäne der Studie eine detailliertere Betrachtung, als sie in diesem Kapitel umgesetzt wurde. Beispielsweise wurde die sexuelle Orientierung der Studienteilnehmenden hinsichtlich der Wahrnehmung von Flirtintentionen der Darstellerin nicht explizit berücksichtigt. Diese Entscheidung beruhte zwar auf der Intuition, dass auch Studienteilnehmende ohne sexuelles Interesse an der Darstellerin ein Verhalten mit hoher Wahrscheinlichkeit einer ausgedrückten Flirtintention als solches erkennen können. Es kann jedoch nicht ausgeschlossen werden, dass sexuelles Interesse am Gegenüber die Bereitschaft zur Wahrnehmung von Flirtintentionen ausdrückendem Verhalten fördert, was komputational beispielsweise als informierter Prior operationalisiert werden könnte.

Zuletzt war es nicht das Ziel dieser Studie, die Auswirkung von Kontexteffekten explizit zu untersuchen, sondern die beschriebenen kognitiven Modelle stattdessen in einer augenscheinvaliden Kombination aus Verhaltensweisen und Kontexten zu prüfen. Im Zuge dessen beinhalten die Stimuli 1 und 7, 4 und 10 sowie 5 und 9 aus Tabelle 13 identische Verhaltensweisen, die sich nur im sozialen Kontext unterscheiden. In Zusammenhang mit der deskriptiven Darstellung an geschätzten Likelihoods aus

Tabelle 15 lässt sich leider keine klare Tendenz erkennen, ob Verhaltensweisen in Abhängigkeit ihres Kontexts oder unabhängig davon beurteilt wurden. Da die Theorie kontextsensitiven Präferenzlernens (Srivastava & Schrater, 2015) die Modellierung solcher Unterschiede explizit ermöglicht, aber nicht erfordert, sollte durch zukünftige Forschung auf datenanalytischer Basis ein Bedarf für die komputationale Differenzierung zwischen sozialen Kontexten ermittelt werden.

5.6. Schlussfolgerungen

Im Gegensatz zur inhaltlichen Domäne in Kapitel 4 konnte das RPM im hier gezeigten Modellvergleich keine Unterstützung durch die empirische Datenlage erhalten. Angleichungsverhalten scheint eine im Durchschnitt angemessenere Beschreibung menschlicher Entscheidungsfindung bei der Wahrnehmung von Flirtintentionen auf Basis nonverbalen Verhaltens zu sein. Erneut konnte gezeigt werden, dass ein rein komputational bayesianischer Ansatz aufgrund seiner deterministischen Entscheidungsregel kein angemessenes Modell menschlicher Entscheidungsfindung unter Unsicherheit ist. Im direkten Vergleich zwischen probMatch und RPM unterscheiden sich beide Modelle bei Entscheidungen auf Basis eines einzelnen Attributes hauptsächlich durch ihre Repräsentation des Wissenszustandes des Agenten, weil für das vorliegende Entscheidungsproblem keine Integration mehrerer Likelihoods oder eines informierten Priors nötig war. Das RPM repräsentiert den Wissenszustand des Agenten nach der Produktion eines Samples über den Erwartungswert einer Beta-Verteilung, sodass er auch bei einer Restriktion auf ein einziges Sample kein striktes Angleichungsverhalten zeigt. Im Kontrast dazu repräsentiert probMatch den Wissenszustand des Agenten als Anzahl erfolgreicher Samples geteilt durch die Gesamtanzahl produzierter Samples. Diese Wissensrepräsentation erfasst das empirisch beobachtete Verhalten der Studienteilnehmenden für die vorliegende inhaltliche Domäne besser. Zukünftige Forschung sollte daher untersuchen, ob es einen Unterschied in der Vorhersagequalität verschiedener Arten der Wissensrepräsentation des Agenten in Domänen mit Entscheidungsproblemen auf Basis einzelner im Vergleich zu Entscheidungssituationen auf Basis mehrerer Attribute gibt. In Bezug auf die inhaltliche Domäne selbst stellt die hier vorgestellte Studie nur einen ersten Versuch der Formalisierung dar, der hinsichtlich verschiedener Charakteristika des Agenten, des gezeigten Verhaltens und des sozialen Kontexts erweitert werden sollte.

6. Diskussion

Die erklärten Ziele dieser Arbeit sind erstens die Identifizierung von Forschungsthemen, die von den theoretischen Entwicklungen in der Anwendung bayesianischer kognitiver Modellierung profitieren können und zweitens die Evaluation ihrer Vorhersagekraft. Diese Evaluation findet hier über den Modellvergleich statt, eine Methode, die den Vorhersagen zweier Modelle relative Glaubwürdigkeit zuschreibt. Die Aussage eines Modellvergleichs ist auch als solche zu interpretieren – relativ und eingeschränkt auf die beiden Modelle, die zu einem Zeitpunkt berücksichtigt werden. Deshalb sind die im Folgenden zusammengefassten Ergebnisse nicht als abschließende Aussage über die in der jeweiligen Domäne relevanten kognitiven Prozesse zu sehen. Chown (2014) betont in diesem Zusammenhang den konsekutiven Charakter kognitiver Modellierung, da es keine nachweislich richtigen Algorithmen zur Beschreibung menschlicher Kognition gäbe. In diesem abschließenden Kapitel lege ich dar, wie der Leser über die Grenzen der hier ausgewählten Modelle hinaus Erkenntnisse für die nächste Iteration kognitiver Modellierung der entsprechenden inhaltlichen Domänen ableiten kann.

6.1. Zusammenfassung des Modellverhaltens

In der vorliegenden Arbeit wurden drei Themenschwerpunkte behandelt, deren Ergebnisse mit Hinblick auf die vorgestellten kognitiven Modelle ich hier diskutiere. Im ersten Themenschwerpunkt wurde das bayesianische Modell für Kausalinferenz (Berniker & Kording, 2011), das von Samad et al. (2015) für die Modellierung der Rubber-Hand-Illusion (RHI) angepasst wurde, auf eine Illusionsvariante für die unteren Gliedmaßen, die Rubber-Foot-Illusion (RFI) übertragen. Fixierte Modellparameter wurden dem neuen Experimentalaufbau entsprechend angepasst, die hauptsächliche Veränderung bestand jedoch in der Verwendung eines empirisch informierten Priors. Diese Änderung führte dazu, dass das vorgestellte Modell individuelle Schätzungen der Gliedmaßposition vor der experimentellen Stimulation berücksichtigen konnte, anstatt ausschließlich ein Signalverhältnis zwischen den beteiligten sensorischen Kanälen wiederzugeben. Die Wahl dieses Priors wurde auf Basis der Intuition getroffen, dass Menschen, die an einem für die RHI oder RFI typischen Experimentalaufbau sitzen, ihre Gliedmaßen sehr erwartbar positionieren, weil sie vom Versuchsleiter darauf aufmerksam gemacht werden dürften. Sowohl für die oberen als auch die unteren Gliedmaßen ähnelt die Positionierung dem aufrechten Sitzen an einem Schreibtischarbeitsplatz. Aus Gründen der Vermeidung subjektiver Verzerrung der Ergebnisse stattdessen auf einen Prior zurückzugreifen, der die Positionierung des modellierten Gliedmaßes überall auf einer azimuthalen Ebene vor Versuchsteilnehmenden gleich wahrscheinlich macht, halte ich aufgrund seiner Konsequenzen für das Modellverhalten für unplausibel. Dennoch ist gerade die Wahl informierter Priors ein intensiv diskutiertes Thema in der Literatur. Die Verwendung bayesianischer Methoden in der Datenanalyse beispielsweise beruht üblicherweise auf uniformen bis uninformativen Priors (Rouder, Speckman, Sun, Morey, & Iverson, 2009). Der Unterschied zwischen beiden besteht darin, dass bei ersteren alle möglichen Werte eines relevanten Parameters als gleich wahrscheinlich betrachtet werden, und sie bei letzteren analytisch betrachtet nicht uniform, aber beispielsweise symmetrisch gleich viel Wahrscheinlichkeitsdichte positiven und negativen Parameterwerten zuschreiben. In der Anwendung bei kognitiver Modellierung ist bei der Wahl eines Priors zwar ebenfalls Vorsicht geboten, weil er das Modellverhalten beeinflussen kann. Gleichzeitig muss seine Auswirkung aber auch aus Sicht des modellierten Systems plausibel sein.

Die Wahl des Priors in rationalen, also traditionell komputational bayesianischen Modellen wie dem Modell für Kausalinferenz, wird von Jones und Love (2011) jedoch als Quelle unregulierter Flexibilität beschrieben. Auch Bowers und Davis (2012) verweisen darauf, dass der Prior in Zusammenhang mit Likelihood- und Nützlichkeitsfunktionen einem bayesianischen Modell zu viele Freiheitsgrade gibt, um bei nachträglicher Anpassung beliebige Datenmuster mit nahezu beliebiger Präzision abbilden zu können. Die Form des Priors als freier Parameter hat eine unbestreitbare Auswirkung auf die Modellvorhersage und demnach auf den Ausgang eines Modellvergleichs, wie in der Ermittlung des Bayes Factors in Kapitel 2 beschrieben ist. Damit hat er einen ähnlichen Einfluss wie jeder andere freie Parameter in einem kognitiven Modell und seine Fixierung sollte denselben Regeln folgen, wie alle anderen auch. Im Fall des ersten Themenschwerpunkts dieser Arbeit wurde die Parametrisierung des Priors anhand von zwei Argumenten vorgenommen: erstens dem postulierten Mangel an Plausibilität des vorherigen Priors, sodass der Prior nicht alle Gliedmaßpositionen gleich plausibel erscheinen ließ. Zweitens wurde seine Präzision anhand empirischer Messungen propriozeptiver Präzision (Jones et al., 2010) fixiert. Von einer nachträglichen Anpassung an den Einzelfall dieses Datensatzes zum Zweck einer Manipulation des Modellverhaltens im Sinne der gewünschten Ergebnisse kann hier keine Rede sein. Gleichzeitig kann der Prior einem skeptischen wissenschaftlichen Publikum präsentiert werden (Kruschke, 2015) und in folgenden Iterationen durchaus von einem sinnvoll hergeleiteten Prior ersetzt werden. Wissenschaftliche Erkenntnis ist durch Fehlverhalten im Umgang mit freien Parametern in bayesianischen Modellen im exakt selben Ausmaß bedroht, wie in nicht bayesianischen Modellen. Diese Gefahr sollte berücksichtigt und beispielsweise durch die Nutzung von Bayes Factors als Methode für den Modellvergleich kontrolliert werden, weil Bayes Factors das Prinzip der Sparsamkeit automatisch umsetzen (Farrell & Lewandowsky, 2018). Ein ebenfalls wichtiger Aspekt ist jedoch die Auswirkung des Parameters auf das resultierende Modellverhalten, das im vorliegenden Anwendungsbeispiel bei uniformem Prior zu einem Signalverhältnis ohne Berücksichtigung von Unterschieden zwischen Individuen verkommen wäre. Es sei erneut darauf hingewiesen, dass bisherige Forschung nahelegt, dass die Erweiterung von der komputationalen auf die algorithmische Ebene für sensomotorische Fragestellungen weniger notwendig zu sein scheint, als für verbalisierte oder bewusste Entscheidungsphänomene (Vul, 2010). Aus diesem Grund finden die theoretischen Komponenten zur Erweiterung bayesianischer Modelle auf die algorithmische Ebene aus Kapitel 1 hier keine Anwendung.

