

TECHNISCHE UNIVERSITÄT MÜNCHEN

Fakultät für Informatik
Lehrstuhl für Wirtschaftsinformatik
Prof. Dr. Helmut Kremer

Prognose der Akzeptanz von Innovationen am Beispiel autonomer Fahrzeuge

Christopher Oswald Kohl

Vollständiger Abdruck der von der Fakultät für Informatik der Technischen Universität München zur Erlangung des akademischen Grades eines

Doktors der Naturwissenschaften (Dr. rer. nat.)

genehmigten Dissertation.

Vorsitzende/-r:	Prof. Dr.-Ing. Jörg Ott
Prüfende/-r der Dissertation: 1.	Prof. Dr. Helmut Kremer
2.	Prof. Dr. Klaus Bengler

Die Dissertation wurde am 18.05.2021 bei der Technischen Universität München eingereicht und durch die Fakultät für Informatik am 28.10.2021 angenommen.

Zusammenfassung

Motivation: Das Ziel dieser Dissertation ist die Prognose der Akzeptanz von Innovationen am Beispiel autonomer Fahrzeuge. Häufig schaffen es Ideen oder Erfindungen nicht zur Marktreife oder werden vom Markt nicht angenommen. Trotz neuer Methoden der Marktforschung bleiben die Misserfolgsraten von Innovationen auf einem hohen Niveau. Die in dieser Dissertation vorgestellten Modelle und Verfahren können dazu beitragen, die Wahrscheinlichkeit für eine erfolgreiche Markteinführung von Erfindungen zu erhöhen.

Forschungsdesign: Im Rahmen dieser Dissertation führen wir vier Studien durch. In Studie 1 entwickeln wir ein Modell zur Prognose der Akzeptanz von Innovationen basierend auf UTAUT. Wir vergleichen die Ergebnisse in Studie 1 mit dem UTAUT Modell und in Studie 2 mit dem UTAUT2 Modell. In Studie 3 verwenden wir das Modell der gesellschaftlichen Akzeptanz. In Studie 4 entwickeln wir ein Verfahren zur Identifikation von Risiken und Nutzen einer neuen Technologie mit sozialen Medien, das auf einem maschinellen Lernverfahren basiert. Dieses Verfahren wenden wir zur Akzeptanzprognose autonomer Fahrzeuge an.

Ergebnisse: In Rahmen der vier Studien wurden 547 Probanden befragt sowie 1.963.905 Beiträge aus sozialen Medien ausgewertet. Wir konnten zeigen, dass subjektive Aspekte wie die Einstellung zur Nutzung oder Meinungen in Form von sozialen Einflüssen im Wesentlichen die Akzeptanz von neuen Technologien determinieren. Objektivere Faktoren wie die Leistungserwartung und die Aufwandserwartung haben nur einen indirekten Effekt auf die Nutzungsintention. Das Modell zur Prognose der Akzeptanz von Innovationen berücksichtigt dies und kann dadurch bereits in frühen Phasen des Produktentwicklungsprozesses angewendet werden, um die Akzeptanz von Innovationen zu erhöhen. Anhand von Studie 3 konnten wir zeigen, dass die Verringerung von Verkehrsunfällen als mit Abstand größter Vorteil autonomer Fahrzeuge betrachtet wird. Größtes Risiko ist der wahrgenommene Kontrollverlust bei autonomen Fahrzeugen. Prototypen von autonomen Fahrzeugen ohne Lenkrad zeigen zwar eindrucksvoll die technologischen Fortschritte, würden aber wohl zunächst nicht akzeptiert werden. In Studie 4 konnten wir zeigen, dass mit dem Verfahren zur Identifikation von Risiken und Nutzen einer neuen Technologie relevante Erkenntnisse für die Prognose der Akzeptanz von Innovationen aus sozialen Medien gewonnen werden können. Insbesondere konnten wir mit der Benefit Rate eine Metrik identifizieren, die als Proxy für die Akzeptanz dienen kann.

Beitrag: Mit dieser Dissertation leisten wir einen Beitrag für die Praxis, indem wir Faktoren aufzeigen, die für die Prognose der Akzeptanz von Innovationen relevant sind und bereits vor ihrer Markteinführung erhoben werden können. Weiterhin ermöglichen wir mit dem Verfahren zur Identifikation von Risiken und Nutzen einer neuen Technologie die Identifikation und Bewertung von akzeptanzrelevanten Beiträgen in sozialen Medien, die in den Produktentwicklungsprozess einfließen können. Der Beitrag zur Forschung ist ein Modell zur Prognose der Akzeptanz von Innovationen. Wir erweitern damit die Technologieakzeptanzforschung um einen neuen Kontext und zeigen, dass bisherige Technologieakzeptanzmodelle nur begrenzte Aussagekraft bezüglich der Prognose der Akzeptanz von Innovationen besitzen. Zusätzlich erschließen wir für die Akzeptanzforschung

eine weitere Methode zur Erhebung und Auswertung frei verfügbarer und umfangreich vorhandener empirischer Daten von der Social-Media-Plattform Twitter.

Limitationen: Wir beschränken uns in dieser Dissertation auf Produktinnovationen. Dienstleistungs- und Verfahrensinnovationen sind nicht Gegenstand dieser Dissertation. Die Ergebnisse der vier Studien dieser Dissertation basieren nicht auf repräsentativen Stichproben der Bevölkerung. Zukünftige Studien, mit dem Ziel repräsentative Ergebnisse für bestimmte Bevölkerungsgruppen zu erhalten, können auf den Studien dieser Dissertation aufbauen, sollten aber zusätzlich Alter und Geschlecht als Moderationseffekte berücksichtigen. Weiterhin muss bei der Anwendung von Verfahren, die auf Daten aus sozialen Medien basieren, auf von Algorithmen verfasste Beiträge geachtet werden. Wir konnten allerdings keine wesentliche Beeinflussung der in Studie 4 erhobenen Daten durch Algorithmen feststellen. Zuletzt erfolgt die Prognose der Akzeptanz von Innovationen nur anhand des Beispiels autonomer Fahrzeuge. Zukünftige Studien sollten die Generalisierbarkeit der Ergebnisse auf weitere Technologien untersuchen.

Abstract

Motivation: The aim of this dissertation is to predict the acceptance of innovations using the example of autonomous vehicles. Often, ideas or inventions do not make it to market maturity or are not accepted by the market. Despite new methods of market research, the failure rates of innovations remain at a high level. The models and methods presented in this dissertation can help to increase the probability of success of inventions for a successful market launch.

Research design: Within the scope of this dissertation, we conduct four studies. In study 1, we develop a model to predict the acceptance of innovations based on UTAUT. We compare the results in study 1 with the UTAUT model and in study 2 with the UTAUT2 model. In study 3, we apply the model of public acceptance. In study 4, we develop an approach to identify risks and benefits of a new technology with social media based on machine learning. We apply this approach to predict the acceptance of autonomous vehicles.

Results: We conducted four studies in which 547 respondents were interviewed and 1,963,905 contributions from social media were examined. We were able to show that subjective aspects such as attitudes towards use or opinions in the form of social influences mainly determine the acceptance of new technologies. More objective factors such as performance expectancy and effort expectancy only have an indirect effect on the intention of use. The model for predicting the acceptance of innovations takes this into account and can therefore be applied in early stages of the product development process to increase the acceptance of innovations. In study 3, we were able to show that the reduction of traffic accidents is considered by far the greatest advantage of autonomous vehicles. The greatest risk is the perceived loss of control caused by autonomous vehicles. Prototypes of autonomous vehicles without a steering wheel impressively show the technological progress but would probably not be accepted initially. In study 4, we were able to show that the approach to identify risks and benefits of a new technology can provide relevant insights for predicting the acceptance of innovations from social media. Particularly the benefit rate could serve as a proxy for acceptance.

Contribution: With this dissertation, we contribute to practice by showing factors that are relevant for predicting the acceptance of innovations and that can be applied even before their market launch. Furthermore, with the method for identifying risks and benefits of a new technology, we enable the identification and evaluation of acceptance-relevant contributions in social media, which can be incorporated into the product development process. The contribution to research is a model for predicting the acceptance of innovations. We thus extend technology acceptance research to a new context and show that previous technology acceptance models have only limited applicability with respect to the prediction of the acceptance of innovations. In addition, we contribute a new method to acceptance research for the collection and analysis of freely available and extensive empirical data on the social media platform Twitter.

Limitations: In this dissertation, we limit the scope to product innovations. Service and process innovations are not the subject of this dissertation. The results of the four studies in this

dissertation are not based on representative samples of the population. Future studies, with the objective of obtaining representative results for specific population groups could build on the studies of this dissertation but should additionally consider age and gender as moderation effects. Furthermore, when applying methods based on data from social media, attention must be paid to content generated by algorithms. However, we could not detect any substantial influence of algorithms on the data collected in study 4. Finally, the prediction of the acceptance of innovations is based only on the example of autonomous vehicles. Future studies should investigate the generalizability of the results to other technologies.

Inhaltsverzeichnis

Zusammenfassung	I
Abstract	III
Inhaltsverzeichnis	V
Abbildungsverzeichnis	IX
Tabellenverzeichnis	XI
Abkürzungsverzeichnis	XV
1 Einleitung	1
1.1 Motivation	1
1.2 Forschungsleitende Fragestellungen.....	3
1.3 Aufbau der Dissertation.....	5
2 Theoretischer Hintergrund	9
2.1 Definition von Innovation, Akzeptanz und Akzeptabilität.....	9
2.2 Technologieakzeptanz	10
2.2.1 Theory of Reasoned Action.....	10
2.2.2 Technology Acceptance Model (TAM).....	11
2.2.3 Unified Theory of Acceptance and Use of Technology (UTAUT)	13
2.2.4 Unified Theory of Acceptance and Use of Technology 2 (UTAUT2)	15
2.2.5 Schlussfolgerungen	19
2.3 Diffusionstheorie	21
2.3.1 Hauptelemente der Diffusionstheorie.....	21
2.3.2 Charakteristiken von Innovationen	22
2.3.3 Zeitliche Betrachtung der Diffusion.....	23
2.3.4 Kategorisierung der Marktteilnehmer	24
2.3.5 Schlussfolgerungen	26
2.4 Gesellschaftliche Akzeptanz.....	29
2.4.1 Modell der gesellschaftlichen Akzeptanz	29
2.4.2 Risikowahrnehmung.....	31
2.4.3 Widerstand gegen Technologie.....	35
2.4.4 Schlussfolgerungen	37
3 Stand der Technik	41
3.1 Anfänge der Fahrzeugautomatisierung.....	41

3.2	Stufen der Fahrzeugautomatisierung	42
3.3	Fahrerassistenzsysteme.....	44
3.4	Infrastruktur und Vernetzung	49
3.5	Evolution der Fahrerassistenzsysteme.....	49
3.6	Aktuelle Entwicklungen	51
4	Forschungsmethoden	55
4.1	Strukturierter Fragebogen.....	55
4.1.1	Skalenniveau	55
4.1.2	Kodierung.....	56
4.1.3	Konstrukte	57
4.2	Strukturgleichungsmodellierung	57
4.2.1	Pfadmodell	58
4.2.2	PLS-SEM Modellberechnung	59
4.2.3	Voraussetzungen für PLS-SEM	60
4.2.4	Anwendung des PLS-SEM Algorithmus	61
4.2.5	Evaluation reflektiv spezifizierter Messmodelle.....	62
4.2.6	Evaluation formativ spezifizierter Messmodelle.....	66
4.2.7	Evaluation des Strukturmodells	68
5	Studie 1: Modell zur Prognose der Akzeptanz von Innovationen	73
5.1	Motivation	73
5.2	Forschungsmodell.....	74
5.3	Material und Methoden	78
5.3.1	Operationalisierung der Leistungserwartung (PE).....	79
5.3.2	Operationalisierung der Aufwandserwartung (EE).....	81
5.3.3	Operationalisierung der sozialen Einflüsse (SI).....	81
5.3.4	Operationalisierung der Angst vor der Nutzung (ANX).....	83
5.3.5	Operationalisierung der Einstellung zur Nutzung (AT).....	83
5.3.6	Operationalisierung der verhaltensbasierten Nutzungsintention (BI).....	84
5.4	Ergebnisse.....	85
5.4.1	Erhebung und Prüfung der Daten.....	85
5.4.2	PLS-SEM Pfadmodell.....	86
5.4.3	Evaluation des Messmodells	87
5.4.4	Evaluation des Strukturmodells	91

5.4.5	Vergleich mit dem UTAUT Modell.....	95
5.5	Diskussion	103
5.6	Fazit	110
6	Studie 2: Technologieakzeptanz nach UTAUT2	111
6.1	Motivation	111
6.2	Forschungsmodell.....	112
6.3	Material und Methoden	116
6.3.1	Operationalisierung der Leistungserwartung (PE).....	118
6.3.2	Operationalisierung der Aufwandserwartung (EE).....	119
6.3.3	Operationalisierung der sozialen Einflüsse (SI).....	120
6.3.4	Operationalisierung der unterstützenden Bedingungen (FC).....	121
6.3.5	Operationalisierung der hedonischen Motivation (HM)	122
6.3.6	Operationalisierung des Preis-Leistungs-Verhältnisses (PV)	123
6.3.7	Operationalisierung der Gewohnheit (HT)	123
6.3.8	Operationalisierung der Nutzungsintention (BI).....	124
6.4	Ergebnisse.....	125
6.4.1	Erhebung und Prüfung der Daten.....	125
6.4.2	Erfahrung und Fachwissen	126
6.4.3	PLS-SEM Pfadmodell	130
6.4.4	Evaluation des Messmodells	132
6.4.5	Evaluation des Strukturmodells	136
6.5	Diskussion	141
6.6	Fazit	149
7	Studie 3: Gesellschaftliche Akzeptanz.....	151
7.1	Motivation	151
7.2	Forschungsmodell.....	152
7.3	Material und Methoden	153
7.3.1	Operationalisierung der Nutzenwahrnehmung (PB).....	155
7.3.2	Operationalisierung der Risikowahrnehmung (PR).....	157
7.3.3	Operationalisierung der Nutzungsintention (BI).....	161
7.4	Ergebnisse.....	163
7.4.1	Erhebung und Prüfung der Daten.....	163
7.4.2	Erfahrung und Fachwissen	164

7.4.3	PLS-SEM Pfadmodell	167
7.4.4	Evaluation des Messmodells	169
7.4.5	Evaluation des Strukturmodells	174
7.5	Diskussion	179
7.6	Fazit	186
8	Studie 4: Akzeptanzprognose mit sozialen Medien.....	187
8.1	Motivation	187
8.2	Material und Methoden	189
8.2.1	Datenextraktion	190
8.2.2	Datenvorverarbeitung.....	192
8.2.3	Modellerstellung und -evaluation.....	193
8.3	Ergebnisse.....	196
8.4	Diskussion	202
8.5	Fazit	206
9	Zusammenfassung.....	209
9.1	Zusammenfassung der Studien.....	209
9.2	Beiträge zu Theorie und Praxis	211
9.3	Limitationen.....	214
9.4	Fazit	216
	Literaturverzeichnis.....	217
	Anhang	237
	Anhang A: Fragebogen der Studie 1	238
	Anhang B: Fragebogen der Studie 2	239
	Anhang C: Fragebogen der Studie 3	240

Abbildungsverzeichnis

Abbildung 1: Aufbau der Dissertation	7
Abbildung 2: Theory of Reasoned Action (TRA).....	10
Abbildung 3: Der Zusammenhang zwischen Nutzungsintention und tatsächlicher Nutzung..	11
Abbildung 4: Technology Acceptance Modell (TAM).....	12
Abbildung 5: Vereinheitlichte Theorie zur Akzeptanz und Nutzung von Technologie (UTAUT)	13
Abbildung 6: UTAUT2 Modell.....	17
Abbildung 7: Marktanteil und Diffusionsrate bei der Diffusion von Innovationen.....	24
Abbildung 8: Kategorisierung der Marktteilnehmer	25
Abbildung 9. Modell der gesellschaftlichen Akzeptanz	30
Abbildung 10: Risiko Thermostat	31
Abbildung 11: Risiko- und Nutzenwahrnehmung von Technologien	33
Abbildung 12: Faktoren zur individuellen Risikobewertung und deren Charakteristika.....	34
Abbildung 13: Nutzer und Nutzung im Kontext von Akzeptanz und Widerstand	36
Abbildung 14: Evolution der Fahrerassistenzsysteme zum autonomen Fahren	50
Abbildung 15: Beispiel eines Pfadmodells	59
Abbildung 16: Phasen im Akzeptanzprozess	76
Abbildung 17: Modell zur Prognose der Akzeptanz von Innovationen.....	77
Abbildung 18: Jährliche Fahrleistung der Probanden bei Studie 1	85
Abbildung 19: Initiales Pfadmodell der Studie 1	87
Abbildung 20: Finales Pfadmodell der Studie 1	95
Abbildung 21: Pfadmodell des UTAUT Vergleichsmodells für Studie 1	96
Abbildung 22: Finales Pfadmodell des UTAUT Vergleichsmodells der Studie 1	103
Abbildung 23: Konstruktwerte der Studie 1	104

Abbildung 24: Ergebnisse zum Forschungsmodell der Studie 1	108
Abbildung 25: Hype Zyklus Modell	114
Abbildung 26: Forschungsmodell der Studie 2.....	116
Abbildung 27: Führender Entwickler (sicherer) autonomer Fahrzeuge.....	128
Abbildung 28: Initiales Pfadmodell der Studie 2	131
Abbildung 29: Finales Pfadmodell der Studie 2	140
Abbildung 30: Konstruktwerte der Studie 2	142
Abbildung 31: Ergebnisse zum Forschungsmodell von Studie 2	148
Abbildung 32: Forschungsmodell der Studie 3.....	153
Abbildung 33: Führende Entwickler autonomer Fahrzeuge (Mehrfachauswahl möglich)....	167
Abbildung 34: Initiales Pfadmodell der Studie 3	168
Abbildung 35: Redundanzanalyse von BI bei Studie 3.....	169
Abbildung 36: Redundanzanalyse von PB und PR bei Studie 3.....	170
Abbildung 37: Finales Pfadmodell der Studie 3	178
Abbildung 38: Indikatorgewichte von PB bei Studie 3.....	180
Abbildung 39: Konstruktwerte der Studie 3	181
Abbildung 40: Indikatorgewichte von PR bei Studie 3.....	183
Abbildung 41: Indikatorgewichte von BI bei Studie 3	184
Abbildung 42: Ergebnisse zum Forschungsmodell der Studie 3	186
Abbildung 43: Prozess der Datenanalyse.....	190
Abbildung 44: Veranschaulichung des SVM Algorithmus.....	194
Abbildung 45: RR und BR im zeitlichen Verlauf.....	197
Abbildung 46: Anzahl der Tweets pro Monat.....	200
Abbildung 47: Anzahl der Tweets pro Firma.....	201
Abbildung 48: RR der Tweets zu Firmen	202

Tabellenverzeichnis

Tabelle 1. Vergleich der Automatisierungsstufen für Fahrzeuge.	43
Tabelle 2. Evaluationskriterien eines reflektiv gemessenen Messmodells bei PLS-SEM.....	66
Tabelle 3. Evaluationskriterien eines formativ gemessenen Messmodells bei PLS-SEM.....	67
Tabelle 4. Evaluationskriterien des Strukturmodells bei PLS-SEM.....	71
Tabelle 5: Operationalisierung von PE für Studie 1	80
Tabelle 6: Die Operationalisierung von EE für Studie 1	81
Tabelle 7: Operationalisierung von SI für Studie 1.....	82
Tabelle 8: Operationalisierung von ANX für Studie 1	83
Tabelle 9: Operationalisierung von AT für Studie 1	84
Tabelle 10: Operationalisierung von BI für Studie 1	84
Tabelle 11: Deskriptive Statistik der Probanden für Studie 1	86
Tabelle 12: Äußere Ladungen bei Studie 1	88
Tabelle 13: Ergebnisse zur Internen-Konsistenz-Reliabilität bei Studie 1	89
Tabelle 14: Kreuzladungstabelle für Studie 1	90
Tabelle 15: Fornell-Larcker-Kriterium bei Studie 1	91
Tabelle 16: HTMT-Verhältnisse bei Studie 1	91
Tabelle 17: Innere VIF Werte bei Studie 1	92
Tabelle 18: Pfadkoeffizienten des Strukturmodells bei Studie 1	92
Tabelle 19: Totale Effekte bei Studie 1.....	93
Tabelle 20: Indirekte Effekte bei Studie 1	93
Tabelle 21: f^2 -Effektstärken bei Studie 1	94
Tabelle 22: q^2 -Effektstärken bei Studie 1.....	94
Tabelle 23: Äußere Ladungen des UTAUT Vergleichsmodells bei Studie 1	97
Tabelle 24: Vergleich der Konfidenzintervalle der äußeren Ladungen für Studie 1	98

Tabelle 25: Ergebnisse zur Internen-Konsistenz-Reliabilität des UTAUT Vergleichsmodell bei Studie 1.....	98
Tabelle 26: Kreuzladungstabelle des UTAUT Vergleichsmodells für Studie 1	99
Tabelle 27: Fornell-Larcker-Kriterium des UTAUT Vergleichsmodells bei Studie 1	99
Tabelle 28: Innere VIF Werte des UTAUT Vergleichsmodells bei Studie 1	100
Tabelle 29: Pfadkoeffizienten des UTAUT Vergleichsmodells bei Studie 1	100
Tabelle 30: f^2 -Effektstärken des UTAUT Vergleichsmodells bei Studie 1.....	101
Tabelle 31: q^2 -Effektstärken des UTAUT Vergleichsmodells bei Studie 1.....	102
Tabelle 32: Operationalisierung von PE für Studie 2	119
Tabelle 33: Operationalisierung von EE für Studie 2	120
Tabelle 34: Operationalisierung von SI für Studie 2.....	121
Tabelle 35: Operationalisierung von FC für Studie 2	122
Tabelle 36: Operationalisierung von HM für Studie 2.....	122
Tabelle 37: Operationalisierung von PV für Studie 2.....	123
Tabelle 38: Operationalisierung von HT für Studie 2.....	124
Tabelle 39: Operationalisierung von BI für Studie 2	124
Tabelle 40: Deskriptive Statistik zu den Probanden von Studie 2.....	125
Tabelle 41: Fachwissen im Bereich autonomer Fahrzeuge und angrenzenden Gebieten bei Studie 2.....	126
Tabelle 42: Auswertung des Fachwissens bei Studie 2.....	127
Tabelle 43: HTMT-Verhältnisse der Studie 2.....	132
Tabelle 44: Ergebnisse zur Internen-Konsistenz-Reliabilität bei Studie 2	133
Tabelle 45: Kreuzladungstabelle für Studie 2	134
Tabelle 46: Fornell-Larcker Kriterium bei Studie 2.....	135
Tabelle 47: Äußere Ladungen bei Studie 2	136
Tabelle 48: Innere VIF Werte bei Studie 2	137

Tabelle 49: Pfadkoeffizienten des Strukturmodells bei Studie 2	137
Tabelle 50: f^2 -Effektstärken bei Studie 2	138
Tabelle 51: q^2 -Effektstärken bei Studie 2.....	138
Tabelle 52: Operationalisierung von PB für Studie 3	156
Tabelle 53: Operationalisierung von PR für Studie 3	158
Tabelle 54: Operationalisierung von BI und BI_R für Studie 3	162
Tabelle 55: Deskriptive Statistik zu den Probanden von Studie 3	164
Tabelle 56: Fahrerfahrung und Fahrleistung der Probanden von Studie 3	164
Tabelle 57: Fachwissen im Bereich autonomer Fahrzeuge und angrenzenden Gebieten bei Studie 3.....	165
Tabelle 58: Auswertung des Fachwissens bei Studie 3.....	165
Tabelle 59: Kollinearitätsstatistik der Indikatoren bei Studie 3	171
Tabelle 60: Initiale Gewichte und Ladungen der Indikatoren bei Studie 3.....	172
Tabelle 61: Finale Gewichte und Ladungen der Indikatoren bei Studie 3.....	174
Tabelle 62: Innere VIF Werte bei Studie 3	175
Tabelle 63: Pfadkoeffizienten des Strukturmodells bei Studie 3	175
Tabelle 64: Totale Effekte bei Studie 3.....	176
Tabelle 65: q^2 -Effektstärken bei Studie 3.....	177
Tabelle 66: Vergleich der Konstruktwerte mit und ohne Unfallkenntnis bei Studie 3	185
Tabelle 67: Deskriptive Statistik der manuell klassifizierten Tweets	192
Tabelle 68: Konfusionsmatrix des SVM Algorithmus.....	195
Tabelle 69: Weitere Metriken des trainierten SVM Modells.....	195
Tabelle 70: Deskriptive Statistik der Tweets nach Jahr	197

Abkürzungsverzeichnis

ABS	Antiblockiersystem
ACC	Adaptive Cruise Control
ADAC	Allgemeiner Deutscher Automobil-Club
ANX	Anxiety
API	Application Programming Interface
ASHAD	Automation & Society: The Case of Highly Automated Driving
AT	Attitude
AUVSI	Association for Unmanned Vehicle Systems International
AVE	Average Variance Extracted
BASt	Bundesanstalt für Straßenwesen
BCa	Bias-Corrected and Accelerated
BI	Behavioral Intention
BR	Benefit Rate
BT	Benefit Tweet
CB-SEM	Covariance-Based SEM
CEO	Chief Executive Officer
CPU	Central Processing Unit
CTA	Consumer Technology Association
DARPA	Defense Advanced Research Projects Agency
DB	Datenbank
DIS	Draft International Standard
DTM	Document-Term-Matrix
EE	Effort Expectancy
FF	Forschungsfrage
FAS	Fahrerassistenzsystem
FC	Facilitating Conditions
FSRA	Full Speed Range Adaptive Cruise Control
GPS	Global Positioning System
HANA	High Performance Analytic Appliance
HD	High Definition
HM	Hedonic Motivation
HT	Habit
HTMT	Heterotrait-Monotrait Ratio
IDF	Inverse Document Frequency
ISO	Internationale Organisation für Normung
IT	Informationstechnologie
KI	Künstliche Intelligenz
km	Kilometer
km/h	Kilometer pro Stunde
LIBSVM	Library for Support Vector Machines
LKW	Lastkraftwagen
LTE	Long Term Evolution

M	Mittelwert
NHTSA	National Highway Traffic Safety Administration
NIMBY	Not in My Backyard
NoSQL	Not only SQL
OLS	Ordinary Least Squares
PATH	California Partners for Advanced Transit and Highways
PB	Perceived Benefits
PE	Performance Expectancy
PKW	Personenkraftwagen
PLS	Partial Least Squares
PLSc	Consistent PLS
PR	Perceived Risks
PROMETHEUS	Programme for a European Traffic System With Highest Efficiency and Unprecedented Safety
PV	Price Value
RAM	Random Access Memory
RR	Risk Rate
RT	Risk Tweet
SAE	Society of Automotive Engineers
SD	Standardabweichung
SEM	Structural Equation Modeling
SI	Social Influence
SPS	Support Package Stack
SQ	Search Query
SQL	Structured Query Language
SVM	Support Vector Machine
TAM	Technology Acceptance Model
TB	Terabyte
TF	Term Frequency
TRA	Theory of Reasoned Action
UNECE	Wirtschaftskommission für Europa der Vereinten Nationen
US	United States
USA	United States of America
UTAUT	Unified Theory of Acceptance and Use of Technology
VIF	Varianzinflationsfaktor
VOC	Voice of the Customer

1 Einleitung

Innovationen sind für Unternehmen ein wichtiges Mittel, um im Wettbewerb mit anderen Unternehmen zu bestehen (Krcmar, 2015, S. 423f). Eine erfolgreiche Innovation verspricht langfristiges Wachstum und wirtschaftlichen Erfolg. Entgegen dem alltäglichen Sprachgebrauch handelt es sich bei einer Innovation um eine Erfindung, die bereits auf dem Markt eingeführt wurde. Häufig schaffen es Erfindungen jedoch nicht bis zur Marktreife. Zusätzlich weisen Innovationen hohe Misserfolgsraten auf, da sie vom Markt nicht angenommen werden (Heidenreich & Kraemer, 2016). Damit sich eine Innovation für Unternehmen lohnt, ist eine erfolgreiche Markteinführung und schnelle Diffusion erforderlich (Montaguti, Kuester & Robertson, 2002). Ein Grund für die zahlreichen fehlgeschlagenen Innovationen ist der Widerstand der Konsumenten gegenüber neuen Technologien, der zu mangelnder Akzeptanz führt (Heidenreich & Kraemer, 2016). Mangelnde Akzeptanz bei der Markteinführung einer Innovation ist ein großer Unsicherheitsfaktor im Innovationsprozess, dessen Behebung mitunter große Investitionen erfordert. Trotz neuer Methoden der Marktforschung und einer Öffnung der Innovationsprozesse zur Integration von Kunden, berichten empirische Studien seit 1977 annähernd konstante Misserfolgsraten zwischen 35 % und 55 % bei Innovationen (Castellion & Markham, 2013).

Ziel dieser Dissertation ist daher die Prognose der Akzeptanz von Innovationen, bevor diese auf dem Markt eingeführt wurden. Eine frühe Untersuchung der Akzeptanz im Produktentwicklungsprozess kann dazu beitragen, die Unsicherheit im Innovationsprozess zu verringern und die Erfolgsrate von Innovationen zu erhöhen (Jalonen, 2011). Wir führen die Prognose der Akzeptanz am Beispiel autonomer Fahrzeuge durch, die zum Zeitpunkt der Erstellung dieser Dissertation noch nicht marktreif sind.

Die Ergebnisse dieser Dissertation sind Bestandteil des interdisziplinären Projektes *Automation & Society: The Case of Highly Automated Driving (ASHAD)* mit dem Ziel, das Zusammenspiel aus Technologie und Gesellschaft am Beispiel des autonomen Fahrens zu untersuchen (Schermann, Kohl & Krcmar, 2014). Die kooperierenden Institute untersuchen gesellschaftliche Aspekte, Entscheidungsfindung, Informationsverarbeitung, Kommunikationsprozesse, Mensch-Maschine-Interaktion und politische Interventionen in Bezug auf neue technologische Entwicklungen. Diese Aspekte werden mit verschiedenen experimentellen und empirischen Methoden analysiert, die von mathematischer Modellierung, Umfragen, Labor- und Interventionsstudien, Analyse von sozialen Medien bis hin zu Fahrsimulationsstudien reichen.

1.1 Motivation

Im Gegensatz zu den großen technischen Fortschritten in der Forschung und Entwicklung von automatisierten Fahrzeugen gab es bisher kaum Untersuchungen zur Akzeptanz dieser neuen Technologie (z. B. Lenz & Fraedrich, 2015; Payre, Cestac & Delhomme, 2014). Die Schwierigkeit bei der Untersuchung der Akzeptanz von neuen Technologien ist, dass diese noch nicht für die Allgemeinheit zur Verfügung stehen und daher von Probanden noch keine eigenen Erfahrungen zur Technologie gemacht werden konnten. Die Akzeptanz ist daher

meinungsgetrieben und anfällig für verzerrte Wahrnehmungen. In der Forschung wird daher zwischen der Akzeptanz von bereits bestehenden Systemen oder Produkten und der Akzeptabilität von neuen Technologien unterschieden, die der Allgemeinheit noch nicht zur Verfügung stehen (Adell, Várhelyi & Nilsson, 2014a).

Die Akzeptabilität des Systems sollte möglichst früh im Entwicklungsprozess untersucht werden. Dadurch kann früh auf die Bedenken der potenziellen Nutzer eingegangen werden. Je früher in der Entwicklung, desto flexibler kann in der Regel auf Einwände reagiert werden. Zudem ist in frühen Phasen der Entwicklung zumeist nur ein geringerer Teil der Projektressourcen bereits aufgewendet worden, sodass bei unüberwindbaren Akzeptanzproblemen auch ein Abbruch des Projektes möglich wäre, ohne die kompletten Projektressourcen aufwenden zu müssen (Abraham, Aier & Winter, 2014).

Erste Studien zur Akzeptabilität deuten darauf hin, dass autonome Fahrzeuge auf Widerstand bei den potenziellen Nutzern und auch in der Gesellschaft stoßen könnten. Michael Toscano, Chief Executive Officer (CEO) der Association for Unmanned Vehicle Systems International (AUVSI), problematisiert den Mangel an Akzeptanz für automatisiertes Fahren mit folgender Aussage: „*The technology maturation is there, but the public acceptance is not there*“ (O’Donnell, 2013). Der technologische Fortschritt für automatisiertes Fahren ist vorhanden, die öffentliche Akzeptanz autonomer Fahrzeuge allerdings noch nicht. Dennoch treiben die Automobilindustrie und verwandte Branchen autonome Fahrzeuge mit Nachdruck und großen Investitionen voran, obwohl deren Akzeptanz bei Markteinführung noch weitgehend unbekannt ist. Selbst Unternehmen aus der Branche der Informationstechnologie (IT) beteiligen sich an der Entwicklung von autonomen Fahrzeugen (Spinrad, 2014). Damit eine neue Technologie jedoch erfolgreich sein kann, wird eine hohe Technologieakzeptanz benötigt (Davis, Bagozzi & Warshaw, 1989).

Voraussetzung für eine frühe Messung der Akzeptanz ist, dass den potenziellen Nutzern das zu entwickelnde System möglichst realistisch präsentiert und zum Testen zur Verfügung gestellt werden kann (Davis et al., 1989). Weiterhin sollte das System für einen adäquaten Zeitraum zum Testen zur Verfügung stehen, damit sich die Probanden eine Meinung dazu bilden können. Allerdings kann eine realistische Präsentation von autonomen Fahrzeugen mangels Marktreife im Rahmen dieser Dissertation nicht durchgeführt werden. Ansätze für die Messung der Akzeptanz von Software noch vor deren Veröffentlichung erscheinen vielversprechend um dieses Problem zu adressieren (Davis & Venkatesh, 2004). Die weite Verbreitung von öffentlichen Beta-Tests für neue Software zeigt, dass eine frühe Integration von Kundenfeedback deren Akzeptanz positiv beeinflusst (Jiang, Scheibe, Nilakanta & Qu, 2017). Bei autonomen Fahrzeugen ist ein öffentlicher Beta-Test jedoch aus technischen, ethischen und rechtlichen Gesichtspunkten nicht möglich: Beta-Tests von autonomen Fahrzeugen im öffentlichen Straßenverkehr könnten aufgrund mangelnder technischer Reife Unfälle verursachen und sind daher gesetzlich nicht erlaubt.

Mit den ersten intelligenten Fahrerassistenzsystemen, einer Vorstufe von autonomen Fahrzeugen, hat Conover (1994) bereits gezeigt, dass Risiko- und Nutzenwahrnehmungen die Akzeptanz dieser Systeme maßgeblich beeinflussen. Ähnliche Studien liegen auch zu anderen,

ehemals neuen Technologien vor, wie beispielsweise für gentechnisch veränderte Lebensmittel (Frewer, Scholderer & Bredahl, 2003) oder Nanotechnologie (Siegrist, Stampfli, Kastenholz & Keller, 2008). Gerade bei Zukunftstechnologien, wie dem automatisierten Fahren, kann eine übersteigerte Risikowahrnehmung zu Angst und Widerständen führen. Zahlreiche Studien belegen die Schlüsselrolle von Risikowahrnehmung für die Akzeptanz (Currall, King, Lane, Madera & Turner, 2006; Siegrist, 2000). Subjektive Fehlwahrnehmungen der Risiken und des Nutzens von Technologien verhindern deren breite Akzeptanz (Gupta, Fischer & Frewer, 2011, 2015). Der Einfluss von Bedenken und Fehleinschätzungen der Öffentlichkeit zu autonomen Fahrzeugen wird dabei möglicherweise unterschätzt (Piao et al., 2016).

Bereits bei der Entwicklung einer neuen Technologie sollten die Risiko- und Nutzenwahrnehmung genau beobachtet werden, um Probleme der öffentlichen Wahrnehmung zu identifizieren. Darüber hinaus sollten die Wahrnehmungen im Verlauf der Zeit untersucht werden, da diese sich mit zunehmender Bekanntheit der Technologie verändern können (Haboucha, Ishaq & Shiftan, 2017; Kauer, Franz, Schreiber, Bruder & Geyer, 2012; König & Neumayr, 2017). In diesem Zusammenhang ist es besonders interessant, die Auswirkungen kritischer Vorfälle mit autonomen Fahrzeugen auf die öffentliche Wahrnehmung zu untersuchen (Woisetschläger, 2016). Firmen können diese Informationen zur Anpassung der Technologieentwicklung oder der technologiespezifischen Kommunikation nutzen, um Bedenken der Konsumenten zu adressieren und Technologiepotentiale optimal auszunutzen.

1.2 Forschungsleitende Fragestellungen

Ausgehend von der in Abschnitt 1.1 geschilderten Motivation ist das Ziel dieser Dissertation die Prognose der Akzeptanz von Innovationen am Beispiel des autonomen Fahrens zu untersuchen. Für die Prognose verwenden wir drei verschiedene Ansätze, die sich aus den drei folgenden forschungsleitenden Fragestellungen ableiten.

Zunächst untersuchen wir die Eignung von etablierten Technologieakzeptanzmodellen zur Prognose der Akzeptanz von Innovationen. Die Forschung zur Technologieakzeptanz ist ein zentrales Thema der Wirtschaftsinformatik. Schwerpunkt der Technologieakzeptanzforschung ist jedoch die Untersuchung der Akzeptanz von neuen Informationssystemen und deren Nutzung innerhalb eines Unternehmens (Venkatesh, Thong & Xu, 2012). Vereinzelt untersuchten auch bereits Technologien im privaten Umfeld, wie beispielsweise Onlinebanking (Martins, Oliveira & Popovič, 2014) oder mobiles Internet (Venkatesh et al., 2012). Neu ist jedoch die Untersuchung einer Technologie im privaten Umfeld, die der Allgemeinheit noch nicht zur Verfügung steht. Daraus leitet sich die erste forschungsleitende Fragestellung (FF) ab:

FF1: Wie kann die Akzeptanz von Innovationen mit Modellen der Technologieakzeptanz prognostiziert werden?

Zur Beantwortung von FF1 erstellen wir in Studie 1 (Kapitel 5) ein Modell zur Prognose der Akzeptanz von Innovationen auf Basis von UTAUT. Das UTAUT Modell erläutern wir in Abschnitt 2.2.3. Zusätzlich führen wir eine weitere Studie zur Technologieakzeptanz mit dem UTAUT2 Modell in Studie 2 (Kapitel 6) durch, das wir in Abschnitt 2.2.4 beschreiben. Die Ergebnisse der Studien 1 und 2 verwenden wir, um die Akzeptanz autonomer Fahrzeuge auf

Basis von Technologieakzeptanzmodellen zu prognostizieren und Akzeptanzhindernisse zu identifizieren. Ergebnis der ersten forschungsleitenden Fragestellung ist ein Modell zur Prognose der Akzeptanz von Innovationen auf Basis von Technologieakzeptanzmodellen.

Im zweiten Schritt untersuchen wir die Eignung des Modells der gesellschaftlichen Akzeptanz zur Prognose der Akzeptanz von Innovationen. Zentrale Einflussfaktoren für die gesellschaftliche Akzeptanz sind Risiko- und Nutzenwahrnehmung (Siegrist, 2000). Für die zweite forschungsleitende Fragestellung untersuchen wir daher die Risiken und den Nutzen autonomer Fahrzeuge und wie diese wahrgenommen werden, sowie deren Einfluss auf die Akzeptanzprognose. Somit formulieren wir folgende forschungsleitende Fragestellung:

FF2: Wie beeinflussen Risiko- und Nutzenwahrnehmungen die prognostizierte Akzeptanz von Innovationen vor deren Markteinführung?

