

Forum Marketing

Katja Gelbrich · Reinhard Hünenberg · Andreas Mann
Armin Töpfer *Hrsg.*

Stefanie Arz

Persönlichkeitsbasierte Personalisierung im Mobile Commerce

Eine verhaltenswissenschaftliche
Analyse am Beispiel von
Supermarkt-Apps

MOREMEDIA



Springer Gabler

Forum Marketing

Reihe herausgegeben von

Katja Gelbrich, Universität Eichstätt-Ingolstadt, Ingolstadt, Deutschland

Reinhard Hünnerberg, FB 07, Universität Kassel, Kassel, Deutschland

Andreas Mann, Lehrstuhl für Marketing, Universität Kassel, Kassel, Deutschland

Armin Töpfer, LS Marktorientierte Unternehmensführung, TU Dresden, Dresden, Sachsen, Deutschland

Die zunehmende Globalisierung führt zu einem verschärften Wettbewerb, vor allem in den Bereichen Qualität, Zeit und Kosten. Vor diesem Hintergrund werden in der Schriftreihe aktuelle Forschungsergebnisse sowohl zu strategischen Fragen der marktorientierten Unternehmensführung als auch zur operativen Umsetzung durch konsequente Kundenorientierung präsentiert. Dazu werden innovative Konzeptionen entwickelt, theoretische Ursache-Wirkungs-Beziehungen analysiert und pragmatische Gestaltungsempfehlungen gegeben.

Weitere Bände in der Reihe <http://www.springer.com/series/12585>

Stefanie Arz

Persönlichkeitsbasierte Personalisierung im Mobile Commerce

Eine verhaltenswissenschaftliche
Analyse am Beispiel von
Supermarkt-Apps

 Springer Gabler

Stefanie Arz
Hofheim am Taunus, Deutschland

Dissertation Universität Kassel, Fachbereich Wirtschaftswissenschaften, 2020

Dissertation ist unter dem folgenden Originaltitel erschienen: Persönlichkeitsbasierte Personalisierung zur Steigerung der Nutzungsabsicht von Shopping-Apps

Disputation am 26.06.2020

Forum Marketing

ISBN 978-3-658-31818-5

ISBN 978-3-658-31819-2 (eBook)

<https://doi.org/10.1007/978-3-658-31819-2>

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), exklusiv lizenziert durch Springer Fachmedien Wiesbaden GmbH, ein Teil von Springer Nature 2020

Das Werk einschließlich aller seiner Teile ist urheberrechtlich geschützt. Jede Verwertung, die nicht ausdrücklich vom Urheberrechtsgesetz zugelassen ist, bedarf der vorherigen Zustimmung des Verlags. Das gilt insbesondere für Vervielfältigungen, Bearbeitungen, Übersetzungen, Mikroverfilmungen und die Einspeicherung und Verarbeitung in elektronischen Systemen.

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: Carina Reibold

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

Inhaltsverzeichnis

1	Einleitung	1
1.1	Problemstellung	1
1.2	Forschungsstand	5
1.2.1	Untersuchungen zu persönlichkeitsbasierter Personalisierung	5
1.2.2	Untersuchungen zur Wirkung von Personalisierung	10
1.2.3	Untersuchungen zur algorithmenbasierten Persönlichkeitsermittlung	18
1.3	Zielsetzung und Aufbau der Arbeit	21
2	Konzeptionelle Grundlagen der persönlichkeitsbasierten Personalisierung	25
2.1	Grundlagen der Personalisierungsforschung	25
2.1.1	Abgrenzung von verwandten Begriffen	26
2.1.2	Personalisiertes Interface als geeignete Form der Personalisierung	29
2.2	Grundlagen der Persönlichkeitsforschung	33
2.2.1	Eigenschaftstheoretische Ansätze	34
2.2.2	Die Big Five	36
2.2.3	Eignung der Big Five für persönlichkeitsbasierte Personalisierung	41
3	Studie 1: Persönlichkeit und App-Interface-Präferenzen	45
3.1	Theoretische Grundlagen: Biologische Persönlichkeitstheorien ...	46
3.1.1	Neurowissenschaftliche Persönlichkeitstheorien	47
3.1.2	Evolutionstheoretische Persönlichkeitstheorien	50

3.2	Empirische Forschungsergebnisse zu App-Interface-Präferenzen	52
3.2.1	Extraversion und App-Interface-Präferenzen	53
3.2.2	Verträglichkeit und App-Interface-Präferenzen	58
3.2.3	Gewissenhaftigkeit und App-Interface-Präferenzen	61
3.2.4	Neurotizismus und App-Interface-Präferenzen	65
3.2.5	Offenheit und App-Interface-Präferenzen	68
3.2.6	Erkenntnisse für die Gestaltung von Supermarkt-Apps	72
3.3	Methodische Grundlagen von Studie 1	73
3.3.1	Präferenzmessung durch Conjoint Analysen	73
3.3.2	Attribute und Ausprägungen der Conjoint Analyse	75
3.3.2.1	Anforderungen an Attribute und Ausprägungen	76
3.3.2.2	Definition von Attributen und Ausprägungen	77
3.3.2.3	Gestaltung der Stimuli	82
3.3.3	Wahl des Conjoint Analyse Verfahrens	86
3.3.4	Design und Ablauf der Adaptiven Choice-based Conjoint Analyse (ACBC)	90
3.3.4.1	„Build Your Own (BYO)“-Phase	91
3.3.4.2	Screening-Phase	93
3.3.4.3	Choice Tournament	94
3.3.4.4	Kalibrierungsphase	96
3.3.4.5	Prüffälle	97
3.3.5	Methoden zur Schätzung der Teilnutzenwerte (TNW)	99
3.3.5.1	Überblick verschiedener Methoden	100
3.3.5.2	Hierarchical-Bayes-Ansatz	101
3.3.6	Operationalisierung der Kovariate	104
3.3.6.1	Big Five	104
3.3.6.2	Kontrollvariablen	107
3.3.7	Grundgesamtheit und Stichprobe	108
3.4	Ergebnisse von Studie 1	109
3.4.1	Beschreibung der Stichprobe	110
3.4.2	Güte der Messung	117
3.4.2.1	Güte der Big Five Skala	117
3.4.2.2	Güte der ACBC	120
3.4.3	Ergebnisse der ACBC	124
3.4.3.1	Allgemeine Präferenzen	124
3.4.3.2	Einfluss der Big Five	128
3.4.3.2.1	Extraversion	130

3.4.3.2.2	Verträglichkeit	133
3.4.3.2.3	Gewissenhaftigkeit	134
3.4.3.2.4	Neurotizismus	134
3.4.3.2.5	Offenheit	135
3.5	Zusammenfassende Erkenntnisse für die persönlichkeitsbasierte Personalisierung	137
4	Studie 2: Wirkung persönlichkeitsbasierter Personalisierung	141
4.1	Theoriegeleitete Hypothesenbildung	141
4.1.1	Auswahl geeigneter Theorien	142
4.1.2	Einstellungstheorien	144
4.1.2.1	Definition Einstellung	145
4.1.2.2	Einstellungs-Intentions-Verhaltensachse	147
4.1.2.3	Hypothesenbildung	150
4.1.3	Konsistenztheorien	151
4.1.3.1	Definition Selbstkonzept	151
4.1.3.2	Selbstkonsistenz- und Selbstkongruenz-Theorie	154
4.1.3.3	Hypothesenbildung	158
4.1.4	Reaktanztheorie	161
4.1.4.1	Reaktanzprozess	161
4.1.4.2	Hypothesenbildung	163
4.1.5	Übersicht Hypothesen	167
4.2	Methodische Grundlagen von Studie 2	169
4.2.1	Experimentelle Befragung als Verfahren der Datenerhebung	169
4.2.2	Strukturgleichungsanalyse als Verfahren der Datenanalyse	171
4.2.3	Manipulation der Experimentalfaktoren	176
4.2.3.1	Persönlichkeitskongruenz	176
4.2.3.2	Datensammlung und -kontrolle	180
4.2.3.3	Manipulationscheck	181
4.2.4	Operationalisierung der latenten Konstrukte	183
4.2.4.1	Einstellung	183
4.2.4.2	Nutzungsabsicht	184
4.2.4.3	Lebensmittel-Involvement	185
4.2.4.4	Datenschutz-Bedenken	187
4.2.5	Design und Ablauf des Experiments	188
4.2.6	Grundgesamtheit und Stichprobe	190
4.3	Ergebnisse von Studie 2	192
4.3.1	Beschreibung der Stichprobe	192