Die wissenschaftliche Vorarbeit zu Nutzungsverhalten bezüglich der Verwendung von Online-Diensten, dem Ausgangspunkt des zweiten Themenschwerpunktes dieser Arbeit, kann überwiegend zwei Kategorien zugeteilt werden: der methodischen Diskussion um die Messung von Verhalten, Intentionen und Präferenzen (Dienlin & Trepte, 2015; Kokolakis, 2017) oder der Interpretation gezeigten Verhaltens nach normativen Gesichtspunkten (Acquisti, 2004, 2009; Acquisti & Grossklags, 2005; Dinev & Hart, 2006). An diesem Ansatz und der Überschneidung zu bayesianischer Entscheidungstheorie und Modellierung setzt das zweite Schwerpunktthema der Arbeit an. Da die bisherigen Hypothesen über grundlegende kognitive Prozesse, aus denen sich als Konsequenz das Privatsphären-Paradox ergeben soll, meines Wissens nach nicht formalisiert wurden, sind ihr Geltungsbereich und ihre Vorhersagen entsprechend unpräzise. Kokolakis (2017) erwähnt als am häufigsten erwähnte Gruppe dieser Hypothesen solche, die kognitive Verzerrungen und die Anwendung von Heuristiken als Konsequenz begrenzter kognitiver Ressourcen verstehen. Die vorherrschende Dichotomie zwischen heuristischem, irrationalem auf der einen und bayesianisch-nützlichkeitsmaximierendem, rationalem Verhalten auf der anderen Seite ließ sich ohne weiterführende Annahmen zunächst nur als Modellvergleich zwischen einem komputational

heuristischen und einem komputational bayesianischen Agenten interpretieren. Eine Formalisierung beider Ansätze, wobei die Take-the-best-Heuristik (Gigerenzer, 2008) am ehesten auf die Entscheidungssituation anwendbar war, offenbarte jedoch deterministische Entscheidungsregeln, die ohne zusätzliche Annahmen un plausible Vorhersagen machten und nur in einem Fall zufällig mit der Empirie zu vereinbaren waren. Die probabilistische Spezifikation von Heuristiken hat zwar in den vergangenen Jahren viele Fortschritte gemacht, aber ihre einfachste Form ist zunächst grundlegend deterministisch (Busemeyer, 2018). Auf dieselbe Art, wie eine einzige Verletzung der Maximierung subjektiver Nützlichkeit bayesianische Entscheidungstheorie (Peterson, 2009) ohne Zugeständnisse zur Notwendigkeit probabilistischen Verhaltens als Modell disqualifiziert, kann auch eine deterministische Anwendung der Take-the-best- oder einer beliebigen anderen Heuristik anhand einer Verletzung ihrer Prämisse disqualifiziert werden. Zwar kann diese Eigenschaft kaum Ziel kognitiver Modellierung oder derer sein, die solche Entscheidungsstrategien als Grundlage des von ihnen beobachteten Verhaltens heranziehen. Doch es muss berücksichtigt werden, dass heuristische Interpretationen speziell aufgrund ihrer komputational simplen Erscheinung, beispielsweise durch Berücksichtigung einer begrenzten Menge an Informationen, in der Erforschung von Nutzungsverhalten und der Entstehung des Privatsphären-Paradox herangezogen wurden (Norberg et al., 2007). Dieser Argumentation zu folgen, ohne explizite Aussagen über probabilistische Eigenschaften der betrachteten Entscheidungsstrategie zu treffen, unterstreicht den in Kapitel 1 erwähnten Bedarf an komputationaler Modellierung (Sun, 2008a) mitsamt ihrem vergleichsweise hohen Ausmaß an Formalisierung.

Die theoretische Erweiterung bayesianischer kognitiver Modelle auf die algorithmische Ebene (Srivastava & Vul, 2015) ist deshalb relevant für die Anwendung in der Domäne der Privatsphärenforschung, weil die Irrationalität, deren Entstehung in der Knappheit kognitiver Ressourcen begründet wird, dadurch nicht notwendigerweise mit einer Ablehnung bayesianischer Prinzipien einhergeht. Im Vergleich der Strukturen und Mechanismen der beiden in Kapitel 4 vorgestellten probabilistischen Modelle wird deutlich, dass sie beide das Potential haben, von ausgedrückten Präferenzen abweichendes und damit irrational erscheinendes Verhalten zu erzeugen. In Relation zu den empirischen Daten produzierte das rationale Prozessmodell dabei in der Mehrzahl aller betrachteten Stimuli bessere Vorhersagen. Dieses Ergebnis sollte im Hinblick auf den konsekutiven Charakter des Modellvergleichs nicht als Beilegung der in der Privatsphärenforschung geführten Debatte über Rationalität und Nutzungsverhalten zugunsten eines bayesianischen Ansatzes verstanden werden. Stattdessen bietet das rationale Prozessmodell zum gegenwärtigen Zeitpunkt die beste Approximation des beobachteten Verhaltens aus der Teilmenge betrachteter Modelle und somit einen theoretischen Ansatzpunkt, auf dessen Basis verhaltensmodifizierende Interventionen gestaltet werden können. Im weiteren Verlauf dieses Kapitels führe ich jedoch aus, warum die Konzentration auf paradigmatische Interpretationen beobachtbarer menschlicher Handlungsstrategien unter Umständen unangebracht ist und keine dauerhafte empirische Unterstützung finden wird.

Der dritte Themenschwerpunkt meiner Arbeit verglich die Vorhersage des in Kapitel 4 eingeführten und auf die Fragestellung von Kapitel 5 übertragenen rationalen Prozessmodells mit dem zweier seiner Sonderfälle. Diese Sonderfälle waren erstens ein Angleichungsmodell, das den Sonderfall des rationalen Prozessmodells beschränkt auf ein produziertes Sample darstellt, und das komputational bayesianische Modell, das bereits in Kapitel 4 Anwendung fand und ein rationales Prozessmodell mit unendlicher Anzahl produzierter Samples repräsentiert. Inhaltlich wurde die Wahrnehmung nonverbalen Flirtverhaltens modelliert, dessen Ambiguität seine Wahrnehmung als Entscheidung

unter Unsicherheit qualifiziert, aber im Gegensatz zum zweiten Themenschwerpunkt der Arbeit keine typischerweise mit dem Thema assoziierten Entscheidungsstrategien mit sich bringt. Das komputational bayesianische Modell scheiterte in seiner Vorhersage des Verhaltens an derselben mangelnden Spezifikation probabilistischen Verhaltens, die in diesem Kapitel bereits für die deterministischen Modelle aus Kapitel 4 besprochen wurde. Im Modellvergleich zwischen den beiden probabilistischen Modellvarianten unterlag das rationale Prozessmodell in neun von zehn Fällen. Für den Kontrast in seiner Vorhersageleistung zwischen Kapitel 4 und 5 gibt es keine aufgabenspezifischen Erklärungen. In Kapitel 5 war zwar keine Integration mehrerer Informationsquellen wie der Features in Kapitel 4 nötig, aber die Kürzung des Satzes von Bayes auf die Likelihood sollte kein computationales Problem darstellen, das den Verlust an Vorhersagekraft erklären könnte.

Der Hauptunterschied zwischen beiden Modellen lag in der Implementierung der Wissensrepräsentation des jeweiligen Agenten. Die Wissensrepräsentation des Agenten im rationalen Prozessmodell mit Hilfe des Erwartungswertes einer Beta-Verteilung wurde explizit zur Verhinderung des Zustandes gewählt, dass ein Agent nach einem erfolgreichen Sample eine interne Überzeugung von 100% bezüglich des Zutreffens einer Annahme hat. Dies sollte aufgrund von zwei Gründen verhindert werden: zunächst scheint es intuitiv plausibel, dass ein Agent die Anzahl der produzierten Samples in seine Einschätzung der Wahrscheinlichkeit des Zutreffens einer Annahme einbezieht. Bei einem Sample je nach Ausgang von 0% oder 100% Erfolgswahrscheinlichkeit auszugehen, produziert über mehrere Durchgänge zwar das empirisch zu beobachtende Angleichungsverhalten, harmonisiert aber zweitens nicht gut mit der in Gleichung 4.1 vorgestellten Regel zur Terminierung des Sampling-Prozesses. Die Berechnung des erwarteten Wertunterschieds zwischen Hypothesen sowie der Schwankungsanfälligkeit der Erfolgswahrscheinlichkeitsschätzung sorgt bei einem Sprung von einem Ausgangswert von 50% auf 0% oder 100% dafür, dass die Produktion eines zweiten Samples mit einer Wahrscheinlichkeit von 50% eintritt. Bedient sich der Agent hingegen der beschriebenen Methode über eine Beta-Verteilung, besteht eine Chance von 83%, ein zweites Sample zu produzieren. Diese Tendenz zur Produktion von mehr als einem Sample schien in der Formalisierung des Modells eine Eigenschaft zu sein, die die Differenzierung von Angleichungsverhalten ermöglicht. Im Modellvergleich entsteht der Eindruck, dass die Tendenz, weniger extreme Entscheidungswahrscheinlichkeiten vorherzusagen, hier zu größerer Evidenz für das Angleichungsmodell geführt hat. Auch für den dritten Themenschwerpunkt gilt, dass die Modellierung als Methode mit dem Anspruch des Erkenntnisgewinns bezüglich des betrachteten Phänomens durchgeführt wurde. In Bezug auf die Art der Wissensrepräsentation des Agenten gibt es meines Wissens nach keine Theorie, die a priori Aufschluss über eine geeignete Implementierung hätte geben können. Gleichzeitig handelt es sich hierbei um ein einflussreiches Charakteristikum der Modelle, das nur für den Fall des Angleichungsverhaltens hinreichend beschränkt ist. Im Sinne iterativer Modellbildung sollte der Aspekt der Wissensrepräsentation des Agenten als Beispiel eines Charakteristikums, das nicht explizit durch die zugrundeliegende Theorie beschränkt ist, stärker in künftige Modellvergleiche einbezogen werden.

