

Martin Sterzel

Effectuation entwickeln

Ein auf Reinforcement Learning
aufbauender agentenbasierter
Modellierungsbeitrag zur
Formalisierung unternehmerischen
Verhaltens

OPEN ACCESS



Springer Gabler


Effectuation entwickeln

Martin Sterzel

Effectuation entwickeln

Ein auf Reinforcement Learning
aufbauender agentenbasierter
Modellierungsbeitrag zur
Formalisierung unternehmerischen
Verhaltens

 Springer Gabler

Martin Sterzel 
Zwickau, Deutschland

Dissertation Technische Universität Chemnitz, 2022



Die vorliegende Arbeit wurde von der Westsächsischen Hochschule Zwickau aus Mitteln des *Dezernat Forschung und Drittmittelangelegenheiten* und der *Fakultät Wirtschaftswissenschaften* finanziert. Der Autor wurde während der Erstellung der Arbeit durch den *Europäischen Sozialfonds* sowie der Westsächsischen Hochschule Zwickau gefördert.

ISBN 978-3-658-39250-5 ISBN 978-3-658-39251-2 (eBook)
<https://doi.org/10.1007/978-3-658-39251-2>

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

© Der/die Herausgeber bzw. der/die Autor(en) 2023. Dieses Buch ist eine Open-Access-Publikation. **Open Access** Dieses Buch wird unter der Creative Commons Namensnennung 4.0 International Lizenz (<http://creativecommons.org/licenses/by/4.0/deed.de>) veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden. Die in diesem Buch enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen. Die Wiedergabe von allgemein beschreibenden Bezeichnungen, Marken, Unternehmensnamen etc. in diesem Werk bedeutet nicht, dass diese frei durch jedermann benutzt werden dürfen. Die Berechtigung zur Benutzung unterliegt, auch ohne gesonderten Hinweis hierzu, den Regeln des Markenrechts. Die Rechte des jeweiligen Zeicheninhabers sind zu beachten. Der Verlag, die Autoren und die Herausgeber gehen davon aus, dass die Angaben und Informationen in diesem Werk zum Zeitpunkt der Veröffentlichung vollständig und korrekt sind. Weder der Verlag, noch die Autoren oder die Herausgeber übernehmen, ausdrücklich oder implizit, Gewähr für den Inhalt des Werkes, etwaige Fehler oder Äußerungen. Der Verlag bleibt im Hinblick auf geografische Zuordnungen und Gebietsbezeichnungen in veröffentlichten Karten und Institutionsadressen neutral.

Planung/Lektorat: Marija Kojic
Springer Gabler ist ein Imprint der eingetragenen Gesellschaft Springer Fachmedien Wiesbaden GmbH und ist ein Teil von Springer Nature.
Die Anschrift der Gesellschaft ist: Abraham-Lincoln-Str. 46, 65189 Wiesbaden, Germany

The most damaging phrase in the language is: 'It's always been done that way.'

(Grace B. M. Hopper)

Alles, was wir für uns selbst tun, tun wir auch für andere, und alles, was wir für andere tun, tun wir auch für uns selbst.

(Thich Nhat Hanh)

Vorwort

Das interdisziplinäre Forschungsgebiet des Entrepreneurships beschäftigt sich mit dem Phänomen der Unternehmensgründung. Als ein Ergebnis der Forschungsaktivitäten entwickelte sich der Ansatz Effectuation heraus, der versucht, unternehmerisches Handeln zu beschreiben. Im Rahmen dieser Theorie wird die Annahme getroffen, dass die Umgebung, in der sich ein Entrepreneur befindet, von Ungewissheit geprägt ist. Entsprechend beschreibt Effectuation das Vorgehen, das Gründer anwenden, um auf unsichere und mehrdeutige Situationen zu reagieren. In diesem Zusammenhang verhalten sich Entrepreneure überwiegend kooperativ, aufgeschlossen gegenüber Neuem und Verlustavers.

Bisherige Untersuchungen behandeln unter anderem die Frage, in welchen Kontexten Effectuation als Entscheidungslogik anwendbar und leistungsfähig ist. Hierbei kamen bisher insbesondere Methoden der qualitativen und quantitativen Forschung zum Tragen. Demgegenüber steht das Potential von Simulations- und Modellierungsansätzen, das eine Formalisierung von Effectuation erlaubt. Effektuatives Verhalten wird dadurch transparent und reproduzierbar. Die vorliegende Arbeit beschäftigt sich daher mit Verfahren, die es ermöglichen, Effectuation zu modellieren und simulieren. Weiterhin wird der wissenschaftlichen Forderung Rechnung getragen, entrepreneurialen Agenten mit Hilfe von Künstlicher Intelligenz das selbstständige Erlernen von Effectuation zu ermöglichen. Die daraus resultierenden Erkenntnisse bilden die Grundlage für die künftige Entwicklung entscheidungsunterstützender Systeme, die Entrepreneuren im Gründungsprozess Hilfestellung leisten können.

Die vorliegende Arbeit entstand im Rahmen eines kooperativen Promotionsverfahrens zwischen der Technischen Universität Chemnitz und der Westsächsischen Hochschule Zwickau an den jeweiligen Fakultäten für Wirtschaftswissenschaften. Die Erstellung dieser Arbeit war geprägt von zahlreichen Herausforderungen, die es zu meistern galt. Gleichzeitig habe ich während des Promotionsvorhabens aber auch ungleich viele neue Dinge lernen, persönlich bereichernde Erfahrungen sammeln und interessante Menschen kennenlernen dürfen. Auf meinem Weg haben mich viele Personen unterstützt, ohne die das Gelingen einer solchen Arbeit nicht denkbar gewesen wäre. Diesen möchte ich an dieser Stelle danken.

Allen voran möchte ich meiner Betreuerin Frau Prof. Dr. Cornelia Zanger und meinem Betreuer Herrn Prof. Dr. Matthias Richter danken, die mich darin bestärkt haben, die Promotion in Angriff zu nehmen. Frau Prof. Dr. Zanger hat mich während des gesamten Vorhabens unterstützt und bei der Entwicklung der Dissertation die richtungsweisenden Fragen gestellt, die gleichzeitig inspirierend waren und mir die Reflektion meines Vorgehens ermöglicht haben. Herrn Prof. Dr. Richter möchte ich in besonderem Maße dafür danken, dass er mit viel Zeit und Geduld meinen inneren *Advocatus Diaboli* geschult und als Mentor meine Persönlichkeitsentwicklung nachhaltig beeinflusst hat. Mit unermüdlichem Einsatz hat er mir neue Sichtweisen aufgezeigt und mein persönliches und wissenschaftliches Vorankommen gefördert.

Trotz seiner vielen anderen Verpflichtungen hat mich Herr Dr. Hendrik Weiß, neben seiner Tätigkeit an der Fakultät Physikalische Technik/Informatik der Westsächsischen Hochschule Zwickau, kontinuierlich und mit viel Engagement während der Promotion unterstützt und wesentlich zum Gelingen der Arbeit beigetragen. Ihm gilt mein tiefer Dank.

Die Erstellung einer solchen Arbeit ist mit vielen Entbehrungen verbunden. Dass ich Menschen während dieser Zeit um mich haben durfte, die mich mental gestärkt und motiviert haben nicht aufzugeben, empfinde ich als Privileg. Ich möchte daher meinen Eltern Conni und Gunter Sterzel, sowie meinem Bruder Peter Sterzel danken, die mich in schwierigen Momenten zum Lachen gebracht haben und stets ein offenes Ohr für mich hatten. Der Selbstlosigkeit meiner Eltern verdanke ich es, dass ich die Möglichkeit hatte den Weg bis zur Promotion zu gehen. Meinem Sohn Till bin ich ebenfalls zu Dank verpflichtet. Mit ihm die Welt entdecken zu dürfen und Teil seines Lebens zu sein, erfüllen mich mit Stolz und Freude.

Ich habe während des Vorhabens viel Unterstützung von Kollegen und Kolleginnen sowie guten Freunden erhalten. Besonders danken möchte ich in diesem Zusammenhang Christopher Taudt und Pierre Tunger, die als Wissenschaftler und

Unternehmer mein Schaffen konstruktiv und kritisch hinterfragt haben und mir jederzeit beratend zur Seite standen. Frau Prof. Dr. Monique Dorsch und Nathalie Schwotzer danke ich für ihre Hilfe bei der finalen Überarbeitung der Dissertation. Meinen Kolleginnen und Kollegen vom Gründernetzwerk SAXEED danke ich ebenfalls für ihre interessanten Impulse, die ich aus Gesprächen und Vorträgen gewinnen und in die Dissertation einfließen lassen konnte.

Ohne alle namentlich aufzuführen zu können, möchte ich stellvertretend der gesamten Open-Source-Community danken. Ihre entwickelten und der Allgemeinheit frei und kostenlos zur Verfügung gestellten Werkzeuge haben zur Durchführung dieses Promotionsvorhabens in erheblichem Maße beigetragen.

Nicht zuletzt möchte ich den europäischen und deutschen Steuerzahlerinnen und -zahlern danken. Die Verwendung der zur Verfügung gestellten Mittel im Rahmen von Promotionsstipendien haben es meiner Familie und mir ermöglicht, während der Erstellung dieser Arbeit, finanziell abgesichert zu sein. Die Sächsische Aufbaubank wie auch die Westsächsische Hochschule Zwickau haben für die Bereitstellung des ESF-Landesinnovationspromotionsstipendiums sowie des WHZ-Stipendiums den formalen Rahmen geschaffen. Dafür bedanke ich mich.

Martin Sterzel

Abstract

Much of the research on effectuation to date has focused on the effectiveness of this entrepreneurship theory in different contexts and its performance relative to other theories. This work aims to create a framework that enables simulation-based studies of effectuation and at the same time lays the foundation for the development of start-up supportive decision-making systems. To this end, the extent to which effectual learning can be modelled and algorithmically interpreted is discussed. Existing simulation models that describe effectuation are first validated, verified and compared. Based on this, an aggregated model is developed with the help of methods of agent-based modelling and reinforcement learning that enables effectual behaviour in the context of a prototypical entrepreneurial situation. The results show that an entrepreneurial agent is able to learn effectual behaviour. Differences in performance during learning occur when the environment changes. The success of the agent depends on the commitment of potential partners or customers. Furthermore, learning success can be determined if the agent applies the affordable loss principle in conjunction with market-conform behaviour. In the future, the developed model can be used to conduct further studies on effectual learning behaviour, taking into account the decision-making behaviour of a real entrepreneur.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Relevanz der Untersuchung und Zielsetzung	3
1.2	Literaturanalyse und Forschungsfrage	5
1.3	Gliederung der Arbeit	10
2	Aspekte entscheidungstheoretischer Grundlagen im Rahmen von Effectuation	13
2.1	Bayesianismus im Kontext von Effectuation	13
2.1.1	Zum bayesschen Wahrscheinlichkeitsbegriff	14
2.1.2	Das Bayes-Theorem	15
2.2	Ungewissheit	22
2.3	Maschinelles Lernen im Kontext von Effectuation	24
2.3.1	Reinforcement Learning als Methode zur Lösung entscheidungstheoretischer Probleme	26
2.3.2	Lösungsverfahren zur Bestimmung optimaler Policies in Reinforcement Learning	32
2.3.3	Reinforcement Learning im entrepreneurialen Kontext	35
3	Evaluierung bestehender Modellierungs- und Simulationsansätze im Kontext von Effectuation	41
3.1	Deskriptive Analyse der Modellierungs- und Simulationsansätze	41
3.1.1	Simulationsmodell nach Mauer et al. (2017)	42
3.1.2	Simulationsmodell nach Welter und Kim (2018)	54

3.1.3	Simulationsmodell nach Eberz (2018)	59
3.1.4	Vergleich der Simulationsmodelle	66
3.2	Verifikation und Validierung der bestehenden effektuativen Simulationsmodelle	72
3.2.1	Kritische Evaluierung des Simulationsmodells von Mauer et al. (2017)	73
3.2.2	Kritische Evaluierung des Simulationsmodells von Welter und Kim (2018)	81
3.2.3	Kritische Einordnung der Simulationsansätze	91
4	Forschungsmethodik	95
4.1	Beschreibung des Problemraums	97
4.2	Modellierung des effektuativ handelnden Agenten	98
4.2.1	Bestimmung der Verhaltensregeln	99
4.2.2	Bestimmung der Lernstrategie	99
4.3	Modellierung der Umgebung	102
4.3.1	Bestimmung des Zustandsraums	102
4.3.2	Bestimmung der Belohnungsfunktion	104
4.3.3	Bestimmung der Transitionswahrscheinlichkeiten	109
4.4	Standardisierung des Modells	114
5	Ergebnisse des Lernprozesses	117
5.1	Untersuchung verschiedener Lernverhalten bei teilweiser Manipulation der Belohnungsfunktion	118
5.1.1	Auswahl der Parameterwerte	118
5.1.2	Leistungsvergleich der Lernverhalten bei teilweiser Variation der Belohnungsfunktion und Interpretation der Ergebnisse	120
5.2	Untersuchung des Lernverhaltens des effektuativen Agenten bei isolierter Betrachtung einzelner Bestandteile der Belohnungsfunktion	123
5.2.1	Auswahl der Parameterwerte	123
5.2.2	Leistungsvergleich der Lernverhalten eines effektuativen Agenten bei isolierter Betrachtung der Belohnungsfunktionsbestandteile und Interpretation der Ergebnisse	124
5.3	Untersuchung verschiedener Lernverhalten bei Manipulation der Transitionswahrscheinlichkeiten	128

5.3.1	Auswahl der Parameterwerte	128
5.3.2	Leistungsvergleich der Lernverhalten bei Variation der Transitionswahrscheinlichkeiten und Interpretation der Ergebnisse	129
5.4	Untersuchung des Lernverhaltens des effektuativen Agenten bei Manipulation ausgewählter Hyperparameter	131
5.4.1	Bestimmung des Parameterraums bei Variation ausgewählter Hyperparameter	131
5.4.2	Vergleich der Lerngeschwindigkeiten bei Variation der Lernrate und Interpretation der Ergebnisse	133
5.4.3	Vergleich der Lerngeschwindigkeiten bei Variation des Explorationsabnahmefaktors und Interpretation der Ergebnisse	135
6	Zusammenfassung und Ausblick	139
6.1	Zusammenfassung	139
6.2	Limitationen	142
6.3	Ausblick	143
Literatur	147

Abkürzungsverzeichnis

ABM	Agentenbasiertes Modell
MDP	Markov Decision Process (deutsch: Markov-Entscheidungsprozess)
MSE	Mean Squared Error (deutsch: Mittlerer Quadratischer Fehler)
RIL	Reinforcement Learning (deutsch: Bestärkendes Lernen)

Symbolverzeichnis

Notation im Reinforcement Learning Kontext

$A(s)$	Menge aller Aktionen, die in Zustand s ausführbar sind
A	Menge aller Aktionen
C_t	Produktvektor des Kunden zum Zeitpunkt t
C	Produktvektor eines Kunden
E_t	Produktvektor des Agenten zum Zeitpunkt t
E	Produktvektor eines Agenten
G_t	Gesamtbelohnung nach Zeitpunkt t
I_t	Potentielle Investition des Kunden zum Zeitpunkt t
I	Investition eines Kunden
M_t	Zur Verfügung stehende Mittel zum Zeitpunkt t
M	Zur Verfügung stehende Mittel
N	Länge der Produktvektoren
$P(Class0 \cap a0)$	Wahrscheinlichkeit für das gemeinsame Auftreten der Ereignisse, dass der Kunde ein <i>echter Kunde</i> ist und der Kunde als <i>echter Kunde</i> eingeschätzt wird
$P(Class0)$	Wahrscheinlichkeit, dass der Kunde ein <i>echter Kunde</i> ist
$P(Class0 a0)$	Wahrscheinlichkeit, dass der Kunde ein <i>echter Kunde</i> ist, sofern der Kunde als <i>echter Kunde</i> eingeschätzt wird
$P(Class0 a1)$	Wahrscheinlichkeit, dass der Kunde ein <i>echter Kunde</i> ist, sofern der Kunde als <i>Nicht-Kunde</i> eingeschätzt wird
$P(Class1)$	Wahrscheinlichkeit, dass der Kunde ein <i>Nicht-Kunde</i> ist
$P(Class1 a0)$	Wahrscheinlichkeit, dass der Kunde ein <i>Nicht-Kunde</i> ist, sofern der Kunde als <i>echter Kunde</i> eingeschätzt wird

$P(Class1 a1)$	Wahrscheinlichkeit, dass der Kunde ein <i>Nicht-Kunde</i> ist, sofern der Kunde als <i>Nicht-Kunde</i> eingeschätzt wird
$P(a0 Class0)$	Wahrscheinlichkeit für das Einschätzen des Kunden als <i>echten Kunden</i> , sofern der Kunde ein <i>echter Kunde</i> ist
$P(a0 Class1)$	Wahrscheinlichkeit für das Einschätzen des Kunden als <i>echten Kunden</i> , sofern der Kunde ein <i>Nicht-Kunde</i> ist
$P(a1 Class0)$	Wahrscheinlichkeit für das Einschätzen des Kunden als <i>Nicht-Kunden</i> , sofern der Kunde ein <i>echter Kunde</i> ist
$P(a1 Class1)$	Wahrscheinlichkeit für das Einschätzen des Kunden als <i>Nicht-Kunden</i> , sofern der Kunde ein <i>Nicht-Kunde</i> ist
S	Menge aller Zustände
T	Finaler Zeitpunkt einer Episode
$V(s)$	Geschätzte Value-Funktion $v_\pi(s)$ oder $v_*(s)$
α	Lernrate
χ	Transitionswahrscheinlichkeit, definiert durch $\chi = P(a0 Class1)$
γ	Diskontierungsfaktor
\mathbb{R}	Menge der reellen Zahlen
ψ	Wahrscheinlichkeit dafür, dass der Kunde ein <i>echter Kunde</i> ist, definiert durch $\varphi = P(Class0)$
$Class0$	Kunde ist ein <i>echter Kunde</i>
$Class1$	Kunde ist ein <i>Nicht-Kunde</i>
$Class_{t-1}$	Klassifizierung zum Zeitpunkt t , ob der Kunde zum Zeitpunkt $t - 1$ ein echter Kunde oder Nicht-Kunde ist
$Class$	Klassifizierung eines Kunden als <i>echten Kunden</i> oder <i>Nicht-Kunden</i>
$Cost_t$	Kosten für die Änderung des Produktvektors von $E_t \rightarrow C_t$ zum Zeitpunkt t
$Cost$	Kosten für eine Produkthanpassung
ε_{decay}	Explorationsabnahmefaktor
ε	Wahrscheinlichkeit eine zufällige Aktion zu wählen
φ	Transitionswahrscheinlichkeit, definiert durch $\varphi = P(a1 Class0)$
$a0$	Einschätzung des Kunden als <i>echten Kunden</i>
$a1$	Einschätzung des Kunden als <i>Nicht-Kunden</i>
a_t	Aktion zum Zeitpunkt t
a	Aktion
m_t	Mittelveränderung zum Zeitpunkt t im Verhältnis zum Anfangsbestand der Mittel

m	Mittelveränderung im Verhältnis zum Anfangsbestand der Mittel
$p(s' s, a)$	Wahrscheinlichkeit für die Transition in den Zustand s' von Zustand s bei Ausführung der Aktion a
p	Transitionsfunktion
$q(s, a)$	Aktions-Value des Zustandes s und der Aktion a
$q_*(s, a)$	Aktions-Value des Zustandes s und der Aktion a unter der optimalen Policy
$q_\pi(s, a)$	Aktions-Value bei Ausführung der Aktion a im Zustand s unter der Policy π
$r(s', a, s)$	Erwartete unmittelbare Belohnung bei Transition von Zustand s nach Zustand s' bei Ausführung der Aktion a
r_t	Belohnung zum Zeitpunkt t
r	Belohnungsfunktion
s, s'	Zustände
s_t	Zustand zum Zeitpunkt t
t	Zeitpunkt
$v_*(s)$	Value des Zustandes s unter der optimalen Policy
$v_\pi(s)$	Value des Zustandes s unter Policy π (Erwartete Gesamtelohnung)
π	Policy (Entscheidungsregelsatz)
$\pi(s)$	Ausgeführte Aktion im Zustand s unter der deterministischen Policy π
$\pi(a s)$	Wahrscheinlichkeit für die Ausführung von Aktion a im Zustand s unter der stochastischen Policy π
π^*	Optimale Policy
r^1, r^2, r^3	Belohnungsfunktionsbestandteile
w_1, w_2, w_3	Gewichtungsfaktor der Belohnungsfunktionsbestandteile r^1, r^2, r^3

Notation im Kontext effektuativer Simulationsmodelle

A	Menge der Angebotsvektoren
K	Anzahl der von einer weiteren Entscheidung abhängigen Entscheidungen einer Entscheidungskonfiguration
N	Anzahl der Entscheidungen einer Entscheidungskonfiguration
P_V	Prohibitiv-Preis
P_f	Produkt-Fit

P_k	Selbstkosten
Q	Anzahl der möglichen Ausprägungen einer Entscheidung s_j
S	Entscheidungskonfiguration als Repräsentation eines Unternehmens
T_S	Anzahl der Simulationsschritte nach der ein Schock in die Fitnesslandschaft initiiert wird
T	Anzahl der Simulationsschritte
$W(S)$	Leistungswert einer Entscheidungskonfiguration S
Y	Menge der Nachfragevektoren
λ	Vorhersageparameter
μ_i	Erwartungswert der optimalen Faktoreinsatzmenge des i -ten Produktionsfaktors
\overline{mf}	Mittlerer Market-Fit
σ_i^2	Streuungsparameter zur Beschreibung der Abweichung vom Erwartungswert der optimalen Faktoreinsatzmenge des i -ten Produktionsfaktors
τ	Grad der Ungewissheit
$\varphi_i(r_i)$	Güte der Einsatzmenge r_i des i -ten Produktionsfaktors
q	Planungsgrad
a	Angebotsvektor
c	Nachfragekonzentration
d	Dominanz der Marktnachfrage
h	Anstieg der Preis-Absatz-Funktion
k	Anzahl der Ausprägungen, die jede Komponente eines Produktvektors annehmen kann
l	Anzahl der Produktionsfaktoren
mf_a	Market-Fit eines Angebotsvektors a
m	Anzahl der flexiblen Produkteigenschaften eines Produktvektors
n	Anzahl der Produkteigenschaften eines Produktvektors
p_i	Faktorpreis des i -ten Produktionsfaktors
po_f	Payoff eines Produktvektors
r_i	Einsatzmenge des i -ten Produktionsfaktors
s_j	j -te Einzelentscheidung einer Entscheidungskonfiguration
s_{-j}	Einzelentscheidungen, die Einfluss auf s_j haben
t	Zeitpunkt
v	Variation der Marktnachfrage
$w(s_j, s_{-j})$	Leistungsbeitrag der j -ten Einzelentscheidung und der K abhängigen Entscheidungen s_{-j}
y	Nachfragevektor
z	Sättigungsmenge

Wahrscheinlichkeitstheoretische Notation im Effectuation Kontext

I_i	Anzahl der gescheiterten Unternehmen des Agenten ist i für $i = 1, 2, \dots$
I	Anzahl der gescheiterten Unternehmen des Agenten ist mindestens 1
$P(I)$	Wahrscheinlichkeit dafür, dass mindestens ein gegründetes Unternehmen des Agenten scheitert.
$P(I S)$	Wahrscheinlichkeit dafür, dass der Agent mit mindestens einem Unternehmen scheitert, unter der Annahme, dass er mehr als ein Unternehmen gründet
$P(I \bar{S})$	Wahrscheinlichkeit dafür, dass der Agent mit mindestens einem Unternehmen scheitert, unter der Annahme, dass er höchstens ein Unternehmen gründet
$P(S)$	Wahrscheinlichkeit dafür, dass der Agent mehr als ein Unternehmen gründet
$P(S I)$	Wahrscheinlichkeit dafür, dass der Agent mehr als ein Unternehmen gründet unter der Bedingung, dass mindestens ein Unternehmen gescheitert ist
$P(\bar{S})$	Wahrscheinlichkeit dafür, dass der Agent höchstens ein Unternehmen gründet
U_1, U_2, \dots	Erfolgreiche oder gescheiterte Unternehmen des Agenten
Ω	Zukünftige Erfolgssituationen der Unternehmen des Agenten
w_1, w_2, \dots	Gegründete Unternehmen des Agenten
S_s	Anzahl der gegründeten Unternehmen des Agenten ist s für $s = 1, 2, \dots$
S	Anzahl der gegründeten Unternehmen des Agenten ist größer als 1
\bar{S}	Anzahl der gegründeten Unternehmen des Agenten ist höchstens 1

Wahrscheinlichkeitstheoretische Notation im allgemeinen Kontext

A, B	Ereignis aus dem Ereignissystem A
I_i	Informationsereignis mit $i = 1, 2, \dots, n_I$, wobei n_I die Anzahl der möglichen Informationsereignisse beschreibt
$P(A)$	Wahrscheinlichkeit für das Auftreten des Ereignisses A

$P(B A)$	Wahrscheinlichkeit für das Auftreten des Ereignisses B, sofern A eingetreten ist
$P(I_i)$	Wahrscheinlichkeit für das Eintreten des Informationsereignisses I_i
$P(I_i S_s)$	Wahrscheinlichkeit für das Eintreten des Informationsereignisses I_i , sofern Zustand S_s eingetreten ist
$P(S_s \cap I_i)$	Wahrscheinlichkeit für das gemeinsame Auftreten des Zustandes S_s und des Informationsereignisses I_i
$P(S_s)$	Wahrscheinlichkeit für das Eintreten des Zustandes S_s
$P(S_s I_i)$	Wahrscheinlichkeit für das Eintreten des Zustandes S_s , sofern Informationsereignis I_i eingetreten ist
P	Wahrscheinlichkeitsmaß
S_s	Bestimmter Zustand mit $s = 1, 2, \dots, n_S$ wobei n_S die Anzahl der möglichen Zustände beschreibt
Ω	Ergebnismenge, definiert durch $\Omega = \{w_1, w_2, \dots\}$
A	Ereignissystem
$P(\Omega)$	Potenzmenge der Ergebnismenge Ω
w_1, w_2, \dots	Mögliche Ergebnisse eines Zufallsexperiments

Abbildungsverzeichnis

Abb. 1.1	Der Effectuation-Prozess	3
Abb. 1.2	Zuordnung der anhand der Literaturauswahlbedingungen erhaltenen Suchergebnisse zu Forschungsfeldern	7
Abb. 1.3	Visualisierung der Häufigkeit des (gemeinsamen) Auftretens von Schlüsselwörtern mit Hilfe von <i>VOSviewer</i>	8
Abb. 2.1	Wechselwirkung zwischen Agent und Umgebung in einem RIL-Problem	28
Abb. 2.2	Generalisierte Policy Iteration	34
Abb. 2.3	Darstellung des beispielhaften Transitionssystems	37
Abb. 3.1	Beispielhafte Payoff-Landschaft für einen Artefakt-Vektor der Konsumenten mit $n = 2$ Komponenten und $k \in [0, 10]$ Ausprägungen (mod. nach Carpenter und Nakamoto (1989))	46
Abb. 3.2	Grafische Darstellung der von Eberz (2018) formulierten Marktnachfrage-Funktion	63
Abb. 3.3	Zusammenspiel zwischen Modellierungsprozess und Validierungs- und Verifikationsprozess nach Schlesinger (1979)	68
Abb. 3.4	Vergleich der Simulationsergebnisse bei Änderung der Isotropie (Nachfragekonzentration c während der Artefakt-Erstellung)	75
Abb. 3.5	Vergleich der Simulationsergebnisse bei Änderung der Isotropie (Anzahl der Merkmalsausprägungen k)	76

Abb. 3.6	Simulationsergebnisse nach Mauer et al. (2017) bei Änderung der Ungewissheit (Nachfragekonzentration c nach der Artefakt-Erstellung)	77
Abb. 3.7	Simulationsergebnisse der replizierten Implementierung bei Änderung der Ungewissheit (Nachfragekonzentration c nach der Artefakt-Erstellung)	78
Abb. 3.8	Simulationsergebnisse nach Mauer et al. (2017) bei Änderung der Ziel-Ambiguität (Anzahl der flexiblen Komponenten m und Nachfragekonzentration c)	79
Abb. 3.9	Simulationsergebnisse der replizierten Implementierung bei Änderung der Ziel-Ambiguität (Anzahl der flexiblen Komponenten m und Nachfragekonzentration c) und 50 Simulationsdurchläufen	80
Abb. 3.10	Simulationsergebnisse der replizierten Implementierung bei Änderung der Ziel-Ambiguität (Anzahl der flexiblen Komponenten m und Nachfragekonzentration c) und 170 Simulationsdurchläufen	81
Abb. 3.11	Simulationsergebnisse nach Welter und Kim (2018) bei Änderung des Grades der Ungewissheit (τ) und der Vorhersagefähigkeit (λ)	83
Abb. 3.12	Simulationsergebnisse der replizierten Implementierung bei Änderung des Grades der Ungewissheit (τ) und der Vorhersagefähigkeit (λ)	84
Abb. 3.13	Simulationsergebnisse nach Welter und Kim (2018) bei Änderung der Vorhersagefähigkeit (λ)	85
Abb. 3.14	Simulationsergebnisse der replizierten Implementierung bei Änderung der Vorhersagefähigkeit (λ)	87
Abb. 3.15	Streuung der Simulationsergebnisse der replizierten Implementierung bei Änderung der Vorhersagefähigkeit (λ)	88
Abb. 3.16	Simulationsergebnisse der replizierten Implementierung bei Änderung der Vorhersagefähigkeit (λ)	89
Abb. 3.17	Simulationsergebnisse der replizierten Implementierung bei Änderung der Vorhersagefähigkeit (λ)	91
Abb. 4.1	Zusammenhang zwischen dem Verhältnis von Means Variation Ratio m und Belohnungsbestandteil r^1	106

Abb. 4.2	Darstellung der Belohnungsfunktion aus Gleichung (4.4) bei variierendem m und $r^3(E_t)$ sowie fixiertem $r^2(Class, a)$	109
Abb. 4.3	Beispielhafte Darstellung einer Transition für Produktvektoren mit der Länge $N = 3$	113
Abb. 5.1	Vergleich des Lernverhaltens des effektiv und zufällig agierenden Agenten bei unterschiedlicher Gewichtung der Konvexkombinationsterme der Belohnungsfunktion	121
Abb. 5.2	Lernverhalten des effektiv agierenden Agenten bei Parameterkonfiguration $\omega_1 = 1, \omega_2 = 1, \omega_3 = 0$	122
Abb. 5.3	Vergleich des Lernverhaltens des effektiv und zufällig agierenden Agenten bei Parameterkonfiguration $\omega_1 = 1, \omega_2 = 1, \omega_3 = 1$	122
Abb. 5.4	Vergleich des Lernverhaltens des effektiven Agenten bei isolierter Betrachtung der Konvexkombinationsterme der Belohnungsfunktion	125
Abb. 5.5	Vergleich des Lernverhaltens des effektiven Agenten bei isolierter Betrachtung der Belohnungsfunktionsbestandteile und bei Parameterkonfiguration $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$	127
Abb. 5.6	Vergleich des Lernverhaltens des effektiv und zufällig agierenden Agenten bei Änderung der Transitionswahrscheinlichkeiten	129
Abb. 5.7	Betrachtung des Lernverhaltens des effektiv und zufällig agierenden Agenten bei Änderung der Transitionswahrscheinlichkeiten	130
Abb. 5.8	Betrachtung der mittleren erhaltenen Belohnungen des effektiv agierenden Agenten bei Änderung der Lernrate	133
Abb. 5.9	Betrachtung der mittleren erhaltenen Belohnungen und des Mittleren Quadratischen Fehlers des effektiv agierenden Agenten bei Änderung der Lernrate	134
Abb. 5.10	Betrachtung der mittleren erhaltenen Belohnungen und der Mittleren Quadratischen Fehler des effektiv agierenden Agenten bei Änderung des Explorationsabnahmefaktors	136

Tabellenverzeichnis

Tab. 2.1	Tabellarische Darstellung eines beispielhaften MDP	37
Tab. 3.1	Gegenüberstellung der Simulationsmodelle	69
Tab. 4.1	Merkmale eines Zustands	103
Tab. 4.2	Entscheidungstabelle	107
Tab. 4.3	Mögliche Werte des Belohnungsfunktionsbestandteils r^2	108
Tab. 4.4	Bedingte Wahrscheinlichkeiten	110



Einleitung

1

Zum Zeitpunkt der Erstellung der vorliegenden Arbeit wird die Welt von einer durch das Virus SARS-CoV-2 hervorgerufenen COVID-19-Pandemie beherrscht. Zum Schutz der Bevölkerung ist das bis dahin gewohnte Gesellschaftsleben vielerorts durch eine Reihe von Einschränkungen geprägt. Entscheidungsträger standen und stehen vor der Herausforderung, die Gesundheit vieler Menschen zu schützen und dabei gleichzeitig ein vollständiges Erliegen wirtschaftlicher Aktivitäten, die die Grundlage für den aktuellen materiellen Wohlstand sind, zu vermeiden. Es lässt sich aktuell nur schwer abschätzen, welche globalen volkswirtschaftlichen Schäden durch die Krise entstanden sind und noch entstehen werden (Fernandes, 2020).

Die Vergangenheit hat jedoch gezeigt, dass Krisen auch immer wieder die Möglichkeit des Hinterfragens bestehender technologischer und gesellschaftlicher Lösungen bieten und zum Treiber von Innovationen werden können (Peris-Ortiz et al., 2013). Das Voranbringen innovativer Ideen und Erkunden neuer Geschäftsmöglichkeiten in krisenbehafteten Zeiten wird insbesondere durch junge, schnell wachsende Unternehmen geleistet (Archibugi et al., 2013). Diese zeigen, dass langfristig geplante Geschäftsideen nicht robust gegenüber unvorhergesehenen Ereignissen sind (Giones et al., 2020).

Im Bereich des Entrepreneurships hat sich ein Ansatz herausgebildet, der das Vorgehen von Gründern in einem unsicheren Umfeld beschreibt und unter dem Begriff *Effectuation* bekannt ist. *Effectuation* wird als eigenständige Entscheidungslogik zur Umsetzung disruptiver Technologien bisher insbesondere von erfahrenen und erfolgreichen Seriengründern angewendet (Sarasvathy, 2001). Dieses

Ergänzende Information Die elektronische Version dieses Kapitels enthält Zusatzmaterial, auf das über folgenden Link zugegriffen werden kann
https://doi.org/10.1007/978-3-658-39251-2_1.

Vorgehen vereint fünf Prinzipien, die Unternehmer in die Lage versetzen „diskontinuierlichen Veränderungen“ (Schumpeter, 1912, S. 155) voranzutreiben und wirtschaftlich erfolgreich umzusetzen.

Im Gegensatz dazu bedeutet kausale Logik im Kontext unternehmerischer Tätigkeit, Ziele festzulegen und diese mit Hilfe zu beschaffender Ressourcen und zu definierender Aktivitäten bestmöglich zu erreichen. Die Entscheidungsfindung findet unter Zuhilfenahme von Vorhersagen statt (Sarasvathy, 2003). Effectuation hingegen setzt bei den vorhandenen Kompetenzen und bereits bestehenden Kontaktnetzwerken des Individuums an, die als Grundlage für das weitere Vorgehen dienen. Dadurch werden Entrepreneurure in die Lage versetzt, Entscheidungen unabhängig von Vorhersagen zu treffen. Dieses Prinzip wird als *Bird-in-Hand* bezeichnet (Sarasvathy, 2009). Demnach fragt sich ein effektiv handelnder Akteur, wer er ist, was er weiß und wen er kennt. Die Antworten auf diese Fragen beschreiben die zur Verfügung stehenden Mittel, die sich auf die eigene Identität, das vorhandene Wissen sowie das bestehende Netzwerk beziehen (Wiltbank et al., 2006).

Weiterhin orientiert sich Effectuation am leistbaren Verlust. Dieser stellt eine vom Entrepreneur selbst definierte Investitionsgrenze dar, die nicht nur finanzieller Natur sein muss und als *Affordable Loss* bezeichnet wird (Dew, Sarasvathy et al., 2009). Da zu Beginn einer Unternehmung nicht klar ist, was genau Gegenstand der Unternehmung sein wird, vermeiden effektiv handelnde Akteure erwartete Gewinne zu prognostizieren und fokussieren sich daher auf das Worst-Case-Szenario (*Downside Potential*) (Wiltbank et al., 2006).

Bei Effectuation sind im Gründungskontext Zufall und Überraschungen etwas Positives. Unerwartete Ereignisse werden für den Entrepreneur als Möglichkeiten verstanden, neue unternehmerische Gelegenheiten zu schaffen und auszunutzen. Dieses als *Lemonade* bezeichnete Prinzip beschreibt, dass Ungewissheit als Hebel für Innovationen genutzt werden kann (Read & Sarasvathy, 2005).

Zudem werden weitere Individuen oder Gruppierungen nicht grundsätzlich von der Unternehmung ausgeschlossen. Vielmehr entstehen Partnerschaften durch Selbstselektion. Beteiligte aus dem Netzwerk des effektiven Entrepreneurs, die nicht bereit sind, das Risiko der Unternehmung mitzutragen, scheiden demnach selbstbestimmt aus dem weiteren Prozess des Unternehmens aus. Dieses Prinzip wird von Sarasvathy (2009) als *Crazy Quilt* bezeichnet. Im Gegensatz dazu unterscheidet man bei kausaler Logik strikt zwischen Konkurrenten und Partnern und grenzt diejenigen von Beginn an aus, die das erklärte Ziel gefährden (Sarasvathy, 2009, S. 88f).

Das von Sarasvathy (2009, S. 16) beschriebene *Pilot-in-the-Plane*-Prinzip verdeutlicht die Logik nicht-prognostizierender Steuerung (*Non-predictive Control*).

Die Konzentration auf die geschickte Mittelverwendung macht die Vorhersage künftiger Ereignisse obsolet (Dew, Read et al., 2009).

Die genannten Prinzipien finden ihren Ausdruck im effektuativen Prozess, der in Abbildung 1.1 illustriert ist. Ausgangspunkt sind die dem Entrepreneur zur Verfügung stehenden Mittel. Ausgehend von den identifizierten Ressourcen kann jener entscheiden, wie er diese verwenden möchte. Die daraus resultierenden veränderlichen Ziele werden mit Partnern aus dem Netzwerk der effektuativ handelnden Person diskutiert. Anschließend werden Vereinbarungen zwischen den Stakeholdern getroffen, die zu neuen Ressourcen und neuen Zielen führen. Dieser Prozess wird iterativ durchlaufen und kann zu neuen Unternehmen und Märkten führen (Read & Sarasvathy, 2005).

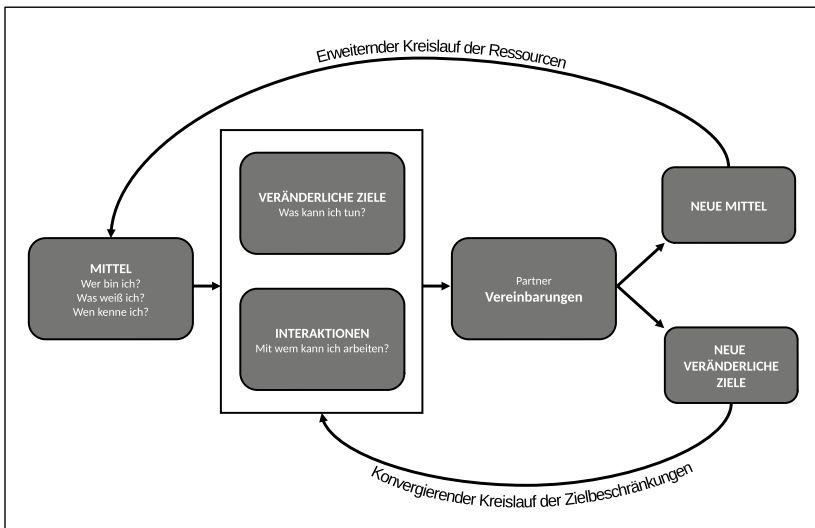


Abb. 1.1 Der Effectuation-Prozess. (Modifiziert nach Sarasvathy (2009, S. 101))

1.1 Relevanz der Untersuchung und Zielsetzung

Das Forschungsgebiet des Entrepreneurships umfasst eine Reihe konkurrierender und sich ergänzender Theorien, die versuchen entrepreneuriales Verhalten

zu beschreiben. Hierbei konnte sich im wissenschaftlichen Kontext, insbesondere neben den Ansätzen Lean Startup (Ries, 2011) und Entrepreneurial Bricolage (Baker & Nelson, 2005), Effectuation (Sarasvathy, 2001) etablieren und ist seit über 20 Jahren Gegenstand der Forschung (Grégoire & Cherchem, 2019). Dabei ist das Theorienkonstrukt von Effectuation immer wieder Kritik ausgesetzt gewesen, was in der Folge zu einer Weiterentwicklung von Effectuation führte (Arend et al., 2015, 2016; Baron, 2009; Karri & Goel, 2008).

Während Effectuation insbesondere im Kontext verschiedener Entrepreneurship-Theorien, der Kreativitäts- und Innovationsforschung, dem Projektmanagement und Marketing diskutiert wird (Grégoire & Cherchem, 2019), stellen S. X. Zhang und Van Burg (2019) fest, dass darüber hinaus die Entwicklung und Interpretation von Effectuation durch die Anwendung von Methoden der Künstlichen Intelligenz profitieren können. Auch Lévesque (2004) bemerkt, dass nur vereinzelt mathematische Modelle – welche die Grundlage für Methoden der Künstlichen Intelligenz bilden – zur Beschreibung entrepreneurialer Phänomene und Prozesse genutzt werden.

Hierfür ist es notwendig, dass Effectuation verstärkt aus prozesstheoretischer Sicht betrachtet wird und Wirkungsweisen im Zeitverlauf untersucht werden. Bisher wird Effectuation überwiegend als varianzorientiertes Konzept erforscht, welches ausschließlich zeitpunktbezogene Zusammenhänge zwischen unabhängigen und abhängigen Variablen beleuchtet (Gupta et al., 2016). Die von Eberz (2018), Welter und Kim (2018) und Mauer et al. (2017) vorgestellten Modellansätze liefern Erkenntnisse darüber, wie Effectuation prozessual und technisch-mathematisch interpretiert werden können, stehen jedoch vor der Herausforderung effektuative Intelligenz, im Sinne von Lernfähigkeit, einzubeziehen.

Yang und Chandra (2013) unterstreichen die Notwendigkeit, entrepreneurialen Lernen, das sich in der kontinuierlichen Anwendung der Effectuation-Logik manifestiert, in agentenbasierte Modelle zu implementieren. Die Umsetzung dessen resultiert nach Ansicht von Yang und Chandra (2013) in einer Stärkung der Entrepreneurship-Forschung sowie in der Nutzbarmachung der Erkenntnisse durch angehende und etablierte Entrepreneure.

Ziel der vorliegenden Arbeit ist es, die ursprünglich von Sarasvathy (2001) formulierte Effectuation-Theorie um einen prozessorientierten Beitrag zu erweitern und Elemente bestehender Modelle, wie sie von Eberz (2018), Welter und Kim (2018) und Mauer et al. (2017) entwickelt wurden, zu aggregieren und um den Baustein effektuativen Lernens zu erweitern.

1.2 Literaturanalyse und Forschungsfrage

Sarasvathy (1998) untersuchte in ihrer Dissertation das Vorgehen von Serienentrepreneuren im Gründungskontext. Als Untersuchungsobjekte wählte sie 27 Experten-Entrepreneure und konfrontierte sie mit Entscheidungssituationen während eines fiktiven Gründungsprozesses. Mit Hilfe von Think-Aloud-Protokollen erfasste sie das Vorgehen der Entrepreneure. Die Entrepreneure besaßen zum Zeitpunkt der Untersuchung mindestens 10 Jahre Erfahrung und hatten mehrere Unternehmen gegründet (inklusive gescheiterter Unternehmen). Mit mindestens einem Unternehmen waren sie am Markt etabliert. Diese Unternehmen wiesen eine Marktkapitalisierung zwischen 250 Millionen und 6,5 Milliarden Dollar auf (Sarasvathy, 2009, S. 20–23).

Die aus dieser Untersuchung abgeleiteten Ergebnisse, in Form von Effectuation, werden von Sarasvathy (2001) erstmalig einer breiteren wissenschaftlichen Öffentlichkeit vorgestellt. Den Ansatz der entwickelten Theorie grenzte Sarasvathy (2004) weiter zu bestehenden Theorien ab, da bis dahin gründungsbezogener Erfolg lediglich mit Unternehmenserfolg gleichgesetzt wurde bzw. Entrepreneure mittels Sammlungen von Verhaltens- und Charaktereigenschaften beschrieben wurden. In der Folge wird Effectuation mit weiteren Theorien der Entrepreneurship-Forschung verglichen, wie Bricolage, Causation, Opportunity Creation und Lean Startup (Fisher, 2012; Ries, 2011; Selden & Fletcher, 2015; Welter et al., 2016).

Um zunächst einen Überblick über die aktuelle Literatur zur Effectuation-Forschung zu erhalten, wurde das Vorgehen, das von Wolfswinkel et al. (2013) vorgeschlagen wurde, angewandt. Folgende Rahmenbedingungen sollen dabei definiert werden, die bei der Literatúrauswahl zu beachten sind:

1. Definition von Anforderungen für die Berücksichtigung bzw. den Ausschluss von Artikeln
2. Identifikation relevanter Forschungsgebiete
3. Bestimmung geeigneter Quellen
4. Festlegung konkreter Suchbegriffe

Ausgehend von Rahmenbedingung 1 wurden all diejenigen Zeitschriften ausgewählt, die einem Rating von A+, A oder B gemäß VHB-JOURQUAL3 (Stand 2015) entsprechen. Die auf Grundlage von Rahmenbedingung 2 ermittelten Artikel, die in Zeitschriften erschienen, die nicht im VHB-JOURQUAL3-Ranking aufgeführt sind, wurden zusätzlich nach dem Scimago Journal & Country Rank bewertet. Hierbei wurden nur Zeitschriften ausgewählt, die sich in 2019 im ersten Quartil befinden. Des Weiteren wurden nur Artikel berücksichtigt, die im Zeitraum 1998–2020

erschienen sind. Effectuation ist in die Entrepreneurship-Forschung einzugliedern (Saravathy & Dew, 2003) und wurde entsprechend Rahmenbedingung 2 zunächst nicht weiter eingrenzt. Um bei der Literaturrecherche eine möglichst große Trefferquote zu erzielen, wurde Web-of-Science als Meta-Datenbank gewählt (Rahmenbedingung 3). Um relevante Literatur zur erhalten, wurde auf Grundlage von Rahmenbedingung 4 der Suchbegriff *effectua**¹ verwendet.

Durch Anwendung der Literaturkriterien 1, 3 und 4 konnten 685 wissenschaftliche Artikel ermittelt werden. Um eine Übersicht darüber zu bekommen, in welchen Forschungsfeldern die erhaltenen Suchergebnisse verortet sind, erfolgt eine Zuordnung durch die Kategorisierungsvorschläge der jeweiligen Zeitschriften und von *Web-of-Science*. Abbildung 1.2 veranschaulicht die Artikel-Forschungsfelder-Zuordnung². Um Bedingung 2 der Literatursuchkriterien zu genügen, wurde die ursprüngliche Suchabfrage, die die Bedingungen 1, 3 und 4 befriedigt, mit einer weiteren Suchabfrage in *Web-of-Science* kombiniert, die den Suchbegriff *entrepreneur** enthält. Die Suchabfragen wurden mit Hilfe eines *AND*-Operators verknüpft. Dadurch konnten 174 Einträge gefunden werden.

Dem Vorschlag von Wolfswinkel et al. (2013) folgend wurden zusätzlich die Abstracts und Titel der Suchergebnisse geprüft und auf ihren thematischen Bezug zur ursprünglich von Saravathy (2001) begründeten Effectuation-Theorie bzw. zur Entrepreneurship-Forschung im Allgemeinen hin untersucht. Dabei konnte festgestellt werden, dass zwei Artikel nicht den geforderten Kriterien entsprachen und sich die Zahl der grundsätzlich relevanten Publikationen auf 172 verringerte. Eine Übersicht der ermittelten wissenschaftlichen Artikel ist in Anhang A.1 im elektronischen Zusatzmaterial dargestellt.

Damit es möglich ist, die Veröffentlichungen thematisch zu erfassen und Schwerpunktthemen zu identifizieren, schlagen Felizardo et al. (2014) im Rahmen einer systematischen Übersichtsarbeit die Visualisierung der Inhalte mittels Textmining-Techniken vor. Feng et al. (2017) stellen in diesem Zusammenhang Softwarelösungen vor, die es erlauben, Ergebnisse einer Literaturanalyse grafisch aufzubereiten. Das von Eck und Waltman (2017) entwickelte Programm *VOSviewer*, das in der Arbeit von Feng et al. (2017) neben anderen aufgezeigt wird, bietet die Möglichkeit, die aus einer Literatursuche ermittelten Titel, Abstracts und Schlüsselwörter zu klassifizieren. Dadurch können Karten erstellt werden, die die Beziehungen zwischen Themenclustern illustrieren.

¹ Das Symbol * dient hierbei als Platzhalter für beliebig viele weitere Zeichen, da neben Effectuation auch Begriffe wie beispielsweise *effectual* auftauchen können.

² Ein Artikel kann mehreren Forschungsfeldern zugeordnet sein.

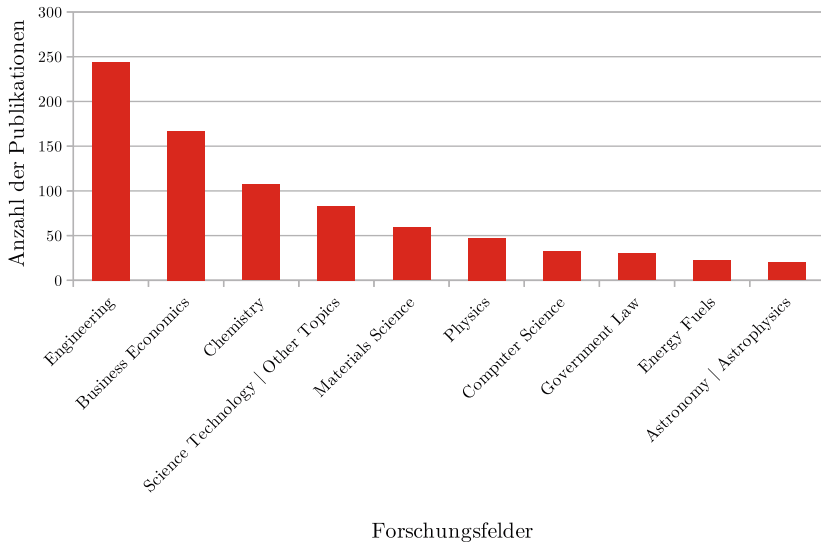


Abb. 1.2 Zuordnung der anhand der Literatursuchbedingungen erhaltenen Suchergebnisse zu Forschungsfeldern

Zur Visualisierung der relevanten Themengebiete wurden zunächst die aus der Literaturanalyse mit *Web-of-Science* erhaltenen bibliografischen Daten der 172 Publikationen in *VOSviewer* importiert. Anschließend wurde der Kookkurrenz-Analysetyp gewählt, bei dem die Verwandtschaft von Schlüsselwörtern auf Grundlage der Anzahl von Dokumenten, in denen sie gemeinsam auftreten, bestimmt wird. Zur Berechnung der Anzahl wurde die *Fractional-Counting-Zählmethode* angewendet (Perianes-Rodriguez et al., 2016). Zur Clusterbildung wurde die minimale Anzahl des Auftretens eines Schlüsselwortes auf den Wert 5 gesetzt. Von durch *VOSviewer* 909 identifizierten Schlüsselwörtern erreichten 76 diesen Schwellwert. Durch die von *VOSviewer* genutzten Text-Mining-Methoden konnten vier Themencluster bestimmt werden. Diese sind in Abbildung 1.3 mit unterschiedlichen Farben markiert. Jeder Kreis mit einem dazugehörigen Text stellt ein Schlüsselwort dar und repräsentiert einen Knoten. Je größer der Umfang eines Kreises ist, desto häufiger tritt dieser Schlüsselbegriff auf. Die Verbindung zwischen Knoten wird mittels Linien visualisiert. Je dicker eine Linie zwischen zwei Knoten ist, desto häufiger treten die Begriffe gemeinsam auf. Ausdrücke wie *effectuation* und *causation* tauchen besonders häufig auf. Der Begriff *effectuation* kommt oft im Zusammenhang mit

In der Arbeit von Mauer et al. (2017) wird eine neue methodische Sichtweise zur Erforschung von Effectuation vorgeschlagen und Einblicke in die konkrete Umsetzung und Anwendung der Methodik diskutiert. Mauer et al. (2017) entwickeln einen Rahmen für einen nach bestimmten Regeln (steuerungsbasiert und vorhersagebasiert) agierenden Agenten und geben Aufschluss über die Leistung der Agenten im gründungsbezogenen Problemraum (Isotropie, Ziel-Ambiguität und Ungewissheit). Das Entscheidungsverhalten des Agenten ist dabei prozedural modelliert. Es vernachlässigt das Lernverhalten des Entrepreneur-Agenten.

Welter und Kim (2018) stellen einen mit Hilfe eines NK-Modells entwickelten Ansatz vor, der ebenfalls die Anpassung der Strategie des Agenten im Prozess vernachlässigt. Dabei werden wie bei Mauer et al. (2017) konkrete Vorschläge zur Umsetzung des Modells diskutiert.

S. X. Zhang und Van Burg (2019) betrachten Effectuation aus einer Design-Science-Perspektive und schlagen grundlegende Gestaltungsprinzipien zur Modellierung von Effectuation vor, die auf aus der Biologie abgeleiteten genetischen Algorithmen aufbauen. Dedizierte Modellierungs- und Implementierungsansätze werden in diesem Kontext nicht erläutert.

Auf Basis des aus der Literaturanalyse gewonnenen Überblicks können Forschungspotentiale identifiziert werden, die im Rahmen der Effectuation-Forschung zu einer Weiterentwicklung des Theoriengerüsts beitragen. S. X. Zhang und Van Burg (2019) geben Hinweise auf weitere Forschungsaktivitäten und sind der Auffassung, dass „future studies can explore how entrepreneurs can use AI [Artificial Intelligence] nondeterministic models as decision support for path-dependent decision-making under uncertainty.“ (S. X. Zhang & Van Burg, 2019, S. 622). Dieser Forschungsbedarf kann mit der Evaluierung mathematischer Modelle, die Entscheidungs- und Lernverhalten abbilden, gedeckt werden. Im Bereich der Multi-Agenten-Systeme existieren eine Reihe von Methoden, die verschiedene Verhaltensformen abbilden können (Panait & Luke, 2005). Mit einer Operationalisierung von Entrepreneurship-Theorien, wie Effectuation und Causation, wird der Erfolg der angewendeten Modelle messbar gemacht (Chandler et al., 2011; Jiang & Rüling, 2017).