4.3.2	Manipulationscheck	195
4.3.3	Güte der Messmodelle	196
4.3.4	Analyse des Strukturmodells	201
4.3.4.1	Modellierung und Schätzung des statistischen Pfadmodells.	202
4.3.4.2	Analyse der direkten Effekte.	210
4.3.4.3	Analyse der Moderatoreffekte.	211
4.3.4.3.1	Möglichkeiten der Datenkontrolle . . .	211
4.3.4.3.2	Lebensmittel-Involvement.	212
4.3.4.3.3	Datenschutz-Bedenken	215
4.3.4.3.4	Lebensmittel-Involvement und Datenschutz-Bedenken	217
4.4	Zusammenfassung der Hypothesenprüfung.	219
5	Schlussbetrachtung	223
5.1	Zusammenfassung der Ergebnisse.	223
5.2	Implikationen für die Forschung	226
5.3	Implikationen für die Praxis.	229
5.4	Limitationen und zukünftiger Forschungsbedarf.	237
	Literaturverzeichnis	243

Abkürzungsverzeichnis

ACA	Adaptive Conjoint Analyse
ACBC	Adaptive Choice-based Conjoint Analyse
ANCOVA	Analysis of Covariance (Kovarianzanalyse)
ANOVA	Analysis of Variance (Varianzanalyse)
BFI	Big Five Inventory
BFI-K	Big Five Inventory – Kurzversion
BFI-S	Big Five Inventory – SOEP
BPS	Brand Personality Scale
CBC	Choice-based Conjoint Analyse
CFIP	Concern for Information Privacy
CIP	Consumer Involvement Profile
DB	Datenschutz-Bedenken
DEV	Durchschnittliche extrahierte Varianz
DK	Datenkontrolle
DS	Datensammlung
EFA	Explorative Faktorenanalyse
EIN	Einstellung
EV-Hypothese	Einstellungs-Verhaltens-Hypothese
EXT	Extraversion
EXT \uparrow -/EXT \downarrow -Personen	Personen mit einem hohen/niedrigen Grad an Extraversion
GEW	Gewissenhaftigkeit
GEW \uparrow -/GEW \downarrow -Personen	Personen mit einem hohen/niedrigen Grad an Gewissenhaftigkeit
GIPC	Global Information Privacy Concern
HB	Hierarchical Bayes

INT	Nutzungsabsicht bzw. -intention
INV	(Lebensmittel-)Involvement
IUIPC	Internet Users' Information Privacy Concerns
KFA	Konfirmatorische Faktorenanalyse
MANCOVA	Multivariate Analysis of Covariance (Multivariate Kovarianzanalyse)
MANOVA	Multivariate Analysis of Variance (Multivariate Varianzanalyse)
MC	Manipulationscheck
ML	Maximum Likelihood
MNL	Multinomiale Logit-Analyse
NEO-FFI	NEO Five-Factor Inventory (NEO: Neurotizismus, Extraversion, Offenheit)
NEO-PI-R	Revised NEO-Personality Inventory (NEO: Neurotizismus, Extraversion, Offenheit)
NEU	Neurotizismus
NEU↑-/NEU↓-Personen	Personen mit einem hohen/niedrigen Grad an Neurotizismus
nz	nullzentriert
OD_OK	Offene Datensammlung ohne Datenkontrolle
OFF	Offenheit
OFF↑-/OFF↓-Personen	Personen mit einem hohen/niedrigen Grad an Offenheit
OK_MK	Offene Datensammlung mit Datenkontrolle
OLS	Ordinary Least Squares (gewöhnliche Methode der kleinsten Quadrate)
PK	Persönlichkeitskongruenz
SEM	Structural Equation Modeling (Strukturgleichungsanalyse)
SOEP	Sozio-oekonomisches Panel
SRMR	Standardized Root Mean Square Residual
TCA	Traditionelle Conjoint Analyse
TNW	Teilnutzenwert
TPB	Theory of Planned Behavior (Theorie des geplanten Verhaltens)
TRA	Theory of Reasoned Action (Theorie des vernünftigen Handelns)
VD	Verdeckte Datensammlung

VER	Verträglichkeit
VER \uparrow -/VER \downarrow -Personen	Personen mit einem hohen/niedrigen Grad an Verträglichkeit

Abbildungsverzeichnis

Abbildung 1.1	Aufbau der Arbeit	23
Abbildung 2.1	Abgrenzung Personalisierung, Individualisierung und Customization	28
Abbildung 2.2	Varianten der Personalisierungsform personalisiertes Interface	32
Abbildung 3.1	Einstiegsseiten deutscher Supermark-Apps	83
Abbildung 3.2	Beispiel-Stimuli von Studie 1	86
Abbildung 3.3	Phasen der ACBC in Studie 1	91
Abbildung 3.4	BYO-Aufgabe in Studie 1.	92
Abbildung 3.5	Choice Tournament in Studie 1.	96
Abbildung 3.6	Holdout-Aufgabe in Studie 1	99
Abbildung 4.1	Einstellungs-Intentions-Verhaltensachse, TRA und TPB	149
Abbildung 4.2	Konzeptionelles Pfadmodell von Studie 2	168
Abbildung 4.3	Experimenteller Stimulus VER \uparrow	178
Abbildung 4.4	Experimenteller Stimulus VER \downarrow	179
Abbildung 4.5	Experimentelle Stimuli Datensammlung und -kontrolle	181
Abbildung 4.6	Konzeptionelles und statistisches Pfaddiagramm (Moderation)	203
Abbildung 4.7	Statistisches Pfadmodell von Studie 2	206
Abbildung 4.8	Ergebnisse der Modell-Schätzung	210
Abbildung 4.9	Ergebnisse Mehrgruppen-Kausalanalyse INV_hoch vs. INV_niedrig	213
Abbildung 4.10	Ergebnisse Mehrgruppen-Kausalanalyse DB_hoch vs. DB_niedrig	216
Abbildung 4.11	Ergebnisse der Modell-Schätzung INV x DB.	218