6.2. Parameterschätzung und die Formalisierung des rationalen Prozessmodells

In dieser Arbeit wurde die Methode des Bayes Factors für den Modellvergleich gewählt. Dies war der Tatsache geschuldet, dass insbesondere die Themenschwerpunkte in Kapitel 3 und 4 spezifische Modellvarianten mit sich brachten, deren Parameterwerte in der Ermittlung der besseren Vorhersage weniger relevant waren, als die jeweilige Modellstruktur. Die in Kapitel 2.2 vorgestellten Informationskriterien zur Bewertung einer Modellvorhersage auf Basis an die Daten angepasster

Parameter hätten hierzu eine Alternative dargestellt. Zudem hätte die Verwendung von Methoden der Parameterschätzung die empirische Schätzung der Präferenzen über die Einordnung in Reihenfolgen in Kapitel 4 und die Paarvergleiche in Kapitel 5 abgelöst. Ein in der gegenwärtigen Fassung des rationalen Prozessmodells hinderlicher Faktor ist jedoch die Art, wie der Agent nach abgeschlossenem Sampling-Prozess die ermittelte Wahrscheinlichkeit einer Hypothese auf Basis der Anzahl produzierter Samples anpasst. Gleichung 1.2 beschreibt diesen Prozess nach Vul et al. (2014) und basiert auf der binomialen kumulativen Dichtefunktion. Für die Parameterschätzung stellt diese Formalisierung jedoch ein Problem dar. Behandelt man die Anzahl produzierter Samples als freien Parameter, statt sie über Gleichung 4.1 im Verlauf des Sampling-Prozesses zu ermitteln, steigt die Wahrscheinlichkeit des beobachteten Verhaltens mit steigender Anzahl produzierter Samples an. Ein Verfahren zur Parameterschätzung, das auf Basis dieser Formalisierung die Kombination an Parameterwerten ermittelt, die am wahrscheinlichsten das beobachtete Verhalten erzeugt, muss deshalb die höchstmögliche Anzahl produzierter Samples als wahrscheinlichsten Parameterwert annehmen und verzerrt dadurch die Schätzung anderer freier Parameter. Dieses Schätzungsverhalten klammert zudem den eigentlichen Nutzen der Sampling-Hypothese (Sanborn & Chater, 2016; Vul et al., 2014), nämlich den rationalen Umgang mit kognitiven Ressourcen bei der Lösung von Problemen, vollständig aus. In seiner gegenwärtigen Formalisierung kann das rationale Prozessmodell also nicht über auf die Parameterschätzung aufbauende Methoden evaluiert werden, was eine unerwünschte Eigenschaft des Modells darstellt. Gleichung 1.2 als Grund für diese Eigenschaft erfüllt in der Formalisierung von Vul et al. (2014) die Funktion, den Agenten bei steigender Anzahl produzierter Samples sicherer in der Einschätzung der Wahrscheinlichkeit einer Hypothese werden zu lassen. In ihrer Arbeit wurden zwar Simulationen zur Ermittlung der optimalen Sampling-Anzahl auf Basis dieser Formalisierung durchgeführt, aber eine Parameterschätzung im Sinn der in Kapitel 2.1 vorgestellten Methoden fand nicht statt. Die Agenteneigenschaft, bei steigender Sampling-Anzahl sicherer zu werden, ist zwar zunächst intuitiv nachvollziehbar. In weiteren Iterationen des Modells sollte sie aber auf eine Art implementiert werden, die Ressourcenrationalität des Agenten und die Schätzung freier Parameter gleichzeitig ermöglicht.

6.3. Einheitliche Anforderungen an psychologisch plausible kognitive Modelle

Sowohl Jones und Love (2011) als auch Bowers und Davis (2012) sehen unter den Vertretern bayesianischer kognitiver Modellierung einen Fokus auf die komputationale Ebene, der Annahmen und Spezifikationen zur algorithmischen Umsetzung von Handlungsstrategien außen vor lässt. Diese Problematik liegt bei ausschließlich komputationaler Betrachtung durchaus vor, aber Schritte zur Berücksichtigung und Integration algorithmischer Ansätze in bayesianischen kognitiven Modellen sind inzwischen ebenso etabliert (Griffiths, Vul, et al., 2012; Lieder et al., 2017; Sanborn & Chater, 2016; Srivastava & Vul, 2015; Vul et al., 2014). Durch diese Entwicklungen verschwimmen auch paradigmatische Grenzen in Bezug auf den normativen Charakter der Rationalität, der die wissenschaftliche Debatte lange Zeit geprägt hat (Hahn, 2014). Als Konsequenz dieser Entwicklung und als Ergebnis der Modellierung menschlichen Verhaltens in dieser Arbeit sammle ich hier Anforderungen an kognitive Modelle, die ich abseits etablierter datenanalytischer Modellkriterien wie Identifizierbarkeit oder Testbarkeit (Farrell & Lewandowsky, 2018) als notwendig oder zuträglich für den wissenschaftlichen Erkenntnisgewinn erachte. Ihre Erfüllung sollte ungeachtet der jeweiligen als Modell umgesetzten Theorie menschlichen Verhaltens möglich sein, damit empirische Befunde bezüglich menschlichen Erlebens und Verhaltens im jeweiligen Modell abgebildet werden können.

Teile dieser Anforderungen sind auf Probleme der Sensomotorik nicht direkt übertragbar und eher für die Entscheidungsmodellierung der Kapitel 4 und 5 relevant, andere sind jedoch auf alle vorgestellten Themenschwerpunkte anwendbar. Ich erhebe mit diesen Anforderungen keinen Anspruch auf Vollständigkeit und die domänenspezifische Relevanz weiterer menschlicher Verhaltensphänomene kann zur Erweiterung oder Modifizierung der Anforderungen führen. Anforderungen, die ich in dieser Arbeit postuliere, sind die Berücksichtigung grundlegender kognitiver Funktionen, die theorieinterne Erlaubnis probabilistischen Verhaltens, die Fähigkeit zur Modellierung individueller Unterschiede, die Generalisierbarkeit auf neue Datenpunkte und die Fähigkeit zur Integration bekannter empirischer Phänomene wie dem der Präferenzumkehr in der Entscheidungsforschung. In den folgenden Abschnitten argumentiere ich für die jeweilige Relevanz dieser Anforderungen.

Die Berücksichtigung grundlegender kognitiver Funktionen führt im Zusammenspiel der komputationalen und algorithmischen Ebene dazu, auf komputationaler Ebene paradox erscheinende Verhaltensweisen rationalisieren und besser vorhersagen zu können, wie beispielsweise in der Modellierung privatsphärenbezogenen Entscheidungsverhalten dieser Arbeit zu sehen ist. Murphy (2011) erwähnt zudem als mögliches Problem kognitiver Modellierung die Tendenz, kognitive Funktionen, die die Zusammenarbeit von Teilsystemen erfordern, unter Ausschluss einzelner dieser Teilsysteme zu betrachten. Dabei bietet speziell die notwendige Formalisierung kognitiver Modelle Anlass, notwendigerweise involvierte Teilsysteme zur Lösung eines Problems zu identifizieren. Für das Beispiel präferenzbasierter Entscheidungen kann man einem Agenten beispielsweise absolute, gleichzeitige Kenntnis und Verbalisierbarkeit all seiner möglichen Präferenzen unterstellen. Psychologisch plausibler ist jedoch die Erarbeitung einer Theorie zum Abruf von Informationen aus dem Gedächtnis. In dieser Arbeit bilden die Sampling-Hypothese (Sanborn & Chater, 2016; Vul et al., 2014) und die Theorie kontextsensitiven Präferenzlernens (Srivastava & Schrater, 2015; Srivastava & Vul, 2015) die Basis für diese Funktion. Für die hier modellierten Szenarien gehe ich von einer Entscheidung des Agenten direkt nach dem Abruf der nötigen Informationen aus, aber in anderen Szenarien ist beispielsweise eine Funktion zum Vergessen abgerufener Informationen notwendig, um beobachtetes menschliches Verhalten zu modellieren. Der Umfang nötiger berücksichtigter Funktionen ist damit domänenspezifisch festzulegen.

Die in dieser Arbeit vorgestellten Modelle unterschieden sich neben ihrem theoretischen Fundament auch in ihren Verhaltensweisen. So wurden sowohl probabilistisch als auch deterministisch agierende Agenten eingeführt. Viele Heuristiken sind in ihrer ursprünglichen Form deterministisch formuliert (Busemeyer, 2018), aber auch ein komputational bayesianischer Agent sollte in einem 2AFC-Szenario deterministisch die Option wählen, die seine subjektive Repräsentation von Nützlichkeit maximiert. Tatsächlich erwarten Vertreter dieser verschiedenen komputationalen Ansätze allerdings kein perfekt deterministisches Verhalten von Menschen, was bedeutet, dass die deterministischen Entscheidungsregeln ihrer Modellinstanzen als Konsequenzen unzureichender Formalisierung verstanden werden können. In der wissenschaftlichen Anwendung erreichen Modelle mit deterministischen Entscheidungsregeln probabilistische Vorhersagen durch Unsicherheit und Variabilität in der Parameterschätzung (Busemeyer, 2018). Damit ist der Modellvergleich leichter durchzuführen als in dieser Arbeit, weil deterministische Modelle nicht mehr die gesamte Wahrscheinlichkeitsdichte ihrer Vorhersagen auf einen Punkt zentrieren. Dieses Vorgehen legt aber nahe, dass modellierte Agenten nach einer hypothetischen perfekten Parameterfixierung kein probabilistisches Verhalten zeigen. Es sollte der interne Anspruch einer Theorie sein, etablierte Eigenschaften des modellierten Verhaltens als Prozesse innerhalb der Theorie zu verorten, statt sie als

schwer differenzierbare Messfehler anzuhängen. Deshalb ist die Erlaubnis für probabilistisches Verhalten modellierter Agenten eine wünschenswerte Eigenschaft des Modells. Gleichzeitig sollte die Parameterschätzung trotz der Modellierung von probabilistischem Verhalten innerhalb der Theorie möglich bleiben, was in der gegenwärtigen Iteration des rationalen Prozessmodells wie in Kapitel 6.2 erwähnt nicht möglich ist.