Die FF2 adressieren wir in Studie 3 dieser Dissertation. Studie 3 basiert auf dem Modell der gesellschaftlichen Akzeptanz (Siegrist, 2000), das wir in Abschnitt 2.4.1 erläutern. Zur Anwendung des Modells werden wir Risiken und Nutzen des autonomen Fahrens anhand aktueller Studien identifizieren und diese von Probanden bewerten lassen. Anschließend analysieren wir das Modell und vergleichen es mit den Ergebnissen der ersten beiden Studien. Mit Studie 3 erhalten wir zudem die Aspekte des autonomen Fahrens, die am riskantesten und am nützlichsten wahrgenommen werden und den größten Einfluss auf die Akzeptanzprognose ausüben. Ergebnis von FF2 ist die Quantifizierung des Einflusses von Risiko- und Nutzenwahrnehmungen auf die prognostizierte Akzeptanz von Innovationen vor deren Markteinführung.

FF1 und FF2 untersuchen wir in den Studien 1-3 dieser Dissertation, die wir mittels strukturierten Online-Fragebögen durchführen. Dies ist ein übliches Vorgehen für die Durchführung von Akzeptanzstudien und wird in Abschnitt 4.1 beschrieben. Die Fragebögen werten wir mit der Methode der Strukturgleichungsmodellierung aus, die wir in Abschnitt 4.2 erläutern.

Um mögliche Validitätsbedenken durch Methodenverzerrung und Einheitsmethodenvarianz (Sharma, Yetton & Crawford, 2009) zu adressieren, entwickeln wir bei der dritten forschungsleitenden Fragestellung eine neues Verfahren zur Prognose der Akzeptanz von Innovationen auf Basis sozialer Medien. Durch die Verwendung sozialer Medien können wir auf große Mengen frei verfügbarer Daten für die Prognose der Akzeptanz von Innovationen zurückgreifen. Dies ist einerseits ein Vorteil, stellt uns aber auch vor die Herausforderung, wie wir die großen Datenmengen sinnvoll und mit einem vertretbaren Aufwand für die Prognose der Akzeptanz von Innovationen auswerten können. Daraus ergibt sich die dritte forschungsleitende Fragestellung:

FF3: Wie können soziale Medien für die Prognose der Akzeptanz von Innovationen verwendet werden?

FF3 untersuchen wir mit Studie 4 dieser Dissertation (Kapitel 8). In Studie 4 erstellen wir ein neues Verfahren, mit dem wir Beiträge aus sozialen Medien extrahieren und automatisiert mit

maschinellen Lernverfahren untersuchen können. Ziel des neuen Verfahrens ist es, Risiken und Nutzen neuer Technologien auf Basis von Nutzerbeiträgen zu identifizieren und statistisch auszuwerten. Ergebnis der dritten forschungsleitenden Fragestellung ist ein Verfahren zur Prognose der Akzeptanz von Innovationen basierend auf Beiträgen aus sozialen Medien.

1.3 Aufbau der Dissertation

In Kapitel 1 führen wir zunächst zum Thema der Prognose der Akzeptanz von Innovationen hin und erläutern die Motivation und das Ziel dieser Dissertation. Anschließend definieren und erläutern wir die forschungsleitenden Fragestellungen, die aufzeigen, wie das Ziel erreicht werden soll.

In Kapitel 2 definieren wir zunächst die zentralen Begriffe dieser Dissertation: Innovation, Akzeptanz und Akzeptabilität. Anschließend geben wir einen Einblick in die Grundlagen und Modelle der Technologieakzeptanz auf denen die Studien 1 und 2 dieser Dissertation basieren. Zudem erläutern wir die Diffusionstheorie, anhand derer wir Schlussfolgerungen für die Diffusion autonomer Fahrzeuge ableiten. Abschließend erläutern wir Theorien und Konzepte der gesellschaftlichen Akzeptanz, welche die Grundlage für Studie 3 dieser Dissertation bilden.

In Kapitel 3 geben wir einen Einblick in den Stand der Technik autonomer Fahrzeuge. Wir beginnen mit den Anfängen der Fahrzeugautomatisierung. Anschließend erläutern wir die Stufen der Automatisierung bis hin zu autonomen Fahrzeugen. Autonome Fahrzeuge basieren auf Fahrerassistenzsystemen und benötigen Infrastruktur sowie eine Vernetzung der Verkehrsteilnehmer, die wir ebenfalls in Kapitel 3 erläutern. Das Kapitel endet mit den aktuellen Entwicklungen im Bereich autonomer Fahrzeuge.

In Kapitel 4 beschreiben wir die Forschungsmethoden, die wir für die Durchführung der Studien 1-3 dieser Dissertation einsetzen. Die Datenerhebung in den Studien 1-3 erfolgt anhand strukturierter Fragebögen, die wir zunächst erläutern. Anschließend werten wir die erhobenen Daten mittels Strukturgleichungsmodellierung aus, die wir im Abschnitt 4.2 des Kapitels beschreiben.

In Kapitel 5 stellen wir Studie 1 dieser Dissertation vor. Grundlage dieser Studie ist das Modell zur Prognose der Akzeptanz von Innovationen, das wir ausgehend vom UTAUT Modell und aktuellen Forschungsergebnissen erstellen und anschließend mit empirischen Daten evaluieren. Zusätzlich vergleichen wir das Modell der Prognose der Akzeptanz von Innovationen mit dem originalen UTAUT Modell. Wir beenden das Kapitel mit der Diskussion der Ergebnisse und einem Fazit.

In Kapitel 6 stellen wir Studie 2 dieser Dissertation vor. Grundlage dieser Studie ist das UTAUT2 Modell, das wir für die Prognose der Akzeptanz von Innovationen anwenden. Anhand empirischer Daten evaluieren wir das UTAUT2 Modell und vergleichen die Ergebnisse mit den Ergebnissen von Studie 1. Wir beenden das Kapitel mit der Diskussion der Ergebnisse und einem Fazit. Studie 2 adressiert zusammen mit Studie 1 die FF1 dieser Dissertation.

In Kapitel 7 stellen wir Studie 3 dieser Dissertation vor, die sich aus FF2 ableitet. Grundlage dieser Studie ist das Modell der gesellschaftlichen Akzeptanz, das wir für die Prognose der Akzeptanz von Innovationen anwenden. Im Unterschied zu den Studien 1 und 2 basiert Studie 3 nicht auf Technologieakzeptanzmodellen, sondern auf der Risiko- und Nutzenwahrnehmung einer Technologie. Anhand empirischer Daten evaluieren wir die Ergebnisse des Modells der gesellschaftlichen Akzeptanz und leiten Schlussfolgerungen für die Akzeptanz autonomer Fahrzeuge ab.

In Kapitel 8 adressieren wir mit Studie 4 die FF3 dieser Dissertation. Im Rahmen von Studie 4 entwickeln wir ein Verfahren zur Prognose der Akzeptanz von Innovationen auf Basis von Beiträgen in sozialen Medien. Zunächst stellen wir dieses Verfahren vor und wenden es anschließend auf die Untersuchung der Risiken und des Nutzens autonomer Fahrzeuge an. Mit den Ergebnissen dieser Studie erhalten wir weitere Einsichten in die Akzeptanz autonomer Fahrzeuge.

Diese Dissertation endet mit Kapitel 9, in dem wir die Studien 1-4 bezugnehmend auf die Forschungsfragen noch einmal zusammenfassen und die Beiträge zu Theorie und Praxis erläutern. Weiterhin diskutieren wir die Limitationen dieser Dissertation und enden mit einem Fazit.

Abbildung 1 fasst den Aufbau dieser Dissertation noch einmal schematisch zusammen.

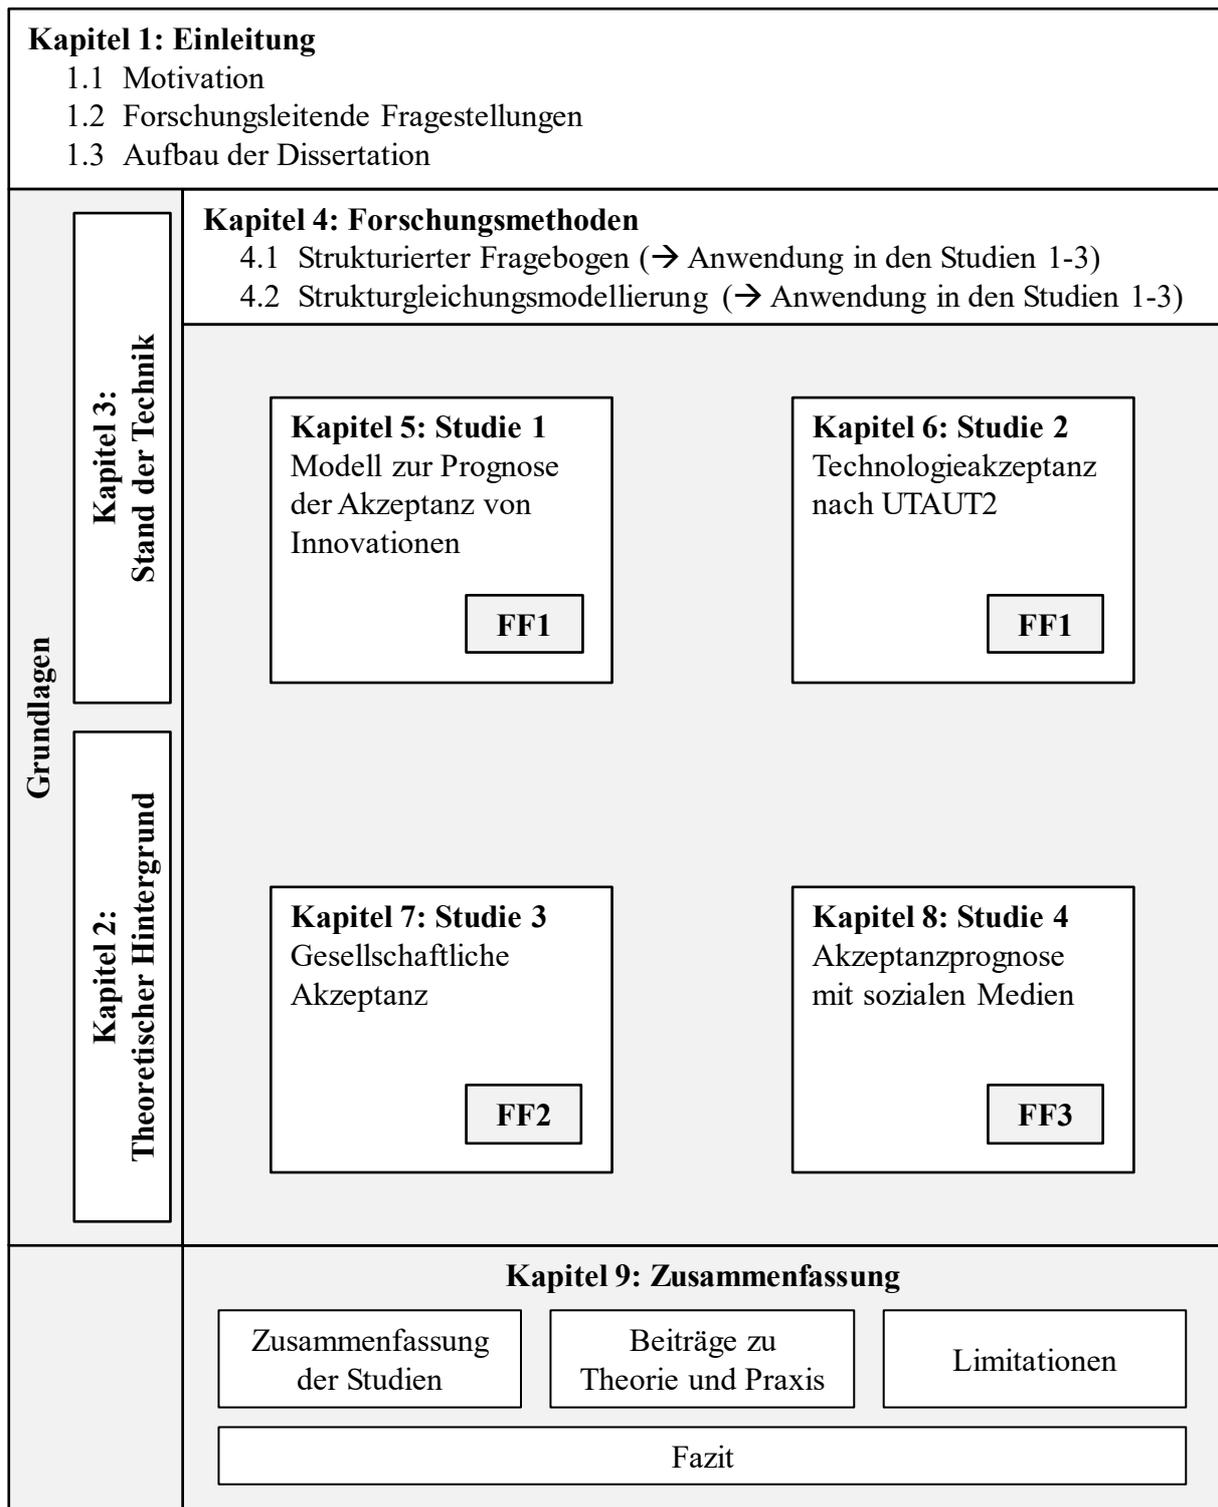


Abbildung 1: Aufbau der Dissertation

Quelle: Eigene Darstellung

2 Theoretischer Hintergrund

In diesem Kapitel wird diese Dissertation in die bestehende Forschung eingeordnet. Darüber hinaus werden wichtige theoretische Grundlagen und Modelle aus den Forschungsgebieten der Technologieakzeptanz, Diffusionstheorie und gesellschaftlicher Akzeptanz vorgestellt, die das theoretische Fundament für die vorliegende Dissertation bilden. Diese werden in den jeweiligen Abschnitten direkt mit Bezug zum autonomen Fahren erläutert und Schlussfolgerungen für die Akzeptanz autonomer Fahrzeuge werden abgeleitet.

2.1 Definition von Innovation, Akzeptanz und Akzeptabilität

Entgegen dem alltäglichen Sprachgebrauch handelt es sich bei einer *Innovation* um eine Erfindung (Invention), die als neues Produkt, Dienstleistung oder Verfahren erfolgreich umgesetzt und im Markt eingeführt wurde (Müller-Prothmann & Dörr, 2011, S. 7). Müller-Prothmann & Dörr (2011, S. 7) fassen die Bestandteile einer Innovation in folgender Formel zusammen:

$$\text{Innovation} = \text{Idee} + \text{Invention} + \text{Diffusion}$$

Am Anfang einer Innovation steht also eine Idee. Führt die Idee zu einer Erfindung, spricht man von einer Invention. Diese muss sich schließlich noch erfolgreich auf dem Markt behaupten, was als Diffusion bezeichnet wird. In dieser Dissertation beschränken wir uns auf eine Produktinnovation, dem autonomen Fahren. Die Prognose der Akzeptanz von Dienstleistungen oder Verfahren ist nicht Gegenstand dieser Dissertation.

Akzeptanz und Akzeptabilität werden häufig austauschbar in der Literatur verwendet (Regan, Horberry & Stevens, 2014). In frühen Phasen der Produktentwicklung, in denen ein neues Produkt noch nicht für den potentiellen Nutzer verfügbar ist, wird von Experten eher der Begriff Akzeptabilität verwendet (Adell et al., 2014a). Hintergrund für die Untersuchung der Akzeptabilität ist, dass bereits vor der allgemeinen Verfügbarkeit eines Produktes Meinungen und Einschätzungen dazu existieren. Diese sollten im weiteren Produktentwicklungsprozess und bei der Markteinführung berücksichtigt werden. Schade & Schlag (2003, S. 47f) grenzen Akzeptanz und Akzeptabilität folgendermaßen voneinander ab:

“The term acceptability describes the prospective judgment of measures to be introduced in the future. Thus the target group will not have experienced any of these measures, making “acceptability” an attitude construct. Acceptance defines respondents’ attitudes including their behavioral reactions after the introduction of a measure.”

Der Begriff der *Akzeptabilität* beschreibt also die vorausschauende Beurteilung von zukünftig einzuführenden Maßnahmen oder Produkten. Die Zielgruppe wird daher noch keine Gelegenheit gehabt haben, diese auszuprobieren. Akzeptabilität ist somit ein Einstellungskonstrukt. Die *Akzeptanz* ist hingegen definiert als die Einstellungen der Befragten einschließlich ihrer Verhaltensreaktionen nach der Einführung einer Maßnahme oder eines Produktes. Diese Definition verdeutlicht, dass unter Akzeptabilität eine vorausschauende

Beurteilung verstanden wird, welche ausschließlich auf der Einstellung und Meinungen von Nutzern basiert. Erst nachdem der Gegenstand der Betrachtung ausprobiert werden konnte, spricht man von Akzeptanz, die anhand der Verhaltensreaktionen und der sich gegebenenfalls geänderten Einstellung der Nutzer nach der Verwendung definiert ist.

2.2 Technologieakzeptanz

Damit die Potentiale durch neue Technologien auch realisiert werden, beschäftigen sich Forscher bereits seit geraumer Zeit mit den Fragen, inwiefern und warum Individuen Technologien akzeptieren oder auch nicht (Venkatesh, Morris, Davis & Davis, 2003). Die Erforschung der Technologieakzeptanz ist daher eines der Forschungsschwerpunkte der Wirtschaftsinformatik (Venkatesh, Davis & Morris, 2007). In diesem Abschnitt stellen wir die zentralen Technologieakzeptanzmodelle vor, auf denen die ersten beiden Studien basieren.

2.2.1 Theory of Reasoned Action

Ausgangspunkt der Technologieakzeptanzforschung bildet die Theory of Reasoned Action (TRA), die im deutschsprachigen Raum auch als Theorie des überlegten Handelns bekannt ist (Benbasat & Barki, 2007; Fishbein & Ajzen, 1975). Sie besagt, dass das *Verhalten* von der *Verhaltensintention* beeinflusst wird. Diese wird wiederum von der persönlichen *Einstellung zum Verhalten* und *subjektiven Normen* beeinflusst. Das TRA Modell der Akzeptanz ist in Abbildung 2 dargestellt.

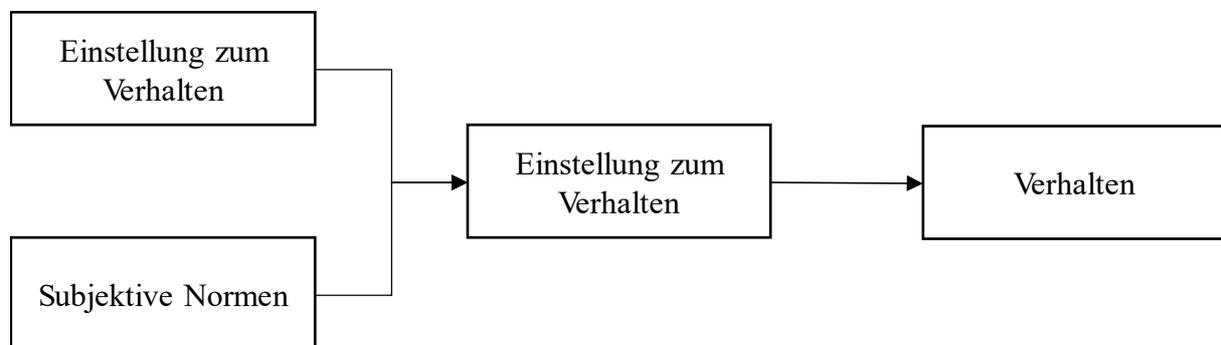


Abbildung 2: Theory of Reasoned Action (TRA)

Quelle: In Anlehnung an Madden, Ellen & Ajzen (1992, S. 4)

Auf Basis des TRA wurden zahlreiche Modelle erstellt mit dem Ziel die Akzeptanz von Informationssystemen in einem breiten Spektrum von Benutzerpopulationen zu untersuchen (Davis et al., 1989). Die gemeinsame Basis bildet dabei der Zusammenhang zwischen Verhaltensintention und tatsächlicher Nutzung, wie in der TRA postuliert (Venkatesh et al., 2003). Dieser ist wohletabliert in der Forschung und in Abbildung 3 dargestellt.

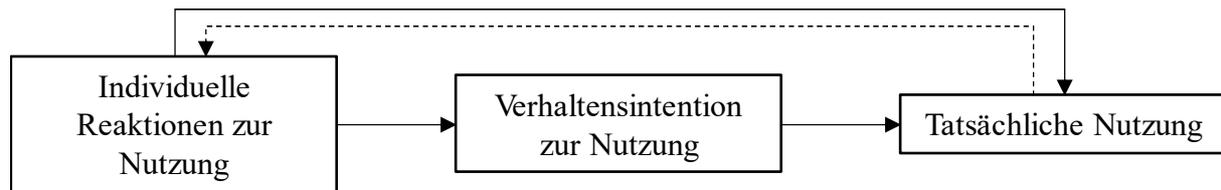


Abbildung 3: Der Zusammenhang zwischen Nutzungsintention und tatsächlicher Nutzung

Quelle: In Anlehnung an Venkatesh et al. (2003, S. 427)

Die Nutzungsintention und die Einstellung zur Nutzung bilden sich bereits vor der erstmaligen Verwendung einer Innovation (Venkatesh et al., 2003). Für die Prognose der Akzeptanz von Innovationen schlussfolgern wir daher, dass wir bereits vor der Markteinführung der Innovation die tatsächliche Nutzung prognostizieren können. Somit können wir auch bereits zum aktuellen Zeitpunkt, in dem autonome Fahrzeuge noch nicht für die Allgemeinheit verfügbar sind, bereits die akzeptanzrelevanten Faktoren der Technologieakzeptanzmodelle messen und mit den erhobenen Daten eine Prognose der Akzeptanz durchführen.

2.2.2 Technology Acceptance Model (TAM)

Das Technology Acceptance Model (TAM) ist ursprünglich für die Untersuchung der Akzeptanz von Informationssystemen in Unternehmen erstellt worden (Davis et al., 1989). Auslöser für die Untersuchung der Akzeptanz war die Feststellung, dass neu eingeführte Computer in Unternehmen nicht die erwarteten Vorteile brachten, was sich auf mangelnde Akzeptanz der Systeme zurückführen ließ (Regan et al., 2014, S. 3–8). Mit der zunehmenden Verbreitung von Informationssystemen in Unternehmen wurde daraus ein Schwerpunkt in der Wirtschaftsinformatik. Aufgrund der Omnipräsenz von Informationssystemen in vielen Bereichen wie Militär, Gesundheitswesen und der Unterhaltungselektronik wurden die Erkenntnisse der Akzeptanzforschung auch in diese Bereiche übertragen. Mit dem zunehmenden Einzug von IT in Fahrzeugen, beispielsweise im Bereich des Infotainments oder auch der Fahrerassistenzsysteme, werden die Erkenntnisse zunehmend auch dort eingesetzt (Adell, Várhelyi & Nilsson, 2014b).

Das TAM postuliert, dass die wahrgenommene Nützlichkeit und die wahrgenommene Benutzerfreundlichkeit die zentralen Einflussfaktoren für die Akzeptanz von Informationssystemen sind (Davis et al., 1989). Das Modell soll dabei einerseits zur Prognose der Akzeptanz und andererseits zur Erklärung der Akzeptanz dienen, um Gegenmaßnahmen für mangelnde Akzeptanz abzuleiten.

Die *wahrgenommene Nützlichkeit* ist in diesem Kontext definiert als die subjektiv eingeschätzte Wahrscheinlichkeit des potenziellen Nutzers, dass die Verwendung eines bestimmten Informationssystems dessen Arbeitsleistung in einem organisatorischen Umfeld erhöht. Bei der *wahrgenommenen Benutzerfreundlichkeit* handelt es sich um den Grad, in dem der potenzielle Nutzer erwartet, dass die Verwendung des untersuchten Informationssystems frei von Aufwand ist. Mit einer einfachen Bedienbarkeit reduziert sich auch der Aufwand für die Bedienung, sodass mit weniger Gesamtaufwand die gleiche Arbeit erledigt werden kann. Im TAM ist dies durch den direkten Einfluss der wahrgenommenen Benutzerfreundlichkeit auf die wahrgenommene Nützlichkeit berücksichtigt. Beide Einflussfaktoren wirken sich auch direkt

auf die *Einstellung zur Nutzung* aus. Diese ist definiert durch die zentralen Überzeugungen einer Person über die Folgen der Nutzung in Kombination mit der Bewertung der Folgen.

Die TRA besagt, dass aus einer positiven *Einstellung zur Nutzung* eine *Nutzungsintention* entsteht, die wiederum zur *tatsächlichen Systemnutzung* führt. Entgegen der TRA postuliert TAM einen direkten Einfluss der wahrgenommenen Nützlichkeit auf die Nutzungsintention. Dieser resultiert daraus, dass TAM spezifisch für die Nutzung von Informationssystemen in Organisationen erstellt wurde und Mitarbeiter in Organisationen neben einer positiven Einstellung zur Nutzung auch die Erhöhung der eigenen Arbeitsleistung als einen wichtigen Grund für die Nutzung eines Systems betrachten. Der Effekt von subjektiven Normen wie in der TRA beschrieben, wurde im TAM nicht berücksichtigt aufgrund der theoretischen und psychometrischen Unsicherheiten bezüglich dieses Einflussfaktors. Die externen Variablen im Modell sind verschiedene mögliche Eigenschaften des zu untersuchenden Informationssystems. So würde die Eigenschaft eines Grafikprogramms, qualitativ hochwertige Diagramme erstellen zu können, zu einer höheren wahrgenommenen Nützlichkeit führen. Eine intuitive Bedienbarkeit des Informationssystems, beispielsweise mittels Touchscreen und selbsterklärenden Bedienkomponenten, würde in eine positiv wahrgenommene Benutzerfreundlichkeit resultieren. Abbildung 4 zeigt das TAM mit den erläuterten direkten und indirekten Einflussfaktoren für die Akzeptanz.

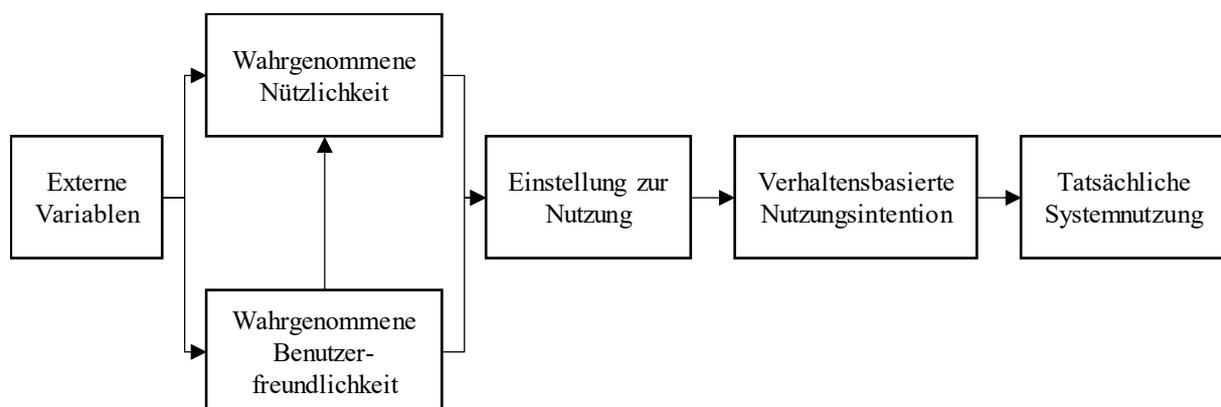


Abbildung 4: Technology Acceptance Modell (TAM)

Quelle: In Anlehnung an Davis et al. (1989, S. 985)

Die Gewichtung der einzelnen Faktoren von TAM ist nicht vorgegeben, sondern wird mittels statistischer Verfahren wie lineare Regression oder Strukturgleichungsmodellierung bestimmt (Davis et al., 1989). Dies ermöglicht bei der Auswertung den Einfluss der wahrgenommenen Nützlichkeit und der wahrgenommenen Benutzerfreundlichkeit miteinander zu vergleichen. Weiterhin kann mit dem TAM der Einfluss verschiedener externer Variablen, wie Systemeigenschaften, individuelle Unterschiede der Probanden, situationsbedingte Unterschiede oder vom Management durchgeführte Maßnahmen, untersucht werden.

2.2.3 Unified Theory of Acceptance and Use of Technology (UTAUT)

Aufgrund der zahlreichen Faktoren, die Technologieakzeptanz beeinflussen können, wurden viele Akzeptanzmodelle als Abwandlung zentraler Modelle wie TAM oder TRA erstellt (Venkatesh et al., 2003). Forscher stehen daher vor der Herausforderung, ein Modell zur Untersuchung der Technologieakzeptanz auszuwählen und Komponenten von Modellen zu kombinieren. Die Auswahl beschränkt sich dabei häufig auf etablierte Modelle der Technologieakzeptanz, wodurch Fortschritte in alternativen Modellen nicht berücksichtigt werden. Vor diesem Hintergrund wurde das UTAUT Modell entwickelt, das acht Akzeptanzmodelle in ein einheitliches Modell zur Prognose der Akzeptanz zusammenfasst (Venkatesh et al., 2003).

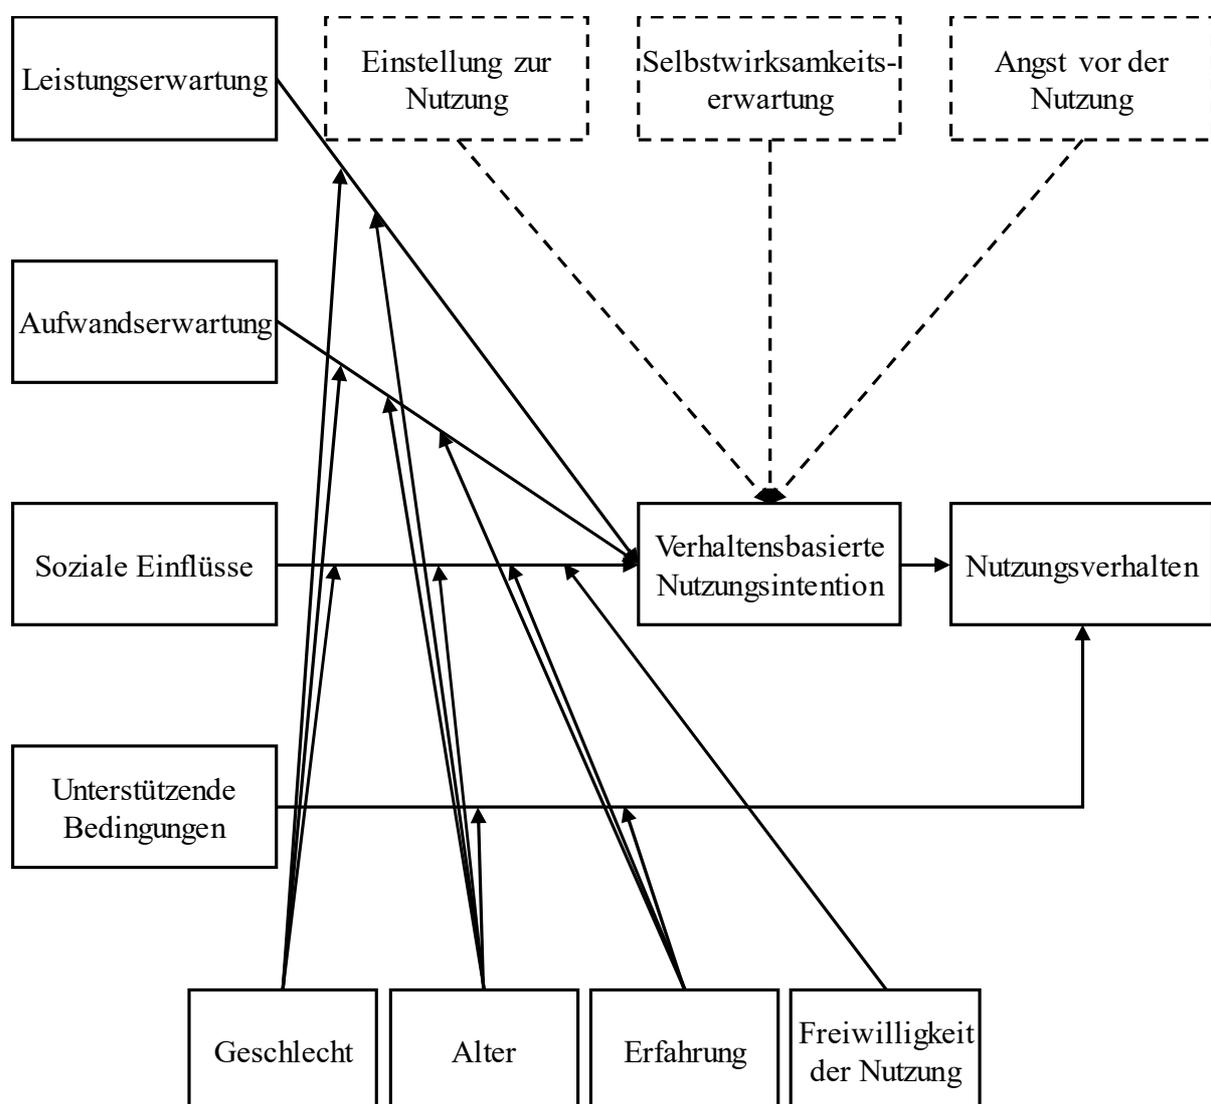


Abbildung 5: Vereinheitlichte Theorie zur Akzeptanz und Nutzung von Technologie (UTAUT)

Quelle: In Anlehnung an Venkatesh et al. (2003, S. 447)

Das UTAUT Modell beinhaltet vier Faktoren, die das *Nutzungsverhalten* direkt und indirekt beeinflussen. Der indirekte Einfluss erfolgt bei drei Faktoren über die *Nutzungsintention*, welche bereits aus dem TAM bekannt ist (Venkatesh et al., 2003). Die Nutzungsintention beeinflusst wie im TAM und der TRA das Nutzungsverhalten, was der tatsächlichen Systemnutzung im TAM Modell entspricht. Die Nutzungsintention wird beeinflusst durch die Leistungserwartung, die Aufwandserwartung und soziale Einflüsse. Im Gegensatz zum TAM beeinflusst ein Faktor direkt das Nutzungsverhalten, die unterstützenden Bedingungen. UTAUT beinhaltet die vier moderierenden Variablen *Geschlecht*, *Alter*, *Erfahrung* und *Freiwilligkeit der Nutzung*. Abbildung 5 zeigt das UTAUT Modell, das im Nachfolgenden genauer beschrieben ist.

Die *unterstützenden Bedingungen* sind definiert als die Einschätzung des Individuums, inwiefern die vorhandene organisatorische und technische Infrastruktur die Nutzung des Systems unterstützt (Venkatesh et al., 2003). Der positive Einfluss der unterstützenden Bedingungen auf das Nutzungsverhalten wird mit zunehmender Erfahrung des Individuums verstärkt, da erfahrene Nutzer auf vielfältige Möglichkeiten der Hilfe und Unterstützung innerhalb der Organisation zurückgreifen und somit Hindernisse für eine nachhaltige Nutzung des Systems beseitigen können. Auch mit zunehmendem Alter nimmt der Effekt der unterstützenden Bedingungen zu. Ältere Nutzer legen größeren Wert darauf, bei Nutzungsproblemen auf Unterstützung zurückgreifen zu können, um so gegebenenfalls kognitive und physische Einschränkungen durch das Alter kompensieren zu können. Sowohl Erfahrung als auch das Alter moderieren somit den Einfluss der unterstützenden Bedingungen auf das Nutzungsverhalten. Ein direkter Effekt der unterstützenden Bedingungen auf die verhaltensbasierte Nutzungsintention wird durch die Faktoren Leistungs- und Aufwandserwartung weitgehend abgedeckt und ist daher nicht im Modell enthalten.

Die *Leistungserwartung* beschreibt, wie die persönliche Leistung bei der Aufgabenerfüllung durch das untersuchte System gesteigert werden kann und entspricht der wahrgenommenen Nützlichkeit bei TAM (Venkatesh et al., 2003). Sie ist der stärkste direkte Einflussfaktor der Nutzungsintention in allen untersuchten Modellen. Aufgrund der vorherrschenden Geschlechterrollen und Sozialisierungsprozesse nach der Geburt, ist Männern die Leistungserwartung eines Systems wichtiger ist als Frauen. Mit sich ändernden Geschlechterrollen ist aber eine Veränderung der Gewichtung in Zukunft möglich, sodass auch das Alter in diesem Zusammenhang berücksichtigt werden sollte. Weiterhin sprechen jüngere Individuen stärker auf extrinsische Belohnungen an, die häufig aus guten Leistungen resultieren. Der Effekt der Leistungserwartung auf die verhaltensbasierte Nutzungsintention wird also moderiert durch Geschlecht und Alter.

Neben Leistungserwartung ist auch die *Aufwandserwartung* bereits im TAM in Form der wahrgenommenen Benutzerfreundlichkeit enthalten und beschreibt, wie leicht einem Benutzer die Bedienung eines Systems fällt (Venkatesh et al., 2003). Der Effekt der Aufwandserwartung beeinflusst nur zu Beginn der Einführung eines Systems die Nutzungsintention und wird nach längerer Zeit der dauerhaften Nutzung unwichtiger. Wie bei der Leistungserwartung zeigt sich ein Unterschied zwischen den Geschlechtern. Für Frauen hat die Aufwandserwartung einen stärkeren Effekt als für Männer und aufgrund sich ändernder Geschlechterrollen sollte auch das

Alter hier ebenfalls berücksichtigt werden. Zusätzlich haben ältere Individuen häufiger Probleme bei der Verwendung von komplexen Systemen, sodass für Ältere die Aufwandserwartung einen höheren Stellenwert einnimmt. Wie bei den unterstützenden Bedingungen beschrieben, fällt es erfahrenen Nutzern leichter, Hindernisse bei der Nutzung zu überwinden. Dies zeigt sich auch bei der Aufwandserwartung, die für erfahrene Individuen eine geringere Rolle für die Nutzungsintention spielt. Zusammengefasst wird der Effekt der Aufwandserwartung auf die Nutzungsintention also von Geschlecht, Alter und Erfahrung beeinflusst.

Der Faktor *soziale Einflüsse* bezeichnet den Einfluss wichtiger Personen im sozialen Umfeld des Individuums, die glauben, dass dieses das neue System nutzen sollte (Venkatesh et al., 2003). Die Nutzung des Systems resultiert in einem erhöhten Ansehen des Nutzers, zumindest in dessen Wahrnehmung. Soziale Einflüsse entsprechen den subjektiven Normen der TRA. Der Effekt auf die verhaltensbasierte Nutzungsintention tritt nur in Fällen auf, bei denen die Nutzung des Systems vorgeschrieben wird. Die sozialen Einflüsse wirken bei der vorgeschriebenen Nutzung als soziale Kontrolle und Konformitätsdruck. Bei freiwilliger Nutzung wird der Effekt der sozialen Einflüsse durch Internalisierung und Identifikation mit dem System durch die Leistungs- und Aufwandserwartung erfasst. Auch bei der vorgeschriebenen Nutzung beeinflussen soziale Einflüsse die Nutzungsintention nur zu Beginn der Einführung eines Systems und werden nach längerer Zeit der dauerhaften Nutzung unwichtiger.

Auch Erfahrung schwächt die sozialen Einflüsse ab, da mit zunehmender Erfahrung der wahrgenommene normative Druck durch das soziale Umfeld nachlässt (Venkatesh et al., 2003). Wie bei Leistungs- und Aufwandserwartung zeigen sich zudem Unterschiede bei den sozialen Einflüssen durch Geschlecht und Alter. Bei Frauen und älteren Individuen sind die sozialen Einflüsse auf die Nutzungsintention stärker. Somit wird der Effekt von sozialen Einflüssen auf die verhaltensbasierte Nutzungsintention von allen vier Moderatoren des Modells beeinflusst.

Der empirische Vergleich der getesteten Akzeptanzmodelle in der UTAUT Studie ergab, dass die einzelnen Modelle jeweils nur zwischen 17 bis 53 Prozent der Varianz für die Nutzungsintention erklären konnten. Das UTAUT Modell hingegen konnte 70 Prozent der Varianz des Nutzungsverhaltens erklären (Venkatesh et al., 2003). Somit ist das UTAUT Modell eine erfolgreiche Weiterentwicklung und Konsolidierung der bis dahin bestehenden Technologieakzeptanzmodelle.