Aufbauend auf dem aktuellen Stand der Effectuation-Forschung, insbesondere im Hinblick auf simulationsgestützte Modelle, und dem Finden einer Möglichkeit, um effektuatives Lernverhalten nachzubilden, ergibt sich für die weitere Arbeit folgende Forschungsfrage: *Wie kann effektuatives Entscheidungs- und Lernverhalten modelliert und algorithmisch interpretiert werden?*

1.3 Gliederung der Arbeit

In den vorhergehenden Abschnitten dieses Kapitels wurden die Grundlagen der Entrepreneurship-Theorie Effectuation vorgestellt und der diesbezügliche aktuelle Stand der Wissenschaft literaturanalytisch behandelt. Darauf aufbauend wurde eine Eingrenzung des Forschungsfeldes vorgenommen und relevante Forschungsbedarfe identifiziert. Diese bildeten die Basis für die Formulierung der Forschungsfrage.

In Kapitel 2 der Arbeit werden entscheidungstheoretische Grundlagen im Kontext von Effectuation diskutiert, um eine differenzierte und detaillierte Betrachtung der effektuativen Entscheidungslogik zu ermöglichen. Dabei wird auf in der Literatur zu findende Verbindungen zwischen Effectuation und etablierten entscheidungstheoretischen Ansätzen Bezug genommen. Vorrangig werden dabei die Begriffe der Ungewissheit – als zentrales Element des entrepreneurialen Problemraums – und des Bayesianismus untersucht. Beide Konzepte bilden die Voraussetzung für eine Reihe von Inferenzmethoden. In diesem Zusammenhang werden Ansätze des maschinellen Lernens vorgestellt und bestehende Anwendungen im entrepreneurialen Kontext erörtert. Kapitel 2 behandelt theoretische Vorüberlegungen zur Beantwortung der in Abschnitt 1.2 formulierten Forschungsfrage.

Kapitel 3 befasst sich mit der Untersuchung bereits existierender effektuativer Simulationsmodelle. Diese werden zunächst hinsichtlich ihrer Eigenschaften und Abläufe analysiert, um ein allgemeines Verständnis für die Wirkungsweisen der Modelle zu entwickeln. Die damit einhergehende Betrachtung der gewählten Methoden gibt Aufschluss über mögliche Gestaltungsaspekte bei der Modellierung effektuativer Entscheidungsfindung. Durch die Gegenüberstellung der Simulationsmodelle können Konstruktionsansätze abgeleitet werden, die zur Beantwortung der Forschungsfrage notwendig sind. Darauf aufbauend werden ausgewählte Modelle mathematisch formuliert und algorithmisch interpretiert, um die zugrundeliegenden Architekturen und Mechanismen transparent zu machen. Dieses Vorgehen ermöglicht die replizierten Modelle zu implementieren und Simulationen durchzuführen. Anschließend werden die Ergebnisse mit denen aus bestehenden Arbeiten, die effektuativer Simulationsmodelle behandeln, verglichen.

In Kapitel 4 wird die für die Arbeit relevante Forschungsmethodik vorgestellt. Dabei wird das Konzept der agentenbasierten Modellierung zur Abbildung emergenter Systeme eingeführt. Auf Grundlage dessen erfolgt die Entwicklung eines auf Reinforcement Learning basierenden Effectuation-Modells. Hierfür wird zunächst ein entrepreneurialer Lernproblem konstruiert. Die Modellierung der Umgebung und der Handlungsmöglichkeiten schaffen den Rahmen zur Lösung des Problems durch einen Agenten. Zur Steuerung effektuativen Verhaltens wird ein Anreizmechanismus formuliert und ein erfahrungsbasiertes Lernverfahren präsentiert.

Abschließend wird ein Ansatz zur Standardisierung des Modells und künftiger effektuativer Lernmodelle vorgeschlagen.

Die Ergebnisse der durchgeführten Lernsimulationen werden in Kapitel 5 dargestellt. Dabei wird das Lernverhalten eines effektuativen Agenten bei Änderung ausgewählter Umgebungsparameter untersucht. Zudem wird das Anreizsystem zur Steuerung effektuativen Verhaltens manipuliert und Auswirkungen auf den Lernprozess evaluiert. Die Leistungsfähigkeit eines effektuativen Agenten wird zudem mit der einer konkurrierenden Strategie verglichen. Zur Verbesserung des Lernverhaltens des effektuativ agierenden Agenten werden anschließend Hyperparameterstudien durchgeführt.

In Kapitel 6 werden die aus der Arbeit gewonnenen Erkenntnisse zusammengefasst und aus den Lernsimulationen ermittelte Ergebnisse im Kontext der eingangs formulierten Forschungsfrage diskutiert. Darüber hinaus werden Einschränkungen dargestellt, denen das methodische Vorgehen und die erarbeiteten Erkenntnisse unterlegen sind. Die aus dem Überblick erhaltenen Kernelemente sowie die diskutierten Limitationen der wissenschaftlichen Arbeit erlauben die Ableitung von künftigen Untersuchungsbedarfen und geben einen Ausblick auf mögliche weitere Forschungsvorhaben.

Open Access Dieses Kapitel wird unter der Creative Commons Namensnennung 4.0 International Lizenz (<http://creativecommons.org/licenses/by/4.0/deed.de>) veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden.

Die in diesem Kapitel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.





Aspekte entscheidungstheoretischer Grundlagen im Rahmen von Effectuation

2

In Sarasvathy (2009) werden entscheidungstheoretische Konzepte vorgestellt, die das Vorgehen effektiv handelnder Entrepreneur:innen begründen. Diese Ideen sollen im Folgenden präsentiert und diskutiert werden. Darüber hinaus werden Ansätze im Kontext von Effectuation erarbeitet, die über die bisher in der Literatur zu findenden Ausführungen hinausgehen. Sie stellen die Grundlage für das entwickelte effektive Entscheidungsmodell dar.

2.1 Bayesianismus im Kontext von Effectuation

Die Verwendung von Methoden der wahrscheinlichkeitstheoretischen Strömung Bayesianismus durch effektiv handelnde Entrepreneur:innen wird in Sarasvathy (2009, S. 137–144) behandelt. Sarasvathy erläutert darin ihre Interpretation des bayesschen Wahrscheinlichkeitsbegriffs im Zuge der Bewertung von gründungsrelevanten Situationen und den Umgang mit diesen.

Bayesianismus wird in diesem Zusammenhang als Verfahren zur Steuerung von Zuständen der Natur beschrieben, die mit den eigenen Überzeugungen in Einklang gebracht werden können (Sarasvathy, 2009, S. 138). Im klassischen Sinne stellt Bayesianismus eine Möglichkeit zur Inferenz dar und wird zur Aktualisierung der persönlichen Überzeugungen im Hinblick auf die Zustände der Natur unter Verwendung gewisser Vorinformationen verwendet (Kumam et al., 2017).

Für die Handlungen von Seriengründer:innen unter bayesschen Voraussetzungen sind zwei Interpretationen zu finden. Bezugnehmend auf klassische Ansichten wird in Sarasvathy (2009, S. 138) wie folgt argumentiert: Die Beobachtung, dass die Rate des Scheiterns von Unternehmen sehr hoch ist, erlaubt den Schluss, dass das Gründen mehrerer unabhängiger Unternehmen sinnvoll ist. Im Kontext von Effectuation kann das bayessche Theorem nach (Sarasvathy, 2009, S. 138) so interpretiert

werden: Ungeachtet dessen, wie hoch die Wahrscheinlichkeit für das Scheitern von Unternehmen ist, kann der Erfolg des Entrepreneurs durch Seriengründen erhöht werden. Beide Deutungen resultieren im Seriengründen. Die Herangehensweise an die Bewertung einer Entscheidungssituation ist jedoch eine andere.

In Read et al. (2016) wird aufgezeigt, dass die Erläuterungen zu den bayesianischen Grundlagen in der Effectuation-Theorie nicht ausreichend sind und detaillierter dargestellt werden müssen. Um diesen Umstand Rechnung zu tragen, werden in den Abschnitten 2.1.1 und 2.1.2 bayessche Entscheidungsmethoden diskutiert und die Übertragung auf Effectuation behandelt.

2.1.1 Zum bayesschen Wahrscheinlichkeitsbegriff

Der Bayesianismus hat historisch gesehen eine Reihe von Interpretationen erlebt und wurde aus verschiedenen Perspektiven betrachtet. Es bildeten sich Hauptströmungen heraus, die den Bayesianismus in seiner heutigen Anschauung prägten. Hierbei sind insbesondere der Subjektive Bayesianismus, der Empirische Bayesianismus und der Logische Bayesianismus zu nennen (Corfield & Williamson, 2001).

Im Subjektiven Bayesianismus werden a-priori-Wahrscheinlichkeiten einzig und allein als Grad persönlicher und rationaler Überzeugung repräsentiert und unterliegen lediglich der Einschränkung, dass sie kohärent im Rahmen der vorliegenden Informationen sein müssen. In der Folge werden die ursprünglich getroffenen Annahmen bezüglich der a-priori-Wahrscheinlichkeit mit Hilfe hinzugewonnener Daten aktualisiert und resultieren in der a-posteriori-Wahrscheinlichkeit (de Finetti, 1974).

Der Empirische Bayesianismus stellt eine Kalibrierung des Subjektiven Bayesianismus dar. Die Grade persönlicher Überzeugung werden mit Hilfe von objektiven Häufigkeiten, sofern diese bekannt sind, ausgedrückt. Dieser Zusammenhang impliziert jedoch das Problem der Referenzklassen. Bayesianische Wahrscheinlichkeiten, nach dem Vorbild des Subjektiven Bayesianismus, beziehen sich auf einen einmaligen Fall, der mittels Sätzen oder Ereignissen formuliert wird. Häufigkeiten hingegen stützen sich auf einen übergeordneten Fall, der über Klassen von Ergebnissen definiert wird. Zu ermitteln, welche Häufigkeit mit welchem gegebenen Grad der Überzeugung kalibriert werden muss, ist nicht ohne Weiteres möglich (Ramsey, 1964). Das *Principal Principle* von D. Lewis (1980) versucht dieses Problem zu umgehen, indem es eine explizite Verbindung zwischen Graden der Überzeugung und objektiven Wahrscheinlichkeiten einmaliger Fälle postuliert.

Eine weitere Perspektive des bayesschen Wahrscheinlichkeitsbegriffs stellt der Logische Bayesianismus dar. Dieser beschreibt zum einen eine Wahrscheinlichkeit

$P(B|A)$ als den Grad, zu dem Ereignis A teilweise Ereignis B zur logischen Folge hat und zum anderen den Grad, zu dem ein rationaler Agent an das Eintreten von B glauben sollte, sofern dieser Kenntnis davon hat, dass A eingetreten ist. Dieser Ansatz suggeriert Objektivität, da zwei verschiedene Agenten mit dem selben Wissen nicht unterschiedliche Evidenzfunktionen verfolgen können, ohne sich dabei rational zu verhalten (Keynes, 1921, S. 32).

Empirischer und Logischer Bayesianismus können zum Objektiven Bayesianismus vereint werden. Zusammengefasst halten Objektive Bayesianisten das Postulat Subjektiver Bayesianisten für nicht ausreichend, dass eine Evidenzfunktion lediglich den Axiomen der Wahrscheinlichkeit genügen muss. Um als rational eingestuft zu werden, müssen weitere Bedingungen erfüllt sein (Corfield & Williamson, 2001, S. 2).

Bayesianismus hat bis heute Einzug in viele Wissenschaftsgebiete gehalten. So finden sich bayessche Erklärungsmodelle beispielsweise im Bereich der Künstlichen Intelligenz und der Wirtschaftswissenschaften wieder. Bayesianismus wird hierbei auch im Zusammenhang mit Kausalität diskutiert (Corfield & Williamson, 2001, S. 3 f.).

2.1.2 Das Bayes-Theorem

Das Bayes-Theorem bildet eine wichtige Grundlage bei der Betrachtung von Entscheidungen. Es dient somit der Modellierung von Lernprozessen. Bedingte Wahrscheinlichkeiten helfen, neue Informationen zu verarbeiten. Dadurch ist ein Agent in der Lage, bisher getroffene Entscheidungen zu überdenken. Die geistige Konstruktion der Umwelt kann angepasst und Situationen neu eingeschätzt werden (Wessler, 2012, S. 158).

Bedingte Wahrscheinlichkeiten stellen einen Zusammenhang zwischen der vor Informationserhalt vorhandenen (a-priori-) Wahrscheinlichkeit für den bestimmten Zustand S_s ($s = 1, 2, \dots, n_S$) und der (a-posteriori-) Wahrscheinlichkeit eben dieses Zustandes nach Eintritt des Informationsereignisses I_i ($i = 1, 2, \dots, n_I$) dar. Das Bayes-Theorem beruht auf bedingten Wahrscheinlichkeiten und drückt die stochastische Abhängigkeit zwischen den Zuständen und Informationsereignissen durch Wahrscheinlichkeiten aus (Laux et al., 2014, S. 304).

In der vorliegenden Arbeit werden ausschließlich diskrete Zustandsräume betrachtet, um die Komplexität der entwickelten Definitionen und Modelle auf ein Minimum zu beschränken. Zur mathematischen Beschreibung des Bayes-Theorems wird zunächst der Wahrscheinlichkeitsraum in der für diese Arbeit sinnvollen Form definiert.

Definition 2.1 (Wahrscheinlichkeitsraum)

Die Ergebnismenge eines Zufallsexperiments sei definiert als

$$\Omega := \{\omega_1, \omega_2, \dots\}.$$

Das Ereignissystem \mathcal{A} wird mit

$$\mathcal{A} := \mathcal{P}(\Omega)$$

als Potenzmenge der Ergebnismenge definiert.

Das Wahrscheinlichkeitsmaß P wird für \mathcal{A} mit

$$P : \mathcal{A} \rightarrow [0, 1]$$

definiert und genüge für $A \in \mathcal{A}$ den von Kolmogoroff (1933, S. 2) eingeführten Axiomen:

1. $0 \leq P(A) \leq 1$,
2. $P(\Omega) = 1$,
3. $P\left(\bigcup_i A_i\right) = \sum_i P(A_i)$, wenn $A_i \cap A_j = \emptyset \forall i \neq j$

Das Tripel (Ω, \mathcal{A}, P) heißt Wahrscheinlichkeitsraum.

Es seien zudem die Zustände S_s für $s = 1, 2, \dots, n_S$ und die Informationsereignisse S_s für $i = 1, 2, \dots, n_I$ Ereignisse über Ω mit den Ergebnissen $\omega \in S_s$ und $\omega \in I_i$, wobei $S_s, I_i \subset \Omega$ ist.

Der Satz von Bayes kann ausgehend vom definierten Wahrscheinlichkeitsraum wie folgt dargestellt werden.

Definition 2.2 (a-priori-Wahrscheinlichkeit)

Sei $P(S_s)$ die a-priori-Wahrscheinlichkeit, dass der Zustand S_s ($s = 1, 2, \dots, n_S$) eintritt, ohne Kenntnis vom Informationsereignis I_i ($i = 1, 2, \dots, n_I$) zu haben.

Sei $P(I_i)$ die a-priori-Wahrscheinlichkeit für das Informationsereignis I_i ($i = 1, 2, \dots, n_I$).

Dann heißt $P(I_i|S_s) = \frac{P(I_i \cap S_s)}{P(S_s)}$ Likelihood des Zustands S_s bezüglich des Informationsereignisses I_i unter der Voraussetzung, dass $P(S_s) \neq 0$ gilt.

Durch Kenntnis der Likelihood $P(I_i|S_s)$ und der a-priori-Wahrscheinlichkeit $P(S_s)$ ist die Berechnung der folgenden Wahrscheinlichkeiten möglich:

Definition 2.3 (a-posteriori-Wahrscheinlichkeit)

$P(S_s|I_i)$ heißt *a-posteriori-Wahrscheinlichkeit* für den Zustand S_s ($s = 1, 2, \dots, n_S$) unter der Bedingung, dass I_i ($i = 1, 2, \dots, n_I$) das Ergebnis der Beschaffung der Information ist, das heißt, dass das Informationsereignis I_i eingetreten ist.

Zur Bestimmung der Wahrscheinlichkeiten $P(I_i)$ und $P(S_s|I_i)$ gilt allgemein:

$$P(S_s \cap I_i) = P(I_i|S_s) \cdot P(S_s). \quad (2.1)$$

Hierbei ist $P(S_s \cap I_i)$ die Wahrscheinlichkeit dafür, dass sowohl das Informationsereignis I_i als auch der Zustand S_s eintritt. Offenbar gilt ebenfalls:

$$P(S_s \cap I_i) = P(S_s|I_i) \cdot P(I_i). \quad (2.2)$$

In Kombination mit Gleichung (2.1) folgt:

$$P(S_s|I_i) = \frac{P(I_i|S_s) \cdot P(S_s)}{P(I_i)}. \quad (2.3)$$

Die totale Wahrscheinlichkeit $P(I_i)$ des Informationsereignisses I_i kann folgendermaßen berechnet werden:

$$P(I_i) = \sum_{s=1}^{n_S} P(S_s \cap I_i) = \sum_{s=1}^{n_S} P(I_i|S_s) \cdot P(S_s) \quad (i = 1, 2, \dots, n_I), \quad (2.4)$$

sofern

$$\bigcup_{s=1}^{n_S} S_s = \Omega \text{ und } S_i \cap S_j = \emptyset \text{ für } i \neq j.$$

Gleichung (2.4) wird auch als *Satz der totalen Wahrscheinlichkeit* bezeichnet.

In Verbindung mit Gleichung (2.3) lässt sich der *Satz von Bayes* wie folgt beschreiben:

$$P(S_s|I_i) = \frac{P(I_i|S_s) \cdot P(S_s)}{\sum_{s=1}^{n_S} P(I_i|S_s) \cdot P(S_s)} \quad (i = 1, 2, \dots, n_I; s = 1, 2, \dots, n_S). \quad (2.5)$$

Das Bayes-Theorem aus Gleichung (2.5) verdeutlicht, wie die a-posteriori-Wahrscheinlichkeiten $P(S_s|I_i)$ aus den a-priori-Wahrscheinlichkeiten $P(S_s)$ berechnet werden können, unter der Voraussetzung, dass die Likelihoods $P(I_i|S_s)$ gegeben sind.

Die Wahrscheinlichkeiten, die ein Agent nach Informationserhalt I_i den Zuständen S_1, S_2, \dots, S_{n_s} zuordnet, hängen, basierend auf Gleichung (2.5), von folgenden Faktoren ab:

- Festlegung der a-priori-Wahrscheinlichkeiten $P(S_1), P(S_2), \dots, P(S_{n_s})$ für die Zustände vor dem Erhalt zusätzlicher Informationen durch den Agenten
- Einschätzung der stochastischen Abhängigkeit zwischen den Zuständen S_1, S_2, \dots, S_{n_s} und den Informationsereignissen I_1, I_2, \dots, I_{n_i} vor Informationserhalt durch den Agenten in Form der bedingten Wahrscheinlichkeiten $P(I_i|S_s)$
- Tatsächliches Eintreten des Informationsereignisses I_i

Eine weitere Bedingung für den *Satz von Bayes* bezieht sich auf die Informationsereignisse I_1, I_2, \dots, I_{n_i} . Diese sind nur dann prognoserelevant und damit für die Berechnung der a-posteriori-Wahrscheinlichkeiten essentiell, wenn ihre Ausprägungen stochastisch abhängig vom Zustand sind. Es ergibt sich sonst offenbar $P(S_s|I_i) = P(S_s)$. Es ist generell nur ein probabilistischer Rückschluss auf den Zustand möglich ist. Das Urteilen hinsichtlich des Zustandes verbessert sich jedoch durch das Auftreten prognoserelevanter Informationen (Laux et al., 2014, S. 305).

Aufbauend auf den vorangegangenen Definitionen wird im Folgenden eine vereinfachte Übertragung des Satzes von Bayes auf effektuatives Schließen vorgenommen. Dies ermöglicht den ursprünglich von Sarasvathy (2009, S. 138) rudimentär formulierten Vergleich von Effectuation und bayesschem Schließen anschließend zu diskutieren.

Definition 2.4 (Wahrscheinlichkeitsraum im Kontext von Effectuation)

Der Wahrscheinlichkeitsraum (Ω, \mathcal{A}, P) sei konkret mit

$$\Omega \hat{=} \text{zukünftige Erfolgssituationen der Unternehmen des Agenten}$$

mit den Elementen $\omega_1, \omega_2, \dots$ bestimmt, wobei für die einzelnen Unternehmen U_1, U_2, \dots , die mit $+$ (erfolgreich) oder $-$ (gescheitert) sein können, gilt

$$\begin{aligned}
\omega_1 &: U_1^+ \\
\omega_2 &: U_1^- \\
\omega_3 &: U_1^+ U_2^+ \\
\omega_4 &: U_1^- U_2^+ \\
\omega_5 &: U_1^+ U_2^- \\
\omega_6 &: U_1^- U_2^- \\
\omega_7 &: U_1^+ U_2^+ U_3^+ \\
&\vdots
\end{aligned}$$

Zudem seien die Ereignisse

$S_s \dots$ Anzahl der gegründeten Unternehmen des Agenten ist s für
 $s = 1, 2, \dots$ und

$I_i \dots$ Anzahl der gescheiterten Unternehmen des Agenten ist i für
 $i = 1, 2, \dots$

mit $S_s, I_i \subset \Omega$ definiert.

Offenbar gilt

$S = \Omega \setminus \{\omega_1, \omega_2\} \dots$ Anzahl der gegründeten Unternehmen des Agenten ist
größer als 1,

$I = \Omega \setminus \{\omega_1, \omega_3, \omega_7, \dots\} \dots$ Anzahl der gescheiterten Unternehmen des
Agenten ist mindestens 1.

A und P seien gemäß Definition 2.1 festgelegt.

Wird der Satz von Bayes auf das Beispiel von Sarasvathy aus Sarasvathy (2009, S. 138) angewendet, ist folgende Definition zweckmäßig:

Korollar 2.5 (Satz von Bayes im Kontext von Effectuation)

$P(I) \hat{=}$ Wahrscheinlichkeit dafür, dass mindestens ein gegründetes Unternehmen
des Agenten, in diesem Fall der Entrepreneur, scheitert.

$P(S) \hat{=}$ Wahrscheinlichkeit dafür, dass der Agent mehr als ein Unternehmen grün-
det.

$P(I|S) \hat{=}$ Wahrscheinlichkeit dafür, dass der Agent mit mindestens einem Unternehmen scheitert, unter der Annahme, dass er mehr als ein Unternehmen gründet.
 $P(S|I) \hat{=}$ Wahrscheinlichkeit dafür, dass der Agent mehr als ein Unternehmen gründet, unter der Bedingung, dass mindestens ein Unternehmen gescheitert ist.

Wie bereits im Abschnitt 2.1 angedeutet, würde ein Agent bzw. Serienentrepreneur im klassischen Sinne des Bayesianismus aus der Beobachtung, dass viele Unternehmen scheitern, schließen, dass es der Gründung mehrerer Unternehmen bedarf. Sarasvathy (2009, S. 138) schreibt dazu konkret:

„I observe that the probability of firm failure is very high. Therefore I will start several firms.“

Sarasvathy definiert jedoch nicht hinreichend genau, ob mit der Beobachtung die a-priori-Wahrscheinlichkeit $P(I)$ oder die bedingte Wahrscheinlichkeit $P(I|S)$ gemeint ist. Aufgrund der Schlussfolgerung, dass der Agent mehrere Unternehmen gründet, wenn er beobachtet, dass viele Unternehmen scheitern, ist anzunehmen, dass $P(S|I)$ die a-posteriori-Wahrscheinlichkeit darstellt. Diese besagt, wie wahrscheinlich es ist, dass ein Agent mehrere Unternehmen gründet, sofern er beobachtet hat, dass mindestens ein bereits von ihm gegründetes Unternehmen gescheitert ist. Folglich kann $P(I)$ nur als a-priori-Wahrscheinlichkeit verstanden werden, dass mindestens ein vom Agenten gegründetes Unternehmen scheitert.

Unter der Voraussetzung, dass neben $P(I)$ die Wahrscheinlichkeiten $P(S)$ und $P(I|S)$ bekannt sind, kann mit Hilfe des *Satz von Bayes* aus Gleichung (2.5) ermittelt werden, wie hoch die Wahrscheinlichkeit des Agenten ist, mehr als ein Unternehmen zu gründen, falls mindestens ein Unternehmen scheitert. Diese Wahrscheinlichkeit ist kleiner als 1, solange die Wahrscheinlichkeit dafür, dass der Agent mit einem Unternehmen scheitert, größer als 0 ist.

Im effektuativen Fall, argumentiert Sarasvathy (2009, S. 138 f.), wird der Agent ebenfalls mehrere Unternehmen gründen, unabhängig davon wie hoch die Wahrscheinlichkeit ist, dass Unternehmen scheitern. Da Sarasvathy davon ausgeht, dass bei einer effektuativen Interpretation des Bayesianismus der Agent die Bedingungen gestalten möchte, beispielsweise durch das Gründen mehr als eines Unternehmens, ist anzunehmen, dass der Zweck die Gründung mindestens eines erfolgreichen Unternehmens ist. Konkret schreibt Sarasvathy (2009, S. 138) dazu:

„In the effectual interpretation, however, the entrepreneur reasons as follows: irrespective of what the probability of firm failure is, I can increase the probability of ‘my’ success through serial entrepreneurship.“

Der Argumentation Sarasvathys folgend, versucht ein effektiv handelnder Agent mehrere Unternehmen zu gründen, um die Wahrscheinlichkeit für seinen Erfolg zu erhöhen. Diese wird durch die bedingte a-posteriori-Wahrscheinlichkeit $P(S|I)$ ausgedrückt. Die Behauptung, dass Bayesianismus unter effektuativen Gesichtspunkten vielmehr ein Steuerungsmechanismus, als ein Inferenzmechanismus ist, kann demnach nicht bestätigt werden. In beiden Fällen werden Wahrscheinlichkeiten für das Eintreten eines bestimmten Zustandes geschätzt. Dieser wird im klassischen wie im effektuativen Fall anders definiert. Im klassischen Sinne wird die Wahrscheinlichkeit für das Eintreten des Ereignisses, dass der Agent mehr als ein Unternehmen gründet, geschätzt, unter der Bedingung, dass ein von ihm gegründetes Unternehmen gescheitert ist. Im effektuativen Beispiel wird versucht zu ermitteln, wie hoch die Wahrscheinlichkeit für den Erfolg des Unternehmens des Agenten ist, unter der Voraussetzung, dass $P(I)$ manipulierbar ist. $P(I)$ kann aus wahrscheinlichkeitstheoretischer Sicht jedoch nicht verändert werden, sondern ist lediglich beobachtbar als a-priori-Wahrscheinlichkeit (Peyrolón, 2020, S. 18). Unter Zuhilfenahme des *Satz von Bayes* aus Gleichung (2.5) kann die a-posteriori-Wahrscheinlichkeit $P(S|I)$ für das Gründen mehr als eines Unternehmens unter der Voraussetzung, dass mindestens ein bereits gegründetes Unternehmen des Agenten gescheitert ist (siehe Korollar 2.5), berechnet werden:

$$P(S|I) = \frac{P(I|S) \cdot P(S)}{P(I|S) \cdot P(S) + P(I|\bar{S}) \cdot P(\bar{S})} \quad (2.6)$$

Der Ausdruck $P(I|\bar{S})$ bildet die Wahrscheinlichkeit für das Eintreten von I unter der Bedingung, dass Ereignis S nicht eingetreten ist. \bar{S} stellt das Komplement zu S dar, damit bildet der Ausdruck $P(\bar{S})$ die Wahrscheinlichkeit, dass Nicht- S eingetreten ist.

Die a-priori-Wahrscheinlichkeit $P(S)$ spielt im Kontext gründungsrelevanter Situationen eine wichtige Rolle, da sie den Grad der Überzeugung an das Eintreten eines bestimmten Zustandes S vor Betrachtung möglicher entscheidungsunterstützender Informationen angibt, die bei der Etablierung eines Unternehmens verhältnismäßig rar sind (Alvarez & Parker, 2009, S. 214 f.).

Wird das entwickelte Beispiel zum grundsätzlichen Gründungsverhalten im Kontext bayesschem Schließens auf Entscheidungssituationen im Gründungs- sowie Produkt- und Dienstleistungsentwicklungsprozess erweitert, besteht die Notwendigkeit möglicherweise auftretende Ereignisse zu formulieren. Konkrete Ereignisse nach Treffen einer Entscheidung können im effektuativen Sinne veränderliche Ziele sein, die sich aus der Verwendung der zur Verfügung stehenden Mittel und dem kalkulierten leistbaren Verlust ergeben (Sarasvathy, 2009, S. 113 f.). Zur Bestimmung des Priors für das Eintreten eines Ereignisses und damit eines losen

Endes, sind in der Literatur verschiedene Methoden zu finden (Lemoine, 2019; Zondervan-Zwijnenburg et al., 2017). Die Maximum-Entropie-Methode, die in Jaynes (1957) vorgestellt wird, bietet die Möglichkeit a-posteriori-Wahrscheinlichkeiten unter Ungewissheit zu modellieren. Das Verfahren beruht auf den Überlegungen zur Entropie im Rahmen der Informationstheorie (Shannon, 1948). Entropie stellt, neben ihrer üblichen Interpretation des mittleren Informationsgehaltes einer Nachricht, auch ein Maß für die Ungewissheit dar (Werner, 2008, S. 5).

Die Maximum-Entropie-Methode gilt als Verallgemeinerung des Indifferenzprinzips von Laplace. Dieses wird auch als *Prinzip vom unzureichenden Grund* bezeichnet und besagt, dass, in Abwesenheit zusätzlicher Informationen, sich gegenseitig ausschließende Ergebnisse mit einer diskreten Gleichverteilung anzusetzen sind (Kreinovich, 2008, S. 16 f.).

Zusammenfassend ist festzustellen, dass zur durch Sarasvathy (2009, S. 137–144) eingeführten Unterscheidung von bayesschem und effektuativem Schließen eine klare Definition der entscheidungsrelevanten Bestandteile benötigt wird. Mit der sich aus Definition 2.4 ergebenden Bildung des Wahrscheinlichkeitsraums und der darauf aufbauenden bayesschen Anwendung (siehe Korollar 2.5) im Kontext von Effectuation, können entscheidungstheoretische Elemente der Inferenzmechanismen transparent dargestellt werden. Ein Ansatz zur Modellierung effektuativen Entscheidens konnte damit nachgewiesen werden.

2.2 Ungewissheit

Das Thema Ungewissheit wird in Werken, die aus der Entrepreneurship-Forschung resultieren, divers diskutiert (Townsend et al., 2018, S. 564), bildet es doch die Grundlage für die Entscheidungsfindung im Prozess des Gründens (Packard et al., 2017, S. 1).

Eine rudimentäre Erklärung des Begriffs der Ungewissheit wird in Petrakis und Konstantakopoulou (2015, S. 11) geliefert. Demzufolge ist der Zeitablauf mit Veränderungen assoziiert, wodurch Ungewissheit auftritt, die wiederum eine Schlüsselkomponente der Zukunft ist. Diese wiederum beinhaltet eine Kombination von Faktoren, die nicht einfach identifiziert und gesteuert werden können. Die Elemente werden *Möglichkeit*, *Gelegenheit*, *Zufall* oder *Glück* genannt.

Eine weitere Beschreibung bezeichnet Ungewissheit als eine vom Individuum wahrgenommene Unfähigkeit, etwas aufgrund des Mangels hinreichender Informationen genau vorherzusagen. Ungewissheit kann dabei noch einmal in Ungewissheit des Zustands, des Ergebnisses und der Antwort klassifiziert werden. Wobei sich die Ungewissheit des Zustandes auf den Mangel an Informationen über bestehende

Bedingungen bezieht. Ungewissheit des Ergebnisses bezieht sich auf das fehlende Wissen über den Zusammenhang von Ursache und Wirkung, während die Ungewissheit der Antwort das fehlende Wissen über die mögliche Rückmeldung des Marktes und weiterer Akteure, nachdem eine Handlung ausgeführt wurde, repräsentiert (Milliken, 1987, S. 134–143).

Ein Klassifizierungsschema von Ungewissheit im Kontext von unternehmerischen Gelegenheiten wird in Tomy und Pardede (2018, S. 615) geliefert. Ungewissheit kann entsprechend in die folgenden Ausprägungen gegliedert werden:

- Technologische Ungewissheit
- Politische Ungewissheit
- Wettbewerbsungewissheit
- Kundenungewissheit
- Ressourcenungewissheit

Technologische Ungewissheit beinhaltet die unzureichende Kenntnis über ein technologisches System oder das Vorhandensein weiterer technischer Lösungen, die dasselbe Problem adressieren (Meijer, 2008, S. 35). In der politischen Dimension beschreibt Ungewissheit das Fehlen von Informationen über das Verhalten von Regierungen, Regimen und politischen Dominanzen im Allgemeinen. Politische Faktoren haben Einfluss auf den Gestaltungsspielraum von Unternehmen (Rakesh, 2014, S. 20). Wettbewerbsungewissheit bezieht sich auf die mangelnde vollständige Kenntnis hinsichtlich der Konkurrenz und ihrer Produkte sowie Strategien, um am Markt zu bestehen (Yadav et al., 2006, S. 60). Das fehlende vollständige Wissen über die Nutzerakzeptanz und Nachfrage, bezogen auf ein Produkt oder eine Dienstleistung, werden als Kundenungewissheit klassifiziert (Gentry et al., 2013, S. 528). Ressourcenungewissheit stellt die Ungewissheit über die Verfügbarkeit von finanziellen und Human-Ressourcen dar (Meijer, 2008, S. 37).

Sarasvathy unterscheidet Ungewissheit weniger nach umweltbezogenen Gesichtspunkten, sondern vielmehr nach dem Wissen über mögliche Ergebnisse einer Entscheidung und deren zugrundeliegenden Verteilung (Sarasvathy, 2009, S. 26). Mit ihrer Taxonomie bezieht sie sich auf das Grundlagenwerk zur Ungewissheit *Risk, Uncertainty and Profit* von Knight.

Die Unterscheidung zwischen Risiko und Ungewissheit wird in Knight (1921) herausgestellt. Risiko wird hierbei als Fähigkeit charakterisiert, möglichen Umweltzuständen eine Wahrscheinlichkeitsverteilung zuzuordnen. Im Risikofall kann nicht mit Gewissheit angegeben werden, was als Nächstes passieren wird. Jedoch sind alle möglichen Umweltzustände bekannt, die eintreten können sowie die dazugehörige Wahrscheinlichkeitsverteilung (Townsend et al., 2018, S. 667).

Ungewissheit wird diesbezüglich nochmals in zwei Arten unterschieden. Im ersten Fall sind die möglichen Umweltzustände einer Handlung bekannt. Die Wahrscheinlichkeitsverteilung, der sie unterliegen, kann allerdings nicht bestimmt werden. Im zweiten Fall sind weder die von der Entscheidung des Entrepreneurs abhängigen Eintrittswahrscheinlichkeiten der Umweltzustände bekannt, noch sind die möglichen Umweltzustände bekannt, die aus der Entscheidung resultieren können (Sarasvathy, 2009, S. 26).

Die Differenzierung des begrifflichen Spektrums von Ungewissheit, welche für das Verständnis entrepreneurialer Entscheidungssituationen von zentraler Bedeutung ist, wird von Knight folgendermaßen zusammengefasst:

„Uncertainty must be taken in a sense radically distinct from the familiar notion of risk, from which it has never been properly separated. [...] The essential fact is that ‘risk’ means in some cases a quantity susceptible of measurement, while at other times it is something distinctly not of this character; and there are far-reaching and crucial differences in the bearings of the phenomena depending on which of the two is really present and operating. [...] It will appear that a measurable uncertainty, or ‘risk’ proper, as we shall use the term, is so far different from an unmeasurable one that it is not in effect an uncertainty at all.“ (Knight, 1921, S. 19)

Das Treffen von Entscheidungen, in Situationen, die von knightscher Ungewissheit geprägt sind, bestimmen das Wesen von Entrepreneurship (Sarasvathy & Kotha, 2001, S. 32). Durch das Vorhandensein von Ungewissheit über zukünftige Ereignisse erhalten Unternehmer die Möglichkeit, trotz bestehender Marktgleichgewichte Gewinne zu erzielen (Blaug, 1997, S. 444). Sie können im Sinne von Schumpeter (1943, S. 83) durch „schöpferische Zerstörung“ Innovationen hervorbringen.

2.3 Maschinelles Lernen im Kontext von Effectuation

Der im Abschnitt 2.1 diskutierte Zusammenhang zwischen Effectuation und bayesianischer Entscheidungstheorie sowie die Beziehung zwischen den verschiedenen Konzepten von Ungewissheit, wie sie in Abschnitt 2.2 vorgestellt wurden, bilden die Grundlage für die Entwicklung entscheidungsbezogener und lernbasierter Verfahren. Der Bereich des maschinellen Lernens, eine Unterkategorie der Künstlichen Intelligenz (Buxmann & Schmidt, 2018), umfasst eine Reihe solcher Verfahren, die von Ideen des Bayesianismus geprägt sind (Ghavamzadeh et al., 2015; Jun, 2016; Katt et al., 2019; Korb & Nicholson, 2004). Ein Ziel der Methoden des maschinellen Lernens ist es, menschliches Verhalten vorherzusagen und zu adaptieren (Plonsky et al., 2019) sowie Entscheidungen in verschiedenen Kontexten zu treffen.

Im Umfeld der Entrepreneurship-Forschung wird maschinelles Lernen in Entscheidungsprozessen vereinzelt angewendet (García et al., 2012; Haiyan, 2018). Bis auf einige Ausnahmen (Vilalta et al., 2004) lässt sich der überwiegende Teil der Ansätze des maschinellen Lernens in drei Kategorien klassifizieren (Marsland, 2014, S. 6; Murphy, 2012, S. 2):

- Supervised Learning,
- Unsupervised Learning und
- Reinforcement Learning.

Zur Lösung von Supervised-Learning-Problemen werden zusammengehörige Eingangs- und Ausgangsvariablen benötigt. Diese bilden einen Trainingsdatensatz, der aufgrund von Beobachtung eines Phänomens ermittelt wird und das gemeinsame Auftreten der Variablen repräsentiert. Werden mit x_i die Eingangsvariablen und mit t_i die Ausgangsvariablen bezeichnet, besteht ein Trainingsdatensatz aus den Tupeln (x_i, t_i) mit $i = 1, \dots, m$ Lerndatensätzen (Marsland, 2014, S. 15 f.). Eine Hypothese $h(x)$ soll sich dem Zielvektor t möglichst genau annähern und somit erlernt werden. Mit $h(x)$ können dadurch für Werte von x auch außerhalb der Menge der Trainingsdatensätze Voraussagen getroffen werden. Um die approximierende Funktion $h(\cdot)$ zu lernen, existieren für unterschiedliche Anwendungsfälle verschiedene Verfahren, wie beispielsweise die Lineare und Logistische Regression sowie unterschiedliche Ausprägungen von Künstlichen Neuronalen Netzen (Mohri et al., 2018, S. 6 f.). Supervised Learning adressiert entsprechend Klassifizierungs- und Regressionsprobleme (Marsland, 2014, S. 6 f.). Im Kontext von Entrepreneurship gibt es Veröffentlichungen, die Supervised-Learning-Methoden verwenden, um unternehmerische Phänomene zu beschreiben und zu erklären (Luis-Rico et al., 2020; Sabahi & Parast, 2020; Tan & Koh, 1996; Zekic-Susac et al., 2013). In Unsupervised-Learning-Problemen wird die Segmentierung von Daten behandelt. Zu den Eingangswerten von x existieren zunächst keine zuordenbaren Ausgangswerte, wie es für Supervised Learning Aufgaben mit der jeweiligen Ausgangsgröße t der Fall ist. Lernalgorithmen aus diesem Bereich sind bestrebt, Muster in den Eingangswerten zu erkennen, die nicht durch Strukturlosigkeit gekennzeichnet sind. Bekannte Verfahren zur Lösung von Unsupervised Learning Problemen und zur Clusterbildung sind k -means, Principal Components Analysis und Mixture of Gaussians. Methoden des Unsupervised Learnings haben ihre Entsprechung in der Statistik als Kerndichteschätzung (Ghahramani, 2004). In der Entrepreneurship-Literatur existieren für diese Kategorie des Machine Learnings ebenfalls Anwendungen (Hemalatha & Nayaki, 2014; Nunes & Balsa, 2013; Shirur et al., 2019; Zekic-Susac et al., 2013). Reinforcement Learning (in Folge abgekürzt mit RIL) stellt die dritte

Hauptkategorie des maschinellen Lernens dar. RIL befasst sich mit dem Lernen von der Zuordnung von Zuständen zu Aktionen, indem eine Belohnungsfunktion maximiert wird. Ein Agent interagiert dabei über die Zeit mit seiner Umgebung und versucht eine Strategie zu erlernen. Dieses Konzept beruht auf dem Modell eines Markov-Entscheidungsproblems (in Folge abgekürzt mit MDP für Markov Decision Process) (Sutton & Barto, 2018, S. 3 f.). RIL findet insbesondere dann Anwendung, wenn die Steuerung eines Prozesses im Zeitverlauf erlernt werden soll (Szepesvari, 1998). Folglich findet RIL Anwendung beispielsweise im Bereich des Autonomen Fahrens, der Robotik, von Empfehlungssystemen, Chatbots, Videospielen, des Ressourcen-Managements sowie autonomer Bildung (Dhingra et al., 2017; Mandel et al., 2016; Mao et al., 2016; Theocharous et al., 2015; Yannakakis & Togelius, 2018; You et al., 2019; S. Zhang et al., 2019).

Im Kontext von Entrepreneurship wendet Haiyan (2018) RIL zur Modellierung spieltheoretischer Abläufe zwischen Investor und Entrepreneur an, um das bestmögliche Vertrauenverhältnis beider Parteien zu erlernen. Damit weist Haiyan (2018) nach, dass die grundsätzliche Anwendung von RIL Methoden auf prozessorientierte Entrepreneurship-Phänomene möglich ist. Gupta et al. (2016) nimmt Bezug auf die bisher varianztheoretische Betrachtung von Effectuation und fordert zur weiteren Theorienbildung prozessorientierte Untersuchungen. Die grundlegende prozessbezogene Natur von RIL (Szepesvari, 1998) und der Bedarf nach einer prozesstheoretischen Analyse von Effectuation (Gupta et al., 2016) begründen den Einsatz von RIL zu Modellierungszwecken. Yang und Chandra (2013) fordern ebenfalls den Einsatz agentenbasierter Modelle unter Zuhilfenahme von Methoden der Künstlichen Intelligenz zur Beschreibung entrepreneurialen, respektive effektuativen, Verhaltens.

2.3.1 Reinforcement Learning als Methode zur Lösung entscheidungstheoretischer Probleme

In RIL versucht ein Agent innerhalb eines MDP die größtmögliche Belohnung zu erreichen, indem er sich durch eine Reihe von Zuständen bewegt und Aktionen ausführt (van Otterlo & Wiering, 2012, S. 10–15). Ein MDP ist, angelehnt an Littman et al. (1995), gekennzeichnet durch ein Tupel (S, A, p, r) , wobei

S ... die Menge von Zuständen mit $s, s' \in S$

A ... die Menge von Aktionen mit $a \in A$

p ... die Transitionsfunktion und

r ... die Belohnungsfunktion

darstellen.

Die Transitionsfunktion ist definiert durch $p(s'|s, a)$ und repräsentiert die Wahrscheinlichkeit vom Zustand s und Ausführung der Aktion a durch den Agenten in den neuen Zustand s' zu kommen. Für die Belohnungsfunktion ist $r : S \times A \times S \rightarrow \mathbb{R}$ mit der erwarteten unmittelbaren Belohnung $r(s', a, s)$. Betrachtet man ein MDP als zeitlichen Prozess mit Zeitpunkten $t = 1, 2, \dots$, wobei $s_t \in S$ die Repräsentation des Zustandes der Umgebung, $a_t \in A$ die gewählte Aktion des Agenten und $r_t = r(s_{t+1}, a_t, s_t)$ die erhaltene Belohnungen zum Zeitpunkt t darstellen, gilt zudem die Markov-Eigenschaft. Diese beschreibt die Annahme, dass Zustandsübergänge lediglich vom zuletzt besuchten Zustand abhängig und unabhängig von vorhergehenden Aktionen oder Zuständen sind (Mocanu et al., 2018). So gilt beispielsweise $p(s'|s, a) = P(s_{t+1} = s' | s_t = s, a_t = a) = P(s_{t+1} = s' | s_t = s, a_t = a, s_{t-1} = \tilde{s}, a_{t-1} = \tilde{a})$.

Die weitere Beschreibung der Bestandteile eines MDP beruht auf den Ausführungen von Otterlo und Wiering (2012). Demnach ist ein Zustand s der Menge S eine einzigartige Repräsentation von Ausprägungen von Merkmalen. Die Merkmale besitzen dabei nur den Umfang, der für die Modellierung und Lösung des zu behandelnden Problems relevant ist. Beispielsweise kann die gesamte Figuren-Konfiguration auf einem Schachbrett zu einem beliebigen Zeitpunkt eines Spiels einen Zustand darstellen.

Aktionen aus der Menge A stellen Möglichkeiten dar, um von einem Zustand s in einen anderen Zustand s' zu gelangen. Die Menge der Aktionen, die innerhalb eines Zustandes ausgeführt werden können, wird mit $A(s)$ für einen bestimmten Zustand $s \in S$ notiert, wobei $A(s) \subseteq A$. Für die Transitionsfunktion p gilt zudem die Bedingung, dass für alle Zustände $s \in S$ und alle Aktionen $a \in A(s)$ $\sum_{s' \in S} p(s'|s, a) = 1$ (van Otterlo & Wiering, 2012).

RIL beinhaltet eine Reihe von Algorithmen zur Lösung des MDP. Zentrale Elemente in RIL-Problemen sind Agenten, die versuchen, innerhalb einer Umgebung durch das Erhalten von Belohnungen ein Verhalten zu erlernen. Dieser Zusammenhang lässt sich vereinfacht in Abbildung 2.1 darstellen. Mitchell (1997, S. 2) beschreibt diesbezüglich konkret, wodurch ein Lernproblem gekennzeichnet ist:

„A computer program is said to learn from experience E with respect to some class of tasks T and performance measure P , if its performance at tasks in T , as measured by P , improves with experience E .“

Die von Mitchell (1997) dargestellte Erfahrung E stellt im Kontext von RIL das Erhalten einer Belohnung $r(s', a, s)$ sowie die Beobachtung eines Zustandes s dar. Zur Bestimmung der Aufgabe T und des Leistungsmaßes P werden in RIL weitere Konzepte eingeführt. Dazu gehören die Policy (zu deutsch etwa Strategie)




Abb. 2.1 Wechselwirkung zwischen Agent und Umgebung in einem RIL-Problem. (Modifiziert nach Amiri et al. (2018))

und die Value-Funktion (zu deutsch etwa Wertfunktion). Eine Policy π stellt in diesem Zusammenhang die Zuordnung von Zuständen $s \in S$ der Umgebung zu Aktionen $a \in A(s)$ dar. Verfolgt ein Agent eine Policy π zum Zeitpunkt t , dann ist $\pi(a|s)$ die Wahrscheinlichkeit dafür, dass $a_t = a$, wenn $s_t = s$, so dass $\pi : S \times A \rightarrow [0, 1]$. Die Policy $\pi(a|s)$ wird dann allgemein eine stochastische Policy genannt. Für den Fall, dass $\pi(a|s) = 1$, wenn zum Zeitpunkt t $a_t = a$ und $s_t = s$, und $\pi(a|s) = 0$, wenn $a_t \neq a$ und $s_t = s$, ergibt sich $\pi : S \rightarrow A$. Die Policy $\pi(s)$ wird deterministische Policy genannt. Eine Policy ist der Kern eines RIL-Agenten und bestimmt sein inhärentes Verhalten. Sutton und Barto (2018, S. 58) schreiben konkret, dass „RIL methods specify how the agent’s policy is changed as a result of its experience.“. Eine Value-Funktion $v_\pi(s)$ beschreibt, welchen Gesamtbetrag an Belohnungen ein Agent über die Zeit erwarten kann, wenn er im Zustand s startet und anschließend der Policy π folgt. Damit wird die langfristige Erwünschtheit von Zuständen ausgedrückt, unter Berücksichtigung der zu erwartenden Zustände und den damit verbundenen Belohnungen. Ziel des Agenten ist es demzufolge, kumulierte Belohnungen zu maximieren, die er auf lange Sicht erhält (Sutton & Barto, 2018). Dieses Ziel entspricht der von Mitchell (1997) definierten Aufgabe T in RIL.

Die weiteren Ausführungen zu RIL-Konzepten beruhen auf einer nach Sutton und Barto (2018) angepassten Notation zur Bestimmung der (Action-)Value-Funktion und Policy. Zur Entwicklung der beiden Konzepte ist es notwendig, das Ziel des Agenten zu formalisieren. Die erwartete Gesamtbelohnung G_t kann als Funktion der Sequenz von erhaltenen Belohnungen nach Zeitpunkt t und dem finalen Zeitpunkt T mit

$$G_t := r_{t+1} + r_{t+2} + r_{t+3} + \dots + r_T \quad (2.7)$$

definiert werden. Die Bestimmung der Gesamtbelohnung G_t nach der Vorschrift (2.7) ist auf episodische RIL-Probleme mit einem Endzustand zum Zeitpunkt T anwendbar. T ist aufgrund der stochastischen Natur eines MDP respektive RIL-Problems eine Zufallsvariable, die von Episode zu Episode variiert.

Demgegenüber stehen Anwendungen, die fortlaufende Aufgaben beschreiben. Eine Gesamtbelohnung G_t kann dann nicht mehr wie in (2.7) bestimmt werden, da bei unendlichem Zeithorizont die zu maximierende Gesamtbelohnung G_t im Allgemeinen ebenfalls unendlich wird. Zur Lösung dieses Problems wird ein Diskontierungsfaktor γ eingeführt, für den $0 \leq \gamma \leq 1$ gilt. Ein Agent wird folglich eine Aktion $a_t \in A(s)$ so wählen, dass die erwartete diskontierte Gesamtbelohnung

$$G_t := r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \dots = \sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \quad (2.8)$$

maximiert wird. Belohnungen, die sich k Zeitschritte in der Zukunft befinden, werden entsprechend nur noch mit γ^{k-1} gewichtet. Für den Fall, dass $\gamma < 1$ gewählt wird, liefert die unendliche Summe aus Gleichung (2.8) einen endlichen Wert. Setzt man $\gamma = 0$, wird der Agent lediglich gewillt sein, die unmittelbare Belohnung r_{t+1} zu maximieren. Je größer γ gewählt wird, desto weitsichtiger wird der Agent im Hinblick auf die Einbeziehung künftiger Belohnungen. Darauf aufbauend kann die Gleichung aus (2.8) wie folgt zusammengefasst werden:

$$\begin{aligned} G_t &:= r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \gamma^3 r_{t+4} + \dots \\ &= r_{t+1} + \gamma (r_{t+2} + \gamma r_{t+3} + \gamma^2 r_{t+4} + \dots) \\ &= r_{t+1} + \gamma G_{t+1}. \end{aligned} \quad (2.9)$$

Zum Zwecke einer einheitlichen Notation von episodischen und fortlaufenden Aufgaben kann die Gesamtbelohnung G_t weiterhin mit

$$G_t := \sum_{k=t+1}^T \gamma^{k-t-1} r_k \quad (2.10)$$

inklusive der Fälle, dass entweder $\gamma = 1$ oder $T = \infty$ gesetzt wird, formuliert werden.

Die eben erläuterten Vorschriften zur Bestimmung der Gesamtbelohnung ist zur Ermittlung der Value-Funktionen und Policy des Agenten von zentraler Bedeutung. Damit lässt sich das von Mitchell (1997) definierte Lernproblem auf RIL übertragen.

Die Unterschiede zwischen verschiedenen Policies stellen demnach einen Lerneffekt dar, wobei das Leistungsmaß P in RIL, zur Messung der Güte des Lerneffekts, im Folgenden anhand der Ausführungen von Sutton und Barto (2018) beschrieben werden soll.

Die Value-Funktion $v_\pi(s)$ eines Zustandes unter der Policy π ist die erwartete Gesamtbelohnung beim Start in Zustand s und der darauffolgenden Anwendung von π . $v_\pi(s)$ lässt sich mit

$$v_\pi(s) := \mathbb{E}_\pi [G_t | s_t = s] = \mathbb{E}_\pi \left[\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \mid s_t = s \right] \quad (2.11)$$

formulieren. Da die Policy π sowie die Gesamtbelohnung G_t stochastisch sind, wird mit $\mathbb{E}_\pi[\cdot]$ der Erwartungswert einer Zufallsgröße bezüglich der durch π gegebenen Verteilung ausgedrückt. $v_\pi(s)$ ist eine Zufallsvariable.

Darauf aufbauend kann die erwartete Gesamtbelohnung für die Ausführung der Aktion a im Zustand s und danach der Policy π zu folgen mit $q_\pi(s, a)$ notiert werden. Formal lässt sich dies durch

$$q_\pi(s, a) := \mathbb{E}_\pi [G_t | s_t = s, a_t = a] = \mathbb{E}_\pi \left[\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \mid s_t = s, a_t = a \right] \quad (2.12)$$

ausdrücken. Die Unterscheidung von $v_\pi(s)$ und q_π ist für die spätere Evaluierung von Lernalgorithmen von Bedeutung und kann wie folgt ausgedrückt werden:

$$v_\pi(s) = \sum_{a \in A} \pi(a|s) q_\pi(s, a). \quad (2.13)$$

Die Value-Funktion $v_\pi(s)$ kann zudem konkretisiert werden, indem die Transitionswahrscheinlichkeiten p eines MDP sowie die Verteilungsfunktion $\pi(a|s)$ in Gleichung (2.11) eingesetzt werden:

$$\begin{aligned} v_\pi(s) &= \mathbb{E}_\pi [G_t | s_t = s] \\ &= \mathbb{E}_\pi [r_{t+1} + \gamma G_{t+1} | s_t = s] \\ &= \sum_a \pi(a|s) \sum_{s'} p(s'|s, a) (r(s', a, s) + \gamma \mathbb{E}_\pi [G_{t+1} | s_{t+1} = s']) \\ &= \sum_a \pi(a|s) \sum_{s'} p(s'|s, a) (r(s', a, s) + \gamma v_\pi(s')) \quad \forall s \in S \end{aligned} \quad (2.14)$$

(2.14) stellt die von Bellman (1957) formulierte rekursive Bellman-Gleichung dar. Diese ermöglicht es, für endliche MDP eine optimale Policy zu bestimmen. Endliche MDP sind dadurch gekennzeichnet, dass die dazugehörigen Zustands- und Aktionsmengen sowie die Menge der Belohnungen endlich viele Elemente enthalten.

Gesucht wird nun für jeden Zustand $s \in S$ eine Policy, die die zugehörige Value-Funktion maximiert. Diese wird als optimale Policy bezeichnet und mit π^* notiert. Es ergibt sich die optimale Value-Funktion

$$v_*(s) := \max_{\pi} v_{\pi}(s) \quad (2.15)$$

für alle $s \in S$.