Die Modellierung individueller Unterschiede zwischen Agenten scheint eine offensichtlich notwendige Eigenschaft zu sein, solange Agenten unterschiedliche Eingangswerte zur Lösung des komputationalen Problems besitzen und zu unterschiedlichen Ergebnissen kommen dürfen. Der Fall des bayesianischen Modells für Kausalinferenz mit uniformem Prior in Kapitel 3 dieser Arbeit ist jedoch ein Beispiel dafür, wie spezielle Formalisierungen, die zunächst wenig mit der theoretischen Erlaubnis individueller Unterschiede zu tun haben, ihre Modellierung unterbinden. Im angeführten Beispiel führte der uniforme Prior zu einer Modellvorhersage, die ausschließlich aus dem Signalverhältnis der beteiligten sensorischen Kanäle bestand. Diese Formalisierung führte zum Ausschluss individueller Unterschiede in der Positionswahrnehmung vor Beginn der experimentellen Stimulation.

Gleichzeitig ist es eine wünschenswerte Modelleigenschaft, auf Basis bereits modellierter individueller Unterschiede auf neue Individuen generalisieren zu können. Bayesianische hierarchische Modellierung (Lee, 2011; Rouder et al., 2013) ist eine hierfür angemessene datenanalytische Methode, die auf der in Kapitel 2.1 vorgestellten bayesianischen Parameterschätzung fußt, aber davon ausgeht, dass Parameterwerte eines modellierten Individuums Samples aus einer Verteilung plausibler Parameterwerte über mehrere Individuen darstellen. Die Ermittlung der diese Verteilungen beschreibenden Hyper-Parameter ist Aufgabe hierarchischer Modellierung. Zudem bietet sie durch ihren Zielkonflikt, individuelle und gruppenspezifische Parameterwerte gleichzeitig zu schätzen, eine effektive Methode gegen Overfitting (Boos, Seer, Lange, & Kopp, 2016).

Zuletzt bringt speziell die kognitive Modellierung von entscheidungstheoretischen Phänomenen eine Sammlung etablierter Effekte wie Präferenzumkehr, Abhängigkeit von der dargebotenen Teilmenge an Optionen und anderer Axiomsverletzungen mit sich, die teilweise bereits als Konsequenz der bisherigen Anforderungen in diesem Teilkapitel abgebildet werden können. Beispielsweise ermöglicht die Modellierung des Abrufs von Informationen aus dem Gedächtnis über die Sampling-Hypothese (Vul et al., 2014) Präferenzumkehr, während die Theorie kontextsensitiven Präferenzlernens Kontexteffekte wie Ähnlichkeits-, Anziehungs-, Referenz- oder Kompromisseffekte abbilden kann (Srivastava & Schrater, 2015). Wann immer jedoch weitere grundlegende kognitive Funktionen für die hinreichend genaue Modellierung eines beobachteten Verhaltens berücksichtigt werden müssen, besteht auch die Notwendigkeit, die zugrundeliegende Theorie hinsichtlich der Fähigkeit zur Integration etablierter empirischer Effekte zu evaluieren.

Ich betrachte ein Modell dann als psychologisch plausibel, wenn es diese und in Abhängigkeit seines modellierten Gegenstands weitere Anforderungen erfüllen kann. Die in dieser Arbeit vorgestellten probabilistischen Modelle berücksichtigen entweder einen Prozess zum ressourcenbegrenzten Abruf von Informationen aus dem Gedächtnis, oder sie umgehen im Fall der probabilistischen Take-the-best-Heuristik den Abruf von Informationen aus dem Gedächtnis, indem sie die Informationen als bekannt annehmen und nur einen Teil davon in ihrer Entscheidungsregel weiterverarbeiten. Die probabilistischen Modelle benötigten für die Lösung ihres jeweiligen komputationalen Problems keinen Vergessensprozess. Gleichzeitig bieten inhaltliche Domänen wie der Themenschwerpunkt von Kapitel 4 das Potential, von der Funktion affektiver Komponenten beeinflusst zu sein. Das affektive

System ist jedoch eine in großen Teilen der kognitiven Modellierung und im rationalen Prozessmodell ausgeklammerte Komponente (Van de Cruys, 2017). Das rationale Prozessmodell und das Angleichungsmodell ermöglichen über die Produktion interner Samples probabilistisches Verhalten, während die probabilistische Take-the-best-Heuristik probabilistisches Verhalten über die Betrachtungsreihenfolge von Optionsattributen erzeugt. Alle drei Modelle ermöglichen individuelle Unterschiede, treffen aber durch das Fehlen einer hierarchischen Struktur keine Aussage über unbeobachtete Individuen. Der Implementierung einer hierarchischen Struktur steht bislang noch die Modellkomponente der Anpassung einer Wahlwahrscheinlichkeit durch die binomiale kumulative Dichtefunktion im rationalen Prozessmodell im Weg. Als Konsequenz war die Modellevaluation in dieser Arbeit nur über Bayes Factors möglich.

Dies führte dazu, dass die deterministischen Modelle dieser Arbeit nicht von probabilistischen Vorhersagen auf Basis von Unsicherheit in der Parameterschätzung profitieren konnten, was ihre unzureichende Formalisierung hinsichtlich der Erlaubnis probabilistischen Verhaltens offenbarte. Zudem berücksichtigen sie keine grundlegenden kognitiven Funktionen, weil ihr Geltungsbereich auf die komputationale Ebene beschränkt ist. Sie ermöglichen individuelle Unterschiede und eine hierarchische Parameterstruktur zur Vorhersage neuer Datenpunkte, bieten aber ohne weiterführende Annahmen kein theoretisches Fundament, aus dem sich die Existenz entscheidungstheoretischer Phänomene und Axiomsverletzungen ableitet.

Das bayesianische Modell für Kausalinferenz beschränkt sich auf die komputationale Ebene, hat aber durch seinen Fokus auf eine sensorische Fragestellung einen stärkeren Bezug zur Implementierungs- als zur algorithmischen Ebene. Gedächtnis-, Vergessens- und affektive Funktionen sind hier eher irrelevant. Das Modell erlaubt probabilistisches Verhalten und individuelle Unterschiede unter Einbezug eines informierten Priors. Eine hierarchische Struktur zur Generalisierung auf neue Datenpunkte war für den beschriebenen Modellvergleich nicht nötig, kann allerdings die Schätzung individueller sensorischer Präzisionsparameter ermöglichen. Eine solche Struktur dürfte die Vorhersagefähigkeit des Modells bezüglich der Auswirkung von Körperillusionen verbessern. Entscheidungstheoretische Axiome waren für das bayesianische Modell für Kausalinferenz in dieser Arbeit nicht relevant.

6.4. Rationale Strategien oder rationale Strategieauswahl?

In der Darstellung unterschiedlicher Paradigmen kognitiver Modellierung in Kapitel 1.5 wurde deutlich, dass sich Theorien menschlicher Kognition zwar in der verwendeten Herleitung und Grammatik unterscheiden, aber stellenweise so viele inhaltliche Übereinstimmungen bieten, dass die Zuordnung in nur ein Paradigma schwerfällt. Zudem zeigt die Auflistung von Anforderungen an psychologisch plausible kognitive Modelle in Kapitel 6.3, dass ihre Erfüllung nicht von einer spezifischen Theorie abhängt. Erfüllt ein Modell also hinreichend viele dieser Kriterien, hat es bereits viele Freiheitsgrade erzeugbaren Verhaltens fixiert, die es von einem anderen Modell mit ähnlichem Ausmaß psychologischer Plausibilität unterscheidbar machen. Ein Beispiel hierfür ist das rationale Prozessmodell, das sich durch seine algorithmische Spezifikation flexibel zwischen Angleichungs- und Maximierungsverhalten positioniert und beide als theoretische Sonderfälle vereinnahmt. Die theoretischen Herleitungen zum Umgang mit begrenzten kognitiven Ressourcen zwischen heuristischen und rationalen Prozessmodellen weisen ebenfalls argumentative Ähnlichkeiten auf, bis sie sich in ihrer komputationalen Umsetzung der jeweiligen Entscheidungsstrategie unterscheiden. In

Anbetracht der Anzahl notwendigerweise geteilter Eigenschaften in den formalisierten Umsetzungen der jeweiligen Theorien ist es überraschend, dass der Anspruch auf grundlegend rationale oder grundlegend irrationale Darstellungen menschlicher Entscheidungsstrategien bis heute mit großer Überzeugung vertreten wird. Durch die Ausweitung auf die algorithmische Ebene folgen bayesianische kognitive Modelle keiner rein rationalen Strategie im Sinne einer statischen, ressourcenunabhängigen Nützlichkeitsmaximierung mehr. Gleichzeitig kann die Verwendung lokal irrationaler Strategien aus einem ressourcenrationalem Prozess der Strategieauswahl resultieren (Lieder & Griffiths, 2015; Lieder et al., 2017; Lieder, Shenhav, Musslick, & Griffiths, 2018). Ich betrachte daher den Fokus auf metakognitive Methoden der Strategieauswahl und Ressourcenzuweisung als vielversprechende Perspektive für die Integration diverser Theorien menschlicher Kognition.

Ich habe in dieser Arbeit bayesianische kognitive Modelle auf menschliche Verhaltensphänomene in drei Themenschwerpunkten angewandt, die im Zusammenhang mit menschlichem Erleben und Verhalten in einer unsicherheitsbehafteten Umwelt stehen. Durch die Anpassung bestehender Parametrisierung oder die erstmalige Formalisierung als kognitive Modelle wurden in den jeweiligen Domänen neue inhaltliche und modelltheoretische Kenntnisse erzeugt. Die Arbeit unterstreicht damit das Potential kognitiver Modellierung für Forschungsgebiete der Psychologie, die bislang verbaltheoretisch oder mathematisch dominiert waren. Dabei stellt bayesianische kognitive Modellierung einen von mehreren vielversprechenden Ansätzen dar, um mit zunehmender Berücksichtigung mehrerer Ebenen der Analyse die große Anzahl domänenspezifischer psychologischer Theorien zugunsten einer übergreifenden Theorie abzulösen.