Tabellenverzeichnis

Tabelle 1.1	Übersicht Untersuchungen zu persönlichkeitsbasierter Personalisierung	9
Tabelle 1.2	Übersicht Untersuchungen zur Wirkung von Personalisierung	14
Tabelle 2.1	Übersicht Formen der Personalisierung	30
Tabelle 2.2	Big Five inkl. Facetten und Beispielitems.	38
Tabelle 3.1	Big Five und Life History Strategien	51
Tabelle 3.2	EXT und App-Interface-Präferenzen	56
Tabelle 3.3	VER und App-Interface-Präferenzen	59
Tabelle 3.4	GEW und App-Interface-Präferenzen	62
Tabelle 3.5	NEU und App-Interface-Präferenzen	67
Tabelle 3.6	OFF und App-Interface-Präferenzen	70
Tabelle 3.7	Ausprägungen des Attributs Text	79
Tabelle 3.8	Ausprägungen des Attributs Bild	79
Tabelle 3.9	Ausprägungen des Attributs Farbe	80
Tabelle 3.10	Ausprägungen des Attributs Form	81
Tabelle 3.11	Ausprägungen des Attributs Feature	82
Tabelle 3.12	Stimuli-Gestaltung für das Attribut Text	85
Tabelle 3.13	Operationalisierung der Big Five (BFI-S)	107
Tabelle 3.14	Beschreibung der Stichprobe (Studie 1).	112
Tabelle 3.15	Big Five der Stichprobe	113
Tabelle 3.16	Ein Stichproben t-Test für Big Five.	115
Tabelle 3.17	Rotierte Komponentenmatrix BFI-S	118
Tabelle 3.18	Reliabilitätskennwerte des BFI-S.	119
Tabelle 3.19	Test-Retest-Reliabilität Übereinstimmungsquote	121
Tabelle 3.20	Test-Retest-Reliabilität Rangkorrelation	122

Tabelle 3.21	Holdout-Validität Hit-Rates	123
Tabelle 3.22	Holdout-Validität Rangkorrelation.	124
Tabelle 3.23	Likelihood-Quotienten-Test (Interaktionseffekte)	125
Tabelle 3.24	TNW und Wichtigkeiten (generischer HB)	126
Tabelle 3.25	Nullzentrierte Big Five.	128
Tabelle 3.26	TNW mit Big Five als Kovariate	131
Tabelle 4.1	Überblick Hypothesensystem.	167
Tabelle 4.2	SEM-Ansätze.	173
Tabelle 4.3	Manipulationscheck Persönlichkeitskongruenz	182
Tabelle 4.4	Manipulationscheck Datensammlung und -kontrolle	183
Tabelle 4.5	Operationalisierung Einstellung.	184
Tabelle 4.6	Operationalisierung Nutzungsabsicht	185
Tabelle 4.7	Operationalisierung Lebensmittel-Involvement.	187
Tabelle 4.8	Operationalisierung Datenschutz-Bedenken	188
Tabelle 4.9	Übersicht Experimentalgruppen.	190
Tabelle 4.10	Beschreibung der Stichprobe (Studie 2).	194
Tabelle 4.11	Anzahl Probanden pro Experimentalgruppe	195
Tabelle 4.12	Ergebnisse Manipulationscheck Datensammlung & -kontrolle.	196
Tabelle 4.13	Reliabilitätskennzahlen der Messmodelle	198
Tabelle 4.14	Prüfung des Fornell-Larcker-Kriteriums	200
Tabelle 4.15	Mustermatrix Hauptachsenanalyse	201
Tabelle 4.16	Zusammenfassung der Hypothesenprüfung.	221
Tabelle 5.1	Präferenzänderungen durch verschiedene Eigenschaften in Studie 1.	231
Tabelle 5.2	Häufigkeitstabelle der Variable Datenschutz-Bedenken (DB) in Studie 2.	232



1.1 Problemstellung

Informieren, spielen, kaufen – zahlreiche Aufgaben werden heute über das Smartphone erledigt. Für fast jede Aktivität gibt es eine App. Das Smartphone ersetzt so Navigationsgeräte, Fitnesstracker, Videotheken und sogar Einkaufszentren. Über 6 Millionen Apps waren 2018 in den App Stores von Google und Apple verfügbar (Bitkom, 2018a). Mehr als 80 Prozent der Deutschen verwenden zumindest hin und wieder ein Smartphone (Bitkom, 2018b), dabei verbringen sie durchschnittlich über zwei Stunden täglich mit der Nutzung von Apps (App Annie, 2019, S. 12). Apps etablieren sich zunehmend auch als Einkaufskanal – zwischen 2016 und 2018 ist die Anzahl der Aufrufe von Shopping-Apps in Deutschland um 75 Prozent gestiegen (ebd., S. 26). Über ein Viertel aller E-Commerce Transaktionen in Europa findet mittlerweile über Apps statt (Criteo, 2018, S. 6). Im Durchschnitt sind auf einem Smartphone in Deutschland über 90 Apps installiert – nur etwa ein Drittel davon werden jedoch mindestens einmal im Monat verwendet (App Annie, 2019, S. 13). Die meisten Apps werden dagegen nur wenige Male genutzt – durchschnittlich nur 10 Prozent der Nutzer öffnen eine App einen Monat nach der Installation noch (Adjust, 2018, S. 10).

Die Zahlen verdeutlichen einerseits die immense Bedeutung von Apps und des *App Commerce* – also dem Verkauf von Waren und Dienstleistungen über Apps. Sie zeigen andererseits aber auch welchem Wettbewerbsdruck App-Betreiber

Elektronisches Zusatzmaterial Die elektronische Version dieses Kapitels enthält Zusatzmaterial, das berechtigten Benutzern zur Verfügung steht
https://doi.org/10.1007/978-3-658-31819-2_1

unterliegen. Sie stehen vor der Herausforderung sich im Überangebot der App Stores durchzusetzen und ihre App als eine der wenigen regelmäßig genutzten Apps auf dem Smartphone eines Nutzers zu etablieren. Insbesondere die Bindung der Nutzer nach der Installation gilt als zentrales Erfolgskriterium für (Shopping-)Apps (Heinemann, 2018, S. 58). Eine Kernfrage für App-Betreiber ist entsprechend, wie sie sicherstellen, dass Nutzer ihre App gerne und regelmäßig verwenden und verhindern, dass diese das Interesse an der App schon nach kurzer Zeit verlieren. Die Nutzung von Shopping-Apps bezieht sich dabei sowohl auf den eigentlichen Kauf über die App also auch auf eine dem Kauf vorgelagerte Nutzung, beispielsweise zum Informieren über Produkte (und den anschließenden Kauf im stationären Geschäft).

In der Literatur werden verschiedene Möglichkeiten zur Steigerung der *Nutzungsabsicht* von Apps diskutiert. Neben qualitativ hochwertigen Inhalten, einem visuell ansprechenden und nutzerfreundlichen Design und Incentives wie Rabattaktionen wird dabei insbesondere die *Personalisierung* von Apps genannt (z. B. Stocchi et al., 2019; Wang & Lin, 2017). Personalisierung meint eine vom App-Betreiber initiierte Anpassung der *Inhalte* einer App, deren *Darstellung* und/oder deren *Funktionalität* an die auf Basis von Nutzerdaten ermittelten Bedürfnisse und Präferenzen eines Nutzers bzw. einer Nutzergruppe (z. B. Fan & Poole, 2006, S. 185; Ullrich, 2012, S. 36; siehe Stüber, 2013, S. 11 ff. für eine Übersicht verschiedener Definitionsansätze). Beispielsweise können Betreiber von Shopping-Apps basierend auf dem vergangenen Kaufverhalten eines Nutzers Rückschlüsse auf seine Präferenzen in Bezug auf Marken, Produktkategorien oder Preisniveau ziehen und Produktempfehlungen entsprechend anpassen. Auch die Begrüßung oder Bilder auf der Einstiegsseite einer App können an Nutzer-eigenschaften wie Geschlecht, Alter oder Wohnort ausgerichtet werden. Der Nutzer erhält auf diese Weise eine auf seine Bedürfnisse zugeschnittene App, ohne hierfür selbst Aufwand betreiben und seine – häufig nur schwer formulierbaren – Präferenzen explizit äußern zu müssen. Die Untersuchung entsprechender Personalisierungsmaßnahmen nimmt in der Marketing-forschung in den letzten Jahren stetig zu (siehe z. B. Literaturüberblicke von Salonen & Karjaluoto, 2016 sowie Zanker et al., 2019). Die Ergebnisse der Studien zeigen, dass Personalisierung die Bewertung von Apps verbessern und ihre Nutzungswahrscheinlichkeit steigern kann (siehe Abschnitt 1.2.2 für einen Studienüberblick). Zudem hilft Personalisierung den begrenzten Platz auf dem kleinen Bildschirm von Smartphones optimal auszunutzen und mit den relevantesten Inhalten zu befüllen (Chung et al., 2016, S. 66).