2.2.4 Unified Theory of Acceptance and Use of Technology 2 (UTAUT2)

Aufgrund des Erfolgs des UTAUT Modells und zahlreicher neuer Studien nach Veröffentlichung des UTAUT Modells, wurde UTAUT2 erstellt. Während das UTAUT Modell Technologieakzeptanz im Unternehmenskontext untersucht, liegt der Fokus bei UTAUT2 im privaten Endkundenbereich (Venkatesh et al., 2012). Hierzu wurde das UTAUT Modell auf drei Arten erweitert:

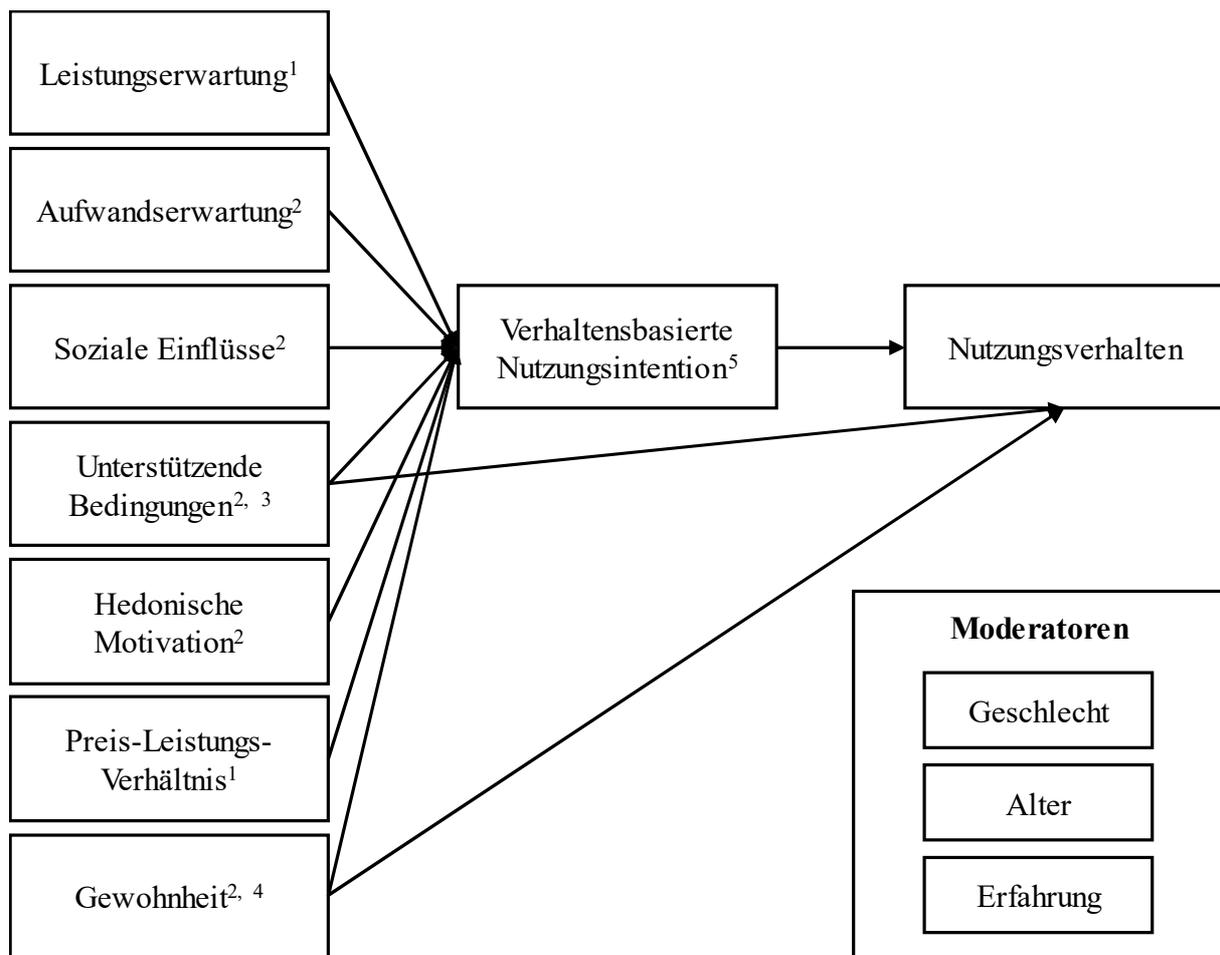
1. Im ersten Schritt wurden drei neue Einflussfaktoren für die Technologieakzeptanz dem Modell hinzugefügt. Dabei handelt es sich um hedonische Motivation, Preis-Leistungs-Verhältnis, und Gewohnheit.
2. Im zweiten Schritt wurden einige Wirkbeziehungen geändert. Freiwilligkeit der Nutzung als Moderator der Beziehung zwischen sozialen Einflüssen und der Nutzungsintention wurde entfernt. Somit ist die Freiwilligkeit der Nutzung kein Bestandteil mehr des UTAUT2 Modells.
3. Ein durch Geschlecht, Alter und Erfahrung moderierter Effekt von den unterstützenden Bedingungen auf die Nutzungsintention wurde hinzugefügt. Der Einfluss der Nutzungsintention auf das Nutzungsverhalten wird nun moderiert durch Erfahrung.

Alle drei neu hinzugefügten Einflussfaktoren beeinflussen die Nutzungsintention unter Berücksichtigung von jeweils mindestens zwei Moderatoren. Zusätzlich beeinflusst Gewohnheit das Nutzungsverhalten direkt. Abbildung 6 zeigt das UTAUT2 Modell. Nachfolgend werden die Änderungen des UTAUT Modells im Detail beschrieben.

Der neue Einflussfaktor *hedonische Motivation* beschreibt den intrinsischen Nutzen einer Technologie für den Nutzer in der Form von Spaß oder Freude bei der Verwendung (Venkatesh et al., 2012). Das UTAUT Modell fokussiert sich hingegen ausschließlich auf den utilitaristischen Wert einer Technologie, der mit extrinsischer Motivation der Nutzung verbunden ist. Somit sind in UTAUT2 sowohl extrinsische als auch intrinsische Nutzungsgründe berücksichtigt, was das Modell aus der Perspektive der Motivationsforschung komplettiert.

Der Effekt durch die hedonische Motivation wird moderiert durch Alter, Geschlecht und Erfahrung. Mit unterschiedlichem Alter und Geschlecht, sind Unterschiede in der Innovationsakzeptanz von Verbrauchertechnologien verbunden. Jüngere Männer zeigen die höchste Innovationsakzeptanz und legen daher höheren Wert auf innovative Produkte und Technologien. Allerdings ist der Effekt der hedonischen Motivation nur in den frühen Phasen der Markteinführung einer neuen Technologie relevant. Mit zunehmender Erfahrung nimmt der Effekt der hedonischen Motivation ab und utilitaristische Gründe für die Nutzung, wie beispielsweise Effektivität und Effizienz, werden relevanter für die Nutzungsintention (Venkatesh et al., 2012).

Das *Preis-Leistungs-Verhältnis* wurde hauptsächlich aufgrund der Fokussierung auf den Endkundenbereich hinzugefügt (Venkatesh et al., 2012). Dort ist die Abwägung zwischen Preis und Leistungsverhältnis ein wichtiger Aspekt bei der Kaufentscheidung, wohingegen im Unternehmenskontext in der Regel diese Abwägung nicht durch die potentiellen Nutzer durchgeführt wird. Ist der wahrgenommene Nutzen einer neuen Technologie größer als die monetären Kosten, so beeinflusst dies die Kaufentscheidung positiv. Ein zu hoher Preis führt in der Regel zur Ablehnung. Der Effekt des Preis-Leistungs-Verhältnisses auf die Nutzungsintention wird moderiert von Alter und Geschlecht. Frauen achten mehr auf Preise und bewerten die Leistung von Produkten kritischer als Männer. Frauen sind oft ausschlaggebend für private Kaufentscheidungen sowie verantwortungsvoller und vorsichtiger im Umgang mit Geld. Da dieser Unterschied nicht biologisch begründet ist und aus einer traditionellen sozialen Rollenverteilung resultiert, nimmt der Effekt mit höherem Alter zu.



Erläuterung der Moderationseffekte:

- 1 Effekt auf verhaltensbasierte Nutzungsintention moderiert von Geschlecht und Alter
- 2 Effekt auf verhaltensbasierte Nutzungsintention moderiert von Geschlecht, Alter und Erfahrung
- 3 Effekt auf Nutzungsverhalten moderiert von Alter und Erfahrung
- 4 Effekt auf Nutzungsverhalten moderiert von Alter, Geschlecht und Erfahrung
- 5 Effekt auf Nutzungsverhalten moderiert von Erfahrung

Abbildung 6: UTAUT2 Modell

Quelle: In Anlehnung an Venkatesh et al. (2012, S. 160)

Gewohnheit bezeichnet den Grad der automatischen Nutzung aufgrund erlernten Verhaltens oder Automtizität, also ein durch eine Intention ausgelöstes, reflexartiges Verhalten (Venkatesh et al., 2012). Das Verhalten wird durch Einstellungsobjekte oder Auslösereize im Umfeld aktiviert und durch Einstellungen oder Intentionen geleitet ohne das darüber nachgedacht werden muss. Beispielsweise prüfen Pendler automatisch ihre Nachrichten auf dem Smartphone, wenn sie in die U-Bahn einsteigen ohne darüber nachzudenken. Die Gewohnheit bildet sich durch Erfahrungen aus der früheren Nutzung und den daraus resultierenden Überzeugungen. Gewohnheit kann als bisherige Nutzung der Technologie operationalisiert werden unter der Annahme, dass frühere Nutzung ein starker Prädiktor für die zukünftige Nutzung ist. In UTAUT2 wird allerdings ein wahrnehmungsbasierter Ansatz

gewählt, der eine Selbsteinschätzung der Gewohnheit erlaubt. Der Einfluss der Gewohnheit auf Nutzungsintention und Nutzungsverhalten wird von Geschlecht, Alter und Erfahrung moderiert. Durch die Nutzung der Technologie über einen ausgedehnten Zeitraum ergeben sich Möglichkeiten, die Nutzung mit Auslösereizen in Verbindung zu bringen. Eine lange Nutzungserfahrung kann sogar zu einer kognitiven Abhängigkeit führen, die Verhaltensänderungen entgegenwirkt. Ältere Individuen vertrauen stärker auf Gewohnheiten, was auch verhindert, dass neue Verhalten erlernt werden. Wenn also bei älteren Individuen ein Nutzungsverhalten zur Gewohnheit wird, lässt sich dieses nur schwer wieder ändern. Da Frauen mehr Wert auf Details in ihrer Umwelt legen, verfallen Sie weniger in Gewohnheiten. Sie nehmen neue und sich ändernde Auslösereize besser wahr und passen ihr Verhalten entsprechend an. Daher ist der Effekt der Gewohnheit bei Frauen schwächer ausgeprägt (Venkatesh et al., 2012).

In frühen Phasen nach der Markteinführung einer neuen Technologie hat Gewohnheit nur einen geringen Einfluss auf das Nutzungsverhalten. Nach längerer Nutzung ersetzt Gewohnheit allmählich die Nutzungsintention als die zentrale Determinante für Nutzungsverhalten. Aufgrund dieses Zusammenhangs moderiert Erfahrung auch den Einfluss der Nutzungsintention auf das Nutzungsverhalten insofern, dass der Effekt stärker ist bei geringerer Erfahrung. Dieser Moderationseffekt der Erfahrung auf die Beziehung zwischen Nutzungsintention und Nutzungsverhalten ist nicht Bestandteil des UTAUT Modells.

Die *Freiwilligkeit der Nutzung*, die die sozialen Einflüsse auf die Nutzungsintention moderiert, ist nicht mehr Bestandteil des UTAUT2 Modells, da die Technologieakzeptanz- und -nutzung von privaten Endnutzern untersucht wird. Die Annahme des UTAUT2 Modells ist, dass die Nutzung im privaten Bereich immer freiwillig erfolgt. Somit wird die Beziehung zwischen sozialen Einflüssen und der Nutzungsintention nur noch von Alter, Geschlecht und Erfahrung moderiert. Die Art der Moderation durch die drei verbleibenden Moderatoren bleibt gleich (Venkatesh et al., 2012).

Im UTAUT2 Modell beeinflussen *unterstützende Bedingungen* im Gegensatz zum UTAUT Modell die Nutzungsintention direkt (Venkatesh et al., 2012). Der Unterschied zum UTAUT Modell resultiert aus dem Fokus auf private Endnutzer bei UTAUT2. Innerhalb von Unternehmen können Individuen üblicherweise auf dieselben unterstützenden Bedingungen wie Schulungen und Support zurückgreifen. Im Endnutzerbereich können sich die unterstützenden Bedingungen aber teilweise deutlich zwischen unterschiedlichen Herstellern oder Technologiegenerationen unterscheiden. Ein Endnutzer mit Zugang zu besseren unterstützenden Bedingungen, beispielsweise einer höheren verfügbaren Mobilfunkbandbreite und besserer Netzabdeckung, hat eine höhere Nutzungsintention für die Verwendung mobiler Internetdienste. Der Effekt der unterstützenden Bedingungen auf die Nutzungsintention wird moderiert durch Alter, Geschlecht und Erfahrung. Ältere Individuen haben häufiger Probleme damit, komplexe Informationen zu verarbeiten. Daher legen sie größeren Wert auf das Vorhandensein von unterstützenden Bedingungen. Weiterhin legen Frauen mehr Wert auf unterstützende Bedingungen, da Männer eine höhere Bereitschaft haben, Beschränkungen und Schwierigkeiten für die Nutzung in Kauf zu nehmen. Auch hier soll allerdings auf die sich ändernden Geschlechterrollen hingewiesen werden. Mit zunehmender Erfahrung werden

unterstützende Bedingungen zunehmend unwichtiger, da die Verwendung der neuen Technologien immer selbstständiger erfolgt und die verfügbaren unterstützenden Bedingungen bekannt und als gegeben betrachtet werden (Venkatesh et al., 2012).

2.2.5 Schlussfolgerungen

Für die Prognose der Akzeptanz von autonomen Fahrzeugen lassen sich aus diesem Abschnitt einige theoretische Schlussfolgerungen ableiten. Die *Leistungs-* und *Aufwandserwartung* werden die wichtigsten Faktoren bei der Einführung autonomer Fahrzeuge sein. Autonome Fahrzeuge sollten also Vorteile gegenüber herkömmlichen Fahrzeugen besitzen und potenzielle Kunden sollten diese auch wahrnehmen können. Dazu gehört beispielsweise, dass man mit autonomen Fahrzeugen schneller und sicherer an sein Ziel kommt. Bei der Einführung ist es außerdem wichtig, dass diese einfach zu bedienen sind. Zwar ist das herkömmliche Autofahren deutlich aufwändiger aber Autofahrer, die bereits jahrelange Fahrerfahrung haben, haben das Fahren bereits internalisiert und identifizieren sich teilweise mit der Fahraufgabe. Die Bedienung autonomer Fahrzeuge ist neu und ungewohnt, wodurch die *Aufwandserwartung* für diese Individuen zunächst deutlich höher sein wird. Bei Individuen, die nicht (mehr) selbst Autofahren können, spricht der Aspekt der *Aufwandserwartung* allerdings für autonome Fahrzeuge. Erst nach einiger Zeit der Nutzung und mit zunehmender *Erfahrung* bezüglich der autonomen Fahrzeuge wird der Aspekt der Aufwandserwartung unwichtiger für die Akzeptanz.

Soziale Einflüsse dürften bei der Einführung autonomer Fahrzeuge die Akzeptanz nur indirekt beeinflussen, da deren Nutzung auf freiwilliger Basis stattfinden sollte. Durch Internalisierung und Identifikation könnten soziale Einflüsse aber die wahrgenommene Leistungs- und Aufwandserwartung beeinflussen. Nach längerer Nutzung und mit zunehmenden eigenen Erfahrungen mit autonomen Fahrzeugen, wird der soziale Einfluss auf die Nutzungsintention geringer.

Unterstützende Bedingungen wirken sich zwar nicht auf die Nutzungsintention aber dafür direkt auf das Nutzungsverhalten aus. Daher ist es entscheidend, dass vor der Einführung autonomer Fahrzeuge gute Rahmenbedingungen geschaffen werden. Es sollten also beispielsweise genügend Strecken für autonome Fahrzeuge verfügbar sein. Dies könnte technische Infrastruktur erfordern, die beispielsweise auf Autobahnen installiert sein muss. Aber auch rechtliche Rahmenbedingungen müssen geschaffen werden, die den Einsatz autonomer Fahrzeuge auf bestimmten Strecken erst ermöglichen. Kommt man mit dem autonomen Fahrzeug nicht zum Ziel oder in dessen Nähe, so muss auf alternative Verkehrsmittel zurückgegriffen werden, die ebenfalls beispielsweise in Form von öffentlichen Verkehrsmitteln oder Leihfahrzeugen oder -rädern angeboten werden müssten.

Die *Einstellung zur Nutzung* ist Bestandteil von zahlreichen Modellen der Technologieakzeptanz und reicht bis auf die Ursprünge der TAM Forschung zurück (Davis et al., 1989). Auch wenn die Nutzungseinstellung durch die Leistungs- und Aufwandserwartung in UTAUT abgedeckt ist, so könnte eine separate Betrachtung dennoch zu interessanten Erkenntnissen führen, um die Akzeptanz oder auch die nicht-Akzeptanz autonomer Fahrzeuge zu erklären. Die Einstellung zur Nutzung kann anhand der positiven und negativen Empfindungen der Probanden bezüglich autonomer Fahrzeuge erhoben werden. Gerade in einer

frühen Phase, in der die Leistungs- und Aufwandserwartung womöglich noch eher unklar sind, kann so bereits ein Meinungsbild erhoben werden.

Zur Einführung könnte auch die *Angst vor der Nutzung* autonomer Fahrzeuge eine wichtige Rolle spielen. Die Unsicherheiten im Umgang mit autonomen Fahrzeugen können Ängste vor der Nutzung auslösen. Diese Ängste könnten allerdings durch Training und Möglichkeiten des Ausprobierens in einer sicheren Umgebung adressiert werden. Hierfür sollte es niedrigschwellige und attraktive Angebote geben, sodass ein hoher Anteil der Gesellschaft daran teilnimmt. Insbesondere die Teile der Gesellschaft, deren Mobilität eingeschränkt ist und die in besonderem Maße von autonomen Fahrzeugen profitieren würden.

Anhand von UTAUT2 können weitere Erkenntnisse bezüglich der Einführung autonomer Fahrzeuge abgeleitet werden. Diese ergänzen die Erkenntnisse aus dem UTAUT Modell. *Leistungserwartung, Aufwandserwartung, soziale Einflüsse* und *unterstützende Bedingungen* sind weiterhin Bestandteil des UTAUT2 Modells. Neu ist hingegen, dass UTAUT2 auch bei *freiwilliger Nutzung* einen Effekt durch soziale Einflüsse postuliert. Dieser wurde bei UTAUT auf die vorgeschriebene Nutzung begrenzt. Der Einfluss der *unterstützenden Bedingungen* auf die *Nutzungsentention* ist ebenfalls ein neuer Bestandteil von UTAUT2 und sollte bei der Untersuchung der Akzeptanz autonomer Fahrzeuge berücksichtigt werden.

Der Einfluss von *hedonischer Motivation* könnte bei der Einführung autonomer Fahrzeuge eine wichtige Rolle spielen, da die utilitaristischen Aspekte wie Leistungs- und Aufwandserwartung zur Einführung noch nicht hinlänglich bekannt sein dürften. Durch hedonische Motivation kann so bereits vorab ein Anreiz zur Nutzung gesetzt werden. Fahrzeughersteller setzen zur hedonischen Motivation beispielsweise auf Fernsehwerbung, soziale Medien oder interaktive Fahrzeugkonfiguratoren auf der Herstellerwebsite (Füller, 2017). Bei der initialen Einführung sollten daher die hedonischen Attribute autonomer Fahrzeuge besonders hervorgehoben werden. Dazu gehört beispielsweise eine visuell ansprechende Darstellung, Unterstützung zur Selbstdarstellung und das Hervorrufen von Fantasien und Emotionen. Auch bei den autonomen Fahrzeugen selbst können ein ansprechendes Interieur und Exterieur bei der Einführung unterstützen.

Bei der Einführung autonomer Fahrzeuge würde auch ein gutes *Preis-Leistungs-Verhältnis* helfen, da deren Nutzen noch nicht vollumfänglich bekannt sein dürfte. Dies steht im Gegensatz zu den hohen Entwicklungskosten, die mit dem Kaufpreis gedeckt werden müssen. Auch an marktüblichen Preisen können sich die Hersteller zu Beginn noch nicht orientieren. Für die initiale Preisfindung könnten Hersteller beispielsweise eine wertbasierte Preisgestaltung verfolgen (Best, 2012). Dazu ist es allerdings erforderlich, die Wünsche der Kunden und deren Zahlungsbereitschaft möglichst genau zu kennen. Um diese bei komplexen und neuen Produkten zu ermitteln sind Conjoint-Analysen gut geeignet (Goffart, Schermann, Kohl, Preißinger & Krcmar, 2016; Green, Krieger & Wind, 2003). Womöglich wird der traditionelle Autokauf allerdings ohnehin nicht das populärste Geschäftsmodell für autonome Fahrzeuge sein (Ambadipudi, Heineke, Kampshoff & Shao, 2017). Beispielsweise könnte ein pay-per-use Geschäftsmodell in Form von „Robo-Taxis“ helfen, autonome Fahrzeuge im öffentlichen Straßenverkehr zu etablieren. Insbesondere in der Anfangsphase der Markteinführung könnte

es sich für Firmen lohnen, Mobilitätsdienstleistungen basierend auf autonomen Fahrzeugen mit geringen Margen anzubieten. Dadurch ließe sich die anfängliche Akzeptanz einerseits durch ein gutes Preis-Leistungs-Verhältnis und andererseits durch Erfahrungen mit der Technologie erhöhen. Autonome Fahrzeuge könnten, insbesondere bei dieser Vorgehensweise, jedoch eine Disruption des bestehenden Marktes auslösen, von der traditionelle Mobilitätsdienstleister, wie beispielsweise Taxiunternehmen, stark betroffen sein dürften.

Eine Herausforderung bei der Einführung autonomer Fahrzeuge sind die bestehenden *Gewohnheiten* der Autofahrer, die jahrzehntlang selbst gefahren sind und nun die Kontrolle an ein System übergeben sollen. Die Änderung von langwierig eingeübten Gewohnheiten gestaltet sich schwierig und kann nur über einen längeren Zeitraum erfolgen. Die evolutionäre Entwicklung von Fahrerassistenzsystemen hin zum autonomen Fahren ermöglicht allerdings, sich vorher schon mit den Möglichkeiten autonomer Fahrzeuge vertraut zu machen. Fahrzeughersteller sollten daher die bereits verfügbaren Fahrerassistenzsysteme wie beispielsweise aktive Spurhalteassistenten oder Notbremsassistenten in attraktiven Angeboten zur Verfügung stellen. Dies würde sich nicht nur positiv auf die Sicherheit der Fahrzeuge sondern auch im Hinblick auf die Akzeptanz autonomer Fahrzeuge positiv auswirken. Weitere Möglichkeiten zur Änderung der Gewohnheiten sind die in Abschnitt 2.3 erläuterten Pilotprojekte, autonome öffentliche Verkehrsmittel und preislich attraktive pay-per-use Angebote.

2.3 Diffusionstheorie

Die Akzeptanz ändert sich im zeitlichen Verlauf. Vor dem Markteintritt sind andere Aspekte für die Akzeptanz relevant als nach dem Markteintritt. Dies zeigt sich schon im Unterschied zwischen Akzeptanz und Akzeptabilität, der in Abschnitt 2.1 erläutert wurde. Weiterhin ändert sich die Akzeptanz auch nach dem Markteintritt einer Innovation. Für die Prognose der Akzeptanz von Innovationen ist es erforderlich, diesen Prozess zu verstehen, der als Diffusion bezeichnet wird. Dieser Abschnitt erläutert die Diffusionstheorie, die auf Rogers (2003) zurückgeführt wird aber ihre Anfänge bereits in den 1940er Jahren begründet.

2.3.1 Hauptelemente der Diffusionstheorie

Diffusion ist der Prozess, in dem eine Innovation über bestimmte Kanäle im Laufe der Zeit unter den Mitgliedern eines sozialen Systems kommuniziert wird (Rogers, 2003, S. 5). Entsprechend dieser Definition können vier Hauptelemente der Diffusion abgeleitet werden:

- **Innovation:** Eine Innovation ist eine Idee, ein Verfahren oder ein Objekt, das von einer Person oder einer anderen Adoptionseinheit als neu wahrgenommen wird.
- **Kommunikation:** Der Prozess, durch den die Teilnehmer Informationen erstellen und miteinander austauschen, um zu einem gegenseitigen Verständnis zu gelangen.
- **Zeit:** Die Zeit von der ersten Kenntnisnahme einer Innovation bis zu deren Annahme oder Ablehnung.
- **Soziales System:** Ein soziales System ist definiert als eine Reihe von miteinander verbundenen Einheiten, die sich mit der gemeinsamen Problemlösung zur Erreichung eines gemeinsamen Ziels befassen.

Entlang dieser vier Hauptelemente lässt sich die Diffusion von Innovationen beschreiben und beeinflussen.

2.3.2 Charakteristiken von Innovationen

Die Diffusionstheorie unterscheidet zwischen fünf Charakteristiken von Innovationen (Rogers, 2003, S. 14–16). Anhand dieser Charakteristiken kann die Diffusion einer Innovation begünstigt oder erschwert sein. In diesem Abschnitt beschreiben wir die Charakteristiken von Innovationen. Anschließend erläutern wir diese am Beispiel autonomer Fahrzeuge und leiten Schlussfolgerungen für deren Diffusion ab.

Relativer Vorteil

Der relative Vorteil ist der Grad, mit dem eine Innovation als besser wahrgenommen wird als die Idee, die sie ersetzt. Der Grad des relativen Vorteils kann in wirtschaftlicher Hinsicht gemessen werden, aber auch soziale Prestigefaktoren, Komfort und Zufriedenheit sind wichtige Faktoren. Entscheidend ist dabei, ob ein Individuum die Innovation als vorteilhaft empfindet. Je größer der wahrgenommene relative Vorteil einer Innovation, desto schneller wird ihre Akzeptanz sein (Rogers, 2003, S. 15).

Kompatibilität

Kompatibilität ist der Grad, mit dem eine Innovation als konsistent mit den bestehenden Werten, bisherigen Erfahrungen und Bedürfnissen potenzieller Anwender wahrgenommen wird. Eine Idee, die mit den Werten und Normen eines Sozialsystems unvereinbar ist, wird nicht so schnell angenommen wie eine Innovation, die kompatibel ist. Die Einführung einer inkompatiblen Innovation erfordert oft die vorherige Einführung eines neuen Wertesystems, was ein relativ langwieriger Prozess ist (Rogers, 2003, S. 15).

Komplexität

Komplexität ist der Grad, mit dem eine Innovation als schwer verständlich und anwendbar wahrgenommen wird. Einige Innovationen werden von den meisten Mitgliedern eines Sozialsystems leicht verstanden, andere sind komplizierter und werden langsamer übernommen. Neue Ideen, die einfacher zu verstehen sind, werden schneller übernommen als Innovationen, bei denen der Anwender neue Fähigkeiten und Erkenntnisse entwickeln muss (Rogers, 2003, S. 15).

Erprobbarkeit

Erprobbarkeit ist der Grad, mit dem eine Innovation ausprobiert werden kann. Neue Ideen, die zu mehreren Zeitpunkten während der Entstehung ausprobiert werden können, werden in der Regel schneller angenommen als Innovationen, bei denen dies nicht der Fall ist. Eine Innovation, die erprobbar ist, stellt für den Einzelnen eine geringere Unsicherheit dar, da während der Entstehung bereits Nutzungserfahrungen gesammelt und notwendige Kenntnisse zur Verwendung erlernt werden konnten (Rogers, 2003, S. 15f).

Beobachtbarkeit

Beobachtbarkeit ist der Grad, in dem die Ergebnisse einer Innovation für andere sichtbar sind. Je einfacher es für den Einzelnen ist, das Vorteile einer Innovation wahrzunehmen, desto wahrscheinlicher ist es, dass dieser sie übernimmt. Die Beobachtbarkeit regt die Diskussion über eine neue Idee an, indem beispielsweise Nachbarn oder Freunde Informationen oder die Meinung des Nutzers erfahren wollen (Rogers, 2003, S. 16).

Zusammenfassend, sollte die Innovation für eine möglichst schnelle Diffusion wie folgt charakterisiert sein:

- Die Innovation sollte einen *hohen relativen Vorteil* gegenüber anderen Innovationen besitzen,
- eine *hohe Kompatibilität* mit den sozialen Praktiken und Normen der Nutzer aufweisen,
- die Verwendung sollte *wenig komplex* sein oder nur geringen Trainingsaufwand benötigen,
- durch Möglichkeiten des Ausprobierens vor der Nutzung eine *hohe Erprobbarkeit* aufweisen und
- eine *hohe Beobachtbarkeit* durch klar erkennbare Vorteile der Technologie sicherstellen.

2.3.3 Zeitliche Betrachtung der Diffusion

Betrachtet man den zeitlichen Verlauf der Diffusion über zahlreiche Innovationen in Retrospektive, so lassen sich Gemeinsamkeiten bei der Entwicklung des Marktanteils und der Diffusionsrate feststellen (Rogers, 2003, S. 243–245). Der Marktanteil folgt einer Sigmoid- oder S-Funktion wie in Abbildung 7 ersichtlich. Die Diffusionsrate ist die Ableitung des Marktanteils über die Zeit und folgt einer Normalverteilung. Sie beschreibt, wie viele neue Nutzer pro Zeiteinheit die Innovation annehmen. Anhand des Verlaufs des Marktanteils ist ersichtlich, dass dieser zu Beginn nur sehr langsam ansteigt aber ab einem bestimmten Punkt in ein sehr schnelles Wachstum übergeht. Dieser Punkt wird als kritische Masse bezeichnet, der aus einer überdurchschnittlich guten Vernetzung der ersten Nutzer hervorgeht (Karnowski, 2013).

Weiterhin befinden sich unter den ersten Nutzern auch überdurchschnittlich viele Meinungsführer, deren Meinung von vielen beachtet und bei der Entscheidung für oder gegen die Innovation einbezogen wird. An dieser Stelle werden auch die interpersonellen Netzwerke aktiv, sodass Nachrichten über die Innovation von Individuum zu Individuum ausgetauscht werden und nicht mehr von wenigen zentralen Punkten aus. Üblicherweise ist dies zwischen 10 % und 20-25 % des Marktanteils der Fall. Durch diese Art der Verbreitung ist es fast unmöglich die Diffusion einer Innovation in dieser Phase noch zu stoppen, bis sich ab einem Marktanteil von 50 % der Anstieg wieder verlangsamt.

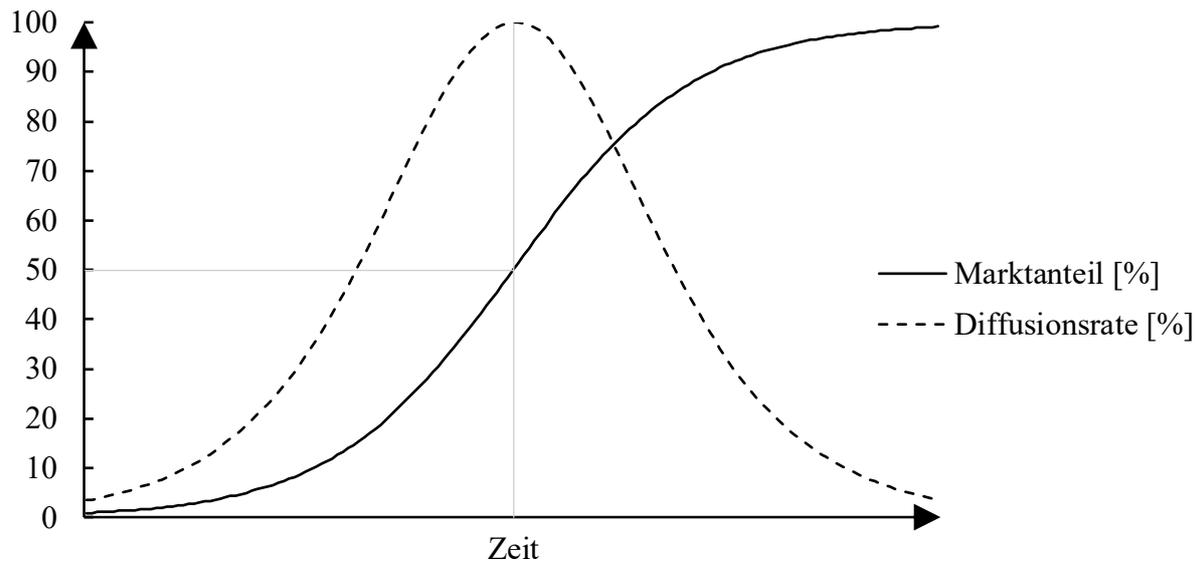


Abbildung 7: Marktanteil und Diffusionsrate bei der Diffusion von Innovationen

Quelle: In Anlehnung an Rogers (2003, S. 243)

2.3.4 Kategorisierung der Marktteilnehmer

Anhand des Zeitpunkts der Annahme der Innovation lassen sich Kategorien für Individuen herausarbeiten, um die Diffusion besser zu verstehen. Wie im vorherigen Abschnitt erläutert, ist die Diffusionsrate annähernd normalverteilt. Mittels dieser Verteilung werden die Individuen in fünf Kategorien untergliedert, denen jeweils bestimmte Eigenschaften zugeteilt werden. Die Grenzen zwischen den Kategorien sind zwar fließend, die Individuen werden jedoch nach den statistischen Kennzahlen für Mittelwert (M) und Standardabweichung (SD) voneinander getrennt. Zum Zeitpunkt M haben 50 % der Marktteilnehmer die Innovation angenommen. Mit diesem Verfahren werden alle Individuen eindeutig einer Kategorie zugeordnet. Es kann somit genau zwischen den einzelnen Kategorien unterschieden werden und auch eine Mehrfachzuordnung ist ausgeschlossen. Die Kategorien und deren Verteilung ist in Abbildung 8 dargestellt und werden im Nachfolgenden beschrieben.

Innovatoren / Innovators: Risikofreudig

Die ersten, die in Kontakt mit der Innovation treten, sind die Innovatoren (Rogers, 2003, S. 248). Nur die ersten 2,5 % der Nutzer einer Innovation werden dieser Kategorie zugeordnet. Sie sind nahezu besessen von ihrer Risikofreudigkeit und probieren sehr bereitwillig neue Ideen aus. Innovatoren sind gut mit anderen Innovatoren vernetzt und befreundet, auch wenn diese durch eine große räumliche Distanz getrennt sind. Durch die hohe Risikofreudigkeit und dem Drang Innovationen auszuprobieren, die mit hohen Verlusten einhergehen können, benötigen sie beträchtliche finanzielle Ressourcen. Weiterhin benötigen Innovatoren Zeit, um sich in komplexe technische Sachverhalte einzuarbeiten und sich mit der Innovation vertraut zu machen. Es gehört auch eine Toleranz für Fehlschläge dazu, da sich viele Innovationen nicht durchsetzen. Der Innovator ist üblicherweise keine Respektsperson innerhalb eines sozialen Systems, übernimmt aber eine wichtige Gatekeeper Rolle in diesem. Er bringt neue Ideen ein, zu denen das soziale System ansonsten keinen Bezug hat.

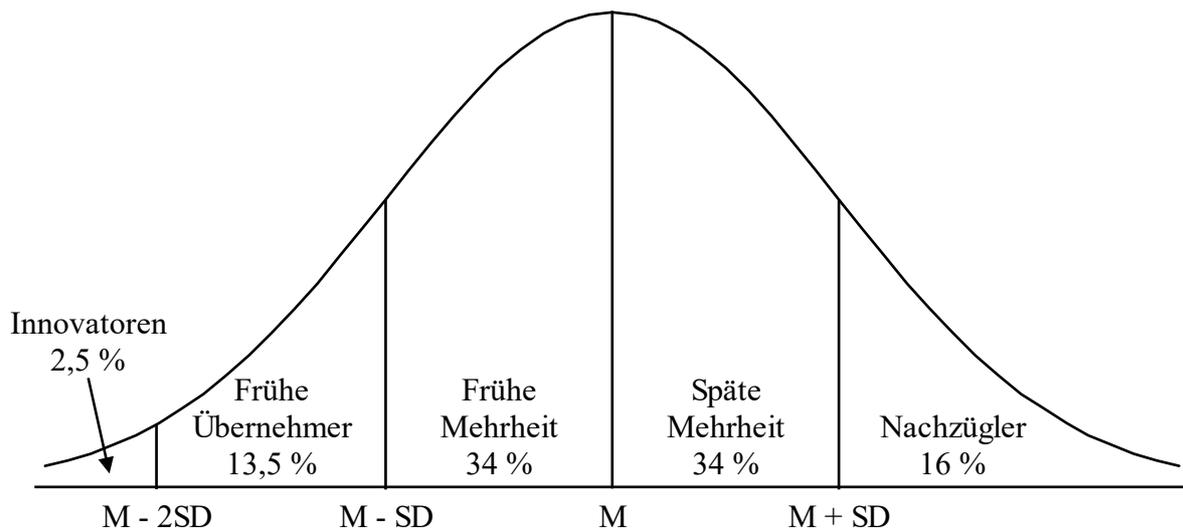


Abbildung 8: Kategorisierung der Marktteilnehmer

Quelle: In Anlehnung an Rogers (2003, S. 247)

Frühe Übernehmer / Early Adopters: Respektabel

Die frühen Übernehmer sind im Vergleich zu den Innovatoren besser in das soziale System integriert (Rogers, 2003, S. 248f). Sie sind nach den Innovatoren die nächsten 13,5 %, die eine Innovation nutzen. Sie genießen Ansehen und sind meistens regional gut vernetzt. In dieser Kategorie befinden sich außerdem die meisten Meinungsführer verglichen mit den anderen Kategorien. Die frühen Übernehmer sind bekannt dafür, über Innovationen informiert zu sein und werden daher auch oft von ihrem Umfeld um ihre Meinung gefragt, bevor eine Anschaffung getätigt wird. Die frühen Übernehmer sind sich ihrer Verantwortung gegenüber ihrem sozialen System bewusst und wählen daher nur für die Allgemeinheit vorteilhafte Innovationen aus. Dadurch festigen sie ihre zentrale und respektable Rolle. Frühe Übernehmer sollten daher als erstes adressiert werden, wenn eine Innovation eingeführt werden soll. Haben frühe Übernehmer Einwände oder Bedenken, sollten diese Berücksichtigt werden, da davon auszugehen ist, dass diese auch dem großen Umfeld der frühen Übernehmer mitgeteilt werden. Können die frühen Übernehmer eines sozialen Systems von der Innovation überzeugt werden, kommt es zur kritischen Masse und dem schnellen Anstieg der Diffusionsrate.

Frühe Mehrheit / Early Majority: Abwartend

Die Kategorie der frühen Mehrheit schließt an die frühen Übernehmer an und beinhaltet die nächsten 34 % der Individuen, die eine Innovation nutzen (Rogers, 2003, S. 249). Mit den beiden vorangegangenen Kategorien sind sie somit Teil der ersten 50 % des Marktes der Innovation. Diese Kategorie zeichnet sich dadurch aus, dass sie auf erste Erfahrungen nach der Einführung der Innovation wartet und nicht direkt nach der Vorstellung einer Innovation kauft. Auch in anderen Aspekten nehmen die Individuen in dieser Kategorie selten eine Führungsrolle ein. Dennoch ist die frühe Mehrheit ein wichtiges Bindeglied zwischen den frühen Übernehmern und den verbleibenden Kategorien. Ihre Erfahrungen mit der Innovation bilden die Entscheidungsgrundlage für die verbleibenden Marktteilnehmer. Darüber hinaus ist der

Marktanteil dieser Kategorie von 34 % relativ groß und daher wichtig für den kommerziellen Erfolg einer Innovation.