Für die optimale Action-Value-Funktion q^* gilt analog

$$q_*(s, a) := \max_{\pi} q_{\pi}(s, a) \quad (2.16)$$

für alle $s \in S$ und $a \in A(s)$. Weiterhin ergibt sich der Zusammenhang zwischen q_* und v_* :

$$q_*(s, a) = \mathbb{E} \left[r_{t+1} + \gamma v_*(s_{t+1}) \mid s_t = s, a_t = a \right]. \quad (2.17)$$

Dieser Zusammenhang lässt sich auch wie folgt erklären:

$$\begin{aligned} v_*(s) &= \max_{a \in A(s)} q_*(s, a) \\ &= \max_{a \in A(s)} \mathbb{E}_{\pi^*} [G_t \mid s_t = s, a_t = a] \\ &= \max_{a \in A(s)} \mathbb{E}_{\pi^*} [r_{t+1} + \gamma G_{t+1} \mid s_t = s, a_t = a] \\ &= \max_{a \in A(s)} \mathbb{E} [r_{t+1} + \gamma v_*(s_{t+1}) \mid s_t = s, a_t = a] \\ &= \max_{a \in A(s)} \sum_{s'} p(s' \mid s, a) (r(s', a, s) + \gamma v_*(s')). \end{aligned} \quad (2.18)$$

Die Gleichung (2.18) stellt die Bellman-Optimalitäts-Gleichung dar. Analog gilt für die optimale Action-Value-Funktion q_* :

$$\begin{aligned}
q_*(s, a) &= \mathbb{E} \left[r_{t+1} + \gamma v_*(s_{t+1}) \mid s_t = s, a_t = a \right] \\
&= \mathbb{E} \left[r_{t+1} + \gamma \max_{a' \in A(s_{t+1})} q_*(s_{t+1}, a') \mid s_t = s, a_t = a \right] \\
&= \sum_{s'} p(s' \mid s, a) \left(r(s', a, s) + \gamma \max_{a' \in A(s')} q_*(s', a') \right). \tag{2.19}
\end{aligned}$$

Das Lösen der Optimalitätsgleichungen v_* und q_* und der damit verbundenen optimalen Policy π^* beschreibt das zentrale Lernproblem in RIL. Die beiden Funktionen v und q stellen in diesem Zusammenhang das von Mitchell (1997) definierte Leistungsmaß P dar. Nähern sich die Value-Funktionen v bzw. q den Fixpunkten v_* bzw. q_* an, ist der Agent im Begriff zu lernen. Zum Lösen der Bellman-Optimalitätsgleichungen existieren eine Reihe von Verfahren, die in Abschnitt 2.3.2 kurz vorgestellt werden.

2.3.2 Lösungsverfahren zur Bestimmung optimaler Policies in Reinforcement Learning

Klassische Verfahren zur Lösung von RIL-Problemen sind Algorithmen aus dem Bereich des Dynamic Programming (Busoniu et al., 2017). Verfahren dieser Art setzen voraus, dass alle Bestandteile eines MDP vollständig zur Verfügung stehen. Demnach müssen neben dem Zustandsraum, der Belohnungsfunktion und dem Aktionsraum auch die Transitionswahrscheinlichkeiten bekannt sein, welche in realen zu lösenden Problemen selten bekannt sind (Barto, 1995).

Dynamic Programming basiert auf dem Konzept der Generalisierten Policy Iteration, bei der die Policy Evaluation und die Policy Verbesserung im stetigen Wechsel stattfinden, um die Konvergenz hin zu einer optimalen Value-Funktion und optimalen Policy zu erreichen. Während der Policy Evaluation wird diesbezüglich angestrebt, eine Value-Funktion mit einer fixen Policy zu lernen. Im Fall der Policy Verbesserung wird eine Policy dahingehend angepasst, dass sie Aktionen aufnimmt, die hinsichtlich der aus der Policy Evaluation ermittelten Value-Funktion am besten sind (Sutton & Barto, 2018).

Formal kann ein Approximationsschritt der Policy Evaluation für fixierte Policy π als

$$\begin{aligned}
v_{k+1}(s) &:= \mathbb{E}_\pi [r_{t+1} + \gamma v_k(s_{t+1}) | s_t = s] \\
&= \sum_a \pi(a|s) \sum_{s'} p(s'|s, a) (r(s', a, s) + \gamma v_k(s')) \quad (2.20)
\end{aligned}$$

für alle $s \in S$ ausgedrückt werden. Die Folge $\{v_k\}$ konvergiert gegen v_π für $k \rightarrow \infty$ (Bertsekas, 2011). Prozedural kann dieses Iterationsverfahren wie in Algorithmus 1 umgesetzt werden.

Algorithmus 1 Schätzung der Value-Funktion $V \approx v_\pi$

```

1: procedure ITERATIVE POLICY EVALUATION( $\pi$ )
2:    $\theta > 0$  ▷ Schwellwert zur Bestimmung der Genauigkeit der Schätzung
3:    $V(s) \leftarrow \mathbb{R} \forall s \in S$ 
4:    $V(s = terminal) \leftarrow 0$ 
5:   repeat
6:      $\Delta \leftarrow 0$ 
7:     for each  $s \in S$  do
8:        $v \leftarrow V(s)$ 
9:        $V(s) \leftarrow \sum_a \pi(a|s) \sum_{s'} p(s'|s, a) [r(s', a, s) + \gamma V(s')]$ 
10:       $\Delta \leftarrow \max(\Delta, |v - V(s)|)$ 
11:    end for
12:  until  $\Delta < \theta$ 
13: end procedure

```

Die Policy Evaluation und die damit einhergehende Berechnung der Value-Funktion dient der Ermittlung besserer Policies (Mansour & Singh, 1999). Eine Policy $\pi(s)'$ ist nicht schlechter als π , wenn für alle $s \in S$

$$q_\pi(s, \pi'(s)) \geq v_\pi(s) \quad (2.21)$$

gilt. Eine bessere oder mindestens genauso gute Policy π' kann im Allgemeinen mittels

$$\begin{aligned}
\pi'(s) &:= \arg \max_{a \in A(s)} q_\pi(s, a) \\
&= \arg \max_{a \in A(s)} \mathbb{E} [r_{t+1} + \gamma v_\pi(s_{t+1}) | s_t = s, a_t = a] \quad (2.22)
\end{aligned}$$

$$= \arg \max_{a \in A(s)} \sum_{s'} p(s'|s, a) (r(s', a, s) + \gamma v_\pi(s')) \quad (2.23)$$

bestimmt werden, da die Gleichungen (2.22) und (2.23) die Bedingungen, die sich aus (2.21) ergeben, erfüllen.

Dieser als Policy Iteration bezeichnete Wechsel zwischen Policy Evaluation und Policy Verbesserung kann durch das Value-Iterationsverfahren verkürzt werden und somit schneller konvergieren (Sutton & Barto, 2018). Es lässt sich für alle $s \in S$ durch

$$\begin{aligned} v_{k+1}(s) &:= \max_{a \in A(s)} \mathbb{E} [r_{t+1} + \gamma v_k(s_{t+1}) | s_t = s, a_t = a] \\ &= \max_{a \in A(s)} \sum_{s'} p(s' | s, a) (r(s', a, s) + \gamma v_k(s')) \end{aligned} \quad (2.24)$$

formalisieren.

Grundsätzlich können das Policy-Iterations- sowie Value-Iterationsverfahren als Generalisierte Policy Iteration kategorisiert werden. Die Wechselwirkungen zwischen Policy Evaluation und Verbesserung werden in Abbildung 2.2 illustriert. Nahezu alle Lernverfahren in RIL lassen sich als Generalisierte Policy Iteration beschreiben (Sutton & Barto, 2018).

Dynamic Programming wird dem Bereich der Model-Based-Methoden zugeordnet. Wie bereits erwähnt ist es bei der Verwendung diesbezüglicher Verfahren notwendig, alle Bestandteile eines MDP zu kennen (F. L. Lewis & Vrable, 2009). Jedoch sind die Transitionswahrscheinlichkeiten sowie die Belohnungsfunk-




Abb. 2.2 Generalisierte Policy Iteration. (Modifiziert nach Sutton und Barto (2018))

tion nicht immer gegeben (Sutton & Barto, 2018). Zur Lösung von RIL-Problemen, bei denen kein vollständiges Wissen der Umgebung vorhanden ist, werden Model-Free-Methoden angewandt. Diese Verfahren beruhen auf stichprobenartigen Erfahrungen, die ein Agent durch sequentielle Interaktion mit seiner Umgebung erlangt (Strehl et al., 2006). Model-Free-Methoden wiederum lassen sich in On- und Off-Policy-Techniken einteilen. Dazu gehören nach Sutton und Barto (2018) beispielsweise:

- First-Visit Monte Carlo Steuerung (On-Policy)
- Importance Sampling (Off-Policy)
- Monte Carlo Vorhersage und Steuerung (Off-Policy)
- Ein-Schritt Temporal-Difference-Learning (Off-Policy)
- SARSA (On-Policy)
- Q-Learning (Off-Policy)

On-Policy-Verfahren dienen dazu, eine Policy zu verbessern, die gleichzeitig auch vom Agenten genutzt wird, um Entscheidungen bezüglich der auszuführenden Aktionen zu treffen. Bei Off-Policy-Methoden hingegen wird zwischen der Policy, die gelernt werden soll (Ziel-Policy), und der Policy, die für das Entscheidungsverhalten des Agenten verwendet wird (Verhaltens-Policy), unterschieden (Poole & Mackworth, 2017, Abschn. 11.3.6). Ziel-Policies enthalten im Allgemeinen explorative Bestandteile, während Verhaltens-Policies exploitativ hinsichtlich der bisher gelernten Policy sind. Eine konkrete Anwendung einer Off-Policy-Strategie wird in Abschnitt 4.2.2 vorgestellt.

2.3.3 Reinforcement Learning im entrepreneurialen Kontext

Um die in den Abschnitten 2.3.1 bis 2.3.2 vorgestellten RIL-Konzepte im Kontext entrepreneurialer Problemstellungen zu veranschaulichen, soll im Folgenden ein Beispiel entwickelt werden, das sich am *Recycling Robot Problem* von Connell (1989) orientiert und die Ideen von Csaszar und Levinthal (2016) zur Produktrepräsentation adaptiert.

Ein entrepreneurialer Agent hat die Aufgabe, ein Produkt erfolgreich am Markt zu etablieren. In diesem Zusammenhang stellt der Markt die Umgebung des Agenten dar. Anhand seiner zur Verfügung stehenden Mittel trifft der Agent Entscheidungen darüber, wie mit dem Produkt umgegangen werden soll. Der Zustandsraum S umfasst hierbei die Zustände $\{\text{hoch}, \text{gering}\}$, die sich auf die dem Agenten zur Verfügung stehenden Mittel beziehen. In jedem Zustand kann der

Agent entscheiden, ob er ein {Produkt anpassen}, ein {Produkt nicht verändern} oder ein {neues Produkt entwickeln} möchte. Im Beispiel wird die Annahme getroffen, dass der entrepreneuriale Agent bei einem Mittelbestand von {hoch} nicht daran interessiert ist, ein neues Produkt zu erstellen. Demnach ergeben sich die Aktionsmengen $A(\text{hoch}) = \{\text{Produkt anpassen}, \text{Produkt nicht verändern}\}$ und $A(\text{gering}) = \{\text{Produkt anpassen}, \text{Produkt nicht verändern}, \text{neues Produkt entwickeln}\}$.

Der Agent erhält eine positive Belohnung, wenn sein Produkt Nachfrage am Markt erzeugt. Dies erreicht er am besten, indem er sein Produkt kontinuierlich anpasst und verbessert. Dieses Vorgehen führt jedoch zu einer Verringerung seiner zur Verfügung stehenden Mittel. Lässt der Agent das Produkt so wie es ist, verringern sich auch nicht seine Mittel. Im Falle, dass der Agent im Begriff ist sein Produkt anzupassen und ihm bei diesem Vorgang die Mittel ausgehen, ist er gezwungen, neue Mittel zu beschaffen. Tritt dies ein, wird der Agent durch Erhalt einer negativen Belohnung bestraft.

Die Wahrscheinlichkeit dafür, dass ein Agent, ausgehend von vielen zur Verfügung stehenden Mitteln und einer Produktpassung, immer noch viele Mittel zur Verfügung hat, beträgt α ; dafür dass er nach der Anpassung nur noch wenige Mittel hat, beträgt sie $1 - \alpha$. Besitzt der Agent zunächst wenige Mittel, nimmt eine Produktpassung vor und besitzt danach immer noch wenige Mittel, ist diese Wahrscheinlichkeit β . Für den Fall, dass er mit den wenigen Mitteln eine Produktpassung vornimmt und ihm die Mittel ausgehen, beträgt diese Wahrscheinlichkeit $1 - \beta$. Folglich ist der Agent gescheitert und er erhält eine Belohnung (Bestrafung) von $r_{\text{scheitern}}$. Er ist nun gezwungen neue Mittel zu beschaffen, um eine Unternehmung mit einem neuen Produkt starten zu können. Im entwickelten Beispiel beträgt entsprechend die Wahrscheinlichkeit dafür, dass der Agent einen hohen Mittelbestand hat, unter der Voraussetzung, dass er zunächst wenige Mittel hatte und ein neues Produkt entwickeln will, 1. Der Agent erhält eine Belohnung von 0. Für die erwarteten Belohnungen $r_{\text{Produkt anpassen}}$, $r_{\text{Produkt nicht verändern}}$ und $r_{\text{scheitern}}$ gilt $r_{\text{Produkt anpassen}} > r_{\text{Produkt nicht verändern}} > r_{\text{scheitern}}$.

Die Transitionswahrscheinlichkeiten sowie die erwarteten Belohnungen des beispielhaften MDP sind in Tabelle 2.1 dargestellt. Die Tabelle enthält jede Kombination von Zustandsübergängen, die aus $s \in S$ und der Aktion $a \in A(s)$ möglich sind. Für Zustandsübergänge, deren Transitionswahrscheinlichkeit $p(s'|s, a) = 0$ sind, sind keine Belohnungen definiert.

Zur Illustration der Transitionen sind zudem die Dynamiken des beispielhaften MDP in Abbildung 2.3 dargestellt. Ein großer weißer Kreis mit Text in dessen Inneren repräsentiert einen Zustandsknoten, während ein kleiner, schwarz ausgefüllter Kreis einen Aktionsknoten symbolisiert. Pfeile stellen in diesem Kontext

Tabelle 2.1 Tabellarische Darstellung eines beispielhaften MDP

s	a	s'	$p(s' s, a)$	$r(s', a, s)$
hoch	Produkt anpassen	hoch	α	$r_{\text{Produkt anpassen}}$
hoch	Produkt anpassen	gering	$1 - \alpha$	$r_{\text{Produkt anpassen}}$
gering	Produkt anpassen	hoch	$1 - \beta$	$r_{\text{scheitern}}$
gering	Produkt anpassen	gering	β	$r_{\text{Produkt anpassen}}$
hoch	Produkt nicht verändern	hoch	1	$r_{\text{Produkt nicht verändern}}$
hoch	Produkt nicht verändern	gering	0	—
gering	Produkt nicht verändern	hoch	0	—
gering	Produkt nicht verändern	gering	1	$r_{\text{Produkt nicht verändern}}$
gering	neues Produkt entwickeln	hoch	1	0
gering	neues Produkt entwickeln	gering	0	—

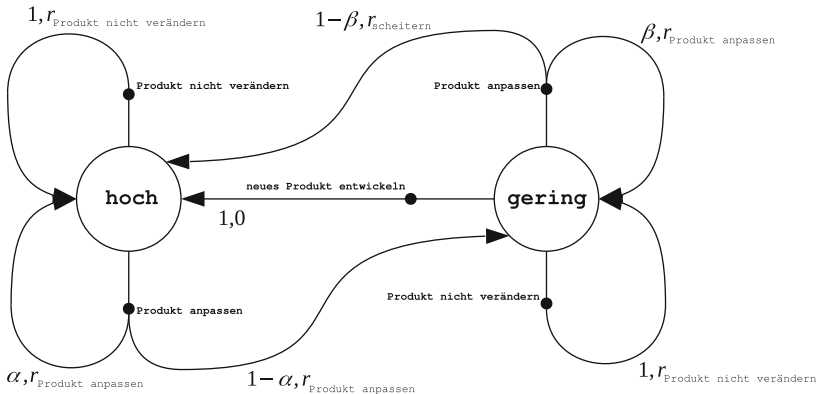


Abb. 2.3 Darstellung des beispielhaften Transitionssystems. (Modifiziert nach Sutton und Barto (2018))

die Übergänge, mit ihren Wahrscheinlichkeiten und erwarteten Belohnungen, von einem Zustandsknoten und des jeweilig gewählten Aktionsknotens in den von da aus erreichbaren Zustandsknoten dar. Zur Bestimmung der besten Policy für das dargestellte Problem wird die Bellman Optimalitätsgleichung aus 2.18 auf das entwickelte Beispiel angewendet. Die Zustände hoch und gering werden aus Gründen der Übersichtlichkeit mit h und g, die Aktionen Produkt anpassen, Produkt nicht verändern und neues Produkt entwickeln mit an, nv und ne

Open Access Dieses Kapitel wird unter der Creative Commons Namensnennung 4.0 International Lizenz (<http://creativecommons.org/licenses/by/4.0/deed.de>) veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden.

Die in diesem Kapitel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.





Evaluierung bestehender Modellierungs- und Simulationsansätze im Kontext von Effectuation

3

Die Auseinandersetzung mit bestehenden Konzepten zur Modellierung von Effectuation dient einerseits einer Annäherung an die Forschungsfrage und andererseits der methodischen Aufarbeitung der Ansätze. Die in diesem Kapitel behandelten Simulationsmodelle von Mauer et al. (2017), Welter und Kim (2018) und Eberz (2018) werden daher zunächst beschreibend dargestellt und deren Wirkungsweisen im Kontext des realen entrepreneurialen Phänomens erläutert. Darauf aufbauend erfolgen unter Abwägung des Erkenntnisnutzens die Verifikation und mathematische Formalisierung und Modellierung. Anschließend werden die Ergebnisse der bestehenden Studien kritisch evaluiert und mit den aus replizierten Implementierungen gewonnenen Ergebnissen verglichen.

3.1 Deskriptive Analyse der Modellierungs- und Simulationsansätze

Die Beschreibung der von Mauer et al. (2017), Welter und Kim (2018) und Eberz (2018) entwickelten Modelle erlaubt, deren Aufbau und Wirkungsweise transparent zu machen. Zudem wird dadurch die Grundlage geschaffen, um eine Gegenüberstellung zu ermöglichen. Die aus der deskriptiven Analyse gewonnenen Erkenntnisse dienen der Entwicklung eines eigenen generalisierten und verbesserten Ansatzes.

Ergänzende Information Die elektronische Version dieses Kapitels enthält Zusatzmaterial, auf das über folgenden Link zugegriffen werden kann
https://doi.org/10.1007/978-3-658-39251-2_3.

3.1.1 Simulationsmodell nach Mauer et al. (2017)

Mauer et al. (2017) untersuchen in ihrer Arbeit die Rahmenbedingungen zweier entrepreneurialer Suchprozesse im Kontext von Isotropie, Ziel-Ambiguität und Unvorhersagbarkeit mit Hilfe von Agent Based Modeling. Sie ermitteln und vergleichen die Leistungsfähigkeit steuerungs- und vorhersagebasierter Suchalgorithmen im unternehmerischen Problemraum. Ein vorhersagebasierter Suchprozess repräsentiert diesbezüglich das Konzept kausaler Logik, während ein steuerungsbasierter Suchprozess das Konzept von Effectuation widerspiegelt. Ziel der Entwicklung des Modells ist die Verbesserung des Entrepreneurship-Theoriegebildes und die nuancierte Darstellung der Beziehung zwischen entrepreneurialer Suche und Umgebung.

Die in Mauer et al. (2017) angestrebte Theorienbildung basiert auf den Konzepten der stochastischen Prozessmodellierung und der agentenbasierten Simulation. Als Grundlage für die Entwicklung wurden insbesondere die Arbeiten von Davis et al. (2009), Gilbert und Troitzsch (2005) und Gilbert (2007) genutzt.

Davis et al. (2009) behandeln vorrangig die Zusammenhänge zwischen Struktur einer Organisation, deren Leistungsfähigkeit und der vorhandenen Umgebung. Die Autoren fanden heraus, dass mit wachsender Unvorhersagbarkeit die optimale Struktur, im Sinne der bestmöglichen Reaktion auf die Umgebung unter Einschränkung der möglichen Aktionen, einer Unternehmung abnimmt. Um diesen Zusammenhang zu untersuchen, wurden Methoden der stochastischen Prozessmodellierung genutzt. Die Wahl dieser Modellierungsform liegt unter anderem in der Abbildbarkeit von improvisierten Aktionen, unternehmerischen Gelegenheiten und den Umgebungsdimensionen Geschwindigkeit und Ambiguität begründet. Teilaspekte des Modellierungsansatzes finden auch in Mauer et al. (2017) Verwendung.

Gilbert und Troitzsch (2005) stellen ein Grundlagenwerk zur Verfügung, in dem sie den Zusammenhang zwischen Sozialforschung und Simulation herausstellen. Darüber hinaus diskutieren sie eine Reihe verschiedener Simulationsmodelle, die zum wissenschaftlichen Erkenntnisgewinn in der Sozialforschung angewendet werden können.

In Gilbert (2007) wird die Funktionsweise und der Aufbau agentenbasierter Modelle vorgestellt. Ein Großteil der Agent Based Models wird laut Gilbert als agent automata modelliert. Dabei ist

$$\mathfrak{A} \sim (S, L)$$

als Agenten-Automat, bestehend aus den zeitlich geordneten Zuständen in S und Regeln L , definiert, wobei

$$S = (S_t) \text{ für } t = 1, \dots, n$$

mit

$S \hat{=}$ Folge von Zuständen über die Zeit aus einer Menge diskreter Zustände
der Mächtigkeit n

$S_t \hat{=}$ Zustand zum Zeitpunkt t

und

$$L : (S_t, I_t) \rightarrow S_{t+1}$$

mit

$L \hat{=}$ Regel, die eine Zustandsänderung mit Änderung der Zeit von
 $t \rightarrow t + 1$ bewirken kann

$I_t \hat{=}$ Input eines anderen Automaten oder externen Stimulus zum
Zeitpunkt t

gilt.

Mauer et al. (2017) machen sich die Erkenntnisse aus den Arbeiten zur stochastischen Prozessmodellierung und Gestaltung von agentenbasierten Modellen zu Nutze. Dabei beziehen sie sich auch auf exemplarische Studien von Almirall und Casadesus-Masanell (2010) oder Keyhani et al. (2014) aus dem Bereich der Strategie- und Entrepreneurship-Forschung, die Simulationsmethoden anwenden. Diese werden an dieser Stelle nicht näher beschrieben.

Bereits Davis et al. (2007) geben in ihren Ausführungen Hinweise, wie die Anwendung von Simulationsmodellen zur Theorienbildung beitragen kann. Dabei gehen sie auf den Auswahlprozess des für die Theorienentwicklung geeigneten Simulationsmodells ein und empfehlen Entscheidungskriterien. Mauer et al. (2017) folgen bei der Entwicklung und Vorstellung des Simulationsmodells nun dem durch Davis et al. (2007) beschriebenen Vorgehen, klammern allerdings die abschließende Validierung der eigenen Ergebnisse mit empirischen Daten anderer Untersuchungen aus. Die Auswahlsschritte für ein geeignetes Simulationsmodell und die Verwendungsaspekte dessen sind nach Davis et al. (2007) folgende:

- Bestimmung der Forschungsfrage
- Identifizierung eines einfachen Theoriengerüsts
- Wahl eines Simulationsansatzes, der die Forschungsfrage adressiert

- Entwicklung der rechnerischen Darstellung des Ansatzes
- Verifizierung der rechnerischen Darstellung durch Überprüfung auf Erfüllung der Anforderungen
- Experimente zum Zweck der Theorienbildung
- Validierung der Simulationsergebnisse mit empirischen Daten

Aufbauend auf den Erkenntnissen der verwendeten Literatur haben Mauer et al. (2017) für die Simulation ein agentenbasiertes Modell entwickelt, das eine unternehmerische Aufgabe lösen soll. Die Agenten im Simulationsmodell entwickeln eine Produkt- oder Dienstleistungsidee bis zur Bereitstellung im Konsumentenmarkt und werden durch den Beobachter anhand des sogenannten Market-Fits bewertet. Das Modell wird im zeitlichen Bereich zwischen Auftreten einer grundlegenden Idee als mentale oder theoretische Repräsentation eines Wertes für eine Unternehmung und dem tatsächlichen Markteintritt angewandt.

Die Überlegungen zu den im Simulationsmodell dargestellten Produkt- und Dienstleistungsideen fußen auf den Vorschlägen von Csaszar und Levinthal (2016). In diesem Zusammenhang ist eine mentale Repräsentation als geistiges Modell der Realität eines Individuums zum Treffen von Vorhersagen über die Realität zu verstehen. Diese werden durch N Strategiemöglichkeiten modelliert. Als Beispiel für eine mentale Repräsentation mit $N = 3$ Strategiedimensionen verwenden die Autoren ein Automobil. Als Vektor ausgedrückt bedeutet die Konfiguration $(1, 0, 1)$ beispielsweise, dass das Automobil ein großes Chassis, einen kleinen Motor und dicke Wände haben könnte.

Das Konzept der mentalen Repräsentation mit verschiedenen Strategiemöglichkeiten übertragen Mauer et al. (2017) auf ihr Simulationsmodell zur Darstellung von Artefakten, die sich als Produkte oder Dienstleistungen mit verschiedenen Eigenschaften manifestieren können. Mathematisch werden diese als n -Tupel modelliert und als Vektor mit n Komponenten dargestellt. Eine Komponente des Vektors repräsentiert jeweils eine Produkteigenschaft. Ein n -dimensionaler Produktvektorraum definiert dabei alle möglichen Produkte, die mit n Komponenten umsetzbar sind. Jede Komponente kann k verschiedene Werte annehmen. Mauer et al. (2017) definieren für die Komponenten $k = 2$ Ausprägungen mit den Werten 0 und 1. Eine beispielhafte Anwendung dieses Modellierungsansatzes ist für den binären Fall von $k = 2$ für sogenannte Gelegenheitsvektoren zur Umgebungsmodellierung auch in Davis et al. (2009) zu finden. Es ergeben sich maximal k^n mögliche Konfigurationen.

Im Simulationsmodell von Mauer et al. (2017) erhalten die Komponenten des Artefakts, die zu Beginn der Simulation noch nicht konkret definiert sind, nun den Wert 9 und sind somit flexibel. Die Anzahl m der flexiblen Komponenten zu Beginn der Simulation variiert je nach verwendeter Suchstrategie (steuerungs- vs.

vorhersagebasiert), wobei $m \leq n$. Die Anwendung flexibler Vektorkomponenten wird ebenfalls in Davis et al. (2009) erläutert, wobei diese als improvisierte Aktionen operationalisiert und mit einem τ notiert werden. Improvisierte Aktionen stellen die Fähigkeit einer Organisation dar, eine unternehmerische Gelegenheit zu einem bestimmten Zeitpunkt zu beeinflussen, während $n - m$ Komponenten eines Gelegenheitsvektors die vor Ergreifung der Gelegenheit fixen Entscheidungen repräsentieren.

Im Modell von Mauer et al. (2017) werden zwei Arten von Agenten beschrieben: Anbieter-Agenten und Konsumenten-Agenten. Konsumenten-Agenten sind in der Form passiv, dass sie jeweils einen Artefakt-Vektor versinnbildlichen, dessen Komponenten nicht durch Interaktion mit anderen Agenten geändert werden können und der keine flexiblen Komponenten enthält.

Die Verteilung der Nachfragevektoren der Konsumenten im Produktvektorraum stellt die Payoff-Landschaft im Sinne der Nachfrage dar. Mauer et al. (2017, S. 244) beschreiben diese als „[...] demand vectors [which] reflect the current universe of consumer preferences at each point in time, thereby forming the payoff landscape.“. Die Payoff-Landschaft wird in diesem Zusammenhang mit einer *taste distribution* verglichen, wie sie Carpenter und Nakamoto (1989) erläutern. In Abbildung 3.1 ist eine beispielhafte Payoff-Landschaft, die durch zwei Artefakt-Komponenten geformt wird, dargestellt.

Die Landschaft stellt sich in der Ebene über die beiden Artefakt-Komponenten als Verteilung der möglichen Komponenten-Kombinationen der Konsumenten dar. Während Carpenter und Nakamoto (1989) die dritte Dimension der Landschaft als Marktwert der jeweiligen Komponenten-Kombinationen verstehen, definieren Mauer et al. (2017) diesen Funktionswert als aggregierte Konsumenten-Präferenzen und drücken damit jeweils die Anzahl der einzelnen tatsächlich nachgefragten Komponenten aus. Das Konzept der Landschaft lässt sich auf das bereits erwähnte Automobilbeispiel übertragen. Hierbei stellen die einzelnen Vektorkomponenten der vektorisierten mentalen Repräsentation die jeweiligen Ausprägungen der Produkteigenschaften dar. Beispielsweise bildet die erste Vektorkomponente des Konfigurationsvektors $(1, 0, 1)$ die Produktausprägung *Chassis-Größe* ab. In diesem Fall steht die 1 für ein großes Chassis (während eine 0 für ein kleines Chassis stehen würde). Da in diesem Beispiel die Vektorkomponenten jeweils zwei verschiedene Werte annehmen können (0 oder 1) und insgesamt drei verschiedene Produkteigenschaften zur Verfügung stehen, existieren 8 verschiedene Produktkonfigurationen für das Automobil. Diesen Konfigurationen, die Punkte im Raum darstellen, werden Funktionswerte, in Form der Payoffs, zugeordnet. Die Funktionswerte wiederum drücken aus, wie stark die Nachfrage einer bestimmten Produktkonfiguration im Vergleich zu anderen Produktkonfigurationen ist.

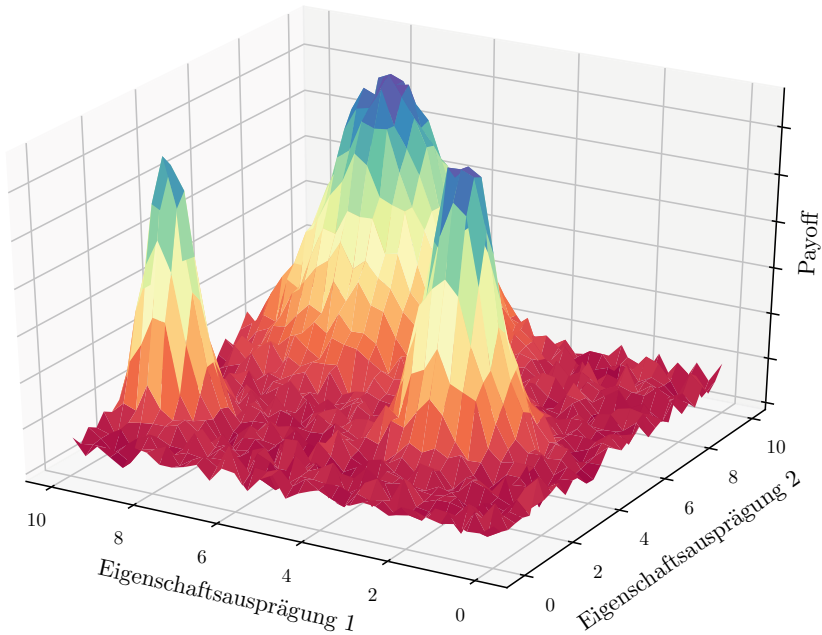


Abb. 3.1 Beispielhafte Payoff-Landschaft für einen Artefakt-Vektor der Konsumenten mit $n = 2$ Komponenten und $k \in [0, 10]$ Ausprägungen (mod. nach Carpenter und Nakamoto (1989))

Carpenter und Nakamoto (1989) beziehen das Konzept der *taste distribution* auf einen einzelnen Konsumenten hinsichtlich eines möglichen Produktes. Mauer et al. (2017) hingegen verwenden die *taste distribution* als Payoff-Landschaft aller Konsumenten und ihrer tatsächlich nachgefragten Produkte (Artefakte). Abbildung 3.1 zeigt, dass die Werte der Komponenten aus einem kontinuierlichen Bereich stammen. Mauer et al. (2017) verwenden in ihrem Modell diskrete Werte für die möglichen Komponenten. Abbildung 3.1, wie sie in der Form auch von Mauer et al. (2017) zur Veranschaulichung genutzt wird, ist für die Darstellung ihres Modellierungsansatzes, mit diskreten Werten für die Komponenten, daher eher ungeeignet.

Für die Modellierung der Angebotsseite verwenden Mauer et al. (2017), wie bereits anfangs erwähnt, Anbieter-Agenten, die Artefakte mittels einer Steuerungs- bzw. Vorhersage-Strategie entwickeln. Anbieter-Agenten, die einer vorhersagebasierten Strategie folgen, beobachten zu Beginn der Simulation stichprobenartig Nachfragevektoren der Konsumenten-Agenten und sammeln so Informationen zu

Präferenzen der Nachfrager. Ein Optimierungsalgorithmus, der lediglich schematisch von Mauer et al. (2017) beschrieben wird, bestimmt dann die besten Werte für die flexiblen Komponenten des Artefakts mittels Maximierung des Market-Fits in Bezug auf die stichprobenartig erfasste Nachfrage. Nach Austausch der flexiblen Komponenten des Artefakt-Vektors mit den ermittelten bestmöglichen Werten, endet der Simulationsprozess mit der Berechnung des Market-Fits.

Der steuerungs-basierte Anbieter-Agent vergleicht seinen ihm zugehörigen Artefakt-Vektor dagegen komponentenweise mit Artefakt-Vektoren anderer passiver steuerungs-basierter Anbieter-Agenten, die ihm zufällig als Kontaktnetzwerk zugeordnet wurden und potentielle Stakeholder repräsentieren. Besitzt der Vektor des passiven steuerungs-basierten Anbieter-Agenten einen festen Wert in einer Komponente, ersetzt der aktive steuerungs-basierte Anbieter-Agent den Wert an dieser Stelle in seinem Artefakt-Vektor, sofern dieser noch flexibel ist. Ist der Wert einer Komponente an der gleichen Stelle des Vektors der beiden Agenten flexibel, muss der aktive steuerungs-basierte Anbieter-Agent mit mindestens einem weiteren passiven steuerungs-basierten Agenten den Artefakt-Vektor abgleichen, um die flexible Komponente mit einem fixen Wert zu versehen. Wie die Reihenfolge festgelegt wird, in der der sequentielle Abgleich mit den passiven steuerungs-basierten Agenten geschieht, ist nicht näher spezifiziert. Auch wenn Mauer et al. (2017) es nicht explizit erläutern, folgt dieses Vorgehen den Ausführungen zur Erreichung von Vereinbarungen mittels effektuativem Vorgehen von Sarasvathy (2009, S. 15). Der Simulationsprozess ist beendet, wenn der Artefakt-Vektor des steuerungs-basierten Agenten keine flexiblen Komponenten mehr enthält. Danach wird der Market-Fit evaluiert.

Der Market-Fit stellt im Modell von Mauer et al. (2017) das Leistungsmaß dar und dient der Bestimmung der Leistungsfähigkeit der steuerungs- bzw. vorher-sagebasierten Suchalgorithmen in verschiedenen Kontexten. Die Gesamtheit der Nachfragevektoren der Konsumenten bildet die Marktnachfrage ab. Nachfragevektoren sind im gleichen Produktvektorraum angesiedelt wie die Artefakt-Vektoren der Anbieter. Nachfragevektoren besitzen lediglich Komponenten mit fixen Werten (0 und 1), die sich jedoch über die Zeit ändern können (0 wird zu 1 bzw. 1 wird zu 0). Zur Bestimmung der Leistungsfähigkeit im Sinne des Market-Fits wird die Kongruenz des Artefakt-Vektors des Anbieter-Agenten mit der Marktnachfrage gemessen. Mauer et al. (2017, S. 244) definieren Market-Fit konkret „[...] as the percentage of consumer agents whose demand vector components show the same values as the product vector components, averaged over all vector dimensions.“. Da Mauer et al. (2017) keine formale Berechnungsvorschrift des Market-Fits bereitstellen, soll im Folgenden anhand eines Beispiels die Berechnung des Market-Fits nachvollzogen

werden. Im Anschluss wird darauf aufbauend der Market-Fit mathematisch modelliert.

Beispiel 3.1 (Market-Fit).

Es gebe $n = 2$ Komponenten und $k = 2$ Ausprägungen.

Es wird angenommen, dass neun Nachfragevektoren der Konsumenten-Agenten existieren. Auf Seiten der Anbieter-Agenten gibt es insgesamt 12 Angebotsvektoren¹. Diese werden zu Vergleichszwecken in 4 Gruppen á 3 Angebotsvektoren unterteilt. Die Erstellung der Vektoren erfolgt willkürlich.

Konkret wird die Menge Y der Nachfragevektoren mit folgender Zusammenstellung der Elemente untersucht:

$$Y = \{(0, 0); (0, 0); (0, 1); (0, 1); (1, 0); (1, 0); (1, 1); (1, 1); (1, 1)\}.$$

Um die Payoff-Landschaft für Y zu erstellen, muss zunächst ermittelt werden, welchen Anteil jede Vektorkomponentenkombination aus der k^n -elementigen Menge aller möglichen Vektorkonfigurationen hat. Es ergeben sich die möglichen Kombinationen $(0, 0)$; $(0, 1)$; $(1, 0)$; $(1, 1)$. Für die Berechnung des Payoffs einer möglichen Kombination wird zunächst die Ausprägung jeder Komponente mit den Ausprägungen der korrespondierenden Komponenten der Nachfragevektoren verglichen. Anschließend wird für jede Komponente die Anzahl der Ausprägungen der Nachfragevektoren bestimmt, die den gleichen Wert wie die Ausprägung der Komponente der möglichen Kombination aufweist. Die für die jeweiligen Komponenten entstandenen Anzahlen werden aufaddiert, durch die Gesamtzahl der Nachfragevektoren dividiert und über die Anzahl der Komponenten gemittelt. Es ergeben sich für die einzelnen Kombinationen die gemittelten Anteile:

$$(0, 0) : \frac{\frac{4}{9} + \frac{4}{9}}{2} = \frac{4}{9}$$

$$(0, 1) : \frac{\frac{4}{9} + \frac{5}{9}}{2} = \frac{1}{2}$$

$$(1, 0) : \frac{\frac{5}{9} + \frac{4}{9}}{2} = \frac{1}{2}$$

$$(1, 1) : \frac{\frac{5}{9} + \frac{5}{9}}{2} = \frac{5}{9}.$$

¹ Da im Beispiel lediglich die Berechnung des Market-Fits betrachtet wird, ist es irrelevant, ob die Artefaktvektoren von steuerungs- oder vorhersagebasierten Agenten erstellt wurden. Sie werden deshalb allgemein als *Angebotsvektoren der Anbieter-Agenten* bezeichnet.

Auf Angebotsseite werden zu Vergleichszwecken vier unterschiedliche Fälle konstruiert, die jeweils drei Angebotsvektoren der Anbieter-Agenten enthalten. Diese setzen sich wie folgt zusammen:

$$\begin{array}{cccc}
 \mathbf{Fall\ 1} & \mathbf{Fall\ 2} & \mathbf{Fall\ 3} & \mathbf{Fall\ 4} \\
 (0, 0) & (1, 1) & (0, 0) & (0, 0) \\
 (1, 1) & (1, 1) & (0, 0) & (1, 0) \\
 (1, 1) & (1, 1) & (0, 0) & (1, 0)
 \end{array}$$

Aufbauend auf den Ausführungen von Mauer et al. (2017) wird der Market-Fit als Payoff derjenigen Vektorkombination der Nachfragevektoren definiert, die mit dem Angebotsvektor übereinstimmt. Der mittlere Market-Fit beschreibt den durchschnittlichen Market-Fit der Angebots-Agenten pro Fall. Im Beispiel errechnen sich für

$$\begin{array}{l}
 \mathbf{Fall\ 1:} \quad \frac{\frac{4}{9} + \frac{5}{9} + \frac{5}{9}}{3} = \frac{14}{27} \\
 \mathbf{Fall\ 2:} \quad \frac{\frac{5}{9} + \frac{5}{9} + \frac{5}{9}}{3} = \frac{5}{9} \\
 \mathbf{Fall\ 3:} \quad \frac{\frac{4}{9} + \frac{4}{9} + \frac{4}{9}}{3} = \frac{4}{9} \\
 \mathbf{Fall\ 4:} \quad \frac{\frac{4}{9} + \frac{1}{2} + \frac{1}{2}}{3} = \frac{13}{27}
 \end{array}$$

die verschiedenen mittleren Market-Fits.

Es zeigt sich, dass in Fall 2 ein Market-Fit von $\frac{5}{9}$ erreicht wird. Dabei hatten alle drei Angebots-Agenten einen Angebotsvektor von (1, 1). Auf Seiten der Nachfrage-Agenten war diese Vektorkombination die am meisten nachgefragte Kombination. Folglich ergibt sich für die Angebotsvektoren aus Fall 2 der mittlere Market-Fit von $\frac{5}{9}$. In Fall 3 hingegen ergibt sich ein mittlerer Market-Fit von $\frac{4}{9}$, da alle drei Angebots-Vektoren einen Wert von (0, 0) aufweisen und dementsprechend der Vektorkombination der Nachfrage-Agenten mit dem geringsten Payoff entsprechen.

Definition 3.2 (Market-Fit)

Sei f ein beliebiger Vektor (f_1, \dots, f_n) mit $f_i \in \{1, \dots, k\}$ und $i = 1, \dots, n$ und

(Y) ... Die Menge aller Nachfragevektoren.

Somit ergibt zur Berechnung des Payoffs po_f

$$po_f = \frac{1}{|Y|} \sum_{y \in Y} \frac{1}{n} \sum_{j=1}^n \mathbb{1}_{\{f_j=y_j\}}. \quad (3.1)$$

Der Market-Fit mf_a eines Angebotsvektors $a \in A$ aus der Menge A der ermittelten Angebotsvektoren ist definiert mit

$$mf_a := po_f|_{f=a}. \quad (3.2)$$

Daraus folgt die Rechenvorschrift des mittleren Market-Fits \overline{mf} mit

$$\overline{mf} = \frac{1}{|A|} \cdot \sum_{a \in A} mf_a. \quad (3.3)$$

Zur Evaluierung der vorhersage- und steuerungs-basierten Suchalgorithmen in unterschiedlichen Kontexten operationalisieren Mauer et al. (2017) den unternehmerischen Problemraum, der unter anderem von Dew und Sarasvathy (2007) beschrieben wurde. Er setzt sich aus den Umgebungsvariablen Ungewissheit, Isotropie und Ziel-Ambiguität zusammen. Diese Elemente des Problemraums können im Grad ihres Auftretens im Modell von Mauer et al. (2017) gesteuert werden.

Ungewissheit, wie sie in Abschnitt 2.2 behandelt wurde, kann hinsichtlich der Marktnachfrage im Simulationsmodell von a-priori bzw. empirisch bis hin zu einem ähnlichen Konzept von Ungewissheit, wie es Knight (1921) formulierte, variiert werden. Dabei folgen Mauer et al. (2017) der Arbeit von Davis et al. (2009) und Dess und Beard (1984), indem sie das Konzept der Umgebungsdynamik für die Modellierung von Ungewissheit nutzen. Die Verteilungen für die Nachfrage von Produkteigenschaften können demnach stabil sein und somit die Abwesenheit von Ungewissheit repräsentieren oder sich im Zeitverlauf ändern und somit den Grad des Vorhandenseins von Ungewissheit widerspiegeln. Die Operationalisierung der Isotropie erfolgt dadurch, dass mehr oder weniger Produkteigenschaften in der Marktnachfrage gleichverteilt werden. Im Falle des Automobil-Beispiels könnte hinsichtlich der Vektorkomponente *Chassis-Größe*, eine Verteilung in der Marktnachfrage von 0/100 bedeuten, dass alle Nachfrage-Agenten die Produktausprägung *großes Chassis* nachfragen und kein Nachfrage-Agent die Produktausprägung *kleines Chassis*.

Ziel-Ambiguität wird durch die Variierung der Anzahl der undefinierten Komponenten des Artefakt-Vektors operationalisiert.

Um die steuerungs- und vorhersagebasierten Suchprozesse auf ihre Leistungsfähigkeit hin zu vergleichen, führen Mauer et al. (2017) drei Simulationsexperimente durch. Dabei gibt jedes Experiment Auskunft über die Auswirkung der jeweiligen Variable aus dem Problemraum (Ungewissheit, Isotropie, Ziel-Ambiguität) auf den durchschnittlichen Market-Fit hinsichtlich der zu vergleichenden Strategien.

Mittels Monte-Carlo-Simulationstechnik wurde jede Parameterkonfiguration mit jeweils unterschiedlich initialisierten Werten des Artefakt-Vektors mehrmals durchlaufen, um statistische Fehler zu vermeiden. Pro Experiment wurden zwischen 50 und 170 Durchläufe ausgeführt, die insgesamt 63.000 bis 214.000 Datenpunkte zur Analyse erzeugten. Ein Datenpunkt ist diesbezüglich eine Datenauslesung aller Parameter eines Agenten. In einem einzelnen Simulationsdurchlauf ist das mittlere Market-Fit-Ergebnis für eine Parameter-Konfiguration die Aggregation aller Market-Fit-Ergebnisse der einzelnen steuerungs- bzw. vorhersagebasierten Agenten. Folgende umgebungsrelevanten Kennzahlen des Simulationsmodells von Mauer et al. (2017) sind darüber hinaus bekannt:

- Gesamtzahl der Agenten: 100, davon:
 - 20 vorhersagebasierte Agenten
 - 20 steuerungs-basierte Agenten
 - 60 Konsumenten-Agenten
- Anzahl der Vektorkomponenten n : 5
- Anzahl der flexiblen Artefakt-Vektorkomponenten m : 0, \dots , 4
- Anzahl der möglichen Ausprägungen pro Artefakt-Vektorkomponente k : 2, \dots , 6

Artefakt-Vektoren werden entsprechend einer zuvor definierten Verteilung in der Payoff-Landschaft erstellt. Die Verteilung ist definiert durch die Anzahl der möglichen Werte (k), die jede Vektor-Komponente annehmen kann, und durch die Verteilung dieser Werte. Beispielsweise wäre es möglich, dass bei $k = 2$ 80 % der Agenten an der i -ten Stelle des Vektors den Wert 0 und 20 % den Wert 1 haben. Artefakt-Vektoren werden für $k = 2$ an der i -ten Stelle identisch verteilt initialisiert. Um eine Verteilung für $k > 2$ zu modellieren, betrachten Mauer et al. (2017) die Anzahl einer ausgewählten Ausprägung über alle Artefaktvektoren als veränderbaren Parameter zur Steuerung des Anteils an der Gesamtverteilung. Nach Festlegung des Anteils dieser Ausprägung an der Verteilung wird der verbleibende Anteil der Marktnachfrage auf die restlichen $k - 1$ Ausprägungen gleichverteilt. Die flexiblen Komponenten der Artefakt-Vektoren werden im Experiment mit Hilfe des steuerungs-basierten bzw. vorhersagebasierten Suchalgorithmus in fixe Werte umgewandelt.

Die Ergebnisse der Simulation zeigen die Auswirkungen von Isotropie, Ziel-Ambiguität und Ungewissheit auf die Marktnachfrage. Das Ausmaß der Isotropie

wird mittels k mit $k \geq 1$ sowie der Nachfragekonzentration c gesteuert. In diesem Zusammenhang beschreibt Isotropie den Umstand, dass zum Zeitpunkt einer Entscheidungssituation nicht vollständig klar ist, welche Informationen der Umgebung zum Treffen einer guten Entscheidung relevant sind. Mauer et al. (2017) operationalisieren Isotropie durch Vielfalt in der Marktnachfrage. Die Nachfragekonzentration c gibt an, ob eine bestimmte Komponente im Vergleich zu anderen Komponenten durchschnittlich mehr, weniger oder gleich nachgefragt ist. Je größer der Anteil einer Komponente im Vergleich zum Durchschnitt ist, desto geringer variiert die Marktnachfrage v . Die Variation in der Marktnachfrage wird berechnet durch:

$$v = \frac{k}{c} \text{ mit } v \in [k; k^2] \text{ und } c \in \left[\frac{1}{k}; 1 \right]$$

Die Dominanz in der Marktnachfrage d wird folgendermaßen berechnet:

$$d = c \cdot k \text{ mit } d \in [1; k]$$

Der Ablauf der Simulation von Mauer et al. (2017) wird exemplarisch in Form von Pseudo-Code in dargestellt. In der Simulation von Mauer et al. (2017) wird die Modellierung von Ungewissheit durch Veränderung der initialen Verteilung der Vektor-Komponenten, nachdem beide Strategien das Artefakt finalisiert haben, erreicht und wird als Market-Shift bezeichnet. Beispielsweise könnte in einem Markt mit 100 Nachfragern initial eine 80/20 Verteilung zwischen zwei Ausprägungen ($k = 2$) einer Artefaktkomponente vorherrschen. Diese Verteilung könnte sich im Verlauf zu einer 60/40 oder 30/70 Verteilung ändern. Steuerungsbasierte Agenten erzielen einen besseren Market-Fit im Vergleich zu vorhersagebasierten Agenten, wenn sich der Market-Shift vergrößert. Dieser Effekt tritt jedoch erst ab einem bestimmten Market-Shift-Wert auf. Je früher die Änderung der Verteilung der Marktnachfrage im Simulationsablauf durchgeführt wird, umso höher ist der erreichte Market-Fit des steuerungs-basierten Agenten. Mauer et al. (2017) widersprechen sich jedoch, was den Zeitpunkt des Market-Shifts im Simulationsablauf angeht. Einerseits schreiben sie: „In our experiments, the market shift occurred *after* both strategies had terminated finalizing the product“. Auf der anderen Seite erläutern sie, dass „the timing of a market shift is important, which is why we investigate by manipulating it in the simulation“.

Bei der Untersuchung der Auswirkungen der Ziel-Ambiguität auf die Marktnachfrage und dementsprechend der Bestimmung des Market-Fits, haben steuerungs-basierte Agenten bei einer moderaten Ziel-Ambiguitäts-Konfiguration ($1 \leq m \leq 2$) eine stabile Leistungsfähigkeit, die (linear) mit Anstieg des Market-Shifts abfällt.

Algorithmus 1 Control-based and Prediction-based model

```

procedure SIMULATION(control agents, prediction agents, consumer agents,  $n$ ,  $k$ ,
c)
2:   $A \leftarrow$  all control agents and prediction agents
   for each  $agent \in A$  do
4:     for  $j \leftarrow 1, n$  do
        $agent_j \leftarrow$  one of  $\{0, \dots, k - 1\}$  with distribution  $c$ 
6:     end for
   end for
8:   for each  $agent \in A$  do
        $flexible\ components \leftarrow m$  random elements from  $\{1, \dots, n\}$ 
10:    for  $j \leftarrow 1, n$  do
        if  $j \in flexible\ components$  then
12:             $agent_j \leftarrow 9$ 
        end if
14:    end for
   end for
16:  for each  $agent \in prediction\ agents$  do
        $consumer\ sample \leftarrow$  random sample of consumer agents
18:    for  $j \leftarrow 1, n$  do
        if  $agent_j = 9$  then
20:             $agent_j \leftarrow$  mode of  $j$ -th component of consumer-sample
        end if
22:    end for
   end for
24:  for each  $agent \in control\ agents$  do
        $agent\ sample \leftarrow$  random sample of remaining control agents
26:    for  $agent\_s \in agent\ sample$  do
        for  $j \leftarrow 1, n$  do
28:            if  $agent_j = 9$  &  $agent\_s_j \neq 9$  then
                 $agent_j = agent\_s_j$ 
30:            end if
        end for
32:    end for
   end for
34:   $Y \leftarrow consumer\ agents$ 
        $market\ fit = \frac{1}{|A| \cdot n \cdot |Y|} \sum_{a \in A} \sum_{y \in Y} \sum_{j=1}^n \mathbb{1}_{\{a_j=y_j\}}$ 
36: end procedure

```

Vorhersagebasierte Agenten zeigen bei fallenden Werten für m eine stärkere Leistungsfähigkeit bei geringem Market-Shift und eine schwächere Leistung bei großem Market-Shift. Mauer et al. (2017) lassen offen, weshalb eine Veränderung des Market-Shifts im dritten Experiment durchgeführt wurde, obwohl es an anderer Stelle der Arbeit heißt, dass „[e]ach experiment examines the effect of one variable on the average market fit of the two strategies being compared.“.

Eine kritische Evaluation der hier zusammengefassten Ergebnisse erfolgt in Abschnitt 3.2.1.

3.1.2 Simulationsmodell nach Welter und Kim (2018)

Welter und Kim (2018) untersuchen in ihrer Arbeit Effectuation mit Hilfe eines NK-Modellansatzes. Sie adressieren damit die Fragestellung, in welchem Kontext Effectuation anwendbar und wirksam ist. Dabei schließen die Autoren an die Erkenntnisse von Welter et al. (2016) an, die die Potentiale in der Theorienbildung von Effectuation thematisieren. Insbesondere zeigen Welter und Kim (2018) auf, dass die bisherige Effectuation-Forschung, wie beispielsweise Dew, Read et al. (2009), den Unterschied zwischen Risiko- und ungewissen Kontexten nicht ausreichend klar herausstellt. Darauf aufbauend versuchen Welter und Kim (2018) die Frage zu beantworten, wie wirksam Effectuation im Vergleich zu kausaler Logik in Risiko- und ungewissen Kontexten ist.

Zur Beantwortung der Frage bemühen Welter und Kim (2018) ein agentenbasiertes Simulationsmodell, das die Leistungsfähigkeit der Theorien Effectuation und Causation mittels einer Fitness-Landschaft untersucht. Zur Modellierung von Risiko- und ungewissen Entscheidungs-Kontexten manipulieren die Autoren die Fitness-Landschaft. Damit erreichen Welter und Kim (2018) eine Beeinflussung des Entscheidungsverhaltens von Entrepreneuren hinsichtlich der Möglichkeit die Zukunft vorherzusagen. Zusammenfassend bietet der Ansatz die Möglichkeit:

- den Grad des Einflusses von Risiko und Ungewissheit zu verändern,
- die Leistungsfähigkeit von Effectuation und Causation in den genannten Kontexten zu bewerten und
- den Planungsgrad des agentenbasierten Entrepreneurs zu steuern.

Welter und Kim (2018) definieren die Konzepte Risiko und Ungewissheit in Vorbereitung auf die Untersuchung. Ergänzend zu den Ausführungen aus Abschnitt 2.2 werden Risiko und Ungewissheit als zwei entgegengesetzte Enden eines

Kontinuums (Edelman & Yli-Renko, 2010) bzw. Grade von Risiko und Ungewissheit beschrieben (Brinckmann et al., 2010).