Literaturverzeichnis

- Acquisti, A. (2004). *Privacy in electronic commerce and the economics of immediate gratification*. 21. <https://doi.org/10.1145/988772.988777>
- Acquisti, A. (2009). Nudging privacy: The behavioral economics of personal information. *IEEE Security & Privacy Magazine*, 7(6), 82–85.
<https://doi.org/10.1109/MSP.2009.163>
- Acquisti, A., & Grossklags, J. (2005). Privacy and rationality in individual decision making. *IEEE Security and Privacy Magazine*, 3(1), 26–33.
<https://doi.org/10.1109/MSP.2005.22>
- Baker, C. L., & Tenenbaum, J. B. (2014). Modeling human plan recognition using Bayesian Theory of Mind. In *Plan, Activity, and Intent Recognition* (pp. 177–204).
<https://doi.org/10.1016/B978-0-12-398532-3.00007-5>
- Beckerle, P., De Beir, A., Schurmann, T., & Caspar, E. A. (2016, August). *Human body schema exploration: Analyzing design requirements of Robotic Hand and Leg Illusions*. 763–768. <https://doi.org/10.1109/ROMAN.2016.7745205>
- Beckerle, P., Salvietti, G., Unal, R., Prattichizzo, D., Rossi, S., Castellini, C., ... Bianchi, M. (2017). A human–robot interaction perspective on assistive and rehabilitation robotics. *Frontiers in Neurorobotics*, 11. <https://doi.org/10.3389/fnbot.2017.00024>
- Beller, S., & Bender, A. (2017). Theory, the final frontier? A corpus-based analysis of the role of theory in psychological articles. *Frontiers in Psychology*, 8.
<https://doi.org/10.3389/fpsyg.2017.00951>
- Bergert, F. B., & Nosofsky, R. M. (2007). A response-time approach to comparing generalized rational and take-the-best models of decision making. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 33(1), 107–129.
<https://doi.org/10.1037/0278-7393.33.1.107>

- Berniker, M., & Kording, K. (2011). Bayesian approaches to sensory integration for motor control. *Wiley Interdisciplinary Reviews: Cognitive Science*, 2(4), 419–428.
<https://doi.org/10.1002/wcs.125>
- Bitzer, S., Park, H., Blankenburg, F., & Kiebel, S. J. (2014). Perceptual decision making: drift-diffusion model is equivalent to a Bayesian model. *Frontiers in Human Neuroscience*, 8. <https://doi.org/10.3389/fnhum.2014.00102>
- Bonawitz, E., Denison, S., Gopnik, A., & Griffiths, T. L. (2014). Win-Stay, Lose-Sample: A simple sequential algorithm for approximating Bayesian inference. *Cognitive Psychology*, 74, 35–65. <https://doi.org/10.1016/j.cogpsych.2014.06.003>
- Boos, M., Seer, C., Lange, F., & Kopp, B. (2016). Probabilistic inference: task dependency and individual differences of probability weighting Revealed by hierarchical Bayesian modeling. *Frontiers in Psychology*, 7. <https://doi.org/10.3389/fpsyg.2016.00755>
- Botvinick, M., & Cohen, J. (1998). Rubber hands “feel” touch that eyes see. *Nature*, 391, 756.
- Bowers, J. S., & Davis, C. J. (2012). Bayesian just-so stories in psychology and neuroscience. *Psychological Bulletin*, 138(3), 389–414. <https://doi.org/10.1037/a0026450>
- Box, G. E., & Draper, N. R. (1987). *Empirical model-building and response surfaces*. New York: John Wiley & Sons.
- Busemeyer, J. R. (2018). Old and new directions in strategy selection. *Journal of Behavioral Decision Making*, 31(2), 199–202. <https://doi.org/10.1002/bdm.2005>
- Busemeyer, J. R., & Johnson, J. G. (2008). Micro-process models of decision making. *Cambridge Handbook of Computational Psychology*, 302, 321.
- Busemeyer, J. R., & Townsend, J. T. (1993). Decision field theory: a dynamic-cognitive approach to decision making in an uncertain environment. *Psychological Review*, 100(3), 432.
- Caspar, E. A., De Beir, A., Magalhaes De Saldanha Da Gama, P. A., Yernaux, F., Cleeremans, A., & Vanderborcht, B. (2015). New frontiers in the rubber hand

- experiment: when a robotic hand becomes one's own. *Behavior Research Methods*, 47(3), 744–755. <https://doi.org/10.3758/s13428-014-0498-3>
- Chasalow, S. (2012). *combinat: combinatorics utilities*. Retrieved from <https://CRAN.R-project.org/package=combinat>
- Chater, N., Goodman, N., Griffiths, T. L., Kemp, C., Oaksford, M., & Tenenbaum, J. B. (2011). The imaginary fundamentalists: The unshocking truth about Bayesian cognitive science. *Behavioral and Brain Sciences*, 34(04), 194–196. <https://doi.org/10.1017/S0140525X11000239>
- Chown, E. (2014). Cognitive Modeling. In *Computing Handbook, Third Edition: Computer Science and Software Engineering* (pp. 43: 1–13).
- Christ, O., Elger, A., Schneider, K., Rapp, A., & Beckerle, P. (2013, March 14). *Identification of haptic paths with different resolution and their effect on body scheme illusion in lower limbs*. Presented at the European Conference on Technically Assisted Rehabilitation (TAR-2013), Berlin, Germany.
- Christ, O., & Reiner, M. (2014). Perspectives and possible applications of the rubber hand and virtual hand illusion in non-invasive rehabilitation: Technological improvements and their consequences. *Neuroscience & Biobehavioral Reviews*, 44, 33–44. <https://doi.org/10.1016/j.neubiorev.2014.02.013>
- Clark, A. (2013). Whatever next? Predictive brains, situated agents, and the future of cognitive science. *Behavioral and Brain Sciences*, 36(3), 181–204.
- Crea, S., D'Alonzo, M., Vitiello, N., & Cipriani, C. (2015). The rubber foot illusion. *Journal of NeuroEngineering and Rehabilitation*, 12(1). <https://doi.org/10.1186/s12984-015-0069-6>
- Daunizeau, J., den Ouden, H. E. M., Pessiglione, M., Kiebel, S. J., Stephan, K. E., & Friston, K. J. (2010). Observing the observer (I): Meta-Bayesian models of learning and

- decision-making. *PLoS ONE*, 5(12), e15554.
<https://doi.org/10.1371/journal.pone.0015554>
- Deneve, S., & Pouget, A. (2004). Bayesian multisensory integration and cross-modal spatial links. *Journal of Physiology-Paris*, 98(1–3), 249–258.
<https://doi.org/10.1016/j.jphysparis.2004.03.011>
- Dienlin, T., & Trepte, S. (2015). Is the privacy paradox a relic of the past? An in-depth analysis of privacy attitudes and privacy behaviors: The relation between privacy attitudes and privacy behaviors. *European Journal of Social Psychology*, 45(3), 285–297. <https://doi.org/10.1002/ejsp.2049>
- Dinev, T., & Hart, P. (2006). An extended privacy calculus model for E-Commerce transactions. *Information Systems Research*, 17(1), 61–80.
<https://doi.org/10.1287/isre.1060.0080>
- Domurat, A., Kowalczyk, O., Idzikowska, K., Borzymowska, Z., & Nowak-Przygodzka, M. (2015). Bayesian probability estimates are not necessary to make choices satisfying Bayes' rule in elementary situations. *Frontiers in Psychology*, 6.
<https://doi.org/10.3389/fpsyg.2015.01194>
- Doya, K. (Ed.). (2011). *Bayesian brain: probabilistic approaches to neural coding* (1. MIT Press paperback ed). In (1. MIT Press paperback ed). Cambridge, Mass.: MIT Press.
- Eddy, D. M. (1982). Probabilistic reasoning in clinical medicine: Problems and opportunities. In D. Kahneman, P. Slovic, & A. Tversky (Eds.), *Judgment under uncertainty* (pp. 249–267). Retrieved from
<http://ebooks.cambridge.org/ref/id/CBO9780511809477A031>
- Ehrsson, H. H., Rosen, B., Stocksélius, A., Ragnö, C., Köhler, P., & Lundborg, G. (2008). Upper limb amputees can be induced to experience a rubber hand as their own. *Brain*, 131(12), 3443–3452. <https://doi.org/10.1093/brain/awn297>
- Eisenfuhr, F., Weber, M., & Langer, T. (2010). *Rational decision making*. Springer Berlin.

- Farkaš, I. (2012). Indispensability of computational modeling in cognitive science. *Journal of Cognitive Science*, *13*(12), 401–435.
- Farrell, S., & Lewandowsky, S. (2018). *Computational Modeling of Cognition and Behavior* (1st ed.). <https://doi.org/10.1017/CBO9781316272503>
- Flögel, M., Beckerle, P., & Christ, O. (2014). Rubber hand and rubber foot illusion: a comparison and perspective in rehabilitation. *Clinical Neurophysiology*, *125*, S113. [https://doi.org/10.1016/S1388-2457\(14\)50371-9](https://doi.org/10.1016/S1388-2457(14)50371-9)
- Flögel, M., Kalveram, K., Christ, O., & Vogt, J. (2015). Application of the rubber hand illusion paradigm: comparison between upper and lower limbs. *Psychological Research*. <https://doi.org/10.1007/s00426-015-0650-4>
- Frank, M. C., & Goodman, N. D. (2014). Inferring word meanings by assuming that speakers are informative. *Cognitive Psychology*, *75*, 80–96. <https://doi.org/10.1016/j.cogpsych.2014.08.002>
- Friston, K. J., & Stephan, K. E. (2007). Free-energy and the brain. *Synthese*, *159*(3), 417–458.
- Gelman, A., Hwang, J., & Vehtari, A. (2014). Understanding predictive information criteria for Bayesian models. *Statistics and Computing*, *24*(6), 997–1016. <https://doi.org/10.1007/s11222-013-9416-2>
- Gershman, S. J., Horvitz, E. J., & Tenenbaum, J. B. (2015). Computational rationality: A converging paradigm for intelligence in brains, minds, and machines. *Science*, *349*(6245), 273–278.
- Gigerenzer, G. (2008). Why heuristics work. *Perspectives on Psychological Science*, *3*(1), 20–29. <https://doi.org/10.1111/j.1745-6916.2008.00058.x>
- Gigerenzer, G. (2010). Personal reflections on theory and psychology. *Theory & Psychology*, *20*(6), 733–743. <https://doi.org/10.1177/0959354310378184>
- Gigerenzer, G., & Selten, R. (2002). *Bounded rationality: The adaptive toolbox*. Cambridge, Mass.: MIT press.