Späte Mehrheit / Late Majority: Skeptisch

Nach den ersten 50 % der Marktteilnehmer entscheidet sich auch die späte Mehrheit für die Innovation (Rogers, 2003, S. 249f). Häufig aber nicht freiwillig, sondern getrieben durch ökonomische Zwänge oder sozialen Druck aus dem Umfeld. Diese Kategorie zeichnet sich durch eine generelle Skepsis gegenüber Innovationen aus. Auch wenn sie von der Nützlichkeit von Innovationen überzeugt werden können, so ist stets auch noch Überzeugungsarbeit des sozialen Umfelds erforderlich, bevor eine Entscheidung zur Annahme der Innovation getroffen wird. Meistens liegt dies begründet in den begrenzten Ressourcen dieser Kategorie. Sie können es sich schlicht nicht erlauben, die mit Innovationen verbundene Unsicherheit in Kauf zu nehmen und sind davon abhängig, dass die Innovation sicher ist und sich die Investition lohnt. Individuen dieser Kategorie zu erreichen ist schwierig aber aufgrund des hohen Marktanteils von 34 % erforderlich.

Nachzügler / Laggards: Traditionell

Die Kategorie der Nachzügler entscheidet sich als letztes für die Innovation, oft wenn für diese bereits ein Nachfolger existiert (Rogers, 2003, S. 250f). Die Nachzügler sind rückwärtsgewandt, nahezu isoliert im sozialen System und nur sehr selten befinden sich Meinungsführer in dieser Kategorie. Die Entscheidung für eine Innovation wird aus der Perspektive von früheren Generationen getroffen und nach Rücksprache mit Individuen, die ähnlich traditionell eingestellt sind. Vom finanziellen Standpunkt leben Nachzügler oft in prekären Verhältnissen. Es muss also noch sorgfältiger als bei der späten Mehrheit mit den geringen verfügbaren Ressourcen umgegangen werden. Daher sind sie sehr risikoavers und vermeiden Unsicherheiten, wo es nur möglich ist. Nach Definition befinden sich 16 % der Teilnehmer des Marktes für eine Innovation in dieser Kategorie.

2.3.5 Schlussfolgerungen

Für die Prognose der Akzeptanz von autonomen Fahrzeugen lassen sich aus diesem Abschnitt einige theoretische Schlussfolgerungen ableiten. Für eine schnelle Diffusion müssen die *relativen Vorteile* autonomer Fahrzeuge gegenüber dem manuellen Fahren klar wahrnehmbar für die potenziellen Nutzer sein. Die relativen Vorteile müssen dazu klar kommuniziert und nachvollziehbar sein. Es genügt also nicht, dass das autonome Fahren objektive Vorteile hat. Beispielsweise können Individuen autonomes Fahren als vorteilhaft empfinden aufgrund der höheren Fahrsicherheit. Ausgehend von psychologischen Faktoren könnte jedoch auch der Kontrollverlust zu einer geringeren wahrgenommenen Sicherheit führen und autonomes Fahren daher eher als unvorteilhaft wahrgenommen werden.

Ein kritischer Punkt stellt die *Kompatibilität* mit sozialen Praktiken und Normen der Nutzer dar. Das Fahren ist für viele nicht nur ein Mittel, um ein Mobilitätsbedürfnis zu erfüllen, sondern auch mit Fahrfreude und Status verbunden (Winner, 2015). Fahrzeuge, die selbst fahren und vielleicht gar nicht Eigentum des Fahrers sind, sondern Teil einer mit mehreren

Personen geteilten Flotte von Fahrzeugen, könnten bei vielen Individuen einen Konflikt mit bestehenden Normen auslösen. Insbesondere in Städten und bei jüngeren Personen ist aber ein Umdenken erkennbar indem beispielsweise vermehrt auf Carsharing Angebote oder andere Verkehrsmittel zurückgegriffen wird und der Besitz eines eigenen Fahrzeugs in den Hintergrund tritt (Winner, 2015).

Bei der *Komplexität* hingegen hat das autonome Fahren klare Vorteile gegenüber herkömmlichen Fahrzeugen, bei denen ein langwieriges Training zum erfolgreichen Bestehen der Führerscheinprüfung erforderlich ist. Diese darf zudem erst ab einem bestimmten Alter abgelegt werden und ist für bestimmte Personengruppen mit körperlichen und geistigen Einschränkungen gar nicht machbar. Trotzdem muss die Komplexität bei der Gestaltung der Benutzerschnittstelle berücksichtigt werden. Möglich wären beispielsweise intuitive Sprachschnittstellen, die mit natürlicher Sprache und gegebenenfalls im Dialog mit dem Nutzer möglichst barrierefrei bedient werden können. Diese Schnittstellen sind auch wichtig für Fahrzeuge mit niedrigeren Automatisierungsstufen in der Übergangsphase. Es muss beispielsweise klar ersichtlich sein, wenn die Automatisierung an ihre Grenzen stößt und wann Fahrer bei Vorstufen autonomer Fahrzeuge wieder die Fahraufgabe übernehmen müssen, damit keine Unfälle durch die Automatisierung ausgelöst werden (Gold, Körber, Hohenberger, Lechner & Bengler, 2015). Solche Unfälle könnten sich auch auf die Akzeptanz zukünftiger autonomer Fahrzeuge auswirken.

Die *Erprobbarkeit* des autonomen Fahrens ist mangels verfügbarer Produkte im Jahr 2019 nur eingeschränkt möglich. Es gibt einige Projekte, bei denen autonome Fahrzeuge die Passagiere in abgegrenzten Bereichen und bei niedrigen Geschwindigkeiten transportieren, beispielweise in Bad Birnbach mit einem Elektrobuss der Deutschen Bahn (Seeger, 2018). Meist ist in diesen Fahrzeugen zusätzlich noch ein Sicherheitsfahrer zugegen, der das Fahrzeug notfalls in eine sichere Halteposition bringen kann - so auch in Bad Birnbach. Weiterhin sind autonome Züge weltweit bereits in 42 Städten im Einsatz, die Passagiere ohne Sicherheitsfahrer transportieren (Weedon, 2019). Auch Erfahrungen mit fortschrittlichen FAS könnten sich positiv auswirken. Bisher ist aber noch nicht erforscht, inwiefern sich Erfahrungen mit solchen Transportmitteln auf die Akzeptanz zukünftiger autonomer Fahrzeuge auswirken wird.

Auch die *Beobachtbarkeit* ist aufgrund des Mangels an verfügbaren Produkten sehr eingeschränkt. Das Informationsbedürfnis kann daher für Laien hauptsächlich durch Medienkonsum und den Austausch von Meinungen erfolgen. Obwohl autonome Fahrzeuge noch nicht für die breite Allgemeinheit verfügbar sind, dürften sich durch die mediale Präsenz dieses Themas bereits viele Menschen eine Meinung zu autonomen Fahrzeugen gebildet haben. Insbesondere in sozialen Medien und in Kommentarbereichen zu online Artikeln finden ein reger Austausch sowie kontroverse Diskussionen statt (Lenz & Fraedrich, 2015). Es ist jedoch noch nicht erforscht, inwiefern sich der Austausch von Meinungen über ein noch nicht verfügbares Produkt auf dessen Akzeptanz auswirkt.

Bei der Erläuterung der Innovationscharakteristika wird bereits die Rolle der *Kommunikationskanäle* deutlich. Über diese können zwei Individuen Nachrichten miteinander austauschen (Rogers, 2003, S. 17–19). Laut der Diffusionstheorie kann mittels Massenmedien

eine Innovation am schnellsten bekannt gemacht werden. Zu den Massenmedien zählen beispielsweise Radiosender, Fernsehen und Zeitungen. Die Kommunikation erfolgt von einem Sender zu vielen Individuen. Dem gegenüber stehen interpersonelle Kanäle des Austauschs zwischen zwei und mehr Individuen, bei denen auch der Austausch über das Internet eine immer größere Rolle bei der Diffusion einnimmt. Eine Zwischenform zwischen Massenmedien und dem interpersonellen Austausch stellen soziale Medien und Netzwerke dar. Die genauen Mechanismen und die Rolle für die Diffusion von Innovationen ist noch Gegenstand aktueller Untersuchungen (z. B. Riedl et al., 2018). Auch wenn die genauen Mechanismen noch nicht bekannt sind, sind soziale Medien zu einem zentralen Kommunikationskanal für die Informationsdiffusion geworden. Stieglitz & Dang-Xuan (2013, S. 218) sprechen sogar davon, dass sich die Physik der Informationsdiffusion durch soziale Medien geändert hat. Insbesondere Twitter erweist sich bei den Untersuchungen immer wieder als wertvolle Quelle von Daten für wegweisende Erkenntnisse zur Diffusion (z. B. Iyengar, Van den Bulte & Valente, 2011; Riedl, Köbler, Goswami & Krcmar, 2013).

Aufgrund der theoretischen Schlussfolgerungen in diesem Abschnitt skizzieren wir im Folgenden ein mögliches Diffusionsszenario für autonome Fahrzeuge. Die Diffusion autonomer Fahrzeuge wird mit risikofreudigen *Innovatoren* beginnen, die bereit sind, die ersten autonomen Fahrzeuge zu nutzen. Entscheidend für den Erfolg werden aber die *frühen Übernehmer* sein, die sich anhand der Erfahrungen der Innovatoren und den fünf in diesem Abschnitt erläuterten Charakteristiken von Innovationen eine Meinung zum autonomen Fahren bilden werden. Vor der Markteinführung autonomer Fahrzeuge sollten diese also zu deren Einschätzung von positiven wie negativen Aspekten befragt werden. Nur wenn diese Individuen überzeugt sind, werden sie eine Empfehlung in deren sozialen Systemen aussprechen (Rogers, 2003, S. 248f).

Ist diese Hürde geschafft, wird der autonome Verkehr schnell zunehmen. In dieser Phase ist nun kritisch, dass es durch den sich rapide ändernden Mischverkehr mit herkömmlichen Fahrzeugen nicht zu schwerwiegenden Beeinträchtigungen des Verkehrsflusses und der Verkehrssicherheit kommt. Insbesondere Unfälle mit hochautomatisierten und autonomen Fahrzeugen könnten sich negativ auf die Verbreitung auswirken. Die *frühe Mehrheit* wird diese Erfahrungen abwarten und sich dann für oder gegen autonome Fahrzeuge entscheiden (Rogers, 2003, S. 249). Kommt es zu einer positiven Entscheidung, werden sich am Ende dieser Phase erstmals mehr autonome Fahrzeuge als herkömmliche Fahrzeuge im Straßenverkehr bewegen (Rogers, 2003, S. 247). Aufgrund des großen Marktpotentials autonomer Fahrzeuge ist mit zahlreichen neuen Geschäftsmodellen im Bereich der Mobilität zu rechnen. Sind diese hinreichend attraktiv, kommen diese auch für die *späte Mehrheit* in Betracht (Rogers, 2003, S. 249f).

In geschäftlichen Bereichen, in denen die Personalkosten des Fahrers einen großen Anteil der Kosten ausmacht, werden sich Entscheider in der *späten Mehrheit* kaum noch gegen die Verwendung autonomer Fahrzeuge aussprechen können (Rogers, 2003, S. 249f). Im privaten Bereich werden die Nutzungskosten für autonome Fahrzeuge vermutlich bereits zu Beginn sehr attraktiv sein. Mit zunehmender Reife der Technologie werden die Herstellkosten weiter sinken und die initial geringeren Margen für Mobilitätsdienstleister und Hersteller werden größer. Zu

einem Teil werden die Ersparnisse aber auch an Kunden weitergegeben, wodurch sich der finanzielle Druck auf die späte Mehrheit weiter erhöht. Neue Geschäftsmodelle könnten auch komplett kostenfreie Fahrten ermöglichen durch Werbung und Freigabe der Bewegungsdaten. Entsprechend des Freemium Geschäftsmodells (Weking, Hein, Böhm & Kremer, 2020) könnten auch Aufpreise für zusätzlichen Komfort oder Werbefreiheit erhoben werden, die preissensitiveren Nutzern kostenfreie Fahren ermöglichen.

Weiterhin wird der soziale Druck für die späte Mehrheit zunehmen, autonome Fahrzeuge zu nutzen. Womöglich wird das Fahren zukünftig als lästige Tätigkeit für die Erfüllung eines Mobilitätsbedürfnisses angesehen, ähnlich dem Wäschewaschen ohne Waschmaschine oder dem Geschirrspülen ohne Geschirrspülmaschine. Ein weiterer Kritikpunkt des sozialen Umfelds könnte das Risiko des manuellen Fahrens sein. Man setzt sich selbst, seine Mitfahrer und andere Verkehrsteilnehmer einer gefährlichen Situation aus, weil man kein autonomes Fahrzeug nutzen möchte.

Die letzte Kategorie der *Nachzügler* entziehen sich durch mangelnde soziale Vernetzung zunächst dieser Diskussion (Rogers, 2003, S. 250f). Kommt es aber beispielsweise vermehrt zu Unfällen durch die letzten 16 % der Bevölkerung, die noch keine autonomen Fahrzeuge verwenden, müsste spätestens zu diesem Zeitpunkt der Gesetzgeber einschreiten und die letzten verbleibenden, nicht autonomen Fahrzeuge aus dem Verkehr ziehen. Diese werden zu diesem Zeitpunkt bereits nicht mehr für den Einsatz im öffentlichen Straßenverkehr produziert, da Hersteller verpflichtet sind, Fahrzeuge auf dem Stand der Technik zu produzieren und ansonsten für Unfälle selbst haftbar sind (Wilhelm, Ebel & Weitzel, 2015).

2.4 Gesellschaftliche Akzeptanz

Neben der Betrachtung der Technologieakzeptanz, bei der die Akzeptanz des Nutzers untersucht wird, kann die Akzeptanz auch auf organisatorischer, kultureller und gesellschaftlicher Ebene untersucht werden (Regan et al., 2014, S. 3–8). Insbesondere die Betrachtung auf gesellschaftlicher Ebene ist für Technologien relevant, bei denen die Gesellschaft ein berechtigtes Mitspracherecht hat. Dies ist beispielsweise der Fall, wenn eine Technologie Risiken für die Allgemeinheit birgt und somit eine Abwägung zwischen Nutzen und Risiko für die Gesellschaft durchgeführt werden muss. Beispiele hierfür sind Gentechnik, Atomenergie oder auch Informations- und Kommunikationstechnologien (Gupta et al., 2011). Auch für autonome Fahrzeuge ist dies der Fall, da unter anderem durch autonome Fahrzeuge verursachte Unfälle ein Risiko für die Allgemeinheit darstellen. Werden Nutzen und Risiko nicht sorgfältig abgewogen, kann dies Widerstandsverhalten auslösen. Somit sollte neben der Technologieakzeptanz auch die gesellschaftliche Akzeptanz autonomer Fahrzeuge untersucht werden. In diesem Abschnitt erläutern wir die theoretischen Grundlagen auf denen die Messung der gesellschaftlichen Akzeptanz basiert.

2.4.1 Modell der gesellschaftlichen Akzeptanz

Die Forschung zur gesellschaftlichen Akzeptanz sieht in Risiko- und Nutzenwahrnehmung zentrale Einflussfaktoren für die Akzeptanz (Siegrist, 2000). Das Modell der gesellschaftlichen Akzeptanz nach Siegrist (2000) beschreibt das Verhältnis von Risiko- und

Nutzenwahrnehmung, Vertrauen und Akzeptanz in der Gesellschaft. Es beinhaltet, dass die Wahrnehmung von Risiken und Nutzen einen direkten Einfluss auf die gesellschaftliche Akzeptanz ausübt, wie in Abbildung 9 dargestellt.

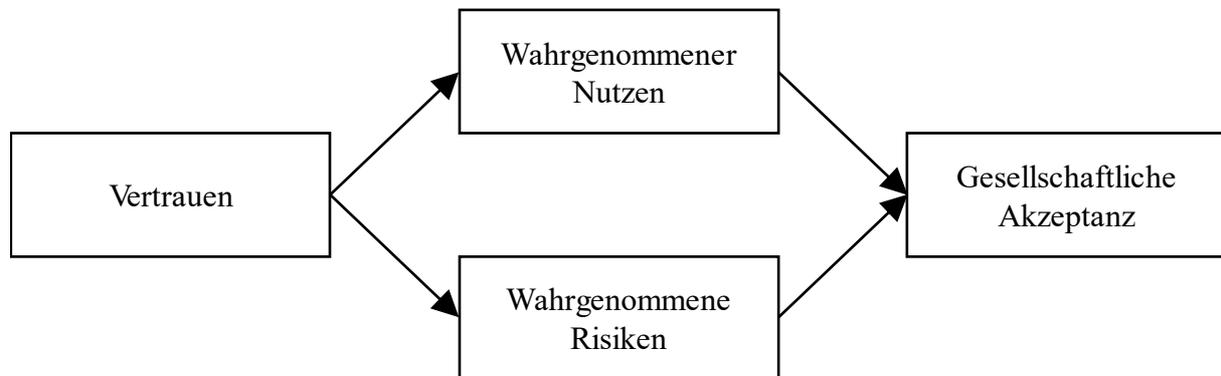


Abbildung 9. Modell der gesellschaftlichen Akzeptanz

Quelle: In Anlehnung an Siegrist (2000, S. 197)

Das Modell der gesellschaftlichen Akzeptanz wurde ursprünglich zur Untersuchung der Akzeptanz von Gentechnologie entwickelt und wurde seitdem für viele neue Technologien von öffentlichem Interesse wie Nanotechnologie (Siegrist, Cousin, Kastenholz & Wiek, 2007) oder Atomkraftwerke (Visschers & Siegrist, 2013) angewendet. Das Modell besagt, dass der wahrgenommene Nutzen einer Technologie die gesellschaftliche Akzeptanz positiv beeinflusst. Wahrgenommene Risiken hingegen beeinflussen die gesellschaftliche Akzeptanz einer Technologie negativ. Es findet also eine Abwägung statt, inwiefern der Nutzen einer Technologie die Risiken überwiegt. Risiko- und Nutzenwahrnehmungen werden durch Vertrauen beeinflusst, das den Menschen hilft, die kognitive Komplexität bei der Bewertung neuer Technologien zu reduzieren (Cvetkovich & Earle, 1995). Anstelle ihrer eigenen Bewertung vertrauen die Menschen Institutionen, dass diese neue Technologien richtig bewerten und anwenden.

Mit der Abwägung, ob wir durch ein bestimmtes Verhalten, wie die Nutzung einer neuen Technologie, ein bestimmtes Risiko in Kauf nehmen, beschäftigen wir uns bewusst und unbewusst täglich. Beispielsweise wenn wir abwägen, ob es gerade sicher ist die Straße zu überqueren (Adams, 1995). Die Spanne der Risiken, die wir jeden Tag gegeneinander abwägen, ist groß und wird durch vorab oft unklare Belohnungen und Verlusten erschwert. Die Entscheidung für oder gegen das Eingehen eines Risikos findet aufgrund der Menge der täglich zu treffenden Entscheidungen oft unbewusst statt um die kognitive Belastung zu verringern. Abbildung 10 zeigt ein Modell dieses teilweise unbewussten Abwägungsverhaltens. Das Modell ist auch als Risiko Thermostat bekannt.

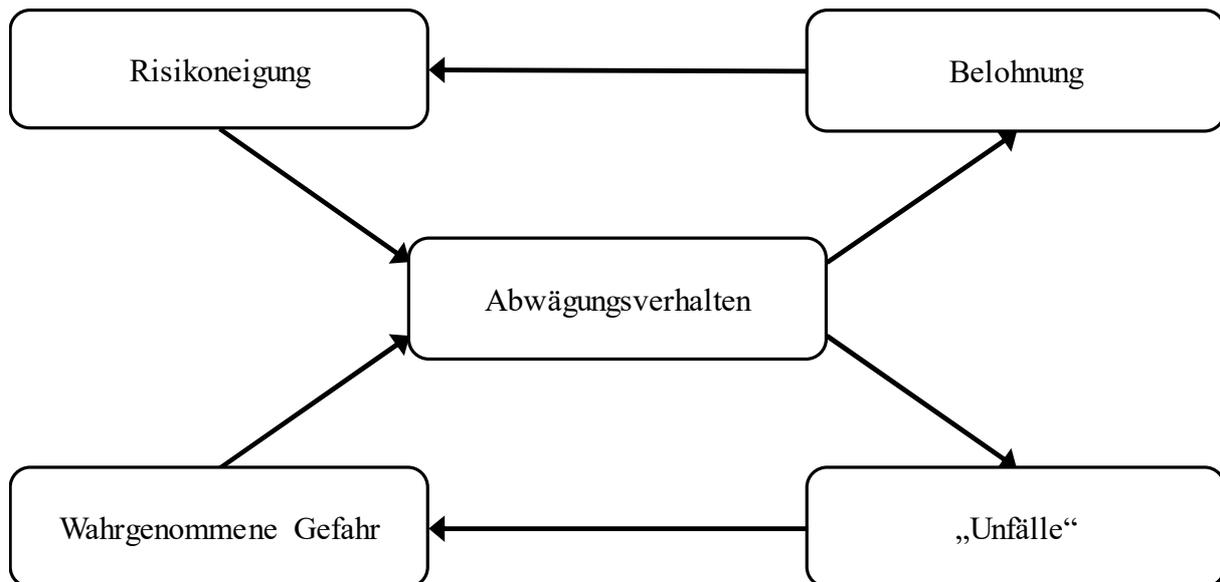


Abbildung 10: Risiko Thermostat

Quelle: In Anlehnung an Adams (1999, S. 9)

Für das *Abwägungsverhalten* wird die *Risikoneigung* und die *wahrgenommene Gefahr* durch das geplante Verhalten berücksichtigt (Adams, 1995). Anhand dieser Faktoren wird abgewogen, ob das Risiko eingegangen werden soll. Kommt es zu einem *Unfall*, so wird die wahrgenommene Gefahr durch das Verhalten erhöht. Ist das Risiko nicht eingetreten, so kommt es zu einer *Belohnung*, die die Risikoneigung steigert. Die Konsequenzen in Form von Verlusten oder Belohnungen reichen von vernachlässigbar bis katastrophal und fließen in die Anpassung der Risikoneigung und der wahrgenommenen Gefahr ein.

Da wir täglich zahlreiche risikobehaftete Entscheidungen treffen, befinden sich Risikoneigung und die Wahrnehmung von Gefahren in einer ständigen Anpassung, ähnlich einem Thermostat. Das Risiko Thermostat zeigt, dass die Risikowahrnehmung nicht nur auf die Untersuchung von Großtechnologien wie Atomkraft beschränkt ist, sondern auch bei alltäglichen Aktivitäten eine wichtige Rolle spielt. Dabei ist das Risiko, das von einem technischen System ausgeht, zu einem wichtigen Orientierungsfaktor für individuelles und gesellschaftliches Verhalten geworden (Jungermann & Slovic, 1993). Es ist eine zunehmende Skepsis gegenüber fortschrittlichen Technologien erkennbar, deren Risiken nur bedingt beherrschbar sind.

2.4.2 Risikowahrnehmung

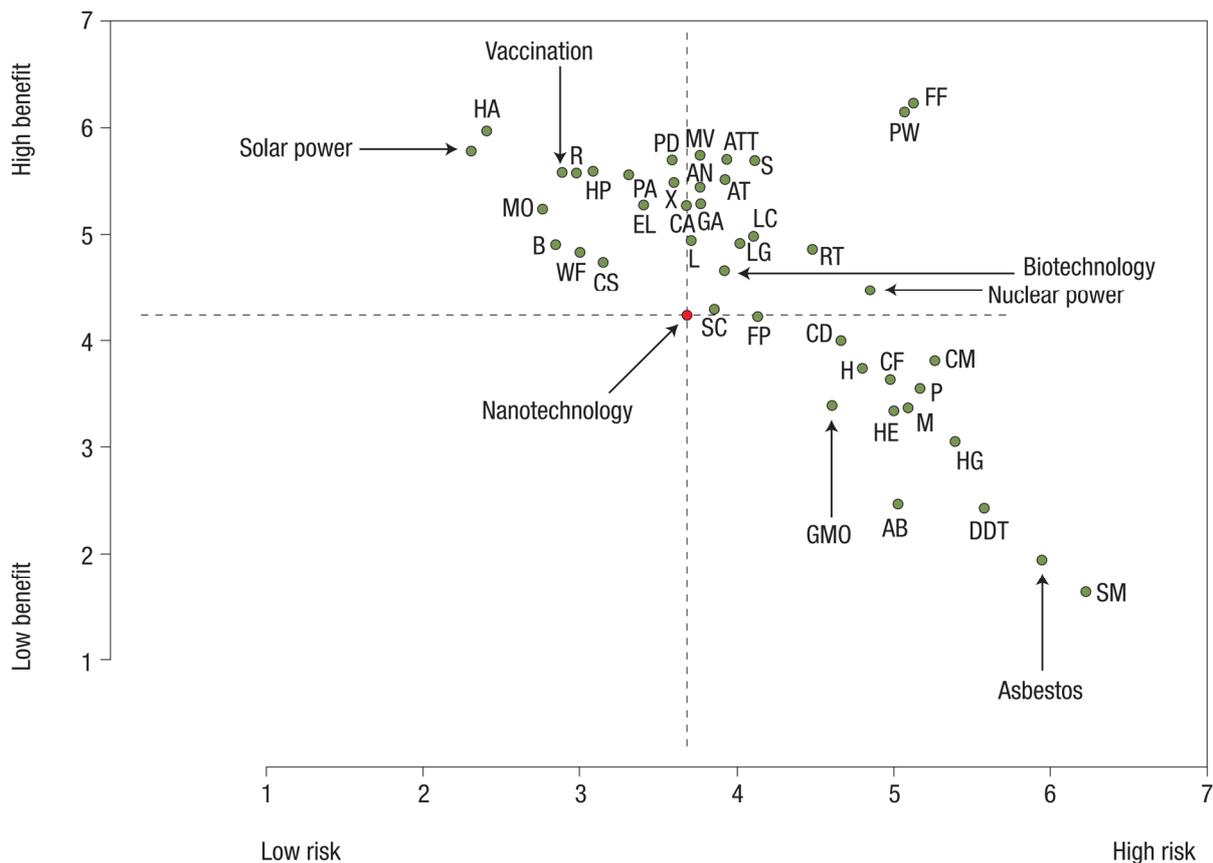
Die Wahrnehmung von Risiken neuer Technologien durch Individuen kann erheblich von dem von Experten ermittelten objektiven Risiko abweichen. Slovic (1987) beschreibt die Wahrnehmung von Risiken, die mit neuen Technologien verbunden sind. Neue Technologien sind für die meisten Menschen zuerst ungewohnt und unverständlich. Individuen verlassen sich auf intuitive Urteile, die auf Medienberichten und eher selten auf der Einschätzung von Experten basieren, um die Risiken für sich zu bewerten (Jungermann & Slovic, 1993). Diese Urteile sind anfällig für Verzerrungen, die durch Heuristiken hervorgerufen werden und häufig zu nicht-optimalen oder nicht-rationalen Entscheidungen führen. Wie im vorherigen Abschnitt erläutert, sind diese Heuristiken aber notwendig aufgrund der Fülle von Entscheidungen, die

wir täglich treffen müssen. Die Prospect Theory beschreibt einige dieser Heuristiken (Kahneman & Tversky, 1979).

Das Risiko Thermostat und die Heuristiken, die in der Prospect Theory beschrieben werden, beeinflussen unsere Entscheidungen unterbewusst und sind tief in uns verankert. Selbst die Kenntnis dieser Mechanismen verhindert eine Beeinflussung nicht. Sie lassen sich also nicht einfach abstellen, um dadurch eine objektivere Einschätzung eines Risikos zu erhalten. Zusätzlich sind die Wahrnehmung von Risiko und Nutzen konfundiert (Alhakami & Slovic, 1994). Das bedeutet, dass bei der Bewertung einer Technologie hohe Nutzenwahrnehmung zu einer geringeren Risikowahrnehmung und hohe Risikowahrnehmung zu einer geringeren Nutzenwahrnehmung führt. Aus diesen Gründen können wir nicht erwarten, dass Menschen rationale Entscheidungen auf der Grundlage von Fakten treffen, sondern ihre Wahrnehmungen die Grundlage ihres Verhaltens darstellen.

Die Verwendung des Risikobegriffs in Technik und Wissenschaft unterscheidet sich üblicherweise von der alltäglichen Verwendung des Begriffs und ist auch in diesen Bereichen unterschiedlich definiert (Jungermann & Slovic, 1993). Häufig wird Risiko als das Produkt von Wahrscheinlichkeit und Schadenshöhe definiert. Dies entspricht aber nicht der subjektiven Bewertung von Laien, sogar wenn diesen die Wahrscheinlichkeit und Schadenshöhe eines Risikos ungefähr bekannt ist.

Eine Studie mit 503 zufällig ausgewählten Individuen in den USA vergleicht Risiko- und Nutzenwahrnehmung von aktuellen Technologien (Currall et al., 2006). Abbildung 11 zeigt einen Überblick über die Ergebnisse der Studie. Das Autofahren ist in der Abbildung als ATT gekennzeichnet und wird mit einem Risiko von 4 eingeschätzt bei 7 möglichen Punkten und wird somit ähnlich hoch bewertet, wie die mit AT bezeichneten Flugreisen. Betrachtet man die Unfallszahlen, so zeigt sich ein deutlicher Unterschied: Im Jahr 2016 gab es alleine in Deutschland 3.206 Verkehrstote (Statistisches Bundesamt, 2018), wohingegen es 2016 weltweit nur 182 Tote durch Flugzeugunfälle gab (International Civil Aviation Organization, 2018). Das wird einem Individuum aber nicht wesentlich dabei helfen, eine Flugangst zu überwinden. Wenn dieses Individuum mit Flugangst bereitwillig am öffentlichen Straßenverkehr teilnimmt, muss die Bewertung des Risikos bei einem Flugzeugabsturz zu verunglücken folglich auf anderen Faktoren beruhen.



Erklärung der Akronyme: alkoholische Getränke (AB), Anästhetika (AN), Flugreisen (AT), Autofahren (ATT), Fahrräder (B), kommerzielle Luftfahrt (CA), chemische Desinfektionsmittel (CD), chemische Düngemittel (CF), Chemieanlagen (CM), Computerbildschirme (CS), Dichlordiphenyltrichlorethan (DDT), elektrische Energie (EL), Feuerbekämpfung (FF), Lebensmittelkonservierungsmittel (FP), Allgemeine Luftfahrt (GA), Herbizide (H), Haushaltsgeräte (HA), Human-Gentechnik (HE), Pistolen (HG), Wasserkraftwerke (HP), Laser (L), große Bauprojekte (LC), flüssiges Erdgas (LG), Motorräder (M), Mikrowellengeräte (MO), Kraftfahrzeuge (MV), Pestizide (P), verschreibungspflichtige Antibiotika (PA), verschreibungspflichtige Medikamente (PD), Polizeiarbeit (PW), Eisenbahn (R), Strahlentherapie (RT), Chirurgie (S), Stammzellforschung (SC), Rauchen (SM), Wasserfluoridierung (WF), Röntgenstrahlen (X)

Abbildung 11: Risiko- und Nutzenwahrnehmung von Technologien

Quelle: Currall et al. (2006, S. 154)

Es wurde gezeigt, dass Individuen Risiken anhand von drei Faktoren bewerten: Der Schrecklichkeit der Gefahr, der Unbekanntheit der Gefahrenquelle und der Anzahl der exponierten Individuen (Jungermann & Slovic, 1993). Aufgrund dieser Faktoren lässt sich die Bewertung der Risiken in Abbildung 11 besser nachvollziehen als mit reinen Unfallstatistiken. Die Abbildung 12 zeigt die Faktoren zur individuellen Risikobewertung und deren Charakteristika.

Die *Schrecklichkeit* der Gefahr, im Englischen als „dread risk“ bekannt, umfasst Gefahrenquellen, die als unkontrollierbar, furchtbar und tödlich wahrgenommen werden (Jungermann & Slovic, 1993). Die Verteilung der Gefahren und der Vorteile wird als ungleichmäßig empfunden, insofern dass die gefährdeten Individuen nicht unmittelbar von den Vorteilen profitieren. Weiterhin besteht bei schrecklichen Risiken die Möglichkeit, dass viele Menschen auf einmal betroffen sind, da dies als schlimmer empfunden wird, als wenn durch viele Einzelereignisse jeweils einzelne Individuen betroffen sind. Dies ist ein Grund, warum

die vielen Verkehrstoten im Straßenverkehr als weniger schlimm wahrgenommen werden als wenn durch einen Flugzeugabsturz viele Menschen auf einmal verunglücken. Beispiele für als schrecklich bewertete Gefahrenquellen sind Krieg, Atomreaktorunfälle und Nervengasunfälle. Sogenannte nicht-schreckliche Risiken hingegen umfassen Risiken, die als kontrollierbare, nicht-furchtbare und nicht-tödliche Risiken wahrgenommen werden und deren Gefahren und Vorteile als gleichmäßig verteilt betrachtet werden. Diese betreffen nur einzelne Individuen. Beispiele hierfür sind Medikamenteneinnahme, Haushaltsgeräte oder Kaffeekonsum.

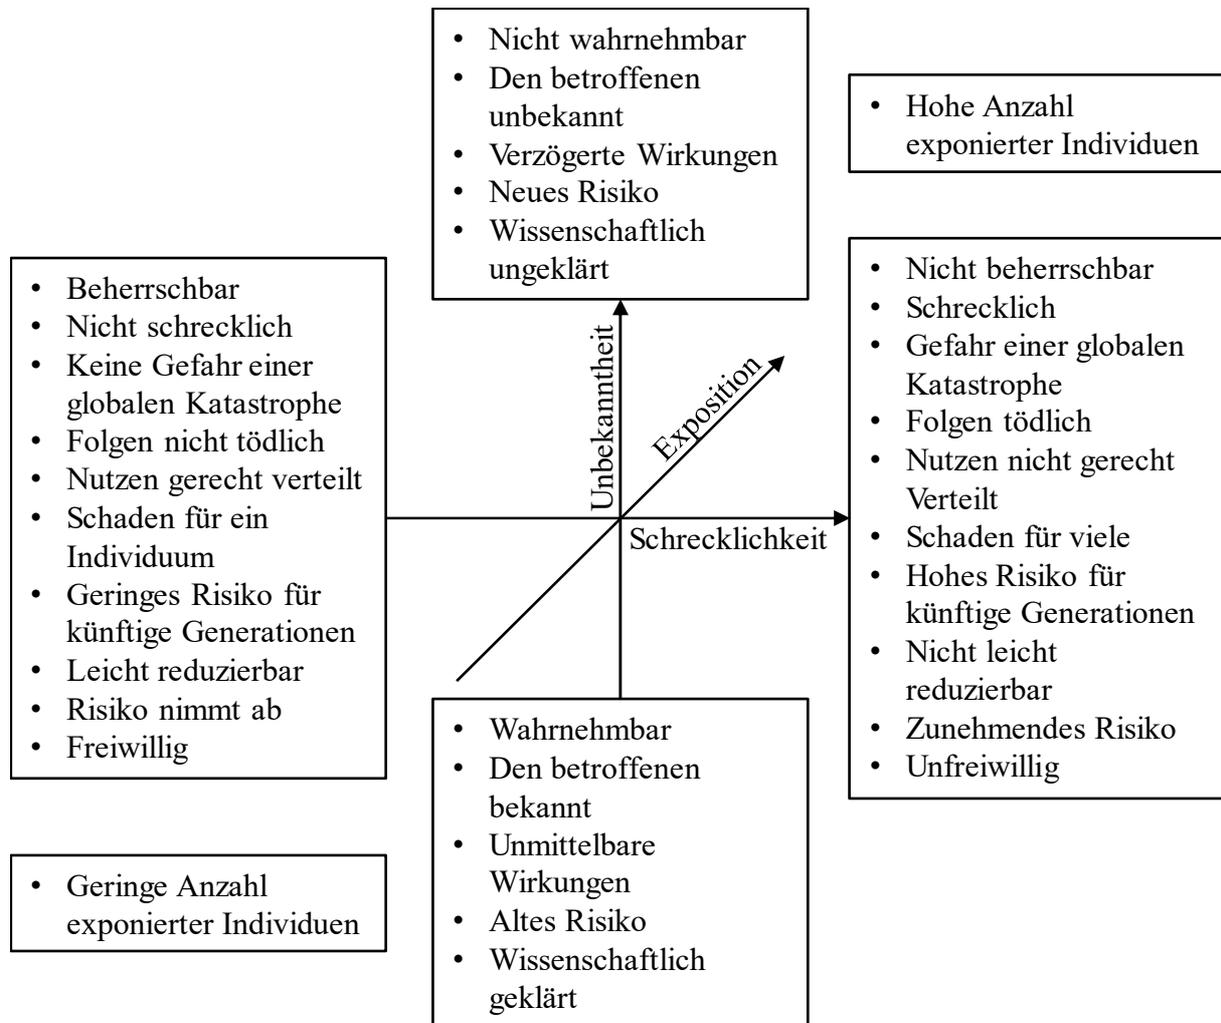


Abbildung 12: Faktoren zur individuellen Risikobewertung und deren Charakteristika

Quelle: In Anlehnung an Jungermann & Slovic (1993, S. 174)

Die *Unbekanntheit* der Gefahr, im Englischen als „unknown risk“ bekannt, umfasst Gefahrenquellen, die als nicht wahrnehmbar, unbekannt und neuartig bewertet werden (Jungermann & Slovic, 1993). Auch Gefahrenquellen, deren Wirkung erst stark verzögert auftreten, werden als unbekannt bewertet. Unbekannte Risiken sind beispielsweise Gentechnik, chemische Düngemittel oder Rauchen. Als bekannt gelten die Risiken eines Autounfalls, Fallschirmspringen oder Feuerwerk.

Der dritte Faktor zur Bewertung von Risiken ist die *Anzahl der Individuen*, die einer Gefahrenquelle *exponiert* sind, im Englischen als „exposure“ bezeichnet (Jungermann &

Slovic, 1993). Die Kernenergie wird als Technologie mit möglichen Auswirkungen für viele Individuen betrachtet wohingegen Tiefseetauchen nur als Risiko für ein Individuum betrachtet wird.

Von den drei Faktoren wird die Risikowahrnehmung am stärksten von der Schrecklichkeit der Gefahr beeinflusst (Jungermann & Slovic, 1993). Eine Technologie ist jedoch selten nur mit einem Risiko verbunden, sondern mit mehreren Verhaltensmöglichkeiten, dessen Folgen Schaden oder Verlust sowie Nutzen oder Gewinn sein können. Aus der bereits beschriebenen Abwägung zwischen den positiven und negativen Folgen des Verhaltens folgt die Entscheidung für oder gegen das geplante Verhalten.

2.4.3 Widerstand gegen Technologie

Neben der Akzeptanz ist auch der Widerstand ein wichtiger Aspekt, der den Erfolg einer Technologie maßgeblich beeinflussen kann. Widerstand ist definiert als eine Verhaltensreaktion zum Ausdruck von Vorbehalten gegenüber dem Druck von Individuen, die eine Veränderung des Status Quo herbeiführen möchten (van Offenbeek, Boonstra & Seo, 2012). Dabei ist Widerstand nicht einfach das Gegenteil von Akzeptanz, sondern als eigenständige Reaktion auf eine Technologie zu betrachten. Abbildung 13 zeigt eine zwei-Faktoren Betrachtung von Akzeptanz und Widerstand. Es ist also sinnvoll bei der Nutzung einer Technologie zu unterscheiden, ob beispielsweise nur eine geringe Nutzung stattfindet oder ob zusätzlich auch Widerstand gegen die Technologienutzung geleistet wird.

Das Spektrum von Widerstand reicht von enthusiastischer Unterstützung bis hin zu aggressivem Widerstand (van Offenbeek et al., 2012). Unterstützendes Verhalten kann beispielsweise in Form von aktiver Teilnahme in einem Umsetzungsteam, das Propagieren der Veränderung bei Kollegen oder die Umstellung der eigenen Arbeitsroutinen, um andere bei der Umstellung zu unterstützen, erfolgen. Beispiele für Widerstandsverhalten sind Gleichgültigkeit, Beschwerden, erhöhte Fehlzeiten, Meinungsverschiedenheiten, vorsätzliche Fehler oder Sabotage.