Als Simulationsansatz für die Untersuchung der Leistungsfähigkeit von Effectuation und kausaler Logik in Risiko- und ungewissen Kontexten wird ein NK-Modell verwendet, das auf den Ausführungen von Levinthal (1997) beruht und bereits in der Management-Forschung vielfach angewendet wird, wie beispielsweise von Ganco und Agarwal (2009), Rivkin (2000) und Lenox et al. (2006). Die Verwendung dieses Ansatzes trägt nach Auffassung von Welter und Kim (2018) dazu bei, folgende Herausforderung der bisherigen Effectuation-Forschung zu überwinden:

- Empirische Messbarkeit von Risiko und Ungewissheit
- Mangel an Bereitstellung leistungsbezogener Daten
- Replizierbarkeit von Entscheidungsverhalten.

Die Fitness-Landschaft von Welter und Kim (2018) ist durch verschiedene lokale Maxima gekennzeichnet, die sich um ein globales Maximum verteilen. Eine Positionierung des Agenten in der Landschaft drückt demzufolge den entsprechenden Leistungswert aus. Lokale Maxima repräsentieren eine hohe Leistung relativ zur Umgebung.

Die Messung der Leistungsfähigkeit bezieht sich auf Unternehmen, die den Untersuchungsgegenstand darstellen und als Agenten im Simulationsmodell handeln. Die Unternehmen werden nach Levinthal (1997) als eine Menge von Entscheidungen modelliert, die die Mächtigkeit N hat. Jede Entscheidung ist von binärem Charakter, was sich in Rivkin (2000) als sinnvoll erwiesen hat. Folglich wird ein Unternehmen durch eine N -dimensionale Binärkette repräsentiert als $S = \{s_1, s_2, \dots, s_{N-1}, s_N\}$, $s_j \in \{0, 1\}$. Es ergeben sich für ein Unternehmen 2^N mögliche Entscheidungskonfigurationen.

Das von Welter und Kim (2018) vorgestellte Simulationsmodell wendet den NK-Modellierungsansatz von Kauffman (1993) und Levinthal (1997) zur Darstellung der Fitness-Landschaft an. Diese bildet jede mögliche Entscheidungskette S auf einem Leistungswert $W(S)$ ab (Siggelkow & Rivkin, 2006). Zur Berechnung des Leistungswertes $W(S)$ einer Entscheidungskette S eines Unternehmens wird der Mittelwert der jeweiligen Leistungen $w(s_j)$ der einzelnen Entscheidungen s_j einer Entscheidungskette S gebildet. Es ergibt sich:

$$W(S) = \frac{1}{N} \sum_{j=1}^N w(s_j). \quad (3.4)$$

In diesem Zusammenhang kann $w(s_j)$ mit $j \in 1, 2, \dots, N$ als Beitrag verstanden werden, den s_j an der Leistung der Entscheidungskonfiguration S hat. Dieser Beitrag von s_j kann unter Umständen auch von anderen Entscheidungen der Entscheidungskonfiguration S abhängen. Dies wird durch $w(s_j, s_{-j})$ symbolisiert, wobei s_{-j} als Bezeichner für alle Entscheidungen aus S steht, die ebenfalls Einfluss auf den Beitrag von s_j haben.

Im NK-Modell parametrisiert K den Grad der Komplexität einer Entscheidung s_j im Rahmen der Entscheidungskonfiguration S des Unternehmens. K drückt die Anzahl der abhängigen Entscheidungen s_{-j} aus. Steigt demnach K , werden Entscheidungen komplexer. Die Annahme, dass mit steigender Komplexität auch die Abhängigkeit zwischen Einzelentscheidungen steigt, findet sich beispielsweise auch in Simon (1962) wieder. Ist $K = 0$, beeinflussen sich die einzelnen Entscheidungen nicht gegenseitig. Dies lässt sich durch $w(s_j, s_{-j}) = w(s_j)$ ausdrücken.

Um eine Fitness-Landschaft zu konstruieren, wird jeder Entscheidung s_j und ihren abhängigen Entscheidungen s_{-j} initial ein zufälliger Wert w , der aus der Gleichverteilung $U[0, 1]$ kommt, zugeordnet. Es ergibt sich:

$$w(s_j, s_{-j}) \sim U[0, 1] \text{ für } j = 1, \dots, N. \quad (3.5)$$

Gleichung (3.4) kann entsprechend zu

$$W(S) = \frac{1}{N} \sum_{j=1}^N w(s_j, s_{-j}) \quad (3.6)$$

erweitert werden.

Die Fitness-Landschaft bildet den Problemraum, in dem Unternehmen bestrebt sind, ihre Entscheidungen zu ändern, um so ihre Leistungsfähigkeit zu erhöhen und demnach eine höhere Fitness zu erreichen.

Um im Modell Ungewissheit zu simulieren, initiieren Welter und Kim (2018) im Simulationsablauf Schocks in die Fitness-Landschaft. Dabei wird nach jeder Periode T_S die Fitness-Landschaft in ihrer Beschaffenheit verändert. Dazu wird $w(s_j, s_{-j})$ mit $(1-\tau)w(s_j, s_{-j}) + \tau U$ ersetzt, wobei U einen zufälligen Wert aus der Gleichverteilung $U[0, 1]$ darstellt und τ im Intervall von $[0, 1]$ liegt. Entsprechend wird die Abbildung von Entscheidungen zu Leistungswerten geändert.

Der Grad der Ungewissheit wird mittels des Parameters τ realisiert. Beträgt $\tau = 0$, befindet sich das Unternehmen in Form eines Agenten in einem Risiko-Kontext. Die Fitness-Landschaft ändert sich während der Simulation nicht. Beträgt

hingegen $\tau = 1$, ist zwischen zwei aufeinanderfolgenden Fitness-Landschaften kein Zusammenhang mehr gegeben und ein ungewisser Kontext tritt ein.

Der Entscheidungsfindungsprozess des Agenten wird durch eine adaptive Suche nach besseren Leistungswerten von begrenzt rationalen Individuen (Simon, 1959) konzeptualisiert (Cyert & March, 1963; Levinthal, 1997). Der Suchprozess im Sinne eines Optimierungsalgorithmus wird mit Hilfe des Hill-Climb-Verfahrens umgesetzt (Csaszar & Siggelkow, 2010; Rivkin, 2000). Bei dieser Heuristik suchen Agenten nach einer Entscheidungskonfiguration, die einen besseren Leistungswert als die ursprüngliche Konfiguration aufweist, indem jeweils nur eine Entscheidung verändert wird und die entsprechenden Leistungswerte verglichen werden. Sofern die geänderte Entscheidungskonfiguration zu einem besseren Leistungswert führt, passt der Agent die untersuchte Entscheidung an. Andernfalls behält der Agent die ursprüngliche Entscheidungskonfiguration bei. Die Anwendung des Hill-Climb-Verfahrens begründen Welter und Kim (2018) zudem mit dem Konzept der begrenzten Rationalität, wie es bereits Simon (1959) eingeführt hat. Demnach können Agenten nicht über die gesamte Fitness-Landschaft nach dem Optimum suchen, sondern haben lediglich die Möglichkeit, pro Zeitpunkt jeweils eine Entscheidung anzupassen und anschließend die Leistungsfähigkeit der Entscheidungskonfiguration zu überprüfen.

Zur Modellierung des Planungsgrades verwenden Welter und Kim (2018) einen Parameter ϱ . Dieser beschreibt die Anzahl an Entscheidungen einer Entscheidungskonfiguration, die während des Suchprozesses fix sind. Dabei kann ϱ die Werte $0, \dots, N$ annehmen. Die ϱ Entscheidungen werden zufällig aus N Entscheidungen ausgewählt. Effektiv handelnde Agenten werden mit $\varrho = 2$, Agenten, die kausaler Logik folgen, werden mit $\varrho = 8$ operationalisiert. Die Tatsache, dass Effectuation-Agenten nicht $\varrho = 0$ fixe Entscheidungen haben, liegt darin begründet, dass effektive Entrepreneurinnen auf ihre aktuell zur Verfügung stehenden Mittel begrenzt sind (Sarasvathy, 2009, S. 75) und demzufolge ein Teil der Entscheidungen ($\varrho = 2$) bereits fix ist.

Um den Agenten mit der Möglichkeit auszustatten Vorhersagen zu treffen, verwenden Welter und Kim (2018) den Parameter λ . Dieser gibt die Wahrscheinlichkeit an, mit der jede der ϱ Entscheidungen der Entscheidungskonfiguration des Agenten mit den Entscheidungen der Entscheidungskonfiguration des globalen Maximums übereinstimmt. Je höher demnach λ ist, desto höher ist die Chance des Agenten das globale Maximum zu bestimmen. Zusammenfassend werden folgende Parameter zur Konstruktion des Simulationsaufbaus und Manipulation des Simulationsablaufs verwendet:

- S mit $s_j \in \{0, 1\}$: Entscheidungskonfiguration als Repräsentation eines Unternehmens
- N : Anzahl der Entscheidungen s_j innerhalb einer Entscheidungskonfiguration S
- K : Komplexitätsgrad im Sinne der Anzahl von Entscheidungen s_{-j} , die mit s_j in Verbindung stehen
- $W(S)$: Leistungsmaß einer Entscheidungskonfiguration, welches zu jedem Simulationszeitpunkt t gemessen wird; nach Ablauf einer Simulation werden alle $W(S)$ aufsummiert und über die Zeit $t = T$, mit T als Anzahl der Simulationszeitschritte, gemittelt; anschließend werden die einzelnen gemittelten Leistungswerte nach Durchführung mehrerer Simulationsdurchläufe mit unterschiedlichen Fitness-Landschaften nochmals gemittelt.
- τ : Parameter zur Steuerung des Risiko- bzw. Ungewissheits-Kontextes durch Veränderung der Fitness-Landschaft
- q : Anzahl der fixen Entscheidungen innerhalb einer Entscheidungskonfiguration S
- λ : Wahrscheinlichkeit, mit der jede der q fixen Entscheidungen des Agenten kongruent mit den Entscheidungen an der selben Stelle der Entscheidungskonfiguration des globalen Maximums ist

Zur Durchführung der Simulation des agentenbasierten Modells wird zunächst aus den Parametern N , K und τ eine Fitness-Landschaft erzeugt. Weiterhin wird die Lage des Unternehmens in der Fitness-Landschaft, in Form einer Entscheidungskonfiguration, zur Zeit $t = 1$ mittels einer Bernoulli-Verteilung mit der Erfolgswahrscheinlichkeit $p = 0,5$ für die einzelnen Entscheidungen s_j mit $j \in \{1, 2, \dots, N\}$ bestimmt. Danach folgen die Unternehmens-Agenten dem adaptiven Suchalgorithmus bis zur Zeit $t = T$, wobei T die Anzahl der gesamten Simulationszeitschritte darstellt. Die Anzahl der Simulationsschritte T wird in Perioden eingeteilt, die die Länge T_S haben. Im Anschluss wird auf Grundlage des Parameters τ nach T_S Zeitschritten ein Schock in die Fitness-Landschaft initiiert, der den Risiko- bzw. ungewissen Kontext simuliert. Nach Auftreten des Schocks ändern die Agenten q ihrer Entscheidungen, basierend auf dem Vorhersage-Parameter λ , hinsichtlich des globalen Maximums. Die Schritte der adaptiven Suche und der Schockinitiierung werden wiederholt bis $t = T$ und die Simulation somit beendet ist. In Form von Pseudo-Code lässt sich der Simulationsablauf von Welter und Kim (2018), wie in der Übersicht Algorithmus 2 beschrieben, algorithmisch interpretieren. Die Prozedur stellt hierbei eine Verallgemeinerung des von Welter und Kim (2018) entwickelten Simulationsablaufs dar, sodass die Anzahl der Ausprägungen, die eine Entscheidung annehmen kann, beliebig groß sein kann. Um die Simulation

durchzuführen, verwenden Welter und Kim (2018) eine Parameterkonfiguration mit $N = 10$, $T_S = 10$ und $T = 200$. Die Parameter K , τ , ϱ und λ werden während der insgesamt 25.000 durchgeführten Simulationsdurchläufe geändert. Damit folgen Welter und Kim (2018) den Monte-Carlo-Simulationstechniken, wie sie unter anderem von Law und Kelton (1991), Mauer et al. (2017), Davis et al. (2009) und Rivkin (2000) vorgeschlagen werden.

Die Simulationsergebnisse zeigen, dass Effectuation (bei $\varrho = 2$) gegenüber kausaler Logik ($\varrho = 8$) in einem großen Spektrum von Risiko- und ungewissen Entscheidungskontexten (τ) sowie dem Großteil der Bandbreite der Vorhersagefähigkeit des Agenten (λ) überlegen ist. Lediglich in Situationen, in denen τ klein ist und somit ein Risiko-Kontext vorherrscht bzw. in denen λ hoch ist, ist die Leistungsfähigkeit kausaler Logik im Vergleich zu Effectuation höher. Eine kritische Evaluation der hier zusammengefassten Ergebnisse erfolgt in Abschnitt 3.2.2.

3.1.3 Simulationsmodell nach Eberz (2018)

Eberz (2018) hat mit FSim eine interaktive Verhaltenssimulation entwickelt, um effektuative und kausale Verhaltensweisen von Nutzern in verschiedenen Szenarien zu untersuchen. Methodisch orientiert sich Eberz (2018, S. 70) an Design Science, wie ihn Hevner et al. (2004) und March und Storey 2008 beschreiben. Charakteristisch für diesen Forschungsansatzes ist, dass im organisationalen Kontext neue und innovative Artefakte geschaffen werden, deren Mehrwert im Anschluss evaluiert wird (Hevner et al., 2004). Mit dem in Eberz (2018) vorgestellten Simulationsmodell wird zudem die Frage untersucht, wie kausales und effektuatives Verhalten operationalisiert werden kann. Dabei erweitert Eberz (2018) die Operationalisierungsbestrebungen in der Effectuation-Forschung von Chandler et al. (2011) und McKelvie et al. (2011) um Faktoren der Persönlichkeit unerfahrener Entrepreneur.

Eberz (2018, S. 78–95) stellt an die Entwicklung des Simulationsmodells mehrere funktionale Anforderungen, die aus Fallstudien und Gedankenexperimenten aus der Literatur abgeleitet werden. Sie betreffen die Bereiche:

- Mittel- und Zielorientierung
- Akteure
- Aktionen
- Nutzer
- Interaktionen
- Allgemein (z. B. Reproduzierbarkeit, Abbildung des entrepreneurialen Problemraums und Protokollierbarkeit der Interaktionen)

Algorithmus 2 NK-Modell

```

1: procedure SIMULATIONSABLAUF( $N, K, Q, \tau, \rho, \lambda$ )
2:    $S \leftarrow \{0, \dots, Q-1\}^N$ 
3:   for each  $q \in Q^{K+1}$  do
4:     for  $j \leftarrow 1, N$  do
5:        $w_j(q) \sim U[0, 1]$ 
6:     end for
7:   end for
8:   for each  $s \in S$  do
9:      $W(S) \leftarrow \frac{1}{N} \sum_{j=1}^N w_j((s_j, \dots, s_{(j+K) \bmod N}))$ 
10:  end for
11:   $s^{max} \leftarrow \arg \max_{s \in S} W(S)$  ▷  $s^{max}$  represents decision configuration at optimal performance value
12:   $s^{agent} \leftarrow$  random choice in  $S$ 
13:   $J \leftarrow$  random sample of  $\rho$  elements of  $\{1, \dots, N\}$ 
14:  for each  $j \in J$  do
15:     $rand \leftarrow Ber(\lambda)$ 
16:    if  $rand = 1$  then
17:       $s_j^{agent} \leftarrow s_j^{max}$ 
18:    end if
19:  end for
20:   $\bar{W} \leftarrow 0$ 
21:  for  $t \leftarrow 1, T$  do
22:    if  $t \bmod T_S = 0$  then
23:      for each  $q \in Q^{K+1}$  do
24:        for  $j \leftarrow 1, N$  do
25:           $w_j(q) \leftarrow (1 - \tau)w_j(q) + \tau U[0, 1]$ 
26:        end for
27:      end for
28:      for each  $s \in S$  do
29:         $W(S) \leftarrow \frac{1}{N} \sum_{j=1}^N w_j((s_j, \dots, s_{(j+K) \bmod N}))$ 
30:      end for
31:       $s^{max} \leftarrow \arg \max_{s \in S} W(S)$ 
32:      for each  $j \in J$  do
33:         $rand \leftarrow Ber(\lambda)$ 
34:        if  $rand = 1$  then
35:           $s_j^{agent} \leftarrow s_j^{max}$ 
36:        end if
37:      end for
38:    end if
39:    for each  $s \in neighbours(s^{agent})$  do
40:      if  $W(s^{agent}) < W(S)$  then
41:         $s^{agent} \leftarrow s$ 
42:      end if
43:    end for
44:     $\bar{W} = \bar{W} + W(s^{agent})$ 
45:  end for
46:   $\bar{W} = \frac{1}{T} \bar{W}$ 
47: end procedure

```

Neben den fallstudienbasiert-funktionalen Anforderungen stellt Eberz (2018, S. 95–104) an FSim auch konstrukt-basiert-funktionale Anforderungen. Diese betreffen Messindikatoren, die Chandler et al. (2011) zur Messung von Effectuation und Causation verwenden. Die operationalisierten Indikatoren interpretiert Eberz (2018) für die konkrete Umsetzung in FSim. Darüber hinaus werden im Hinblick auf die Entwicklung des Simulationsmodells auch mehrere nicht-funktionale Anforderungen benannt, die sich insbesondere auf die Bedienbarkeit des Simulationsmodells beziehen. Die Bestimmung nicht-funktionaler Anforderungen liegt in der Tatsache begründet, dass FSim effektuatives und kausales Verhalten auf Grundlage der Nutzerinteraktion mit dem Artefakt untersucht.

Im Vorfeld der Implementierung des Simulationsmodells beschreibt Eberz (2018, S. 72–78) die Architekturskizze und das Domänenmodell von FSim und bezieht sich dabei auf die Erläuterungen zum grundlegenden Aufbau in Eberz et al. (2015). Dabei dient die Architekturskizze als Mittel zur Darstellung der Vision von FSim. Darüber hinaus gibt sie Aufschluss über die Rolle des Nutzers als Akteur, der mit FSim interagiert und die des Beobachters, der auf die historischen Daten, die durch die Interaktion entstanden sind, zugreifen kann. Der Akteur steht diesbezüglich in Interaktion mit dem Artefakt. Der Beobachter hingegen hat die Möglichkeit auf historische Daten zuzugreifen, die durch die vom Akteur durchgeführten Interaktionen entstanden sind. Das Domänenmodell, das als UML-Klassendiagramm umgesetzt ist (Rupp, 2007), dient als Glossar für die Darstellung der Entitäten und Beziehungen dieser zueinander, zur Beschreibung der zu untersuchenden Domäne.

Nach Interaktionen der Akteure mit FSim werden zu Simulationszwecken verschiedene Ereignisse ausgelöst. Dazu gehören die Produktions- und Vertriebsroutinen. Zudem wird eine virtuelle Nachfrage des virtuell zu produzierenden Produkts berechnet. Die mathematische Modellierung des Produkt-Fits, der als Grundlage für die Ermittlung der Nachfragefunktion fungiert sowie die Modellierung der Nachfrage selbst, werden im Anhang der Arbeit von Eberz (2018, S. 233–238) vorgestellt.

Der Produkt-Fit dient in Eberz (2018) der Operationalisierung der Produktgüte. Nkwocha et al. (2005) verwenden den Begriff des *product fit* im Kontext der Markenerweiterung und verstehen darin, wie sehr sich ein Kunde mit einem Produkt identifizieren kann. In der populärwissenschaftlichen Literatur ist auch der Begriff *product-market-fit* zu finden, der beschreibt, inwieweit die Ausgestaltung eines Produktes der Marktnachfrage entspricht (Blank & Dorf, 2020, S. 57). Eberz (2018) weicht von den bisherigen Interpretationen ab und definiert, dass der „Produkt-Fit zur Operationalisierung der Güte eines Produktes“ (Eberz, 2017, S. 233) dient. Zur Berechnung des Produkt-Fit bezieht sich (Eberz, 2018, S. 233) auf die Einsatzmenge und den Preis von verschiedenen Produktionsfaktoren, die während der Simulation bestimmt werden. Die Beitragsleistung eines Produktionsfaktors zur Gesamtgüte

eines Produktes (Produkt-Fit) wird über die Dichtefunktion φ einer Normalverteilung $N(\mu, \sigma^2)$ ausgedrückt. Die optimale Einsatzmenge eines Produktionsfaktors als maximaler Beitrag zur Produktgüte wird durch den Erwartungswert μ bestimmt, Abweichungen davon werden mit dem Streuungsparameter σ^2 beschrieben. Die Dichtefunktion φ_i stellt die Abbildung der Einsatzmenge r_i eines Produktionsfaktors i auf ein Gütemaß $\varphi_i(r_i)$ dar. Dieser Zusammenhang lässt sich durch

$$\varphi_i(r_i) = \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(r_i-\mu_i)^2}{2\sigma_i^2}} \quad (3.7)$$

ausdrücken.

Das wirtschaftliche Ziel ist es, die Gütebeiträge der Produktionsfaktoren zu maximieren, da diese Einfluss auf die Nachfrage des Produkts haben. Die Maximierung eines Gütebeitrags kann mathematisch mit $\varphi_i(r_i) \rightarrow \max$ beschrieben werden. Die Beitragshöhe eines Produktionsfaktors i lässt sich mit Hilfe des Varianzparameters σ_i^2 steuern. Dabei ist zu erreichen, dass in optimaler Menge eingesetzte Produktionsfaktoren, die vergleichsweise teurer sind, einen größeren Beitrag zum Produkt-Fit leisten. Die Bestimmung des Streuparameters σ_i^2 für jeden Produktionsfaktor i wird mittels des jeweiligen Faktorpreises p_i modelliert². Es ergibt sich:

$$\sigma_i^2 = \frac{1}{p_i}.$$

Die optimale Faktoreinsatzmenge, die dem Erwartungswert μ_i entspricht, wird in Eberz (2018, S. 234) aus den vorgegebenen Faktorpreisen festgelegt und errechnet sich mit Hilfe der Differenz des Preises des teuersten Faktors und des jeweiligen Produktionsfaktors plus 1. Mathematisch ließe sich dies durch

$$\mu_i = g(p_{max} - p_i + 1)$$

ausdrücken, wobei p_{max} den Preis des teuersten Faktors repräsentiert. Dabei ist jedoch unklar, ob die Funktion $g(\cdot)$ die identische Abbildung oder eine andere

² Eberz (2018, S. 233) verwendet zur Darstellung eines Faktorpreises die Notation i_p . Um in der vorliegenden Arbeit die Notation konsistent zu halten, wird der Produktionsfaktor i , wie auch beispielsweise bei den Einsatzmengen r und den Gütebeiträgen φ , als Laufindex der Preise mit p_i formuliert. Weiterhin ist anzumerken, dass Eberz (2018, S. 233) die Preise ganzzahlig modelliert.

monoton wachsende Funktion ist. Eberz (2018, S. 234) formuliert darauf aufbauend lediglich folgende axiomatische Annahme:

„Je größer der preisliche Abstand zum teuersten Produktionsfaktor, desto höher die optimale Einsatzmenge des betrachteten Faktors.“

Eberz (2018, S. 233–235) stellt in seinen Ausführungen keinen eindeutigen Zusammenhang zwischen der Einsatzmenge r_i und dem jeweiligen Preis p_i eines Produktionsfaktors i heraus. Auf Grundlage der bisherigen Annahmen wird die Berechnung des Produkt-Fits für l verschiedene Produktionsfaktoren durch Eberz (2018, S. 235) folgendermaßen definiert:

$$P_f = \frac{1}{l} \sum_{i=1}^l \varphi_i(r_i).$$

Zur Modellierung der Marktnachfrage verwendet Eberz (2018, S. 236) eine linear fallende Funktion, wobei der Prohibitiv-Preis P_V als Schnittpunkt der Funktion mit der Ordinatenachse (Preis) und die Sättigungsmenge z als Schnittpunkt mit der Abszissenachse (abgesetzte Menge) definiert sind. Dieser Zusammenhang wird grafisch in Abbildung 3.2 veranschaulicht.

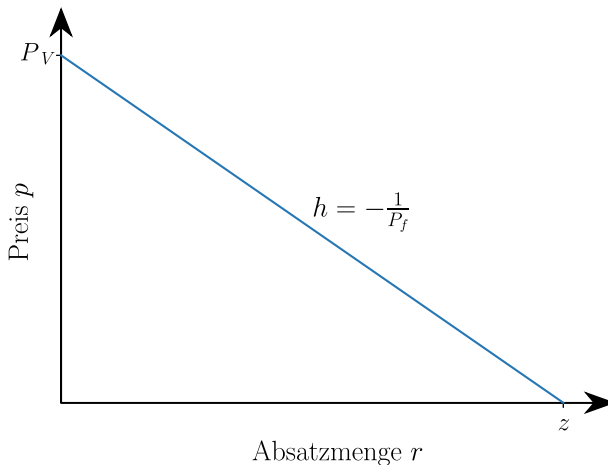


Abb. 3.2 Grafische Darstellung der von Eberz (2018) formulierten Marktnachfrage-Funktion

Der Prohibitiv-Preis P_V eines Produktes P wird mit Hilfe des Produkt-Fits P_f und des Selbstkostenpreises P_k wie folgt berechnet:

$$P_V = P_f \cdot 10 \cdot P_k.$$

Eberz (2018, S. 236) bezieht in die Berechnung die Selbstkosten P_k ein, da teurere Produktionsfaktoren einen höheren Prohibitiv-Preis begründen. Die Einbeziehung des Faktors 10 in die Berechnung des Prohibitiv-Preises hat gemäß Eberz (2018, S. 236) die Funktion eines Multiplikators, wobei offengelassen wird, welchen Nutzen die Verwendung des Faktors bringt.

Zur Beschreibung der Nachfragefunktion verwendet Eberz (Eberz, 2018, S. 236) die mathematische Form:

$$r = h \cdot p + z,$$

wobei h durch

$$h = \frac{\Delta r}{\Delta p} = \frac{-\frac{1}{P_f}}{1} = -\frac{1}{P_f}$$

bestimmt wird. Die Mengenänderung Δr wird, bei einer Preisänderung von $\Delta p = 1$, mittels des negativ inversen Produkt-Fits dargestellt. Zudem stellt die Mengenänderung im Kontext der Nachfragefunktion, wie sie beispielsweise in Natrop (2012) beschrieben wird, eine Änderung der nachgefragten Gesamtmenge eines Gutes dar. Der Produkt-Fit P_f in Eberz (2018, S. 235) bezieht sich auf die mengenabhängigen Gütebeiträge von Produktionsfaktoren zum Produkt. Inwiefern der Produkt-Fit eines Produktes inhaltlich in Zusammenhang mit der nachgefragten Menge des Produktes steht, lässt Eberz (2018) offen.

Die nach dem erläuterten Vorgehen berechnete Nachfrage r wird während der Simulation nach jeder Simulationsperiode modifiziert. In Eberz (2018, S. 237 f.) wird die Nachfragemodifikation in fünf Teile untergliedert:

1. Multiplikation der Nachfrage r mit einem Basismultiplikator, der durch das jeweilige Simulationsszenario bestimmt ist zur Festlegung eines Nachfrage-Niveaus
2. Multiplikation der Marktnachfrage r mit einem Marktereignis-Multiplikator im Intervall $[1; \infty)$ (Marktaufschwung) bzw. $[0; 1]$ (Marktrezession).
3. Anteilmäßige Verringerung der Nachfrage proportional zu den gehaltenen Marktanteilen der virtuellen Konkurrenz

4. Multiplikation der Nachfrage r mit einem Marketing-Multiplikator
5. Multiplikation der Nachfrage r mit einem Vertriebs-Multiplikator, der durch die Wahl des Vertriebskanals bestimmt ist

Die interaktive Simulation, die in Eberz (2018, S. 107) beschrieben wird, beginnt für den FSim-Nutzer mit einem Erklärungsvideo zur Benutzung des Artefakts. Dabei erhält er einen Begrüßungsdialog mit dem Hinweis, dass Nutzer – im Rahmen des Programms – freie Handlungsmöglichkeiten besitzen und kein bestimmtes Verhalten von den Probanden erwartet wird. Im Anschluss wird dem Nutzer die von Eberz (2018, S. 107) definierte Szenario-Beschreibung angezeigt. Das für die Simulation zugrundeliegende Szenario wird durch FSim automatisch gewählt und spiegelt eine spezifische Handlungsumgebung inklusive des aktuellen Simulationszustandes und der Simulationsparameter wider. Die Parameterkonfiguration bildet die für Effektuatation kennzeichnenden Merkmale knightsche Ungewissheit, Umgebungsisotropie und Zielambiguität ab. Eberz (2018, S. 124) verwendet zur Operationalisierung knightscher Ungewissheit das Konzept der Umgebungsturbulenz (Waldman et al., 2001). Die Umgebungsisotropie wird mit Hilfe eines Indikators operationalisiert, der die Adäquatheit der zur Verfügung gestellten Informationen repräsentiert (Duncan, 1972, S. 318). Die Operationalisierung der Ziel-Ambiguität wird mittels der Indikatoren von Stazyk und Goerdel (2011) zur Zielklarheit realisiert.

Nach Initialisierung der FSim-Umgebung und Einführung des Nutzers in das Programm beginnt die interaktive Simulation, die durch Eingaben des Nutzers geprägt ist. Der Nutzer kann – ausgehend vom Szenariokontext – Handlungsentscheidungen anhand seines Vermögens, möglicher Rechtsformen und Lager sowie gehaltener Unternehmensanteile treffen. Nach Durchführung der Aktivitäten durch den Nutzer werden die Vertriebs- und Produktionsroutinen angestoßen und die entsprechenden Parameter für die nächste Simulationsperiode gesetzt. Der Benutzer hat die Möglichkeit, am Ende jeder Simulationsperiode die Simulation zu beenden. Nach Beendigung des Simulationsteils hat der Nutzer die Möglichkeit, Fragen zum eigenen Verhalten, zu Beobachtungen der Umgebung während der Simulation und seiner Persönlichkeit zu beantworten. Die daraus resultierenden Daten dienen gemäß den Ausführungen in Eberz (2018) zur Bestimmung effektuativen und kausalen Verhaltens. Die Offenlegung der in den Experimenten erfassten Befragungs- und Simulationsdaten ist nicht Bestandteil der Arbeit. Es erfolgt lediglich eine Darstellung der Verhaltensausmaße und Verhaltensunterschiede auf Grundlage der Daten.

3.1.4 Vergleich der Simulationsmodelle

Um auf die in dieser Arbeit gestellte Forschungsfrage Antworten zu finden, werden die in den Abschnitten 3.1.1 bis 3.1.3 diskutierten Simulationsmodelle evaluiert und gegenübergestellt. Dadurch wird die Ableitung weiterer Modellierungsanforderungen ermöglicht. Zur Bewertung von Simulationsmodellen schlagen Gulyás und Kampis (2015) ein Rahmenwerk vor, das sich auf Erkenntnisse aus Robinson (1997) bezieht. In Robinson (1997) wird die Notwendigkeit von Verifikation und Validierung eines Simulationsmodells beschrieben. Dabei erlauben Verifikation und Validierung Ergebnisse einer Studie transparent und nachvollziehbar zu machen. Ausgehend von den Ausführungen von Sargent (1992) zu Verifikations- und Validierungsanforderungen während des Simulationsmodellierungsprozesses definiert Robinson (1997) verschiedene Arten der Validierung:

- *Konzeptuelle Modellvalidierung*: Prüfung des Detailgrades des Modellkonzeptes gegen die Erkenntnisziele der Simulationsstudie
- *Datenvalidierung*: Prüfung der Akkuratess der für die Modellierung, Validierung und Experimentation geforderten Daten
- *White-Box-Validierung*: Prüfung der Akkuratess der Simulationselemente gegen die abzubildenden realweltlichen Systemelemente
- *Black-Box-Validierung*: Prüfung der Akkuratess des gesamten Simulationsmodells gegen das gesamte zu untersuchende realweltliche Phänomen

Gulyás und Kampis (2015) fassen die Validierungsanforderungen von Robinson (1997) zusammen und beziehen diese in die Entwicklung ihres Frameworks ein. Dabei werden folgende Kriterien für den Vergleich verschiedener Simulationsmodelle identifiziert:

- *Validierung*: Prüfung der Akkuratess des Modells und der Modellelemente hinsichtlich der tatsächlichen Abbildung bisheriger empirischer Modelle über die reale Welt. Konkret kann Validierung auch definiert werden als „substantiation that a computerized model within its domain of applicability possesses a satisfactory range of accuracy consistent with the intended application of the model“ (Schlesinger et al., 1979, S. 104)
- *Verifikation*: Vergleich des implementierten Simulationsmodells mit den durch den Modellierer im Vorfeld definierten Spezifikationen
- *Replikation*: Als Alternative zur Verifikation können die Ergebnisse einer reproduzierten Implementierung mit den Ergebnissen einer bereits existierenden Implementierung desselben Modells verglichen werden

- *Simulations-Docking*: Als Alternative zur Verifikation können die Ergebnisse unterschiedliche Modellansätze mit demselben Simulationsziel miteinander verglichen werden

Das SCS Technical Committee on Model Credibility hat eine Terminologie entwickelt, um die Glaubwürdigkeit von Simulationsmodellen zu untersuchen (Schlesinger et al., 1979). Die Terminologie wurde in einem Rahmenwerk zusammengefasst, das in der Literatur weiterentwickelt und erweitert wurde (Robinson, 1997; Sargent, 2013). Die Zusammenhänge der Verifikations- und Validierungsprinzipien im Rahmen des Modellierungsprozesses von Sargent (2013) werden in Abbildung 3.3 dargestellt und bauen auf dem entwickelten Modell in Schlesinger et al. (1979) auf. Abbildung 3.3 zeigt die Zusammenhänge im Modellierungsprozess zwischen den Elementen Realität als System, dem konzeptuellen Modell zur Beschreibung der analysierten Realität sowie dem computerisierten Modell in Form einer Implementierung des konzeptuellen Modells zur Experimentierzwecken. Parallel dazu erfolgen die Verifikations- und Validierungsprozesse, die den Abgleich zwischen den Modellierungselementen beschreiben. Zum Vergleich und zur kritischen Diskussion der in den Abschnitten 3.2.1 und 3.2.2 vorgestellten effektuativen Simulationsmodelle wird insbesondere die Überprüfung der Modelle vorgenommen. Da den zu diskutierenden Modellen von Eberz (2018), Welter und Kim (2018) sowie Mauer et al. (2017) nur rudimentäre Hinweise zur Implementierung der vorgestellten Modelle gegeben werden, wird eine konzeptuelle Validierung der Modelle vorgenommen, wie sie in Sargent (2013) vorgestellt wird. Hierzu soll insbesondere geklärt werden, ob “(1) the theories and assumptions underlying the conceptual model are correct and (2) the model’s representation of the problem entity and the model’s structure, logic, and mathematical and causal relationships are ‘reasonable’ for the intended purpose of the model” (Sargent, 2013, S. 17). Zur Beantwortung dieser Modellvalidierungsfragen stellt Sargent (2013) Validierungstechniken vor. Die zur Beurteilung der betrachteten Simulationsmodelle relevanten Methoden sind:

- *Vergleich zu anderen Modellen*: Gegenüberstellung der Ergebnisse unterschiedlicher (valider) Simulationsmodelle
- *Augenscheinvalidität (face validity)*: Überprüfung des Modellverhaltens hinsichtlich der Nachvollziehbarkeit durch Domänenexperten
- *Interne Validierung*: mehrfache Durchführung des Simulationsablaufs zur Überprüfung der Variabilität des Modells
- *Operationalisierende Grafiken*: Grafische Darstellung von Leistungswerten im Simulationszeitverlauf

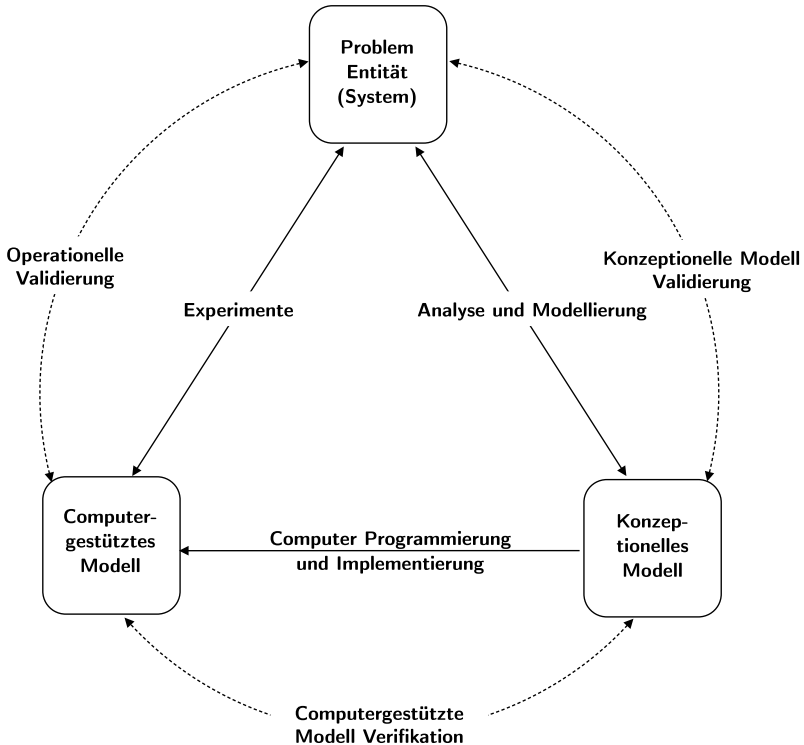


Abb. 3.3 Zusammenspiel zwischen Modellierungsprozess und Validierungs- und Verifikationsprozess nach Schlesinger (1979)

Aufgrund der durch die Autoren Mauer et al. (2017), Welter und Kim (2018) und Eberz (2018) vorgestellten Modelleigenschaften und -daten wird zur Gegenüberstellung der Simulationsmodelle das von Gulyás und Kampis (2015) vorgeschlagene Konzept des Simulations-Dockings verwendet, bei dem Simulationsmodelle mit demselben Simulationsziel miteinander verglichen werden. Zusätzlich werden zur deskriptiven Gegenüberstellung der effektuativen (und kausalen) Modelle und zur Beantwortung der von Sargent (2013) formulierten Modellvalidierungsfragen folgende Kriterien definiert:

- Typ des Simulationsmodells
- Ziel der Modellierung

Tab. 3.1 Gegenüberstellung der Simulationsmodelle

	FL-Modell (Mauer et al. (2017))	NK-Modell (Welter und Kim (2018))	FSim (Eberz (2018))
Typ	Agentenbasiertes Simulationsmodell	Agentenbasiertes Simulationsmodell	Interaktives Simulationsmodell
Modellierungsziel	<ul style="list-style-type: none"> • Verstehen von leistungsfähigkeitsunterschieden vorhersagebasierter (abk. CA) und steuerungsbasierter (abk. EA) unternehmerischer Suchprozesse • Verstehen des Einflusses von Informationsisotropie, Ungewissheit (umgebungsbedingte Unvorhersagbarkeit) und Zielambiguität auf die Marktmachfrage bei Anwendung der unterschiedlichen unternehmerischen Suchprozesse 	<ul style="list-style-type: none"> • Verstehen von Leistungsfähigkeitsunterschieden von EA und CA in Risiko- und Ungewissheitskontexten 	<ul style="list-style-type: none"> • Untersuchung, inwieweit unerfahrene Entrepreneure in Abhängigkeit der Umgebungsunsicherheit kausales oder effektives Verhalten zeigen • Untersuchung, welchen Einfluss die Persönlichkeit von unerfahrenen Entrepreneuren in Abhängigkeit von Umgebungsunsicherheit auf kausales und effektives Verhalten hat
Einflussgrößen	<ul style="list-style-type: none"> • Anzahl vorhersagebasierte, Konsumenten-Agenten • Anzahl Artefakt-Vektorcomponenten n • Anzahl flexible Artefakt-Vektorcomponenten • Anzahl mögliche Ausprägungen pro Artefakt-Vektorcomponente k • Marktnachfragenvariation v • Marktnachfragenominanz d • Verteilung von jeweils k Ausprägungen über die Vektorcomponenten der Agenten • Nachfragekonzentration c 	<ul style="list-style-type: none"> • N-dimensionale Entscheidungskette S mit $s_j \in \{0, 1\}$ • Komplexitätsgrad K einer Entscheidung s_j • Aus einer Gleichverteilung gewählter zufälliger Leistungen einer Entscheidung mit K abhängigen Entscheidungen s_{-j} innerhalb einer Entscheidungskonfiguration $w(s_j, s_{-j}) \sim U[0, 1]$ • Steuerungsparameter der Ungewissheit τ • Steuerungsparameter des Planungsgrades ϱ • Steuerungsparameter des Vorhersagegrades λ 	<ul style="list-style-type: none"> • Anfänglicher Vermögensstand • Max. Geldbetrag von Freunden und Bekannten • Maximale Kreditsumme & Sollzins • Wählbare Rechtsform • Anzahl der verschiedenen einsetzbaren Produktionsfaktoren • Produktions-/Nachfrage-Zyklen pro Periode inkl. Schwankung • Vertriebswege • Ergebnisoffenheit & Kosten der Marktanalyse und Wettbewerbsanalyse • Anzahl Konkurrenten und deren Marktanteil • Wahrscheinlichkeit für Auftreten eines neuen Konkurrenten • Verfügbare Marketing-Kampagnen • Lageroptionen (gekennzeichnet durch Anz. lagerbarer Einheiten und Kosten) • Diverse wahrnehmlichkeitsbasierte Ereignisse • Diverse Multiplikatoren für die Ereignisse

(Fortsetzung)

Tab. 3.1 (Fortsetzung)

<p>Allgemein:</p> <ul style="list-style-type: none"> • Variierung der Marktnachfrage: $v = \frac{k}{c} \text{ mit } v \in [k; k^2]$ <ul style="list-style-type: none"> • Dominanz in der Marktnachfrage: $d = c \cdot k \text{ mit } d \in [1; k]$ <ul style="list-style-type: none"> • Initiale Parameterkonfiguration mittels Monte-Carlo-Algorithmen • Implementierung mittels <i>Recapast_Symphony</i> (Java-basiert) <p>Entrepreneurialer Problemraum:</p> <ul style="list-style-type: none"> • Steuerung von Informationsisotropie mittels variierender Marktnachfrage \rightarrow Veränderung von Produktdiversität, k und Marktkonzentration c • Steuerung von Ungewissheit (umgebungsbedingte Unvorhersagbarkeit) mittels Steuerung der Konstanz der Verteilung der Produktvektorkomponentennachfrage k im Zeitverlauf der Simulation • Steuerung der Zielambiguität mittels der flexiblen Produktvektorkomponenten m 	<p>Allgemein:</p> <ul style="list-style-type: none"> • Berechnung des Leistungswertes einer Entscheidungskonfiguration: $W(S) = \frac{1}{N} \sum_{j=1}^N w(s_j, s_{-j})$ <ul style="list-style-type: none"> • Verteilung der Entscheidungskonfigurationen in der NK-Landschaft mittels Bernoulli-Versuchen <p>Entrepreneurialer Problemraum:</p> <ul style="list-style-type: none"> • Steuerung von Ungewissheit durch Veränderung des Leistungswertes $w(s_j, s_{-j})$ zum Zeitpunkt T_S mit $(1 - \tau)w(s_j, s_{-j}) + \tau U(0, 1)$ • Steuerung des Planungsgrades mittels Fixierungs von ϑ Entscheidungen während des Simulationsablaufes, die mit Wahrscheinlichkeit λ dem globalen Maximum entsprechen 	<p>Allgemein:</p> <ul style="list-style-type: none"> • Berechnung des Produkt-Fits P_f: $P_f = \frac{1}{l} \sum_{i=1}^l \varphi_i(r_i)$ <p>mit $\varphi_i(r_1) \dots$ Gütebeitrag Produktionsfaktor $\varphi_i(r_1) \dots$ Gütebeitrag Produktionsfaktor</p> <ul style="list-style-type: none"> • Berechnung des Prohibitivpreises P_V: $P_V = P_f \cdot 10 \cdot P_k$ <p>mit $P_k \dots$ <i>Selbstkostenpreis</i></p> <ul style="list-style-type: none"> • Berechnung der Nachfragefunktion r: $r = -\frac{1}{P_f} \cdot p + 10 \cdot P_k$ <p>mit $p \dots$ <i>Preis</i></p> <ul style="list-style-type: none"> • Implementierung mittels <i>FSim</i> (Java-basiert) <p>Entrepreneurialer Problemraum:</p> <ul style="list-style-type: none"> • Steuerung knightischer Ungewissheit, Informationsisotropie und Zielunklarheit durch Bereitstellung von zwei Szenarien innerhalb der interaktiven Simulation
<p>Allgemein:</p> <ul style="list-style-type: none"> • Leistungswert $W(S)$ 	<ul style="list-style-type: none"> • Verhaltensmaß von EA (Experimentieren, Akzeptabler Verlust, Flexibilität, Vereinbarungen) und CA bei unerfahrenen Entrepreneuren • Einfluss der Persönlichkeit auf EA- und CA-Verhalten bei unerfahrenen Entrepreneuren 	<p>Allgemein:</p> <ul style="list-style-type: none"> • Verhaltensmaß von EA (Experimentieren, Akzeptabler Verlust, Flexibilität, Vereinbarungen) und CA bei unerfahrenen Entrepreneuren • Einfluss der Persönlichkeit auf EA- und CA-Verhalten bei unerfahrenen Entrepreneuren
<p>Allgemein:</p> <ul style="list-style-type: none"> • Leistungswert $W(S)$ 	<ul style="list-style-type: none"> • Verhaltensmaß von EA (Experimentieren, Akzeptabler Verlust, Flexibilität, Vereinbarungen) und CA bei unerfahrenen Entrepreneuren • Einfluss der Persönlichkeit auf EA- und CA-Verhalten bei unerfahrenen Entrepreneuren 	<p>Allgemein:</p> <ul style="list-style-type: none"> • Leistungswert $W(S)$
<p>Allgemein:</p> <ul style="list-style-type: none"> • Leistungswert $W(S)$ 	<ul style="list-style-type: none"> • Verhaltensmaß von EA (Experimentieren, Akzeptabler Verlust, Flexibilität, Vereinbarungen) und CA bei unerfahrenen Entrepreneuren • Einfluss der Persönlichkeit auf EA- und CA-Verhalten bei unerfahrenen Entrepreneuren 	<p>Allgemein:</p> <ul style="list-style-type: none"> • Leistungswert $W(S)$

(Fortsetzung)

Tab. 3.1 (Fortsetzung)

Ergebnisse	
<p>Informationsisotropie</p> <ul style="list-style-type: none"> • Gleiche Leistungsfähigkeit von CA und EA bei maximaler Marktkonzentration c • Bessere Leistungsfähigkeit von CA bei Ungleichverteilung der k Ausprägungen über die Marktnachfrage bei geringem Grad von Ungewissheit • Verringerung des Abstandes zwischen größtem und mittlerem Marktsegment bei Vergrößerung der Produktdiversität k und konstanter Dominanz der Marktnachfrage bei $d = 1,5$ 	<p>Ungewissheits- und Risikokontext</p> <ul style="list-style-type: none"> • EA ist überwiegend leistungsfähiger als CA in Ungewissheits- und Risikokontexten • EA ist überwiegend leistungsfähiger als CA im Kontext der Fähigkeit Vorhersagen zu treffen <p>Vorhersagefähigkeit</p> <ul style="list-style-type: none"> • CA ist leistungsfähiger als EA, erst bei Vorhersagegenauigkeit $\lambda > 0,75$ • CA ist leistungsfähiger als EA, bei geringer Vorhersagegenauigkeit und großer Ungewissheit ($\tau = 1$)
<p>Umgebungsbedingte Unvorhersagbarkeit (Ungewissheit)</p> <ul style="list-style-type: none"> • Höhere Leistungsfähigkeit von CA bei geringer Abweichung der veränderten Marktnachfrage vom ursprünglich größten Nachfragesegment • Bessere Leistungsfähigkeit von EA bei steigender Abweichung der veränderten Marktnachfrage vom ursprünglich größten Nachfragesegment bei Produktdiversität $k = 2$ und $k = 4$ • Mit steigender Abweichung der veränderten Marktnachfrage vom ursprünglich größten Nachfragesegment sinkt die Leistungsfähigkeit von CA und EA tendenziell, bei CA stärker, als bei EA 	<p>Entscheidungskomplexität</p> <ul style="list-style-type: none"> • Leistungsfähigkeit von EA wird von Entscheidungskomplexität K beeinflusst • CA wird von Entscheidungskomplexität K nicht signifikant beeinflusst <p>Schocks in die Landschaft</p> <ul style="list-style-type: none"> • Kein Effekt, bei Variation der zeitlichen Schock-Abstände EA und CA Operationalisierung
<p>Zielambiguität</p> <ul style="list-style-type: none"> • EA weisen höhere Leistungsfähigkeit bei dynamischer Nachfrageänderung und höherer Zielambiguität ($m < 2$) auf • Negativer Anstieg der Leistungsfähigkeit von CA steigt mit größer werdender Zielambiguität • Stabile Leistungsfähigkeit von EA bei geringer bis moderater Zielambiguität ($0 < m < 3$), die linear fällt 	<p>Verhalten</p> <ul style="list-style-type: none"> • Akzeptabler Verlust ist in sicheren Umgebungen stärker ausgeprägt als in unsicheren Umgebungen (EA) • Flexibles Verhalten ist in sicheren Umgebungen stärker ausgeprägt als in unsicheren Umgebungen (EA) • Experimentierverhalten ist in sicheren Umgebungen stärker ausgeprägt als in unsicheren Umgebungen (EA) • Kausales Verhalten ist i.d.R. in sicheren Umgebungen stärker ausgeprägt als in unsicheren Umgebungen • Kausales Verhalten ist in unsicheren Umgebungen stärker als in sicheren Umgebungen ausgeprägt hinsichtlich der durchschnittlichen Änderungen der Produktpalette und gewählten Marketing-Kampagne <p>Einfluss der Persönlichkeit auf EA und CA</p> <ul style="list-style-type: none"> • Aktivität-Facetten hat in sicheren Umgebungen einen starken Einfluss auf experimentelles Verhalten (EA) • Risikofreudigkeit hat einen negativen Einfluss auf verlustakzeptables Verhalten (EA) in sicherer Umgebung • Handlungs- und Aktivität-Facetten haben keinen positiven Einfluss auf flexibles Verhalten (EA) • Positiver Einfluss der Geselligkeit auf kooperatives Verhalten (EA) in einer sicheren Umgebung • Vertrauens-Pacette hat keinen positiven Einfluss auf kooperatives Verhalten (EA) • Besonnenheit und Ordnung haben einen positiven Einfluss in unsicheren Umgebungen auf kausales Verhalten (CA)

- Beeinflussende Modellparameter
- Modell-Ausgangsgrößen
- Modellmechanismen
- Ergebnisse der Simulation bzw. Befragung
- Implementierungsform

In Tabelle 3.1 sind die gegenübergestellten Kriterien aufgeführt.

Neben dem Vergleich der unterschiedlichen Simulationsmodelle werden in den Abschnitten 3.2.1 und 3.2.2 die Modelle von Mauer et al. (2017) und Welter und Kim (2018) zunächst im Rahmen der von Sargent (2013) vorgeschlagenen Augenscheinvalidität überprüft. Im Zuge dessen werden die bestehenden Modellierungsentwürfe und Ergebnispräsentationen kritisch diskutiert.

Des Weiteren werden die Modelle einer internen Validierung unterzogen. Mit Hilfe der replizierten Implementierungen werden die Simulationsabläufe nachgebildet und können anschließend mehrfach wiederholt werden. Dies entspricht der Anwendung der Simulation als Experimentierwerkzeug und erlaubt die Untersuchung realweltlicher Phänomene unter kontrollierten Bedingungen (Peck, 2004).

Die aus den Simulationen gewonnenen Ergebnisse können anschließend durch die Erstellung von Grafiken visualisiert werden. Dies erlaubt den Vergleich von Erkenntnissen, die einerseits aus der originären Simulation gewonnen wurden und andererseits aus einer Replizierung resultieren.

3.2 Verifikation und Validierung der bestehenden effektuativen Simulationsmodelle

Um die Ergebnisse von Mauer et al. (2017) und Welter und Kim (2018) nachzuvollziehen, wird im Folgenden der Ansatz der Replikation der Simulationsmodelle nach Gulyás und Kampis (2015) angewendet. Während bei der Verifikation bereits implementierte Simulationsmodelle mit einer im Vorfeld vom Modellierer definierten Spezifikation verglichen werden, werden bei der Replikation die Ergebnisse einer bereits bestehenden Implementierung mit den Ergebnissen einer reproduzierten Implementierung desselben Modells verglichen. Diese Form des Vergleichs wird im Kontext dieser Arbeit verwendet, da Implementierungsdetails, insbesondere in den Arbeiten von Mauer et al. (2017) und Welter und Kim (2018), nicht näher beschrieben werden.

Die vorhandenen Modelle von Mauer et al. (2017) und Welter und Kim (2018) wurden mit der Programmiersprache Python implementiert. Python bietet durch seine einfache Syntax die Möglichkeit gut lesbaren Programmiercode zu erstellen.

Zudem können durch das Einbinden weiterer Bibliotheken zusätzliche Funktionalitäten genutzt werden, die vor allem im Bereich der wissenschaftlichen Programmierung Vorteile bringen (Oliphant, 2007). Im Rahmen der reproduzierten Implementierung wurden diesbezüglich die Programmbibliotheken *numpy*, *pandas*, *matplotlib* und weitere Standard-Python-Bibliotheken genutzt. Die konkreten Implementierungen der Modelle von Mauer et al. (2017) und Welter und Kim (2018) sind in Anhang B.1 und B.2 im elektronischen Zusatzmaterial zu finden.

Das von Eberz (2018) interaktive Simulationsmodell wurde nicht als eigene Implementierung reproduziert. Die teils unzureichenden Beschreibungen der Simulationsroutinen, die für eine Replikation jedoch notwendig sind, und die Einbeziehung von Versuchsteilnehmern, deren zugrundeliegende Merkmalsstruktur in der Nachbildung der Simulation berücksichtigt werden müsste, rechtfertigen den zusätzlichen Erkenntnisgewinn aus forschungsökonomischen Gründen nicht.

Für die implementierten Replikationen wurden dieselben Parameterwerte verwendet, die in Mauer et al. (2017) und Welter und Kim (2018) genannt werden und die daraus resultierenden Ergebnisse mit den Ergebnissen der genannten Autoren verglichen.

3.2.1 Kritische Evaluierung des Simulationsmodells von Mauer et al. (2017)

Im Fall von Mauer et al. (2017) wurden im Zuge der kritischen Evaluierung die folgenden Parameter in die Untersuchung einbezogen:

- Anzahl der Artefakt-Vektorkomponenten (n)
- Anzahl der flexiblen Artefakt-Vektorkomponenten (m)
- Anzahl der möglichen Ausprägungen pro Artefakt-Vektorkomponente
- Anzahl der vorhersagebasierten Agenten
- Anzahl der steuerungs-basierten Agenten
- Anzahl der Konsumenten-Agenten
- Nachfragekonzentration (c)

Ergänzend wurden zur Realisierung der Implementierung und der damit einhergehenden Untersuchung des Simulationsmodells die Anzahl der Konsumenten-Agenten, die vorhersagebasierte Agenten zur Abschätzung der gesamten Nachfrage betrachten, sowie die Anzahl der Simulationsdurchläufe definiert.