Eine zentrale Voraussetzung für eine erfolgreiche Personalisierung ist die Identifikation des Nutzers – beispielsweise über einen Login, Cookies oder die IP-Adresse – und das Abrufen von mit dem Nutzer verknüpften Daten (Ullrich, 2012, S. 41). Dabei stehen App-Betreibern in Zeiten von Big Data große Datenmengen aus vielfältigen Quellen zur Verfügung. Playlists auf Spotify, Amazon-Transaktionen, Facebook-Profile, Suchanfragen bei Google oder GPS-Koordinaten sind nur einige Beispiele für entsprechende Datenquellen. Mit jeder Bewegung im Internet hinterlassen Nutzer Spuren und offenbaren dabei ihre Angewohnheiten, Bedürfnisse und Präferenzen. Entsprechende Spuren werden daher auch als *digitaler Fußabdruck* bezeichnet (Matz & Netzer, 2017, S. 7; Muhle, 2018, S. 143 f.).

Noch vor einigen Jahren wurde der digitale Fußabdruck hauptsächlich genutzt, um soziodemografische und kaufverhaltensbezogene Informationen über Nutzer zu ermitteln. Beispielsweise kann anhand von Transaktionsdaten (d. h. gekaufte Produkte, Preise, Zahlungsweise etc.) prognostiziert werden, ob ein Nutzer eher männlich oder weiblich ist, welcher Altersgruppe er wahrscheinlich angehört oder, ob er ein Markenkäufer oder Schnäppchenjäger ist (Matz & Netzer, 2017, S. 7). Schon Anfang der 2000er merken Davenport et al. (2001) jedoch an, dass das Ansammeln entsprechender deskriptiver Informationen nicht automatisch zu einem besseren Verständnis der Nutzer führt.: “Companies [...] may know more *about* their customers, but they don’t know the customers themselves” (S. 63). So können zwei Nutzer mit gleichem Geschlecht, Alter und Preisbewusstsein sehr unterschiedliche Interessen, Einstellungen und Werte haben, die sich letztlich auch in ihrem Kauf- und Konsumverhalten manifestieren (Daniel, 2014, S. 2). Es werden daher aktuell zunehmend Ansätze entwickelt, die psychografische Merkmale wie Werte und Einstellungen (z. B. Kosinski et al., 2013), den Lebensstil (z. B. Daniel, 2014) oder die Persönlichkeit (z. B. Kosinski et al., 2014) von Nutzern mit Hilfe von Algorithmen und maschinellem Lernen auf Basis von digitalen Fußabdrücken vorhersagen und damit einen Einblick in das Innenleben der Nutzer ermöglichen.

Von besonderer Bedeutung ist dabei die *Persönlichkeit*, die als „mehr oder weniger feste und überdauernde Organisation des Charakters, des Temperaments, des Intellekts und der Physis eines Menschen“ (Eysenck, 1953, S. 2) andere Merkmale wie Werte oder den Lebensstil maßgeblich prägt. Die Persönlichkeit umfasst die Gesamtheit aller Eigenschaften, die eine Person unverwechselbar, d. h. von anderen unterscheidbar machen. Entsprechende Persönlichkeitseigenschaften (auch Traits oder Dispositionen) sind *zeitlich stabil* und *transsituativ*

konsistent, sie bleiben also über die Zeit und verschiedene Situationen hinweg erhalten (z. B. Extraversion, Gewissenhaftigkeit). Sie sind abzugrenzen von Zuständen, anhand derer Menschen sich nur kurzfristig voneinander unterscheiden (z. B. Müdigkeit, Freude) (Herzberg & Roth, 2014, S. 20). Die Bedeutung der Persönlichkeit für das Kauf- und Konsumverhalten wird schon seit vielen Jahrzehnten untersucht (z. B. Aaker, 1999; Levy, 1959; Sirgy, 1985). Lange Zeit war die Ermittlung von Persönlichkeitseigenschaften jedoch nur mit Hilfe von aufwendigen Befragungstechniken möglich, sodass persönlichkeitsbezogene Marketingansätze in der Praxis kaum umzusetzen waren (Matz & Netzer, 2017, S. 7 f.). Da Persönlichkeitseigenschaften nun jedoch auch auf Basis von z. B. Social Media Profilen, Smartphone-Daten oder Blog-Einträgen eines Nutzers prognostiziert werden können, sind entsprechende Eigenschaften zunehmend leicht zugänglich (Kosinski et al., 2014). Matz & Netzer (2017) bezeichnen algorithmenbasierte Ansätze zur Persönlichkeitsermittlung daher als „Game Changer“ (S. 8) für das psychografische Marketing.

Auch App-Betreiber haben häufig Zugriff auf Daten, die zur Persönlichkeitsermittlung verwendet werden können (siehe Abschnitt 1.3). Die ermittelten Persönlichkeitseigenschaften können dann wiederum zur Personalisierung der Apps genutzt werden. So können Nutzern je nachdem, ob sie beispielsweise extravertiert oder introvertiert sind, andere Produkte und Kaufargumente präsentiert oder unterschiedliche Bilder und Interaktionselemente angeboten werden. Eine entsprechende Personalisierung auf Grundlage von prognostizierten Persönlichkeitseigenschaften wird im Folgenden als *persönlichkeitsbasierte Personalisierung* bezeichnet. Da die Persönlichkeit das Einzigartige und Unverwechselbare einer Person widerspiegelt (Stemmler et al., 2011, S. 44), kann angenommen werden, dass App-Personalisierungsmaßnahmen, die auf Persönlichkeitseigenschaften beruhen, Nutzern stärker das Gefühl geben eine App sei „wie für sie gemacht“ als Personalisierungsmaßnahmen, die auf etablierteren, eher deskriptiven Eigenschaften (z. B. Soziodemografie) basieren. Damit hat die persönlichkeitsbasierte Personalisierung das Potential die Nutzungsabsicht von Apps in besonderem Maße zu steigern.

Grundsätzlich ist persönlichkeitsbasierte Personalisierung für Apps aus verschiedenen Bereichen und Branchen relevant. Sie eignet sich jedoch insbesondere für Apps mit heterogenen Zielgruppen, also Nutzern mit sehr unterschiedlichen Persönlichkeiten. Daher erscheint gerade die Lebensmittel-Branche als interessanter Anwendungsbereich und Untersuchungskontext, da sich die potenzielle Zielgruppe hier aus der gesamten (erwachsenen) Bevölkerung zusammensetzt. Zudem ist der Lebensmittel-Onlinehandel einer der wachstumsstärksten Bereiche des E-Commerce, wobei Lebensmittel-Onlinehändler

zunehmend auch Apps für den Verkauf der Lebensmittel anbieten (Lambrecht, 2018). Entsprechende Apps werden im Folgenden als *Supermarkt-Apps* bezeichnet. Das Verständnis des Begriffs Lebensmittel beschränkt sich in der Marketingforschung und -praxis nicht nur auf Nahrungsmittel, sondern orientiert sich am tatsächlichen Sortiment des Lebensmitteleinzelhandels. Daher umfasst der Begriff auch verbrauchsnahe Non-Food-Artikel wie Hygieneartikel, Körperpflegemittel, Drogerie- und Haushaltswaren (Hofer, 2009, S. 114).