Die Gründe für Widerstandsverhalten sind vielfältig. Eine häufige Ursache für Widerstand ist eine Veränderung des Gleichgewichts aus Vorteilen und Nachteilen eines Individuums hin zu weniger Vorteilen oder mehr Nachteilen. Auch bei einer Ungleichverteilung der Vorteile und Nachteile aufgrund einer Veränderung des Status Quo kann Widerstand auslösen. Ausgangspunkt ist eine Diskrepanz zwischen den Veränderungen durch eine neue Technologie und den Interessen der Nutzer wie beispielsweise deren sozialer Status (Joshi, 1991; Marakas & Hornik, 1996; Markus, 1983; Martinko, Zmud & Henry, 1996). Der Grad des Widerstandes ist dabei beeinflusst von der wahrgenommenen Wichtigkeit des Systems (Markus, 1983), den persönlichen Eigenschaften der Nutzer (Marakas & Hornik, 1996) und vorherige Erfahrungen mit dem neuen System (Martinko et al., 1996).

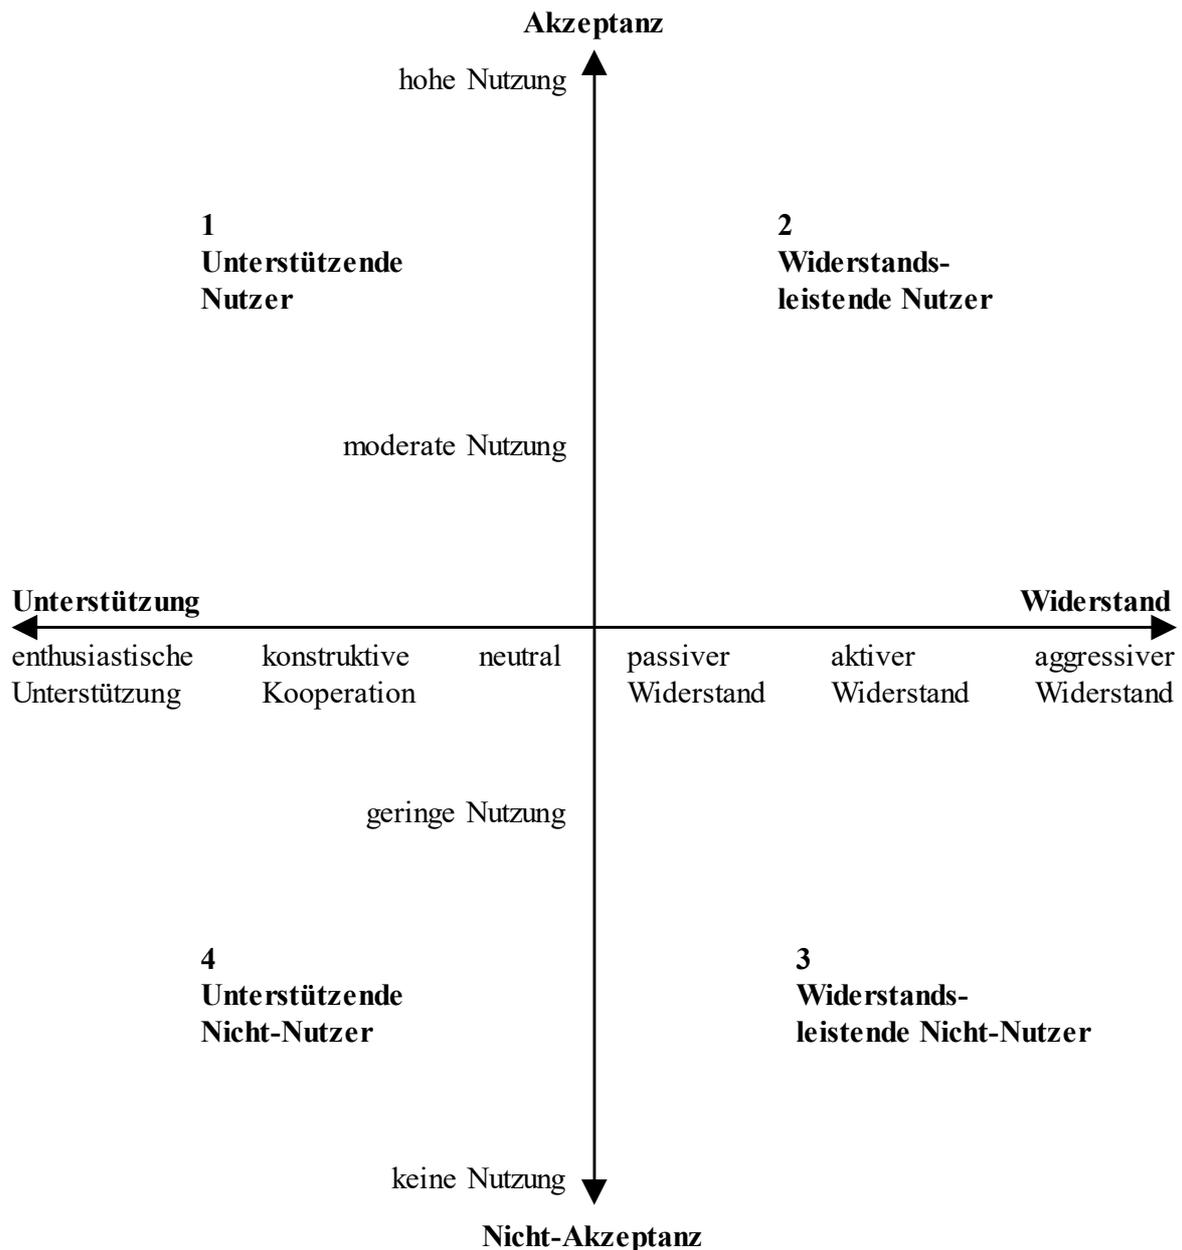


Abbildung 13: Nutzer und Nutzung im Kontext von Akzeptanz und Widerstand

Quelle: In Anlehnung an van Offenbeek, Boonstra, & Seo (2012, S. 438)

Schlussfolgerungen für die Akzeptanz autonomer Fahrzeuge

Um Widerstandsverhalten zu untersuchen ist es sinnvoll, dieses aus den folgenden drei Perspektiven zu untersuchen: *Nutzerperspektive*, *Systemperspektive* und *Interaktionsperspektive* (Kling, 1980). Aus *Nutzerperspektive* können sich Vorbehalte gegenüber der Einführung von neuen Systemen bilden, wenn die bestehenden Systeme bereits über einen langen Zeitraum genutzt wurden. Übertragen auf autonome Fahrzeuge kann dies zu Widerstandsverhalten vor allem bei langjährigen Autofahrern führen, da keine Notwendigkeit für autonome Fahrzeuge gesehen wird.

Die *Systemperspektive* bezieht sich auf die objektiven Eigenschaften des Systems. Ist das neue System also objektiv schlechter als das alte System, kann mit Widerstand bei der Einführung gerechnet werden. Autonome Fahrzeuge sollten daher sicherer oder komfortabler sein als nicht-autonome Fahrzeuge. Hierfür empfiehlt es sich, potentielle Nutzer in die Entwicklung mit einzubeziehen (Ives & Olson, 1984).

Unter der *Interaktionsperspektive* versteht man Widerstand, der aufgrund der Interaktion mit dem neuen System hervorgeht. Fühlen sich Nutzer bevormundet durch ein neues System, kann dies zu Widerständen führen (Lapointe & Rivard, 2005). Bei autonomen Fahrzeugen gibt es Konzepte, bei denen kein Lenkrad mehr vorhanden ist wie beispielsweise beim Google Car (Fraedrich, Beiker & Lenz, 2015). Der daraus resultierende Kontrollverlust könnte zu Widerständen führen. Aus dieser Perspektive sollten die Nutzer autonomer Fahrzeuge zumindest anfänglich die Möglichkeit haben, selbst zu fahren, wenn sie dies möchten und sie dazu in der Lage sind.

Widerstand wurde auch im Kontext von Innovationen untersucht (Ram, 1989). Dabei wurde festgestellt, dass der Widerstand mit den Veränderungen wächst, die durch die Innovation verursacht werden. Handelt es sich bei einer Innovation um kleinere Veränderungen eines bestehenden Produktes, so ist mit keinem großen Widerstand zu rechnen. Man spricht in diesem Zusammenhang auch von Evolution. Handelt es sich jedoch um eine revolutionäre Innovation, sind große Veränderungen zu erwarten und somit auch ein großer Widerstand der potenziellen Nutzer. Aus diesem Grund wird in diesem Zusammenhang auch vom Widerstand gegen Veränderung gesprochen (Cornescu & Adam, 2013). Vor diesem Gesichtspunkt erscheint eine graduelle Einführung von autonomen Fahrzeugen sinnvoll. Anstatt große Veränderungen durch die direkte Einführung autonomer Fahrzeuge zu erzeugen, sollte der Automatisierungsgrad schrittweise erhöht werden, damit sich die Nutzer schrittweise an Fahrzeugautomatisierungssysteme gewöhnen können.

Ein weiterer großer Einflussfaktor für Widerstandsverhalten ist die Risikowahrnehmung der Innovation (Gatignon & Robertson, 1989; Ram, 1989). Diese kann mittels gezielter Kommunikationsstrategien adressiert werden. Traditionell werden Massenmedien oder Einzelgespräche eingesetzt um einer übersteigerten Risikowahrnehmung entgegenzuwirken (Ram, 1989). In diesem Kontext werden jedoch soziale Medien immer wichtiger (Mou & Lin, 2014). Um Widerstände gegen die Einführung autonomer Fahrzeuge zu verhindern, ist die Kombination verschiedener Medien, von Massenmedien, über soziale Medien bis hin zu Einzelgesprächen, im Rahmen einer kohärenten Kommunikationsstrategie zu empfehlen.

2.4.4 Schlussfolgerungen

Für die Prognose der Akzeptanz von autonomen Fahrzeugen lassen sich aus diesem Abschnitt einige theoretische Schlussfolgerungen ableiten. Am Anfang der Untersuchung der gesellschaftlichen Akzeptanz ist es zunächst notwendig, die Risiken und Nutzenpotentiale autonomer Fahrzeuge zu ermitteln. Diese sollten anschließend bezüglich der subjektiv wahrgenommenen Vor- und Nachteile bewertet werden. Die subjektive Bewertung wird üblicherweise nicht mit der objektiven Bewertung von Experten übereinstimmen, auch wenn eindeutige Fakten vorliegen.

Im Gegensatz zu herkömmlichen Fahrzeugen könnten Unfälle mit autonomen Fahrzeugen nicht als einzelne, sondern als systematische Fehler betrachtet werden. Unfälle mit autonomen Fahrzeugen werden somit gesammelt betrachtet, was die wahrgenommene Schrecklichkeit dieser Unfälle erhöhen könnte. Hinzu kommt, dass das Risiko von Unfällen als weniger beherrschbar wahrgenommen werden könnte, da die Fahrzeuginsassen nur noch begrenzte Einflussmöglichkeiten haben. Kommt es wie im Abschnitt 2.3 beschrieben zu einer vorgeschriebenen Nutzung autonomer Fahrzeuge, so könnte sich diese aufgrund der unfreiwilligen Exposition ebenfalls auf die empfundene Schrecklichkeit der Technologie auswirken (Jungermann & Slovic, 1993).

Diesen Effekten gegenüber steht das Risiko Thermostat, das nach der Einführung autonomer Fahrzeuge zum Zuge kommt. Durch regelmäßigen Kontakt mit diesen Fahrzeugen und deren Vorteile steigt die Bereitschaft die Risiken bei der Nutzung einzugehen, solange es nicht zu einer großen Anzahl oder schwerwiegenden Unfällen mit einer hohen Anzahl an Betroffenen kommt. Es genügt in diesem Fall von dem Unfall zu erfahren, man muss also nicht selbst beteiligt gewesen sein. Bereits heutige Unfälle, bei denen fortschrittliche Fahrerassistenzsysteme beteiligt sind, erreichen eine hohe Sichtbarkeit durch die Medien (z. B. Vlastic & Boudette, 2016) und wirken sich potenziell negativ auf die Risikowahrnehmung und somit auf die Akzeptanz autonomer Fahrzeuge aus.

Unterstützend für die Akzeptanz autonomer Fahrzeuge könnten sich beispielsweise vertrauenswürdige Institutionen auswirken, die sich für die Nutzung autonomer Fahrzeuge aussprechen (Choi & Ji, 2015). In Frage dafür kommen Interessensgruppen und Vereine wie der Allgemeine Deutsche Automobil-Club (ADAC), Regulierungsbehörden und die Gesetzgebung. Auch unabhängige Tests zur Sicherheit autonomer Fahrzeuge könnten die Akzeptanz erhöhen. Zunehmend wichtiger werden in diesem Zusammenhang auch soziale Medien, die mit positiven Erfahrungs- und Testberichten in der Phase der Einführung die Akzeptanz fördern können (van Offenbeek et al., 2012).

Die öffentliche Meinung zu autonomen Fahrzeugen wurde bereits durch einige Studien erhoben. Eine 2014 durchgeführte Umfrage zu autonomen Fahrzeugen in den USA, Großbritannien und Australien mit 1.533 Befragten zeigt, dass 56 % der Befragten eine positive Einstellung zu diesen haben, während 13,8 % negative Bedenken äußern und 29,4 % neutral dazu eingestellt sind (Schoettle & Sivak, 2014). Die Consumer Technology Association (CTA) gab an, dass 70 % der Fahrer in den USA Interesse an der Erprobung eines autonomen Fahrzeuges bekundeten und mehr als 60 % der befragten Fahrer bereit waren, ihre Fahrzeuge durch ein autonomes Fahrzeug zu ersetzen (Markwalter, 2015). Eine Studie unter 421 französischen Autofahrern ergab, dass 68,1 % bereit wären, autonome Fahrzeuge zu benutzen (Payre et al., 2014).

Befürworter argumentieren, dass 93 % der Autounfälle auf Fahrfehler zurückzuführen sind (Treat et al., 1977), wodurch der Einsatz von autonomen Fahrzeugen die Zahl der Autounfälle somit um 93 % reduzieren könnte (Fagnant & Kockelman, 2015; Markwalter, 2015). Gegner dieser Auffassung behaupten jedoch, dass autonome Fahrzeuge neue und bisher unbekannte Risiken wie Systemausfälle oder Kompensationsverhalten mit sich bringen könnten. Einige

Studien kamen daher zu dem Schluss, dass autonome Fahrzeuge nicht sicherer sein werden als ein durchschnittlicher Fahrer und dass sie zu einer Zunahme der Gesamtunfälle führen könnten, wenn gleichzeitig autonome und menschengeführte Fahrzeuge eingesetzt würden (Schoettle & Sivak, 2014).

Die bisherigen Studien zeigen, dass die gesellschaftliche Akzeptanz unterschiedlich bewertet wird und auf Basis dieser Datenlage keine klare Prognose zur Akzeptanz autonomer Fahrzeuge getroffen werden kann. Die öffentliche Wahrnehmung von Risiken und Nutzen autonomer Fahrzeuge scheint verzerrt zu sein und sich regional und auch im Laufe der Zeit zu ändern. Daher sind eine systematische Identifikation und Bewertung der bekannten Risiken und Nutzen autonomer Fahrzeuge erforderlich. Weiterhin sollten auch bisher unbekannte Risiken und Nutzen autonomer Fahrzeuge identifiziert werden, damit die Risiken adressiert und neue Nutzenpotentiale in der Entwicklung berücksichtigt werden können. Zuletzt wäre auch eine zeitliche Betrachtung der Risiko- und Nutzenwahrnehmung hilfreich, um akzeptanzrelevante Ereignisse zu identifizieren und deren Auswirkungen auf die Akzeptanz messen zu können.

3 Stand der Technik

In diesem Kapitel wird der Stand der Technik zum autonomen Fahren erläutert. Es werden zunächst die Anfänge der Fahrzeugautomatisierung beschrieben. Anschließend werden die Stufen der Fahrzeugautomatisierung vorgestellt, die eine Abgrenzung des Untersuchungsgegenstandes erst ermöglichen. Es folgt ein Überblick der aktuell im Jahr 2019 verfügbaren Fahrerassistenzsysteme, die die Vorstufe zu autonomen Fahrzeugen darstellen. Für die Realisierung autonomen Fahrens müssen auch Anforderungen an die Infrastruktur und Vernetzung berücksichtigt werden, die wir im darauffolgenden Abschnitt erläutern. Im vorletzten Abschnitt dieses Kapitels beschreiben wir einen Entwicklungspfad von fortschrittlichen Fahrerassistenzsystemen hin zum autonomen Fahren. Das Kapitel endet mit einer Zusammenfassung und einem Fazit.

3.1 Anfänge der Fahrzeugautomatisierung

Ein Überblick über die Entwicklungsgeschichte der Fahrzeugautomatisierung seit 1950 geben Matthaei et al. (2015, S. 1140–1142). Da im Jahr 1950 die Rechenleistung von Computern und Bildverarbeitungsmöglichkeiten noch sehr eingeschränkt waren, konzentrierte man sich bei der Entwicklung des autonomen Fahrens auf Infrastrukturmaßnahmen wie beispielsweise Magnete in der Fahrbahn (Fenton, 1970). In den 1970er und 1980er Jahren konnten erste Erfolge mit bildgebenden Verfahren in Japan erzielt werden und Infrastrukturansätze wurden weiterverfolgt (Tsugawa, 1994). Bereits in den 1990er Jahren durchquerte der Versuchsträger NavLab 5 der California Partners for Advanced Transit and Highways (PATH) die USA, der 4.500 von den 4.587 gefahrenen km auf Highways ohne Fahrereingriff zurücklegen konnte (Pomerleau & Jochem, 1996).

Ein weiterer Meilenstein bei der Entwicklung des autonomen Fahrens war die Fahrt des Versuchsträgers VaMoRs-P im Jahr 1995 von München nach Odense mit 1.758 km von denen 1.678 km ohne Fahrereingriff zurückgelegt wurden (Maurer, 2000). Diese Fahrt fand im Rahmen des von der Europäischen Union geförderten Projektes PROMETHEUS (Programme for a European Traffic System With Highest Efficiency and Unprecedented Safety) statt, das zwischen 1987 und 1994 zu großen Fortschritten auf dem Gebiet des autonomen Fahrens geführt hat (Maurer, 2000). Bei diesen Fahrten war stets ein Sicherheitsfahrer für die Überwachung des Systems im Fahrzeug. Erstmals bei der DARPA (Defense Advanced Research Projects Agency) Grand Challenge im Jahr 2005 durchquerten mehrere fahrerlose Fahrzeuge eine 229 km lange Strecke durch die Wüste Nevadas, nachdem im Vorjahr kein einziges Fahrzeug das Ziel erreichte (Thrun et al., 2006). Die erfolgreichen DARPA Wettbewerbe wurden 2007 im Rahmen der Urban Challenge fortgeführt, bei der sich fahrerlose Fahrzeuge im mit Stuntfahrern simulierten Stadtverkehr bewegen mussten (Rouff, 2007).

3.2 Stufen der Fahrzeugautomatisierung

Die Entwicklungsgeschichte der Fahrzeugautomatisierung im vorherigen Abschnitt zeigt, dass beim Begriff des autonomen Fahrens zwischen verschiedenen Stufen der Automatisierung unterschieden werden muss. Während in den Projekten in den 1990er Jahren mit Sicherheitsfahrern gearbeitet wurde, die permanent das Fahrgeschehen beobachten mussten, wurden die zuletzt beschriebenen DARPA Wettbewerbe fahrerlos durchgeführt. Zur klaren Abgrenzung der verschiedenen Ansätze wurden Automatisierungsstufen definiert, die beispielsweise auch für die Klärung von juristischen Rahmenbedingungen von großer Bedeutung sind (Gasser et al., 2015). Die Bundesanstalt für Straßenwesen (BASt) und die zivile US-Bundesbehörde für Straßen- und Fahrzeugsicherheit (NHTSA) beschreiben fünf Automatisierungsstufen (Gasser et al., 2015; NHTSA, 2013).

Eine weitere Automatisierungsstufe definiert der Verband der Automobilingenieure (SAE) (SAE International, 2018). Die SAE Definition umfasst dabei alle Automatisierungsstufen von BASt und NHTSA und ist somit die detaillierteste und umfangreichste der drei Definitionen. Daher beziehen wir uns im weiteren Verlauf dieser Dissertation auf die Stufendefinition der SAE. Tabelle 1 zeigt die Definitionen von SAE, BASt, und NHTSA im Vergleich. Die Stufen der Fahrzeugautomatisierung reichen von Stufe 0, bei der der Fahrer Längs- und Querführung des Fahrzeuges während der gesamten Fahrt ausführt, bis Stufe 5, bei der das Fahrzeug alle Aspekte der Fahraufgabe übernimmt.

Neben den technischen Aspekten gibt es einen entscheidenden Unterschied zwischen den niedrigeren Stufen bis Stufe 2 und den folgenden Stufen. Ab Stufe 3 ist nicht mehr der Fahrer jederzeit für die Fahraufgabe verantwortlich, sondern nur noch teilweise in den Stufen 3 und 4. In Stufe 5 Fahrzeugen gibt es keinen menschlichen Fahrer mehr, sondern nur noch Passagiere. Folglich müsste bei Unfällen während eines automatisiert zurückgelegten Fahrabschnitts innerhalb der Systemgrenzen der Hersteller des Systems haften.

Aufgrund dieses Unterschieds zwischen den Stufen 0 bis 2 und den Stufen 3 bis 5 gibt es unterschiedliche Ansichten, wie Stufe 5 erreicht werden kann. Ein Ansatz geht davon aus, dass sich Fahrerassistenzsysteme evolutionär weiterentwickeln und verschmelzen, wie in Abschnitt 3.5 beschrieben. Ein anderer Ansatz geht hingegen von einer sprunghaften Entwicklung des autonomen Fahrens aus, sobald Stufe 3 erreicht wurde. Daher arbeitet Google beispielsweise direkt an einem Stufe 5 Fahrzeug und überspringt die Zwischenstufen 3 und 4. Im Folgenden erläutern wir die im Jahr 2019 verfügbaren Fahrerassistenzsysteme, um eine Einschätzung des aktuellen Standes der Technik zu ermöglichen. Die Fahrerassistenzsysteme zeigen auch die Schwierigkeiten der Fahraufgabe auf, die einem womöglich bei der alltäglichen Autofahrt gar nicht mehr bewusst sind.

SAE Stufe¹	BASSt Stufe²	NHTSA Stufe³	Definition
0: No Automation	Driver only	0: No Automation	Fahrer führt dauerhaft (während der gesamten Fahrt) die Längsführung (Beschleunigen / Verzögern) und die Quersführung (lenken) aus. ²
1: Driver Assistance	Assistiert	1: Function-specific Automation	Fahrer führt dauerhaft entweder die Quer- oder die Längsführung aus. Die jeweils andere Fahraufgabe wird in gewissen Grenzen vom System ausgeführt. ²
2: Partial Automation	Teil-automatisiert	2: Combined Function Automation	Das System übernimmt Quer- und Längsführung (für einen gewissen Zeitraum oder / und in spezifischen Situationen). Der Fahrer muss das System dauerhaft überwachen. ²
3: Conditional Automation	Hoch-automatisiert	3: Limited Self-Driving Automation	Das System übernimmt Quer- und Längsführung für einen gewissen Zeitraum in spezifischen Situationen. Der Fahrer muss das System dabei nicht überwachen aber muss bei Bedarf die Fahraufgabe in angemessener Zeit wieder übernehmen können. ²
4: High Automation	Voll-automatisiert	4: Full Self-Driving Automation	Das System übernimmt Quer- und Längsführung vollständig in einem definierten Anwendungsfall. ²
5: Full Automation	Nicht definiert		Das System übernimmt alle Aspekte der dynamischen Fahraufgabe, die auch ein menschlicher Fahrer bewältigen kann unter allen Straßen- und Umweltbedingungen. ¹

¹ Entspricht der SAE Definition (SAE International, 2018)

² Entspricht der BASSt Definition (Gasser et al., 2015)

³ Entspricht der NHTSA Definition (NHTSA, 2013)

Tabelle 1. Vergleich der Automatisierungsstufen für Fahrzeuge.

Quelle: Eigene Darstellung.

3.3 Fahrerassistenzsysteme

Serienfahrzeuge erfüllen im Jahr 2019, je nach Ausführung, die Stufen 0 bis 2 der Fahrzeugautomatisierung. Ein Fahrzeug mit dem Antiblockiersystem (ABS) erfüllt bereits die Stufe 1 der Automatisierung, da das System die Längsführung bei Bremsvorgängen in gewissen Grenzen übernimmt. Die Fahrzeugautomatisierung wird herstellerspezifisch mit jeweils unterschiedlichen Fahrerassistenzsystemen (FAS) umgesetzt. Neben Eigenentwicklungen wird auch auf Systeme von großen Tier-1 Zulieferern wie Bosch, Continental oder ZF Friedrichshafen zurückgegriffen (Neugebauer, 2018). Während die Stufe 1 der Automatisierung durch ein einzelnes FAS erreicht wird, wird die Stufe 2 der Automatisierung üblicherweise durch eine Kombination von FAS ermöglicht, beispielsweise durch einen Abstandsregeltempomat in Kombination mit einem Spurhalteassistenten. Während der Fahrt auf Stufe 2 überwachen weitere FAS das Fahrzeug und dessen Umfeld. So würde ein Lichtassistent in der Dämmerung automatisch das Abblendlicht einschalten, auch wenn ein anderes System, wie der Abstandsregeltempomat, ebenfalls aktiv ist. Im Jahr 2019 ist noch kein Serienfahrzeug mit einer höheren Automatisierungsstufe als Stufe 2 erhältlich.

Der 2017 von Audi vorgestellte A8 sollte das erste teilautonome Serienfahrzeug der Stufe 3 mit einem hochautomatisierten Stauassistenten werden. Dieser sollte auf Schnellstraßen mit baulicher Trennung zwischen den Richtungsfahrbahnen bei einer Geschwindigkeit bis 60 km/h die Fahrverantwortung temporär übernehmen (Becker, 2019). Der Fahrer muss das System somit in dieser definierten Situation nicht überwachen, bis eine Übergabeaufforderung des Fahrzeugs stattfindet. Somit erfüllt der Stauassistent die Voraussetzungen für SAE Stufe 3. Aufgrund von technischen und rechtlichen Problemen ist der Staupilot allerdings noch nicht erhältlich (Becker, 2019). Im Folgenden werden die zentralen FAS für Stufe 2 Fahrzeuge beschrieben, die Quer- und Längsführung eines Fahrzeugs für einen gewissen Zeitraum oder / und in spezifischen Situationen übernehmen.

Abstandsregeltempomat

Der Abstandsregeltempomat oder auch Adaptive Cruise Control (ACC) bezeichnet eine aktive Geschwindigkeitsregelanlage, die die Fahrzeuggeschwindigkeit an die Verkehrssituation anpasst (Winner & Schopper, 2015). Dabei handelt es sich um eine Erweiterung der Geschwindigkeitsregelanlage, die auch als Tempomat bezeichnet wird. Dazu wird eine Sollgeschwindigkeit eingestellt, die das Fahrzeug so lange versucht zu halten, bis der Abstand zum vorausfahrenden Fahrzeug zu gering wird. ACC reduziert dann die Geschwindigkeit durch Reduktion der Beschleunigung und üblicherweise auch dem Einsatz der Bremse. Wird der Fahrkorridor wieder frei, erhöht ACC die Geschwindigkeit des Fahrzeugs automatisch wieder auf die Sollgeschwindigkeit.

Eine Erweiterung von ACC ist Full-Speed-Range-ACC (FSRA), welches die Geschwindigkeit des Fahrzeugs bis auf 0 km/h reduzieren kann (Winner & Schopper, 2015). Beim herkömmlichen ACC ist eine minimale Regelgeschwindigkeit definiert, beispielsweise 30 km/h. Bei Unterschreiten dieser Mindestgeschwindigkeit deaktiviert sich ACC automatisch. Beim FSRA bleibt die Geschwindigkeitsregelung aktiv und wechselt in einen speziellen Zustand, wenn das Fahrzeug anhält. Das Fahrzeug fährt dann nicht automatisch los, wenn sich

der Abstand zum vorausfahrenden Fahrzeug erhöht, sondern erst wenn der Fahrer das Weiterfahren bestätigt. Eine weitere Ergänzung des Abstandsregeltempomats ist eine automatische Geschwindigkeitserkennung in Form eines Geschwindigkeitsassistenten (Tesla Motors, 2017, S. 108f). Dieser erkennt durch detaillierte Navigationskarten, die Positionserkennung des Fahrzeuges mittels GPS und Verkehrszeichenerkennung die vorgeschriebene Geschwindigkeit. Der Geschwindigkeitsassistent warnt, wenn die zulässige Höchstgeschwindigkeit überschritten wird und kann je nach Umsetzung die Sollgeschwindigkeit des Abstandsregeltempomats auf die erkannte Geschwindigkeit anpassen. Zusätzlich können auch Toleranzen hierfür eingestellt werden.

Notbremsassistent

Der Notbremsassistent ist neben dem Abstandsregeltempomat ein weiteres System zur Unterstützung der Längsführung eines Fahrzeuges (Dörner, Schwertberger & Hipp, 2015). Je nach Ausführung des Systems wird der Fahrer bei akuter Gefahr eines Auffahrunfalles gewarnt, bei einer Bremsung unterstützt oder sogar eine Vollbremsung des Fahrzeuges durchgeführt. Entscheidend für das System ist das korrekte Erkennen von Verkehrssituationen, die eine Notbremsung erfordern. Dies erfolgt mit Hilfe von Sensorik, wie beispielsweise Hochfrequenz-Radarsensoren und Kameras. Nicht jedes Hindernis löst direkt eine Bremsung aus. Zunächst wird der Fahrer üblicherweise optisch und akustisch auf das Hindernis aufmerksam gemacht. Reagiert dieser nicht, erfolgt zunächst eine schwache Bremsung. Erfolgt immer noch keine Reaktion des Fahrers und die Situation verschärft sich, erfolgt schließlich eine Vollbremsung. Dabei wird bei moderneren Systemen auch der Rückwärtige Verkehr berücksichtigt (Reschka, Rieken & Maurer, 2015): Befindet sich dicht hinter dem Fahrzeug ein weiteres Fahrzeug, so wird nicht mit maximaler Bremskraft gebremst.

Spurwarner und Spurhalteassistent

Spurwarner und Spurhalteassistent unterstützen den Fahrer bei der Querführung des Fahrzeuges (Bartels, Rohlf, Hamel, Saust & Klauske, 2015). Der Spurwarner informiert den Fahrer durch ein optisches, akustisches oder haptisches Signal über ein ungewolltes Verlassen der Spur. Der Spurhalteassistent hingegen greift aktiv in die Querführung des Fahrzeuges ein, um die Fahrspur zu halten. Je nach Ausführung können Spurhalteassistenten entweder den Fahrer durch leichte Gegenlenkbewegungen unterstützen, um das ungewollte Verlassen der Spur zu verhindern (Typ 1: Spurrückführung) oder das Fahrzeug durch aktive Querführung in der Fahrstreifenmitte halten (Typ 2: Spurmittenunterstützung). Nach UNECE R-79 darf das System bei Geschwindigkeiten über 12 km/h nur temporär die Querführung übernehmen und der Fahrzeugführer behält die Hauptverantwortung für die Querführung des Fahrzeuges. Nach ISO DIS 11270 ist das System zudem bezüglich Querschleunigungen ($\leq 3 \text{ m/s}^2$) und Querruck ($\leq 5 \text{ m/s}^2$) beschränkt. Durch Betätigung des Blinkers oder einen Lenkeingriff muss der Fahrer stets in der Lage sein, das System zu übersteuern. Dennoch kann der Fahrer weiterhin vor einem Spurwechsel in einer solchen Situation gewarnt werden, wenn beispielsweise die Zielspur durch ein Fahrzeug im Toten Winkel belegt ist.

Der Spurhalteassistent nutzt verschiedene Sensoren zur Fahrbahnerkennung wie beispielsweise eine monokulare Kamera auf der Rückseite des Rückspiegels (Bartels, Rohlf, et al., 2015).

Zumeist werden auch Daten aus verschiedenen Sensoren miteinander kombiniert, um die Spur besser zu erkennen als die Einzelsysteme für sich und um eine Plausibilitätsprüfung durchzuführen. Fehlen beispielsweise in einer Baustelle die Fahrbahnmarkierungen, kann das System auch die Position des vorausfahrenden Fahrzeuges, die Leitplanken oder Fahrzeuge auf angrenzenden Spuren für die Planung der Spurführung verwenden.

Spurwechselwarner und Spurhalteassistent

Ein Spurhalteassistent kann um einen Spurwechselassistenten ergänzt werden. Auch hier gibt es unterschiedliche Varianten. Der Spurwechselwarner ist in der ISO-Norm 17387 beschrieben (Bartels, Meinecke & Steinmeyer, 2015). Dieser warnt vor Fahrzeugen im Toten Winkel sowie vor sich von hinten annähernden Fahrzeugen auf den angrenzenden Spuren. Der Spurwechselwarner wird daher auch als Totwinkelwarner bezeichnet. Üblicherweise ist dazu auf der Innenseite der Außenspiegel oder teilweise auch in den Außenspiegeln selbst eine Indikation dafür vorhanden. Dies hat den Vorteil, dass sich die Indikation nicht im primären Sichtfeld des Fahrers befindet, jedoch aber beim vorgeschriebenen Blick in den Seitenspiegel bei einem Spurwechsel wahrgenommen werden kann. Zeigt der Fahrer die Intention eines Spurwechsels, beispielsweise durch Antippen des Blinkers oder Änderung der Position innerhalb des Fahrstreifens, obwohl die angrenzende Spur belegt ist, können weitere Warnungen und Signale vom Fahrzeug erfolgen. Bei einem aktiven Spurwechselassistenten kann hier auch ein aktiver Lenkeingriff erfolgen. Die Detektion von Fahrzeugen erfolgt üblicherweise mit Nahbereichsradarsensoren oder durch Bilderkennung einer im Rückspiegel verbauten Kamera. Fortschrittlichere Systeme können auch selbstständig einen Spurwechsel durchführen (Tesla Motors, 2017, S. 91–96). Dazu muss der Abstandsregeltempomat aktiviert sein und der Fahrer durch den Blinker die gewünschte Fahrspur signalisieren. Das System erfasst jedoch nur Fahrzeuge in einem begrenzten Umkreis um das Fahrzeug. Dies ist besonders auf deutschen Autobahnen ohne Geschwindigkeitsbegrenzungen und somit möglicherweise sehr hohen Differenzgeschwindigkeiten problematisch. Eine zufriedenstellende Lösung für deutsche Autobahnen wird hier womöglich erst durch die Kommunikation mit anderen Fahrzeugen und Infrastruktur möglich sein, denn die Reichweite der Sensorik eines Fahrzeuges ist begrenzt.

Stauassistent

Der Stauassistent ist in verschiedenen Varianten verfügbar (Lüke, Fochler, Schaller & Regensburger, 2015). Der Stop-and-go-Assistent ist die naheliegende Weiterentwicklung des FSRA. Das Fahrzeug wird bei zu geringem Abstand zum vorausfahrenden Fahrzeug bis zum Stillstand abgebremst. Fährt das vorausfahrende Fahrzeug nun weiter, muss das Weiterfahren durch den Fahrer nicht mehr signalisiert werden, sondern erfolgt automatisch. Die Weiterentwicklung des Stop-and-go-Assistenten ist der Fahrzeugfolge- und Fahrstreifenhalteassistent. Dieser übernimmt in Stausituationen auch die Querführung des Fahrzeuges. Mit Hilfe von Kamera-Bildverarbeitung erkennt das System die Fahrstreifenmarkierungen und mittels eines Radarsystems die Position des vorausfahrenden Fahrzeuges. Mit diesen Daten wird eine Solltrajektorie zur Querführung des Fahrzeuges berechnet und durch eine Querregelung umgesetzt. Oft ist jedoch die Fahrstreifenerkennung

aufgrund des vorausfahrenden Verkehrs oder noch nicht ausreichender Bilderkennungsverfahren bei diesen Systemen im Jahr 2019 noch nicht möglich. Das Fahrzeug würde dadurch bei einem Fahrstreifenwechsel des vorausfahrenden Fahrzeugs ebenfalls den Fahrstreifen wechseln. Wird der Fahrstreifen erkannt, würde die Querführung bei einem Fahrstreifenwechsel des vorausfahrenden Fahrzeugs deaktiviert.

Parkassistent

Die Parkplatzsuche und das Parken können insbesondere in Großstädten eine Herausforderung darstellen. Der Parkassistent unterstützt den Fahrer bei den verschiedenen Teilaufgaben des Parkvorgangs (Katzwinkel et al., 2015). Die im Jahr 2019 verfügbaren Systeme lassen sich in drei Kategorien einteilen. Informierende Einparkassistenten können beim langsamen Vorbeifahren mit etwa 15 bis 30 km/h die Länge einer Parklücke vermessen und den Fahrer mitteilen, ob die Parklücke ausreichend groß für das Fahrzeug ist. Hierfür werden meistens preisgünstige Ultraschallsensoren verwendet. Diese unterstützen den Fahrer auch beim Einparkvorgang durch akustische Signale und optische Darstellung der Abstände. Manche Fahrzeuge haben auch Kameras verbaut, mit denen ein Bild zur besseren Orientierung des Fahrers aus der Vogelperspektive errechnet und in einem zentralen Informationsdisplay angezeigt wird.

Die zweite Kategorie von Parkassistenten unterstützen den Fahrer auch beim Einfahren in die Parklücke. Hierfür werden dem Fahrer üblicherweise ein Kamerabild angezeigt, das um dynamische Hilfslinien ergänzt wird. Einfachere Systeme funktionieren aber auch ohne Kamerabild und signalisieren dem Fahrer den Solllenkwinkel, die Fahrtrichtung, Stopp-Punkte sowie das Ende des Einparkvorgangs. Bei der dritten Kategorie von Parkassistenten übernimmt das System üblicherweise die Querführung des Fahrzeuges und der Fahrer die Längsführung.

Parkassistenten können auch mit einem Notbremsassistenten kombiniert werden, wodurch Kollisionen beim Ein- und Ausparken vermieden werden können.

Nothalteassistent

Durch die zuvor genannten Systeme kann bereits eine hohe Automatisierung des Fahrens erreicht werden. Dennoch müssen die in diesem Abschnitt beschriebenen Systeme alle dauerhaft vom Fahrer überwacht werden. Erkennt das System, dass der Fahrer die Fahraufgabe aufgrund eines medizinischen Notfalls nicht erfüllen kann, soll ein Nothalteassistent das Fahrzeug in eine risikominimale Anhalteposition bringen (Langer, Abendroth & Bruder, 2015). Medizinische Notfälle können kardiologische Notfälle, Epilepsie, Synkope, Zuckerschok oder ein Schlaganfall sein. Aufgrund des demografischen Wandels und des damit einhergehenden höheren Anteils von älteren Verkehrsteilnehmern ist eine Zunahme solcher Notfälle durchaus zu erwarten. Medizinische Notfälle sind nicht nur für den Fahrer gefährlich, sondern auch für andere Verkehrsteilnehmer. Ein besonders dramatischer Fall ereignete sich 2012 als ein Autofahrer kurz vor einer Ortseinfahrt bei Aschaffenburg einen Schlaganfall erlitt und infolgedessen das Lenkrad verriss (Hilgendorf, 2018). Unter normalen Umständen wäre das Fahrzeug dadurch von der Straße abgekommen und in einem Gebüsch vor der Ortseinfahrt zum Stehen gekommen. Der Spurhalteassistent hat das Fahrzeug jedoch wieder zurück in die Spur

geleitet, sodass das Fahrzeug mit hoher Geschwindigkeit in den Ort einfuhr und eine Frau und ihr Kind erfasste, die beide bei diesem Unfall verstorben sind.