- Gigerenzer, G., & Todd, P. M. (2001). *Simple heuristics that make us smart* (1. issued as an Oxford Univ. Press paperback). In *Evolution and Cognition* (1. issued as an Oxford Univ. Press paperback). Oxford: Oxford Univ. Press.
- Giummarra, M. J., Gibson, S. J., Georgiou-Karistianis, N., & Bradshaw, J. L. (2008). Mechanisms underlying embodiment, disembodiment and loss of embodiment. *Neuroscience & Biobehavioral Reviews*, 32(1), 143–160.
<https://doi.org/10.1016/j.neubiorev.2007.07.001>
- Goldstein, D. G., & Gigerenzer, G. (2002). Models of ecological rationality: The recognition heuristic. *Psychological Review*, 109(1), 75–90. <https://doi.org/10.1037//0033-295X.109.1.75>
- Goodman, N. D., & Stuhlmüller, A. (2013). Knowledge and implicature: Modeling language understanding as social cognition. *Topics in Cognitive Science*, 5(1), 173–184.
<https://doi.org/10.1111/tops.12007>
- Goodman, N. D., Tenenbaum, J. B., Feldman, J., & Griffiths, T. L. (2008). A rational analysis of rule-based concept learning. *Cognitive Science*, 32(1), 108–154.
- Graefe, A., & Armstrong, J. S. (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. <https://doi.org/10.1002/bdm.710>
- Griffiths, T. L., Chater, N., Norris, D., & Pouget, A. (2012). How the Bayesians got their beliefs (and what those beliefs actually are): Comment on Bowers and Davis (2012). *Psychological Bulletin*, 138(3), 415–422. <https://doi.org/10.1037/a0026884>
- Griffiths, T. L., Lieder, F., & Goodman, N. D. (2015). Rational use of cognitive resources: Levels of analysis between the computational and the algorithmic. *Topics in Cognitive Science*, 7(2), 217–229. <https://doi.org/10.1111/tops.12142>

- Griffiths, T. L., Vul, E., & Sanborn, A. N. (2012). Bridging levels of analysis for probabilistic models of cognition. *Current Directions in Psychological Science*, *21*(4), 263–268.
<https://doi.org/10.1177/0963721412447619>
- Hahn, U. (2014). The Bayesian boom: good thing or bad? *Frontiers in Psychology*, *5*.
<https://doi.org/10.3389/fpsyg.2014.00765>
- Hall, J. A., Carter, S., Cody, M. J., & Albright, J. M. (2010). Individual differences in the communication of romantic interest: Development of the Flirting Styles Inventory. *Communication Quarterly*, *58*(4), 365–393.
<https://doi.org/10.1080/01463373.2010.524874>
- Hall, J. A., Xing, C., & Brooks, S. (2015). Accurately detecting flirting: Error Management Theory, the traditional sexual script, and flirting base rate. *Communication Research*, *42*(7), 939–958. <https://doi.org/10.1177/0093650214534972>
- Henningsen, D. D. (2004). Flirting with meaning: An examination of miscommunication in flirting interactions. *Sex Roles*, *50*(7/8), 481–489.
<https://doi.org/10.1023/B:SERS.0000023068.49352.4b>
- Hertwig, R., Barron, G., Weber, E. U., & Erev, I. (2004). Decisions from Experience and the effect of rare events in risky choice. *Psychological Science*, *15*(8), 534–539.
<https://doi.org/10.1111/j.0956-7976.2004.00715.x>
- Hirsh, I. J., & Sherrick, C. E., Jr. (1961). Perceived order in different sense modalities. *Journal of Experimental Psychology*, *62*(5), 423–432.
<https://doi.org/10.1037/h0045283>
- Hoffmann, C. P., Lutz, C., & Ranzini, G. (2016). Privacy cynicism: A new approach to the privacy paradox. *Cyberpsychology: Journal of Psychosocial Research on Cyberspace*, *10*(4). <https://doi.org/10.5817/CP2016-4-7>

- Hong, Y. (2013a). On computing the distribution function for the Poisson binomial distribution. *Computational Statistics & Data Analysis*, 59, 41–51.
<https://doi.org/10.1016/j.csda.2012.10.006>
- Hong, Y. (2013b). *poibin: The poisson binomial distribution*. Retrieved from
<https://CRAN.R-project.org/package=poibin>
- Jara-Ettinger, J., Gweon, H., Schulz, L. E., & Tenenbaum, J. B. (2016). The Naïve Utility Calculus: Computational principles underlying commonsense psychology. *Trends in Cognitive Sciences*, 20(8), 589–604. <https://doi.org/10.1016/j.tics.2016.05.011>
- Jeffreys, H. (1998). *Theory of probability* (3rd ed). In *Oxford Classic Texts in the Physical Sciences* (3rd ed). Oxford: Clarendon Press ; Oxford University Press.
- Jones, M., & Love, B. C. (2011). Bayesian Fundamentalism or Enlightenment? On the explanatory status and theoretical contributions of Bayesian models of cognition. *Behavioral and Brain Sciences*, 34(04), 169–188.
<https://doi.org/10.1017/S0140525X10003134>
- Jones, M. N. (2016). Developing cognitive theory by mining large-scale naturalistic data. In *Big data in cognitive science* (pp. 1–12).
- Jones, S., Cressman, E. K., & Henriques, D. Y. P. (2010). Proprioceptive localization of the left and right hands. *Experimental Brain Research*, 204(3), 373–383.
<https://doi.org/10.1007/s00221-009-2079-8>
- Kahneman, D., & Tversky, A. (1979). Prospect Theory: An analysis of decision under risk. *Econometrica*, 47(2), 263. <https://doi.org/10.2307/1914185>
- Kehr, F., Kowatsch, T., Wentzel, D., & Fleisch, E. (2015). Blissfully ignorant: the effects of general privacy concerns, general institutional trust, and affect in the privacy calculus: Privacy calculus: dispositions and affect. *Information Systems Journal*, 25(6), 607–635. <https://doi.org/10.1111/isj.12062>

- Kehr, F., Wentzel, D., & Kowatsch, T. (2014). Privacy Paradox revised: Pre-existing attitudes, psychological ownership, and actual disclosure. *Thirty Fifth International Conference on Information Systems*. Presented at the Auckland. Auckland.
- Knill, D. C., & Pouget, A. (2004). The Bayesian brain: the role of uncertainty in neural coding and computation. *TRENDS in Neurosciences*, 27(12), 712–719.
- Knill, D. C., & Richards, W. (Eds.). (1996). *Perception as Bayesian Inference*.
<https://doi.org/10.1017/CBO9780511984037>
- Kokolakis, S. (2017). Privacy attitudes and privacy behaviour: A review of current research on the privacy paradox phenomenon. *Computers & Security*, 64, 122–134.
<https://doi.org/10.1016/j.cose.2015.07.002>
- Kolb, N., Bartsch, S., Volkamer, M., & Vogt, J. (2014). Capturing attention for warnings about insecure password fields – systematic development of a passive security intervention. In T. Tryfonas & I. Askoxylakis (Eds.), *Human Aspects of Information Security, Privacy, and Trust* (pp. 172–182). Retrieved from
http://dx.doi.org/10.1007/978-3-319-07620-1_16
- Körding, K. P., Beierholm, U., Ma, W. J., Quartz, S., Tenenbaum, J. B., & Shams, L. (2007). Causal inference in multisensory perception. *PLoS ONE*, 2(9), e943.
<https://doi.org/10.1371/journal.pone.0000943>
- Körding, K. P., & Wolpert, D. M. (2006). Bayesian decision theory in sensorimotor control. *Trends in Cognitive Sciences*, 10(7), 319–326.
<https://doi.org/10.1016/j.tics.2006.05.003>
- Krasnova, H., Kolesnikova, E., & Günther, O. (2009). “It won’t happen to me!”: self-disclosure in online social networks. Presented at the 15th Americas Conference on Information Systems (AMCIS 2009), Atlanta, Georgia.
- Kruschke, J. K. (2008). Bayesian approaches to associative learning: From passive to active learning. *Learning & Behavior*, 36(3), 210–226. <https://doi.org/10.3758/LB.36.3.210>

- Kruschke, J. K. (2010). What to believe: Bayesian methods for data analysis. *Trends in Cognitive Sciences*, 14(7), 293–300. <https://doi.org/10.1016/j.tics.2010.05.001>
- Kruschke, J. K. (2015). *Doing Bayesian data analysis: a tutorial with R, JAGS, and stan* (2E [edition]). Boston: Academic Press.
- Kruschke, J. K., Aguinis, H., & Joo, H. (2012). The time has come: Bayesian methods for data analysis in the organizational sciences. *Organizational Research Methods*, 15(4), 722–752. <https://doi.org/10.1177/1094428112457829>
- Lee, H., Park, H., & Kim, J. (2013). Why do people share their context information on Social Network Services? A qualitative study and an experimental study on users' behavior of balancing perceived benefit and risk. *International Journal of Human-Computer Studies*, 71(9), 862–877. <https://doi.org/10.1016/j.ijhcs.2013.01.005>
- Lee, M. D. (2011). How cognitive modeling can benefit from hierarchical Bayesian models. *Journal of Mathematical Psychology*, 55(1), 1–7.
- Lee, M. D., & Wagenmakers, E.-J. (2013). *Bayesian Cognitive Modeling: A Practical Course*. <https://doi.org/10.1017/CBO9781139087759>
- Lenggenhager, B., Hilti, L., & Brugger, P. (2015). Disturbed body integrity and the “rubber foot illusion”. *Neuropsychology*, 29(2), 205–211. <https://doi.org/10.1037/neu0000143>
- Lichtenstein, S., & Slovic, P. (1971). Reversals of preference between bids and choices in gambling decisions. *Journal of Experimental Psychology*, 89(1), 46.
- Lieder, F., & Griffiths, T. L. (2015). When to use which heuristic: A rational solution to the strategy selection problem. *CogSci*.
- Lieder, F., Griffiths, T. L., M. Huys, Q. J., & Goodman, N. D. (2017). The anchoring bias reflects rational use of cognitive resources. *Psychonomic Bulletin & Review*. <https://doi.org/10.3758/s13423-017-1286-8>

- Lieder, F., Hsu, M., & Griffiths, T. L. (2014). The high availability of extreme events serves resource-rational decision-making. *Proceedings of the Annual Meeting of the Cognitive Science Society*, 36.
- Lieder, F., Shenhav, A., Musslick, S., & Griffiths, T. L. (2018). Rational metareasoning and the plasticity of cognitive control. *PLoS Computational Biology*, 14(4), e1006043.
- Lilienfeld, S. O., & Waldman, I. D. (Eds.). (2017). *Psychological science under scrutiny: Recent challenges and proposed solutions*. <https://doi.org/10.1002/9781119095910>
- Luce, R. D. (1959). *Individual choice behavior: A theoretical analysis*. Oxford: Courier Corporation.
- Luce, R. D., & Raiffa, H. (2012). *Games and decisions: Introduction and critical survey*. Oxford: Courier Corporation.
- Lutz, C., & Strathoff, P. (2014). Privacy concerns and online behavior not so paradoxical after all? Viewing the Privacy Paradox through different theoretical lenses. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2425132>
- Ma, W. J., Beck, J. M., Latham, P. E., & Pouget, A. (2006). Bayesian inference with probabilistic population codes. *Nature Neuroscience*, 9(11), 1432–1438. <https://doi.org/10.1038/nn1790>
- Marr, D. (1982). *Vision: A computational investigation into the human representation and processing of visual information*. Cambridge, Mass.: MIT Press.
- Moore, M. M. (1985). Nonverbal courtship patterns in women. *Ethology and Sociobiology*, 6(4), 237–247. [https://doi.org/10.1016/0162-3095\(85\)90016-0](https://doi.org/10.1016/0162-3095(85)90016-0)
- Morgenstern, O., & Von Neumann, J. (1953). *Theory of games and economic behavior*. Princeton, N.J.: Princeton university press.
- Moseley, G. L., Gallace, A., & Spence, C. (2012). Bodily illusions in health and disease: Physiological and clinical perspectives and the concept of a cortical ‘body matrix.’