Vor Ausführung der reproduzierten Implementierung wurden die Parameter mit den in Mauer et al. (2017) genannten Werten initialisiert. Zur Untersuchung des

Einfluss der Änderung der Nachfragekonzentration c auf den mittleren Market-Fit werden initial die Parameterwerte

$$\begin{aligned}n &= 5 \\m &= 3 \\k &= 2 \\c &= 0.5\end{aligned}$$

verwendet. Die Anzahl der vorhersagebasierten und steuerungsbasierten Agenten wird jeweils auf den Wert 20 gesetzt. Die Anzahl der Konsumenten-Agenten wird auf den Wert 60 festgelegt. Die Anzahl der Simulationsdurchläufe beträgt im allgemeinen Fall 170. Zusätzlich wurde die Anzahl der Konsumenten-Agenten, die zur Abschätzung der Nachfrage notwendig sind, mit dem Wert 10 initialisiert. Dieser Parameter wurde in Mauer et al. (2017) nicht explizit aufgeführt, ist jedoch für die Durchführung der replizierten Simulation von Bedeutung.


Die Nachfragekonzentration c , deren inhaltliche Erläuterung in Abschnitt 3.1.1 zu finden ist, wurde mit dem Wert 0.5 initialisiert. Für den Fall, dass es zwei Merkmalsausprägungen ($k = 2$) gibt, treten demnach beide Ausprägungen über alle Komponenten aller Nachfragevektoren gleich häufig auf.

Zum Vergleich der Simulationsergebnisse wurden die folgenden Aspekte des entrepreneurialen Problemraums und die damit in Verbindung stehenden Parameteränderungen untersucht:


- Isotropie → Auswirkungen der Änderung der Nachfragekonzentration c während der Fertigstellung der Produkt-Artefakte durch die Anbieter-Agenten und der Produktdiversität k auf den mittleren Market-Fit
- Unvorhersagbarkeit → Auswirkungen der Änderung der Nachfragekonzentration c nach Fertigstellung der Produkt-Artefakte durch die Anbieter-Agenten auf den mittleren Market-Fit
- Ziel-Ambiguität → Auswirkungen der Änderung der flexiblen Artefakt-Vektorkomponenten m und Nachfragekonzentration c auf den mittleren Market-Fit

Auswirkungen bei Änderung der Isotropie

Die Abbildungen 3.4 und 3.5 stellen das Verhalten der vorhersage- und steuerungsbasierten Agenten bei sich ändernder Isotropie dar. Abbildung 3.4 zeigt die Änderung der Nachfragekonzentration c einer zufällig gewählten



(a) Simulationsergebnisse nach Mauer et al. (2017)




(b) Simulationsergebnisse der replizierten Implementierung

Abb. 3.4 Vergleich der Simulationsergebnisse bei Änderung der Isotropie (Nachfragekonzentration c während der Artefakt-Erstellung)


Merkmalsausprägung bei $k = 2$ und ihre Auswirkungen auf den mittleren Market-Fit während des Produkt-Artefakt-Erstellungsprozesses. Die Nachfragekonzentration ist zunächst gleichverteilt über $k = 2$ Merkmalsausprägungen und ändert sich hin zu einer einseitigen Marktkonzentration der zufällig ausgewählten Merkmalsausprägung, so dass diese von allen Nachfrage-Agenten präferiert wird. Abbildung 3.4a zeigt in diesem Zusammenhang die Simulationsergebnisse von Mauer et al. (2017). Dabei sinkt der mittlere Market-Fit der vorhersage- und steuerungs-basierten Agenten mit steigender Nachfragekonzentration und damit sinkender Isotropie. Dem Ansatz von Gulyás und Kampis (2015) folgend, erlaubt die Validierung der Ergebnisse gegen das realweltliche Phänomen keinen logischen Schluss, da – mit eindeutiger Präferenz der Nachfrager hinsichtlich einer Merkmalsausprägung – die Anbieter mit sinkender Isotropie den Markt während der Produkt-Artefakt-Erstellung schlechter einschätzen und somit einen niedrigeren Market-Fit erzielen. Die Ergebnisse der replizierten Implementierung zeigen im Gegensatz dazu in 3.4b, dass der mittlere Market-Fit beider Anbieter-Agenten-Typen mit sinkender Isotropie und damit steigender Nachfragekonzentration ebenfalls steigt.

In beiden Fällen wird deutlich, dass der steuerungs-basierte Anbieter-Agent während der Änderung der Nachfragekonzentration einen niedrigeren mittleren Market-Fit erzielt, als der vorhersage-basierte Anbieter-Agent, sofern $c < 1$.

Zur weiteren Untersuchung des Verhaltens der vorhersage- bzw. steuerungs-basierten Agenten bei Änderung der Isotropie wurde ebenfalls eine Variierung der Anzahl der Merkmalsausprägungen k vorgenommen. Dabei wird $k = 2, \dots, 6$



(a) Simulationsergebnisse nach Mauer et al. (2017)



(b) Simulationsergebnisse der replizierten Implementierung

Abb. 3.5 Vergleich der Simulationsergebnisse bei Änderung der Isotropie (Anzahl der Merkmalsausprägungen k)

gewählt und die Auswirkungen des Vorgehens der Anbieter-Agenten auf den mittleren Market-Fit beobachtet.

Der Dominanzwert d wurde über die Variierung der Anzahl der Merkmalsausprägungen mit dem Wert 1.5 konstant gehalten. Hieraus ergibt sich, dass eine zufällig gewählte Merkmalsausprägung mit der Wahrscheinlichkeit $c = \frac{d}{k}$ auftritt. Die verbleibenden $k - 1$ Merkmalsausprägungen treten folglich jeweils mit der Wahrscheinlichkeit $\frac{1-c}{k-1}$ auf.

Abbildung 3.5 zeigt die Ergebnisse der Simulation von Mauer et al. (2017) und der replizierten Implementierung. In beiden Fällen nimmt der mittlere Market-Fit der vorhersage- und steuerungs-basierten Agenten mit zunehmender Produkt-Diversität k ab. Demnach wirkt sich eine Zunahme der Isotropie negativ auf den Market-Fit aus. Weiterhin wird deutlich, dass der steuerungs-basierte Anbieter-Agent in jedem Fall einen geringeren mittleren Market-Fit erzielt. Dieses Verhalten ist sowohl in den Simulationsergebnissen von Mauer et al. (2017) und der replizierten Implementierung zu beobachten.

Auswirkungen bei Änderung der Unvorhersagbarkeit

Um die Auswirkungen der Änderung der Unvorhersagbarkeit auf den erzielten Market-Fit zu untersuchen, wurde erneut die Nachfragekonzentration c variiert, allerdings erst nach Fertigstellung der Produkt-Artefakte durch die Anbieter-Agenten. Die vorhersage- und steuerungs-basierten Agenten reagieren demnach nicht mehr unmittelbar auf einen sich ändernden Markt, sobald der Produkt-Erstellungsprozess abgeschlossen ist.

Die Abbildungen 3.6 und 3.7 zeigen die Simulationsergebnisse von Mauer et al. (2017) und der replizierten Implementierung im Kontext einer variierenden Unvorhersagbarkeit bei einer Produktdiversität von $k = 2$ und einer Start-Wahrscheinlichkeit für das Auftreten einer zufällig gewählten Merkmalsausprägung von $c = 0.2$ der Konsumenten-Agenten. Für die replizierte Implementierung wurde eine andere Skalierung für die Werte von c gewählt als in Mauer et al. (2017) und ist in den Abbildungen 3.6, 3.7a und 3.7b ersichtlich. Dies hat keinen Einfluss auf die Ergebnisse der Simulationen. Die veränderte Skalierung ist jedoch aufgrund einer besseren Nachvollziehbarkeit im Kontext der replizierten Implementierung besser geeignet.

Ein Vergleich der Ergebnisse der Implementierungen zeigt, dass die Anbieter-Agenten mit zunehmender Verschiebung der Nachfragekonzentration c nach Fertigstellung der Produkt-Artefakte einen geringeren mittleren Market-Fit erzielen. Demnach wirkt sich eine Zunahme der Unvorhersagbarkeit über die künftige Nachfrage negativ auf die Leistungsfähigkeit der Anbieter-Agenten aus. Die Leistungsfähigkeit der steuerungsbasierten Agenten nimmt im Vergleich zu den vorhersagebasierten Agenten mit zunehmender Verschiebung der Nachfragekonzentration c allerdings schwächer ab. Ab einer Marktkonzentration $c > 0.5$ erzielt der steuerungsbasierte Anbieter-Agent in jedem Fall einen größeren mittleren Market-Fit als der vorhersagebasierte Anbieter-Agent.

Die Ergebnisse der replizierten Implementierung weisen nicht das volatile Verhalten des steuerungsbasierten Agenten auf wie das in den Simulationsergebnissen von Mauer et al. (2017) zu beobachtende. Die Simulation der replizierten Implementierung wurde, um das Verhalten nachvollziehen zu können, im Standardfall mit 170 (Abbildung 3.7b) und 50 Durchläufen (3.7a) ausgeführt. In beiden Fällen folgt der






Abb. 3.6 Simulationsergebnisse nach Mauer et al. (2017) bei Änderung der Ungewissheit (Nachfragekonzentration c nach der Artefakt-Erstellung)



(a) Simulationsergebnisse bei 50 Simulationsdurchläufen



(b) Simulationsergebnisse bei 170 Simulationsdurchläufen

Abb. 3.7 Simulationsergebnisse der replizierten Implementierung bei Änderung der Ungewissheit (Nachfragekonzentration c nach der Artefakt-Erstellung)

Kurvenverlauf demselben Trend. Das Schwankungsverhalten konnte jedoch nicht reproduziert werden. Der in Abbildung 3.6 exakt lineare Zusammenhang zwischen Änderung der Nachfragekonzentration c und dem mittleren Market-Fit der vorhergesagtebasierten Agenten konnte mit der von Mauer et al. (2017) beschriebenen Anzahl an Simulationsdurchläufen (50–170) ebenfalls nicht repliziert werden. Allerdings lässt sich beobachten, dass die Verläufe sich trendmäßig gleich verhalten.

Auswirkungen bei Änderung der Ziel-Ambiguität

Die Auswirkungen einer unterschiedlich stark ausgeprägten Ziel-Ambiguität wurden mit Hilfe der Änderung des Parameters m modelliert, der die Anzahl der flexiblen Komponenten in den Produkt-Artefakt-Vektoren widerspiegelt. Hierbei wurde der Parameter m von 0 bis 4 variiert und die Auswirkungen der Änderung der Nachfragekonzentration c auf den mittleren Market-Fit für die vorhergesagte- und steuerungsbasierten Agenten bei $k = 2$ untersucht.

Die Ergebnisse der von Mauer et al. (2017) durchgeführten Simulation und der replizierten Implementierung sind in den Abbildungen 3.8, 3.9 und 3.10 zu sehen. Erneut wird ersichtlich, dass mit zunehmender Änderung der Nachfragekonzentration c einer zufällig gewählten Merkmalsausprägung der erzielte mittlere Market-Fit der Anbieter-Agenten sinkt. Die steuerungsbasierten Agenten weisen im Fall von Mauer et al. (2017) bei einer hohen bis moderaten Zielspezifizierung von $0 < m < 3$ eine ähnliche Leistungsfähigkeit auf (Abbildung 3.8). Bei einer geringen Zielspezifizierung von $m \geq 3$ ist die Leistungsfähigkeit der steuerungsbasierten Agenten, im Vergleich zu einer hohen bis moderaten Zielspezifizierung, tendenziell schlechter.


Die abweichende Leistungsfähigkeit der steuerungs-basierten Agenten bei $m \geq 3$ konnte mit Hilfe der replizierten Implementierung bei 170 (Abbildung 3.10) bzw. 50 Simulationsdurchläufen (Abbildung 3.9) nicht reproduziert werden.

Bei den vorhersagebasierten Agenten zeigt sich bei Variation des Grades der Zielspezifizierung und Änderung der Nachfragekonzentration c ein ähnliches Verhalten (vgl. Abbildung 3.8, 3.9 und 3.10). Mit steigender Nachfragekonzentration c wird für $0 \leq m < 5$ ein niedrigerer Market-Fit erreicht. Mit zunehmender Ziel-Ambiguität fällt jedoch mit steigender Nachfragekonzentration c die Leistungsfähigkeit stärker ab. Die Simulationsergebnisse in Abbildung 3.8, 3.9 und 3.10 weisen darauf hin, dass bei einer geringen Nachfragekonzentration c der zufällig gewählten Merkmalsausprägung für größer werdenden Parameter m eine höhere Leistungsfähigkeit zu beobachten ist. Bei einer maximalen Nachfragekonzentration c zeigt sich das gegenteilige Verhalten, sodass mit größer werdender Ziel-Ambiguität m die Leistungsfähigkeit, in Form des mittleren Market-Fits, geringer wird.


Im Gegensatz zu den Simulationsergebnissen von Mauer et al. (2017) in Abbildung 3.8 konnte in den Ergebnissen der replizierten Implementierung der exakt lineare Zusammenhang mit 50 (Abbildung 3.9) bzw. 170 Durchläufen (Abbildung 3.10) nicht reproduziert werden.

Diskussion der Simulationsergebnisse

Grundsätzlich weisen die Ergebnisse von Mauer et al. (2017) und der Replikation in den untersuchten Kontexten Isotropie, Unvorhersagbarkeit und Ziel-Ambiguität



(a) Simulationsergebnisse des effektuativen Agenten nach Mauer et al. (2017) bei Änderung der Ziel-Ambiguität



(b) Simulationsergebnisse des kausalen Agenten nach Mauer et al. (2017) bei Änderung der Ziel-Ambiguität

Abb. 3.8 Simulationsergebnisse nach Mauer et al. (2017) bei Änderung der Ziel-Ambiguität (Anzahl der flexiblen Komponenten m und Nachfragekonzentration c)




Abb. 3.9 Simulationsergebnisse der replizierten Implementierung bei Änderung der Ziel-Ambiguität (Anzahl der flexiblen Komponenten m und Nachfragekonzentration c) und 50 Simulationsthroughläufen

das trendmäßig gleiche Verhalten auf. Lediglich der Vergleich der Leistungswerte bei Änderung der Nachfragekonzentration während der Artefakt-Erstellung zeigt einen spiegelbildlichen Verlauf (siehe Abbildung 3.4).

Da Mauer et al. (2017, S. 253) zu dem Schluss kommen, dass, wenn „[...] many people constantly want the same thing, prediction might be a valuable tool to reach fit with market demand“, ist davon auszugehen, dass die Darstellung der Achsenskalierung in Abbildung 3.4a fehlerhaft ist. Verbal beschreiben Mauer et al. (2017) in ihrer Ergebnisdiskussion dasselbe Verhalten, welches sich in den Simulationsergebnissen der replizierten Implementierung in Abbildung 3.4b wiederfindet. Präferieren Konsumenten demnach ein spezielles Produktmerkmal im Vergleich zu anderen Ausprägungen stärker, können vorhersagebasierte Strategien erfolgsversprechender sein.

Weist die Umgebung eines Entrepreneurs einen hohen Grad an Unvorhersagbarkeit auf und ist die konkrete Ausgestaltung von Produktmerkmalen noch nicht vollständig spezifiziert, bietet sich die Anwendung steuerungsbasierter Strategien

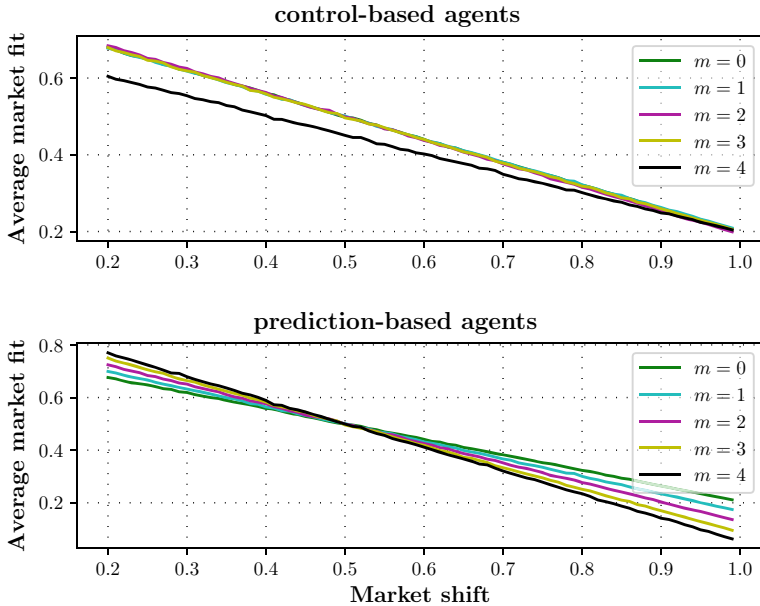


Abb. 3.10 Simulationsergebnisse der replizierten Implementierung bei Änderung der Ziel-Ambiguität (Anzahl der flexiblen Komponenten m und Nachfragekonzentration c) und 170 Simulationdurchläufen

an. Je höher die Dynamik des und je ungewisser das Umfeld eines Entrepreneurs ist, desto sinnvoller ist ein steuerungsbasiertes Vorgehen. Diese Schlussfolgerungen lassen sich aus den Ergebnissen von Mauer et al. (2017) wie auch aus den replizierten Simulationsergebnissen ableiten.

3.2.2 Kritische Evaluierung des Simulationsmodells von Welter und Kim (2018)

Zur Nachvollziehbarkeit der Ergebnisse von Welter und Kim (2018) wurden die folgenden Parameter in der replizierten Implementierung (vgl. Anhang B.2 im elektronischen Zusatzmaterial) verwendet:

- Anzahl der Entscheidungen innerhalb einer Entscheidungskonfiguration (N)
- Anzahl der in Verbindung stehenden Entscheidungen (K)
- Anzahl der gesamten Simulationszeitschritte (T)
- Periodenlänge, nach der die NK-Landschaft mittels τ einen Schock erfährt (T_S)
- Grad der Ungewissheit (τ)
- Anzahl der Entscheidungen einer Entscheidungskonfiguration, die während des Suchprozesses fix sind (ϱ)
- Wahrscheinlichkeit, mit der jede der ϱ Entscheidungen den korrespondierenden Entscheidungen des globalen Maximums entsprechen (λ)

Ergänzend wurden zur Realisierung der Implementierung und der damit einhergehenden Untersuchung des Simulationsmodells die Anzahl der möglichen Ausprägungen einer Entscheidung (Q) und die Anzahl der Simulationsdurchläufe definiert.

Vor der Ausführung der reproduzierten Implementierung wurden die Parameter mit den in Welter und Kim (2018) vorgestellten Werten initialisiert. Zur Untersuchung des Einflusses der Änderung der Wahrscheinlichkeit λ und des Grades der Ungewissheit τ auf die mittlere Leistungsfähigkeit von Unternehmen bei unterschiedlichem ϱ wurden die Parameterwerte

$$\begin{array}{ll}
 N = 10 & \tau \in \{0, 0.1, \dots, 0.9, 1\} \\
 K = 8 & \varrho = 2 \text{ (Effectuation) bzw. } \varrho = 8 \text{ (Causation)} \\
 T = 200 & \lambda \in \{0, 0.1, \dots, 0.9, 1\} \\
 T_S = 10 & Q = 2
 \end{array}$$

verwendet. Die Anzahl der Simulationsdurchläufe wurde auf 300 festgelegt³.

Der Vergleich der Ergebnisse der effektuativen und kausal handelnden Unternehmen findet im Kontext unterschiedlicher Ausprägungen von Risiko bzw. Ungewissheit und der Fähigkeit Vorhersagen zur Leistungsfähigkeit zu treffen statt. Diese werden mittels der Parameter τ und λ modelliert:

Risiko bzw. Ungewissheit \rightarrow Auswirkungen der Änderung von τ auf die mittlere Leistungsfähigkeit eines Unternehmens. Je kleinere

³ Welter und Kim (2018) verwenden für ihre Simulationszwecke 25.000 Simulationsdurchläufe. Da ein Vergleich der Ergebnisse von Welter und Kim (2018) und der replizierten Implementierung lediglich auf visueller Ebene erfolgt, werden die Genauigkeitsverluste durch die geringere Anzahl an Simulationsdurchläufen im replizierten Simulationsmodell in der vorliegenden Betrachtung akzeptiert.

Werte τ annimmt, desto eher befindet sich das Unternehmen in einem von Risiko geprägten Umfeld. Je größere Werte τ annimmt, desto eher ist die Umgebung des Unternehmens von Ungewissheit geprägt.

Vorhersagefähigkeit \rightarrow Auswirkungen der Änderung von λ auf die mittlere Leistungsfähigkeit des Unternehmens. Mit wachsendem λ steigt die Wahrscheinlichkeit des Unternehmens ϱ optimale Entscheidungen, und damit den besten Leistungswert in der NK-Landschaft, vorauszusagen.

Auswirkungen bei Änderung des Grades der Ungewissheit und der Vorhersagefähigkeit

Die in den Konturdiagrammen 3.11a und 3.11b dargestellten Ergebnisse zeigen die ermittelten mittleren Leistungswerte bei Variation der Parameter τ und λ für $\varrho = 2$ und $\varrho = 8$ von Welter und Kim (2018). Während dunklere Rottöne vergleichsweise niedrige Leistungswerte repräsentieren, beschreiben hellere Rottöne vergleichsweise hohe Leistungswerte.




Abb. 3.11 Simulationsergebnisse nach Welter und Kim (2018) bei Änderung des Grades der Ungewissheit (τ) und der Vorhersagefähigkeit (λ)


Im effektuativen Fall (vgl. Abbildung 3.11a) sind in Kontexten, die nahezu ausschließlich von Ungewissheit bzw. nahezu ausschließlich von Risiko geprägt sind, höhere Leistungswerte zu beobachten als in Bereichen, die eine Mischform von Ungewissheit und Risiko darstellen.

Bei kausal modelliertem Verhalten (vgl. Abbildung 3.11b) sind für große Werte von λ über das gesamte Kontinuum von Ungewissheit bis Risiko im Mittel höhere

Leistungswerte zu verzeichnen als bei kleinen Werten von λ . Mit wachsender Akkuratess der Vorhersage der optimalen Entscheidungskonfiguration des Unternehmens werden demzufolge höhere Leistungswerte erzielt.

Aufgrund dessen, dass im effektuativen Fall (vgl. Abbildung 3.11a) ein größerer Anteil an Fläche mit helleren Rottönen als im kausalen Fall (vgl. Abbildung 3.11b) zu beobachten ist, ist darauf zu schließen, dass das effektuativ handelnde Unternehmen im Mittel über alle Parameterkonfigurationen von τ und λ einen höheren Leistungswert erreicht als das kausal handelnde Unternehmen.

Um die Ergebnisse von Welter und Kim (2018) nachzuvollziehen, wurden ebenfalls über die Parameterkonfigurationen von τ und λ mit Hilfe der replizierten Implementierung, wie sie in Anhang B.2 im elektronischen Zusatzmaterial zu finden ist, simuliert. Die resultierenden Konturdiagramme werden in 3.12a und 3.12b dargestellt.




(a) Simulationsergebnisse der replizierten Implementierung für $\varrho = 2$

(b) Simulationsergebnisse der replizierten Implementierung für $\varrho = 8$


Abb. 3.12 Simulationsergebnisse der replizierten Implementierung bei Änderung des Grades der Ungewissheit (τ) und der Vorhersagefähigkeit (λ)

In extremen Bereichen nahe $\tau = 0$ und $\tau = 1$ treten bei variierendem λ im effektuativen Fall der replizierten Simulationsergebnisse vergleichsweise hohe Leistungswerte auf (vgl. Abbildung 3.12a). Dies deckt sich mit dem Verhalten der Simulationsergebnisse von Welter und Kim (2018). Unterschiede zeigen sich jedoch in der Konzentration der vergleichsweise hohen Leistungswerte. Die replizierten Simulationsergebnisse sind für den Fall, dass $\varrho = 2$, annähernd symmetrisch um den Wert $\tau = 0.5$ verteilt. In den Ergebnissen von Welter und Kim (2018) hingegen zeigt sich, dass der Bereich mit vergleichsweise hohen Leistungswerten für große Werte von τ größer als für kleine Werte von τ – und damit nicht symmetrisch – ist.

Weiterhin reichen die Leistungswerte von Welter und Kim (2018) gemäß der in der Abbildung 3.11b dargestellten Skala von 0.5 bis 0.8, wobei aufgrund der Wahl des Farbschemas nicht eindeutig festgestellt werden kann, ob diese Werte vom effektuativen Agenten tatsächlich erreicht wurden. Erst Abbildung 3.13a gibt Aufschluss darüber, welche Leistungswerte tatsächlich erreicht werden. Demnach werden Werte von größer als 0.5 bis 0.8 erreicht.



(a) Simulationsergebnisse nach Welter und Kim (2018) für $\tau = 0$



(b) Simulationsergebnisse nach Welter und Kim (2018) für $\tau = 1$

Abb. 3.13 Simulationsergebnisse nach Welter und Kim (2018) bei Änderung der Vorhersagefähigkeit (λ)

Im Vergleich dazu befinden sich die Leistungswerte in der replizierten Simulation für $\varrho = 2$ in einem kleineren Intervall, das von 0.608 bis 0.672 reicht. Für den kausal modellierten Fall der replizierten Implementierung ($\varrho = 8$) werden Leistungswerte von 0.6 bis 0.76 beobachtet. Erneut sind die Leistungswerte annähernd symmetrisch um den Parameterwert $\tau = 0.5$ verteilt. Für den Fall, dass $\lambda < 0.5$ ist, treten, wie bei $\varrho = 2$, in den Extrembereichen nahe $\tau = 0$ und $\tau = 1$, vergleichsweise höhere Leistungswerte auf. Dieses Verhalten unterscheidet sich von den Ergebnissen von Welter und Kim (2018) in Abbildung 3.12b. Dort sind für Werte von $\lambda < 0.5$ lediglich in sehr ungewissen Kontexten (nahe $\tau = 1$) vergleichsweise höhere Leistungswerte zu beobachten. Tendenziell steigen die Leistungswerte der replizierten Simulation mit wachsendem λ . Die Simulationsergebnisse von Welter und Kim (2018) zeigen ebenfalls ein Ansteigen der Leistungswerte für größer werdendes λ . Diese konzentrieren sich für große Werte von λ allerdings überwiegend im Bereich großer Werte von τ .

Auswirkungen bei Änderung der Vorhersagefähigkeit

Der Einfluss der Vorhersagefähigkeit λ auf die Leistungsfähigkeit effektuativer ($\varrho = 2$) und kausaler ($\varrho = 8$) Unternehmen für den reinen Risiko-Kontext ($\tau = 0$) bzw. Kontext der Ungewissheit nach Welter und Kim (2018) ist in den Abbildungen 3.13a bzw. 3.13b ersichtlich. Die Darstellungen sind Spezialfälle von 3.11 für die Extremfälle $\tau = 0$ und $\tau = 1$. Für den Fall, dass $\tau = 0$ ist, zeigt sich, dass effektuativ agierende Unternehmen ($\varrho = 2$) im Mittel höhere Leistungswerte erzielen als kausal handelnde Unternehmen ($\varrho = 8$). Die Leistungswerte bei $\varrho = 2$ fallen mit größer werdenden λ zunächst schwach, bis sie anschließend wieder progressiv wachsen. Die Leistungswerte bei $\varrho = 8$ weisen ein ähnliches Verhalten auf, wobei diese bei großen Werten von λ vergleichsweise schneller progressiv wachsen als die Leistungswerte des effektuativen Unternehmens. Die Leistungswerte bei $\varrho = 8$ sind für Werte von λ nahe 1 größer als bei $\varrho = 2$. Demnach sind kausal agierende Unternehmen in stark risikoorientierten Kontexten erst mit hoher Vorhersagefähigkeit leistungsfähiger als effektuateive Unternehmen.

In sehr ungewissen Kontexten ($\tau = 1$) bleiben die Leistungswerte bei $\varrho = 2$ mit variierendem λ konstant. Während die Leistungswerte für $\varrho = 8$ im Vergleich zu $\varrho = 2$ für Werte von $\lambda < 0.5$ kleiner sind, wachsen diese anschließend mit größer werdendem λ progressiv an. Ab $\lambda > 0.9$ werden mit $\varrho = 8$ in jedem Fall höhere Leistungswerte erzielt als mit $\varrho = 2$. Bei hoher Präzision der Vorhersage von kausal handelnden Unternehmen sind in sehr ungewissen Kontexten ($\tau = 1$) die Leistungswerte des kausal handelnden dem des effektuativ agierenden Unternehmens deutlich überlegen, wenngleich im Falle von Effectuation im Mittel bessere Leistungswerte im Gegensatz zu Causation erzielt werden. Diese Erkenntnis würde dem bisherigen Verständnis zu Effectuation widersprechen, lässt sich jedoch damit begründen, dass „in uncertain environments, causation outperforms effectuation at a lower threshold not because causation is much better in uncertain contexts but because effectuation performs worse in uncertain contexts than in risky ones.“ (Welter & Kim 2018, S. 108). Anders ausgedrückt ermöglicht Effectuation Entrepreneurien durch Experimentierfreudigkeit leistungsfähig zu sein. Kausale Logik hingegen zeigt, wie präzise die Vorhersagefähigkeiten von Entrepreneurien sind. Sind Entrepreneurien in der Lage gute Vorhersagen zu treffen, erzielen sie auch gute Leistungswerte. Fehlt kausal handelnden Entrepreneurien diese Fähigkeit, werden sie wahrscheinlich von effektuativ handelnden Entrepreneurien überboten. Zum Vergleich der Simulationsergebnisse sind in 3.14a und 3.14b die Resultate der korrespondierenden replizierten Implementierung ersichtlich.

In eher risikoreichen Umgebungen ($\tau = 0$) verhalten sich kausal agierende Unternehmen ($\varrho = 8$) in der replizierten Simulation ähnlich wie in den Ergebnissen von Welter und Kim (2018). Ab Werten von $\lambda > 0.5$ steigen die Leistungswerte

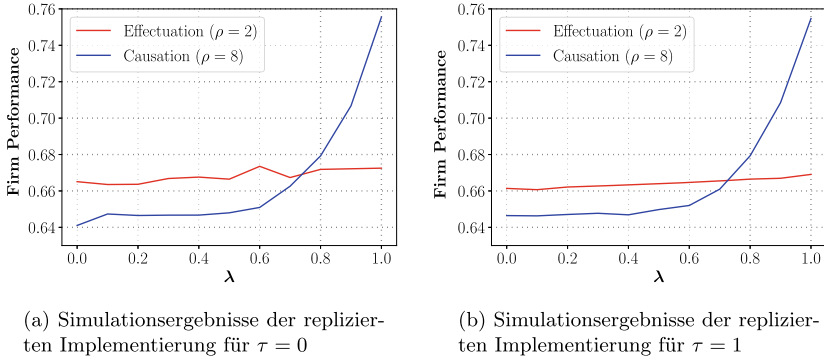
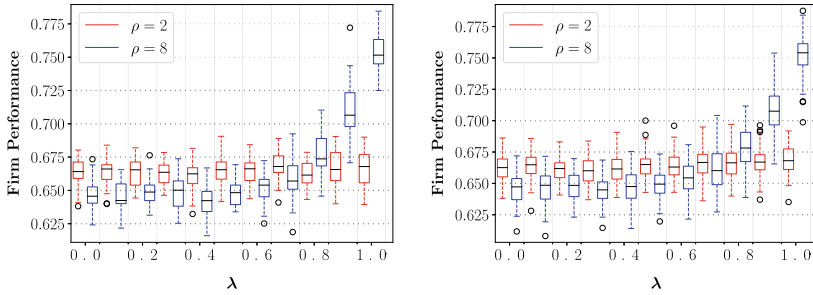


Abb. 3.14 Simulationsergebnisse der replizierten Implementierung bei Änderung der Vorhersagefähigkeit (λ)

progressiv an. Abweichungen ergeben sich jedoch im Spektrum der erreichten Leistungswerte. Während bei Welter und Kim (2018) Werte zwischen nahe unterhalb 0.6 und nahe 0.8 erreicht werden, reichen die Leistungswerte des kausal handelnden Unternehmens der replizierten Simulationsergebnisse lediglich von nahe 0.64 bis nahe 0.76. Die Ergebnisse der replizierten Implementierung des effektuativ agierenden Unternehmens weichen ebenfalls von den Resultaten der Simulation von Welter und Kim (2018) ab. Entsprechend ist bei den replizierten Simulationsergebnissen in risikoreichen Kontexten, anders als bei den Ergebnissen von Welter und Kim (2018), kein progressiver Kurvenverlauf ersichtlich. Effektuative Unternehmen reagieren in ihrer Leistungsfähigkeit folglich nicht signifikant auf einen Anstieg der Vorhersagefähigkeit. Dies wiederum hat zur Folge, dass kausale Unternehmen, im Fall der replizierten Simulation, bereits bei kleineren Werten von λ höhere Leistungswerte erzielen als effektuative Unternehmen im Vergleich zu Welter und Kim (2018). Im Gegensatz zu Welter und Kim (2018) erreicht das kausale Unternehmen der replizierten Simulation bereits bei kleineren Werten von λ größere Leistungswerte als das effektuative Unternehmen.

Die Streuung der Leistungswerte bei Variation von λ kann in Abbildung 3.15 nachvollzogen werden. Im Fall, dass $\rho = 8$ ist, nimmt die Streuung der Leistungswerte mit steigendem λ zu. Die in den Abbildungen abgetragenen Whisker spiegeln den 1.5-fachen Interquartilsabstand wider. Verlängern sich die Whisker, steigt auch die Streuung der Werte. Die in den Boxes zu findenden schwarzen Linien repräsentieren den Median der aus der Simulation für unterschiedliche λ erhaltenen Leistungswerte. Die Boxes selbst geben die Spannweite des oberen und unteren Quartils

an. Schwarze Kreise symbolisieren Ausreißer, die außerhalb des 1.5-fachen Interquartilsabstandes – ausgehend vom unteren bzw. oberen Quartil – gelegen sind.



(a) Streuung der Simulationsergebnisse der replizierten Implementierung für $\tau = 0$

(b) Streuung der Simulationsergebnisse der replizierten Implementierung für $\tau = 1$

Abb. 3.15 Streuung der Simulationsergebnisse der replizierten Implementierung bei Änderung der Vorhersagefähigkeit (λ)


Die Ergebnisse von Welter und Kim (2018) für variierenden Parameter λ und $\tau = 0$ können nicht vollumfänglich reproduziert und bestätigt werden.

Für stark ungewisse Kontexte ($\tau = 1$) weisen effektuativ und kausal handelnde Unternehmen in den Ergebnissen von Welter und Kim (2018) und der replizierten Implementierung ein ähnliches Verhalten auf, wie in den Abbildungen 3.13b und 3.14b ersichtlich ist. Für effektuateive Unternehmen hat die Variation der Vorhersagefähigkeit keinen wesentlichen Einfluss auf die Höhe der Leistungswerte. Lediglich ein leichter Anstieg der Leistungsfähigkeit geht mit wachsendem λ einher. Tendenziell erzielen das effektuateive und kausale Unternehmen im replizierten Fall höhere Leistungswerte als bei Welter und Kim (2018). Für den Fall, dass sich effektuateive und kausale Unternehmen in einer ungewissen Umgebung befinden ($\tau = 1$), kann deren grundsätzliches Verhalten bei variierender Vorhersagefähigkeit bestätigt werden.


Auswirkungen bei Änderung des Grades der Ungewissheit

Der Einfluss von Risiko bzw. Ungewissheit (τ) auf die Leistungsfähigkeit effektuativer ($\rho = 2$) und kausaler ($\rho = 8$) Unternehmen für verschiedene Werte der Vorhersagefähigkeit ($\lambda = 0$, $\lambda = 0.5$ und $\lambda = 1$) ist in Abbildung 3.16 dargestellt.


Es wird deutlich, dass mit variierendem τ für $\varrho = 2$ generell höhere Leistungswerte als bei $\varrho = 8$ erzielt werden, für den Fall, dass $\lambda = 0$ (vgl. 3.16a) und $\lambda = 0.5$ (vgl. 3.16b) ist. Ist $\lambda = 1$ (vgl. 3.16c) werden bei $\varrho = 8$ für alle abgetragenen τ höhere Leistungswerte erreicht, als bei $\varrho = 2$. Es wird zudem deutlich, dass, unabhängig von λ , die Werte bei $\varrho = 2$ und $\varrho = 8$ von $\tau = 0$ zu $\tau = 0.2$ jeweils vergleichsweise stark fallen und für $\tau > 0.2$ wieder wachsen. Effektuativ handelnde Unternehmen erreichen bei schlechter ($\lambda = 0$) und mittlerer ($\lambda = 0.5$) Präzision der Vorhersagefähigkeit von sehr risikoorientierten ($\tau = 0$) bis sehr ungewissen ($\tau = 1$) Kontexten bessere Leistungswerte als kausal agierende Unternehmen. Lediglich bei hoher Präzision der Vorhersagefähigkeit schneiden kausal agierende Unternehmen besser als effektuateive Unternehmen ab.



(a) Simulationsergebnisse nach Welter und Kim (2018) für $\lambda = 0$



(b) Simulationsergebnisse nach Welter und Kim (2018) für $\lambda = 0.5$



(c) Simulationsergebnisse nach Welter und Kim (2018) für $\lambda = 1$

Abb. 3.16 Simulationsergebnisse der replizierten Implementierung bei Änderung der Vorhersagefähigkeit (λ)


Effektuate wie kausale Unternehmen erzielen, unabhängig von ihrer Vorhersagefähigkeit, die höchsten Leistungswerte in sehr risikoorientierten ($\tau = 0$) und sehr ungewissen ($\tau = 1$) Kontexten.

Die Untersuchungsergebnisse der replizierten Simulation bei Variation des Parameters τ zur Steuerung der Ungewissheit bzw. des Risikos unter Beachtung unterschiedlicher Werte für den Vorhersagefähigkeitsparameter λ (0, 0.5, 1) sind in den Abbildungen 3.17a, 3.17b und 3.17c dargestellt. Wie auch bei den Resultaten von Welter und Kim (2018) erzielen effektuate Unternehmen der replizierten Simulation bei $\lambda = 0$ und $\lambda = 0.5$ und variierendem τ in jedem Fall höhere Leistungswerte als kausal agierende Unternehmen; bei hoher Vorhersagefähigkeit ($\lambda = 1$) schneiden kausal handelnde Unternehmen generell besser ab. Deutliche Unterschiede ergeben sich bei Betrachtung des Verlaufs der Leistungswerte mit wachsendem τ . Die Leistung effektuativer und kausaler Unternehmen fällt zunächst mit wachsendem τ und steigt dann wieder wie in 3.17 deutlich wird. Im Falle von Welter und Kim (2018) vollzieht sich der Leistungsabfall bereits zwischen den Werten für τ von 0 und 0.2. Für $\tau = 0$ werden für $q = 2$ und $q = 8$ die höchsten Leistungswerte erzielt (vgl. Abbildung 3.16). Die Ergebnisse der replizierten Implementierung zeigen ein anderes Verhalten. Ein abrupter Leistungsabfall für Werte von τ zwischen 0 und 0.2 lässt sich nicht beobachten. Vielmehr fallen die Leistungswerte bis näherungsweise $\tau = 0.5$ und steigen danach mit derselben Intensität wieder an. Grundsätzlich zeigen die Ergebnisse für effektuate und kausale Unternehmen bei Welter und Kim (2018) und der replizierten Implementierung ein ähnliches Verhalten. Signifikante Unterschiede ergeben sich bei Betrachtung der Differenz von Leistungswerten für aufeinanderfolgende Werte von τ . Kausale und effektuate Agenten der replizierten Simulation reagieren entsprechend weniger sensibel auf Änderung des Risikos bzw. der Ungewissheit als bei Welter und Kim (2018).


Diskussion der Simulationsergebnisse

Grundsätzlich ist festzustellen, dass Effectuation so lange besser als kausale Logik ist, bis ein Entrepreneur leistungsstarke Entscheidungskonfigurationen mit hoher Akkuratessse voraussagen kann. In sehr ungewissen Kontexten erzielen kausal handelnde Entrepreneur mit stark ausgeprägten Vorhersagefähigkeiten bessere Leistungen als effektuativ handelnde Entrepreneur.


Welter und Kim (2018) konstatieren, dass die Leistungsfähigkeit – unabhängig vom verwendeten Vorgehen – am größten ist, wenn die Umgebung nicht von Ungewissheit geprägt ist. Diese Einschätzung kann auf Grundlage der Ergebnisse der replizierten Implementierung nicht bestätigt werden. Die höchsten Leistungswerte werden bei ausschließlich ungewissen und ausschließlich risikoorientierten Umgebungen erreicht. Die Erkenntnis aus den replizierten Simulationsergebnissen,



(a) Simulationsergebnisse der replizierten Implementierung für $\lambda = 0$



(b) Simulationsergebnisse der replizierten Implementierung für $\lambda = 0.5$



(c) Simulationsergebnisse der replizierten Implementierung für $\lambda = 1$

Abb. 3.17 Simulationsergebnisse der replizierten Implementierung bei Änderung der Vorhersagefähigkeit (λ)

dass die Leistungswerte nach der Einführung von Ungewissheit zunächst fallen, um anschließend wieder mit dem annähernd gleichen Anstieg zu steigen, deckt sich mit den Aussagen von Welter und Kim (2018).

3.2.3 Kritische Einordnung der Simulationsansätze

Mit Hilfe der deskriptiven Analyse der effektuativen Simulationsmodelle konnte die Grundlage für die kritische Evaluierung der Ansätze von Mauer et al. (2017) und Welter und Kim (2018) geschaffen werden. Die Überführung der Verfahren in mathematische Modelle folgt den konzeptuellen Validierungsprinzipien von Sargent (2013) und ermöglicht so die notwendige Transparenz für die Interpretation

der Simulationsergebnisse. Die formalisierte Darstellung der Ansätze liefert erste Erkenntnisse darüber, inwieweit effektuatives Entscheidungsverhalten modelliert werden kann.

Aufbauend auf den mathematischen Modellbeschreibungen stellen die Algorithmen 1 und 2 einen weiteren Schritt zur von Schlesinger et al. (1979) geforderten konzeptuellen Modellformalisierung dar. Die Algorithmen dienen als Basis für die Implementierung der Simulationsmodelle, welche wiederum die Voraussetzung für die Erzeugung der replizierten Ergebnisse sind. Durch Vergleich der Simulationsergebnisse wird die Verifikation der Modelle ermöglicht.

Die Ergebnisse von Mauer et al. (2017) und Welter und Kim (2018) sowie der replizierten Simulationen zeigen, dass Effectuation im Gegensatz zur kausalen Strategie in einer vorrangig ungewissen Umgebung effizienter ist. Diese Beobachtungen decken sich mit den bisherigen Erkenntnissen aus der Effectuation-Forschung (Grégoire & Cherchem, 2019; Read, Dew et al., 2009). Die Modellierung von Ungewissheit ist in den in Kapitel 3 vorgestellten Arbeiten zentral. Zur weiteren Untersuchung entrepreneurialen Verhaltens ist die Umgebungsmodellierung von Mauer et al. (2017) und Welter und Kim (2018) durch weitere Merkmale gekennzeichnet.

Tragend für die Simulationsmodelle von Mauer et al. (2017) und Welter und Kim (2018) sind die verschiedenen Kontexte, in denen entrepreneurialen Agenten agieren. Mauer et al. (2017) und Welter und Kim (2018) untersuchen hierbei die Leistungsfähigkeit von effektuativ und kausal handelnden Agenten. Während Mauer et al. (2017) die Leistungsunterschiede im Zusammenhang mit Informationsisotropie, Ziel-Ambiguität und Ungewissheit beleuchten, legen Welter und Kim (2018) den Schwerpunkt auf eine ungewisse bis risikoorientierte Umgebung sowie die Vorhersagefähigkeit der Agenten. Die Analyse der Ansätze in Kapitel 3 gibt Aufschluss darüber, dass effektuatives Entscheidungsverhalten unmittelbar durch die Umgebung, in der sich ein Entrepreneur befindet, beeinflusst wird.

Die Interaktion der Agenten mit der jeweiligen Umgebungssituation basiert auf einem statischen Entscheidungsverhalten. Mauer et al. (2017) präsentieren für effektuativ sowie kausal handelnde Agenten verschiedene Vorgehen. Kausale Agenten passen flexible Produktvektorkomponenten anhand einer Stichprobe der momentanen Nachfrage an. Effektuative Agenten hingegen nehmen diese Anpassung aufgrund der Kommunikation mit dem Partnernetzwerk vor. Welter und Kim (2018) verwenden für kausal wie auch effektuativ handelnde Agenten das Hill-Climb-Verfahren (Csaszar & Siggelkow, 2010; Rivkin, 2000). Dieses Vorgehen ist dadurch gekennzeichnet, dass ein Agent bestrebt ist sein Leistungsniveau bei jeder Entscheidung zu verbessern, auch wenn dies langfristig nicht zwangsläufig zum bestmöglichen Leistungsniveau führt. Bisherige Modellansätze fokussieren demnach nicht auf das Lernverhalten der Agenten.

Open Access Dieses Kapitel wird unter der Creative Commons Namensnennung 4.0 International Lizenz (<http://creativecommons.org/licenses/by/4.0/deed.de>) veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden.

Die in diesem Kapitel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.





Ziel der vorliegenden Arbeit ist es, effektuatives Verhalten algorithmisch zu modellieren und interpretieren. Dadurch sollen zum einen Erkenntnisse darüber gewonnen werden, wie Effectuation erlernt wird. Andererseits soll damit die Grundlage geschaffen werden, effektuative Entscheidungsfindung automatisiert anwendbar zu machen. Insgesamt soll damit ein Beitrag zur Weiterentwicklung des Theoriengerüsts von Effectuation geleistet werden.

Zur Erreichung des genannten Ziels und zur Beantwortung der in Abschnitt 1.2 erläuterten Forschungsfrage ist der Einsatz von Agentenbasierten Modellen (in der Folge ABM), der Argumentation von Garcia (2005) folgend, zweckdienlich. Konkret wird diesbezüglich die Auffassung vertreten, dass „simulation should be used as a tool for the refinement of theory“ (Garcia, 2005, S. 382). Weiterhin fordern Chandler et al. (2011) und Alsos et al. (2019), dass die Operationalisierung und Messbarkeit von Effectuation weiterentwickelt werden muss. Die Verwendung von ABM als Untersuchungsmethode wird dieser Forderung gerecht, da „by simulating an approximation of real world behavior that may be difficult to capture in static models, the ABM approach focuses on how processes evolve over time and how policies might be changed to affect the outcomes of an evolving system“ (Garcia, 2005, S. 382).

ABM eignen sich gemäß Bonabeau (2002) insbesondere bei der Beschreibung realweltlicher unternehmerischer Probleme und weisen folgende Eigenschaften auf:

Ergänzende Information Die elektronische Version dieses Kapitels enthält Zusatzmaterial, auf das über folgenden Link zugegriffen werden kann
https://doi.org/10.1007/978-3-658-39251-2_4.

- ABM bieten die Möglichkeit emergente Phänomene zu erfassen.
- ABM stellen eine natürliche Beschreibung eines Systems zur Verfügung.
- ABM sind flexibel in ihrer Ausgestaltung.

Dabei repräsentieren ABM Prozesse, bei denen davon auszugehen ist, dass sie in der sozialen Welt existieren (Macy & Willer, 2002).

Gupta et al. (2016) fordern darüber hinaus die künftige Betrachtung von Effectuation aus einer insbesondere prozessorientierten Sicht und die Abkehr von einer rein varianzbasierten Perspektive. Varianztheoretische Betrachtungen zielen auf die Einordnung eines Phänomens in ein Marktgleichgewicht ab (Chiles et al., 2009) und verkennen so die diskontinuierlichen Marktdynamiken entrepreneurialer Phänomene (Gupta et al., 2016). Payne et al. (2016) stellen heraus, dass die Betrachtung einer Problemstellung aus prozesstheoretischer Sicht die Frage nach der emergenten Entwicklung eines Phänomens über die Zeit adressiert. Wie Bonabeau (2002) konstatieren, eignen sich ABM zur Untersuchung sich über die Zeit emergent verhaltender Systeme.

Die von Mauer et al. (2017) und Welter und Kim (2018) verwendeten ABM erlauben die Interaktion von Agenten in emergenten Systemen, vernachlässigen jedoch aufgrund des statischen Verhaltensregelsatzes der Agenten das dynamische Anpassen des Vorgehens aufgrund von neuen Erfahrungen. Die Agenten in den Modellen von Mauer et al. (2017) und Welter und Kim (2018) werden das kurzfristige Erreichen schlechterer Leistungswerte in der unmittelbaren Umgebung nicht zugunsten einer möglichen langfristigen Leistungsmaximierung in Kauf nehmen. Folglich wird nur ein Teil des realweltlichen Phänomens abgebildet, da (effektiv agierende) Entrepreneur*innen aus dem Wechselspiel zwischen Exploration und Exploitation ihrer Umgebung lernen (Yang & Chandra, 2013).

Dass die Modellierung von Lern- und Entscheidungsverhalten durch den Einsatz von RIL im Rahmen von ABM sinnvoll ist, wurde durch Bone und Dragičević (2010) veranschaulicht. Zudem konnte durch Haiyan (2018) nachgewiesen werden, dass RIL im Kontext von entrepreneurialen Problemen anwendbar ist.

Inwiefern ABM grundlegend aufgebaut werden und Abläufe gestaltet werden können, beschreiben Abdou et al. (2012). Demnach bestehen ABM im Wesentlichen aus Agenten und der korrespondierenden Umgebung. Weitere charakteristische Elemente von ABM sind

- eine Menge von Verhaltensregeln des Agenten,
- ein Arbeitsgedächtnis des Agenten,
- ein adäquates Lernverhalten des Agenten sowie
- das Modell der Umgebung.

In RIL werden diese Elemente ebenfalls bei der Modellierung von Entscheidungsproblemen berücksichtigt (Abbeel & Ng, 2004; Mnih et al., 2016; Sutton & Barto, 2018). Die in den folgenden Abschnitten vorgeschlagene Modellierung effektuativen Verhaltens im Kontext von ABM und RIL basiert grundlegend auf den Vorgehensbeschreibungen und Ansätzen von Welter und Kim (2018), Mauer et al. (2017), Yang und Chandra (2013), Sutton und Barto (2018) und Abdou et al. (2012)

4.1 Beschreibung des Problemraums

Wie in Abschnitt 2.3.1 dargestellt, müssen Algorithmen, die ein Lernproblem mit der dort beschriebenen Struktur lösen sollen, mit einer konkreten Aufgabe konfrontiert werden (Mitchell, 1997). Zur Modellierung und Untersuchung des Lernverhaltens eines effektuativen Agenten ist analog die Konstruktion einer Entscheidungsaufgabe im entrepreneurialen Kontext notwendig. Saravathy (2009) beschreibt zur Veranschaulichung effektuativer Logik eine Entscheidungssituation im Rahmen des Produktentwicklungsprozesses eines Entrepreneurs, welche sie mit „The anatomy of the initial commit“ (Saravathy, 2009, S. 102 f.) betitelt.

In diesem Entscheidungsproblem offeriert ein Entrepreneur einem potentiellen Kunden eine bestimmte Menge eines Produkts mit einer speziellen Produkteigenschaft zu einem initialen Preis. In der Entscheidungssituation wird die Annahme getroffen, dass der Kunde das Produkt unter Umständen kaufen würde, wenn die spezielle Produkteigenschaft eine andere Ausprägung hätte (beispielsweise: Das Produkt soll die Farbe blau statt grün haben.). Der Entrepreneur steht nun vor der Entscheidung, eine bestimmte Höhe von Kosten für die Anpassung des Produkts in Kauf zu nehmen.

Saravathy (2009) definiert daraufhin drei Kriterien, die die Entscheidung beeinflussen:

- Der Entrepreneur ist oder ist nicht im Besitz der Mittel zur Umsetzung der Produktpassung.
- Die Vermutung des Entrepreneurs, ob der Kunde das Produkt kaufen wird oder nicht, wenn die Produktpassung vorgenommen wurde.
- Es existiert ein weiterer Kunde, der bereit ist, das Produkt ohne Anpassung zu kaufen und einen höheren Preis pro Einheit zu bezahlen als ursprünglich vom Entrepreneur gefordert oder ein solcher Kunde existiert nicht.

Um für sich festzulegen, ob der ursprüngliche Kunde das angepasste Produkt kaufen wird (*echter Kunde*) oder nicht (*Nicht-Kunde*), benötigt der Entrepreneur einen

Entscheidungsmechanismus. Dieser Mechanismus ist für zwei Arten von Fehlern anfällig, die auch im Kontext der klassischen Statistik Anwendung finden (Neyman & Pearson, 1933):

- Der Entrepreneur klassifiziert einen Kunden als *Nicht-Kunden*, obwohl dieser bereit gewesen wäre das Produkt nach Produkthanpassung zu kaufen (Typ-I-Fehler).
- Der Entrepreneur klassifiziert einen Kunden als *echten Kunden*, obwohl dieser in Wirklichkeit ein *Nicht-Kunde* ist (Typ-II-Fehler).

Zur Lösung des beschriebenen Problems nach effektuativem Vorgehen ist der Entrepreneur bestrebt, Typ-I-Fehler zu reduzieren, wengleich damit Kosten für das Auftreten von Typ-II-Fehlern einhergehen. Weiterhin wird ein effektuativ handelnder Entrepreneur dem Kunden den Vorschlag unterbreiten, dass dieser die Kosten für die Produkthanpassung übernimmt und dafür im Gegenzug einen geringeren Gesamtpreis nach der Produkthanpassung zahlen muss, wodurch sich gegenüber dem initialen Preis ein Kostenvorteil für den Kunden ergibt.

Das geschilderte Szenario dient als Grundlage für die Formulierung des ABM unter Einbeziehung des Lernverhaltens durch RIL.

4.2 Modellierung des effektuativ handelnden Agenten

Im Gegensatz zu Mauer et al. (2017) und Welter und Kim (2018) zielt die Entwicklung des vorliegenden Modells nicht vordergründig auf den Vergleich der Leistungsfähigkeit von Effectuation und Causation ab, welcher die varianztheoretische Untersuchung der Logiken in den Mittelpunkt stellt. Vielmehr soll der Forderung von Gupta et al. (2016) Rechnung getragen werden, den prozesstheoretischen Hintergrund von Effectuation verstärkt in die Betrachtung einzubeziehen und entsprechend zu modellieren.

Um das in der Arbeit vorgestellte ABM, welches auf Methoden des RIL basiert, nutzbar zu machen, ist es notwendig, einen Aktionsraum zu definieren, der effektuatives Handeln beinhaltet. Weiterhin ist die Bestimmung einer Lernfunktion maßgeblich für die Steuerung des Lernverhaltens des Agenten. Darauf aufbauend wird mit der Wahl einer geeigneten Lernstrategie sichergestellt, dass Effectuation performant und realitätsnah erlernt werden kann.

In den Abschnitten 4.2.1 und 4.2.2 werden diese Aspekte näher diskutiert.