Ein solcher Unfall hätte auch durch einen unaufmerksamen Fahrer herbeigeführt werden können. Dennoch zeigt dieser Unfall die Notwendigkeit von Systemen, die den Gesundheitszustand und im Falle von noch nicht autonomen Fahrzeugen auch die Aufmerksamkeit des Fahrers überwachen. Solche Systeme können unter anderem eine Müdigkeits- (Langer et al., 2015, S. 691f) oder eine Freihandfahrererkennung (Bartels, Rohlf, et al., 2015, S. 947) durchführen. Aufmerksamkeit und Müdigkeit werden Stand 2019 mit Kameras erkannt. Die Freihandfahrererkennung basiert auf der Erkennung von minimalen Lenkbewegungen bei elektromechanischen Lenkrädern. Somit kann sichergestellt werden, dass sich zumindest eine Hand am Lenkrad befindet. Zusätzlich werden auch Fahrerbeobachtungskameras sowie kapazitive oder druckempfindliche Sensoren im Lenkrad hierfür eingesetzt. Wird ein Haltegrund erkannt, erfolgt zumeist erst eine kurze, ruckartige Bremsung (Krieger-Lamina, 2016, S. 25). Erfolgt danach immer noch keine Reaktion des Fahrers, wird der nachfolgende Verkehr zunächst gewarnt, beispielsweise mit der Warnblinkanlage. Anschließend wird die Geschwindigkeit durch den Abstandsregeltempomaten reduziert und gegebenenfalls mit Hilfe des Spurwechselassistenten am Fahrbahnrand angehalten. Anschließend kann vom Fahrzeug ein automatischer Notruf abgesetzt werden (Langer et al., 2015, S. 696).

Autopilot

Bereits 2015 hat Tesla mit dem „Autopilot“ ein fortschrittliches FAS eingeführt. Anders als der Name vermuten lässt, handelt es sich dabei um ein System der Stufe 2 und nicht um einen Autopiloten, der wie im Flugzeug die komplette Steuerung übernimmt. Das System übernimmt nur für einen begrenzten Zeitraum und in bestimmten Situationen die Quer- und Längsführung. Der Fahrer ist zu jedem Zeitpunkt für die Fahraufgabe verantwortlich, was allerdings von den Nutzern nicht immer verstanden wird (z. B. Davies, 2015). Da es sich beim Tesla Autopilot um ein Stufe 2 FAS handelt, muss das System dauerhaft vom Fahrer überwacht werden, denn das System kann jederzeit und unmittelbar an seine Systemgrenzen stoßen. In einem solchen Fall muss der Fahrer eingreifen, da es ansonsten zu schwerwiegenden Unfällen kommen kann.

Am 07. Mai 2016 kam es so beispielsweise zu einem ersten Todesfall durch die falsche Verwendung des Tesla Autopilot (Vlasic & Boudette, 2016). Das Fahrzeug, ein Tesla Model S, fuhr zum Zeitpunkt des Unfalls mit aktiviertem Autopiloten. Sowohl das Fahrzeug selbst als auch der Fahrer haben keine Reaktion auf einen auf der Straße befindlichen weißen Anhänger eines kreuzenden Sattelschleppers gezeigt, sodass es zu dem ungebremsten Auffahrunfall mit ungefähr 100 km/h kam. Anhand der Sensoren des Fahrzeugs wäre das Hindernis zwar erkannt worden aber die Auswerteelektronik hat bei der Fusion der teilweise widersprüchlichen Sensorwerte entschieden, dass keine Vollbremsung erforderlich ist. Dennoch hat das System innerhalb der definierten Systemgrenzen funktioniert, denn der Tesla Autopilot ist ein SAE Level 2 System, bei dem der Fahrer das System dauerhaft überwachen muss (siehe Tabelle 1). Für den Laien ist diese Unterscheidung und Einordnung von Fahrzeugen jedoch oft nicht klar, was, wie in diesem Fall, schwerwiegende Konsequenzen haben kann. Tesla betont bei seinem

Autopiloten stets, dass die Fahrer weiterhin für die Fahraufgabe verantwortlich sind und warnt diese mehrmals bei der Installation und der Nutzung des Autopiloten. Dennoch kommt es häufig zu einer missbräuchlichen Verwendung des Systems.

3.4 Infrastruktur und Vernetzung

Eng verbunden mit der technischen Systemreife sind Anforderungen an die Infrastruktur und deren Kapazitäten. Entsprechende Infrastruktur wird für die Selbstlokation des Fahrzeuges benötigt und um die Umwelt auch außerhalb der Sensorenreichweite zu erkennen (Seif & Hu, 2016). In diesem Zusammenhang wird auch die Notwendigkeit von Echtzeit-Karten in HD Qualität genannt (Seif & Hu, 2016). Diese Karten enthalten neben hochgenauen Positionsinformationen zu statischen Objekten wie Straßen oder Häusern auch dynamische Informationen zum aktuellen Verkehrsgeschehen. Daraus resultieren die folgenden Herausforderungen (Seif & Hu, 2016):

- **Datensammlung:** Während einer Stunde Autofahrt werden ungefähr ein Terabyte an Daten erzeugt.
- **Datenverarbeitung:** Die Interpretation eines Terabytes an Daten mit einem Hochleistungsrechner benötigt ungefähr zwei Tage, um verwendbare Navigationsdaten zu erhalten.
- **Datenübertragung:** Mit LTE ist im Jahr 2019 eine Übertragungsrate von bis zu 100 Mbit/s möglich. Für eine hinreichende Kartenqualität in Echtzeit sind ungefähr 2,2 Gbit/s erforderlich. Es wird erwartet, dass die nächste Generation des mobilen Internets 5 Gbit/s ermöglichen wird.
- **Latenz:** Wegen der Echtzeitanforderungen ist eine Latenzzeit von etwa 10 Millisekunden erforderlich. Die Latenzzeit setzt sich aus der Übertragungszeit mit der Infrastruktur und der Verarbeitungszeit der Informationen durch das Fahrzeug zusammen.

Eine weitere Herausforderung ist die Vernetzung von Infrastruktur und Verkehrsteilnehmern, die es autonomen Fahrzeugen erlaubt, Informationen mit der Verkehrsinfrastruktur auszutauschen (Seif & Hu, 2016). Dazu müssen die Systeme integriert sowie eine ausreichende Verbindungsqualität sichergestellt werden. Die Schwierigkeiten bei der Entwicklung eines Ampelassistenten offenbart die Komplexität dieses Vorhabens (Reek, 2016). Andererseits wird argumentiert, dass ein klarer Trend zur umfassenden Automatisierung der städtischen Infrastruktur erkennbar ist (Heinrichs, 2016), aus der sich Synergien mit autonomen Fahrzeugen ergeben dürften.

3.5 Evolution der Fahrerassistenzsysteme

Wie sich anhand der beschriebenen Systeme erkennen lässt, nähern sich die meisten Hersteller den höheren Automatisierungsstufen, indem sie bestehende Assistenzsysteme weiterentwickeln und kombinieren. Die drei Ausgangspunkte für die Entwicklung des autonomen Fahrens lauten dabei: Einfache Szenarien, niedrige Geschwindigkeit und Hochrisiko-Situationen wie in Abbildung 14 ersichtlich (Winner, 2015, S. 1180–1182).

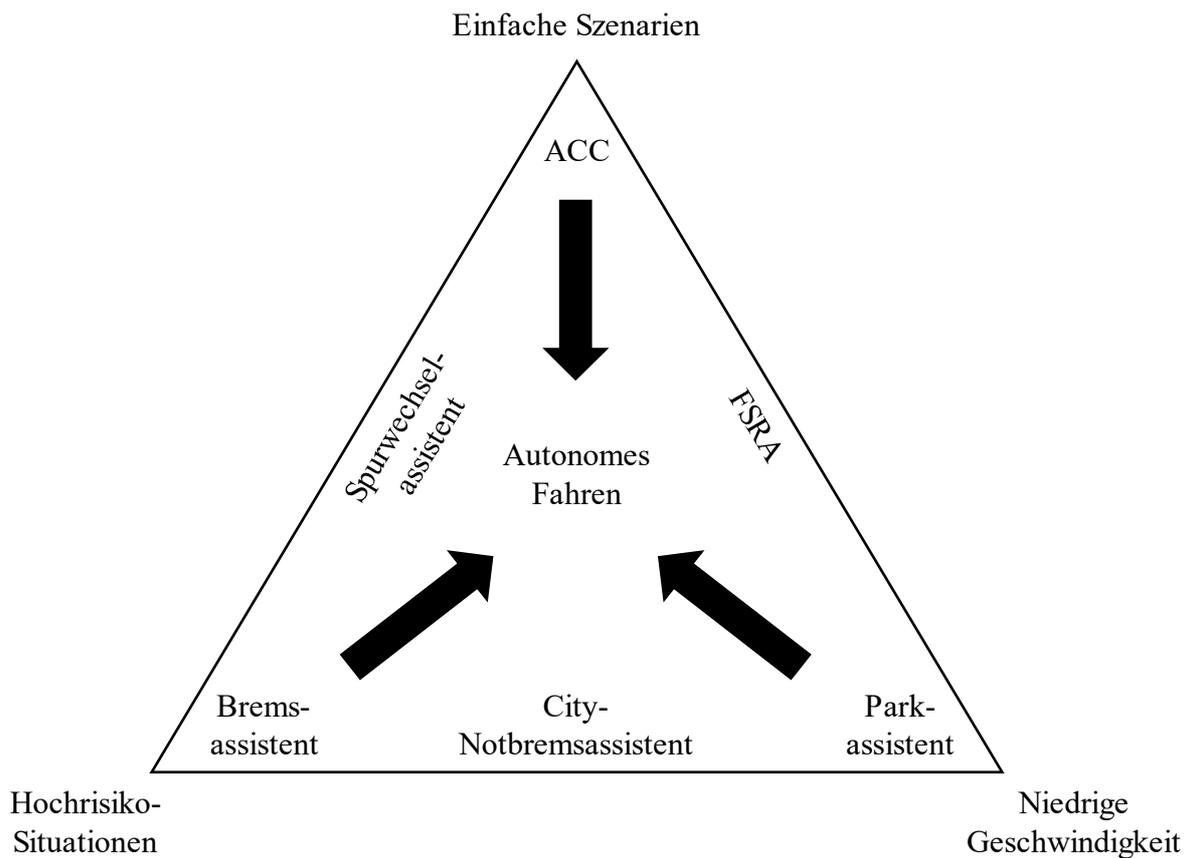


Abbildung 14: Evolution der Fahrerassistenzsysteme zum autonomen Fahren

Quelle: In Anlehnung an Winner (2015, S. 1181)

Einfache Szenarien werden durch ACC und dem Spurhalteassistenten, die Längs- und Querführung des Fahrzeugs bei Frei- und Folgefahrt und bei höheren Geschwindigkeiten übernehmen, abgedeckt. Dabei handelt es sich im Jahr 2019 noch um Komfortfunktionen, deren Auslegung die Aufmerksamkeit und Übernahmefähigkeit des Fahrers voraussetzt (Winner, 2015).

Der Ausgangspunkt von Assistenzsystemen bei *niedrigen Geschwindigkeiten* ist der Parkassistent, der vom informierenden, zum unterstützenden und schließlich zum selbstlenkenden System weiterentwickelt wird. Zukünftige Systeme könnten das Fahrzeug aufgrund der niedrigen Geschwindigkeiten und des damit verbundenen kurzen Bremsweges mit verhältnismäßig geringem Aufwand in eine sichere Anhalteposition bringen. Daher wird erwartet, dass zukünftige Systeme vom Fahrer auch außerhalb des Fahrzeugs gesteuert werden können, bis das Fahrzeug schließlich autonom einparken kann (Winner, 2015).

Der letzte Ausgangspunkt für die Entwicklung des autonomen Fahrens sind *Hochrisiko-Situationen*, die mittels Bremsassistenten adressiert werden. Die Basisversion des Bremsassistenten unterstützt den Fahrer beim richtigen Bremsen, indem der maximale Bremsdruck in Notsituationen schneller erreicht wird. Weiterentwicklungen bremsen automatisiert, wenn eine Kollision unmittelbar bevorsteht, um die Kollisionsfolgen zu lindern. Die neuesten Bremsassistenten im Jahr 2019 verfolgen das Ziel der Kollisionsvermeidung. Hier zeigt sich der Synergieeffekt in der Kombination der Assistenzsysteme unterschiedlicher

Ausgangspunkte. In diesem Beispiel wird der Gestaltungsspielraum durch die niedrige Geschwindigkeit genutzt, um Hochrisiko-Situationen besser adressieren zu können. Der Gestaltungsspielraum wurde bereits durch die Entwicklung von Parkassistenten untersucht, was nun der Entwicklung eines City-Notbremsassistenten zugutekommt. Dieser ist auf niedrige Geschwindigkeiten begrenzt, wie sie innerhalb von Ortschaften üblich sind, kann dafür aber auch kollisionsvermeidende Bremsungen durchführen (Winner, 2015).

Für Hochrisiko-Situationen bei höheren Geschwindigkeiten ist zur Kollisionsvermeidung oftmals ein Ausweichmanöver besser geeignet. Ein entsprechendes System wurde im PRORETA Projekt entworfen (Bender, Darms, Schorn, Stählin & Isermann, 2007). Voraussetzung für ein solches System ist, dass das Fahrzeug die eigene sowie angrenzende Fahrspuren erkennt und prüft, ob diese frei sind. Außerdem muss das System in der Lage sein, die Trajektorie für den Spurwechsel zu planen und umzusetzen. Diese Erkenntnisse aus der Entwicklung eines Notausweichassistenten für Hochrisiko-Situationen werden im einfachen Szenario einer Autobahnfahrt für die Entwicklung eines aktiven Spurwechselassistenten genutzt (Winner, 2015).

Eine Kombination aus einem einfachen Szenario und niedriger Geschwindigkeit zeigt sich in der Entwicklung des FSRA, der den Fahrer bei Staufahrten unterstützt. Wie beim Parken muss das Fahrzeug Kollisionen mit den Fahrzeugen in seiner unmittelbaren Nähe vermeiden und die Längsführung des Fahrzeugs in beengten Verhältnissen durchführen. Auch hier ist ersichtlich, wie die Weiterentwicklung von ACC in Form des FSRA von den Erkenntnissen bei der Entwicklung von Parkassistenten profitiert (Winner, 2015).

3.6 Aktuelle Entwicklungen

Aktueller Stand der Technik im Jahr 2019 ist das teilautomatisierte Fahren (SAE Level 2), welches bereits in vielen Serienfahrzeugen verfügbar ist. Ein fortschrittliches SAE Level 2 System ist der bereits mehrfach erwähnte Autopilot im Tesla Model S. Aufgrund mehrerer Unfälle steht dieses System jedoch in Kritik, erfüllt aber aus technischer Sicht alle Anforderungen an ein Level 2 System. Es hat sich gezeigt, dass hier nicht die Technik selbst, sondern die Fahrer durch missbräuchliche Nutzung des Systems oft die Ursache für die Unfälle darstellen (z. B. Krok, 2015). Die missbräuchliche Nutzung wird von anderen Systemen wie beispielsweise Intelligent Drive von Mercedes-Benz durch Systemrestriktionen effektiver unterbunden (Kohl, Schermann & Krcmar, 2016).

Die Gestaltung der Benutzeroberflächen für zunehmend automatisierte Fahrzeuge ist noch eine der zentralen Herausforderungen für deren Einführung (Kyriakidis et al., 2019). Für Fahrer ist es beispielsweise schwer, bei hochautomatisierten Fahrzeugen der SAE Stufe 3 innerhalb kurzer Zeit übernahmebereit zu sein (Gold, Dambock, Lorenz & Bengler, 2013). Auch bei FAS der Stufe 2 wird der Anteil der Fahrtstrecke, bei welcher der Fahrer nur mit der Überwachung des Systems beschäftigt ist, immer größer. Um dieser monotonen Aufgabe zu entgehen, beschäftigen sich die Fahrer mit anderen Dingen während der Fahrt und vernachlässigen die Überwachung des Systems. Es sind Fälle dokumentiert, bei denen der Fahrer den Fahrersitz eines Tesla Model S verlässt und sich auf die Rücksitzbank setzt (Krok, 2015). Wenn man bedenkt, dass der Fahrer bei diesem System jederzeit eingriffsbereit sein muss und wie

schwierig es für den Fahrer ist wieder in die Verkehrssituation zurückzufinden (Gold et al., 2013; Körber, Gold, Lechner & Bengler, 2016), dann sind solche Meldungen sehr beunruhigend. Sie zeigen, dass eine Überschätzung der FAS negative Auswirkungen auf die Fahrsicherheit und damit auf die Akzeptanz in der Bevölkerung haben können, anstatt diese zu erhöhen.

Umfragen zeigen, dass Menschen bereit sind, autonome Fahrzeuge zu akzeptieren, ohne diese getestet zu haben (z. B. Kyriakidis, Happee & de Winter, 2015). Für viele Menschen ist nicht einmal klar, wozu aktuell im Jahr 2019 verfügbare FAS in der Lage sind. Namen von FAS wie *Autopilot* deuten darauf hin, dass Fahrzeuge bereits komplett selbstständig Strecken zurücklegen können, was bei im Jahr 2019 verfügbaren FAS nicht der Fall ist. Es handelt sich dabei um ein gefährliches, aber weit verbreitetes Missverständnis, welches in vielen Fällen zur falschen oder sogar missbräuchlichen Verwendung von FAS führt (z. B. Fung, 2015). Die Akzeptanz autonomer Fahrzeuge könnte deutlich sinken, wenn die Zahl der Unfälle durch falsche Verwendung steigt (Rajasekhar & Jaswal, 2015).

Auch wenn in den letzten Jahren beträchtliche technische Fortschritte bei der Entwicklung von FAS verzeichnet wurden, ist bis 2020 noch kein FAS der Stufe 3 in einem Serienfahrzeug erhältlich. Dies bedeutet, dass trotz umfangreicher Automatisierung der Fahrzeuge weiterhin dauerhaft der Fahrer die Verantwortung für die Quer- und Längsführung des Fahrzeuges trägt. Erst ab Stufe 3 kann der Fahrer die Fahrverantwortung in bestimmten Situationen und für definierte Zeiträume dem Fahrzeug übergeben. Im Falle eines Unfalls während ein Stufe 3 System die Quer- und Längsführung des Fahrzeugs durchführt, würde also nicht der Fahrer, sondern der Hersteller des Fahrzeugs haften. Um dies im Nachgang eines Unfalls nachvollziehen zu können, ist eine Blackbox, wie sie in Flugzeugen eingesetzt wird, erforderlich.

Erste Ansätze für SAE Level 3 Systeme sind im Jahr 2019 bereits erkennbar. Üblicherweise werden solche Systeme zunächst in Oberklasse-Fahrzeugen angeboten und nach einiger Zeit dann auch in der Mittelklasse. So kündigte AUDI 2017 mit dem *Staupilot* einen Stauassistenten in der Oberklasse Limousine A8 an, der als erstes System SAE Level 3 erfüllen sollte (Hansen, 2017). In Stausituationen bis 60 km/h kann der Fahrer den Staupilot aktivieren und entsprechend der Definition von SAE Level 3 anderen Aufgaben nachgehen. Allerdings muss sich der Fahrer bereit halten die Fahraufgabe wieder zu übernehmen, wenn das System eine Systemgrenze erreicht. Daher wird der Fahrer im Audi A8 mittels einer Kamera überwacht, die die Position und Bewegung des Kopfes und den Lidschlag überwacht (Hansen, 2017). Schließt der Fahrer beispielsweise die Augen für einen längeren Zeitraum oder sind die Augen verdeckt, so wird der Fahrer zur Übernahme der Fahraufgabe aufgefordert. Da die rechtlichen Rahmenbedingungen allerdings immer noch nicht geklärt sind, kann der Staupilot im A8 im Jahr 2019 noch immer nicht aktiviert werden (Greis, 2019). Erste Vorschriften für solche hochautomatisierten Fahrfunktionen werden bis Mitte 2020 erwartet (Greis, 2019).

Zunehmend testen Hersteller im Jahr 2019 Fahrzeuge mit höherer Automatisierung, also SAE Level 4-5. Hierfür müssen die Fahrzeuge alle für die Fahraufgabe relevanten Fähigkeiten eines Menschen nachbilden (Seif & Hu, 2016). Das Fahrzeug benötigt dazu neben hochpräzisen,

digitalen Karten und adäquater Konnektivität auch Sensoren wie Sonar, Radar, Laserscanner oder Kameras. Die resultierenden Daten müssen anschließend kombiniert und interpretiert werden, um korrekte Entscheidungen treffen zu können. Die Kommunikation, Datenerfassung und Datenverarbeitung müssen unter hohen Zeit- und Sicherheitsanforderungen durchgeführt werden. Aufgrund der hohen Komplexität und der Fülle an Daten spricht man hierbei von *Big Data*, für deren Verarbeitung neue Verfahren erforderlich sind, beispielsweise aus dem Bereich maschineller Lernverfahren (Schermann, Hemsen, et al., 2014). Solche Verfahren benötigen eine enorme Menge an Trainingsdaten, um alle möglichen Fahrsituationen meistern zu können. Firmen wie Google sammeln daher bereits seit geraumer Zeit Trainingsdaten im realen Straßenverkehr und führen umfangreiche Simulationen durch (Etherington, 2019). Aufgrund dieses Vorgehens ist es schwierig im Jahr 2019 genaue Vorhersagen über die Verfügbarkeit serienreifer Technik für SAE Level 4-5, also autonomen Fahrzeugen, zu treffen.

4 Forschungsmethoden

Für die Beantwortung der forschungsleitenden Fragestellungen führen wir vier Studien durch. In drei dieser Studien verwenden wir strukturierte Fragebögen zur Datenerhebung und Strukturgleichungsmodellierung zur Auswertung der erhobenen Daten. In diesem Kapitel werden die Grundlagen der verwendeten Forschungsmethoden für die ersten drei Studien beschrieben. Da wir in der vierten Studie eine Methode entwickeln, ist diese in Abschnitt 8.2 separat beschrieben.

4.1 Strukturierter Fragebogen

Für die Fragebogenkonstruktion ist das Verständnis einiger grundlegender maßtheoretischer und statistischer Konzepte erforderlich. Im Folgenden erläutern wir zunächst die Skalenniveaus, die für die Auswahl von statistischen Verfahren für die Auswertung der erhobenen Daten entscheidend sind. Anschließend beschreiben wir das Vorgehen bei der Kodierung von Antworten und erörtern abschließend das Konzept von Konstrukten.

4.1.1 Skalenniveau

Das Skalenniveau bezieht sich auf die Antwortoptionen einer Frage und ist für die statistische Auswertung von Fragebögen von großer Bedeutung (Hair et al., 2017, S. 7f). Je nach Skalenniveau können nur bestimmte statistische Auswertungsverfahren verwendet werden. Das geringste Skalenniveau weisen *Nominal- oder Kategorienskalen* auf. Die einzige Voraussetzung die *Nominalskalen* erfüllen sind sich gegenseitig ausschließende Antwortoptionen, wie beispielsweise die Marke des Fahrzeuges, das man hauptsächlich nutzt. Als statistische Auswertung für diese Frage könnte der Marktanteil einer Fahrzeugmarke in der Studienpopulation berechnet und mit anderen Marken verglichen werden. Diese Berechnung basiert rein auf den Häufigkeiten der von Probanden gegebenen Antworten.

Können Antwortoptionen nach einer Rangfolge geordnet werden, so spricht man von einer *Ordinalskala* (Hair et al., 2017, S. 7f). Beispielsweise bei einer Frage nach der subjektiven Einschätzung der jährlichen Fahrleistung mit dem eigenen PKW und den Antwortoptionen „sehr gering“, „gering“, „mittel“, „hoch“ und „sehr hoch“ ist eine Rangfolge erkennbar. Probanden mit einer geringen Fahrleistung schätzen diese offensichtlich höher ein als Probanden mit einer mittleren Fahrleistung. Es kann aber keine Aussage bezüglich der Abstände der einzelnen Antwortoptionen getroffen werden. Somit dürfen insbesondere statistische Auswertungen, die auf gleichen Abständen zwischen den Antwortoptionen basieren, nicht angewendet werden. Dies sind beispielsweise Mittelwerte, Varianzen oder ein t-Test. Der Median kann aber auch bei ordinalskalierten Daten berechnet werden. Somit wäre eine Aussage möglich, dass der Median der subjektiv eingeschätzten Fahrleistung unter den Probanden „hoch“ ist. Das bedeutet nicht, dass die Mehrheit der Probanden angibt, eine hohe Fahrleistung zu haben. Beispielsweise wäre der Median auch „hoch“, wenn bei zwei Probanden ein Proband die Antwortoption „mittel“ wählt und der andere „sehr hoch“ und somit keiner der Probanden die Antwortoption „hoch“ wählt.

Gibt es eine Rangfolge bei sich gegenseitig ausschließenden Antworten und sind die Abstände zwischen den Antwortoptionen gleich, so handelt es sich um eine *Intervallskala* (Hair et al., 2017, S. 7f). Durch diese Eigenschaft ist nun ein Mittelwert oder die Standardabweichung sinnvoll definiert. Durch Reskalierung kann eine Intervallskala auch in eine andere Skala transformiert werden. So kann zum Beispiel kann eine Leistungsangabe in Pferdestärken durch eine lineare Transformation in die Einheit Watt umgewandelt werden.

Das höchste Skalenniveau besitzen schließlich *Ratioskalen* (Hair et al., 2017, S. 7f). Im Vergleich mit einer Intervallskala weisen diese einen absoluten Nullpunkt oder Ursprung im Wert 0 auf. Dies ist zum Beispiel bei der Temperaturmessung in der Einheit Kelvin der Fall. Bei der Messung in °C hingegen handelt es sich um eine Intervallskala, da es sich bei 0 °C nicht wie bei der Einheit Kelvin um den absoluten Nullpunkt für Temperaturen handelt. Nur bei Ratioskalen sind alle mathematischen Operationen erlaubt.

Liegen intervall-, ratio- oder äquidistante ordinalskalierte Daten vor, stehen viele statistische Verfahren zur Auswertung der Daten zur Verfügung. Damit diese angewendet werden dürfen, gibt es bei parametrischen Tests noch weitere Voraussetzungen an die Verteilung der empirisch erhobenen Daten (Hair et al., 2017, S. 9f). Für bestimmte multivariate Verfahren sind beispielsweise normalverteilte Daten erforderlich. Werden die Annahmen von statistischen Tests über die Verteilung der Daten verletzt, kann dies zu falschen Schlussfolgerungen führen. Es sollten daher immer die Annahmen über die Verteilung der Daten geprüft werden, bevor ein statistischer Test angewendet wird.

4.1.2 Kodierung

Zur Auswertung der Antworten auf einen Fragebogen werden die Antwortoptionen mit Zahlen kodiert (Hair et al., 2017, S. 8f). Im obigen Beispiel der jährlichen Fahrleistung mit dem eigenen PKW könnten die Antwortoptionen von 1 bis 5 durchnummeriert werden. Häufig wird in Fragebögen mit einer Likert Skala nach der Zustimmung zu einer vorgegebenen Aussage gefragt mit Antwortoptionen, die von 0 % Zustimmung bis 100 % Zustimmung reichen (Albaum, 1997). Die Antwortoptionen sind dabei oft als textuelle Beschreibung gegeben. Somit handelt es sich eigentlich um ordinalskalierte Antworten, bei denen viele statistische Analysen nicht möglich wären. Sind die Antwortoptionen allerdings äquidistant gewählt, so kann nach einer Kodierung näherungsweise von einer Intervallskala ausgegangen werden (Norman, 2010).

Bei Zustimmungsfragen verwendet man häufig Likert-Skalen, bei denen die Endpunkte fest definiert und die Zwischenschritte nur als Zahlenwert angegeben sind, beispielsweise: „1: Stimme voll und ganz zu, 2, 3, 4, 5: Stimme überhaupt nicht zu“. Bei dieser 5-Punkte Likert Skala können die Antwortoptionen als äquidistant angenommen werden, was die Voraussetzung für die Anwendung multivariater Analysen bildet. Wird dies bei der Fragebogenkonstruktion nicht berücksichtigt, kann dies zu Verzerrungen in den erhobenen Daten führen, was die Validität der gesamten Studie in Frage stellen kann (Hair et al., 2017, S. 8f).

4.1.3 Konstrukte

Die zu untersuchende Akzeptanz von Innovationen kann, im Gegensatz zu beispielsweise Volumen einer Flüssigkeit oder Masse eines Gegenstandes, nicht direkt beobachtet werden. In solchen Fällen spricht man von Konstrukten oder latenten Variablen (Hair et al., 2017, S. 6). Um Konstrukte dennoch untersuchen zu können, können diese mittels Indikatoren in Form von Fragen in einem Fragebogen operationalisiert werden. Indikatoren werden auch als Items oder manifeste Variablen bezeichnet und entsprechen verschiedenen Aspekten von oder Sichtweisen auf ein Konstrukt. Meistens werden mehrere Indikatoren für ein Konstrukt verwendet, was als Multi-Item-Skala bezeichnet wird. Durch die Kombination mehrerer Indikatoren für ein Konstrukt wird der Messfehler reduziert und somit die Messgenauigkeit für das Konstrukt erhöht, was sich auch auf die Güte des Gesamtmodells auswirken kann.

4.2 Strukturgleichungsmodellierung

Zur Untersuchung sozialwissenschaftlicher Phänomene werden seit mehr als einem Jahrhundert statistische Analysen eingesetzt (Hair et al., 2017, S. 2). Einfache Zusammenhänge können dabei mittels uni- und bivariater Analyseverfahren untersucht werden. Die aktuellen sozialwissenschaftlichen Modelle erfordern jedoch aufgrund ihrer zunehmenden Komplexität multivariate Analysen. Durch die Verfügbarkeit von geeigneter Hardware in Kombination mit bedienerfreundlicher Software werden diese multivariaten Verfahren in sozialwissenschaftlicher Forschung mittlerweile häufig eingesetzt.

Multivariate Verfahren ermöglichen die gleichzeitige statistische Analyse von mehreren Variablen und Wirkzusammenhängen (Hair et al., 2017, S. 2f). Sind die Wirkzusammenhänge vorher nicht bekannt, verwendet man explorative Verfahren, um diese aufzudecken. Beispiele für explorative Verfahren sind die Clusteranalyse, die explorative Faktorenanalyse und die multidimensionale Skalierung. Sind die Wirkzusammenhänge bereits bekannt, können diese in Form von Hypothesen statistisch getestet werden. In diesem Fall spricht man von konfirmatorischen Verfahren. Konfirmatorische Verfahren sind unter anderem die Varianzanalyse, logistische Regression, multiple Regression und die konfirmatorische Faktorenanalyse. Die Einteilung der Verfahren erfolgt anhand der üblichen Verwendung der Verfahren. Eine Regressionsanalyse beispielsweise basiert üblicherweise auf vorher hypothetisierten Zusammenhängen, die dann mittels der Regressionskoeffizienten statistisch getestet werden (konfirmatorisch). Allerdings können mit diesem Verfahren auch vorab unbekannte statistische Zusammenhänge gefunden werden (explorativ).

Die Strukturgleichungsmodellierungsverfahren basieren auf den zuvor genannten Beispielen für multivariate Verfahren und werden daher als multivariate Verfahren der zweiten Generation bezeichnet (Fornell, 1982). Sie besitzen eine höhere statistische Aussagekraft und ermöglichen die Messung von nicht direkt beobachtbaren latenten Variablen, die mittels mehrerer Indikatorvariablen gemessen werden können (Hair et al., 2017, S. 4). Zudem ermöglichen sie die Berücksichtigung von Messfehlern bei den Indikatoren. Die Strukturgleichungsmodellierungsverfahren werden unter dem Begriff Structural Equation Models (SEM) zusammengefasst. Überwiegt der konfirmatorische Aspekt in einer Analyse, verwendet man üblicherweise kovarianzbasierte SEM (Covariance-Based-SEM, CB-SEM).

Dabei werden gut etablierte Modelle mittels empirischer Daten überprüft. Für die Entwicklung neuer Theorien und Hypothesen, ist Partial Least Squares SEM (PLS-SEM) im Vorteil. PLS-SEM gehört daher formal zu den explorativen multivariaten Verfahren.

Zur Messung und Prognose der Akzeptanz von Innovationen ist die Untersuchung von verschiedenen, nicht direkt beobachtbaren Variablen, die in Wirkzusammenhängen miteinander stehen, erforderlich. Wir verwenden daher SEM für die statistische Auswertung der mit Fragebögen erhobenen Daten dieser Dissertation. Da es sich bei der Prognose der Akzeptanz von Innovationen um einen neuen Forschungskontext handelt, untersuchen wir die Strukturgleichungsmodelle mittels PLS-SEM. Die dafür benötigten Pfadmodelle erläutern wir im folgenden Abschnitt.

4.2.1 Pfadmodell

Die zu untersuchenden Zusammenhänge zwischen Konstrukten können mit einem Pfadmodell grafisch dargestellt werden. Abbildung 15 zeigt ein solches Pfadmodell. Das Pfadmodell enthält vier Konstrukte Y1 bis Y4, die mit den Indikatoren x1 bis x10 indirekt gemessen werden (Hair et al., 2017, S. 10ff). Konstrukte werden in einem Pfadmodell als Ellipsen und Indikatoren als Rechtecke dargestellt. Die Verbindung von Konstrukten mit den zugehörigen Indikatoren findet mit Pfeilen statt. Die Indikatoren eines Konstrukts beschreiben das *Messmodell*, das auch als *äußeres Modell* bezeichnet wird. Auch die Konstrukte untereinander sind mit Pfeilen verbunden, was als *Strukturmodell* oder *inneres Modell* bezeichnet wird. Die Richtung der Pfeile zwischen den Konstrukten repräsentiert eine gerichtete Wirkbeziehung. Die Richtung der Pfeile ergibt sich aus einer dem Modell zugrundeliegenden Theorie, denn mathematisch werden nur Korrelationen zwischen den Konstrukten untersucht. Kausalität folgt nur mit entsprechender theoretischer Fundierung des Modells (Hair et al., 2017, S. 10).

Enthält ein Pfadmodell Beziehungen zwischen Konstrukten, so wird zwischen *exogenen* und *endogenen Konstrukten* unterschieden (Hair et al., 2017, S. 11ff). Die exogenen Konstrukte erklären dabei die endogenen Konstrukte. Im Beispiel erklären Y1 und Y2 das Konstrukt Y3; Y3 wiederum erklärt Y4. Y1 und Y2 sind somit endogene Konstrukte und Y3 und Y4 sind exogene Konstrukte. Aufgrund der gerichteten Wirkbeziehung kann auch von abhängigen und unabhängigen Variablen gesprochen werden. Die Zuordnung zu endogenen und exogenen Konstrukten ist allerdings nicht eindeutig. Im Beispiel ist Y3 sowohl eine unabhängige Variable, da sie von Y1 und Y2 erklärt wird, als auch eine abhängige Variable, da sie Y4 erklärt. Die Semantik der Pfeile zwischen Konstrukten erscheint naheliegend. Die Semantik der Pfeile zwischen Konstrukten und Indikatoren unterscheidet sich davon: Zeigen die Pfeile von den Indikatoren zum Konstrukt, so handelt es sich um eine *formative* Messung des Konstruktes wie im Falle von Y1 und Y2. Das bedeutet, dass die Indikatoren des Konstruktes dessen komplette Kovarianz erklärt, indem jeder Indikator einen Aspekt des Konstruktes abdeckt. Im Gegensatz dazu werden bei einem *reflektiven* Messmodell die wesentlichen Aspekte des Konstruktes mit jedem Indikator gemessen. Es wird aber bei reflektiven Konstrukten stets eine Abweichung zum tatsächlichen Wert geben. Diese Abweichung wird mittels Fehlertermen modelliert, wie beim Konstrukt Y3 ersichtlich.

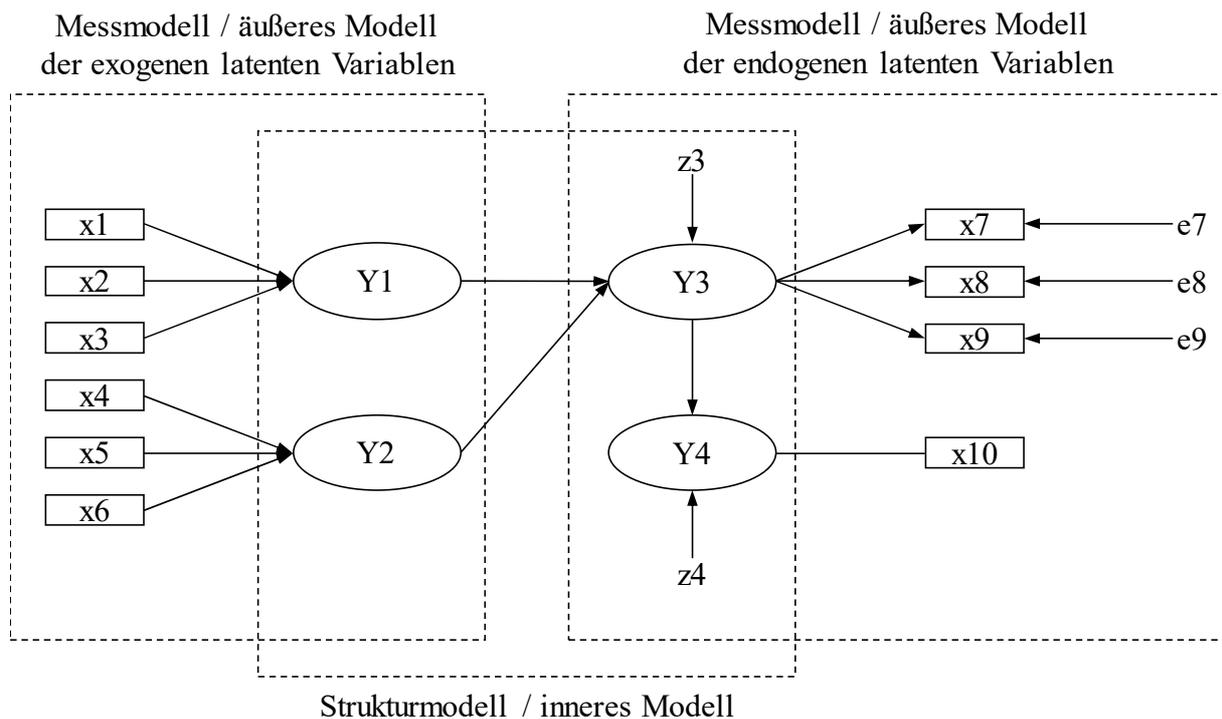


Abbildung 15: Beispiel eines Pfadmodells

Quelle: In Anlehnung an Hair et al. (2017, S. 11)

Die Fehlerterme e_7 bis e_9 in Abbildung 15 modellieren die nicht erklärte Kovarianz des reflektiv gemessenen Konstruktes durch die Indikatoren. Wird ein Konstrukt nur mit einem Indikator gemessen, spricht man von einem Single-Item-Konstrukt wie im Falle von Y4 (Hair et al., 2017, S. 11ff). In diesem Fall ist das Konstrukt äquivalent zum zugehörigen Indikator. Ein Fehlerterm beim Indikator ist somit nicht vorhanden. Endogene Konstrukte weisen ebenfalls Fehlerterme auf, im Beispiel z_3 und z_4 .

4.2.2 PLS-SEM Modellberechnung

Die PLS-SEM Modellberechnung basiert auf der Addition der gewichteten Indikatoren eines Konstruktes zu sogenannten *Composite-Variablen* (Hair et al., 2017, S. 13ff). Durch die Gewichtung der Indikatoren können Messfehler direkt bei der Modellberechnung berücksichtigt werden. Ein trivialer Algorithmus zur Modellberechnung ist die Regression mit Summenwerten, die alle Indikatoren mit 1 gewichtet. Für das obige Beispiel wäre folglich die Composite-Variable Y1 definiert als die Summe der zugehörigen Indikatoren: $x_1 + x_2 + x_3$. Nach der Bildung aller Composite-Variablen können die Zusammenhänge zwischen den Konstrukten mit einem statistischen Verfahren wie der linearen Regression berechnet werden. Die ungewichtete Summation der Indikatoren hat allerdings den Nachteil, dass sowohl die Fehlerterme als auch die Bedeutung der einzelnen Indikatoren nicht berücksichtigt werden. Daher werden bei PLS-SEM die Indikatorgewichte mittels Ordinary Least Squares (OLS) Regression bestimmt, mit dem Ziel, die Residualvarianz der endogenen Konstrukte zu minimieren. Ziel ist somit, die R^2 -Werte der endogenen Konstrukte zu maximieren. Daher ist PLS-SEM ein geeignetes Verfahren zur Theorieentwicklung. Die Entscheidung PLS-SEM für

die Auswertung der Studien in dieser Dissertation zu verwenden ist jedoch nicht nur darin begründet.