Zusammenfassend lässt sich festhalten, dass neue technische Möglichkeiten der algorithmenbasierten Persönlichkeitsermittlung neuartige Personalisierungsmaßnahmen auf Basis der Persönlichkeit zulassen. Diese persönlichkeitsbasierte Personalisierung hat das Potential wesentlich zur Steigerung der Nutzungsabsicht von Shopping-Apps beizutragen und damit einer der zentralen Herausforderungen im App Commerce zu begegnen. Aufgrund der heterogenen Zielgruppe sowie der aktuellen Relevanz des (mobilen) Lebensmittel-Onlinehandels, steht die persönlichkeitsbasierte Personalisierung zur Steigerung der Nutzungsabsicht von Supermarkt-Apps im Fokus der vorliegenden Arbeit.

1.2 Forschungsstand

In den folgenden Kapiteln werden bestehende Forschungsarbeiten zu persönlichkeitsbasierter Personalisierung und aus verwandten Forschungsfeldern diskutiert, um die Zielsetzung der vorliegenden Arbeit zu schärfen und detailliertere Forschungsfragen abzuleiten. Zunächst werden hierzu Untersuchungen zu persönlichkeitsbasierter Personalisierung vorgestellt. Da es zu diesem Themenfeld bisher jedoch nur wenig Forschung gibt und diese zudem einen eher technischen Fokus hat, werden im Anschluss Untersuchungen dargelegt, die sich mit der Wirkung anderer Arten der Personalisierung beschäftigen. Abschließend werden kurz verschiedene Arbeiten zur algorithmenbasierten Persönlichkeitsermittlung präsentiert, da diese die (technische) Basis für die persönlichkeitsbasierte Personalisierung bilden.

1.2.1 Untersuchungen zu persönlichkeitsbasierter Personalisierung

Bestehende Untersuchungen zu persönlichkeitsbasierter Personalisierung (für einen Überblick siehe Tabelle 1.1) stammen größtenteils aus der Informatikforschung

und beschäftigen sich vor allem mit der Entwicklung von Algorithmen für die Empfehlung von Produkten oder anderen Objekten (z. B. Artikeln auf einer Nachrichtenseite). Entsprechende Systeme, die möglichst geeignete Objekte für einen Nutzer prognostizieren und empfehlen, werden auch als *Recommender Systeme* (Empfehlungssysteme) bezeichnet. Eine Reihe von Studien versucht Recommender Systeme durch Informationen über die Persönlichkeit der Nutzer anzureichern und die prognostizierten Empfehlungen auf diese Weise zu verbessern¹. Dabei können Studien, die Collaborative Filtering nutzen und solche, die Knowledge-based Filtering verwenden, unterschieden werden.

Bei dem *Collaborative Filtering (CF)* werden einem Nutzer Objekte empfohlen, an denen „ähnliche“ Nutzer ein Interesse haben (z. B. Produkte, die von ähnlichen Nutzern bereits gekauft wurden). Die Ähnlichkeit der Nutzer wird typischerweise auf Basis von Verhaltensmustern (z. B. Klick- oder Kaufhistorie) oder soziodemografischen Informationen bestimmt. Die Studien von Braunhofer et al. (2015), Fernández-Tobías et al. (2016), Hafshejani et al. (2018), Hu & Pu (2011) und Tkalčić et al. (2011) zeigen jedoch, dass die Identifikation von ähnlichen Nutzern auf Basis der Persönlichkeit² zu besseren Empfehlungsleistungen (gemessen z. B. durch die Auswahl oder Bewertung der empfohlenen Objekte) führen kann. Bei Wu & Chen (2015) ergibt sich die beste Empfehlungsleistung, wenn sowohl die Persönlichkeit als auch Verhaltensmuster zur Identifikation ähnlicher Nutzer herangezogen werden. Ein Experiment von Braunhofer et al. (2014) deutet zudem darauf hin, dass Empfehlungen, die durch CF-Recommender Systeme auf Basis der Persönlichkeit generiert werden, von Nutzern positiver bewertet werden als CF-Empfehlungen basierend auf soziodemografischen Daten.

¹Die Studien greifen dabei in der Regel auf bestehende Datensätze zurück, die in Trainingsdaten und Testdaten unterteilt werden. Auf Basis der Trainingsdaten wird ein Algorithmus „trainiert“, anhand der Testdaten wird die Leistung des Algorithmus (hier die Empfehlungsleistung) dann überprüft. Dabei werden die Empfehlungen des Algorithmus mit den Testdaten abgeglichen, es wird also geprüft, ob die für einen Nutzer empfohlenen Objekte, für diesen tatsächlich von besonderem Interesse sind. Das „besondere Interesse“ wird dabei je nach Studie z. B. durch die Bewertung von empfohlenen Videos (Wu & Chen, 2015) oder die Streaming-Häufigkeit von empfohlenen Musikstücken (Hu & Pu, 2011) ermittelt.

²Die Persönlichkeit wird dabei entweder direkt abgefragt (z. B. im Registrierungsprozess) oder algorithmenbasiert ermittelt (siehe Abschnitt 1.3).

Das *Knowledge-Based Filtering (KBF)* basiert auf explizit definierten Zusammenhängen zwischen Nutzer- und Objekteigenschaften. Die Basis hierfür bilden Studien, die Zusammenhänge zwischen der Persönlichkeit und der Präferenz für bestimmte Produkte oder Inhalte feststellen: Laut den Ergebnissen einer Befragung von Rentfrow & Gosling (2003) hängt beispielsweise die Vorliebe für Musik-Genres von der Persönlichkeit ab (z. B. hören extravertierte Personen tendenziell gerne Rap, Hip-Hop, Funk und elektronische Musik). Ähnliche Studien wurden auch für Präferenzen für Filme, Fernsehshows, Bücher und Zeitschriften durchgeführt (Cantador et al., 2013; Rentfrow et al., 2011). Entsprechende Erkenntnisse können zur Entwicklung von KBF-Algorithmen genutzt werden. Der Algorithmus von Hu & Pu (2010) schlägt beispielsweise jedem Nutzer solche Musikstücke vor, die laut den Ergebnissen von Rentfrow & Gosling (2003) zu seiner Persönlichkeit passen (beispielsweise wird extravertierten Personen vermehrt Rap, Hip-Hop, Funk und elektronische Musik empfohlen). Auch Büttner (2017) entwickelt einen KBF-Algorithmus, der Nutzern Produkte vorschlägt, die auf ihre Persönlichkeit abgestimmt sind (der „Produkt-Persönlichkeitsfit“ wurde in einer Vorstudie ermittelt). Die Ergebnisse seines Experiments zeigen, dass die Empfehlungen des persönlichkeitsbasierten KBF-Algorithmus die Präferenzen der Nutzer signifikant besser abbilden als zufällig generierte Empfehlungen. Der KBF-Algorithmus von Khwaja et al. (2019) schlägt Nutzern einer Tracking-App Aktivitäten vor, die kongruent zu ihrer Persönlichkeit sind. Die Kongruenz zwischen den Aktivitäten und der Persönlichkeit wurde vorab durch theoretische Überlegungen und eine Vorstudie beurteilt. Mit Hilfe eines Laborexperiments weisen die Autoren nach, dass das Ausführen der empfohlenen Aktivitäten das subjektive Wohlbefinden der Probanden erhöht.