4.2.1 Bestimmung der Verhaltensregeln

Die Modellierung des Aktionsraums dient der Bestimmung des Verhaltens des Agenten innerhalb der definierten Umgebung. Der Aktionsraum A , als eines der vier Elemente des 4-Tupels eines MDP, beinhaltet alle möglichen Aktionen, die ein Agent grundsätzlich im formulierten Problem ausführen kann. Die ausführbaren Aktionen können weiter eingeschränkt werden, indem in einem bestimmten Zustand $s \in S$ nur ausgewählte Aktionen ausgeführt werden können. Dies ist dann der Fall, wenn in definierten Zuständen nur einzelne Aktionen sinnvoll sind.

Beispielsweise könnte ein Aktionsraum, wie in Abschnitt 2.3.1 erläutert, mit $A = \{\text{Produkt anpassen, Produkt nicht verändern, neues Produkt entwickeln}\}$ definiert sein. Befindet sich ein Agent in einem Zustand, in dem er einen Mittelbestand, der mit *hoch* gekennzeichnet ist, beobachtet, kann es für diesen ausschließlich sinnvoll sein, das bestehende Geschäftsmodell inklusive der dazugehörigen Produkte auszunutzen, anstatt mit der Entwicklung eines neuen Produktes in einem unsicheren Markt zu starten. Folglich ergibt sich die Aktionsmenge $A(\text{hoch}) = \{\text{Produkt anpassen, Produkt nicht verändern}\}$.

Die Bestimmung effektiver Handlungsoptionen ergibt sich aus der von Sarasvathy (2009) beschriebenen Entscheidungssituation. Im erläuterten Szenario wird ausgehend von einer formulierten Problemstellung ein entrepreneuriales Lösungsvorgehen geschildert, das der Effectuation-Logik folgt: „It may either classify C as a non-customer (F) [...] or it might classify C as [a real customer] (T) [...].“ (Sarasvathy, 2009, S. 103). Dieses Vorgehen bildet die Grundlage für die Konkretisierung des Aktionsraums. Es lassen sich zwei Aktionen aus der Aussage filtern:

- a_0 : *classify C as customer* und
- a_1 : *classify C as non-customer*.

Der Aktionsraum wird daher mit den diskreten Elementen $A = \{a_0, a_1\}$ definiert. Diese Aktionen kann der Agent in jedem Zustand $s \in S$ anwenden. Es gilt $A(s) = A \forall s \in S$. Im vorliegenden Fall ist der Aktionsraum folglich nicht von $s \in S$ abhängig.

4.2.2 Bestimmung der Lernstrategie

Zur Entwicklung einer allgemeingültigen Policy π , die effektives Entscheiden ermöglicht, ist die Auswahl einer geeigneten Lernstrategie erforderlich. In Abschnitt

2.3.2 wurden einige Lernverfahren aufgezählt bzw. genauer erläutert. Um einen adäquaten Lernalgorithmus zu identifizieren, besteht die Notwendigkeit, Bedingungen für die Auswahl zu definieren. Mauer et al. (2017), Welter und Kim (2018) und Eberz (2018) nutzen zur Modellierung der Simulationsumgebung das Konzept der *knightschen Ungewissheit* (Knight, 1921). Mauer et al. (2017) erweitern den Modellraum um die Aspekte *Informationsisotropie* und *Ziel-Ambiguität*. Zusammen bilden die genannten Elemente den von Sarasvathy (2009, S. 70) beschriebenen entrepreneurialen Problemraum.

Folglich sollte die gewählte Lernstrategie

- knightsche Ungewissheit,
- Informationsisotropie und
- Ziel-Ambiguität

handhaben können.

Wie in Abschnitt 2.3.2 geschildert, können RIL-Lösungsmethoden in Model-Free- und Model-Based-Verfahren eingeteilt werden. Bei Model-Free-Methoden lernt der Agent durch Interaktion mit der Umgebung, ohne die Wahrscheinlichkeiten von Zustandsänderungen zu kennen (Bertsekas & Tsitsiklis, 1995). Bei knightscher Ungewissheit sind weder die möglichen einzutretenden Ereignisse (Zustände) noch deren Eintrittswahrscheinlichkeiten (Transitionswahrscheinlichkeiten) bekannt (Knight, 1921).

Zur Lösung des RIL-Problems kommen daher nur Model-Free-Lernalgorithmen in Frage. Anders als bei Mauer et al. (2017), Welter und Kim (2018) und Eberz (2018) besteht keine Notwendigkeit, zusätzliche Konzepte zur Modellierung von knightscher Ungewissheit – wie beispielsweise *Umgebungsturbulenzen* – zu verwenden. Das von Watkins & Dayan (1992) formulierte Q-Learning-Prinzip ist dem Bereich der Model-Free-Methoden zuzuordnen (Sutton & Barto, 2018, S. 131) und kann mit

$$q(s_t, a_t) \leftarrow q(s_t, a_t) + \alpha \left[r_{t+1} + \gamma \max_a q(s_{t+1}, a) - q(s_t, a_t) \right] \quad (4.1)$$

formuliert werden. Gleichung (4.1) macht deutlich, dass der Agent lediglich durch die Interaktion mit seiner Umgebung lernt, welche Aktion in welchem Zustand seine Gesamtbelohnung langfristig maximiert. Die optimale Action-Value-Funktion q_* wird hierbei direkt approximiert.

Die Formulierung aus (4.1) stellt eine Update-Funktion dar, bei der $q(s, a)$ in jedem Zeitschritt anhand der zur Verfügung stehenden Informationen mit dem

Lernparameter $\alpha \in [0, 1]$ aktualisiert wird. Diese Informationen sind der unmittelbar nach einem Zeitschritt erhaltene Reward r_{t+1} , der bereits bekannte q -Wert $q(s_t, a_t)$ und zum Zeitschritt $t + 1$ beobachtbare Wert $q(s_{t+1}, a)$. Die Action-Value-Funktion hat unmittelbaren Einfluss auf die Policy π des Agenten. Der Agent wird nach Beobachtung des Zustands die Aktion auswählen, für die $q(s, a)$ maximal ist.

Diese Modellierung erlaubt die Konzeptualisierung der Informationsisotropie (Kalinic et al., 2012). Einem Entrepreneur stehen in der Realität zum Zeitpunkt der Entscheidung eine Fülle von Informationen zur Verfügung, von denen nicht klar ist, welche für die zu fällende Entscheidung relevant sind. Wird dieses Problem auf das Modell übertragen, wird der effektive Agent daher zu Beginn seiner Unternehmung zunächst ein exploratives Verhalten an den Tag legen und Aktionen zu einem bestimmten Grad zufällig wählen, da er nicht sicher sein kann, welche Informationen des jeweiligen Zustandes für ein optimales Verhalten notwendig sind. Mit zunehmender Lernerfahrung wird der Agent immer häufiger Aktionen wählen, für die $q(s, a)$ maximal ist. In RIL wird dieses Vorgehen als Exploration-Exploitation-Tradeoff bezeichnet (Still & Precup, 2012).

Der Parameter $\varepsilon \in [0, 1]$ dient der Steuerung des Tradeoffs während des Lernvorgangs und legt fest, mit welcher Wahrscheinlichkeit der Agent exploratives Verhalten an den Tag legt. Zu Beginn wird $\varepsilon = 1$ gesetzt, wodurch der Agent zunächst die Aktion a zufällig aus dem Aktionsraum A wählt. Nach jeder durchgeführten Aktion wird ε um einen festgelegten Anteil ε_{decay} anhand folgender Vorschrift verringert:

$$\varepsilon_t = \varepsilon_{t-1} \cdot \varepsilon_{decay}.$$

Dadurch steigt die Wahrscheinlichkeit mit jedem Zeitschritt, dass der Agent die Aktion a in Zustand s wählt, für die $q(s, a)$ maximal ist. Zudem wird eine untere Grenze ε_{min} als Hyperparameter festgelegt, die bei Erreichen der Grenze in jedem Zeitschritt ermöglicht, dass der Agent mit einer geringen Wahrscheinlichkeit exploratives Verhalten an den Tag legt.

Des Weiteren sind die Bestandteile des entrepreneurialen Problemraums, Ziel-Ambiguität (Gabrielsson & Gabrielsson, 2013) und knightsche Ungewissheit (Townsend et al., 2018), inhärente Eigenschaften des Q-Learning Prinzips. Ein effektiv handelnder Agent bezieht sich zu jedem Zeitpunkt auf den beobachteten Zustand sowie die davon ausgehend möglichen Aktionen. Aus Sicht des Agenten ist es nicht notwendig konkrete Ziele zu definieren. Sie ergeben sich aus der Vereinbarung (Ausführung der Aktion) mit den Kunden und resultieren in neuen Zuständen, die wiederum die Produktvorstellungen des Entrepreneurs und des Kunden im jeweiligen Zeitschritt beinhalten. Die Produktvorstellungen des effektiven Agenten sind nicht fix und können anhand der verwendeten Lernstrategie angepasst werden.

Das Konzept der knightschen Ungewissheit, wie es in Abschnitt 2.2 diskutiert wurde, wird im vorliegenden Modell ebenfalls konkret umgesetzt. Dies wird ermöglicht, indem der Agent keinen Zugang zur Umgebungsdynamik hat. Dadurch ist er nicht in der Lage, direkt vorauszusagen, mit welcher Transitionswahrscheinlichkeit er einen bestimmten Zustand erreicht respektive welchen Zustand er überhaupt erreicht. Der Agent lernt lediglich durch Interaktion mit seiner Umgebung und baut anhand von Erfahrung sein Wissen über die Dynamiken des Modells auf. Dieses Vorgehen erweitert die bisher von Eberz (2018), Mauer et al. (2017) und Welter und Kim (2018) vorgestellten Modellierungsansätze und macht knightsche Ungewissheit zu einem direkten Bestandteil der Umgebung.

Das effektuative Lernproblem wird zudem als nicht-episodische Aufgabe modelliert. Dies erfordert einen Wert $\gamma < 1$ für den Diskontierungsfaktor zu wählen. Dieser Faktor ermöglicht die Festlegung, inwieweit künftige Belohnungen in die Berechnung der Action-Value-Funktion einbezogen werden. In Effectuation spielen mögliche Gewinne der Unternehmung in der Zukunft, die eine Vorhersage erfordern, eine untergeordnete Rolle (Saravathy, 2001). Daher wird der Diskontierungsfaktor mit einem vergleichsweise kleinen Wert initialisiert, so dass $\gamma = 0.2$ während des Lernprozesses angenommen wird.

4.3 Modellierung der Umgebung

Die Modellierung der Umgebung ist durch den Zustandsraum S sowie den Transitionswahrscheinlichkeiten p eines MDP bestimmt. Im vorliegenden Fall werden zur Formulierung der Umgebung die Erkenntnisse von Mauer et al. (2017), Welter und Kim (2018) und das Szenario aus Abschnitt 4.1 einbezogen. Die Beschreibung der Umgebung hat, neben der Formulierung der Belohnungsfunktion r , Einfluss auf das Verhalten des lernenden effektuativen Agenten. Die in den Abschnitten 4.3.1 und 4.3.3 erläuterte Modellierung der Umgebung stellt eine Annäherung an eine realweltliche Entscheidungssituation eines effektuativ agierenden Entrepreneurs dar.

4.3.1 Bestimmung des Zustandsraums

Die Zustände $s \in S$ beschreiben, in welcher konkreten Ausprägung des Umfeldes sich der lernende Agent befindet. Zustände selbst bestehen aus Realisierungen einer definierten Menge von Merkmalen, die für die Lösung eines MDP von Relevanz

Tabelle 4.1 Merkmale eines Zustands

Symbol	Beschreibung
E_t	Produktvektor des Agenten zum Zeitpunkt t
C_t	Produktvektor des Kunden zum Zeitpunkt t
$Class_{t-1}$	Klassifizierung zum Zeitpunkt t , ob der Kunde zum Zeitpunkt $t - 1$ ein <i>echter Kunde</i> oder <i>Nicht-Kunde</i> ist
$Cost_t$	Kosten für die Änderung des Produktvektors von $E_t \rightarrow C_t$
I_t	Potentielle Investition des Kunden zum Zeitpunkt t , sofern der Agent die Änderung des Produktvektors vornimmt

sind.¹ Die Merkmale eines Zustandes des Zustandsraumes S wird für das vorliegende Modell für $t \in \{0, \dots, T\}$ mit T als finalem Zeitpunkt in Tabelle 4.1 definiert.

Die Modellierung der Produktvektoren der Agenten E und der Kunden C orientieren sich an den Vorschlägen von Mauer et al. (2017) und Welter und Kim (2018) zur Repräsentation von Produkten respektive Entscheidungsketten. In der vorliegenden Untersuchung werden die von Welter und Kim (2018) verwendeten Entscheidungskonfigurationen als konkrete Produktentscheidungen interpretiert, indem sie zum einen die gleiche mathematische Struktur wie die von Mauer et al. (2017) verwendeten Produktvektoren aufweisen und diese Interpretation zum anderen keinen Einfluss auf die Dynamik des zu entwickelnden Modells hat.

Die Produktvektoren im Fallbeispiel besitzen die Länge $N = 10$, wobei N die Anzahl der möglichen Produkteigenschaften eines Produkts darstellt und diese grundsätzlich verallgemeinerbar ist. Jede Produktvektorkomponente kann zwei verschiedene Ausprägungen annehmen, die unabhängig voneinander entweder 0 oder 1 sein können. Die binäre Repräsentation von Produktvektorkomponenten deckt sich mit dem Vorgehen von Mauer et al. (2017) und Welter und Kim (2018) sowie der von Sarasvathy (2009) beschriebenen Entscheidungssituation, in der es heißt, dass „ C responds as follows: ‚I would gladly buy [the product] if only it were blue instead of green‘.“ (Sarasvathy, 2009, S. 102). Im Gegensatz zu Mauer et al. (2017) und Welter und Kim (2018) wird ein Produktvektor E nicht als inhärente Eigenschaft des Agenten modelliert, sondern als Teil eines beobachtbaren Zustandes. Dies

¹ Manche Autoren unterscheiden zwischen der reinen Beobachtung eines Agenten und dem tatsächlichen Zustand eines Problems (Azzizadenesheli et al., 2016; Kimura et al., 1997). Im Allgemeinen hat ein Agent keine Möglichkeit alle Aspekte eines Zustands zu erfassen und kann daher nur einen Teil seiner Umgebung beobachten. Für die vorliegende Betrachtung ist eine Unterscheidung der beiden Konzepte aufgrund des Umfangs des Zustandsraums nicht von Bedeutung.

ermöglicht eine weitere Annäherung an das realweltliche Phänomen. Durch die Anzahl der Produktvektorkomponenten N und der Anzahl an möglichen Ausprägungen der Komponenten ergeben sich 2^N mögliche Produkte. Unter der Voraussetzung, dass $N = 10$ existieren demzufolge 1024 Produktvarianten.

Ein Kunde kann ein *echter Kunde* oder *Nicht-Kunde* sein. Das binäre Merkmal *Class* kann demzufolge die zwei Werte 0 und 1 annehmen. Darüber hinaus ist das Klassifizierungsmerkmal, neben den definierten Aktionen aus dem Aktionsraum, grundlegend zur Bestimmung der Transitionswahrscheinlichkeiten, welche ebenfalls in Abschnitt 4.3.3 diskutiert werden. Weiterhin ist der effektuate Agent in der Lage, das Investitionsverhalten I eines Kunden zu beobachten. Dabei ist grundsätzlich $I > 0$. Unter welchen Voraussetzungen ein Kunde bereit ist in die Produktentwicklung des Agenten zu investieren, wird in Abschnitt 4.3.3 näher erläutert.

Wie im von Sarasvathy (2009, S. 102 f.) beschriebenen Szenario können für einen effektuativen Agenten Kosten für die Produktpassung anfallen. Diese werden im Modell durch das Merkmal *Cost* symbolisiert und können Werte von $Cost \geq 0$ annehmen. Die Bedingungen, die für das Auftreten von Kosten für den Agenten gelten, werden ebenfalls in Abschnitt 4.3.3 erläutert.

Die Menge aller möglichen Zustände im Zustandsraum definiert sich durch die Menge aller Kombinationen der Ausprägungen von C , E und *Class*. Dabei wird jeder möglichen Ausprägungskombination von C und E ein Paar von *Cost* und I zugeordnet. Um die Vergleichbarkeit mit den bereits bekannten Modellen von Mauer et al. (2017) und Welter und Kim (2018) zuzulassen, erweitern die Kosten und Investitionen den Zustandsraum nicht.

4.3.2 Bestimmung der Belohnungsfunktion

Die Belohnungsfunktion r eines MDP dient der Verhaltenssteuerung eines Agenten und bestimmt maßgeblich den Lernvorgang. Sie beschreibt inhaltlich, welche Belohnung ein Agent erhält, wenn er in einem bestimmten Zustand eine ausgewählte Aktion ausführt und in den nächsten Zustand gelangt. Formal lässt sich dies durch $r(s', a, s)$ ausdrücken (siehe Abschnitt 2.3.1).

Zur Modellierung einer Belohnungsfunktion, die effektuatives Verhalten des Agenten belohnt, ist herauszustellen, welche Aspekte im Sinne von Effectuation belohnenswert sind. Für das vorliegende Modell wurden drei Aspekte identifiziert, die Einfluss auf eine effektuate Belohnungsfunktion r haben. Die Bestandteile werden mit r^1 bezeichnet. Zudem soll gelten $0 \leq r \leq 1$.

Der erste Bestandteil zur Beeinflussung des Verhaltens des Agenten im Sinne eines effektuativen Vorgehens lässt sich durch die Übertragung der zur Verfügung

stehenden Mittel M des Agenten in eine Belohnungsfunktion realisieren. Konkret repräsentiert M_t das aktuell vorhandene finanzielle Budget des Agenten, welches ihm die Anpassung des Produktes E ermöglicht. Durch Einbeziehung der Mittel M in die Modellierung werden die von Mauer et al. (2017) und Welter und Kim (2018) definierten Problemräume erweitert und der von Sarasvathy (2001), Sarasvathy (2003), Wiltbank et al. (2006) und Zhang und Van Burg (2019) beschriebenen *means*, als Entscheidungsgrundlage im effektuativen Prozess, Rechnung getragen. Im von KfW Research (2017) publizierten Gründungsreport wurde herausgestellt, dass Existenzgründer im Jahr 2016 mit einem mittleren Eigenkapitaleinsatz von 7.500 € eine Unternehmung begonnen haben. Die dem Agenten zu Beginn des Lernprozesses zur Verfügung stehenden Mittel M_0 werden daher im Fallbeispiel mit dem Wert 7500 initialisiert. Die Mittel des Agenten zu einem beliebigen Zeitpunkt $t > 0$ beziehen die Kosten für eine Produktpassung sowie das Investitionsverhalten eines Kunden in die Berechnung ein. Welchen Berechnungsvorschriften die Mittel unterliegen, wird in Abschnitt 4.3.3 dargestellt. Um die effektuateive Verwendung der Mittel, wie sie unter anderem von Peng et al. (2020), Brettel et al. (2012), Sarasvathy (2009) und Karami et al. (2019) diskutiert wird, zu modellieren, ist die Bewertung der Veränderung des Mittelbestandes innerhalb eines Zeitschritts einzu-beziehen, die mit $M_{t+1} - M_t$ definiert ist. Für den Belohnungsfunktionsbestandteil gilt, dass mit jeder Erhöhung des Mittelzuwachses ein geringerer Anstieg der Belohnung einhergeht. Dieser Modellierungsansatz deckt sich mit den Annahmen von Sarasvathy (2001), wonach effektuativ agierende Entrepreneurure im Sinne des Affordable-Loss-Prinzips weniger Wert darauf legen, künftige Einnahmen respektive ihren Mittelbestand zu erhöhen, sondern vielmehr bestrebt sind, ihren aktuellen Mittelbestand so ressourcenschonend wie möglich einzusetzen. Eine Funktion, die diese Eigenschaften erfüllt, kann wie folgt modelliert werden:

$$r^1(m) = \begin{cases} \frac{e^m}{e^m + e^{\frac{1}{m}}} & m > 0 \\ 0 & \text{sonst.} \end{cases} \quad (4.2)$$

Dabei stellt m die Mittelveränderung im Verhältnis zum Anfangsbestand der Mittel als Bezugsgröße dar (in der Folge als Means Variation Ratio bezeichnet) und lässt sich mit

$$m_t = 1 + \frac{M_{t+1} - M_t}{M_0} \quad (4.3)$$

berechnen.

Abbildung 4.1 zeigt den Zusammenhang zwischen dem Verhältnis von Means Variation Ratio m und Belohnungsbestandteil r^1 . Es wird deutlich, dass der Agent

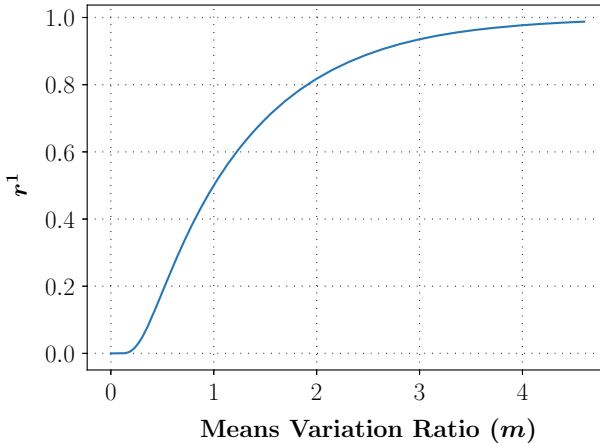


Abb. 4.1 Zusammenhang zwischen dem Verhältnis von Means Variation Ratio m und Belohnungsbestandteil r^1

nicht bereits bei $m = 1$ keine Belohnung mehr erhält. Vielmehr kann der Agent das Affordable-Loss-Prinzip anwenden und seine aktuell zur Verfügung stehenden Mittel zum Voranbringen der Unternehmung aufbrauchen. Er wird erst dann keine Belohnung mehr erhalten ($r^1 = 0$), wenn die Kosten für eine Produkthanpassung der Höhe der Mittel zu Beginn der Unternehmung entsprechen und er einen Typ-II-Fehler begeht.

Ein weiterer die Belohnungsfunktion beeinflussender Aspekt ergibt sich aus dem von Sarasvathy vorgestellten Entscheidungsszenario, welches ein typisches effektuatives Verhaltensmerkmal herausstellt:

„This final solution to the problem is the strongly effectual one consisting any mechanism that reduces Type I errors at the cost of incurring Type II errors. In other words, the effectual commitment always favors the error of letting possible customers go as opposed to letting non-customers drive the decision process.“ (Sarasvathy, 2009, S. 103)

Demnach nimmt ein effektuativ handelnder Entrepreneur in Kauf, Typ-II-Fehler (Agent schätzt Kunden als *echten Kunden* ein, obwohl sich dieser in Wirklichkeit als *Nicht-Kunde* herausstellt und entsprechend das angepasste Produkt nicht kaufen wird.) zu begehen, wenn er damit erreicht, Typ-I-Fehler (Agent schätzt Kunden als *Nicht-Kunden* ein, obwohl sich dieser in Wirklichkeit als *echter Kunde* herausstellt

Tabelle 4.2 Entscheidungstabelle

		Wirklichkeit	
		Class0	Class1
Einschätzung mit	... a0	Korrekte Einschätzung	Typ-II-Fehler
	... a1	Typ-I-Fehler	Korrekte Einschätzung

und entsprechend das angepasste Produkt gekauft hätte.) zu vermeiden. Zur Veranschaulichung der Zusammenhänge zwischen der Klassifizierung des Kunden durch den Agenten und des tatsächlichen Verhaltens des Kunden dient die Entscheidungstabelle 4.2. Die Merkmalsausprägungen *Class0* und *Class1* repräsentieren hierbei folgendes:

- *Class0*: Der Kunde ist ein *echter Kunde* und
- *Class1*: Der Kunde ist ein *Nicht-Kunde*.

Neben dem Auftreten der Fehler vom Typ I und II kann der Agent den Kunden auch korrekt einschätzen, indem er

- den Kunden mit der Aktion *a0* als *echten Kunden* einschätzt und *Class0* eintritt oder
- den Kunden mit der Aktion *a1* als *Nicht-Kunden* einschätzt und *Class1* eintritt.

Aus den in Tabelle 4.2 vorgestellten Entscheidungsergebnissen und der von Sarasvathy (2009) beschriebenen bevorzugten effektuativen Verhaltensweise ergibt sich ein Aspekt zur Bestimmung der Belohnungsfunktion.

Die vier möglichen Entscheidungsergebnisse lassen sich für das Fallbeispiel in die in Tabelle 4.3 dargestellten Belohnungsparameter überführen und initialisieren. Für das Einschätzen eines Kunden als *echten Kunden*, der in Wirklichkeit ein *Nicht-Kunde* ist (Typ-I-Fehler) bzw. das Einschätzen eines Kunden als *Nicht-Kunden*, der in Wahrheit ein *echter Kunde* ist (Typ-II-Fehler), erhält der Agent keine Belohnung ($r^2(\text{Class0}, a1) = r^2(\text{Class1}, a0) = 0$). Für das korrekte Einschätzen des Kunden erhält der Agent eine Belohnung von 1 ($r^2(\text{Class0}, a0)$) bzw. 0.5 ($r^2(\text{Class1}, a1)$). Unter der Annahme, dass die Wahrscheinlichkeiten dafür, dass ein Kunde in Wirklichkeit ein *echter Kunde* beziehungsweise *Nicht-Kunde* ist, gleich sind, wird ein Agent bei Wahl der Aktion *a0* im Mittel eine höhere Belohnung erwarten, als wenn er sich für die Aktion *a1* entscheidet. Folglich nimmt er langfristig eher in Kauf, Typ-II-Fehler zu begehen.

Tabelle 4.3 Mögliche Werte des Belohnungsfunktionsbestandteils r^2

r^2	Class0	Class1
$a0$	1 (Korrekte Einschätzung)	0 (Typ-II-Fehler)
$a1$	0 (Typ-I-Fehler)	0.5 (Korrekte Einschätzung)

Ein weiterer Aspekt zur Steuerung effektuativen Verhaltens mittels einer Belohnungsfunktion ist die Einbeziehung der Leistungsfähigkeit eines Produktvektors, wie sie von Welter und Kim (2018) vorgeschlagen wurde. Die Leistungsfähigkeit eines vom Entrepreneur entwickelten Produktes dient im Modell als Maß zur Bestimmung, zu welchem Grad der Product-Market-Fit erreicht wurde. Formal lässt sich der Product-Market-Fit als $r^3(E)$ mit $r^3 \in [0, 1]$ ausdrücken. Die Berechnung von $r^3(E)$ folgt der Vorschrift, die sich aus Gleichung (3.6) in Abschnitt 3.1.2 ergibt. Zum Zeitpunkt t beschreibt der Wert $r^3(E_t)$ folglich, wie gut das vom effektuativ handelnden Entrepreneur angepasste Produkt der Marktnachfrage entspricht. Ein vergleichsweise guter Product-Market-Fit korrespondiert mit vergleichsweise hohen Werten $r^3(E)$, ein schlechter Product-Market-Fit mit vergleichsweise niedrigen Werten $r^3(E)$.

Zur Bestimmung der endgültigen Belohnungsfunktion, die das effektuate Verhalten des Agenten beeinflusst, werden die beschriebenen Teilaspekte einer Belohnung in eine Konvexkombination überführt und jeweils mit einem Gewichtungskoeffizienten versehen. Daraus ergibt sich die Belohnungsfunktion

$$r_{t+1} = \frac{\omega_1 r^1(m_t) + \omega_2 r^2(\text{Class}, a)_t + \omega_3 r^3(E_{t+1})}{\sum_{i=1}^3 \omega_i} \quad (4.4)$$

für $\omega_1 \geq 0$ mit $r_t \in [0, 1]$ und $t \geq 0$. Die in Gleichung (4.4) vorgestellte Belohnungsfunktion wird in Abbildung 4.2 veranschaulicht. Die Abbildung zeigt die Belohnungsfunktionen r_t für variierendes Means Variation Ratio m und Product-Market-Fit $r^3(E_t)$ bei fixierter Belohnung für das Einschätzen des Kunden durch den Agenten mit $r^2(\text{Class}0, a0) = 1$ und unterschiedlichen Gewichtungsfaktoren ω_3 . Der Gewichtungsfaktor ω_3 wurde mit den Werten 1 und 4 initialisiert, um die damit verbundene Änderung der Belohnungsfunktion r_t zu verdeutlichen. Demnach kann ein Agent grundsätzlich größere Belohnungen erhalten, wenn die Gewichtung $\omega_3 = 4$ gesetzt wird. Bei Fixierung von m ist ein stärker Anstieg von r_t mit steigendem $r^3(E_t)$ im Vergleich zu $\omega_1 = 1$ zu beobachten.

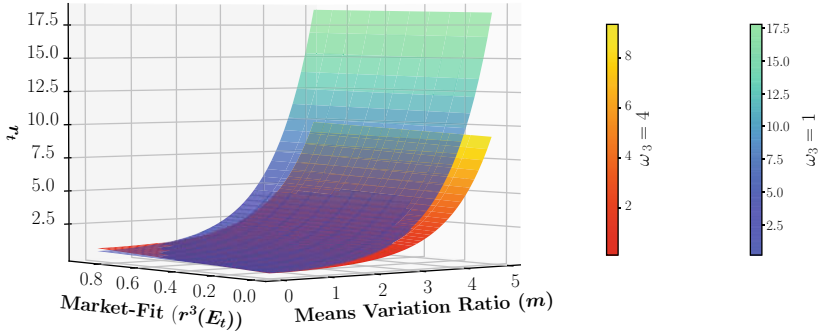


Abb. 4.2 Darstellung der Belohnungsfunktion aus Gleichung (4.4) bei variierendem m und $r^3(E_t)$ sowie fixiertem $r^2(Class, a)$

Camacho et al. (2019) folgend müssen Belohnungsfunktionen unter anderem die Markov-Eigenschaft erfüllen und Zuständen bzw. Zustands-Aktionspaaren skalare Belohnungswerte zuordnen. Die in Gleichung (4.4) dargestellte Belohnungsfunktion erfüllt diese Bedingungen. Die Teilbelohnung, welche sich aus Gleichung (4.2) ergibt, bezieht zur Berechnung von m_t Investitionswerte und Kosten aus maximal einem vorhergehenden Zeitpunkt $t - 1$ ein. Die Teilbelohnungen $r^2(Class, a)_t$ und $r^3(E_t)$ stehen in Zusammenhang mit einem Zustands-Aktionspaar im Zeitschritt $t - 1$ zu t , wodurch die Markov-Eigenschaft ebenfalls nicht verletzt wird. Die Belohnung r_t ergibt nach der in Gleichung (4.4) definierten Rechenvorschrift einen skalaren Wert. Der entsprechende Quellcode zum Aufbau des Zustandsraums und der Bildung des NK-Modells zur Bestimmung des Produkt-Market-Fits kann in Anhang C.2 im elektronischen Zusatzmaterial nachvollzogen werden.

4.3.3 Bestimmung der Transitionswahrscheinlichkeiten

Die Bestimmung der Transitionswahrscheinlichkeiten p ist Bestandteil der Modellierung der Umgebung. Die Transitionswahrscheinlichkeiten geben Auskunft darüber, mit welcher Wahrscheinlichkeit ein Agent nach Ausführung einer Aktion von einem Zustand in den nächsten Zustand kommt. Im Modellansatz sind diese Wahrscheinlichkeiten dem Agenten aus den in Abschnitt 4.2.2 erläuterten Gründen nicht bekannt. Dadurch kann der Agent lediglich durch Interaktion mit der Umgebung die Genauigkeit der Schätzung des Erwartungswertes einer Action-Value-Funktion, wie sie ebenfalls in Abschnitt 4.2.2 beschrieben ist, über die Zeit verbessern.

Tabelle 4.4 Bedingte Wahrscheinlichkeiten

$P(a Class)$	$Class0$	$Class1$
$a0$	$1 - \varphi$	χ
$a1$	φ	$1 - \chi$

Tabelle 4.2 bildet die Grundlage zur Bestimmung der Transitionswahrscheinlichkeiten und orientiert sich in ihrer Darstellungsform an Entscheidungstabellen im Kontext von Hypothesentests. Diese dienen traditionell der Ermittlung statistischer Fehler (Neyman & Pearson, 1933). Formal kann Tabelle 4.2 auch mit Hilfe bedingter Wahrscheinlichkeiten ausgedrückt werden (Wooldridge, 2013, S. 779). In Tabelle 4.4 werden die bedingten Wahrscheinlichkeiten definiert.

Die bedingte Wahrscheinlichkeit $P(a0|Class0)$ korrespondiert hierbei mit der linken oberen Zelle in Tabelle 4.2 (Korrekte Einschätzung), $P(a0|Class1)$ mit der rechten oberen Zelle (Typ-II-Fehler), $P(a1|Class0)$ mit der linken unteren Zelle (Typ-I-Fehler) und $P(a1|Class1)$ mit der rechten unteren Zelle (Korrekte Einschätzung).

Zur Bestimmung der Wahrscheinlichkeiten, dass ein Kunde ein *echter Kunde* ($Class0$) bzw. *Nicht-Kunde* ($Class1$) ist, unter der Voraussetzung, dass ein Kunde als *echter Kunde* (Aktion $a0$) bzw. *Nicht-Kunde* (Aktion $a1$) eingeschätzt wird, erfolgt die Anwendung des Satzes von Bayes, der in Abschnitt 2.1 diskutiert wird. Hierfür ist es zusätzlich notwendig, die totale Wahrscheinlichkeit für das Eintreten des Ereignisses, dass ein Kunde ein *echter Kunde* bzw. *Nicht-Kunde* ist, zu modellieren. Die Wahrscheinlichkeit für das Eintreten des Ereignisses, dass ein Kunde ein *echter Kunde* ist, wird entsprechend mit $P(Class0) = \psi$ definiert. Für das Eintreten des Ereignisses, dass ein Kunde ein *Nicht-Kunde* ist, ergibt sich die Gegenwahrscheinlichkeit mit $P(Class1) = 1 - \psi$. Für die Zustandsänderungen können damit die folgenden Eintrittswahrscheinlichkeiten berechnet werden:

$$P(Class0|a0) = \frac{(1 - \varphi)\psi}{\chi(1 - \psi) + (1 - \varphi)\psi} \quad (4.5)$$

$$P(Class1|a0) = \frac{\chi(1 - \psi)}{(1 - \varphi)\psi + \chi(1 - \psi)} \quad (4.6)$$

$$P(Class0|a1) = \frac{\varphi\psi}{\varphi\psi + (1 - \chi)(1 - \psi)} \quad (4.7)$$

$$P(Class1|a1) = \frac{(1 - \chi)(1 - \psi)}{\varphi\psi + (1 - \chi)(1 - \psi)}. \quad (4.8)$$

Dem Vorgehen von Welter und Kim (2018) folgend, wird im vorliegenden Modell ein Agent bei einer Zustandsänderung potentiell nur die Zustände erreichen, bei denen der Produktvektor eines Kunden in maximal einer Komponente von dem des Entrepreneurs abweicht. Führt der Agent die Aktion $a0$ zum Zeitpunkt t aus, übernimmt er für den Produktvektor E_{t+1} den Produktvektor C_t , so dass gilt $E_{t+1} = C_t$. Klassifiziert der Agent einen Kunden mit der Aktion $a1$, verändert der Agent seinen bisherigen Produktvektor nicht und es ergibt sich $E_{t+1} = E_t$. Schätzt der Agent einen Kunden demnach als *echten Kunden* ein, ist er bereit die Produktvorstellung des Kunden umzusetzen. Klassifiziert der Agent einen Kunden als *Nicht-Kunden*, wird er von einer Produkthanpassung Abstand nehmen und belässt das Produkt im ursprünglichen Zustand.

Bisher beziehen sich die gemeinsam auftretenden Ereignisse nur auf die auszuführende Aktion und die tatsächliche Klassifizierung des Kunden. Da bei jeder Zustandsänderung grundsätzlich jedoch unterschiedliche Produktvektoren bei den Kunden auftreten können, müssen die bedingten Wahrscheinlichkeiten auf die Anzahl der möglichen zu beobachtenden Zustände aufgeteilt werden. Im vorliegenden Modell werden die bedingten Wahrscheinlichkeiten über alle Zustände mit dem vom Agenten beobachtbaren Produktvektoren der Kunden nach Ausführung einer Aktion gleichverteilt. Es ergibt sich die Gewichtung der bedingten Wahrscheinlichkeiten mit $\frac{1}{N}$.

Die Bestimmung der Transitionswahrscheinlichkeiten erfolgt auf Grundlage eines empirischen Wertes, der in der Literatur zu finden ist. Laut dem Center for Venture Research (2019) beträgt die Investitionsrate von Wagniskapital-Unternehmen in der ersten Finanzierungsphase eines Unternehmens 30,7%. Die Investitionsrate stellt hierbei das Verhältnis von der tatsächlich getätigten Anzahl an Investitionen des Wagniskapital-Unternehmens zur Anzahl der Investitionsmöglichkeiten dar. Im Rahmen der Effectuation-Theorie entfällt eine Unterscheidung zwischen Kunden und Investor (Sarasvathy, 2009, S. 102–105), da beide grundsätzlich im Sinne des Crazy-Quilt-Prinzips Partner der Unternehmung des effektuativen Entrepreneurs sein können (Chandler et al., 2011). Die Nutzung der Investitionsrate zur Modellierung der Wahrscheinlichkeit, ob ein Kunde in Wirklichkeit ein *echter Kunde* oder *Nicht-Kunde* ist, ist daher zielführend. Entsprechend wird die Wahrscheinlichkeit dafür, dass der Kunde, mit dem eine potentielle Zusammenarbeit angestrebt wird, ein *echter Kunde* ist und dieser als *echter Kunde* klassifiziert wird ($P(Class0 \cap a0)$), mit dem Wert 0.307 initialisiert. Formal lässt sich die Wahrscheinlichkeit $P(Class0)$ durch

$$\psi = P(Class0) = \frac{P(Class0 \cap a0)}{P(a0|Class0)} = \frac{0.307}{1 - \varphi} \quad (4.9)$$

berechnen. Die Wahrscheinlichkeiten φ und χ werden zur Untersuchung des Lernverhaltens des effektuativen Agenten als variabel angenommen.

Die in (4.5) bis (4.8) formulierten bedingten Wahrscheinlichkeiten basieren auf den Ereignissen $a0$ bzw. $a1$ und $Class0$ bzw. $Class1$. Für die gemeinsam auftretenden Ereignisse existieren verschiedene Berechnungsvorschriften der Mittel in Zeitschritt $t + 1$:

$$Class0 \cap a0 : M_{t+1} = M_t - Cost_t + I_t \quad (4.10)$$

$$Class1 \cap a0 : M_{t+1} = M_t - Cost_t \quad (4.11)$$

$$Class0 \cap a1 : M_{t+1} = M_t \quad (4.12)$$

$$Class1 \cap a1 : M_{t+1} = M_t \quad (4.13)$$

Schätzt ein Agent einen Kunden als *echten Kunden* ein, wird der Agent zunächst seinen Produktvektor so anpassen, dass gilt $E_{t+1} = C_t$. Klassifiziert der Agent einen Kunden als *Nicht-Kunden* gilt $E_{t+1} = E_t$. Der Agent glaubt demzufolge nicht, dass der Kunde das angepasste Produkt kaufen wird und nimmt daher von einer mit Kosten verbundenen Anpassung des Produktvektors Abstand. Stellt der Agent nach Ausführung der Aktion $a0$ fest, dass der Kunde tatsächlich ein *echter Kunde* ($Class0$) ist, ergibt sich die Rechenvorschrift der Mittel aus (4.10). Die Mittel M_{t+1} errechnen sich aus den zum Zeitpunkt t verfügbaren Mitteln M_t abzüglich der Kosten $Cost_t$ für die Produkthanpassung $E_{t+1} \leftarrow C_t$ und zuzüglich der Investition I_t , die ein Kunde bereit ist für die Produkthanpassung zu leisten. Dabei wird I_t gleichverteilt mit $Cost_t < I_t < 1.5 \cdot Cost_t$ angenommen.

Tritt der Fall ein, dass der Agent einen Kunden als *echten Kunden* einschätzt, dieser in Wahrheit jedoch ein *Nicht-Kunde* ist, hat der Agent die mit Kosten verbundene Produkthanpassung vorgenommen, ohne dass der Kunde bereit ist, das Produkt zu kaufen und damit in die Anpassung zu investieren. Gleichung (4.11) verdeutlicht die damit einhergehende Berechnung der Mittel M_{t+1} .

Wird der Agent einen Kunden im Zeitschritt t als *Nicht-Kunden* klassifizieren, ergeben sich zur Mittelberechnung im Zeitschritt $t + 1$ die Vorschriften aus den Gleichungen (4.12) und (4.13). Unabhängig davon, ob der Agent beobachtet, dass der Kunde aus dem vorangegangenen Zeitschritt ein *echter Kunde* oder *Nicht-Kunde* ist, nimmt der Agent keine Produkthanpassung vor. Folglich fallen keine Kosten für den Agenten an und er erhält keine Investitionen vom Kunden, wodurch die Mittel im Zeitschritt $t + 1$ dem Mittelbestand M_t entsprechen.

Zur Veranschaulichung der erläuterten Transitionen ist in Abbildung 4.3 eine beispielhafte Zustandsänderung dargestellt. In der Darstellung ist der Anfangszustand mit der Start-Produktkonfiguration des Agenten $E_0 = (010)$ sowie des Kunden

$C_0 = (000)$ der Länge $N = 3$ zu finden. Der Agent startet mit den im Zustand zu beobachtenden Mitteln $M_0 = 7500$. Die Kosten für die Produkthanpassung von $(010) \rightarrow (000)$ betragen 1000. Die mögliche Investitionssumme I_0 des Kunden für eine Produkthanpassung beträgt 1100.

Der Agent hat die Möglichkeit, den Kunden aus dem initialen Zustand als *echten Kunden* (a_0) oder *Nicht-Kunden* (a_1) zu klassifizieren. Nach Ausführung einer Aktion kann der Agent in einem der in den beiden Tabellen dargestellten möglichen Zustände landen. Jede Spalte beschreibt hierbei jeweils einen möglichen Zustand im Zeitschritt 1 mit konkreten Ausprägungen, die vom Zustand zum Zeitpunkt 0 aus erreichbar sind.

4.4 Standardisierung des Modells

Um die Möglichkeit zu gewährleisten, das entwickelte Modell entsprechend der in Abschnitt 3.1.4 erläuterten Methoden durch weitere Autoren zu verifizieren, besteht die Notwendigkeit den Implementierungsprozess zu standardisieren. Brockman et al. (2016) präsentieren in ihrem Rahmenwerk eine Möglichkeit Modelle, die auf Methoden des RIL aufbauen, zu vereinheitlichen. Mit Hilfe der *OpenAI Gym*-Schnittstelle können modellierte RIL-Probleme explizit dargestellt und korrespondierende Lösungen verglichen werden. Die Verifikations-Umgebung ist quelloffen verfügbar und in Python implementiert. Im Kern stellt die Bibliothek eine Schnittstelle zur Verfügung, um die Umgebung des RIL-Problems standardisiert darzustellen. Hierfür ist die Erstellung einer dedizierten *Environment*-Klasse notwendig, die die Implementierung einiger weniger Attribute und Methoden fordert. Zu Vergleichszwecken ist unter anderem die Typen-Deklaration der Elemente des Zustandsraumes notwendig.

Anhand der Charakteristik der einzelnen Merkmale des in Abschnitt 4.3.1 beschriebenen Zustandsraumes ergibt sich die in Anhang C.1 im elektronischen Zusatzmaterial aufgestellte Klassen-Definition zur Implementierung in *OpenAI Gym*. Der modellierte Zustandsraum wird in *OpenAI Gym* zu Deklarationszwecken als Python-Dictionary übergeben. Die Merkmale des Zustandsraumes werden als Schlüssel-Strings codiert. Den Schlüsseln werden Werte zugeordnet. Die Typen der Werte werden entsprechend der durch *OpenAI Gym* vorgegebenen möglichen Klassendefinitionen deklariert. In einer *OpenAI Gym*-Umgebung dienen die Werte des Dictionaries als Definition des Wertebereiches der möglichen Ausprägungen der Zustandsmerkmale. Der vollständige Aufbau der Umgebung ist in Anhang C.3 im elektronischen Zusatzmaterial dargestellt.

Algorithmus 4 Q-Learning-Algorithmus zur Schätzung von $\pi \approx \pi_*$

```

1: procedure Q-LEARNING( $\alpha, \gamma, T$ )
2:    $q(s, a) \leftarrow 0 \forall s \in S, a \in A$ 
3:   Zufällige Wahl von  $s_0$  gemäß einer Gleichverteilung über alle  $s \in S$  mit  $M_0$ 
4:   while  $t < T$  do
5:      $a_t \leftarrow \arg \max_a q(s_t, a)$ 
6:      $s_{t+1} \leftarrow f(s_t, a_t, \varphi, \chi, \psi)$   $\triangleright$  Zustandsübergang als Funktion der ausgeführten
       Aktion und der Transitionswahrscheinlichkeit
7:      $q(s_t, a_t) \leftarrow q(s_t, a_t) + \alpha \left[ r_{t+1} + \gamma \max_a q(s_{t+1}, a) - q(s_t, a_t) \right]$ 
8:      $t \leftarrow t + 1$ 
9:   end while
10: end procedure

```

Zum Zweck der Transparenz und Nachvollziehbarkeit ist zudem in Algorithmus 4 das Lernprogramm des sich in der definierten Umgebung bewegendem Agenten in Pseudo-Code dargestellt. Dabei wird angenommen, dass der Agent in jedem Zeitschritt ein exploitatives Verhalten an den Tag legt. Die konkrete Implementierung des Algorithmus in Python unter Beachtung des Explorations-Exploitations-Tradeoffs ist in Anhang C.4 im elektronischen Zusatzmaterial wiederzufinden.

Open Access Dieses Kapitel wird unter der Creative Commons Namensnennung 4.0 International Lizenz (<http://creativecommons.org/licenses/by/4.0/deed.de>) veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden.

Die in diesem Kapitel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.





Ergebnisse des Lernprozesses

5

Die Feststellung der Güte von RIL-Algorithmen kann zum einen durch die Beurteilung der Lerngeschwindigkeit einer Policy oder der Höhe der gesammelten Belohnungen während des Lernprozesses erfolgen. Dementsprechend können entweder der Mittlere Quadratische Fehler von q -Werten aufeinanderfolgender Episoden oder die mittlere erhaltene Belohnung pro Episode als Gütemaß verwendet werden (Greenwald & Hall, 2003, Poole & Mackworth, 2017, Kap. 12.6).

Der Mittlere Quadratische Fehler (in der Folge MSE, englisch für *Mean Squared Error*) einer Episode errechnet sich aus dem Produkt der Summe der quadrierten Differenz aller $q(s, a)$ zum Zeitpunkt t und aller $q(s, a)$ zum Zeitpunkt $t - K$ und dem Reziproke des Produktes der Umfänge des Zustands- und Aktionsraums $\frac{1}{|S| \cdot |A|}$, wobei $K \in \mathbb{N}$ die Episodenlänge darstellt. Es ergibt sich

$$MSE = \frac{1}{|S| \cdot |A|} \sum_{s \in S} \sum_{a \in A} (q_t(s, a) - q_{t-K}(s, a))^2. \quad (5.1)$$

Die Ermittlung der mittleren erhaltenen Belohnung des Agenten pro Episode ergibt sich aus dem Produkt der Summe der durch Anwendung der jeweiligen Strategie beobachteten Belohnungen r_j zu jedem Zeitpunkt j im Zeitraum $t - K + 1 \dots t$ und dem Reziproke der Episodenlänge $\frac{1}{K}$. Dies kann formal mit

Ergänzende Information Die elektronische Version dieses Kapitels enthält Zusatzmaterial, auf das über folgenden Link zugegriffen werden kann
https://doi.org/10.1007/978-3-658-39251-2_5.

$$\text{Average Rewards} = \frac{1}{K} \sum_{j=t-K+1}^t r_j \quad (5.2)$$

ausgedrückt werden.

Im Rahmen der Untersuchung wird die Episodenlänge $K = 100$ gesetzt. Folglich werden pro Episode 100 Zeitschritte durchlaufen. Nach Durchführung von Testläufen der Simulation konnte festgestellt werden, dass die Wahl dieser Episodenlänge geeignet für die Darstellung des in Gleichung 5.1 vorgestellten Mittleren Quadratischen Fehlers und der in Gleichung 5.2 beschriebenen mittleren Belohnung ist. Eine Episode stellt in diesem Zusammenhang lediglich einen Zeitraum zu Vergleichszwecken dar. Sie endet nicht mit einem absorbierenden Zustand, da das in Abschnitt 4.2.2 erläuterte RIL-Problem als fortlaufende Aufgabe modelliert ist.

Zur Untersuchung der Leistungsfähigkeit des Lernverhaltens des effektuativen Agenten werden die in den Abschnitten 5.1 bis 5.4 erläuterten Ergebnisse mit denen eines Agenten verglichen, der einer zufälligen Strategie folgt. Bei diesem Verhalten wählt der Agent zufällig eine Aktion a_t gleichverteilt aus den Werten von A aus. Durch Gegenüberstellung der beiden Strategien kann anhand der Gütemaße, die sich aus den Vorschriften 5.1 und 5.2 ergeben, überprüft werden, ob effektuatives Verhalten des Agenten im modellierten Problemraum sinnvoll ist.

5.1 Untersuchung verschiedener Lernverhalten bei teilweiser Manipulation der Belohnungsfunktion

Die in Abschnitt 4.3.2 formulierte Belohnungsfunktion dient der Verhaltenssteuerung des Agenten. Sie bewirkt, dass ein Agent für eine effektuateive Aktion in einem bestimmten Zustand entsprechend honoriert wird. Die in Gleichung (4.4) dargestellte Funktion setzt sich im Wesentlichen aus drei Bestandteilen zusammen, die jeweils mit einem Gewichtungsparmeter versehen sind. Jeder der Konvexkombinationsterme misst die Güte verschiedener Aspekte der Entscheidung des Agenten im entrepreneurialen Kontext.

5.1.1 Auswahl der Parameterwerte

Zur Untersuchung, welche Auswirkungen die Betrachtung bestimmter Teile der Belohnungsfunktion auf das Lernverhalten des Agenten hat, werden die Gewichtungsfaktoren ω_1 , ω_2 , ω_3 in unterschiedlichen Konfigurationen als Parameter ange-

setzt. Konkret werden zunächst die Ergebnisse bei Verwendung der Parameterkonfigurationen

$$\omega_1 = 1, \omega_2 = 1, \omega_3 = 1$$

$$\omega_1 = 0, \omega_2 = 1, \omega_3 = 1$$

$$\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$$

$$\omega_1 = 1, \omega_2 = 1, \omega_3 = 0$$

analysiert. Mittels der Parameter ω_i kann gesteuert werden, welche Aspekte effektuativen Verhaltens Einfluss auf die Lernerfahrung des Agenten nehmen. Die Resultate werden in Abschnitt 5.1.2 mit denen eines zufällig handelnden Agenten verglichen.

Zur Untersuchung des Einflusses der isoliert betrachteten Belohnungsfunktionsbestandteile auf die Leistungsfähigkeit eines effektuativ lernenden Agenten werden in Abschnitt 5.2 danach die Parameterkonfigurationen

$$\omega_1 = 1, \omega_2 = 0, \omega_3 = 0$$

$$\omega_1 = 0, \omega_2 = 1, \omega_3 = 0$$

$$\omega_1 = 0, \omega_2 = 0, \omega_3 = 1$$

zu Grunde gelegt und die daraus resultierenden Lernergebnisse verglichen. Durch die einzelne Betrachtung der jeweiligen Konvexkombinationssummanden kann der unmittelbare Einfluss der Belohnungsfunktionsbestandteile auf die Leistungsfähigkeit und das Lernverhalten des Agenten bestimmt werden.

Die Parameter φ und χ spiegeln die Wahrscheinlichkeiten für die Ereignisse wider, dass der Kunde als *Nicht-Kunde* eingeschätzt wird, unter der Bedingung, dass der Kunde ein *echter Kunde* ist bzw. dass der Kunde als *echter Kunde* eingeschätzt wird, unter der Bedingung, dass der Kunde in Wirklichkeit ein *Nicht-Kunde* ist. Aufgrund des Mangels an weiterführenden Informationen werden zur Untersuchung des Lernverhaltens bei sich ändernder Belohnungsfunktion die bedingten Wahrscheinlichkeiten φ und χ mit dem Wert 0.5 initialisiert. Dieses Vorgehen folgt dem Indifferenzprinzip, wonach ohne Vorliegen weiterer Informationen eine diskrete Gleichverteilung der möglichen Ereignisse anzunehmen ist (de Laplace, 1812, S. 182 f.). Die Ereignisse des Ausführens einer bestimmten Aktion und der Klassifizierung eines Kunden werden damit stochastisch unabhängig. So gilt beispielsweise

$$P(\text{Class0}|a0) = \frac{(1 - \varphi)\psi}{\chi(1 - \psi) + (1 - \varphi)\psi} = \frac{0.5 \cdot 0.614}{0.5 \cdot 0.386 + 0.5 \cdot 0.614} = 0.614$$

$$P(\text{Class0}|a1) = \frac{\varphi\psi}{\varphi\psi + (1 - \chi)(1 - \psi)} = \frac{0.5 \cdot 0.614}{0.5 \cdot 0.614 + 0.5 \cdot 0.386} = 0.614.$$

Daraus folgt offenbar

$$P(\text{Class0}|a0) = P(\text{Class0}|a1) = P(\text{Class0}) = 0.614$$

und damit die stochastische Unabhängigkeit.

Zur Bestimmung der Hyperparameter, die das Explorationsverhalten und die Lerngeschwindigkeit steuern, wird zunächst auf Erfahrungswerte, die aus der prototypischen Umsetzung des Modells stammen, zurückgegriffen. Sie werden für den effektiv agierenden Agenten wie folgt initialisiert:

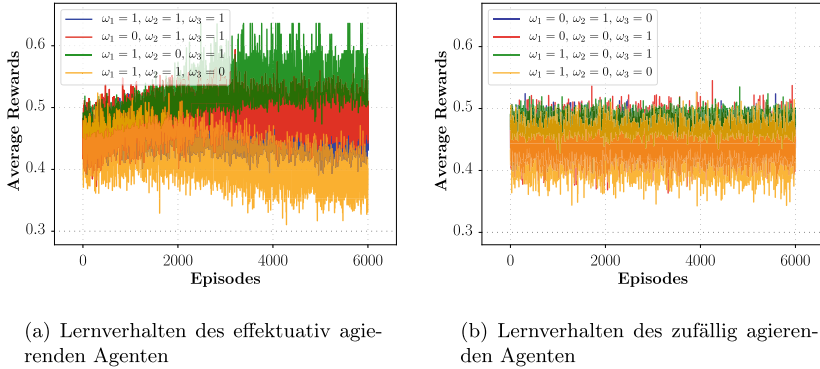
$$\begin{aligned}\varepsilon &= 1 \\ \varepsilon_{min} &= 0.005 \\ \varepsilon_{decay} &= 0.999 \\ \alpha &= 0.65.\end{aligned}$$

Die Untersuchung des Lernverhaltens bei Variation ausgewählter Hyperparameter erfolgt in Abschnitt 5.4.