Weitere Vorteile von PLS-SEM sind, dass das Verfahren auch bei kleinen Stichproben und komplexen Modellen effizient arbeitet (Hair et al., 2017, S. 18f). Im Allgemeinen wird eine hohe statistische Teststärke mit PLS-SEM erreicht, obwohl es sich bei PLS-SEM um ein nicht-parametrisches Verfahren handelt, das keine Annahmen zur Verteilung der Daten voraussetzt. Die statistische Teststärke ist auch gegenüber der Regression mit Summenwerten und CB-SEM überlegen (Hair et al., 2017, S. 18f). Weiterhin sind effiziente Algorithmen verfügbar, die innerhalb weniger Iterationen gegen die optimale Lösung konvergieren und Software, die diese Algorithmen für Endanwender implementiert (Ringle, Wende & Becker, 2015; Rönkkö, 2019).

Neben den Vorteilen dürfen jedoch auch die Nachteile von PLS-SEM nicht vernachlässigt werden. Ein wesentlicher Nachteil von PLS-SEM ist, dass kein etabliertes globales Gütekriterium existiert (Hair et al., 2017, S. 17ff). Daher ist die Modellevaluation relativ umfangreich. Die Evaluation gliedert sich in die Bewertung des Messmodells und anschließend der Bewertung des Strukturmodells jeweils anhand multipler Kriterien. Ebenfalls können durch den Mangel eines etablierten globalen Gütekriteriums Modelle nicht anhand dieses Kriteriums (statistisch) miteinander verglichen werden, um beispielsweise zu testen, ob ein neues Modell besser als das etablierte Modell ist.

Ein weiterer Nachteil ist die fehlende Konsistenz zwischen CB-SEM und PLS-SEM Schätzungen (Hair et al., 2017, S. 17ff). Bei den PLS-SEM Parameterschätzungen werden im Vergleich zu CB-SEM Beziehungen im Strukturmodell generell unterschätzt und Beziehungen im Messmodell überschätzt. Dies muss beim Vergleich von Studien mit unterschiedlichen Verfahren berücksichtigt werden. Eine Abweichung der Parameterschätzungen deutet aber nicht auf einen systematischen Fehler in PLS-SEM oder CB-SEM hin, sondern resultiert aus den unterschiedlichen Optimierungszielen der Verfahren. Das Optimierungsziel von PLS-SEM ist die Minimierung der Residualvarianz der endogenen Konstrukte. Daraus folgt, dass der R^2 -Wert der endogenen Konstrukte maximiert wird und sich daraus die Parameterschätzungen von PLS-SEM ergeben. Ein direkter Vergleich mit CB-SEM Modellschätzungen ist daher nicht möglich. Da auch in den UTAUT Studien PLS-SEM verwendet wurde (Venkatesh et al., 2003) spricht dieses Argument allerdings sogar für die Verwendung von PLS-SEM. Vor diesem Hintergrund verwenden wir auch nicht den PLSc Ansatz, der auf Konsistenz der Parameterschätzungen mit CB-SEM ausgelegt ist.

Unter Berücksichtigung der Vor- und Nachteile der beiden SEM Verfahren verwenden wir in der vorliegenden Dissertation ausschließlich PLS-SEM für die Modellberechnung.

4.2.3 Voraussetzungen für PLS-SEM

Die Auswahl der Stichprobe unterscheidet sich nicht von herkömmlichen Umfragen. Auch PLS-SEM kann keine repräsentativen Ergebnisse liefern, wenn die Stichprobe zu klein gewählt ist (Hair et al., 2017, S. 20ff). Weiterhin muss die Stichprobe die Gemeinsamkeiten und Unterschiede der Population umfassen, auf welche die Ergebnisse generalisiert werden sollen. Zusätzlich stellt PLS-SEM als statistisches Verfahren Anforderungen an die Stichprobengröße,

damit tatsächlich vorhandene Effekte auch durch signifikante Ergebnisse der Analyse nachgewiesen werden können. Der Fehler, der durch zu kleine Stichproben oder mangelnde Teststärke auftritt, wird auch als *Fehler zweiter Art* oder als β -*Fehler* bezeichnet.

Bei PLS-SEM können fehlende Werte im Fragebogen durch gängige Verfahren wie Mittelwertersetzung oder dem *Nächster-Nachbar-Ansatz* behandelt werden (Hair et al., 2017, S. 23ff). Fehlen weniger als 5 % der Werte eines Indikators, führt dies in der Regel nur zu geringen Abweichungen bei den Ergebnissen. Eine Behandlung der fehlenden Werte ist dem Löschen von Beobachtungen vorzuziehen, da dies zu Verzerrungen führen kann, insbesondere wenn den fehlenden Werten eine Systematik zugrunde liegt. Es sollten daher alle Fragen in den Fragebögen als Pflichtfelder eingestellt werden, insofern die Beantwortung der Fragen für die Probanden vertretbar und dadurch nicht die Anonymität einzelner Umfrageteilnehmer gefährdet ist.

Bezüglich der Verteilung der Daten hat PLS-SEM nur wenige Voraussetzungen (Hair et al., 2017, S. 23). Insbesondere wird keine Normalverteilung der Daten vorausgesetzt. Dadurch müssen die bei Umfragen häufig auftretenden Verletzungen der Normalverteilung nicht gesondert behandelt werden. Somit kann auf das Entfernen von Beobachtungen oder Transformation der Daten weitgehend verzichtet werden. Da die Parameterberechnung bei PLS-SEM auf OLS-Regressionen basiert, können die Ergebnisse allerdings von Ausreißern und Multikollinearität beeinflusst werden.

Für die Indikatoren bei PLS-SEM werden ratio- oder intervallskalierte metrische Daten benötigt (Hair et al., 2017, S. 23f). Wie im Abschnitt 4.1 erläutert, können aber auch ordinalskalierte Daten mit äquidistanten Antwortoptionen verwendet werden. Auch binär-kodierte Antworten, wie zum Beispiel für das Geschlecht, können in das Modell als Moderator integriert werden. Binär kodierte Antworten können aber nicht als Indikator zur Messung von Konstrukten verwendet werden. Bei der Fragebogenkonstruktion muss daher auf entsprechend kodierte Antwortoptionen geachtet werden.

Neben den Voraussetzungen für das Messmodell gibt es auch eine Vorgabe für das Strukturmodell: Dieses darf keine zirkulären Beziehungen oder Schleifen enthalten (Hair et al., 2017, S. 24f). Ansonsten gibt es keine weiteren strikten Vorgaben zur Modellierung des Strukturmodells. Alle in dieser Dissertation untersuchten Modelle enthalten weder zirkuläre Beziehungen noch Schleifen. Daher stellt diese Vorgabe keine Einschränkung im Rahmen dieser Dissertation dar.

4.2.4 Anwendung des PLS-SEM Algorithmus

Zur Auswertung der erhobenen Daten mit dem PLS-SEM Algorithmus verwenden wir die Software SmartPLS in der Version 3.2.8 (Ringle et al., 2015). SmartPLS bietet eine grafische Benutzeroberfläche und kann alle benötigten statistischen Auswertungen durchführen. Weiterhin liefert die Software alle benötigten Werte, damit die Modellgüte nach wissenschaftlichen Standards bewertet werden kann. Es gibt aber auch kostenlose Alternativen wie matrixPLS, die für die PLS-SEM Modellberechnung verwendet werden können (Rönkkö, 2019).

Vor der Ausführung des PLS-SEM Algorithmus müssen einige Parameter und Einstellungen definiert werden. Zunächst muss ein Gewichtungsschema für das Strukturmodell definiert werden. Es stehen drei Gewichtungsschemata zur Verfügung (Henseler, Ringle & Sinkovics, 2009): Zentroid-Gewichtungsschema, Faktor-Gewichtungsschema und Pfad-Gewichtungsschema. Die Ergebnisse bei den verschiedenen Gewichtungsschemata unterscheiden sich nur geringfügig. Allerdings liefert das Pfad-Gewichtungsschema die höchsten R^2 -Werte für endogene Konstrukte, sodass dieses Gewichtungsschema empfohlen wird. Da es ansonsten keine Nachteile bei der Verwendung des Pfad-Gewichtungsschemas bezüglich unserer Studien gibt, wählen wir immer das Pfad-Gewichtungsschema aus.

Der PLS-SEM Algorithmus benötigt als Eingabedaten ratio- oder intervallskalierte metrische Daten, die zudem z-standardisiert sein müssen (Hair et al., 2017, S. 76f). Die erhobenen Daten müssen also zunächst z-transformiert werden, damit jeder Indikator einen Mittelwert von 0 und eine Varianz von 1 aufweist. Dies wird von der SmartPLS Software automatisch durchgeführt. Auch die für die Konstrukte berechneten Werte werden z-transformiert, sodass die berechneten Pfadkoeffizienten stets im Intervall zwischen -1 und +1 liegen. Je näher die Pfadkoeffizienten an -1 oder +1 liegen, desto höher ist somit die Beeinflussung des Konstruktes. Pfadkoeffizienten nahe 0 bedeuten hingegen eine schwache Beeinflussung.

Für die Initialisierung des iterativen PLS-SEM Algorithmus wird für jeden Indikator ein Startgewicht benötigt um den Wert des Konstruktes zu ermitteln (Hair et al., 2017, S. 77f). Das übliche Vorgehen ist für jeden Indikator ein Startgewicht von +1 zu definieren. Andere Startgewichte wirken sich im Allgemeinen nur auf die Anzahl der benötigten Iterationen aus, bis der Algorithmus konvergiert. Da der PLS-SEM Algorithmus sehr performant läuft, wird eine solche Optimierung auf aktuellen Rechnern nicht mehr benötigt. Zudem besteht die Möglichkeit, dass abweichende Startgewichte zu Problemen führen könnten, was ein unnötiges Risiko darstellt. Daher belassen wir die Startgewichte auf +1 für jeden Indikator.

Da es sich beim PLS-SEM Algorithmus um einen iterativen Algorithmus handelt, wird ein Stopp-Kriterium benötigt (Hair et al., 2017, S. 78). Für das Stopp-Kriterium wird die Änderung der äußeren Gewichte zwischen jeder Iteration verglichen. Bei hinreichend kleinen Änderungen kann das Ergebnis als stabil betrachtet werden. Der Grenzwert für die Änderung der äußeren Gewichte kann in SmartPLS definiert werden. Es wird ein Wert von 10^{-7} als Grenzwert empfohlen (Hair et al., 2017, S. 78), den wir übernehmen. Sollte sich das Ergebnis nicht stabilisieren, was sehr ungewöhnlich ist, kann auch eine maximale Anzahl an Iterationen angegeben werden. Es wird ein Wert von 300 Iterationen empfohlen (Hair et al., 2017, S. 78), den wir ebenfalls übernehmen.

4.2.5 Evaluation reflektiv spezifizierter Messmodelle

Wie in Abschnitt 4.2.2 bereits angesprochen, ist eines der zentralen Nachteile von PLS-SEM, ein fehlendes etabliertes globales Gütekriterium zur Modellevaluation. Daher werden mehrere Gütekriterien bei PLS-SEM verwendet, die jeweils Teilaspekte des Modells untersuchen. Ein Fokus liegt hierbei darauf, die Prognosefähigkeit des Modells und die erklärte Varianz des Modells zu maximieren. Zur systematischen Analyse der Modellgüte hat sich ein zweistufiger

Ansatz etabliert: Zunächst wird das Messmodell untersucht und anschließend das Strukturmodell (Hair et al., 2017, S. 90ff).

Mittels PLS-SEM können sowohl reflektiv als auch formativ spezifizierte Messmodelle untersucht werden (Hair et al., 2017, S. 91ff). Allerdings muss bei reflektiven Messmodellen anders als bei formativen Messmodellen vorgegangen werden. Das reflektive Messmodell wird bezüglich Interner-Konsistenz-Reliabilität, Konvergenzvalidität und Diskriminanzvalidität untersucht. Das formative Messmodell hingegen wird bezüglich Konvergenzvalidität, Kollinearität zwischen den Indikatoren, sowie Höhe und Signifikanz der Indikatorgewichte untersucht.

Wir beschreiben zunächst die Evaluation reflektiver Messmodelle (Hair et al., 2017, S. 90ff). Im ersten Schritt der Evaluation wird die Reliabilität der Indikatoren untersucht. Das erste Kriterium, das wir für die Reliabilität prüfen ist die *Interne-Konsistenz-Reliabilität*. Ein bekanntes Maß hierfür ist Cronbachs Alpha (Cronbach, 1951). Dieses ist definiert als:

$$\alpha_k = \frac{n}{n-1} \left(\frac{\sum_i V_i}{V_k} \right)$$

In der Formel bezeichnet n die Anzahl der Indikatoren für das untersuchte Konstrukt k , V_i ist definiert als die Varianz des Indikators i und V_k ist definiert als die Gesamtvarianz über alle Indikatoren des Konstruktes k . Die Formel zeigt, dass bei Cronbachs Alpha alle Indikatoren gleich gewichtet sind. Zudem führt eine hohe Anzahl von Indikatoren für ein Konstrukt dazu, dass die interne Konsistenz der Indikatoren unterschätzt wird (Hair et al., 2017, S. 90ff). Somit ist Cronbachs Alpha ein eher konservatives Maß für die Interne-Konsistenz-Reliabilität. Ein bei PLS-SEM häufig verwendetes Maß zur Untersuchung der internen Konsistenz ist die Composite-Reliabilität beziehungsweise Faktorreliabilität. Dieses berücksichtigt die bei PLS-SEM berechneten standardisierten Ladungen l_i eines Konstruktes und ist wie folgt definiert (Hair et al., 2017, S. 96):

$$\rho_c = \frac{(\sum_i l_i)^2}{(\sum_i l_i)^2 + \sum_i \text{var}(e_i)} = \frac{(\sum_i l_i)^2}{(\sum_i l_i)^2 + \sum_i (1 - l_i^2)}$$

Neben standardisierten Ladungen l_i eines Konstruktes beinhaltet die Formel für die Composite-Reliabilität außerdem die Summe aller Varianzen der Indikatormessfehler eines Konstruktes. Der Messfehler einer Indikatorvariablen i ist definiert als $1 - l_i^2$. Die Wertebereiche für Cronbachs Alpha und die Composite-Reliabilität liegen zwischen 0 und 1. Werte zwischen 0,60 und 0,70 gelten als akzeptabel, Werte zwischen 0,70 und 0,90 sind zufriedenstellend und Werte ab 0,90 gelten als problematisch (Hair et al., 2017, S. 97). Werte nahe 1 treten auf, wenn bei reflektiven Konstrukten Indikatoren gleich oder synonym formuliert und somit semantisch redundant sind. Dies kann sich aufgrund von stark korrelierten Fehlertermen nachteilig auf die Inhaltsvalidität von Konstrukten auswirken (Drolet & Morrison, 2001; Hayduk & Littvay, 2012). Werte unter 0,60 deuten auf eine geringe interne Konsistenz der Indikatoren eines Konstruktes hin.

Während Cronbachs Alpha die interne Konsistenz der Indikatoren tendenziell unterschätzt, wird diese bei der Composite-Reliabilität eher überschätzt. Idealerweise liegen beide Werte im akzeptablen Bereich, also zwischen 0,6 und 0,9. Der wahre Wert für die interne Konsistenz dürfte aber zwischen den beiden Maßen liegen. Wir berichten beide Maße, insbesondere da *Cronbachs Alpha* auch abseits PLS-SEM sehr bekannt ist und somit eine gute Vergleichbarkeit mit anderen Studien bietet.

Als zweites Kriterium für die Reliabilität der Indikatoren untersuchen wir die *Konvergenzvalidität* oder auch *Indikatorreliabilität*. Dazu betrachten wir die Ladungen der Indikatoren auf das zugehörige Konstrukt. Alle Indikatoren eines Konstruktes sollten für Konvergenzvalidität mindestens 50 % der Varianz des zugehörigen Konstruktes erklären. Dies ist der Fall, wenn die Ladungen aller Indikatoren eines Konstruktes mindestens einen Wert von 0,708 besitzen, wobei auch Werte von 0,70 noch als akzeptabel angesehen werden. Liegt eine Ladung unter dem Wert von 0,70 und über 0,40 so sollte eine Entfernung des Indikators aus dem Modell in Betracht gezogen werden. Dies erfordert jedoch eine Abwägung, ob die Inhaltsvalidität dadurch weiterhin gegeben ist, also ob die Indikatoren weiterhin das Konstrukt vollständig abdecken. Ist dies der Fall, sollte die Löschung dennoch nur durchgeführt werden, wenn dadurch die Werte für Cronbachs Alpha und der Composite-Reliabilität nicht die Grenzwerte über- beziehungsweise unterschreiten. Bleiben die Werte im akzeptablen Bereich, sollten die Indikatoren aus dem Modell entfernt werden. Bei Ladungen unterhalb von 0,40 sollten Indikatoren immer entfernt werden (Bagozzi, Yi & Phillips, 1991; Hair, Ringle & Sarstedt, 2011).

Ein weiteres Maß für die Konvergenzvalidität ist die durchschnittlich erfasste Varianz (AVE) eines Konstruktes. Die AVE ist wie folgt definiert (Hair et al., 2017, S. 99):

$$AVE = \frac{\sum_i l_i^2}{n}$$

Die AVE sollte mindestens einen Wert von 0,50 besitzen (Hair et al., 2017, S. 99). Dies bedeutet, dass das Konstrukt mindestens die Hälfte der Varianz seiner Indikatoren erklärt. Haben alle Indikatorladungen einen Wert von mindestens 0,708, so beträgt die AVE stets mindestens 0,50, wie nachfolgend gezeigt:

$$AVE = \frac{\sum_i l_i^2}{n} \geq \frac{n \cdot 0,708^2}{n} \geq 0,50$$

Unterschreiten einige Indikatoren des Konstruktes den Wert von 0,708, sollte für die Konvergenzvalidität die AVE des Konstruktes mindestens einen Wert von 0,50 aufweisen. Dies muss für alle reflektiv gemessenen Konstrukte mit mehr als einem Indikator der Fall sein, damit Konvergenzvalidität angenommen werden darf (Hair et al., 2017, S. 99).

Das dritte Kriterium zur Untersuchung des reflektiv spezifizierten Messmodells ist die *Diskriminanzvalidität*. Diese beschreibt ob die hypothetisierten Konstrukte sich empirisch

unterscheiden und somit unterschiedliche Konzepte messen (Hair et al., 2017, S. 99ff). Zur Untersuchung der Diskriminanzvalidität gibt es drei Ansätze:

- Analyse der Kreuzladungen
- Fornell-Larcker-Kriterium
- Heterotrait-Monotrait-Verhältnis

Die Analyse der Kreuzladungen ist ein naheliegendes Verfahren. Dieses vergleicht die Ladungen der Indikatoren auf das zugehörige Konstrukt mit den Korrelationen zu den anderen Konstrukten, den Kreuzladungen (Hair et al., 2017, S. 99f). Die Ladungen der Indikatoren auf das zugehörige Konstrukt sollten höher sein als alle Kreuzladungen. Hierfür wird eine Tabelle der Ladungen und Kreuzladungen erstellt und die Einträge verglichen. Eine Spalte der Tabelle enthält alle Ladungen und Kreuzladungen eines Konstruktes; eine Zeile der Tabelle enthält diese für einen Indikator. Die Analyse der Kreuzladungen wird häufig zur Analyse der Diskriminanzvalidität verwendet. Gibt es im Modell jedoch eine perfekte Korrelation zwischen zwei Konstrukten, so werden Probleme bezüglich der Diskriminanzvalidität nicht korrekt erkannt (Henseler, Ringle & Sarstedt, 2015).

Das Fornell-Larcker-Kriterium vergleicht die Quadratwurzel der AVE eines Konstruktes mit dessen Korrelationen zu allen anderen Konstrukten (Fornell & Larcker, 1981). Hierfür wird eine Tabelle erstellt mit den Korrelationen (Hair et al., 2017, S. 100f). Auf der Diagonalen wird die Quadratwurzel der AVE eingetragen. Ist die Quadratwurzel der AVE eines Konstruktes größer als die Korrelationen zu allen anderen Konstrukten, so kann Diskriminanzvalidität angenommen werden. Auch das Fornell-Larcker-Kriterium wird häufig verwendet zur Analyse der Diskriminanzvalidität. Sind allerdings alle Indikatorladungen relativ ähnlich, so werden Probleme mit der Diskriminanzvalidität nicht zuverlässig erkannt (Henseler et al., 2015).

Aufgrund der bekannten Probleme der beiden vorgenannten Ansätze zur Erkennung von Problemen bei der Diskriminanzvalidität wird in neueren Studien zusätzlich das Heterotrait-Monotrait-Verhältnis (HTMT) für alle Kombinationen aus zwei Konstrukten untersucht (Henseler et al., 2015). Hierfür wird zunächst der Mittelwert der Korrelationen zwischen Indikatoren unterschiedlicher Konstrukte gebildet (Between-Trait-Korrelationen). Dieser wird durch das geometrische Mittel der Mittelwerte der Korrelationen der Indikatoren innerhalb der beiden Konstrukte (Within-Trait-Korrelationen) geteilt. Ein HTMT-Wert über 0,90 bei konzeptionell ähnlichen Konstrukten und 0,85 bei eher unterschiedlichen Konstrukten deuten auf Probleme bei der Diskriminanzvalidität hin. Zudem sollte mittels Bootstrapping das Konfidenzintervall für den HTMT-Wert untersucht werden. Beinhalten die Konfidenzintervalle für alle HTMT-Werte jeweils nicht die 1, so kann Diskriminanzvalidität angenommen werden. Obwohl der HTMT Ansatz den anderen Ansätzen überlegen ist, sollten dennoch immer alle drei Verfahren angewendet werden, da es sich bei den ersten beiden Ansätzen um etablierte Standards handelt (Hair et al., 2017, S. 104).

Tabelle 2 fasst die Schritte und Kriterien zur Evaluation eines reflektiv spezifizierten Messmodells bei PLS-SEM zusammen.

Modellaspekt	Kriterium
Interne-Konsistenz Reliabilität	Bewertung anhand der Richtlinien für Cronbachs Alpha Zufriedenstellend: $0,90 \geq \alpha \geq 0,70$ Akzeptabel: $0,70 \geq \alpha \geq 0,60$ Problematisch: $\alpha > 0,90$ oder $\alpha < 0,60$
	Bewertung anhand der Richtlinien für die Composite-Reliabilität Zufriedenstellend: $\alpha \geq 0,70$ Akzeptabel: $0,70 \geq \alpha \geq 0,60$
Konvergenzvalidität	Bewertungen der Indikatorladungen l_i für Indikatorreliabilität Zufriedenstellend: $l_i \geq 0,70$ Prüfbedürftig: $0,70 > l_i \geq 0,40$ Problematisch: $l_i < 0,40$
	AVE aller Konstrukte $\geq 0,50$
Diskriminanzvalidität	Ladungen sind größer als alle Kreuzladungen anhand der Kreuzladungstabelle
	Fornell-Larcker-Kriterium: Quadratwurzel der AVE eines Konstruktes ist größer als alle Korrelationen zu anderen Konstrukten
	Bewertung der HTMT-Verhältnisse anhand der Richtlinien HTMT für ähnliche Konstrukte $\leq 0,90$ HTMT für unterschiedlichere Konstrukte $\leq 0,85$ Bootstrapping Konfidenzintervall für HTMT enthält die 1 nicht

Tabelle 2. Evaluationskriterien eines reflektiv spezifizierten Messmodells bei PLS-SEM

Quelle: Eigene Darstellung

4.2.6 Evaluation formativ spezifizierter Messmodelle

Wir beschreiben nun die Evaluation formativer Messmodelle (Hair et al., 2017, S. 120ff). Im ersten Schritt der Evaluation ist die *Konvergenzvalidität* formativ spezifizierter Messmodelle zu prüfen. Hierfür ist es erforderlich, dass zu jedem formativ gemessenen Konstrukt auch eine reflektive Messung desselben Konstruktes erhoben wird. Die beiden Messungen werden dann mittels Redundanzanalyse (Chin, 1998) untersucht. Dazu werden die beiden Konstrukte in ein eigens für die Redundanzanalyse erstelltes Modell eingefügt und miteinander verbunden wobei das formative Konstrukt das reflektive Konstrukt vorhersagt. Für Konvergenzvalidität ist ein R^2 -Wert für das reflektive Konstrukt von mindestens 0,50 als Grenzwert vorgegeben. Dies entspricht einem Pfadkoeffizienten zwischen den beiden Konstrukten von 0,70.

Zur reflektiven Messung des Konstruktes können etablierte Skalen mit einem oder mehreren Items verwendet werden (Hair et al., 2017, S. 122f). Zu beachten ist jedoch, dass redundante Messungen von Konstrukten mit vielen Indikatoren einen Fragebogen sehr umfangreich werden lassen. Lange Fragebögen schrecken Probanden ab und können zu vorzeitig abgebrochenen Umfragen führen. Zudem führen zu lange und monotone Fragebögen zur Ermüdung der Probanden, was zu Flüchtigkeitsfehlern bei den Antworten oder fehlenden

Werten führen kann. Alternativ können auch globale Items verwendet werden, die den Kern eines Konstruktes zusammenfassen (Sarstedt, Wilczynski & Melewar, 2013). Die Verwendung von globalen Items sollte sich aber auf die Verwendung in der Redundanzanalyse beschränken und ist ansonsten nicht empfehlenswert (Hair et al., 2017, S. 122f).

Im zweiten Schritt zur Evaluation formativ spezifizierter Messmodelle untersuchen wir die Indikatoren auf *Kollinearität* (Hair et al., 2017, S. 123ff). Hierzu berechnen wir den Varianzinflationsfaktor (VIF). VIF ist ein Maß für die Erhöhung des Standardfehlers eines Schätzers durch Kollinearität (Hair et al., 2017, S. 125). Bei vierfacher VIF verdoppelt sich der Standardfehler durch die Kollinearität. VIF-Werte über fünf deuten auf Kollinearitätsprobleme hin. Hohe VIF-Werte reduzieren die Wahrscheinlichkeit, dass die äußeren Gewichte der Indikatoren als signifikant erkannt werden.

Die *Prüfung der äußeren Gewichte* auf Signifikanz und Relevanz führen wir im letzten Schritt der Evaluation formativ spezifizierter Messmodelle durch (Hair et al., 2017, S. 127ff). Mittels Bootstrapping ermitteln wir die *t*-Werte, *p*-Werte und Konfidenzintervalle für die Gewichte. Hierbei gilt es zu beachten, dass sich der Wert eines Konstruktes aus einer Linearkombination des Gewichtes mit dem standardisierten Indikatorwert zusammensetzt. Eine hohe Anzahl von Indikatoren für ein Konstrukt führt daher zu geringen oder sogar nicht-signifikanten Gewichten. Größere Konstrukte sollten auf mehrere Konstrukte aufgeteilt werden insofern dies konzeptionell möglich ist (Cenfetelli & Bassellier, 2009). Dies kann beispielsweise auch mit einem Konstrukt höherer Ordnung erfolgen. Die erstellten Teilstrukturen werden dabei mit dem Konstrukt höherer Ordnung verbunden, der alle Indikatoren enthält (Hair et al., 2017, S. 127ff).

Idealerweise sind im Messmodell alle äußeren Gewichte signifikant. Ist dies nicht der Fall, sollte die Ladung des Indikators mit nicht-signifikantem Gewicht geprüft werden (Hair et al., 2017, S. 129ff). Ist die Ladung des Indikators größer oder gleich 0,5, sollte der Indikator aufgrund seines absoluten Beitrages zum Konstrukt nicht entfernt werden. Ist die Ladung des Indikators jedoch kleiner als 0,5, gibt es keine empirische Unterstützung für den Verbleib des Indikators im Modell. Daher sollte der Indikator aus dem Modell entfernt werden. Tabelle 3 fasst die Schritte und Kriterien zur Evaluation eines formativ spezifizierten Messmodells bei PLS-SEM zusammen.

Modellaspekt	Kriterium
Konvergenzvalidität	Redundanzanalyse R^2 des reflektiv gemessenen Konstruktes $\geq 0,50$ Ladung zwischen reflektiv gemessenem Konstrukt und formativ gemessenem Konstrukt $\geq 0,70$
Kollinearität	VIF-Werte ≤ 5
Gewichte der Indikatoren	Signifikantes Gewicht oder Ladung $\geq 0,50$

Tabelle 3. Evaluationskriterien eines formativ spezifizierten Messmodells bei PLS-SEM

Quelle: Eigene Darstellung

4.2.7 Evaluation des Strukturmodells

Nach der Evaluation des Messmodells, erfolgt die Evaluation des Strukturmodells. Die Evaluation des Strukturmodells erfolgt wie beim Messmodell anhand mehrerer Kriterien mit einem Fokus auf der Prognosefähigkeit des Modells (Hair et al., 2017, S. 164ff). Dies ist erforderlich, da es kein etabliertes globales Kriterium zur Modellgüte des Strukturmodells bei PLS-SEM gibt. Aufgrund der unterschiedlichen Ansätze von CB-SEM und PLS-SEM können auch nicht einfach die Modellgütekriterien der CB-SEM auf PLS-SEM übertragen werden.

Zur Untersuchung des Strukturmodells wird dieses auf Kollinearität geprüft sowie die Relevanz und statistische Signifikanz der Pfadkoeffizienten analysiert. Anschließend werden die Bestimmtheitsmaße R^2 , die f^2 -Effektstärken, die Prognosevarianzen Q^2 und die q^2 -Effektstärken bestimmt. Die Werte für die Analysen des Strukturmodells werden neben der PLS-SEM Berechnung auch durch Bootstrapping und Blindfolding gewonnen, bei denen es sich um nicht-parametrische Verfahren handelt. Die Analyseschritte werden im Folgenden genauer erläutert.

Im ersten Schritt der Evaluation des Strukturmodells untersuchen wir die *Kollinearität* zwischen den Konstrukten mittels des VIF (Hair et al., 2017, S. 167f). Für die Evaluation des Strukturmodells werden für jedes Konstrukt die inneren VIF-Werte zwischen dessen Treiberkonstrukten ermittelt. Treiberkonstrukte sind alle Konstrukte, die ein Zielkonstrukt beeinflussen, von denen also ein Pfeil im Strukturmodell zum Zielkonstrukt zeigt. Im Beispiel in Abbildung 15 sind Y1 und Y2 die Treiberkonstrukte für Y3. VIF-Werte über fünf deuten auf Kollinearität hin.

Im nächsten Schritt wird die *statistische Signifikanz der Pfadkoeffizienten* im Strukturmodell mittels Bootstrapping untersucht (Hair et al., 2017, S. 168ff). Dadurch erhalten wir die empirischen t -Werte und p -Werte für die Pfadkoeffizienten. Als kritischen Wert für die t -Werte definieren wir 1,96, das einem Signifikanzniveau von 0,05 bei einem zweiseitigen t -Test entspricht. Dies bedeutet, dass wir einen Pfadkoeffizienten mit einer Wahrscheinlichkeit von 5 % fälschlicherweise als signifikant erklären. Übertragen auf die Hypothese, die hinter dem Pfadkoeffizienten steht, bedeutet dies, dass wir fälschlicherweise die Nullhypothese ablehnen. Zusätzlich berichten wir die Bootstrapping-Konfidenzintervalle für die Pfadkoeffizienten, da dieses den plausiblen Wertebereich eines Pfadkoeffizienten aufzeigt.

Für das Bootstrapping verwenden wir das Bias-korrigiertes und accelerated (BCa) Bootstrapping, das Bias und Schiefe der Bootstrap-Verteilung bei der Berechnung der Konfidenzintervalle berücksichtigt (Henseler et al., 2009). Für ein stabiles Ergebnis verwenden wir die für PLS-SEM empfohlene Anzahl von 5.000 Subsamples (Hair et al., 2017, S. 132). Für die Berechnung der Konfidenzintervalle verwenden wir das definierte Signifikanzniveau von 0,05 für die Durchführung eines zweiseitigen Signifikanztestes.

Neben den statischen Tests der Pfadkoeffizienten untersuchen wir zudem deren *Relevanz*. Dies erfolgt analog zu standardisierten Beta-Koeffizienten einer OLS Regression (Hair et al., 2017, S. 169f): Eine Erhöhung des Treiberkonstruktes um eine Standardabweichung führt zu einer Erhöhung des Zielkonstruktes um den Wert des zugehörigen Pfadkoeffizienten ceteris paribus. Somit zeigt der Vergleich von Pfadkoeffizienten und deren Konfidenzintervalle die Höhe des

Einflusses auf das Zielkonstrukt. Weiterhin berichten wir den direkten, indirekten und totalen Effekt, um auch mediierende Effekte aufzuzeigen.

Schritt 3 der Evaluation des Strukturmodells ist die Ermittlung der *Bestimmtheitsmaße* R^2 für die endogenen Konstrukte (Hair et al., 2017, S. 170ff). Dieses gibt den Anteil der Varianz an, der von den Treiberkonstrukten beim Zielkonstrukt erklärt wird. Schwellwerte für R^2 hängen von vielen verschiedenen Faktoren ab. Daher sollte das R^2 im Kontext von bisherigen Forschungsvorhaben bewertet werden. In der Marketing Forschung haben sich beispielsweise Schwellwerte von 0,75 (substantiell), 0,50 (moderat) und 0,25 (schwach) etabliert (Hair et al., 2011; Henseler et al., 2009).

Auch wenn das R^2 das am weitesten verbreitete Gütekriterium für das Strukturmodell ist, so sind Modelle mit höherem R^2 nicht notwendigerweise besser (Hair et al., 2017, S. 171f). Üblicherweise führt das Hinzufügen von Treiberkonstrukten zu einem höheren R^2 im Zielkonstrukt, auch wenn die neuen Treiberkonstrukte nur nicht-signifikante Pfadkoeffizienten zum Zielkonstrukt aufweisen. Generell werden daher eher einfache Modelle mit hohem R^2 von Forschern bevorzugt. Das adjustierte Bestimmtheitsmaß R^2_{adj} berücksichtigt diesen Aspekt und gewichtet R^2 mit der Anzahl der latenten Variablen im Modell k sowie der Anzahl der Beobachtungen n . R^2_{adj} ist wie folgt definiert:

$$R^2_{adj} = 1 - (1 - R^2) \cdot \frac{n - 1}{n - k - 1}$$

Neben den Pfadkoeffizienten deuten auch die *Effektstärken* f^2 auf den Einfluss von exogenen Konstrukten hin (Hair et al., 2017, S. 173f). Für die Berechnung von f^2 wird der R^2 -Wert eines endogenen Konstruktes einmal mit (R_i^2) und einmal ohne ($R_{i'}^2$) ein zugehöriges exogenes Konstrukt berechnet. Dazu wird der PLS-SEM Algorithmus einmal mit und einem ohne dem exogenen Konstrukt ausgeführt. Die f^2 Effektstärke für ein exogenes Konstrukt i wird dann anhand folgender Formel ermittelt:

$$f_i^2 = \frac{R_i^2 - R_{i'}^2}{1 - R_i^2}$$

Entsprechend der Richtlinien für die Interpretation von Effektstärken werden f^2 Werte über 0,35 als großer Effekt, Werte zwischen 0,35 und 0,15 als mittlere Effekte und Werte kleiner als 0,15 als kleine Effekte bezeichnet (Cohen, 1988). Effektstärken unter 0,02 deuten darauf hin, dass von einem exogenen Konstrukt kein Effekt auf das zugehörige endogene Konstrukt ausgeübt wird.

Mit dem R^2 -Wert wird die In-Sample-Prognosefähigkeit gemessen (Rigdon, 2012; Sarstedt, Ringle, Henseler & Hair, 2014). Daher ist es wichtig, auch die *Out-of-Sample-Prognosefähigkeit* zur Bewertung der Prognoserelevanz zu ermitteln (Hair et al., 2017, S. 174ff). Prognosefähigkeit beschreibt, wie gut das Modell die Werte für ein endogenes Konstrukt vorhersagt anhand der zugehörigen exogenen Variablen. Bei In-Sample-Prognosefähigkeit werden für die Prognose dieselben Daten verwendet, die auch zur Modellschätzung verwendet wurden. Bei Out-of-Sample-Prognosefähigkeit werden mittels

Blindfolding Daten zur Modellschätzung ausgelassen, mit denen dann die Vorhersage des Wertes eines endogenen Konstruktes getestet wird. Hierfür wird der Stone-Geisser Q^2 -Wert ermittelt (Geisser, 1974; Stone, 1974).

Für die Blindfolding-Prozedur muss die Auslassungsdistanz D spezifiziert werden, die definiert, dass jeder D -te Wert bei den Indikatoren der endogenen Konstrukte bei der Modellberechnung ausgelassen wird (Chin, 1998; Henseler et al., 2009; Tenenhaus, Vinzi, Chatelin & Lauro, 2005). Für die Berechnung von Q^2 werden dann die vorhergesagten Werte der Indikatoren der endogenen Konstrukte mit den tatsächlichen Werten verglichen (Hair et al., 2017, S. 174ff). Das Blindfolding wird D -mal wiederholt, sodass alle Daten einmal ausgelassen und zur Prognose verwendet wurden. Weiterhin wird das Blindfolding jeweils für alle endogenen Konstrukte durchgeführt, die reflektiv oder mittels Single-Item gemessen wurden.

Empfohlene Werte für die Auslassungsdistanz liegen zwischen 5 und 10 wobei eine Division der Anzahl der Beobachtungen durch die Auslassungsdistanz nicht ganzzahlig sein darf (Sarstedt et al., 2014). Mit den durch Blindfolding berechneten Differenzen zwischen vorhergesagten und tatsächlichen Werten der endogenen Konstrukte kann nun der Q^2 -Wert für jedes endogene Konstrukt ermittelt werden. Ist der Q^2 -Wert positiv, so besitzt das Modell Prognoserelevanz, also Out-of-Sample Prognosefähigkeit. Werte von 0 oder weniger deuten auf einen Mangel der Prognoserelevanz hin.

Der letzte Schritt für die Evaluation des Strukturmodells ist die Berechnung der q^2 -Effektstärken. Analog zu den f^2 -Effektstärken, die auf R^2 basieren, werden die q^2 -Effektstärken anhand des Stone-Geisser Q^2 -Wertes berechnet indem jeweils einzelne exogene Konstrukte bei der Berechnung von Q^2 ausgeschlossen werden. Die q^2 -Effektstärke für ein exogenes Konstrukt i wird somit entsprechend folgender Formel ermittelt:

$$q_i^2 = \frac{Q_i^2 - Q_{i'}^2}{1 - Q_i^2}$$

Die Schritte und Kriterien zur Modellevaluation bei PLS-SEM sind in Tabelle 4 zusammengefasst.