- Neuroscience & Biobehavioral Reviews*, 36(1), 34–46.
<https://doi.org/10.1016/j.neubiorev.2011.03.013>
- Murphy, G. (2011). The contribution (and drawbacks) of models to the study of concepts. In E. Pothos & A. Willis (Eds.), *Formal Approaches in Categorization* (pp. 299–312). Cambridge University Press.
- Neupärtl, N., & Rothkopf, C. (2018). Perceptual explaining away in depth judgements. *Journal of Vision*, 18(10), 660. <https://doi.org/10.1167/18.10.660>
- Norberg, P. A., Horne, D. R., & Horne, D. A. (2007). The Privacy Paradox: Personal information disclosure intentions versus behaviors. *Journal of Consumer Affairs*, 41(1), 100–126. <https://doi.org/10.1111/j.1745-6606.2006.00070.x>
- O’Farrell, K. J., Rosenthal, E. N., & O’Neal, E. C. (2003). Relationship satisfaction and responsiveness to nonmates’ flirtation: testing an evolutionary explanation. *Journal of Social and Personal Relationships*, 20(5), 663–674.
<https://doi.org/10.1177/02654075030205005>
- Open Science Collaboration. (2015). Estimating the reproducibility of psychological science. *Science*, 349(6251), aac4716–aac4716. <https://doi.org/10.1126/science.aac4716>
- Orbán, G., & Wolpert, D. M. (2011). Representations of uncertainty in sensorimotor control. *Current Opinion in Neurobiology*, 21(4), 629–635.
<https://doi.org/10.1016/j.conb.2011.05.026>
- Perfors, A., Tenenbaum, J. B., Griffiths, T. L., & Xu, F. (2011). A tutorial introduction to Bayesian models of cognitive development. *Cognition*, 120(3), 302–321.
<https://doi.org/10.1016/j.cognition.2010.11.015>
- Peterson, M. (2009). *An introduction to decision theory*. In *Cambridge Introductions to Philosophy*. New York: Cambridge University Press.
- Popper, K. (2005). *The logic of scientific discovery*. London: Routledge.

- R Core Team. (2017). *R: A language and environment for statistical computing*. Retrieved from <https://www.R-project.org/>
- Ratcliff, R., Smith, P. L., Brown, S. D., & McKoon, G. (2016). Diffusion decision model: current issues and history. *Trends in Cognitive Sciences*, *20*(4), 260–281.
- Renninger, L. A., Wade, T. J., & Grammer, K. (2004). Getting that female glance. *Evolution and Human Behavior*, *25*(6), 416–431.
<https://doi.org/10.1016/j.evolhumbehav.2004.08.006>
- Robbins, S., Waked, E., Allard, P., McClaran, J., & Krouglicof, N. (1997). Foot position awareness in younger and older men: The influence of footwear sole properties. *Journal of the American Geriatrics Society*, *45*(1), 61–66.
<https://doi.org/10.1111/j.1532-5415.1997.tb00979.x>
- Robbins, S., Waked, E., & McClaran, J. (1995). Proprioception and stability: Foot position awareness as a function of age and footwear. *Age and Ageing*, *24*(1), 67–72.
<https://doi.org/10.1093/ageing/24.1.67>
- Roberts, S., & Pashler, H. (2000). How persuasive is a good fit? A comment on theory testing. *Psychological Review*, *107*(2), 358–367.
- Rouder, J. N., Morey, R. D., & Pratte, M. S. (2013). Hierarchical Bayesian models. *Practice*, *1*(5), 10.
- Rouder, J. N., Speckman, P. L., Sun, D., Morey, R. D., & Iverson, G. (2009). Bayesian t tests for accepting and rejecting the null hypothesis. *Psychonomic Bulletin & Review*, *16*(2), 225–237. <https://doi.org/10.3758/PBR.16.2.225>
- RStudio Team. (2015). *RStudio: Integrated development environment for R*. Retrieved from <http://www.rstudio.com/>
- Samad, M., Chung, A. J., & Shams, L. (2015). Perception of body ownership is driven by Bayesian sensory inference. *PLOS ONE*, *10*(2), e0117178.
<https://doi.org/10.1371/journal.pone.0117178>

- Sanborn, A. N., & Chater, N. (2016). Bayesian Brains without Probabilities. *Trends in Cognitive Sciences*, 20(12), 883–893. <https://doi.org/10.1016/j.tics.2016.10.003>
- Sanborn, A. N., Griffiths, T. L., & Navarro, D. J. (2010). Rational approximations to rational models: Alternative algorithms for category learning. *Psychological Review*, 117(4), 1144–1167. <https://doi.org/10.1037/a0020511>
- Schürmann, T., Overath, P., Christ, O., Vogt, J., & Beckerle, P. (2015, September). *Exploration of lower limb body schema integration with respect to body-proximal robotics*. 61–65. <https://doi.org/10.1109/RTSI.2015.7325072>
- Schürmann, Tim, Mohler, B. J., Peters, J., & Beckerle, P. (2019). How cognitive models of human body experience might push robotics. *Frontiers in Neurorobotics*, 13, 14.
- Shanks, D. R., Tunney, R. J., & McCarthy, J. D. (2002). A re-examination of probability matching and rational choice. *Journal of Behavioral Decision Making*, 15(3), 233–250. <https://doi.org/10.1002/bdm.413>
- Shi, L., Griffiths, T. L., Feldman, N. H., & Sanborn, A. N. (2010). Exemplar models as a mechanism for performing Bayesian inference. *Psychonomic Bulletin & Review*, 17(4), 443–464. <https://doi.org/10.3758/PBR.17.4.443>
- Shimada, S., Fukuda, K., & Hiraki, K. (2009). Rubber Hand Illusion under Delayed Visual Feedback. *PLoS ONE*, 4(7), e6185. <https://doi.org/10.1371/journal.pone.0006185>
- Simon, H. A. (1955). A behavioral model of rational choice. *The Quarterly Journal of Economics*, 69(1), 99–118.
- Simons, D. J. (2014). The value of direct replication. *Perspectives on Psychological Science*, 9(1), 76–80. <https://doi.org/10.1177/1745691613514755>
- Srivastava, N., Müller-Trede, J., Schrater, P., & Vul, E. (2016). Modeling sampling duration in decisions from experience. *Proceedings of the 38th Annual Meeting of the Cognitive Science Society*.

- Srivastava, N., & Schrater, P. (2014). Frugal preference formation. *Proceedings of the 36th Annual Meeting of the Cognitive Science Society*.
- Srivastava, N., & Schrater, P. (2015). Learning what to want: Context-sensitive preference learning. *PLOS ONE*, *10*(10), e0141129. <https://doi.org/10.1371/journal.pone.0141129>
- Srivastava, N., & Vul, E. (2015). Choosing fast and slow: explaining differences between hedonic and utilitarian choices. In D. Noelle, R. Dale, A. Warlaumont, J. Yoshimi, T. Matlock, C. Jennings, & P. Maglio (Eds.), *Proceedings of the 37th Annual Meeting of the Cognitive Science Society* (pp. 2272–2277). Austin, TX: Cognitive Science Society.
- Srivastava, N., & Vul, E. (2017a). A rational analysis of marketing strategies. *Proceedings of CogSci*. Retrieved from http://www.evullab.org/pdf/srivastava_marketing_2017.pdf
- Srivastava, N., & Vul, E. (2017b). Rationalizing subjective probability distortions. *Proceedings of the 39th Annual Meeting of the Cognitive Science Society*.
- Stafford, T. (2009). What use are computational models of cognitive processes? In J. Mayor, N. Ruh, & K. Plunkett (Eds.), *Connectionist models of behaviour and cognition II: proceedings of the Eleventh Neural Computation and Psychology Workshop, University of Oxford, UK, 16-18 July 2008* (pp. 265–274).
- Stigler, S. M. (2000). *The history of statistics: the measurement of uncertainty before 1900* (8. ed). Cambridge, Mass.: Belknap Press of Harvard Univ. Press.
- Storer, T., Marsh, S., Noel, S., Esfandiari, B., El-Khatib, K., Briggs, P., ... Bicakci, M. V. (2013). Encouraging second thoughts: Obstructive user interfaces for raising security awareness. *PST*, 366–368.
- Sun, R. (2008a). Introduction to computational cognitive modeling. In R. Sun (Ed.), *The Cambridge Handbook of Computational Psychology* (pp. 3–20). <https://doi.org/10.1017/CBO9780511816772.003>

- Sun, R. (Ed.). (2008b). *The Cambridge handbook of computational psychology*. New York: Cambridge University Press.
- Tenenbaum, J. B., & Griffiths, T. L. (2001). Generalization, similarity, and Bayesian inference. *Behavioral and Brain Sciences*, *24*(4), 629–640.
- Tenenbaum, J. B., Kemp, C., Griffiths, T. L., & Goodman, N. D. (2011). How to grow a mind: Statistics, structure, and abstraction. *Science*, *331*(6022), 1279–1285.
- Trafimow, D. (2017). Commentary: Reproducibility in psychological science: When do psychological phenomena exist? *Frontiers in Psychology*, *8*.
<https://doi.org/10.3389/fpsyg.2017.00918>
- Tsakiris, M., & Haggard, P. (2005). The Rubber Hand Illusion revisited: Visuotactile integration and self-attribution. *Journal of Experimental Psychology: Human Perception and Performance*, *31*(1), 80–91. <https://doi.org/10.1037/0096-1523.31.1.80>
- Tsetsos, K., Usher, M., & Chater, N. (2010). Preference reversal in multiattribute choice. *Psychological Review*, *117*(4), 1275.
- Tversky, A., & Kahneman, D. (1973). Availability: A heuristic for judging frequency and probability. *Cognitive Psychology*, *5*(2), 207–232.
- Tversky, A., & Kahneman, D. (1983). Extensional versus intuitive reasoning: The conjunction fallacy in probability judgment. *Psychological Review*, *90*(4), 293.
- Tversky, A., & Simonson, I. (1993). Context-dependent preferences. *Management Science*, *39*(10), 1179–1189. <https://doi.org/10.1287/mnsc.39.10.1179>
- Tversky, A., Slovic, P., & Kahneman, D. (1990). The causes of preference reversal. *The American Economic Review*, 204–217.
- van Beers, R. J., Sittig, A. C., & Denier van der Gon, J. J. (1998). The precision of proprioceptive position sense. *Experimental Brain Research*, *122*(4), 367–377.
<https://doi.org/10.1007/s002210050525>