Recommender Systeme sind nur eine der vielfältigen Möglichkeiten zur Personalisierung. Dennoch existieren kaum Arbeiten, die eine persönlichkeitsbasierte Personalisierung außerhalb von Recommender Systemen erforschen. Eine Ausnahme stellt die Studie von Matz et al. (2017) dar. Die Autoren untersuchen Varianten einer Werbeanzeige auf Facebook, deren Text und Bild auf verschiedene Persönlichkeiten zugeschnitten ist (z. B. je eine Variante für extravertierte und introvertierte Personen). Die Ergebnisse von drei Feldexperimenten zeigen, dass Nutzer, die eine Anzeige präsentiert bekommen, deren Text und Bild zu ihrer Persönlichkeit passt, signifikant häufiger auf die Anzeige klicken und häufiger auf der beworbenen Seite kaufen als Nutzer, die eine Anzeige sehen, deren Text und Bild ihrer Persönlichkeit widerspricht.

Auch die Studie von Sarsam & Al-Samarraie (2018) deutet auf ein großes Wirkungspotential persönlichkeitsbasierter Personalisierung hin. Die Autoren identifizieren in einer Vorstudie zunächst Zusammenhänge zwischen der Persönlichkeit und Design-Präferenzen (z. B. in Bezug auf Farben, Navigationsstruktur, Informationsmenge und -ausrichtung, Layout) und erstellen auf dieser Basis verschiedene Design-Varianten einer Lern-App. Die Ergebnisse eines Eye-Tracking-Experiments zeigen, dass Nutzer die App mit einem geringeren kognitiven Aufwand (gemessen anhand des Pupillendurchmessers) und einer größeren visuellen Aufmerksamkeit (gemessen anhand der Dauer der Augenfixierung) nutzen, wenn das Design an ihre Persönlichkeit angepasst ist.

Zusammenfassend kann festgehalten werden, dass Informationen über die Persönlichkeit von Nutzern in aktuellen Studien hauptsächlich für die Entwicklung von (CF) Recommender Systemen verwendet werden. Die entwickelten Algorithmen werden meist anhand von Sekundärdatensätzen getestet und weisen größtenteils eine bessere Empfehlungsleistung auf als Recommender Systeme ohne Berücksichtigung der Persönlichkeit. Die meisten Studien überprüfen jedoch nicht, wie entsprechende Empfehlungen von Nutzern wahrgenommen werden und ob sie entsprechend eine gesteigerte Nutzungsabsicht bewirken können. Die wenigen Studien, die Nutzerreaktionen untersuchen, lassen jedoch eine positive Wirkung vermuten. Die Studien von Matz et al. (2017) und Sarsam & Al-Samarraie (2018) zeigen zudem, dass die Persönlichkeit auch außerhalb von Recommender Systemen sinnvoll für eine Personalisierung verwendet werden kann und hier weitere Forschungsbemühungen wertvoll sind.

Tabelle 1.1 Übersicht Untersuchungen zu persönlichkeitsbasierter Personalisierung

Quelle	Kontext	Methode*	Ergebnis
1. Recommender Systeme			
<i>1.1 Collaborative Filtering (CF)</i>			
Braunhofer et al. (2014)	Tourismus-App	LE (n = 51)	CF-Empfehlungen auf Basis der Persönlichkeit werden besser bewertet als CF-Empfehlungen auf Basis der Soziodemografie
Braunhofer et al. (2015)	Tourismus-App	SD (n = 239)	Bessere Empfehlungsleistung bei CF auf Basis der Persönlichkeit als bei CF auf Basis der Soziodemografie
Fernández-Tobías et al. (2016)	Facebook (Likes)	SD (n > 220.000)	Bessere Empfehlungsleistung bei CF auf Basis der Persönlichkeit als bei Empfehlung der "beliebtesten Objekte"
Hafshejani et al. (2018)	Tourismus-App	SD (n = 380)	Bessere Empfehlungsleistung bei CF auf Basis der Persönlichkeit als bei CF auf Basis von Nutzerverhalten
Hu & Pu (2011)	Musikstreaming-Dienst	SD (n = 230)	Bessere Empfehlungsleistung bei CF auf Basis der Persönlichkeit als bei CF auf Basis der Streaming-Historie
Tkalčić et al. (2011)	Bilderdatenbank	SD (n = 52)	Bessere Empfehlungsleistung bei CF auf Basis der Persönlichkeit als bei CF auf Basis von Bilderbewertungen
Wu & Chen (2015)	Videostreaming-Dienst	SD (n = 2.672)	Beste Empfehlungsleistung bei CF auf Basis der Persönlichkeit <u>und</u> Streaming-Historie
<i>1.2 Korrelationsstudien, Basis für Knowledge-Based Filtering (KBF)</i>			
Cantador et al. (2013)	Facebook (Likes)	SD (n = 53.226)	Persönlichkeit beeinflusst, welche Unterhaltungsseiten auf Facebook gelikt werden (z. B. welche Buch- oder Filmgenres)
Rentfrow & Gosling (2003)	Präferenzen Musik-Genres	OB (n > 3.500)	Persönlichkeit beeinflusst Vorlieben für Musik-Genres
Rentfrow et al. (2011)	Präferenzen Unterhaltungs-Genres	OB (n > 3.000)	Persönlichkeit beeinflusst Vorlieben für Unterhaltungs-Genres (z. B. Musik, Fernsehen, Bücher und Zeitschriften)
<i>1.3 Knowledge-Based Filtering (KBF)</i>			
Büttner (2017)	Online-Shop (Elektronik)	LE (n = 62)	Empfehlungen auf Basis der Persönlichkeit bilden Präferenzen signifikant besser als der Zufall ab
Hu & Pu (2010)	Musikstreaming-Dienst	OB (n = 80)	Empfehlungen auf Basis der Persönlichkeit werden als passend und hilfreich bewertet
Khwaja et al. (2019)	Tracking-App	LE (n = 256)	Empfehlungen auf Basis der Persönlichkeit erhöhen das subjektive Wohlbefinden der Nutzer
2. Personalisierung von Text & Bild			
Matz et al. (2017)	Facebook (Werbeanzeigen)	3 FE (n > 3,5 Mio.)	Höhere Klick- und Conversionrate, wenn Texte und Bilder von Anzeigen auf Persönlichkeit eines Nutzers angepasst sind
3. Design-Personalisierung			
Sarsam & Al-Samarraie (2018)	Lern-App	LE (n = 87)	Geringerer kognitiver Aufwand und höhere Aufmerksamkeit, wenn Design einer App an Persönlichkeit eines Nutzers angepasst ist
* Legende:			
LE = Laborexperiment FE = Feldexperiment SD = Auswertung Sekundärdaten OB = Online-Befragung			

1.2.2 Untersuchungen zur Wirkung von Personalisierung

Bisher wurde vor allem an der Optimierung persönlichkeitsbasierter Recommender Systeme geforscht. Optimierte Recommender Systeme nutzen jedoch wenig, wenn nicht sichergestellt ist, dass die auf dieser Basis generierten Empfehlungen von den Nutzern positiv aufgenommen werden. Wissenschaftliche Erkenntnisse dazu, wie persönlichkeitsbasierte Personalisierung sich auf die Nutzungsabsicht auswirkt, liegen derzeit jedoch kaum vor. Daher werden nun die Ergebnisse von Studien dargestellt, die sich mit der Wirkung anderer Formen der Personalisierung beschäftigen (für einen Überblick siehe Tabelle 1.2). Dabei können vier Gruppen von Studien unterschieden werden: Von besonderer Relevanz sind zunächst Studien, die anstelle der Persönlichkeit andere *psychografische Merkmale* wie den Lebensstil eines Nutzers ermitteln und digitale Inhalte und deren Design daran anpassen. Daneben gibt es wissenschaftliche Arbeiten, die anstelle psychografischer Merkmale unmittelbare Informationen wie das Kauf- oder Klickverhalten und Angaben aus dem Registrierungsprozess als Basis der Personalisierung nutzen. Hierzu gehören einerseits Studien, die die Wirkung von durch *Recommender Systeme generierten Empfehlungen* untersuchen. Andererseits überprüfen einige Untersuchungen, wie Nutzer auf die *Integration von persönlichen Daten* wie ihren Namen oder Wohnort in Apps oder andere digitale Services reagieren. Die letzte Gruppe bilden schließlich Studien, die verschiedene *Personalisierungsmaßnahmen kombinieren*³.