5.1.2 Leistungsvergleich der Lernverhalten bei teilweiser Variation der Belohnungsfunktion und Interpretation der Ergebnisse

Anhand der in Abschnitt 5.1.1 erläuterten Parameterkonfiguration erfolgt die Gegenüberstellung der mittleren pro Episode erhaltenen Belohnungen eines effektiv agierenden und eines zufällig agierenden Agenten über einen Zeitraum von 6000 Episoden. In Abbildung 5.1 ist dieser Leistungsvergleich illustriert.

Für die Parameterkonfigurationen $\omega_1 = 0, \omega_2 = 1, \omega_3 = 1$ und $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ ist ein Lernverhalten des effektiv agierenden Agenten in Abbildung 5.1a erkennbar. Im Vergleich zum zufällig handelnden Agenten werden über die Zeit im Schnitt höhere Belohnungen erzielt. Dabei ist das Lernverhalten für $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ am deutlichsten ausgeprägt. Bei der



(a) Lernverhalten des effektiv agierenden Agenten

(b) Lernverhalten des zufällig agierenden Agenten

Abb. 5.1 Vergleich des Lernverhaltens des effektiv und zufällig agierenden Agenten bei unterschiedlicher Gewichtung der Konvexkombinationsterme der Belohnungsfunktion

Parameterkonfiguration $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ versucht der effektive Agent gleichzeitig seine Mittel so effizient wie möglich einzusetzen sowie die Marktnachfrage bestmöglich zu befriedigen und lässt dabei die Verbesserung seiner Fähigkeit, einen Kunden korrekt einzuschätzen, außer Acht. Er wird in dieser konkreten Situation am erfolgreichsten sein.

Bei Betrachtung der Ergebnisse bei $\omega_1 = 1, \omega_2 = 1, \omega_3 = 0$ wird deutlich, dass der effektiv handelnde Agent im untersuchten Zeitraum im Mittel schlechter abschneidet als ein Agent, der eine zufällige Strategie verfolgt. Versucht ein effektiver Agent folglich gleichzeitig seinen Mitteleinsatz und seine Fähigkeit Kunden korrekt zu klassifizieren zu optimieren, wird dieser langfristig weniger erfolgreich sein als ein Agent, der ein zufallsbasiertes Entscheidungsverhalten an den Tag legt. Aus Abbildung 5.1a ist nicht erkennbar, ob die Ergebnisse auch nach 6000 Episoden weiterhin einem Abwärtstrend folgen. Abbildung 5.2 illustriert, dass der Erfolg des effektiven Agenten in späteren Episoden im Mittel stabil bleibt.

Allgemein bleiben für die ersten 15000 Episoden die Ergebnisse des effektiven Agenten weiterhin unter denen des zufällig handelnden Agenten.

Inwiefern Leistungsunterschiede zwischen dem effektiven und zufällig agierenden Agenten bei der Parameterkonfiguration $\omega_1 = 1, \omega_2 = 1, \omega_3 = 1$ bestehen, lässt sich aus den Abbildungen 5.1a und 5.1b nicht ohne Weiteres ablesen. Zur besseren Veranschaulichung werden die beiden Agententypen daher in Abbildung 5.3 gegenübergestellt. Es ist ersichtlich, dass der effektiv agierende Agent zu Beginn des Lernprozesses zunächst bessere Ergebnisse als der zufällig handelnde Agent erreicht. Im weiteren Verlauf nimmt die Leistungsfähigkeit jedoch ab und der




Abb. 5.2 Lernverhalten des effektiv agierenden Agenten bei Parameterkonfiguration $\omega_1 = 1, \omega_2 = 1, \omega_3 = 0$

Agent, der eine zufällige Strategie verfolgt, erhält im Mittel größere Belohnungen. Zurückzuführen ist dieses Verhalten erneut auf den Versuch des Agenten, gleichzeitig den Mitteleinsatz zu optimieren und seine Fähigkeit, einen Kunden korrekt einzuschätzen, zu verbessern.

Grundsätzlich lassen sich bei Agenten, die in einer Umgebung mit den Parameterkonfigurationen $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ und $\omega_1 = 0, \omega_2 = 1, \omega_3 = 1$ der Belohnungsfunktion agieren, effektive Lerneffekte nachweisen, da im Mittel höhere Leistungswerte erzielt werden als bei den korrespondierenden zufällig handelnden Agenten. In einer Umgebung, in der bei der Belohnungsfunktion alle Summanden der Konvexkombination gleich gewichtet werden ($\omega_1 = 1, \omega_2 = 1, \omega_3 = 1$) oder die Parameterkonfiguration $\omega_1 = 1, \omega_2 = 1, \omega_3 = 0$




Abb. 5.3 Vergleich des Lernverhaltens des effektiv und zufällig agierenden Agenten bei Parameterkonfiguration $\omega_1 = 1, \omega_2 = 1, \omega_3 = 1$

gegeben ist, kann kein erfolgreiches effektuatives Lernen beobachtet werden. Der gleichzeitige Versuch des Agenten den Mitteleinsatz zu verbessern und seine Klassifizierungsfähigkeiten zu optimieren, führt dazu, dass langfristig kein effektuatives Verhalten erlernt wird. Im Fall, dass der vermeintlich effektuative Agent nicht marktkonform handelt ($\omega_1 = 1, \omega_2 = 1, \omega_3 = 0$), tritt ebenso wenig wie bei $\omega_1 = 1, \omega_2 = 1, \omega_3 = 1$ im betrachteten Beobachtungszeitraum ein Lerneffekt auf.

Da der effektuativ handelnde Agent, der versucht, gleichzeitig seinen Mitteleinsatz und seine Fähigkeit einen Kunden korrekt einzuschätzen zu optimieren, im Vergleich zu einem Agenten, der eine zufällige Strategie verfolgt, schlechter abschneidet, werden in den folgenden Untersuchungen die Parameterkonfigurationen $\omega_1 = 1, \omega_2 = 1, \omega_3 = 0$ und $\omega_1 = 1, \omega_2 = 1, \omega_3 = 1$ nicht weiter berücksichtigt. Für weitere Untersuchungen und Vergleiche stehen folglich die Parameterkonfigurationen $\omega_1 = 0, \omega_2 = 1, \omega_3 = 1$ und $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ zur Verfügung, die grundsätzlich effektuatives Verhalten widerspiegeln. Da ein effektuativer Agent langfristig nur dann erfolgreich sein wird, wenn er es schafft, für das entwickelte Produkt Nachfrage zu erzeugen und sich marktkonform zu verhalten, findet die Konfiguration $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ in den folgenden Betrachtungen Berücksichtigung. Diese erzielte auch das beste Lernverhalten.

5.2 Untersuchung des Lernverhaltens des effektuativen Agenten bei isolierter Betrachtung einzelner Bestandteile der Belohnungsfunktion

In Abschnitt 5.1.2 wurde ein Leistungsvergleich zwischen effektuativem und zufälligem Verhalten entrepreneurialer Agenten angestellt. Dabei wurden Modifikationen der Belohnungsfunktion in die Betrachtung einbezogen, um zu überprüfen, ob auch bei unterschiedlich betontem effektuativen Verhalten Unterschiede zwischen den beiden Agententypen auftreten. Um den konkreten Einfluss der einzelnen Belohnungsfunktionsbestandteile auf das Verhalten des effektuativen Agenten zu untersuchen, ist es sinnvoll, diese isoliert zu betrachten.

5.2.1 Auswahl der Parameterwerte

Zur Bestimmung des Einflusses einzelner Bestandteile der Belohnungsfunktion auf das Lernverhalten eines effektuativen Agenten ist es zweckmäßig, nur jeweils einen Koeffizienten der Konvexkombination mit dem Wert 1 zu versehen, wäh-

rend die anderen beiden Koeffizienten auf 0 gesetzt werden. Es ergeben sich die in Abschnitt 5.1.1 möglichen Parameterkonfigurationen

$$\omega_1 = 1, \omega_2 = 0, \omega_3 = 0$$

$$\omega_1 = 0, \omega_2 = 1, \omega_3 = 0$$

$$\omega_1 = 0, \omega_2 = 0, \omega_3 = 1.$$

Um den Vergleich zum Verhalten eines Agenten herzustellen, der mehrere Aspekte effektuativen Handelns berücksichtigt, wird die Parameterkonfiguration

$$\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$$


ebenfalls betrachtet.

Ebenso wie in Abschnitt 5.1.1 werden $\varphi = \chi = 0.5$ initialisiert und die dort definierten Werte der Hyperparameter angewendet.


5.2.2 Leistungsvergleich der Lernverhalten eines effektuativen Agenten bei isolierter Betrachtung der Belohnungsfunktionsbestandteile und Interpretation der Ergebnisse

Die in Abschnitt 5.2.1 definierten Parameterwerte bilden die Grundlage für die Untersuchung des Lernverhaltens eines effektuativen Agenten bei isolierter Betrachtung der Bestandteile der Belohnungsfunktion aus (4.4) über einen Zeitraum von 6000 Episoden. In Abbildung 5.4a sind die mittleren erreichten Belohnungen pro Episode bei Betrachtung der Belohnungsfunktion mit der Konfiguration $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ eines effektuativen Agenten abgetragen (vgl. hierzu auch Abbildung 5.1a bei Parameterkonfiguration $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$). Zu Beginn des Prozesses ist ein Lernverhalten des Agenten zu beobachten, welches sich in den steigenden mittleren Belohnungen ausdrückt. Im weiteren Verlauf ist kein tendenzieller Anstieg der Leistungswerte mehr zu verzeichnen.


Das Lernverhalten bei ausschließlicher Betrachtung der ersten Komponente der Belohnungsfunktion ($\omega_1 = 1, \omega_2 = 0, \omega_3 = 0$) zeigt sich in Abbildung 5.4b. Die in Gleichung (4.4) formulierte Belohnungsfunktion verkürzt sich auf $r_{t+1} = r^1(m_t)$. Folglich wird lediglich der vermeintlich geschickte Mitteleinsatz des effektuativen Agenten belohnt. In Abbildung 5.4b ist ein Leistungsanstieg zu Beginn des Lernprozesses zu beobachten. Im weiteren Verlauf stabilisiert sich das Verhalten und die




(a) Lernverhalten des effektuativen agierenden Agenten bei Parameterkonfiguration $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$



(b) Lernverhalten des effektuativen agierenden Agenten bei $\omega_1 = 1, \omega_2 = 0, \omega_3 = 0$



(c) Lernverhalten des effektuativen agierenden Agenten $\omega_1 = 0, \omega_2 = 1, \omega_3 = 0$



(d) Lernverhalten des effektuativen agierenden Agenten $\omega_1 = 0, \omega_2 = 0, \omega_3 = 1$

Abb. 5.4 Vergleich des Lernverhaltens des effektuativen Agenten bei isolierter Betrachtung der Konvexkombinationsterme der Belohnungsfunktion

erhaltenen Belohnungen steigen über die Zeit nicht mehr an. Im Zeitverlauf nimmt die Schwankung der Leistungswerte zwischen zwei Episoden ab. Der Agent wird im Umgang mit seinen zur Verfügung stehenden Mitteln sicherer und wendet folglich selbstbewusst das Affordable-Loss-Prinzip an. Das erlernte Verhalten zeigt jedoch auch, dass der Agent im Laufe der Zeit einen Kunden vorrangig als *Nicht-Kunden* klassifizieren wird und damit eher bereit ist Typ-I-Fehler zu begehen. Das steht im Kontrast zum von Sarasvathy (2009, S. 103) beschriebenen typischen effektuativen Verhalten, bei dem Entrepreneurere Typ-II-Fehler in Kauf nehmen, um Typ-I-Fehler zu vermeiden. Der Agent versucht, sich in der Simulation einer mittleren Belohnung von 0.5 anzunähern. Um eine Belohnung vom Wert 0.5 zu erhalten, muss ausgehend

von Gleichung (4.3) $m_t = 1$ sein. Dazu muss der Summand $\frac{M_{t+1}-M_t}{M_0} = 0$ werden. Das ist dann der Fall, wenn die Rechenvorschriften (4.12) und (4.13) zum Tragen kommen, in denen für die Mittel $M_{t+1} = M_t$ gilt und der Agent die Aktion a_1 wählt (Kunde wird als *Nicht-Kunde* klassifiziert).

Die Abbildungen 5.4c und 5.4d verdeutlichen ein effektuatives Lernverhalten des Agenten. Die mittleren erhaltenen Belohnungen steigen zunächst und stabilisieren sich im Laufe der ersten 6000 Episoden. Während die Leistungswerte bei $\omega_1 = 0, \omega_2 = 1, \omega_3 = 0$ einen im Mittel degressiven Verlauf nehmen, verläuft der Anstieg der Leistungswerte bei $\omega_1 = 0, \omega_2 = 0, \omega_3 = 1$ im Mittel näherungsweise linear. Die Leistungswerte unter der Parameterkonfiguration $\omega_1 = 0, \omega_2 = 0, \omega_3 = 1$ weisen zusätzlich im Zeitverlauf stärkere Schwankungen der mittleren erhaltenen Belohnungen auf. Da der Agent unter dieser Konfiguration die Belohnung $r_t = r^3(E_t)$ erhält, wird ausschließlich das Finden optimaler Fitness-Werte belohnt. Wenngleich die erhaltenen Belohnungen im Mittel steigen, werden die Abweichungen von diesem Mittel im Zeitverlauf größer. Durch die Zunahme der Schwankungen sinkt die Prognosesicherheit des Agenten bezüglich der Marktnachfrage.

Zur Veranschaulichung der erreichten mittleren Belohnungen sind in Abbildung 5.5 die Lernergebnisse bei isolierter Betrachtung der Belohnungsfunktionsbestandteile und bei Betrachtung der Parameterkonfiguration $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ abgetragen. Der alleinige Vergleich der erzielten mittleren Belohnungen der unterschiedlichen Parameterkonfigurationen ist aufgrund der verschiedenen Bewertungskriterien der Belohnungsfunktionsbestandteile nicht sinnvoll. Leistungsunterschiede des Lernens können aus Abbildung 5.5 nicht ohne Weiteres abgelesen werden. Es ist daher zweckdienlich, zusätzlich die jeweiligen prozentualen Änderungen der erhaltenen Belohnungen im Beobachtungszeitraum zu vergleichen. Dadurch kann die Effizienz des Lernens des effektuativen Agenten herausgestellt werden. Zur Bestimmung der jeweiligen Anstiege wird die Vorschrift

$$\frac{\sum_{i=j-n+1}^j \text{Average Rewards}_i - \sum_{i=1}^n \text{Average Rewards}_i}{\sum_{i=1}^n \text{Average Rewards}_i} \cdot 100$$




Abb. 5.5 Vergleich des Lernverhaltens des effektuativen Agenten bei isolierter Betrachtung der Belohnungsfunktionsbestandteile und bei Parameterkonfiguration $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$

mit $n = 1000$ und $j = 6000$ angewendet. Dabei stellt *Average Rewards_i* die mittlere erhaltene Belohnung einer Episode dar. Folglich wird die Differenz der mittleren erhaltenen Belohnung der letzten 1000 Episoden des Untersuchungszeitraumes und der mittleren erhaltenen Belohnung der ersten 1000 Episoden gebildet und ins Verhältnis zur mittleren erhaltenen Belohnung der ersten 1000 Episoden gesetzt.

Es ist zu beobachten, dass der Agent bei der Parameterkonfiguration $\omega_1 = 0, \omega_2 = 0, \omega_3 = 1$ die höchste prozentuale Änderung erreicht. Bei Parameterkonfiguration $\omega_1 = 0, \omega_2 = 1, \omega_3 = 0$ erzielt der Agent die zweitbesten und bei $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ die drittbesten Ergebnisse. Liegt der Fokus des Agenten allein auf der Optimierung des Mitteleinsatzes ($\omega_1 = 1, \omega_2 = 0, \omega_3 = 0$), ist die Lerneffizienz am geringsten. Diese Beobachtung schwächt das Argument, dass Entrepreneurere vorrangig das Affordable-Loss-Prinzip anwenden sollen. Diese Erkenntnis deckt sich mit den Ergebnissen von Deligianni et al. (2015), die keine signifikanten Effekte durch Anwendung des genannten Prinzips im Kontext von Produkt-Diversifikationsmaßnahmen auf den Unternehmenserfolg feststellen konnten. Erst in Verbindung mit der Befriedigung der Marktnachfrage ($\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$) durch den effektuativen Agenten wird eine höhere Lerneffizienz erzielt und der geschickte Mitteleinsatz führt zu vergleichsweise besseren Ergebnissen.

5.3 Untersuchung verschiedener Lernverhalten bei Manipulation der Transitionswahrscheinlichkeiten

Die Modelldynamik eines RIL-Problems lässt sich mithilfe von Wahrscheinlichkeiten von Zustandsübergängen (Transitionswahrscheinlichkeiten) darstellen. Sie drücken die Unsicherheit aus, mit der ein Agent konfrontiert ist, wenn dieser eine Entscheidung hinsichtlich des weiteren Vorgehens treffen muss. Für ihn ist, ausgehend vom aktuellen Zustand und nach Ausführung einer bestimmten Aktion, nicht sicher, ob er in einem von ihm gewünschten nächsten Zustand gelangen wird. Im vorliegenden Modell sind die Transitionswahrscheinlichkeiten dem Agenten nicht bekannt und nur dem Modellierer zugänglich. Diese Konstruktion erlaubt die Durchführung kontrollierter Experimente. In der folgenden Untersuchung werden die erreichten Leistungswerte der Agenten bei sich ändernden Wahrscheinlichkeiten vorgestellt und diskutiert.

5.3.1 Auswahl der Parameterwerte

Die im Modell verwendete Formel (4.9) zur Bestimmung der Transitionswahrscheinlichkeiten beruht auf einem empirischen Wert und wird als unveränderbar angenommen. Die Wahrscheinlichkeit für die Ereignisse, dass ein Kunde ein *echter Kunde* ist und auch als *echter Kunde* klassifiziert wird, wird in der Untersuchung als fix festgelegt und auf 0.307 gesetzt. Ein weiterer Teil der zu Grunde liegenden Wahrscheinlichkeiten wird als variabel modelliert. Die mittleren Belohnungen der Agenten werden bei diskreten Werten der in den Gleichungen (4.6) und (4.7) formulierten Wahrscheinlichkeiten betrachtet. Bei der Untersuchung der Lernverhalten der Agenten wird für jeden Verlauf $\varphi = \chi$ gesetzt. Für die untersuchten Wahrscheinlichkeiten φ und χ gilt


$$\varphi, \chi \in \{0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.693\}. \quad (5.3)$$

Um zu vermeiden, dass Transitionswahrscheinlichkeiten außerhalb des Intervalls $[0, 1]$ liegen, muss $0 \leq \varphi \leq 0.693$ gewählt werden. Dieser Umstand ergibt sich aus der Wahl von $P(\text{Class}0 \cap a0) = 0.307$ und Anwendung der Rechenvorschrift für ψ aus Gleichung 4.9.


Zur Bestimmung der Belohnungsfunktion wird die Parameterkonfiguration $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ verwendet, wodurch der erste und dritte Summand der Konvexkombination in die Berechnung einbezogen werden. Es werden dieselben Werte der Hyperparameter für $\varepsilon, \varepsilon_{min}, \varepsilon_{decay}$ und α wie in Abschnitt 5.1.1 verwendet.

5.3.2 Leistungsvergleich der Lernverhalten bei Variation der Transitionswahrscheinlichkeiten und Interpretation der Ergebnisse

In Abbildung 5.6 sind die mittleren erreichten Belohnungen über die Zeit – in Form von Episoden – eines effektiv agierenden und eines zufällig handelnden Agenten bei variierenden Transitionswahrscheinlichkeiten dargestellt. Eine Einzelbetrachtung der Ergebnisse bei Variation der Transitionswahrscheinlichkeiten ist in Anhang D.1 im elektronischen Zusatzmaterial zu finden. Der effektive Agent, dessen Lernverhalten in Abbildung 5.6a illustriert ist, erreicht für alle untersuchten Transitionswahrscheinlichkeiten im Laufe des Lernprozesses durchschnittlich höhere Leistungswerte als der zufällig agierende Agent, dessen Verhalten in Abbildung 5.6b abgetragen ist.



(a) Lernverhalten des effektiv agierenden Agenten bei Änderung der Wahrscheinlichkeiten



(b) Lernverhalten des zufällig agierenden Agenten bei Änderung der Wahrscheinlichkeiten


Abb. 5.6 Vergleich des Lernverhaltens des effektiv und zufällig agierenden Agenten bei Änderung der Transitionswahrscheinlichkeiten

In Abbildung 5.6a ist ersichtlich, dass bei $\varphi = \chi = 0.7$ ¹ die im Mittel höchsten Leistungswerte des effektiven Agenten erreicht werden. Zurückzuführen ist dieses Verhalten auf eine für den Agenten günstige Konstellation der Transitionswahrscheinlichkeiten. Unabhängig davon, welche Aktion der Agent wählt, werden


¹ Zur besseren Lesbarkeit der Wahrscheinlichkeiten φ und χ wird in den folgenden Ausführungen und Abbildungen der Wert 0.7 (statt, wie in der Fallunterscheidung (5.3), 0.693) dargestellt. Während des Trainings des Agenten wurde mit dem tatsächlichen Wert 0.693 gerechnet.

mit Wahrscheinlichkeit 1 nur die nächsten Zustände erreicht, bei denen das Klassifizierungsmerkmal des Kunden *echter Kunde* (*Class0*) lautet. Dadurch verringert sich der Zustandsraum des Agenten, für den er versucht, eine optimale Strategie zu erlernen sowie die möglichen Belohnungen für seine Entscheidungen. Der Agent trifft ausschließlich Kunden, die bereit sind, tatsächlich in die Unternehmung zu investieren, wenn eine Produktpassung vorgenommen wurde. Dies ermöglicht es dem Agenten, seinen Mitteleinsatz effizient zu gestalten und entsprechend leistungsfähiger zu agieren.

Zur besseren Nachvollziehbarkeit des trendmäßigen Verhaltens des effektuativen und zufällig handelnden Agenten bei sich ändernden Transitionswahrscheinlichkeiten, ist in Abbildung 5.7a der gleitende Mittelwert² der pro Episode erhaltenen mittleren Belohnungen abgetragen. Wie bereits in Abbildung 5.6a ist auch in Abbildung 5.7a erkennbar, dass der effektuative Agent in einer Umgebung mit $\varphi = \chi = 0.7$ die im Mittel besten Ergebnisse erzielt. Der zufällig handelnde Agent erreicht bei $\varphi = \chi = 0$ und $\varphi = \chi = 0.7$, im Vergleich zu allen anderen Transitionswahrscheinlichkeiten, die höchsten Leistungswerte. Zurückzuführen ist dies erneut auf eine für den Agenten günstige Konstellation der Transitionswahrscheinlichkeiten. In einer Umgebung mit $\varphi = \chi = 0.7$ wird der Agent lediglich auf *echte Kunden* treffen. Zur Berechnung der Mittel m_t kommen nur die Berechnungsvorschriften (4.10) und (4.12) zum Tragen, wodurch sich $m_t \geq 1$ ergibt und folglich



(a) Trendmäßige Betrachtung des Lernverhaltens des effektuativ agierenden Agenten bei Änderung der Transitionswahrscheinlichkeiten



(b) Trendmäßige Betrachtung des Lernverhaltens des zufällig agierenden Agenten bei Änderung der Transitionswahrscheinlichkeiten

Abb. 5.7 Betrachtung des Lernverhaltens des effektuativ und zufällig agierenden Agenten bei Änderung der Transitionswahrscheinlichkeiten

² Als Fenstergröße wurde der Wert 100 gewählt.

für $r^1(m_t) \geq 0.5$ gilt. Für den Fall, dass $\varphi = \chi = 0$ ist, werden zur Berechnung von m_t nur die Vorschriften aus (4.10) und (4.13) verwendet und es folgt analog $m_t \geq 1$ und $r^1(m_t) \geq 0.5$. In Abbildung 5.7a wird dieses Verhalten ebenfalls deutlich. Der effektuate Agent geht zu Beginn des Lernprozesses explorativ vor (ε ist nahe dem Wert 1) und wählt seine Aktionen überwiegend zufällig aus. Der Agent erreicht bei einer Umgebung, die von $\varphi = \chi = 0$ und $\varphi = \chi = 0.7$ bestimmt wird, ähnliche Ergebnisse.

5.4 Untersuchung des Lernverhaltens des effektuativen Agenten bei Manipulation ausgewählter Hyperparameter

RIL-Probleme, die mit Hilfe von Q-Learning gelöst werden, konvergieren unter milden Voraussetzungen hin zu einer optimalen Action-Value-Funktion und folglich optimalen Strategie des Agenten (Tsitsiklis, 1994). Die optimale Strategie ermöglicht es dem Agenten, die im Mittel höchsten Belohnungen innerhalb der Umgebung einzusammeln. Durch Variation der Lernrate α kann die Geschwindigkeit, mit der die optimale Strategie gefunden wird, beeinflusst werden (Watkins & Dayan, 1992).

5.4.1 Bestimmung des Parameterraums bei Variation ausgewählter Hyperparameter

Die Untersuchung des Mittleren Quadratischen Fehlers sowie der mittleren erhaltenen Belohnungen geben Aufschluss über die Geschwindigkeit und Stabilität des Lernens eines Agenten. Mittels der beiden genannten Gütemaße kann bestimmt werden, zu welchem Zeitpunkt eine optimale Strategie annähernd erreicht ist und diese bestmöglich ausgenutzt wird.

Die Betrachtung des Mittleren Quadratischen Fehlers über die Zeit gibt Aufschluss darüber, wann eine optimale Strategie gefunden wurde (Monekosso & Remagnino, 2004). Die Strategie ist optimal, wenn der Mittlere Quadratische Fehler ausreichend klein ist. Ab welchem Zeitpunkt die optimale Strategie bestmöglich ausgenutzt wird, kann nicht nur durch diesen Wert bestimmt werden. Zusätzlich muss dafür das Stabilitätsverhalten der mittleren Belohnungen über die Zeit betrachtet werden (Poole & Mackworth, 2017, Kap. 12.6). Werden die pro Episode erhaltenen Belohnungen über eine ausreichend lange Zeit im Mittel nicht größer oder kleiner, wird die bis dahin erlernte Strategie bestmöglich ausgenutzt.

Die Geschwindigkeit des Findens einer optimalen Strategie kann durch Änderung der Lernrate α beeinflusst werden. Zur Diskussion des Einflusses des Hyperparameters werden folgende Werte untersucht:

$$\alpha \in \{0.2, 0.4, 0.6, 0.8, 1\}.$$

Der Wert $\alpha = 0$ wird in der Untersuchung nicht betrachtet. Wird dieser Wert in den Q-Learning-Algorithmus aus (4.1) eingesetzt, wird keine Aktualisierung der initialen q -Werte über die Zeit ausgeführt. Entsprechend kann kein Lernverhalten des Agenten beobachtet werden und die q -Werte ändern sich nicht. Die Aktualisierungsfunktion aus (4.1) lässt sich in diesem Fall zu

$$\begin{aligned} q(s_t, a_t) &\leftarrow q(s_t, a_t) + 0 \cdot \left[r_{t+1} + \gamma \max_a q(s_{t+1}, a) - q(s_t, a_t) \right] \\ q(s_t, a_t) &\leftarrow q(s_t, a_t) \end{aligned}$$

zusammenfassen. Der Agent folgt über dem Beobachtungszeitraum einer zufälligen Strategie, da die in den Episoden erhaltenen Belohnungen keinen Einfluss auf die zu aktualisierenden q -Werte haben. Für alle $s \in S$ und $a \in A$ ist zu Beginn und am Ende der Simulation $q(s, a) = 0$.

Der Diskontierungsfaktor γ wird bei der Untersuchung der Lerngeschwindigkeit nicht variiert. Aufgrund der in Abschnitt 4.2.2 erläuterten Annahmen ist γ ein fixer Bestandteil des Modells und nicht als Optimierungsparameter zu verwenden.

Der Hyperparameter ε dient der Steuerung des Explorations-Exploitations-Verhaltens des Agenten. Ein Agent wählt mit Wahrscheinlichkeit $1 - \varepsilon$ die bestmögliche Aktion der bisher erlernten Strategie. Um eine Balance zwischen explorativem und exploitativem Verhalten zu erreichen, wird ε durch Multiplikation mit ε_{decay} in jeder Episode im Laufe des Lernprozesses verringert. Zu Beginn des Lernens wählt der Agent überwiegend zufällige Aktionen, um zu verhindern, in einem lokalen Minimum zu verweilen. Gegen Ende der Lernphase wird der Agent überwiegend Aktionen anhand der bis dahin ermittelten Strategie wählen und das bis dahin erlernte Wissen über den Zustandsraum und dessen Belohnungssystem anwenden. Um dem Agenten dennoch zu ermöglichen seine Strategie zu optimieren, wählt der Agent mit einer gewissen Rest-Wahrscheinlichkeit ε_{min} eine zufällige Aktion aus. Dieses Vorgehen wird als *Exponentially decaying ε -greedy exploration strategy* bezeichnet (Morales, 2020, Kap. 9.1.5).

Um zu ermitteln, über welchen Zeitraum es für den Agenten sinnvoll ist sich explorativ zu verhalten und damit eine partiell nicht-effektive Strategie zu verfolgen, werden die Werte für ε_{decay} variiert. Aufgrund der Größe des Zustandsraumes

werden vergleichsweise große Werte für ε_{decay} gewählt. Dabei wird der Einfluss der folgenden Werte auf das Lernverhalten untersucht:


$$\varepsilon_{decay} \in \{0.99, 0.995, 0.999, 0.9995\}.$$

Für die Untersuchung der Hyperparameter wird erneut $\varphi = \chi = 0.5$ gesetzt und die Belohnungsfunktion aus Gleichung 4.4 mit einer Parameterkonfiguration von $\omega_1 = 1, \omega_2 = 0, \omega_3 = 1$ vorausgesetzt.


5.4.2 Vergleich der Lerngeschwindigkeiten bei Variation der Lernrate und Interpretation der Ergebnisse

Zur Feststellung der Auswirkungen der Lernraten auf die mittleren erhaltenen Belohnungen des Agenten und das Konvergenzverhalten wird der betrachtete Lernzeitraum auf 15000 Episoden verlängert. Dadurch wird ermöglicht, dass sich das Lernverhalten des effektuativen Agenten auch bei kleinen Lernraten mit der Zeit stabilisiert.

Die Abbildungen 5.8a und 5.8b zeigen die mittleren erhaltenen Belohnungen des Agenten bei variierenden Lernraten. Abbildung 5.8a illustriert die mittleren Belohnungen über alle Episoden, während in Abbildung 5.8b das gleitende Mittel der mittleren Belohnungen mit einer Breite von 100 aufeinanderfolgenden Episoden



(a) Betrachtung der mittleren erhaltenen Belohnungen des effektuativen Agenten bei Änderung der Lernrate zu bestimmten Zeitpunkten




(b) Betrachtung des gleitenden Mittelwertes der mittleren erhaltenen Belohnungen des effektuativen Agenten bei Änderung der Lernrate

Abb. 5.8 Betrachtung der mittleren erhaltenen Belohnungen des effektuativen Agenten bei Änderung der Lernrate


abgetragen ist. In Anhang D.2 im elektronischen Zusatzmaterial sind die mittleren erhaltenen Belohnungen bei unterschiedlichen Lernraten über die Gesamtheit der Episoden illustriert. Es wird deutlich, dass bei den Lernraten $\alpha = 0.6$, $\alpha = 0.8$ bzw. $\alpha = 1$ zum Ende des Lernprozesses ein ähnliches Niveau der mittleren erhaltenen Belohnungen erreicht wird. Ist $\alpha = 0.4$ bleiben im Beobachtungszeitraum die Ergebnisse unterhalb dieses Niveaus. Bei einer Lernrate von $\alpha = 0.2$ sind die Leistungsunterschiede zu den anderen untersuchten Lernraten noch ausgeprägter. Ist ein effektuativer Agent demnach kaum gewillt durch neu hinzugewonnene Erfahrungen sein Verhalten zu ändern ($\alpha = 0.2$), wird er zunächst vergleichsweise schlechtere Leistungswerte erzielen. Er wird nicht das für Effectuation typische Lemonade Prinzip anwenden (Read & Sarasvathy, 2005). Dieses Prinzip beschreibt „[...] the entrepreneur’s willingness to change when confronted with new information, means or surprises.“ (Read, Song et al., 2009, S. 574).

Anhand der in Abbildung 5.8 dargestellten Lernverhalten kann nicht abschließend festgestellt werden, welche Lernrate im Kontext effektuativen Verhaltens zu bestmöglichen Ergebnissen für den Agenten führen. Zusätzlich ist es notwendig, das Konvergenzverhalten bei Variation der Lernraten zu betrachten, da dieses Auskunft darüber gibt, wie schnell ein Agent eine näherungsweise optimale Strategie findet.

In Abbildung 5.9a ist der Mittlere Quadratische Fehler der zu untersuchenden Lernraten über 15000 Episoden zu sehen. Es zeigt sich, dass in allen Fällen mit der



(a) Betrachtung des des Mittleren Quadratischen Fehlers des effektuativ agierenden Agenten bei Änderung der Lernrate



(b) Betrachtung der mittleren erhaltenen Belohnungen des effektuativ agierenden Agenten im Verhältnis zu den Mittleren Quadratischen Fehlern bei Änderung der Lernrate

Abb. 5.9 Betrachtung der mittleren erhaltenen Belohnungen und des Mittleren Quadratischen Fehlers des effektuativ agierenden Agenten bei Änderung der Lernrate


Zeit eine Stabilisierung der Mittleren Quadratischen Fehler eintritt und die Werte gegen Null konvergieren. Nimmt der Agent kaum noch Änderungen seiner Strategie vor – der Mittlere Quadratische Fehler ist demnach nahe Null – hat der Agent eine annähernd optimale Strategie zur Interaktion in der Umgebung gefunden. Es wird deutlich, dass mit sinkenden Werten der Lernrate α zu Beginn des Lernprozesses auch geringere Mittlere Quadratische Fehler zu verzeichnen sind und die Lerngeschwindigkeit (erkennbar an der Anzahl der Episoden nach denen der Mittlere Quadratische Fehler nahe Null ist) steigt.

Da auch die Lerngeschwindigkeit nicht einzig zur Bestimmung der in diesem Kontext bestmöglichen Lernrate ausreicht, ist eine gemeinsame Betrachtung der mittleren erhaltenen Belohnungen und des Mittleren Quadratischen Fehlers sinnvoll. Abbildung 5.9b verdeutlicht den Zusammenhang zwischen der gemeinsamen Entwicklung der beiden Gütekriterien. Es ist ersichtlich, dass grundsätzlich mit sinkendem Mittleren Quadratischen Fehler die mittleren Belohnungen steigen. Ein Kompromiss zwischen hoher Lerngeschwindigkeit und schnellem Stabilisierungsverhalten der mittleren Belohnungen wird bei einer Lernrate von $\alpha = 0.6$ erreicht. In diesem Zusammenhang ist es für den effektuativen Agenten folglich sinnvoll zu einem überwiegenden Teil neue Erfahrungen in sein Entscheidungsverhalten einfließen zu lassen, ohne bestehendes Wissen vollständig zu verwerfen.

5.4.3 Vergleich der Lerngeschwindigkeiten bei Variation des Explorationsabnahmefaktors und Interpretation der Ergebnisse

Um untersuchen zu können, inwieweit die Geschwindigkeit, mit der ein Agent von einem explorativen zu einem exploitativen Verhalten wechselt, Einfluss auf das Lernverhalten hat, werden Werte für ε_{decay} aus der in Abschnitt 5.4.1 definierten Menge zu Grunde gelegt. Des Weiteren wird der in Abschnitt 5.4.2 diskutierte Hyperparameterwert $\alpha = 0.6$ für den Lernprozess vorausgesetzt. Wiederum wird der Betrachtungszeitraum auf 15000 Episoden festgelegt.

In Abbildung 5.10a ist der gleitende Mittelwert der mittleren erhaltenen Belohnungen bei unterschiedlichen Werten von ε_{decay} abgetragen. Dabei wird deutlich, dass, bei einem vergleichsweise langsamen Wechsel des Agenten von einem explorativem zu einem exploitativen Verhalten ($\varepsilon_{decay} = 0.999$ und $\varepsilon_{decay} = 0.9995$), im Untersuchungszeitraum grundsätzlich höhere Leistungswerte erzielt werden. Verhält sich der Agent demnach länger explorativ und experimentiert in der Umgebung, kann dieser schneller höhere Leistungswerte erzielen. Die positiven Auswirkungen des Experimentier-Verhaltens des Agenten, der zunächst die Dynamiken der



(a) Betrachtung des gleitenden Mittelwertes der mittleren erhaltenen Belohnungen des effektiv agierenden Agenten bei Änderung des Explorationsabnahmefaktors

(b) Betrachtung der mittleren erhaltenen Belohnungen des effektiv agierenden Agenten im Verhältnis zu den Mittleren Quadratischen Fehlern bei Änderung des Explorationsabnahmefaktors

Abb. 5.10 Betrachtung der mittleren erhaltenen Belohnungen und der Mittleren Quadratischen Fehler des effektiv agierenden Agenten bei Änderung des Explorationsabnahmefaktors

Umgebung nicht kennt, decken sich mit den Erkenntnissen von Chandler et al. (2011), die auf eine positive Korrelation von Ungewissheit und Experimentierfreudigkeit hindeuten. Allerdings zeigt sich auch, dass der Agent bei $\epsilon_{decay} = 0.9995$ länger benötigt, um ein ähnliches Leistungsniveau wie der Agent bei $\epsilon_{decay} = 0.9995$ zu erreichen. Ab einem gewissen Punkt wirkt sich die Experimentierfreudigkeit demnach bereits wieder negativ auf einen zügigen Erfolg aus.

Abbildung 5.10b zeigt den Zusammenhang zwischen Mittlerem Quadratischen Fehler und den mittleren erhaltenen Belohnungen bei unterschiedlichen Werten für ϵ_{decay} . Es zeigt sich, dass bei $\epsilon_{decay} = 0.999$ und $\epsilon_{decay} = 0.9995$ der Mittlere Quadratische Fehler im Betrachtungszeitraum tendenziell geringer wird. Für Werte von $\epsilon_{decay} = 0.99$ und $\epsilon_{decay} = 0.995$ ist dieses Verhalten nicht erkennbar. Es zeigt sich, dass bei $\epsilon_{decay} = 0.99$ und $\epsilon_{decay} = 0.995$ auch bereits für vergleichsweise kleine mittlere Belohnungen der Mittlere Quadratische Fehler klein ist.

Trotz der vergleichsweise geringen Mittleren Quadratischen Fehler des Agenten bei $\epsilon = 0.99$ und $\epsilon = 0.995$ bei geringen Werten der mittleren erhaltenen Belohnungen, die auf den geringen Lerneffekt des Agenten zurückzuführen sind, werden bei $\epsilon = 0.999$ die höchsten mittleren erhaltenen Belohnungen erzielt. Im Rahmen der untersuchten Werte für ϵ_{decay} ist es für einen effektiv handelnden Agenten folglich günstig sich länger explorativ zu verhalten und sein Gründungsumfeld durch experimentelles Verhalten ausgiebiger zu untersuchen.

Open Access Dieses Kapitel wird unter der Creative Commons Namensnennung 4.0 International Lizenz (<http://creativecommons.org/licenses/by/4.0/deed.de>) veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden.

Die in diesem Kapitel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.





Ziel der Arbeit war es, Effectuation um einen prozessorientierten Beitrag zu erweitern und effektuates Lernen aufbauend auf bestehenden Modellen in die Betrachtung einzubeziehen. Im Folgenden sollen die gewonnenen Erkenntnisse in zusammengefasster Form dargestellt werden. Die daraus abgeleiteten Grenzen der Untersuchung geben Aufschluss über den weiteren Forschungsbedarf. Darauf aufbauend werden Implikationen für Theorie und Praxis herausgestellt und Vorschläge für künftige Untersuchungen erarbeitet.

6.1 Zusammenfassung

Um den aktuellen Stand der Effectuation-Forschung zu überblicken, wurde zunächst eine strukturierte Literaturanalyse durchgeführt. Dabei wurde anhand der von Wolfswinkel et al. (2013) vorgeschlagenen Rahmenbedingungen Literatur ausgewählt und diskutiert. Durch Eingrenzung der zu analysierenden Literatur und den daraus abgeleiteten Forschungsbedarf konnte die für die Untersuchung relevante Fragestellung identifiziert werden.

Um darüber hinaus ein grundlegendes Verständnis für effektuates Schließen zu schaffen, wurden entscheidungstheoretische Aspekte im Kontext von Effectuation durchleuchtet und kritisch diskutiert. Hierbei wurde der durch Sarasvathy (2009) eingeführte Vergleich zwischen effektuativer Inferenz und bayesschem Schließen weitreichender als bisher untersucht. Diesbezüglich wurden bisherige Ungenauigkeiten bei der Verwendung bayesianischer Konzepte und Zusammenhänge aufgearbeitet und in eine mathematisch notierte Definition überführt. Dadurch ist es künftig möglich, Effectuation präziser von bestehenden Entscheidungstheorien abzugrenzen.

Des Weiteren wurden Verfahren des maschinellen Lernens vorgestellt, die grundsätzlich die Möglichkeit bieten, das Konzept der Ungewissheit abzubilden und autonomes Entscheiden von Agenten zu modellieren. Yang und Chandra (2013) fordert in diesem Zusammenhang, dass agentenbasierte Modellierung unter Verwendung Künstlicher Intelligenz in die Entrepreneurship-Forschung Einzug hält. Aufgrund des von Gupta et al. (2016) beschriebenen Bedarfs, Effectuation aus prozesstheoretischer Sicht in den Fokus zu stellen, wurde die Funktionsweise von RIL – als prozessbasiertes Lernsystem – ausführlich diskutiert.

Außerdem sollten bestehende Modellierungsansätze, die die algorithmische Interpretation von Effectuation erlauben, evaluiert werden. Die Gegenüberstellung und Diskussion bestehender Modelle dienen der Zusammenfassung geeigneter Modellelemente und Erforschung bisher vernachlässigter Modellierungsaspekte, die Effectuation technisch-mathematisch abbildbar machen. Daher wurden die Modelle von Mauer et al. (2017), Welter und Kim (2018) und Eberz (2018) deskriptiv dargestellt und bisher lediglich verbal beschriebene Elemente und Wirkungsweisen der Modelle in eine mathematische Form übertragen.

Durch die explizite Darstellung der Modelle konnte eine Gegenüberstellung der verwendeten Eingangsgrößen, Ausgangsgrößen und Methodiken vorgenommen werden. Zudem wurden die Modelle von Mauer et al. (2017) und Welter und Kim (2018) in replizierter Form implementiert und Simulationsergebnisse verglichen. Dabei konnte die grundsätzliche Argumentation, unter welchen Bedingungen Effectuation Causation überlegen ist, nachvollzogen werden. Abweichungen zwischen den ursprünglichen und den replizierten Simulationsergebnissen ergeben sich jedoch unter Verwendung spezifischer Modellparameter, die zu unterschiedlichen Leistungswerten führen. Grundlegende Aussagen zur Leistungsfähigkeit von Effectuation und Causation in verschiedenen Umgebungssituationen blieben trotz der Unterschiede erhalten.

Die aus der Gegenüberstellung und Nachmodellierung gewonnenen Erkenntnisse bilden die Grundlage für ein aggregiertes Modell, das bestehende Ansätze um Aspekte effektuativen Lernens ergänzt. Damit soll das von Sarasvathy (2001) eingeführte Theoriengerüst methodisch erweitert und ein Beitrag zur Effectuation-Forschung geleistet werden. Durch die Bereitstellung des RIL-Effectuation-Modells, welches effektuatives Lernen explizit und interpretierbar formuliert, wird die Grundlage für entscheidungsunterstützende Systeme im Gründungsumfeld geschaffen. Das in Kapitel 4 entwickelte Modell erlaubt es einem effektuativen Agenten, eine entrepreneurial Problemstellung zu bearbeiten.

Durch die Verwendung von RIL- und agentenbasierter Methoden wurde die Operationalisierung des entrepreneurial Problemraums (*knightische Ungewissheit, Ziel-Ambiguität, Informationsisotropie*) realisiert. Die Modellierung einer

Belohnungsfunktion, die effektuatives Verhalten motiviert, erlaubt es einem Agenten Effectuation zu erlernen und steht damit im Kontrast zu den fixierten Regelsätzen von Mauer et al. (2017) und Welter und Kim (2018), die die Entscheidungen eines Agenten von der Umgebungsdynamik entkoppeln. Zudem wurde mit der Formulierung des Problemraums als MDP die Möglichkeit geschaffen, die Umgebung mittels Zuständen zu modellieren. Diese stellen Beobachtungvektoren dar, die die Wahrnehmung eines Agenten widerspiegeln. Die in einem Zustand erfassten Merkmale sind grundsätzlich erweiterbar.

Die Ergebnisse der mit dem entwickelten Modell durchgeführten Untersuchung zeigen, dass Effectuation durch einen autonom agierenden Agenten erlernbar ist. Anhand der modellierten Umgebung wurden geeignete Parameter identifiziert, die effektuatives Lernen begünstigen. Die Bestimmung der auf Grundlage der Güte-*maße Average Rewards* und *MSE* bestmöglichen Hyperparameter α und ϵ_{decay} geben Aufschluss darüber, zu welchem Grad neue Erfahrungen und exploratives Verhalten für den effektuativen Lernfortschritt förderlich sind. Es konnte weiterhin nachgewiesen werden, dass das Affordable-Loss-Prinzip unter den gegebenen Bedingungen nur unter bestimmten Voraussetzungen einen positiven Effekt auf die Leistungs- und Lernfähigkeit des effektuativen Agenten hat. Eine gleichzeitige Belohnung des effektuativen Mitteleinsatzes sowie der korrekten Einschätzung eines Kunden führen zu keinem positiven Lerneffekt des Agenten.

Die zu Beginn der Arbeit gestellte Forschungsfrage konnte durch die Gegenüberstellung bestehender effektuativer Simulationsmodelle, Aggregation der Modellierungsansätze und Erweiterung um Komponenten des Lernens beantwortet werden. Durch die Formalisierung von Effectuation wurde die Grundlage geschaffen, die Theorie in ihrer Wirkungsweise transparent und reproduzierbar zu machen. Die Synthese bisheriger Modellierungsansätze in Verbindung mit der Ergänzung um Elemente effektuativen Lernens hat eine Standardisierung der Effectuation-Theorie ermöglicht. Der Einsatz Künstlicher Intelligenz, in Form von RIL, um entrepreneuriales Verhalten abzubilden, stellt einen neuen methodischen Ansatz zur Modellierung effektuativen Handelns dar. Einem effektuativ agierenden Agenten wird es möglich, autonom in einer Gründungssituation Entscheidungen zu treffen und unternehmerisches Handeln zu erlernen.

Aus den Ergebnissen der Untersuchung lässt sich für die unternehmerische Praxis ableiten, dass Entrepreneur, die ihren Fokus auf den geschickten Mitteleinsatz setzen und dabei gleichzeitig das Feedback von Konsumenten hinsichtlich gewünschter Funktionalitäten eines Produktes abfragen, langfristig eher erfolgreich sein werden. Versuchen Entrepreneur sich gleichzeitig auf den Mitteleinsatz und die Verbesserung ihrer Fähigkeit einen Kunden korrekt einzuschätzen zu konzentrieren, kann das zu einer verminderten Leistungsfähigkeit der Unternehmung führen. Zudem ist

der Erfolg für effektiv handelnde Entrepreneur*innen abhängig von der Dynamik der Gründungssituation und der Verbindlichkeit ihrer potentiellen Partner bzw. Kunden. Treffen Entrepreneur*innen die Entscheidung, ein Produkt aufgrund von Kundenfeedback anzupassen, werden sie umso erfolgreicher sein, je eher Partner sich kooperativ verhalten und bereit sind in die weitere Produktentwicklung zu investieren. Es lässt sich außerdem feststellen, dass Entrepreneur*innen, die ihr Verhalten aufgrund neu hinzugewonnener Informationen anpassen, ihre Unternehmung schneller zum Erfolg führen können und so dem von Read und Sarasvathy (2005) formulierten Lemonade Prinzip folgen. Die positiven Auswirkungen von hoher Experimentierfreudigkeit in einem besonders ungewissen Gründungsumfeld, wie bereits Chandler et al. (2011) konstatierte, konnten ebenfalls bestätigt werden. Exploratives Verhalten führt demnach schneller zum Erfolg einer Unternehmung im Sinne der Effectuation-Theorie.

6.2 Limitationen

ABM beruhen aus Gründen der Komplexitätsreduktion auf Annahmen (Fioretti, 2012). Dadurch kann das realweltliche Phänomen nur unter Einschränkungen erfasst werden (Bonabeau, 2002). Das im Modell verwendete Entscheidungsproblem basiert auf der von Sarasvathy (2009) vorgeschlagenen Gründungssituation *the initial commitment*, welches ausgewählte Aspekte der Herausforderungen repräsentiert, mit denen ein Entrepreneur zu Beginn einer Unternehmung konfrontiert wird. Die damit einhergehende Abstraktion eines Teils des Gründungsprozesses vernachlässigt operationalisierbare Bestandteile effektiven Entscheidens (Chandler et al., 2011). Dadurch kann eine entrepreneuriale Entscheidungssituation nicht vollumfänglich abgebildet werden. Das die Entscheidung beeinflussende Kriterium, dass möglicherweise ein weiterer Kunde existiert, der bereit ist, das Produkt ohne Anpassung zu kaufen und einen höheren Preis pro Einheit zu bezahlen als ursprünglich vom Entrepreneur gefordert, wurde im Modell nicht explizit als Bestandteil der Belohnungsfunktion berücksichtigt. Wenngleich die Modellierung des Zustandsraumes es grundsätzlich ermöglicht, dieses Verhalten abzubilden, geht mit der Einbeziehung des Kriteriums eine weitreichende Anpassung der Belohnungsfunktion einher, die einer weiteren Untersuchung bedarf.

Um verschiedene Entwicklungen von Gründungsprozessen zu simulieren, wurde die Umgebungsdynamik variiert. Dies ermöglichte die Untersuchung der Leistungsfähigkeit des Agenten bei unterschiedlichem Verhalten der Kunden. Die Einbeziehung empirischer Werte zur Modellierung der Transitionswahrscheinlichkeiten wurde mit Hilfe der vom Center for Venture Research (2019) veröffentlichten Investitionsrate von Wagniskapitalgebern umgesetzt. Aufgrund des Mangels an weiteren

empirischen Werten wurde bei der Untersuchung das Indifferenzprinzip angewendet, welches für den Einsatz bei fehlenden Informationen geeignet ist. Es ist davon auszugehen, dass realweltliche Zustandsübergänge in Gründungssituationen dem Indifferenzprinzip nicht uneingeschränkt folgen.

Weiterhin umfassen die Zustände des Zustandsraums Merkmale, die auf Basis der von Welter und Kim (2018) und Mauer et al. (2017) beschriebenen Modellierungsvorschläge und der Konzeptualisierung der dem Entrepreneur zur Verfügung stehenden Mittel umgesetzt wurden. Eine weitere Operationalisierung gründungsrelevanter Aspekte wurde bisher nicht in die Modellierung einbezogen, um die grundlegenden Wirkungsweisen des Modells nachvollziehbar zu gestalten. Grundsätzlich ist das erarbeitete Modell diesbezüglich jedoch anpassbar.

Das im Modell verwendete Lernverfahren und der von Watkins und Dayan (1992) vorgestellte Q-Learning-Algorithmus eignen sich für vergleichsweise kleine Zustands- und Aktionsräume und Simulationen. Bei einer Erweiterung des bestehenden Modells um weitere Aktionen und Zustände oder die Übertragung auf realweltliche Situationen wird die Gegenüberstellung der Leistungsfähigkeit weiterer Lernverfahren notwendig (Hasselt, 2010).

6.3 Ausblick

Das in der vorliegenden Arbeit entwickelte Modell dient dem Nachweis, dass Effectuation algorithmisch interpretiert werden kann und autonome Agenten in die Lage versetzt werden, rudimentär effektuatives Verhalten zu erlernen. Die in Abschnitt 6.2 erläuterten Einschränkungen der Forschungsarbeit zeigen, welcher weitere Untersuchungsbedarf ausgehend vom aktuellen Stand besteht.

Das in Kapitel 4 vorgestellte RIL-Effectuation-Modell adressiert Problemstellungen, die Mauer et al. (2017) in der Diskussion über künftige Forschungspotentiale beschreiben. Unter anderem wird die Untersuchung eines kompakten Finanzmaßes gefordert. Die Entwicklung einer effektuativen Belohnungsfunktion trägt dieser Anforderung in Teilen Rechnung. Unter Einbeziehung von Kosten und Mitteleinsatz (Read, Dew et al., 2009) konnte das von Mauer et al. (2017) vorgestellte Leistungsmaß erweitert werden. Die Modellierung des Anreizes für den effektuativen Mitteleinsatz in Gleichung 4.2 wurde mittels einer Exponentialfunktion realisiert. In folgenden Untersuchungen wäre eine Diskussion weiterer Ansätze zur formalisierten Gestaltung des Mitteleinsatzes denkbar, die eine Parametrisierung des Mittelverbrauchs ermöglichen. Die Erhebung empirischer Daten zum Mittelverbrauch effektuativ handelnder Entrepreneurere kann dabei ebenfalls in die Modellierung einfließen.

Weitere Aspekte, die in die Entwicklung eines Leistungsmaßes gemäß Mauer et al. (2017) einfließen können, wie beispielsweise das Renditeverhalten von Strategien (Wiltbank et al., 2009), haben im RIL-Effectuation-Modell bisher keine Beachtung gefunden. Es ist denkbar, die Belohnungsfunktion in künftigen Untersuchungen diesbezüglich zu erweitern. Die Einbeziehung des Zeitfortschritts und von Opportunitätskosten in die Modellierung der Belohnungsfunktion können die Berücksichtigung des Renditeverhaltens ermöglichen.

Die bisher bestehende effektuateive Belohnungsfunktion wurde anhand von in der Literatur zu findenden Ausführungen modelliert. Zur weiteren Annäherung an ein realweltliches Verhalten des Agenten ist die Einbeziehung empirischer Daten notwendig. Dies kann beispielsweise durch den Einsatz eines humanen Trainers realisiert werden. Knox und Stone (2009), Pilarski et al. (2011) und Suay und Chernova (2011) geben Hinweise darauf, wie der Einsatz eines menschlichen Lehrers realisiert und die damit verbundene Modellierung der Belohnungsfunktion umgesetzt werden kann. Folglich können in künftigen Untersuchungen Entrepreneurure in die Lage versetzt werden, in gründungsbezogenen Entscheidungssituationen Belohnungssignale an den Agenten zu senden, um beispielsweise effektuatives Verhalten zu erlernen.