- Van de Cruys, S. (2017). *Affective value in the predictive mind*. MIND Group.
- Vehtari, A., Gelman, A., & Gabry, J. (2017). Practical Bayesian model evaluation using leave-one-out cross-validation and WAIC. *Statistics and Computing*, 27(5), 1413–1432. <https://doi.org/10.1007/s11222-016-9696-4>
- Vlaev, I., Seymour, B., Dolan, R. J., & Chater, N. (2009). The price of pain and the value of suffering. *Psychological Science*, 20(3), 309–317. <https://doi.org/10.1111/j.1467-9280.2009.02304.x>
- Vul, E. (2010). *Sampling in human cognition* (PhD Thesis). Massachusetts Institute of Technology, Cambridge, Mass.
- Vul, E., Goodman, N., Griffiths, T. L., & Tenenbaum, J. B. (2014). One and done? Optimal decisions from very few samples. *Cognitive Science*, 38(4), 599–637. <https://doi.org/10.1111/cogs.12101>
- Weiss, Y., Simoncelli, E. P., & Adelson, E. H. (2002). Motion illusions as optimal percepts. *Nature Neuroscience*, 5(6), 598–604. <https://doi.org/10.1038/nn858>
- Xu, F., & Tenenbaum, J. B. (2007). Word learning as Bayesian inference. *Psychological Review*, 114(2), 245–272. <https://doi.org/10.1037/0033-295X.114.2.245>
- Yuille, A., & Kersten, D. (2006). Vision as Bayesian inference: analysis by synthesis? *Trends in Cognitive Sciences*, 10(7), 301–308. <https://doi.org/10.1016/j.tics.2006.05.002>
- Zednik, C., & Jäkel, F. (2014). How does Bayesian reverse-engineering work? *Proceedings of the 36th Annual Conference of the Cognitive Science Society*, 666–671. Austin, TX: Cognitive Science Society.

Abbildungsverzeichnis

<i>Abbildung 1.</i> Metapher eines Samples produzierenden Androiden nach Sanborn und Chater (Sanborn & Chater, 2016). Der Android erzeugt abhängig von seiner Startposition auch nach einer großen Anzahl produzierter Samples keine adäquate Approximation der bimodalen Verteilung.	17
<i>Abbildung 2.</i> Aufbau einer aktiven Variation der RHI mit einer beweglichen Roboterhand. Die echte Hand der Versuchsperson trägt einen Sensorhandschuh und wird unter einer Abdeckung aus Karton und einer Decke verdeckt und ist aus ihrer Perspektive nicht sichtbar. Die Roboterhand ahmt dabei Bewegungen der echten Hand nach.	29
<i>Abbildung 3.</i> Modellvorhersagen und empirische Positionsangaben des echten Gliedmaßes nach der experimentellen Stimulation. Steigende Werte auf der x-Achse repräsentieren die horizontale Ebene von links nach rechts vor Studienteilnehmenden.	35
<i>Abbildung 4.</i> Modellvorhersagen und empirischer propriozeptiver Drift. Positive Werte stehen für einen Drift von der Position des echten zum künstlichen Gliedmaß.	36
<i>Abbildung 5.</i> Aufgabe der Rangfolgenpositionierung zur Identifizierung von Feature-Präferenzen. Das dargestellte Beispiel wurde zur Präferenzermittlung in Studie 1 verwendet.	42
<i>Abbildung 6.</i> Beispiele der verwendeten Stimuli in Studie 1 und 2.	43
<i>Abbildung 7.</i> Modellvorhersagen und empirische Beobachtung der Anzahl an Nutzungsentscheidungen für den ersten Stimulus aus Studie 1.	50
<i>Abbildung 8.</i> Modellvorhersagen und empirische Beobachtung der Anzahl an Nutzungsentscheidungen für den zweiten Stimulus aus Studie 1.	50
<i>Abbildung 9.</i> Modellvorhersagen und empirische Beobachtung der Anzahl an Nutzungsentscheidungen für den dritten Stimulus aus Studie 1.	50
<i>Abbildung 10.</i> Modellvorhersagen und empirische Beobachtung der Anzahl an Nutzungsentscheidungen für den ersten Stimulus aus Studie 2.	51
<i>Abbildung 11.</i> Modellvorhersagen und empirische Beobachtung der Anzahl an Nutzungsentscheidungen für den zweiten Stimulus aus Studie 2.	51
<i>Abbildung 12.</i> Verteilung der durchschnittlichen Anzahl produzierter Samples (in Prozent).	53
<i>Abbildung 13.</i> Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den ersten Stimulus.	65
<i>Abbildung 14.</i> Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den zweiten Stimulus.	65
<i>Abbildung 15.</i> Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den dritten Stimulus.	65

<i>Abbildung 16.</i> Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den vierten Stimulus.	66
<i>Abbildung 17.</i> Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den fünften Stimulus.	66
<i>Abbildung 18.</i> Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den sechsten Stimulus.	66
<i>Abbildung 19.</i> Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den siebten Stimulus.	67
<i>Abbildung 20.</i> Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den achten Stimulus.	67
<i>Abbildung 21.</i> Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den neunten Stimulus.	67
<i>Abbildung 22.</i> Modellvorhersagen und empirische Beobachtung der Wahrnehmung einer Flirtintention für den zehnten Stimulus.	68

Tabellenverzeichnis

Tabelle 1.	27
<i>Unterteilung von Bayes Factors in Kategorien nach Jeffreys (1998) mit Interpretationen nach Lee und Wagenmakers (2013).</i>	
Tabelle 2.	33
<i>Prozess der Informationsintegration for das uniforme und die informierten Modelle. Die konzeptionell und empirisch informierten Modelle sind in der rechten Spalte der Tabelle zusammengefasst.</i>	
Tabelle 3.	41
<i>Beschreibung und Feature-Stufen der Stimuli in Studie 1.</i>	
Tabelle 4.	41
<i>Beschreibung und Feature-Stufen der Stimuli in Studie 2.</i>	
Tabelle 5.	43
<i>Liste der Feature-Stufen für jeden Stimulus in Studie 1.</i>	
Tabelle 6.	44
<i>Liste der Feature-Stufen für jeden Stimulus in Studie 2.</i>	
Tabelle 7.	46
<i>Beschreibung des rationale Prozessmodells in Pseudocode.</i>	
Tabelle 8.	48
<i>Beschreibung des probTTB in Pseudocode.</i>	
Tabelle 9.	51
<i>Bayes Factors für den Modellvergleich zwischen RPM und probTTB für alle Stimuli. Die Bayes Factors nutzen die marginale Likelihood des RPM im Zähler.</i>	
Tabelle 10.	52
<i>Klassifikationsergebnisse der Modelle detBayes und detTTB aggregiert über alle Stimuli (in Prozent, gerundet auf ganze Zahlen).</i>	
Tabelle 11.	52
<i>Durchschnittliche Feature-Präferenzen (Standardabweichung in Klammern) als Ergebnis der Rangfolgenpositionierung für Studie 1 (in Prozent, gerundet auf ganze Zahlen).</i>	
Tabelle 12.	53
<i>Durchschnittliche Feature-Präferenzen (Standardabweichung in Klammern) als Ergebnis der Rangfolgenpositionierung für Studie 2 (in Prozent, gerundet auf ganze Zahlen).</i>	
Tabelle 13.	62
<i>Behaviorale Beschreibung der verwendeten Stimuli nach Moore (1985). Sozialer Kontext in Klammern.</i>	

Tabelle 14.	68
<i>Bayes Factors für den Modellvergleich zwischen RPM und probMatch für alle Stimuli. Die Bayes Factors nutzen die marginale Likelihood des RPM im Zähler.</i>	
Tabelle 15.	69
<i>Durchschnittliche Wahrscheinlichkeit der Anwesenheit einer Flirtintention (Standardabweichung in Klammern) als Ergebnis der Paarvergleiche (in Prozent, gerundet auf ganze Zahlen).</i>	
Tabelle 16.	69
<i>Klassifikationsergebnisse des Modelle detBayes aggregiert über alle Stimuli (in Prozent, gerundet auf ganze Zahlen).</i>	

Anhang – Verbleibende Stimuli der Studien aus Kapitel 4

Stimulus 1 aus Studie 1:



The screenshot shows the HOTELO mobile application interface. At the top, there is a status bar with the time 12:20 and various icons. Below the status bar, the app's logo (HOTELO) is displayed on the left, and the text 'HOTELO' is centered. To the right of the logo, there is a green button with the text '2,99€'. Below the logo and text, there is a section titled 'BESCHREIBUNG' (Description) containing four bullet points. Below the description, there is a section titled 'ANFORDERUNGEN' (Requirements) containing one bullet point.

HOTELO

HOTELO.com 2,99€


BESCHREIBUNG

- Ob Geschäfts- oder Privatreise, mit HOTELO erhalten Sie exklusive Preisnachlässe bei Buchungen.
- Die HOTELO Preisprognose bezieht die Preise unzähliger Anbieter ein und verrät Ihnen den optimalen Buchungszeitpunkt.
- Die Bewertungen unserer Reise-Experten helfen bei der Auswahl Ihres Hotels.
- Durch die einfache Suche und Navigation per GPS-Funktion ist es so einfach wie nie, weltweit Hotels zu buchen.

ANFORDERUNGEN

- Benötigt Zugriff auf die Ortungsfunktion Ihres Smartphones.

Stimulus 2 aus Studie 1:

Urlaubsdeals 
urlaubsdeals.com **KOSTENLOS**

BESCHREIBUNG

- Profitieren Sie von exklusiven Preisdeals bei der Nutzung unserer App.
- Ehrliche Kundenbewertungen sind Ihnen bei der Auswahl von Reisedeals und Hotels behilflich.
- Durch die Aktivierung der GPS-Funktion Ihres Smartphones werden Ihnen alle Sehenswürdigkeiten in der Umgebung ihrer Unterkunft angezeigt.
- Gebuchte Reisedaten werden automatisch und komfortabel in den Kalender Ihres Smartphones eingetragen.

ANFORDERUNGEN

- Benötigt Zugriff auf die Ortungsfunktion Ihres Smartphones.
- Benötigt Zugriff auf die Kalender-App Ihres Smartphones.

Stimulus 2 aus Studie 2:

Quickmessage
quickmessage.com

4,5 ★★★★★ **2,99 €**

BESCHREIBUNG

- Vollständig verschlüsselte Übertragung von Nachrichten und Dateien
- Kommunizieren Sie auf allen gängigen Plattformen - PC, MacOS, Smartphones und Tablets. Alles über denselben Service.

ANFORDERUNGEN

- Benötigt Zugriff auf Kontakte