³Im Folgenden nicht weiter beschrieben werden Studien, die Personalisierung nur oberflächlich untersuchen. Beispielsweise messen einige Studien die Einstellung von Nutzern gegenüber Personalisierung mittels generischer Items wie „I value Web sites that are personalized for my usage experience preferences.“ (Chellappa & Sin, 2005, S. 199). Die Ergebnisse entsprechender Studien sind vollkommen abhängig von der subjektiven Interpretation des Begriffs ‚personalisiert‘ durch den Befragten und damit wenig aussagekräftig für die Gestaltung von Personalisierungsmaßnahmen. Außerdem nicht beachtet werden Studien, die sich mit Umsetzungsdetails wie der optimalen Anzahl und Platzierung personalisierter Empfehlungen (z. B. Bodoff & Ho, 2016) beschäftigen, da die vorliegende Arbeit sich darauf fokussieren soll, zunächst das grundsätzliche Wirkungspotential von persönlichkeitsbasierter Personalisierung zu bestimmen. Schließlich werden Studien aus der Informatikforschung ausgeklammert, die sich allein mit der Entwicklung von Recommender Systemen befassen, diese jedoch nicht an realen Nutzern überprüfen (z. B. Li et al., 2014).

Die erste Gruppe von Studien weist die größte Ähnlichkeit zur persönlichkeitsbasierten Personalisierung auf: Zunächst werden hier anhand von Daten wie der Klick- oder Kaufhistorie *psychografische Merkmale* ermittelt, die dann wiederum die Basis für eine Personalisierung darstellen. Hauser et al. (2009) entwickeln einen Algorithmus, der aus dem Klickverhalten eines Nutzers auf seinen Denkstil⁴ schließt und das „Look and Feel“ eines Online-Shops entsprechend anpasst. Je nachdem welchen Denkstil ein Nutzer hat, weist der Shop beispielsweise ein verändertes Text-Bild-Verhältnis, einen anderen Informationsumfang und Komplexitätsgrad auf. Die Ergebnisse eines Feldexperiments zeigen, dass die Wiederbesuchs- und Kaufabsicht durch diese denkstilbasierte Personalisierung signifikant gesteigert werden kann. In einer Folgestudie mit optimiertem Algorithmus (Hauser et al. 2014) können die Ergebnisse repliziert werden, wobei die Wiederbesuchs- und Kaufabsicht noch stärker verbessert wird. Urban et al. (2014) wenden die denkstilbasierte Personalisierung im Zusammenhang mit Online-Anzeigen an und weisen eine signifikante Steigerung der Klickrate und Kaufabsicht im Vergleich zu generischen Anzeigen nach. In der Untersuchung von Böttger et al. (2015) wird dagegen der Lebensstil eines Nutzers anhand seiner Kundenkarteninformationen prognostiziert. Auf dieser Basis werden dann Bilder und Texte eines Newsletters angepasst. Laut den Ergebnissen eines Feldexperiments führt diese lebensstilbasierte Personalisierung zu einer gesteigerten Klickrate und wirkt sich positiv auf das Kaufverhalten (z. B. gesteigerte Anzahl gekaufter Produkte und Ausgaben pro Nutzer) aus. Kaptain & Parvian (2015) ordnen Nutzer basierend auf ihrem Klickverhalten schließlich verschiedenen Persuasionstypen zu und prognostizieren für jeden Typ die geeignetsten Call-to-Actions. Es zeigt sich ein signifikant positiver Einfluss auf Klickrate und Umsatz, wenn die Call-to-Actions an den Persuasionstypen eines Nutzers angepasst werden.

Die meisten Studien zur Wirkung von Personalisierung verzichten jedoch auf die Ermittlung von psychografischen Merkmalen und nutzen eher deskriptive Daten wie die *Klick- oder Kaufhistorie* direkt zur Personalisierung. Hierbei finden sich insbesondere Untersuchungen, die entsprechende Daten zur Generierung von *personalisierten Empfehlungen* verwenden, d. h. einem Nutzer

⁴Unter *Denkstil* verstehen die Autoren dabei a „person’s preferred way of gathering, processing, and evaluating information“ (Hauser et al., 2009, S. 203).

werden z. B. Produkte vorgeschlagen, die gut zu anderen angeschauten Produkten oder bisher getätigten Käufen passen (z. B. gleiche Marke oder Farbe). Die Studie von Frey et al. (2017) zeigt, dass entsprechende Empfehlungen in Apps häufiger angeklickt werden als generische Empfehlungen. Zudem lässt sich laut den Ergebnissen von Chung et al. (2016) auf diese Weise die Nutzungsfrequenz einer App erhöhen. Eine positive Wirkung auf die Klickrate konnte auch im Zusammenhang mit Online-Werbung nachgewiesen werden (Bleier & Eisenbeiss, 2015a). Darüber hinaus wurde in der Untersuchung von Liang et al. (2006) eine Verbesserung der Kundenzufriedenheit durch personalisierte Empfehlungen festgestellt. Allerdings zeigen die Autoren auch, dass eine hohe Anzahl an personalisierten Empfehlungen zu einem Information Overload führt und die Kundenzufriedenheit wieder senkt. Mögliche negative Effekte von Personalisierung ergeben sich zudem in der Untersuchung von Bleier & Eisenbeiss (2015b). Personalisierte Empfehlungen in Online-Bannern erhöhen hier nur bei vertrauenswürdigen Werbetreibenden die wahrgenommene Nützlichkeit und Klickrate der Banner. Bei wenig vertrauenswürdigen Werbetreibenden dagegen löst Personalisierung Datenschutz-Bedenken aus und senkt die Klickrate. In einem Laborexperiment von Bol et al. (2018) senkt Personalisierung direkt das Vertrauen in den Werbetreibenden. Negative Effekte ergeben sich auch bei Aguirre et al. (2015), sofern eine personalisierte Werbe-Anzeige keine Hinweise zur Datensammlung enthält. Wird die Datensammlung dagegen offen kommuniziert, erhöht Personalisierung die Klickrate. Zu einem ähnlichen Ergebnis kommt die Untersuchung von Song et al. (2016) im Zusammenhang mit Newslettern. Personalisierung führt hier ebenfalls zu Datenschutz-Bedenken, die jedoch gesenkt werden, wenn Nutzer kontrollieren können, welche Daten über sie gesammelt werden.