Dies geht einher mit der Operationalisierung der Merkmale im Zustandsraum, die vom Entrepreneur als relevant für die Entscheidungssituation eingeschätzt werden. Weitere Untersuchungen zur Darstellung des Beobachtungsraums im Gründungsumfeld in maschinenlesbarer Form können für das realitätsnahe Lernen effektuativen Verhaltens eines Agenten hilfreich sein. Die damit einhergehende Verbesserung des Algorithmus kann neben der Verfeinerung der Effectuation-Theorie praxisrelevante Erkenntnisse nach sich ziehen. Ist der effektuateive Agent in der Lage entrepreneuriales Verhalten in verbesserter Form abzubilden, kann die Künstliche Intelligenz beispielsweise in entscheidungsunterstützenden Systemen genutzt werden. Novizen wie auch erfahrene Entrepreneurure wären dadurch in der Lage, Gründungssituationen besser einzuschätzen und Empfehlungen zu erhalten.

Die damit verbundene Veränderung des Zustandsraums beinhaltet die Evaluierung weiterer Lernalgorithmen. Bei einer Vergrößerung des Zustands- wie auch des Aktionsraumes besteht die Notwendigkeit, weitere performante Verfahren zu erproben. Mit Hilfe von *Deep-Reinforcement-Learning*-Methoden besteht die Möglichkeit auch für umfangreiche Aktions- und Zustandsräume, effiziente Strategien zu erlernen. Durch die Verbindung von Supervised-Learning- und RIL-Verfahren können hochdimensionale Eingabedaten verarbeitet und eine Steuerungsstrategie erlernt werden (Mnih et al., 2016).

Im Einklang mit Welter und Kim (2018) zu zukünftigen Forschungsaktivitäten, kann die Untersuchung, in welchen Situationen ein Wechsel zwischen

Effectuation und Causation als dominierende Strategie sinnvoll ist, Hinweise sowohl für die Praxis als auch die Theorie liefern. Im vorgestellten RIL-Effectuation-Modell wurde bislang lediglich effektuatives Verhalten beanreizt. Durch die Gestaltung einer Belohnungsfunktion, die Effectuation und Causation berücksichtigt, kann überprüft werden, in welchen Zuständen eher effektuatives oder kausales Verhalten sinnvoll ist.

Weitere Untersuchungen zur Beziehung von knightscher Ungewissheit und Effectuation können zudem Aufschluss über die zugrundeliegenden Annahmen der Theorie liefern. Taleb (2010, S. 345) stellt fest, dass Individuen funktional nicht in der Lage sind auf einer Mikro-Ebene zwischen Risiko und Ungewissheit zu unterscheiden. Für die weitere Forschung kann davon ausgehend die Relevanz des entrepreneurialen Problemraums – der für Effectuation zentral ist – untersucht werden. Eine Weiterentwicklung des Problemraums kann wiederum Ausgangspunkt für neue Erkenntnisse zur Beschreibung entrepreneurialen Verhaltens sein.

Effectuation konnte sich in der Vergangenheit insbesondere neben den Entrepreneurship-Theorien Bricolage (Baker & Nelson, 2005), Lean Startup (Ries, 2011) und kausalen Ansätzen etablieren. Im Rahmen von Produktentwicklungsprozessen in einem unsicheren Umfeld, die nicht zwangsläufig dem Entrepreneurship zuzuordnen sind, entstanden Vorgehensmodelle, die, wie Effectuation, ebenfalls durch einen iterativen Charakter geprägt sind. Ähnlichkeiten ergeben sich beispielsweise in Bezug auf Scrum (Mathiaszyka et al., 2019) und Design Thinking (Mansoori & Lackeus, 2019). Künftige Untersuchungen könnten mittels einer holistischen Betrachtung der Vorgehensbeschreibungen den Grundstein für ein ganzheitliches Modell liefern und den möglicherweise daraus resultierenden Mehrwert für Entrepreneure ergründen.

Zusammengefasst erweitert das in der Arbeit vorgestellte Modell bisherige Ansätze zur Modellierung von Effectuation und stellt dabei autonomes Lernen in den Vordergrund. Mit der Vorstellung einer Methode zur Gestaltung von knightscher Ungewissheit im Kontext agentenbasierter Modelle konnten bisherige Herausforderung bei deren Formulierung überwunden werden. Durch Einsatz von Verfahren des maschinellen Lernens wurden bestehende Simulationsansätze um eine intelligente Verhaltenskomponente ergänzt. Die gewonnenen Erkenntnisse liefern damit einen Beitrag zur Verfeinerung der Effectuation-Theorie und bereiten den Weg für weitere Forschungsvorhaben.

Open Access Dieses Kapitel wird unter der Creative Commons Namensnennung 4.0 International Lizenz (<http://creativecommons.org/licenses/by/4.0/deed.de>) veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden.

Die in diesem Kapitel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.



Literatur

- Abbeel, P., & Ng, A. Y. (2004). Apprenticeship learning via inverse reinforcement learning. *Proceedings of the twenty-first international conference on Machine learning*, 1–8. <https://doi.org/10.1145/1015330.1015430> (siehe S. 86)
- Abdou, M., Hamill, L., & Gilbert, N. (2012). Designing and Building an Agent-Based Model. In A. J. Heppenstall, A. T. Crooks, L. M. See & M. Batty (Hrsg.), *Agent-Based Models of Geographical Systems* (S. 141–165). Springer Netherlands. https://doi.org/10.1007/978-90-481-8927-4_8. (Siehe S. 86)
- Almirall, E., & Casadesus-Masanell, R. (2010). Open Versus Closed Innovation: A Model of Discovery and Divergence. *Academy of Management Review*, 35 (1), 27–47. <https://doi.org/10.5465/amr.35.1.zok27> (siehe S. 37)
- Alsos, G. A., Clausen, T. H., Mauer, R., Read, S., & Sarasvathy, S. D. (2019). Effectual exchange: from entrepreneurship to the disciplines and beyond. *Small Business Economics*, 54 (3), 605–619. <https://doi.org/10.1007/s11187-019-00146-9> (siehe S. 85)
- Alvarez, S. A., & Parker, S. C. (2009). Emerging firms and the allocation of control rights: a Bayesian approach. *The Academy of Management review: AMR*, 34 (2), 209–227 (siehe S. 18).
- Amiri, R., Mehrpouyan, H., Fridman, L., Mallik, R. K., Nallanathan, A., & Matolak, D. (2018). A Machine Learning Approach for Power Allocation in HetNets Considering QoS. 2018 *IEEE International Conference on Communications (ICC)*, 1–7. <https://doi.org/10.1109/ICC.2018.8422864> (siehe S. 24)
- Archibugi, D., Filippetti, A., & Frenz, M. (2013). Economic crisis and innovation: Is destruction prevailing over accumulation? *Research Policy*, 42 (2), 303–314. <https://doi.org/10.1016/j.respol.2012.07.002> (siehe S. 1)
- Arend, R. J., Sarooghi, H., & Burkemper, A. (2015). Effectuation As Ineffectual? Applying the 3E Theory-Assessment Framework to a Proposed New Theory of Entrepreneurship. *Academy of Management Review*, 40 (4), 630–651. <https://doi.org/10.5465/amr.2014.0455> (siehe S. 3)
- Arend, R. J., Sarooghi, H., & Burkemper, A. (2016). Effectuation, Not Being Pragmatic or Process Theorizing, Remains Ineffectual: Responding to the Commentaries. *Academy of Management Review*, 41 (3), 549–556. <https://doi.org/10.5465/amr.2016.0086> (siehe S. 3)
- Azzadenesheli, K., Lazaric, A., & Anandkumar, A. (2016). Reinforcement Learning of POMDPs using Spectral Methods. In V. Feldman, A. Rakhlin & O. Shamir (Hrsg.), *29th Annual Conference on Learning Theory* (S. 193–256). PMLR. (Siehe S. 91).

- Baker, T., & Nelson, R. E. (2005). Creating Something from Nothing: Resource Construction through Entrepreneurial Bricolage. *Administrative Science Quarterly*, 50 (3), 329–366. <https://doi.org/10.2189/asqu.2005.50.3.329> (siehe S. 3, 130)
- Baron, R. A. (2009). Effectual versus predictive logics in entrepreneurial decision making: Differences between experts and novices: Does experience in starting new ventures change the way entrepreneurs think? Perhaps, but for now, „Caution“ is essential. *Journal of Business Venturing*, 24 (4), 310–315. <https://doi.org/10.1016/j.jbusvent.2008.04.001> (siehe S. 3)
- Barto, A. G. (1995). Reinforcement Learning and Dynamic Programming. *IFAC Proceedings Volumes*, 28 (15), 407–412. [https://doi.org/10.1016/s1474-6670\(17\)45266-9](https://doi.org/10.1016/s1474-6670(17)45266-9) (siehe S. 28)
- Bellman, R. (1957). *Dynamic programming*. Princeton University Press. (Siehe S. 26).
- Bertsekas, D. P. (2011). Approximate policy iteration: a survey and some new methods. *Journal of Control Theory and Applications*, 9 (3), 310–335. <https://doi.org/10.1007/s11768-011-1005-3> (siehe S. 28)
- Bertsekas, D. P., & Tsitsiklis, J. N. (1995). Neuro-dynamic programming: an overview. *Proceedings of 1995 34th IEEE Conference on Decision and Control*. <https://doi.org/10.1109/cdc.1995.478953> (siehe S. 89)
- Blank, S., & Dorf, B. (2020). *The Startup Owner's Manual: The Step-By-Step Guide for Building a Great Company* (Bd. 1). Wiley. (Siehe S. 53).
- Blaug, M. (1997). *Economic Theory in Retrospect* (5. Aufl.). Cambridge University Press. (Siehe S. 21).
- Bonabeau, E. (2002). Agent-based modeling: Methods and techniques for simulating human systems. *Proceedings of the National Academy of Sciences*, 99 (Supplement 3), 7280–7287. <https://doi.org/10.1073/pnas.082080899> (siehe S. 85, 86, 128)
- Bone, C., & Dragičević, S. (2010). Simulation and validation of a reinforcement learning agent-based model for multi-stakeholder forest management. *Computers, Environment and Urban Systems*, 34 (2), 162–174. <https://doi.org/10.1016/j.compenvurbsys.2009.10.001> (siehe S. 86)
- Brettel, M., Mauer, R., Engelen, A., & Küpper, D. (2012). Corporate effectuation: Entrepreneurial action and its impact on R&D project performance. *Journal of Business Venturing*, 27 (2), 167–184. <https://doi.org/10.1016/j.jbusvent.2011.01.001> (siehe S. 94)
- Brinckmann, J., Grichnik, D., & Kapsa, D. (2010). Should entrepreneurs plan or just storm the castle? A meta-analysis on contextual factors impacting the business planning-performance relationship in small firms. *Journal of Business Venturing*, 25 (1), 24–40. <https://doi.org/https://doi.org/10.1016/j.jbusvent.2008.10.007> (siehe S. 47)
- Brockman, G., Cheung, V., Pettersson, L., Schneider, J., Schulman, J., Tang, J., & Zaremba, W. (2016). OpenAI Gym. Verfügbar 29. Mai 2020 unter <http://arxiv.org/abs/1606.01540>. (Siehe S. 103)
- Busoniu, L., Babuska, R., Schutter, B. D., & Ernst, D. (2017). *Reinforcement Learning and Dynamic Programming Using Function Approximators*. CRC Press. (Siehe S. 28).
- Buxmann, P., & Schmidt, H. (2018). Grundlagen der Künstlichen Intelligenz und des Maschinellen Lernens. In P. Buxmann & H. Schmidt (Hrsg.), *Künstliche Intelligenz* (S. 3–19). Springer Gabler. https://doi.org/10.1007/978-3-662-57568-0_1. (Siehe S. 21)
- Camacho, A., Icarte, R. T., Klassen, T. Q., Valenzano, R., & McIlraith, S. A. (2019). LTL and Beyond: Formal Languages for Reward Function Specification in Reinforcement Learning.

- Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence*. <https://doi.org/10.24963/ijcai.2019/840> (siehe S. 97)
- Carpenter, G. S., & Nakamoto, K. (1989). Consumer Preference Formation and Pioneering Advantage. *Journal of Marketing Research*, 26 (3), 285. <https://doi.org/10.2307/3172901> (siehe S. 38, 39)
- Center for Venture Research. (2019). The Angel Market in 2019: Commitments by Angels Increase with a Significant Rise in Deal Valuations. <https://paulcollege.unh.edu/sites/default/files/resource/files/2019-analysis-report.pdf>. (Siehe S. 99, 128)
- Chandler, G. N., DeTienne, D. R., McKelvie, A., & Mumford, T. V. (2011). Causation and effectuation processes: A validation study. *Journal of Business Venturing*, 26 (3), 375–390. <https://doi.org/10.1016/j.jbusvent.2009.10.006> (siehe S. 8, 51, 85, 99, 122, 127, 128)
- Chiles, T. H., Vultee, D. M., Gupta, V. K., Greening, D. W., & Tuggle, C. S. (2009). The Philosophical Foundations of a Radical Austrian Approach to Entrepreneurship: *Journal of Management Inquiry*, 19 (2), 138–164. <https://doi.org/10.1177/1056492609337833> (siehe S. 85)
- Connell, J. (1989). *A Colony Architecture for an Artificial Creature* (Technical Report Nr. 1151). Massachusetts Institute of Technology, Cambridge. (Siehe S. 30).
- Corfield, D., & Williamson, J. (2001). Foundations of Bayesianism. In D. Corfield & J. Williamson (Hrsg.). Springer Netherlands. <https://doi.org/10.1007/978-94-017-1586-7>. (Siehe S. 12, 13)
- Caszar, F. A., & Levinthal, D. A. (2016). Mental representation and the discovery of new strategies. *Strategic Management Journal*, 37 (10), 2031–2049. <https://doi.org/10.1002/smj.2440> (siehe S. 30, 37)
- Caszar, F. A., & Siggelkow, N. (2010). How Much to Copy? Determinants of Effective Imitation Breadth. *Organization Science*, 21 (3), 661–676. <https://doi.org/10.1287/orsc.1090.0477> (siehe S. 49, 83)
- Cyert, R. M., & March, J. G. (1963). *A behavioral theory of the firm*. Prentice Hall. (Siehe S. 49).
- Davis, J. P., Eisenhardt, K. M., & Bingham, C. B. (2007). Developing Theory Through Simulation Methods. *Academy of Management Review*, 32 (2), 480–499. <https://doi.org/10.5465/amr.2007.24351453> (siehe S. 37)
- Davis, J. P., Eisenhardt, K. M., & Bingham, C. B. (2009). Optimal Structure, Market Dynamism, and the Strategy of Simple Rules. *Administrative Science Quarterly*, 54 (3), 413–452. <https://doi.org/10.2189/asqu.2009.54.3.413> (siehe S. 36, 38, 43, 51)
- de Finetti, B. (1974). Bayesianism: Its Unifying Role for Both the Foundations and Applications of Statistics. *International Statistical Review/Revue Internationale de Statistique*, 42 (2), 117–130. <https://doi.org/10.2307/1403075> (siehe S. 12)
- de Laplace, P. S. (1812). *Théorie analytique des probabilités*. Courcier. (Siehe S. 107).
- Deligianni, I., Voudouris, I., & Lioukas, S. (2015). Do Effectuation Processes Shape the Relationship Between Product Diversification and Performance in New Ventures? *Entrepreneurship Theory and Practice*, 41 (3), 349–377. <https://doi.org/10.1111/etap.12210> (siehe S. 114)
- Dess, G. G., & Beard, D. W. (1984). Dimensions of Organizational Task Environments. *Administrative Science Quarterly*, 29 (1), 52–73. <https://doi.org/10.2307/2393080> (siehe S. 43)

- Dew, N., Read, S., Sarasvathy, S. D., & Wiltbank, R. (2009). Effectual versus predictive logics in entrepreneurial decision-making: Differences between experts and novices. *Journal of Business Venturing*, 24 (4), 287–309. <https://doi.org/10.1016/j.jbusvent.2008.02.002> (siehe S. 2, 47)
- Dew, N., Sarasathy, S., Read, S., & Wiltbank, R. (2009). Affordable loss: behavioral economic aspects of the plunge decision. *Strategic Entrepreneurship Journal*, 3 (2), 105–126. <https://doi.org/10.1002/sej.66> (siehe S. 2)
- Dew, N., & Sarasvathy, S. D. (2007). Innovations, Stakeholders & Entrepreneurship. *Journal of Business Ethics*, 74 (3), 267–283. <https://doi.org/10.1007/s10551-006-9234-y> (siehe S. 43)
- Dhingra, B., Li, L., Li, X., Gao, J., Chen, Y.-N., Ahmed, F., & Deng, L. (2017). Towards End-to-End Reinforcement Learning of Dialogue Agents for Information Access. *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, 484–495. <https://doi.org/10.18653/v1/P17-1045> (siehe S. 22)
- Duncan, R. B. (1972). Characteristics of Organizational Environments and Perceived Environmental Uncertainty. *Administrative Science Quarterly*, 17 (3), 313–327. <https://doi.org/10.2307/2392145> (siehe S. 56)
- Eberz, S. (2018). *Effectuation oder Causation?: Der Einfluss der Persönlichkeit unerfahrener Entrepreneur*. Springer Gabler. (Siehe S. 4, 35, 51, 53–57, 59, 61, 64, 89, 91, 126).
- Eberz, S., Manesh, M., Bertram, M., & von Kortzfleisch, H. (2015). Entscheidungen im Gründungskontext: Anforderungen an die Simulation von Causation und Effectuation. *Wirtschaftsinformatik Proceeding 2015*, 1649–1663 (siehe S. 53).
- Edelman, L., & Yli-Renko, H. (2010). The Impact of Environment and Entrepreneurial Perceptions on Venture-Creation Efforts: Bridging the Discovery and Creation Views of Entrepreneurship. *Entrepreneurship Theory and Practice*, 34 (5), 833–856. <https://doi.org/10.1111/j.1540-6520.2010.00395.x> (siehe S. 47)
- Felizardo, K. R., Nakagawa, E. Y., MacDonell, S. G., & Maldonado, J. C. (2014). A visual analysis approach to update systematic reviews. *Proceedings of the 18th International Conference on Evaluation and Assessment in Software Engineering – EASE '14*, (4), 1–10. <https://doi.org/10.1145/2601248.2601252> (siehe S. 5)
- Feng, L., Chiam, Y. K., & Lo, S. K. (2017). Text-Mining Techniques and Tools for Systematic Literature Reviews: A Systematic Literature Review. *2017 24th Asia-Pacific Software Engineering Conference (APSEC)*, 41–50. <https://doi.org/10.1109/apsec.2017.10> (siehe S. 6)
- Fernandes, N. (2020). *Economic Effects of Coronavirus Outbreak (COVID-19) on the World Economy* (Diskussionspapier WP-1240-E). IESE Business School. Barcelona. <https://doi.org/10.2139/ssrn.3557504>. (Siehe S. 1)
- Fioretti, G. (2012). Agent-Based Simulation Models in Organization Science. *Organizational Research Methods*, 16 (2), 227–242. <https://doi.org/10.1177/1094428112470006> (siehe S. 128)
- Fisher, G. (2012). Effectuation, Causation, and Bricolage: A Behavioral Comparison of Emerging Theories in Entrepreneurship Research. *Entrepreneurship Theory and Practice*, 36 (5), 1019–1051. <https://doi.org/10.1111/j.1540-6520.2012.00537.x> (siehe S. 4)
- Gabrielsson, P., & Gabrielsson, M. (2013). A dynamic model of growth phases and survival in international business-to-business new ventures: The moderating effect of decision-making

- logic. *Industrial Marketing Management*, 42 (8), 1357–1373. <https://doi.org/10.1016/j.indmarman.2013.07.011> (siehe S. 90)
- Ganco, M., & Agarwal, R. (2009). Performance Differentials Between Diversifying Entrants and Entrepreneurial start-ups: A Complexity Approach. *Academy of Management Review*, 34 (2), 228–252. <https://doi.org/10.5465/amr.2009.36982618> (siehe S. 47)
- García, R. (2005). Uses of Agent-Based Modeling in Innovation/New Product Development Research. *Journal of Product Innovation Management*, 22 (5), 380–398. <https://doi.org/10.1111/j.1540-5885.2005.00136.x> (siehe S. 85)
- García, J., Borrajo, F., & Fernández, F. (2012). Reinforcement Learning for decision-making in a business simulator. *International Journal of Information Technology & Decision Making*, 11 (05), 935–960. <https://doi.org/10.1142/s0219622012500277> (siehe S. 21)
- Gentry, R. J., Dalziel, T., & Jamison, M. A. (2013). Who Do Start-Up Firms Imitate? A Study of New Market Entries in the CLEC Industry. *Journal of Small Business Management*, 51 (4), 525–538. <https://doi.org/10.1111/jsbm.12055> (siehe S. 20)
- Ghahramani, Z. (2004). *Unsupervised Learning*. In O. Bousquet, U. von Luxburg & G. Rätsch (Hrsg.). Springer. https://doi.org/10.1007/978-3-540-28650-9_5. (Siehe S. 22)
- Ghavamzadeh, M., Mannor, S., Pineau, J., & Tamar, A. (2015). Bayesian Reinforcement Learning: A Survey. *Foundations and Trends® in Machine Learning*, 8 (5–6), 359–483. <https://doi.org/10.1561/22000000049> (siehe S. 21)
- Gilbert, N. (2007). *Agent-Based Models*. SAGE Publications. (Siehe S. 36).
- Gilbert, N., & Troitzsch, K. G. (2005). *Simulation for the Social Scientist* (2. Aufl.). Open University Press. (Siehe S. 36).
- Giones, F., Brem, A., Pollack, J. M., Michaelis, T. L., Klyver, K., & Brinckmann, J. (2020). Revising entrepreneurial action in response to exogenous shocks: Considering the COVID-19 pandemic. *Journal of Business Venturing Insights*, 14, 1–7. <https://doi.org/10.1016/j.jbvi.2020.e00186> (siehe S. 1)
- Greenwald, A., & Hall, K. (2003). Correlated Q-Learning. *Proceedings of the Twentieth International Conference on International Conference on Machine Learning*, 242–249 (siehe S. 105).
- Grégoire, D. A., & Cherchem, N. (2019). A structured literature review and suggestions for future effectuation research. *Small Business Economics*, 54 (3), 621–639. <https://doi.org/10.1007/s11187-019-00158-5> (siehe S. 3, 83)
- Gulyás, L., & Kampis, G. (2015). Models, Representations and Comparisons in Computer Simulations. *Procedia Computer Science*, 66, 5–12. <https://doi.org/https://doi.org/10.1016/j.procs.2015.11.003> (siehe S. 57, 59, 64, 66)
- Gupta, V. K., Chiles, T. H., & McMullen, J. S. (2016). A Process Perspective on Evaluating and Conducting Effectual Entrepreneurship Research. *Academy of Management Review*, 41 (3), 540–544. <https://doi.org/10.5465/amr.2015.0433> (siehe S. 3, 22, 85, 86, 88, 126)
- Haiyan, L. (2018). Dynamic trust game model between venture capitalists and entrepreneurs based on reinforcement learning theory. *Cluster Computing*, 22 (3), 5893–5904. <https://doi.org/10.1007/s10586-017-1666-x> (siehe S. 21, 22, 86)
- Hasselt, H. V. (2010). Double Q-learning. *Proceedings of the 23rd International Conference on Neural Information Processing Systems – Volume 2*, 2613–2621 (siehe S. 129).
- Hemalatha, M., & Nayaki, S. S. (2014). K-means clustering for profiling the rural women entrepreneurs in India. *International Journal of Business Information Systems*, 17 (1), 33–48. <https://doi.org/10.1504/ijbis.2014.064114> (siehe S. 22)

- Hevner, A. R., March, S. T., Park, J., & Ram, S. (2004). *Design Science in Information Systems Research*. *MIS Quarterly*, 28 (1), 75–105 (siehe S. 51).
- Jaynes, E. T. (1957). Information Theory and Statistical Mechanics. *The Physical Review*, 106 (4), 620–630. <https://doi.org/https://doi.org/10.1103/PhysRev.106.620> (siehe S. 18)
- Jiang, Y., & Rilling, C.-C. (2017). Opening the Black Box of Effectuation Processes: Characteristics and Dominant Types. *Entrepreneurship Theory and Practice*, 43 (1), 171–202. <https://doi.org/10.1177/1042258717744204> (siehe S. 8)
- Jun, S. (2016). Frequentist and Bayesian Learning Approaches to Artificial Intelligence. *International Journal of Fuzzy Logic and Intelligent Systems*, 16 (2), 111–118. <https://doi.org/10.5391/IJFIS.2016.16.2.111> (siehe S. 21)
- Kalinic, I., Sarasvathy, S. D., & Forza, C. (2012). Internationalization and effectuation: explaining entrepreneurial decision-making in uncertain international environments. *Proceedings of the 38th Annual Conference of the European International Business Academy (EIBA)*, Sussex (siehe S. 90).
- Karami, M., Wooliscroft, B., & McNeill, L. (2019). Effectuation and internationalisation: a review and agenda for future research. *Small Business Economics*, 55 (3), 777–811. <https://doi.org/10.1007/s11187-019-00183-4> (siehe S. 94)
- Karri, R., & Goel, S. (2008). Effectuation and Over-Trust: Response to Sarasvathy and Dew. *Entrepreneurship Theory and Practice*, 32 (4), 739–748. <https://doi.org/10.1111/j.1540-6520.2008.00251.x> (siehe S. 3)
- Katt, S., Oliehoek, F. A., & Amato, C. (2019). Bayesian Reinforcement Learning in Factored POMDPs. *Proceedings of the 18th International Conference on Autonomous Agents and MultiAgent Systems*, 7–15 (siehe S. 21).
- Kauffman, S. A. (1993). *The Origins of Order: Self-Organization and Selection in Evolution*. Oxford University Press. (Siehe S. 48).
- Keyhani, M., Lévesque, M., & Madhok, A. (2014). Toward a theory of entrepreneurial rents: A simulation of the market process. *Strategic Management Journal*, 36 (1), 76–96. <https://doi.org/10.1002/smj.2203> (siehe S. 37)
- Keynes, J. M. (1921). *A Treatise on Probability*. Macmillan And Co. (Siehe S. 12).
- KfW Research. (2017). Gründungsfinanzierung: Existenzgründer erhöhen Kapitaleinsatz. https://www.kfw.de/KfW-Konzern/Newsroom/Aktuelles/News-Details_445184.html. (Siehe S. 93)
- Kimura, H., Miyazaki, K., & Kobayashi, S. (1997). Reinforcement Learning in POMDPs with Function Approximation. *Proceedings of the Fourteenth International Conference on Machine Learning*, 152–160 (siehe S. 91).
- Knight, F. H. (1921). *Risk, Uncertainty and Profit*. Houghton Mifflin. (Siehe S. 20, 43, 89).
- Knox, W. B., & Stone, P. (2009). Interactively shaping agents via human reinforcement: The TAMER Framework. *Proceedings of the fifth international conference on Knowledge capture – K-CAP '09*, 9–16. <https://doi.org/10.1145/1597735.1597738> (siehe S. 129)
- Kolmogoroff, A. N. (1933). *it Grundbegriffe der Wahrscheinlichkeitsrechnung* (S. des „Zentralblatt für Mathematik“, Hrsg.; Bd. 2). Julius Springer. (Siehe S. 14).
- Korb, K., & Nicholson, A. E. (2004). *Bayesian artificial intelligence*. Chapman & Hall/CRC. (Siehe S. 21).
- Kreinovich, V. (2008). Interval Computation as an Important Part of Granular Computing: An Introduction. In W. Pedrycz, A. Skowron & V. Kreinovich (Hrsg.), *Handbook of Granular Computing* (S. 3–32). John Wiley & Sons. (Siehe S. 18).

- Kumam, W., Saipara, P., & Kumam, P. (2017). *Bayesian Inference Application*. In J. P. Tejedor (Hrsg.), *Bayesian Inference* (S. 3–22). InTech. <https://doi.org/10.5772/intechopen.70530>. (Siehe S. 11)
- Laux, H., Gillenkirch, R. M., & Schenk-Mathes, H. Y. (2014). *Entscheidungstheorie* (9. Aufl.). Springer Gabler. (Siehe S. 13, 15).
- Law, A. M., & Kelton, W. D. (1991). *Simulation Modeling and Analysis* (2. Aufl.). McGraw-Hill. (Siehe S. 51).
- Lemoine, N. P. (2019). Moving beyond noninformative priors: why and how to choose weakly informative priors in Bayesian analyses. *Oikos*, *128* (7), 912–928. <https://doi.org/10.1111/oik.05985> (siehe S. 18)
- Lenox, M. J., Rockart, S. F., & Lewin, A. Y. (2006). Interdependency, Competition, and the Distribution of Firm and Industry Profits. *Management Science*, *52* (5), 757–772. <https://doi.org/10.1287/mnsc.1050.0495> (siehe S. 47)
- Lévesque, M. (2004). Mathematics, theory, and entrepreneurship. *Journal of Business Venturing*, *19* (5), 743–765. [https://doi.org/10.1016/S0883-9026\(03\)00028-4](https://doi.org/10.1016/S0883-9026(03)00028-4) (siehe S. 3)
- Levinthal, D. A. (1997). Adaptation on Rugged Landscapes. *Management Science*, *43* (7), 934–950. <https://doi.org/https://doi.org/10.1287/mnsc.43.7.934> (siehe S. 47–49)
- Lewis, D. (1980). A subjectivist's guide to objective chance. In R. C. Jeffrey (Hrsg.), *Studies in Inductive Logic and Probability* (S. 263–293). University of California Press. (Siehe S. 12).
- Lewis, F. L., & Vrabie, D. (2009). Reinforcement learning and adaptive dynamic programming for feedback control. *IEEE Circuits and Systems Magazine*, *9* (3), 32–50. <https://doi.org/10.1109/MCAS.2009.933854> (siehe S. 29)
- Littman, M. L., Dean, T. L., & Kaelbling, L. P. (1995). On the Complexity of Solving Markov Decision Problems. *Proceedings of the Eleventh Conference on Uncertainty in Artificial Intelligence*, 394–402 (siehe S. 23).
- Luis-Rico, I., Escolar-Llamazares, M.-C., De la Torre-Cruz, T., Jiménez, A., Herrero, Á., Palmero-Cámara, C., & Jiménez-Eguizábal, A. (2020). Entrepreneurial Interest and Entrepreneurial Competence Among Spanish Youth: An Analysis with Artificial Neural Networks. *Sustainability*, *12* (4), 1–17. <https://doi.org/10.3390/su12041351> (siehe S. 22)
- Macy, M. W., & Willer, R. (2002). From Factors to Actors: Computational Sociology and Agent-Based Modeling. *Annual Review of Sociology*, *28* (1), 143–166. <https://doi.org/10.1146/annurev.soc.28.110601.141117> (siehe S. 85)
- Mandel, T., Liu, Y.-E., Brunskill, E., & Popović, Z. (2016). Offline evaluation of online reinforcement learning algorithms. *Thirtieth AAAI Conference on Artificial Intelligence*, 1926–1933 (siehe S. 22).
- Mansoori, Y., & Lackéus, M. (2019). Comparing effectuation to discoverydriven planning, prescriptive entrepreneurship, business planning, lean startup, and design thinking. *Small Business Economics*, *54* (3), 791–818. <https://doi.org/10.1007/s11187-019-00153-w> (siehe S. 131)
- Mansour, Y., & Singh, S. (1999). On the complexity of policy iteration. *Proceedings of the Fifteenth conference on Uncertainty in artificial intelligence*, 401–408 (siehe S. 29).
- Mao, H., Alizadeh, M., Menache, I., & Kandula, S. (2016). Resource Management with Deep Reinforcement Learning. *Proceedings of the 15th ACM Workshop on Hot Topics in Networks*, 50–56. <https://doi.org/10.1145/3005745.3005750> (siehe S. 22)

- March, S. T., & Storey, V. C. (2008). Design Science in the Information Systems Discipline: An Introduction to the Special Issue on Design Science Research. *MIS Quarterly*, 32 (4), 725–730 (siehe S. 51).
- Marsland, S. (2014). *Machine Learning: An Algorithmic Perspective* (2. Aufl.). CRC Press. (Siehe S. 21).
- Mathiaszyka, L., Volkman, C., & Read, S. (2019). Effectual Project Management: Thinking Like an Expert Entrepreneur. *PM World Journal*, 8 (3), 1–18 (siehe S. 131).
- Mauer, R., Wuebker, R., Schlüter, J., & Brettel, M. (2017). Prediction and control: An agent-based simulation of search processes in the entrepreneurial problem space. *Strategic Entrepreneurship Journal*, 12 (2), 237–260. <https://doi.org/10.1002/sej.1271> (siehe S. 4, 8, 35–45, 51, 59, 61, 64–72, 82, 83, 86, 88, 89, 91–93, 126, 128, 129)
- McKelvie, A., Haynie, J. M., & Gustavsson, V. (2011). Unpacking the uncertainty construct: Implications for entrepreneurial action. *Journal of Business Venturing*, 26 (3), 273–292. <https://doi.org/10.1016/j.jbusvent.2009.10.004> (siehe S. 51)
- Meijer, I. S. M. (2008). *Uncertainty and entrepreneurial action. The role of uncertainty in the development of emerging energy technologies* (Diss.). Utrecht University. (Siehe S. 20).
- Milliken, F. J. (1987). Three Types of Perceived Uncertainty about the Environment: State, Effect, and Response Uncertainty. *The Academy of Management Review*, 12 (1), 133–143. <https://doi.org/https://doi.org/10.2307/257999> (siehe S. 19)
- Mitchell, T. (1997). *Machine Learning*. McGraw-Hill. (Siehe S. 23, 24, 26, 27, 86).
- Mnih, V., Badia, A. P., Mirza, M., Graves, A., Lillicrap, T., Harley, T., Silver, D., & Kavukcuoglu, K. (2016). Asynchronous Methods for Deep Reinforcement Learning. In M. F. Balcan & K. Q. Weinberger (Hrsg.), *Proceedings of The 33rd International Conference on Machine Learning* (S. 1928–1937). PMLR. (Siehe S. 86, 130).
- Mocanu, E., Nguyen, P. H., & Gibescu, M. (2018). Deep Learning for Power System Data Analysis. In R. Arghandeh & Y. Zhou (Hrsg.), *Big Data Application in Power Systems* (S. 125–158). Elsevier. <https://doi.org/10.1016/b978-0-12-811968-6.00007-3>. (Siehe S. 23)
- Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). *Foundations of Machine Learning* (2. Aufl.). MIT Press. (Siehe S. 21).
- Monekosso, N., & Remagnino, P. (2004). The analysis and performance evaluation of the pheromone-Q-learning algorithm. *Expert Systems*, 21 (2), 80–91. <https://doi.org/10.1111/j.1468-0394.2004.00265.x> (siehe S. 118)
- Morales, M. (2020). *Grokking Deep Reinforcement Learning*. Manning Publications. (Siehe S. 119).
- Murphy, K. (2012). *Machine learning: a probabilistic perspective*. MIT Press. (Siehe S. 21).
- Natrop, J. (2012). *Grundzüge der Angewandten Mikroökonomie* (2. Aufl.). Oldenbourg Wissenschaftsverlag. (Siehe S. 56).
- Neyman, J., & Pearson, E. S. (1933). On the Problem of the Most Efficient Tests of Statistical Hypotheses. *Philosophical Transactions of the Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character*, 231, 289–337 (siehe S. 87, 98).
- Nkwocha, I., Bao, Y., Johnson, W. C., & Brotspies, H. V. (2005). Product Fit and Consumer Attitude Toward Brand Extensions: The Moderating Role of Product Involvement. *Journal of Marketing Theory and Practice*, 13 (3), 49–61. <https://doi.org/10.1080/10696679.2005.11658549> (siehe S. 53)

- Nunes, A., & Balsa, C. (2013). Clustering entrepreneurship aspirations: innovation, growth and international orientation of activities. *International Journal of Innovation and Regional Development*, 5 (2), 165–178. <https://doi.org/10.1504/ijird.2013.055235> (siehe S. 22)
- Oliphant, T. (2007). Python for Scientific Computing. *Computing in Science & Engineering*, 9, 10–20. <https://doi.org/10.1109/MCSE.2007.58> (siehe S. 64)
- Packard, M. D., Clark, B. B., & Klein, P. G. (2017). Uncertainty Types and Transitions in the Entrepreneurial Process. *Organization Science*, 28 (5), 840–856. <https://doi.org/10.1287/orsc.2017.1143> (siehe S. 19)
- Panait, L., & Luke, S. (2005). Cooperative Multi-Agent Learning: The State of the Art. *Autonomous Agents and Multi-Agent Systems*, 11 (3), 387–434. <https://doi.org/10.1007/s10458-005-2631-2> (siehe S. 8)
- Payne, G. T., Pearson, A. W., & Carr, J. C. (2016). Process and Variance Modeling. *Family Business Review*, 30 (1), 11–18. <https://doi.org/10.1177/0894486516679749> (siehe S. 86)
- Peck, S. L. (2004). Simulation as experiment: a philosophical reassessment for biological modeling. *Trends in Ecology & Evolution*, 19 (10), 530–534. <https://doi.org/10.1016/j.tree.2004.07.019> (siehe S. 60)
- Peng, X. B., Liu, Y. L., Jiao, Q. Q., Feng, X. B., & Zheng, B. (2020). The nonlinear effect of effectuation and causation on new venture performance: The moderating effect of environmental uncertainty. *Journal of Business Research*, 117, 112–123. <https://doi.org/10.1016/j.jbusres.2020.05.048> (siehe S. 93)
- Perianes-Rodríguez, A., Waltman, L., & van Eck, N. J. (2016). Constructing bibliometric networks: A comparison between full and fractional counting. *Journal of Informetrics*, 10 (4), 1178–1195. <https://doi.org/10.1016/j.joi.2016.10.006> (siehe S. 6)
- Peris-Ortiz, M., Fuster-Estruch, V., & Devece-Carañana, C. (2013). Entrepreneurship and Innovation in a Context of Crisis. In K. Rüdiger, M. Peris-Ortiz & A. B. González (Hrsg.), *Entrepreneurship, Innovation and Economic Crisis: Lessons for Research, Policy and Practice* (S. 1–10). Springer. https://doi.org/10.1007/978-3-319-02384-7_1. (Siehe S. 1)
- Petrakis, P. E., & Konstantakopoulou, D. P. (2015). *Uncertainty in Entrepreneurial Decision Making: The Competitive Advantages of Strategic Creativity*. Palgrave Macmillan. <https://doi.org/10.1057/9781137460790>. (Siehe S. 19)
- Peyrolón, P. (2020). *Der Satz von Bayes: Wahrscheinlichkeitstheorie für Finanzen und Betriebswirtschaft*. Springer Gabler. (Siehe S. 18).
- Pilarski, P. M., Dawson, M. R., Degris, T., Fahimi, F., Carey, J. P., & Sutton, R. S. (2011). Online human training of a myoelectric prosthesis controller via actor-critic reinforcement learning. *2011 IEEE International Conference on Rehabilitation Robotics*, 1–7. <https://doi.org/10.1109/icorr.2011.5975338> (siehe S. 129)
- Plonsky, O., Apel, R., Ert, E., Tennenholtz, M., Bourgin, D., Peterson, J. C., Reichman, D., Griffiths, T. L., Russell, S. J., Carter, E. C., Cavanagh, J. F., & Erev, I. (2019). Predicting human decisions with behavioural theories and machine learning. Verfügbar 22. April 2020 unter <http://arxiv.org/abs/1904.06866>. (Siehe S. 21)
- Poole, D., & Mackworth, A. K. (2017). *Artificial intelligence: Foundations of Computational Agents* (2. Aufl.). Cambridge University Press. (Siehe S. 30, 105, 118).
- Rakesh, C. (2014). PEST analysis for micro small medium enterprises sustainability. *Journal of Management and Commerce*, 1 (1), 18–22 (siehe S. 20).
- Ramsey, F. P. (1964). Foresight: its logical laws, its subjective sources. In H. E. Smokler & H. E. Kyburg (Hrsg.), *Studies in Subjective Probability* (S. 23–52). New York. (Siehe S. 12).

- Read, S., Dew, N., Sarasvathy, S. D., Song, M., & Wiltbank, R. (2009). Marketing under Uncertainty: The Logic of an Effectual Approach. *Journal of Marketing*, 73 (3), 1–18. <https://doi.org/10.1509/jmkg.73.3.001> (siehe S. 83, 129)
- Read, S., & Sarasvathy, S. D. (2005). Knowing What to Do and Doing What You Know: Effectuation as a Form of Entrepreneurial Expertise. *The Journal of Private Equity*, 9 (1), 45–62. <https://doi.org/10.3905/jpe.2005.605370> (siehe S. 2, 120, 127)
- Read, S., Sarasvathy, S. D., Dew, N., & Wiltbank, R. (2016). Response to Arend, Sarooghi, and Burkemper (2015): Cocreating Effectual Entrepreneurship Research. *Academy of Management Review*, 41 (3), 528–536. <https://doi.org/10.5465/amr.2015.0180> (siehe S. 12)
- Read, S., Song, M., & Smit, W. (2009). A meta-analytic review of effectuation and venture performance. *Journal of Business Venturing*, 24 (6), 573–587. <https://doi.org/10.1016/j.jbusvent.2008.02.005> (siehe S. 120)
- Ries, E. (2011). *The Lean Startup: How Today's Entrepreneurs Use Continuous Innovation to Create Radically Successful Businesses*. Crown Publishing Group. (Siehe S. 3, 4, 130).
- Rivkin, J. W. (2000). Imitation of Complex Strategies. *Management Science*, 46 (6), 824–844. <https://doi.org/https://doi.org/10.1287/mnsc.46.6.824.11940> (siehe S. 47–49, 51, 83)
- Robinson, S. (1997). Simulation Model Verification and Validation: Increasing the Users' Confidence. *Proceedings of the 29th Conference on Winter Simulation*, 53–59. <https://doi.org/10.1145/268437.268448> (siehe S. 57, 58)
- Rupp, C. (2007). *Requirements-Engineering und -Management: Professionelle, iterative Anforderungsanalyse für die Praxis* (4. Aufl.). Carl Hanser. (Siehe S. 53).
- Sabahi, S., & Parast, M. M. (2020). The impact of entrepreneurship orientation on project performance: A machine learning approach. *International Journal of Production Economics*, 226, 107621. <https://doi.org/10.1016/j.ijpe.2020.107621> (siehe S. 22)
- Sarasvathy, S. D. (1998). *How do Firms Come to Be? Towards a Theory of the Entrepreneurial Process* (Diss.). Carnegie Mellon University. (Siehe S. 4).
- Sarasvathy, S. D. (2001). Causation and Effectuation: Toward a Theoretical Shift from Economic Inevitability to Entrepreneurial Contingency. *The Academy of Management Review*, 26 (2), 243–263. <https://doi.org/https://doi.org/10.2307/259121> (siehe S. 1, 3–5, 91, 93, 94, 126)
- Sarasvathy, S. D. (2003). Entrepreneurship as a science of the artificial. *Journal of Economic Psychology*, 24 (2), 203–220. [https://doi.org/https://doi.org/10.1016/S0167-4870\(02\)00203-9](https://doi.org/https://doi.org/10.1016/S0167-4870(02)00203-9) (siehe S. 1, 93)
- Sarasvathy, S. D. (2004). Making It Happen: Beyond Theories of the Firm to Theories of Firm Design. *Entrepreneurship Theory and Practice*, 28 (6), 519–531. <https://doi.org/10.1111/j.1540-6520.2004.00062.x> (siehe S. 4)
- Sarasvathy, S. D. (2009). *Effectuation: Elements of Entrepreneurial Expertise*. Edward Elgar Publishing. (Siehe S. 2–4, 11, 15–20, 40, 49, 86–89, 92–94, 96, 99, 113, 125, 128).
- Sarasvathy, S. D., & Dew, N. (2003). Effectual Networks: A pre-commitment approach to bridging the gap between opportunism and trust. *Proceedings of the Academy of Management Annual Meeting* (siehe S. 5).
- Sarasvathy, S. D., & Kotha, S. (2001). Managing Knightian Uncertainty in the New Economy. In J. Butler (Hrsg.), *ECommerce & Entrepreneurship* (S. 31–62). Information Age Publishing. (Siehe S. 21).

- Sargent, R. G. (1992). Validation and Verification of Simulation Models. *Proceedings of the 24th Conference on Winter Simulation*, 104–114. <https://doi.org/10.1145/167293.167311> (siehe S. 57)
- Sargent, R. G. (2013). Verification and Validation of Simulation Models. *Journal of Simulation*, 7 (1), 12–24. <https://doi.org/https://doi.org/10.1057/jos.2012.20> (siehe S. 58–60, 82)
- Schlesinger, S., Crosbie, R. E., Gagné, R. E., Innis, G. S., Lalwani, C. S., Loch, J., Sylvester, R. J., Wright, R. D., Kheir, N., & Bartos, D. (1979). Terminology for model credibility. *Simulation*, 32 (3), 103–104. <https://doi.org/10.1177/003754977903200304> (siehe S. 57, 58, 82)
- Schumpeter, J. A. (1943). *Capitalism, Socialism and Democracy*. George Allen & Unwin. (Siehe S. 21).
- Schumpeter, J. A. (1912). *Theorie der wirtschaftlichen Entwicklung*. Duncker & Humblot. (Siehe S. 1).
- Selden, P. D., & Fletcher, D. E. (2015). The entrepreneurial journey as an emergent hierarchical system of artifact-creating processes. *Journal of Business Venturing*, 30 (4), 603–615. <https://doi.org/10.1016/j.jbusvent.2014.09.002> (siehe S. 4)
- Shannon, C. E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27 (3), 379–423 (siehe S. 18).
- Shirur, M., Shivalingegowda, N. S., Chandregowda, M. J., Manjunath, V., & Rana, R. K. (2019). Critical dimensions of entrepreneurship and entrepreneurial behaviour among mushroom growers: Investigation through Principal Component Analysis. *Indian Journal Of Agricultural Research*, 53 (5), 619–623. <https://doi.org/10.18805/ijare.a-5261> (siehe S. 22)
- Siggelkow, N., & Rivkin, J. W. (2006). When Exploration Backfires: Unintended Consequences of Multilevel Organizational Search. *Academy of Management Journal*, 49 (4), 779–795. <https://doi.org/10.5465/amj.2006.22083053> (siehe S. 48)
- Simon, H. A. (1959). Theories of Decision-Making in Economics and Behavioral Science. *The American Economic Review*, 49 (3), 253–283. <http://www.jstor.org/stable/1809901> (siehe S. 49)
- Simon, H. A. (1962). The Architecture of Complexity. *Proceedings of the American Philosophical Society*, 106 (6), 467–482 (siehe S. 48).
- Stazyk, E. C., & Goerdel, H. T. (2011). The Benefits of Bureaucracy: Public Managers' Perceptions of Political Support, Goal Ambiguity, and Organizational Effectiveness. *Journal of Public Administration Research and Theory*, 21 (4), 645–672. <https://doi.org/10.1093/jopart/muq047> (siehe S. 56)
- Sterzel, M., & Richter, M. (2019). Effectuation: State Of The Art Literature Review And Developing Agent-Based Model Approaches. *BAM2019 Conference Proceedings* (siehe S. 7).
- Still, S., & Precup, D. (2012). An information-theoretic approach to curiositydriven reinforcement learning. *Theory in Biosciences*, 131 (3), 139–148. <https://doi.org/10.1007/s12064-011-0142-z> (siehe S. 90)
- Strehl, A. L., Li, L., Wiewiora, E., Langford, J., & Littman, M. L. (2006). PAC model-free reinforcement learning. *Proceedings of the 23rd international conference on Machine learning*, 881–888. <https://doi.org/10.1145/1143844.1143955> (siehe S. 29)

- Suay, H. B., & Chernova, S. (2011). Effect of human guidance and state space size on Interactive Reinforcement Learning. *2011 Ro-Man*, 1–6. <https://doi.org/10.1109/roman.2011.6005223> (siehe S. 129)
- Sutton, R. S., & Barto, A. G. (2018, 13. November). *Reinforcement Learning: An Introduction* (2. Aufl.). MIT Press. (Siehe S. 22, 24, 26, 28–30, 32, 86, 89).
- Szepesvari, C. (1998). Reinforcement learning: Theory and practice. In M. Hrehus (Hrsg.), *Proceedings of the 2nd Slovak Conference on Artificial Neural Networks (SCANN'98)* (S. 29–39). (Siehe S. 22).
- Taleb, N. N. (2010). *The Black Swan: Second Edition: The Impact of the Highly Improbable Fragility*. Random House. (Siehe S. 130).
- Tan, S. S., & Koh, H. C. (1996). Modelling Entrepreneurial Inclination with an Artificial Neural Network. *Journal of Small Business & Entrepreneurship*, 13 (2), 14–24. <https://doi.org/10.1080/08276331.1996.10600518> (siehe S. 22)
- Theocharous, G., Thomas, P. S., & Ghavamzadeh, M. (2015). Personalized ad recommendation systems for life-time value optimization with guarantees. *Proceedings of the 24th International Conference on Artificial Intelligence*, 1806–1812 (siehe S. 22).
- Tomy, S., & Pardede, E. (2018). From Uncertainties to Successful Start Ups: A Data Analytic Approach to Predict Success in Technological Entrepreneurship. *Sustainability*, 10 (3), 602–626 (siehe S. 19).
- Townsend, D. M., Hunt, R. A., McMullen, J. S., & Sarasvathy, S. D. (2018). Uncertainty, Knowledge Problems, and Entrepreneurial Action. *Academy of Management Annals*, 12 (2), 659–687. <https://doi.org/10.5465/annals.2016.0109> (siehe S. 19, 20, 90)
- Tsitsiklis, J. N. (1994). Asynchronous stochastic approximation and Q-learning. *Machine learning*, 16 (3), 185–202 (siehe S. 118).
- van Eck, N. J., & Waltman, L. (2017). Citation-based clustering of publications using CitNetExplorer and VOSviewer. *Scientometrics*, 111 (2), 1053–1070. <https://doi.org/10.1007/s11192-017-2300-7> (siehe S. 6)
- van Otterlo, M., & Wiering, M. (2012). Reinforcement Learning and Markov Decision Processes. In M. van Otterlo & M. Wiering (Hrsg.), *Adaptation, Learning, and Optimization* (S. 2–42). Springer. https://doi.org/10.1007/978-3-642-27645-3_10. (Siehe S. 23)
- Vilalta, R., Giraud-Carrier, C. G., Brazdil, P., & Soares, C. (2004). Using Meta-Learning to Support Data Mining. *International Journal of Computer Science & Applications*, 1 (1), 31–45 (siehe S. 21).
- Waldman, D. A., Ramirez, G. G., House, R. J., & Puranam, P. (2001). Does Leadership Matter? CEO Leadership Attributes and Profitability under Conditions of Perceived Environmental Uncertainty. *The Academy of Management Journal*, 44 (1), 134–143. <https://doi.org/10.2307/3069341> (siehe S. 56)
- Watkins, C. J. H., & Dayan, P. (1992). Q-learning. *Machine Learning*, 8, 55–68. Verfügbar 6. Mai 2020 unter <https://ci.nii.ac.jp/naid/10000035109/> (siehe S. 89, 118, 128)
- Welter, C., & Kim, S. (2018). Effectuation under risk and uncertainty: A simulation model. *Journal of Business Venturing*, 33 (1), 100–116. <https://doi.org/10.1016/j.jbusvent.2017.11.005> (siehe S. 4, 8, 35, 47–51, 59, 61, 64, 72–83, 86, 88, 89, 91–93, 96, 99, 126, 128, 130)
- Welter, C., Mauer, R., & Wuebker, R. J. (2016). Bridging Behavioral Models and Theoretical Concepts: Effectuation and Bricolage in the Opportunity Creation Framework. *Strategic Entrepreneurship Journal*, 10 (1), 5–20. <https://doi.org/10.1002/sej.1215> (siehe S. 4, 47)

- Werner, M. (2008). *Information und Codierung: Grundlagen und Anwendungen* (2. Aufl.). Vieweg+Teubner. (Siehe S. 18).
- Wessler, M. (2012). *Entscheidungstheorie: Von der klassischen Spieltheorie zur Anwendung kooperativer Konzepte*. Springer Gabler. (Siehe S. 13).
- Wiltbank, R., Dew, N., Read, S., & Sarasvathy, S. D. (2006). What to do next? The case for non-predictive strategy. *Strategic Management Journal*, 27 (10), 981–998. <https://doi.org/10.1002/smj.555> (siehe S. 2, 93)
- Wiltbank, R., Read, S., Dew, N., & Sarasvathy, S. D. (2009). Prediction and control under uncertainty: Outcomes in angel investing. *Journal of Business Venturing*, 24 (2), 116–133. <https://doi.org/10.1016/j.jbusvent.2007.11.004> (siehe S. 129)
- Wolfswinkel, J. F., Furmueller, E., & Wilderom, C. P. M. (2013). Using grounded theory as a method for rigorously reviewing literature. *European Journal of Information Systems*, 22 (1), 45–55. <https://doi.org/10.1057/ejis.2011.51> (siehe S. 4, 5, 7, 125)
- Wooldridge, J. (2013). *Introductory Econometrics: A Modern Approach* (5. Aufl.). South-Western Cengage Learning. (Siehe S. 98).
- Yadav, N., Swami, S., & Pal, P. (2006). High Technology Marketing: Conceptualization and Case Study. *Vikalpa*, 31 (2), 57–74. <https://doi.org/10.1177/0256090920060204> (siehe S. 20)
- Yang, S.-J. S., & Chandra, Y. (2013). Growing artificial entrepreneurs. *International Journal of Entrepreneurial Behavior & Research*, 19 (2), 210–237. <https://doi.org/10.1108/13552551311310383> (siehe S. 4, 22, 86, 125)
- Yannakakis, G. N., & Togelius, J. (2018). *Artificial Intelligence and Games*. Springer. <https://doi.org/10.1007/978-3-319-63519-4>. (Siehe S. 22)
- You, C., Lu, J., Filev, D., & Tsiotras, P. (2019). Advanced planning for autonomous vehicles using reinforcement learning and deep inverse reinforcement learning. *Robotics and Autonomous Systems*, 114, 1–18. <https://doi.org/10.1016/j.robot.2019.01.003> (siehe S. 22)
- Zekic-Susac, M., Sarlija, N., & Pfeifer, S. (2013). Combining PCA analysis and neural networks in modelling entrepreneurial intentions of students. *Croatian Operational Research Review*, 4 (1), 306–317 (siehe S. 22).
- Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep Learning Based Recommender System: A Survey and New Perspectives. *ACM Computing Surveys*, 52 (1), 5:1–5:38. <https://doi.org/10.1145/3285029> (siehe S. 22)
- Zhang, S. X., & Van Burg, E. (2019). Advancing entrepreneurship as a design science: developing additional design principles for effectuation. *Small Business Economics*, 55, 607–626. <https://doi.org/10.1007/s11187-019-00217-x> (siehe S. 3, 8, 93)
- Zondervan-Zwijenburg, M., Peeters, M., Depaoli, S., & de Schoot, R. V. (2017). Where Do Priors Come From? Applying Guidelines to Construct Informative Priors in Small Sample Research. *Research in Human Development*, 14 (4), 305–320. <https://doi.org/10.1080/15427609.2017.1370966> (siehe S. 18)