Neben der Klick- oder Kaufhistorie können auch *Registrierungsinformationen*, also Angaben, die Nutzer bei der Registrierung selbst tätigen (z. B. Geschlecht, Interessen, Wohnort), für die Generierung von Empfehlungen verwendet werden. Entsprechende direkte Selbstauskünfte gelten als valide Datenbasis für Recommender Systeme, sie sind jedoch nur bei registrierten Nutzern verfügbar⁵. Eine aktuelle Untersuchung im Kontext Supermarkt-Apps

⁵Die Abfrage von (vielen) Informationen kann zudem eine Hürde für die Registrierung darstellen.

von Ho & Lim (2018) zeigt, dass Produktempfehlungen auf Basis von Registrierungsinformationen einen Kaufreiz auslösen und zu (ungeplanten) Käufen der empfohlenen Produkte führen können. Laut den Ergebnissen der Untersuchung von Sutanto et al. (2013) können entsprechende Produktempfehlungen zudem die Nutzungsfrequenz einer Supermarkt-App erhöhen. Dies ist jedoch nur der Fall, wenn die Registrierungsdaten sicher auf dem eigenen Smartphone und nicht auf dem Server des App-Anbieters gespeichert werden. Im Kontext Online-Werbung führen personalisierte Empfehlungen auf Basis von durch den Nutzer getätigten Angaben laut der Studie von Li et al. (2019) zu einer verbesserten Einstellung gegenüber der Anzeige und der beworbenen Marke. Dies ist insbesondere dann der Fall, wenn Nutzer über stabile und extreme Präferenzen verfügen. Mögliche negative Konsequenzen von personalisierten Produktempfehlungen auf Basis von Registrierungsinformationen werden von Chau et al. (2013) offengelegt – in der Untersuchung führt Personalisierung zu Misstrauen, wenn die Empfehlungen einseitig oder irrelevant sind. Das Misstrauen wiederum resultiert in einer gesenkten Klickrate der Empfehlungen.

Gerade in Apps werden Empfehlungen häufig auch an den Standort eines Nutzers – in der Regel bestimmt über GPS oder WLAN – angepasst (*location-basierte Empfehlungen*). In einem Experiment von Ho & Chau (2013) erhalten Nutzer beispielsweise Empfehlungen für Restaurants, die sich in ihrer Nähe befinden und ihren Esspräferenzen entsprechen. Laut den Ergebnissen kann sich eine entsprechende Personalisierung sowohl positiv als auch negativ auf die Nutzungsabsicht einer App auswirken, wobei die Wirkungsrichtung von den grundsätzlichen Datenschutz-Bedenken eines Nutzers abhängt. Auch die Untersuchungen von Kang & Namkung (2019), Lee & Rha (2016) und Xu et al. (2011) stellen fest, dass Nutzer im Zusammenhang mit location-basierten Empfehlungen sowohl Mehrwerte als auch Risiken – insbesondere in Bezug auf ihre Privatsphäre – wahrnehmen. Die wahrgenommenen Mehrwerte überwiegen dabei jedoch tendenziell. Wahrgenommene Datenschutz-Risiken können zudem durch Möglichkeiten der Datenkontrolle gesenkt werden.

Tabelle 1.2 Übersicht Untersuchungen zur Wirkung von Personalisierung

Quelle	Kontext	Methode*	Ergebnis
1. Personalisierung auf Basis psychografischer Merkmale			
Böttger et al. (2015)	Newsletter (Möbel)	FE (n = 3.266)	Anpassung von Texten und Bildern an Lebensstil steigert Klickrate, Anzahl gekaufter Produkte und Ausgaben pro Nutzer
Hauser et al. (2009)	Online-Shop (Telekomm.)	FE (n = 835)	Anpassung des Designs an Denkstil eines Nutzers steigert Wiederbesuchs- und Kaufabsicht
Hauser et al. (2014)	Online-Shop (Finanzdienstleistungen)	FE (n = 502)	Anpassung des Designs an Denkstil eines Nutzers steigert Wiederbesuchs- und Kaufabsicht
Kaptein & Parvinen (2015)	Online-Shop (Mode)	FE (n = 1.449)	Anpassung von Call-to-Actions an Persuasionstyp erhöht Klickrate und Umsatz
Urban et al. (2014)	Online-Anzeigen (Elektronik)	FE (n = 116.168)	Anpassung des Designs an Denkstil steigert Klickrate und Kaufabsicht für beworbene Produkte
2. Personalisierte Empfehlungen			
<i>2.1 Empfehlungen basierend auf Klick- & Kaufhistorie</i>			
Aguirre et al. (2015)	Online-Werbung (Finanzdienstleistungen)	3 LE (n = 120 / 194 / 123)	Personalisierung erhöht Klickrate, wenn Datensammlung offen kommuniziert wird; offensichtliche Personalisierung ohne Kommunikation der Datensammlung führt zu Gefühl der Verletzlichkeit und senkt Klickrate
Bleier & Eisenbeiss (2015a)	Online-Werbung (Mode)	2 FE (n = 44.995 / 38.501)	Personalisierung erhöht Klickrate auf Produktempfehlungen (v.a. zu Beginn des Kaufprozesses)
Bleier & Eisenbeiss (2015b)	Online-Werbung (Elektronik)	LE (n = 252)	Bei vertrauenswürdigen Werbetreibenden: Personalisierung erhöht wahrgenommene Nützlichkeit und Klickrate; Bei nicht vertrauenswürdigen Werbetreibenden: Personalisierung führt zu Datenschutz-Bedenken und senkt Klickrate
Bol et al. (2018)	Online-Werbung (diverse Branchen)	LE (n = 1.131)	Personalisierung senkt Vertrauen in Werbetreibenden, insbesondere bei Werbung für Nachrichten-Websites und Online-Shops
Chung et al. (2016)	Nachrichten-App	FE (n = 109)	Personalisierung erhöht Nutzungsfrequenz der App
Frey et al. (2017)	Shopping-App (Elektronik)	FE (n = 73.244)	Personalisierung steigert Klickrate
Liang et al. (2006)	Nachrichten-Website	2 LE (n = 91 / 88)	Personalisierung erhöht Zufriedenheit; hohe Anzahl an Empfehlungen führt jedoch zu Information Overload und senkt Zufriedenheit
Song et al. (2016)	Newsletter (Finanzdienstleistungen)	3 LE (n = 102 / 110 / 168)	Personalisierung führt zu Datenschutz-Bedenken; diese können durch eine Kontrolle über die Datensammlung durch den Nutzer wieder gesenkt werden
<i>2.2. Empfehlungen basierend auf Registrierungsprofil</i>			
Chau et al. (2013)	Musik-Streamingdienst	LE (n = 245)	Personalisierung kann zu Misstrauen führen, wenn Produktempfehlungen irrelevant oder einseitig sind; Misstrauen senkt Klickrate auf Empfehlungen
Ho & Lim (2018)	Supermarkt-App	3 FE (n = 516 / 247 / 256)	Personalisierung löst Kaufreiz ('urge to buy') aus und führt zu ungeplanten Käufen
Ho & Tam (2005)	Online-Shop (Handy-Klingeltöne)	3 LE (n = 408 / 412 / 307)	Personalisierung erhöht Klickrate auf Produktempfehlungen und Kaufwahrscheinlichkeit der empfohlenen Produkte (v.a. zu Beginn des Kaufprozesses)
Li et al. (2019)	Online-Werbung (Reisen)	LE (n = 227)	Personalisierung verbessert Einstellung ggü. einer Anzeige und ggü. der beworbenen Marke, insbesondere bei stabilen und extremen Präferenzen der Nutzer
Sutanto et al. (2013)	Supermarkt-App	FE (n = 629)	Personalisierung erhöht Nutzungsfrequenz der App, bei hoher Datensicherheit (d. h. Daten auf Smartphone und nicht beim Unternehmen gespeichert)

(Fortsetzung)