Modellaspekt	Kriterium
Kollinearität	VIF-Werte ≤ 5
Pfadkoeffizienten	BCa-Bootstrapping mit 5.000 Subsamples durchführen
	Signifikanz der Pfadkoeffizienten aus Bootstrapping prüfen
	Konfidenzintervalle für Pfadkoeffizienten aus dem Bootstrapping enthalten nicht die 0
	Untersuchung und Interpretation der direkten, indirekten und totalen Effekte
Bestimmtheitsmaß R^2	Vergleich von R^2 mit bisherigen Forschungsergebnissen
	Faustregel zur Interpretation von R^2
	Substanzielle Prognoseleistung: $R^2 \geq 0,75$
	Moderate Prognoseleistung: $0,75 > R^2 \geq 0,50$
Schwache Prognoseleistung: $0,50 > R^2 \geq 0,25$	
	Berechnung der adjustierten Bestimmtheitsmaße für alle endogenen Konstrukte
f^2 -Effektstärken	Bewertung anhand der Richtlinien für Effektstärken
	Großer Effekt: $f^2 \geq 0,35$
	Mittlerer Effekt: $0,35 > f^2 \geq 0,15$
	Kleiner Effekt: $0,15 > f^2 \geq 0,02$
	Kein Effekt: $f^2 < 0,02$
Prognoserelevanz	Blindfolding mit Auslassungsdistanz D zwischen 5 und 10, wobei das Ergebnis der Division der Anzahl der Beobachtungen durch D nicht ganzzahlig sein darf
	Stone-Geisser Q^2 aus Blindfolding für alle endogenen Konstrukte > 0
q^2 -Effektstärken	Bewertung anhand der Richtlinien für Effektstärken wie bei f^2 -Effektstärken

Tabelle 4. Evaluationskriterien des Strukturmodells bei PLS-SEM

Quelle: Eigene Darstellung

5 Studie 1: Modell zur Prognose der Akzeptanz von Innovationen

Im Rahmen der ersten von vier Studien dieser Dissertation wird ein Akzeptanzmodell zur Prognose der Akzeptanz von Innovationen entwickelt und anhand des autonomen Fahrens evaluiert. Autonomes Fahren steht dabei stellvertretend für Technologien, die bereits in der Öffentlichkeit diskutiert werden, aber noch nicht zur Erprobung für die Allgemeinheit verfügbar sind. Somit ermöglicht das Akzeptanzmodell bereits in einer frühen Phase der Entwicklung, die individuelle Technologieakzeptanz zu prognostizieren und zu erklären. Die so gewonnenen Einsichten können in den Entwicklungsprozess einfließen und die Akzeptabilität der neuen Technologie erhöhen. Hierzu wird eine Online-Umfrage mittels eines strukturierten Fragebogens durchgeführt. Mit den erhobenen Daten evaluieren wir das von uns entwickelte Modell zur Prognose der Akzeptanz von neuen Technologien und vergleichen dieses mit dem UTAUT Modell.

Im folgenden Abschnitt 5.1 beschreiben wir Motivation und Ziele dieser Studie. In Abschnitt 5.2 leiten wir das Forschungsmodell und die darin enthaltenen Hypothesen her. Im darauffolgenden Abschnitt 5.3 operationalisieren wir die Konstrukte für den Fragebogen und beschreiben unser methodisches Vorgehen. In Abschnitt 5.4 berichten wir die Ergebnisse der Studie, die wir im darauffolgenden Abschnitt 5.5 diskutieren. Wir beenden dieses Kapitel mit einem Fazit in Abschnitt 5.6.

5.1 Motivation

Mit den in Abschnitt 2.2 vorgestellten Akzeptanzmodellen wie UTAUT werden üblicherweise bestehende Systeme und insbesondere spezialisierte Unternehmenssysteme untersucht (Williams, Rana & Dwivedi, 2015). Die Akzeptanzmodelle liefern somit wichtige Erkenntnisse zur Akzeptanz dieser Systeme, indem sie die zentralen Determinanten der Akzeptanz quantifizieren. Wird ein System beispielsweise nur wenig genutzt, so kann anhand einer Befragung basierend auf UTAUT ermittelt werden, ob die Leistung des Systems ungenügend ist (Leistungserwartung), die Bedienung des Systems zu umständlich ist (Aufwandserwartung), das soziale Umfeld mit der Nutzung nicht einverstanden ist (soziale Einflüsse) oder ob es an Unterstützung bei der Nutzung des Systems (unterstützende Bedingungen) mangelt. Auch eine Kombination der Faktoren ist möglich. Zudem können auch Individuen mit geringer Akzeptanz identifiziert und speziell adressiert werden, insofern die Befragung nicht anonym erfolgt.

Dennoch ist ein Modell stets nur ein Abbild eines Ausschnittes der Realität, der im Hinblick auf Zielgruppe, Zweck und Zeit gewählt wird (Krcmar, 2015, S. 31). Im Kontext von Akzeptanzmodellen bedeutet dies, dass immer nur ein Teil der akzeptanzrelevanten Aspekte für einen bestimmten Zweck und einem bestimmten Zeitpunkt mit einem Modell untersucht werden können. Sobald sich der Zweck ändert oder ein anderer Zeitpunkt gewählt wird, muss also geprüft werden, ob das Modell noch die relevanten Aspekte der Realität korrekt abbildet.

Mit dem Modell zur Prognose der Akzeptanz von Innovationen können wir eine Erhebung der Akzeptanz bereits in einer frühen Phase im Innovationsprozess durchführen. Der Zweck des Modells ist im Gegensatz zu klassischer Technologieakzeptanzforschung nicht die Messung

der Akzeptanz eines bereits verfügbaren Informationssystems im Unternehmenskontext, sondern die Prognose der Akzeptanz einer noch nicht marktreifen Erfindung für private Endanwender. Die Erkenntnisse aus den erhobenen Daten können in den Entwicklungsprozess der Innovation einfließen, um deren Akzeptanz bei der Markteinführung zu erhöhen. Wir zeigen somit einen neuen Forschungskontext für die Akzeptanzforschung auf, was zu neuen Einsichten führen und zur Erweiterung von Theorien beitragen kann (Alvesson & Kärreman, 2007).

Für diesen neuen Forschungskontext erweitern wir das UTAUT Modell um zwei zusätzliche Konstrukte, Einstellung zur und Angst vor der Nutzung, sowie weitere Wirkbeziehungen zwischen den Konstrukten. Die Einstellung zur Nutzung ist ein wichtiger Prädiktor für die tatsächliche Nutzung einer neuen Technologie (Dwivedi, Rana, Jeyaraj, Clement & Williams, 2019), wie wir auch im folgenden Abschnitt erläutern werden. Verschiedene Studien zeigen, dass die Einstellung zur Nutzung insbesondere auch im Kontext autonomer Fahrzeuge von Relevanz ist (Becker & Axhausen, 2017). Auch die Angst vor der Nutzung ist ein häufig untersuchter Einflussfaktor der Akzeptanz, der aber im UTAUT Modell nicht enthalten ist (Lee, Kozar & Larsen, 2003; Venkatesh et al., 2003; Williams et al., 2015). Somit leisten wir mit dieser Studie einen Beitrag zur Akzeptanzforschung und zur Untersuchung der Akzeptanz von autonomen Fahrzeugen.

5.2 Forschungsmodell

Das in dieser Studie vorgestellte Modell zur Prognose der Akzeptanz von Innovationen basiert auf dem UTAUT Modell (Venkatesh et al., 2003), welches wir in Abschnitt 2.2.3 vorgestellt haben. Dieses besagt, dass *Leistungserwartung*, *Aufwandserwartung* und *soziale Einflüsse* die *Nutzungsintention* beeinflussen. Die *Nutzungsintention* beeinflusst schließlich die *tatsächliche Nutzung* des Systems. Da bei unserem Untersuchungsgegenstand noch keine Nutzung möglich ist, haben wir das Konstrukt der tatsächlichen Nutzung entfernt. Das Konstrukt der *unterstützenden Bedingungen* beeinflusst entsprechend UTAUT nur die tatsächliche Nutzung. Daher haben wir die unterstützenden Bedingungen im Modell zur Prognose der Akzeptanz von Innovationen ebenfalls entfernt.

Die *Leistungserwartung* ist Bestandteil vieler Akzeptanzmodelle und beschreibt die Nützlichkeit eines Systems (Davis, 1989). Im TAM Modell wird dieses Konstrukt daher auch als wahrgenommene Nützlichkeit bezeichnet und entspricht der Definition von Leistungserwartung im UTAUT Modell. Die Leistungserwartung ist definiert als die Nützlichkeit eines Systems bezüglich der Ziele, die durch die Nutzung des Systems erreicht werden sollen (Venkatesh et al., 2003). Aufgrund der ursprünglichen Ausrichtung der Akzeptanzmodelle in der Wirtschaftsinformatik, wird dieses Konstrukt auch häufig mit einer Verbesserung der Arbeitsleistung eines Individuums definiert (Davis, 1989; Venkatesh et al., 2003). Entsprechend des UTAUT Modells formulieren wir folgende Hypothese:

H1: Je höher die Leistungserwartung einer neuen Technologie ist, desto höher ist die verhaltensbasierte Nutzungsintention für diese Technologie.

Neben der Leistungserwartung ist auch die *Aufwandserwartung* ein zentraler Bestandteil vieler Akzeptanzmodelle und geht ebenfalls auf das TAM Modell zurück (Davis, 1989; Venkatesh et

al., 2003). Die Aufwandserwartung wird üblicherweise positiv operationalisiert, sodass ein hoher Wert für die Aufwandserwartung einer hohen Benutzerfreundlichkeit entspricht. Im TAM Modell ist die Aufwandserwartung als wahrgenommene Benutzerfreundlichkeit bezeichnet (Davis, 1989). Da die Menge an Aufwand, die ein Individuum bewältigen kann, begrenzt ist, kann ein System mit geringem Bedienaufwand in größerem Umfang genutzt werden. Wenn alle anderen Einflussfaktoren der Nutzung identisch sind, resultiert aus einem geringeren Bedienaufwand eine höhere Nutzung (Davis, 1989). Entsprechend dieses Zusammenhangs formulieren wir die folgende Hypothese:

H2: Je benutzerfreundlicher eine neue Technologie ist, desto höher ist die verhaltensbasierte Nutzungsintention für diese Technologie.

Das Konstrukt *soziale Einflüsse* geht auf das TRA Modell der Akzeptanzforschung zurück und wird darin als subjektive Norm bezeichnet (Fishbein & Ajzen, 1975). Es beschreibt den Einfluss bezüglich der Nutzung eines Systems, den für das Individuum wichtige andere Individuen ausüben. Der Einfluss wird in der Form ausgeübt, als dass sich das Ansehen des Individuums in dessen Wahrnehmung durch die Nutzung eines Systems ändert. Der Einfluss kann beispielsweise positiv sein, wenn mit der Nutzung des Systems Prestige verbunden ist und somit das Ansehen des Individuums verbessert wird. Der Einfluss ist hingegen negativ, wenn durch die Nutzung des Systems ein sozialer Abstieg befürchtet werden muss und das Ansehen des Individuums sinken würde. Wenn eine Verbesserung des eigenen Ansehens durch die Nutzung des Systems zu erwarten ist, steigt auch die Nutzungsintention. Dementsprechend formulieren wir folgende Hypothese:

H3: Je positiver der soziale Einfluss durch die Nutzung einer neuen Technologie ist, desto höher ist die verhaltensbasierte Nutzungsintention für diese Technologie.

Die *Angst vor der Nutzung* ist eines der am häufigsten untersuchten Konstrukte in TAM und UTAUT Studien, häufig in der Form von Angst vor Computern (Lee et al., 2003; Williams et al., 2015). Dennoch enthalten die etablierten Technologieakzeptanzmodelle dieses Konstrukt nicht, wie in Abschnitt 2.2 ersichtlich. Angst vor der Nutzung ist definiert als die Sorge oder Furcht, wenn die Möglichkeit besteht ein System zu nutzen (Lee et al., 2003). Insbesondere im Hinblick auf die Unsicherheit, die mit neuen Technologien verbunden ist, rechnen wir mit einem Einfluss der Angst vor der Nutzung auf die Nutzungsintention. Die Unsicherheit begründet sich bei neuen Technologien einerseits durch die Unsicherheit aufgrund der fehlenden Erprobungsmöglichkeiten wie in Abschnitt 2.3 erläutert, sowie andererseits durch unbekannte Risiken, wie in Abschnitt 2.4 erläutert. Wir formulieren daher die folgende Hypothese:

H4: Je größer die Angst vor der Nutzung einer Technologie ist, desto geringer ist die verhaltensbasierte Nutzungsintention für diese Technologie.

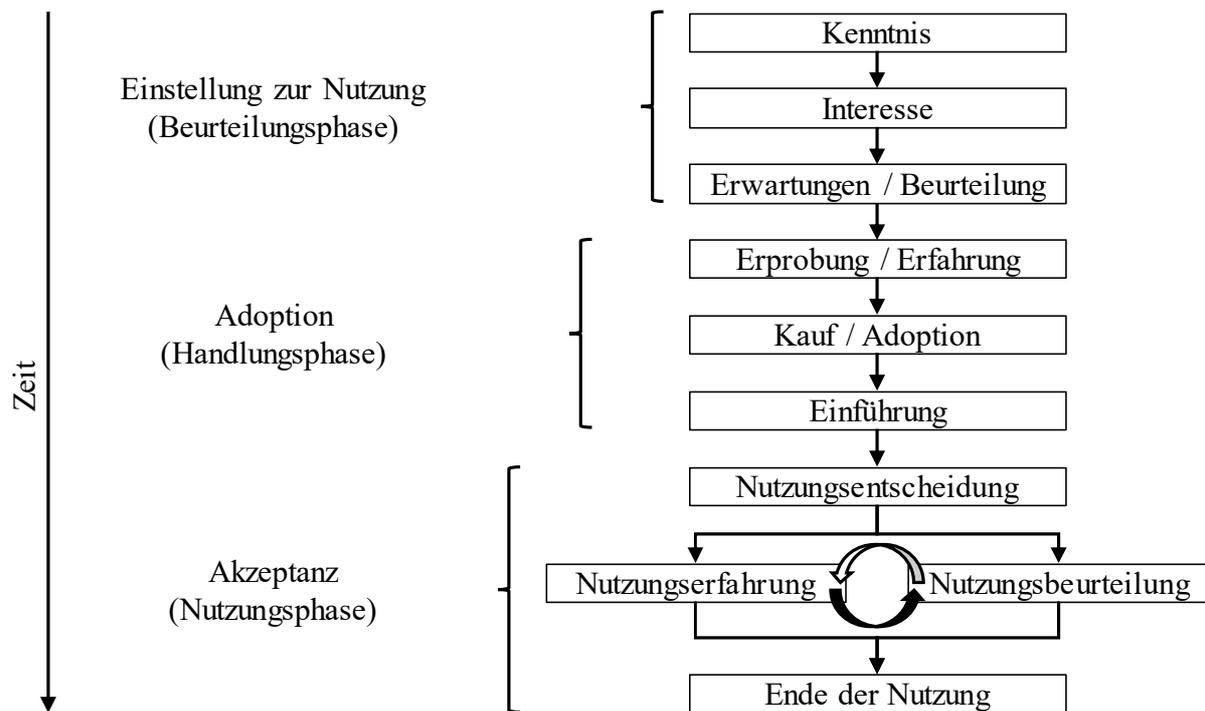


Abbildung 16: Phasen im Akzeptanzprozess

Quelle: In Anlehnung an Kollmann (2004, S. 140)

Eine positive *Einstellung zur Nutzung* ist in der frühen Phase der Diffusion von Innovationen eine entscheidende Vorbedingung für die Adoption und schließlich die Akzeptanz einer Innovation, wie in Abbildung 16 dargestellt (Kollmann, 2004). Sobald Individuen Kenntnis von einer neuen Technologie erhalten und dieses auch auf Interesse stößt, formen sich die Erwartungen in diese neue Technologie, sodass eine Beurteilung bereits in einem frühen Stadium möglich ist. Bei positiver Beurteilung erfolgt die Erprobung, bei der erstmals eigene Erfahrungen gebildet werden können. Vorher basiert die Einstellung nur auf den verfügbaren Informationen und Meinungen zur neuen Technologie. Somit ist bereits vor der öffentlichen Verfügbarkeit einer neuen Technologie die Erhebung der Einstellung zur Nutzung von zentraler Bedeutung.

Auch bei bereits verfügbaren Technologien ist die Nutzungseinstellung von zentraler Bedeutung. Schon im TRA Modell ist die Einstellung zur Nutzung eine Vorbedingung für die Akzeptanz (Fishbein & Ajzen, 1975). Im TAM wurde die Rolle der Nutzungseinstellung für die Akzeptanz übernommen (Davis et al., 1989). Obwohl UTAUT auf TRA und TAM basiert, ist dieser Zusammenhang in UTAUT nicht enthalten. Eine Metaanalyse von 162 Akzeptanzmodellen zeigt jedoch, dass die Einstellung zur Nutzung neben Leistungserwartung, Aufwandserwartung und sozialen Einflüssen ein zentraler Einflussfaktor der Akzeptanz ist (Dwivedi et al., 2019). Die Metaanalyse zeigt, dass der Einfluss der Nutzungseinstellung auf die tatsächliche Nutzung sogar stärker ist als die Nutzungsintention. Weiterhin mediiert die Einstellung zur Nutzung den Effekt von Leistungserwartung, Aufwandserwartung und sozialen Einflüssen auf die Nutzungsintention.

Aufgrund ihrer zentralen Rolle im Diffusionsprozess als auch aufgrund von neuen empirischen Erkenntnissen, enthält das von uns entwickelte Modell zur Prognose der Akzeptanz von Innovationen die Einstellung zur Nutzung sowohl als direkten Einflussfaktor der Nutzungsintention als auch als Mediator der Effekte auf die Nutzungsintention. Hieraus resultieren die folgenden Hypothesen:

H5: Je positiver die Einstellung zur Nutzung einer neuen Technologie ist, desto höher ist die verhaltensbasierte Nutzungsintention für diese Technologie.

H6: Je höher die Leistungserwartung einer neuen Technologie ist, desto positiver ist die Einstellung zur Nutzung für diese Technologie.

H7: Je benutzerfreundlicher eine neue Technologie ist, desto positiver ist die Einstellung zur Nutzung für diese Technologie.

H8: Je positiver der soziale Einfluss durch die Nutzung einer neuen Technologie ist, desto positiver ist die Einstellung zur Nutzung für diese Technologie.

H9: Je größer die Angst vor der Nutzung einer Technologie ist, desto negativer ist die Einstellung zur Nutzung für diese Technologie.

Die in diesem Abschnitt hergeleiteten Hypothesen bilden das Forschungsmodell zur Prognose der Akzeptanz von Innovationen, welches in Abbildung 17 dargestellt ist.

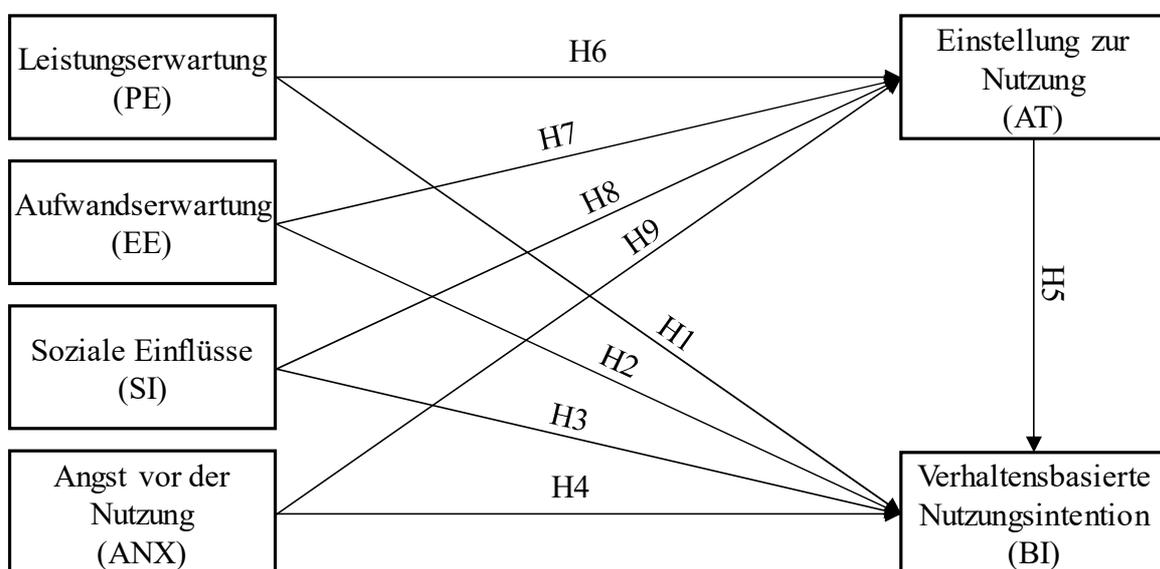


Abbildung 17: Modell zur Prognose der Akzeptanz von Innovationen

Quelle: Eigene Darstellung

5.3 Material und Methoden

Die im vorherigen Abschnitt beschriebenen Hypothesen prüfen wir mittels eines strukturierten Fragebogens, wie in Abschnitt 4.1 erläutert. Der strukturierte Fragebogen wird in Form eines Online-Fragebogens an die Probanden verteilt. Hierfür nutzen wir die Software LimeSurvey. Die Probanden erhalten einen Link zur Umfrage per E-Mail mit der Bitte, die Umfrage auszufüllen. Zur Beantwortung der Fragen zur Akzeptanz autonomer Fahrzeuge dient eine Likert-Skala mit fünf Punkten von 1 = „Fully disagree“, was einer vollständigen Ablehnung der Aussage entspricht, bis 5 = „Fully agree“, also einer vollständigen Zustimmung. Die dazwischenliegenden Skalenelemente wurden nicht benannt, damit eine äquidistante Verteilung der Antwortoptionen angenommen werden kann. Um Reihenfolgeeffekte zu vermeiden, wurde die Fragenreihenfolge für die Fragen bei jedem Probanden zufällig beim Start der Umfrage festgelegt. Die Umfrage enthält neben den Fragen zu Akzeptanz auch Fragen zu Alter, Geschlecht, Fahrerfahrung und Autobesitz. Der Fragebogenteil zur Akzeptanz von Studie 1 befindet sich in Anhang A.

Wir messen die Konstrukte reflektiv mit jeweils mindestens vier Indikatoren, damit wir mit CB-SEM vergleichbare Ergebnisse erhalten (Hair et al., 2017, S. 24). Zukünftige konfirmatorische Studien, die das Modell zur Prognose der Akzeptanz von Innovationen verwenden, können dadurch auch mittels CB-SEM ausgewertet werden und erhielten mit dieser Studie vergleichbare Ergebnisse. Die Operationalisierung der Konstrukte erfolgt mittels etablierter Indikatoren, die theoretisch fundiert sind und bereits empirisch validiert wurden. Diese passen wir für den Anwendungsfall autonomer Fahrzeuge jeweils an. Die Operationalisierung basiert auf drei Studien (Carlsson, Carlsson, Hyvonen, Puhakainen & Walden, 2006; Martins et al., 2014; Venkatesh et al., 2003). Zur besseren Lesbarkeit sind die Konstrukte wie folgt abgekürzt:

- PE (Performance Expectancy) steht für die Leistungserwartung
- EE (Effort Expectancy) steht für die Aufwandserwartung
- SI (Social Influence) steht für Soziale Einflüsse
- ANX (Anxiety) steht für die Angst vor der Nutzung
- AT (Attitude) steht für die Einstellung zur Nutzung
- BI (Behavioral Intention) steht für die Nutzungsintention

Die erste Studie, die wir als Grundlage für die Operationalisierung der Konstrukte verwenden, ist die UTAUT Studie, in welcher acht verschiedene Akzeptanzmodelle miteinander verglichen werden (Venkatesh et al., 2003). In der UTAUT Studie sind alle Konstrukte enthalten, die in unserem Modell zur Prognose der Akzeptanz von Innovationen enthalten sind, also insbesondere AT und ANX. In der UTAUT Studie wurde die Akzeptanz von Unternehmenssystemen untersucht. Daher sind nicht alle Indikatoren direkt für autonome Fahrzeuge anwendbar, beispielsweise „OE7: *If I use the system, I will increase my chances of getting a raise.*“ (Venkatesh et al., 2003, S. 460), also ob der Proband sich durch die Nutzung des Systems bessere Chancen auf eine Gehaltserhöhung erhofft.

Die UTAUT Studie von Venkatesh et al. (2003) besteht aus drei separat voneinander durchgeführten Befragungen in drei Unternehmen. In allen drei Befragungen nahmen jeweils 215 Probanden teil. Bei separater Auswertung der Daten und ausschließlicher Berücksichtigung der direkten Effekte, wurden für BI R^2 -Werte von 0,40 (Befragung 1), 0,41 (Befragung 2) und 0,42 (Befragung 3) erreicht. Bei gemeinsamer Auswertung der Daten kann nur noch ein geringes R^2 von 0,31 erreicht werden. Erst durch Berücksichtigung aller Moderationseffekte, insbesondere PE x Geschlecht x Alter erhöht sich der R^2 -Wert bei der gemeinsamen Auswertung der Befragungen auf 0,76.

Die zweite Studie, die wir zur Operationalisierung der Konstrukte verwenden, beschäftigt sich mit der Akzeptanz neuer Mobilfunkdienste in Finnland (Carlsson et al., 2006). In dieser Studie sind ebenfalls alle Konstrukte enthalten, aber teilweise sehr spezifisch für den Anwendungsfall angepasst. Dies ist insbesondere bei ANX und AT der Fall, bei denen wir keine der Indikatoren direkt verwenden können. Beispielsweise lautet ein Indikator für die Einstellung der Nutzung „*I want my mobile device to be the latest model.*“, also ob der Proband stets das gerade aktuelle Mobilgerät besitzen möchte. In der Studie von Carlsson et al. (2006) wurden 157 Probanden befragt. Zum erreichten R^2 -Wert für BI wird keine Angabe in der Veröffentlichung gemacht.

Die dritte und neueste Studie wurde von Martins et al. (2014) durchgeführt und beschäftigt sich mit der Akzeptanz und Risikowahrnehmung von Onlinebanking. Der zugehörige Fragebogen enthält Fragen zu allen UTAUT Konstrukten aber nicht zu ANX und AT. Weiterhin wurde das ursprüngliche UTAUT Modell um die Risikowahrnehmung als Einflussfaktor für BI und PE ergänzt. Die Risikowahrnehmung wird von EE beeinflusst. An der Studie von Martins et al. (2014) haben 249 Probanden teilgenommen. Nur mit den UTAUT Konstrukten wird für BI ein R^2 -Wert von 0,52 erreicht, der sich unter Berücksichtigung der Risikowahrnehmung auf 0,56 verbessert. Mit allen Moderationseffekten wird ein R^2 von 0,56 (nur UTAUT) beziehungsweise 0,60 (UTAUT und Risikowahrnehmung) für BI erreicht.

In den folgenden Abschnitten 5.3.1 bis 5.3.6 erläutern wir die Operationalisierung der einzelnen Konstrukte von Studie 1 dieser Dissertation, basierend auf den drei in diesem Abschnitt erläuterten Studien.

5.3.1 Operationalisierung der Leistungserwartung (PE)

Für die strukturierte Befragung der Probanden haben wir PE entsprechend Tabelle 5 operationalisiert. Die Indikatoren PE1 und PE3 implizieren, dass es in einem autonomen Fahrzeug keinen Fahrer gibt. Das Fahrzeug fährt nach SAE Stufe 5 komplett selbstständig und gegebenenfalls sogar ohne Insassen, wie in Abschnitt 3.2 erläutert. Alle Insassen des Fahrzeuges können somit andere Aufgaben während der Fahrt erledigen, wie dies beispielsweise in öffentlichen Verkehrsmitteln bereits der Fall ist. So könnten beispielsweise auf dem Weg zur Arbeitsstätte bereits E-Mails gelesen und beantwortet oder der Tag vorab strukturiert werden. Neben den beruflichen Zwecken könnte die zusätzliche Zeit aber auch dafür verwendet werden, ein Buch zu lesen oder zu frühstücken. Durch das Wegfallen der Fahraufgabe erhöht sich somit die Gesamtproduktivität eines Individuums, das ansonsten selbst gefahren wäre.

Der Indikator PE2 befasst sich mit der Zeitersparnis durch autonomes Fahren. Diese resultiert einerseits daraus, dass durch autonome Fahrzeuge die Straßen effizienter genutzt werden können und man somit schneller zum Ziel kommt. Weiterhin wird keine Zeit für die Parkplatzsuche oder das Tanken des Fahrzeuges benötigt. Andererseits können im Fahrzeug Aufgaben während der Fahrt erledigt werden, die ansonsten vor oder nach der Fahrt erledigt werden müssten.

Auch der Indikator PE4 deckt zwei Aspekte ab. Einerseits wird erwartet, dass durch autonome Fahrzeuge die Anzahl der Verkehrsunfälle drastisch reduziert werden könnte, wie in den Abschnitten 2.4 und 3.3 erläutert. Autonome Fahrzeuge können unter Verwendung zahlreicher Sensoren und Kommunikationsmöglichkeiten mit anderen Fahrzeugen sowie Infrastruktur ihre Umwelt detailliert erfassen. Algorithmen steuern das Fahrzeug auf Basis dieser Informationen mit maschineller Präzision. Andererseits kann die Zeit während der Fahrt, beispielsweise zur Arbeitsstelle, genutzt werden, um sich auszuruhen oder sogar zu schlafen und somit die Leistungsfähigkeit zu erhöhen.

Nr.	Frage in Fragebogen	(Venkatesh et al., 2003)	(Carlsson et al., 2006)	(Martins et al., 2014)
PE1	I think that using autonomous driving would enable me to conduct other tasks more quickly.	Using the system enables me to accomplish tasks more quickly.	I am in real time since I carry a mobile device with me that is always connected to the network.	I think that using Internet Banking would enable me to conduct tasks more quickly.
PE2	In my opinion, I would save time by using autonomous cars.		I save time by using a mobile device.	
PE3	I think that using autonomous driving would increase my productivity.	Using the system increases my productivity.	Using a mobile device is flexible since I may use it anywhere. Using a mobile device is flexible since I may use it anytime.	I think that using Internet Banking would increase my productivity.
PE4	I think that using autonomous driving would improve my performance.			I think that using Internet Banking would improve my performance.

Tabelle 5: Operationalisierung von PE für Studie 1

Quelle: Eigene Darstellung

5.3.2 Operationalisierung der Aufwandserwartung (EE)

Das Konstrukt EE haben wir ebenfalls, wie in Tabelle 6 ersichtlich, anhand aller drei Studien operationalisiert. Auch wenn keine Details zur Benutzerschnittstelle von autonomen Fahrzeugen zum Zeitpunkt der Studiendurchführung bekannt sind, so ist dennoch intuitiv eine erhebliche Erleichterung im Vergleich zur aktuellen Situation zu erwarten. Um ein autonomes Fahrzeug zu bedienen, wäre kein intensives Training mit abschließenden oder sogar regelmäßigen Fahrprüfungen erforderlich. Autonome Fahrzeuge könnten wie Taxis oder öffentliche Verkehrsmittel verwendet werden. Daraus ergeben sich folgende Indikatoren: Die Interaktion mit autonomen Fahrzeugen ist klar, verständlich (EE1) und einfach (EE3). Weiterhin ist es einfach die Bedienung autonomer Fahrzeuge zu erlernen (EE4) und zu beherrschen (EE2).

Nr.	Frage in Fragebogen	(Venkatesh et al., 2003)	(Carlsson et al., 2006)	(Martins et al., 2014)
EE1	My interaction with autonomous cars would be clear and understandable.	My interaction with the system would be clear and understandable.		My interaction with Internet Banking would be clear and understandable.
EE2	It would be easy for me to become skillful at using autonomous driving.	It would be easy for me to become skillful at using the system.		It would be easy for me to become skillful at using Internet Banking.
EE3	I would find autonomous driving easy to use.	I would find the system easy to use.	It is easy for me to use a mobile device.	I would find Internet Banking easy to use.
EE4	I think that learning to operate autonomous driving would be easy for me.	Learning to operate the system is easy for me.		I think that learning to operate Internet Banking would be easy for me.

Tabelle 6: Die Operationalisierung von EE für Studie 1

Quelle: Eigene Darstellung

5.3.3 Operationalisierung der sozialen Einflüsse (SI)

Für die Operationalisierung des Konstruktes SI können wir ebenfalls Fragen aus allen drei Studien verwenden, entsprechend Tabelle 7. Es sprechen einige Gründe für eine soziale Einflussnahme bezüglich der Nutzung autonomer Fahrzeuge. Sobald autonome Fahrzeuge verfügbar sind, könnte selbst zu Fahren als eine Tätigkeit mit unnötigen Risiken für Fahrer, Mitfahrer und andere Verkehrsteilnehmer betrachtet werden. Dies könnte dazu führen, dass wichtige Personen im sozialen Umfeld (SI2) und wichtige Ratgeber, wie beispielsweise Eltern

(SI1), sich für die Nutzung autonomer Fahrzeuge aussprechen. Weiterhin könnte die Nutzung autonomer Fahrzeuge, insbesondere in der Anfangsphase nach dem Marktstart autonomer Fahrzeuge, mit Prestige verbunden sein (SI3-SI5). Durch eine anfängliche Skepsis gegenüber autonomen Fahrzeugen würden diese eher risikofreudigere Individuen nutzen, die dann gefragte Ansprechpartner sind, wie in Abschnitt 2.3 erläutert.

Nr.	Frage in Fragebogen	(Venkatesh et al., 2003)	(Carlsson et al., 2006)	(Martins et al., 2014)
SI1	People who influence my behaviour think that I should use autonomous driving.	People who influence my behaviour think that I should use the system.	My friends/family members value my choice of a mobile device.	People who influence my behaviour think that I should use Internet Banking.
SI2	People who are important to me think that I should use autonomous driving.	People who are important to me think that I should use the system.		People who are important to me think that I should use Internet Banking.
SI3	People in my environment who would use autonomous driving have more prestige than those who do not.		I am trendy while using a mobile device.	People in my environment who use Internet Banking services have more prestige than those who do not.
SI4	People in my environment who would use autonomous driving have a high profile.			People in my environment who use Internet Banking services have a high profile.
SI5	Having autonomous driving would be a status symbol in my environment.			Having Internet Banking services is a status symbol in my environment.

Tabelle 7: Operationalisierung von SI für Studie 1

Quelle: Eigene Darstellung

5.3.4 Operationalisierung der Angst vor der Nutzung (ANX)

Das ANX Konstrukt operationalisieren wir alleine auf Basis der originalen UTAUT Studie von Venkatesh et al. (2003), wie in Tabelle 8 ersichtlich. Die Indikatoren leiten sich einerseits von einer generellen Angst vor der Nutzung neuer, noch weitgehend unbekannter Technologien ab, für die es noch wenig bis gar keine allgemeinen Erfahrungswerte gibt und noch nicht selbst erprobt werden können. Daraus resultieren Bedenken (ANX1) und es schüchtert viele vor der Nutzung ein (ANX4). Andererseits verhindern Ängste die konkrete Nutzung der neuen Technologie, da man befürchtet dabei Fehler zu machen (ANX3) oder sogar Unfälle zu verursachen (ANX2).

Nr.	Frage in Fragebogen	(Venkatesh et al., 2003)
ANX1	I would feel apprehensive about using the system.	I feel apprehensive about using the system
ANX2	It scares me to think that a problem or accident might happen by using the system wrongly.	It scares me to think that I could lose a lot of information using the system by hitting the wrong key
ANX3	I would hesitate to use the system for fear of making mistakes.	I hesitate to use the system for fear of making mistakes I cannot correct
ANX4	Autonomous driving is somewhat intimidating to me.	The system is somewhat intimidating to me.

Tabelle 8: Operationalisierung von ANX für Studie 1

Quelle: Eigene Darstellung

5.3.5 Operationalisierung der Einstellung zur Nutzung (AT)

Auch das AT Konstrukt operationalisieren wir nur auf Basis der originalen UTAUT Studie von Venkatesh et al. (2003) entsprechend Tabelle 9. Die Indikatoren decken ein Spektrum an Einstellungen zur Nutzung ab. Das Spektrum beginnt bei der rationalen Überlegung, dass es eine gute Idee sei, autonome Fahrzeuge zu nutzen (AT1). Nach Indikator AT2 ist autonomes Fahren interessanter als selbst zu fahren. Das kann zum einen daran liegen, dass der Fahrer interessantere Tätigkeiten ausführen kann als zu fahren, wie beispielsweise eine Zeitung zu lesen. Andererseits kann AT2 auch auf Interesse hinweisen, etwas Neues auszuprobieren. AT3 beschreibt ein hedonistisches Interesse am autonomen Fahren. Dieses kann auf Tätigkeiten zurückzuführen sein, die während der Fahrt ausgeführt werden können. Ein weiterer Grund kann das Fahren an sich sein, vergleichbar mit dem Hobby mancher Personen mit dem Zug zu fahren oder zu fliegen. Dies kann sogar so weit gehen, dass man in positiver Antizipation das Fahren in autonomen Fahrzeugen bereits gerne heute schon nutzen möchte (AT4), auch wenn autonome Fahrzeuge zum Zeitpunkt der Studiendurchführung noch nicht verfügbar sind.

Nr.	Frage in Fragebogen	(Venkatesh et al., 2003)
AT1	Using autonomous driving is a good idea.	Using the system is a bad/good idea.
AT2	The system makes driving more interesting.	The system makes work more interesting.
AT3	Driving with autonomous cars would be fun.	Working with the system is fun.
AT4	I would like driving autonomous cars.	I like working with the system.

Tabelle 9: Operationalisierung von AT für Studie 1

Quelle: Eigene Darstellung

5.3.6 Operationalisierung der verhaltensbasierten Nutzungsintention (BI)

Für die Operationalisierung von BI lehnen wir uns an die UTAUT Originalstudie von Venkatesh et al. (2003) sowie die Studie zum Onlinebanking (Martins et al., 2014) an, wie in Tabelle 10 ersichtlich. Die Indikatoren BI1 und BI3 beinhalten die relativ direkte Frage nach der Nutzungsintention autonomer Fahrzeuge. Dies ist auch der Zweck von BI2R, allerdings als negative Aussage formuliert. Hohe Zustimmung zu BI2R bedeutet also, dass es eine geringe oder keine Intention gibt, autonome Fahrzeuge zu nutzen. BI4 formuliert die Nutzungsintention autonomer Fahrzeuge dadurch, dass ein Proband bei Verfügbarkeit autonomer Fahrzeuge beabsichtigt, von seinem bisher favorisierten Verkehrsmittel auf diese umzusteigen.

Nr.	Frage in Fragebogen	(Venkatesh et al., 2003)	(Martins et al., 2014)
BI1	If autonomous driving was available, I would intend to use autonomous driving in the next months.	I intend to use the system in the next months.	I intend to use the system in the next months.
BI2R	If autonomous driving was available, I would predict I would not use autonomous driving in the next months.	I predict I would use Internet Banking in the next months.	I predict I would use Internet Banking in the next months.
BI3	If autonomous driving was available, I would plan to use autonomous driving in the next months.	I plan to use the system in the next months.	I plan to use the system in the next months.
BI4	If autonomous driving was available, I would intend to switch to autonomous driving.		I intend to perform a transfer on the platform of Internet banking.

Tabelle 10: Operationalisierung von BI für Studie 1

Quelle: Eigene Darstellung

5.4 Ergebnisse

5.4.1 Erhebung und Prüfung der Daten

Im Zeitraum vom 10.07.2015 bis zum 31.07.2015 haben insgesamt 197 Probanden an der Online-Umfrage teilgenommen. Um eine hohe Datenqualität zu gewährleisten und falsche Schlüsse zu vermeiden, wurden die Antworten aller Probanden anhand von drei Kriterien geprüft (Hair et al., 2017, S. 50f):

1. Eine Frage im Fragebogen (ANX1) wurde doppelt gestellt. Unterschieden sich die Antworten des gleichen Probanden auf die doppelt gestellte Frage um mindestens drei Punkte auf der 5-Punkte Likert Skala, so wurde der Proband entfernt. Dies war bei fünf Probanden der Fall.
2. Eine Frage im Fragebogen (BI2R) war invers formuliert. Falls sich die Antwort auf diese Frage um mindestens drei Punkte vom Durchschnitt der anderen Fragen desselben Konstruktes (Nutzungsintention) unterschieden, wurde der Proband aufgrund der inkonsistenten Antwort entfernt. Vier Probanden wurden aufgrund dieses Kriteriums entfernt.
3. Wurde die gleiche Antwortoption bei einem hohen Anteil der Fragen angekreuzt („Straight-Lining“), wurden die jeweiligen Probanden entfernt. Dies traf bei drei Probanden zu.

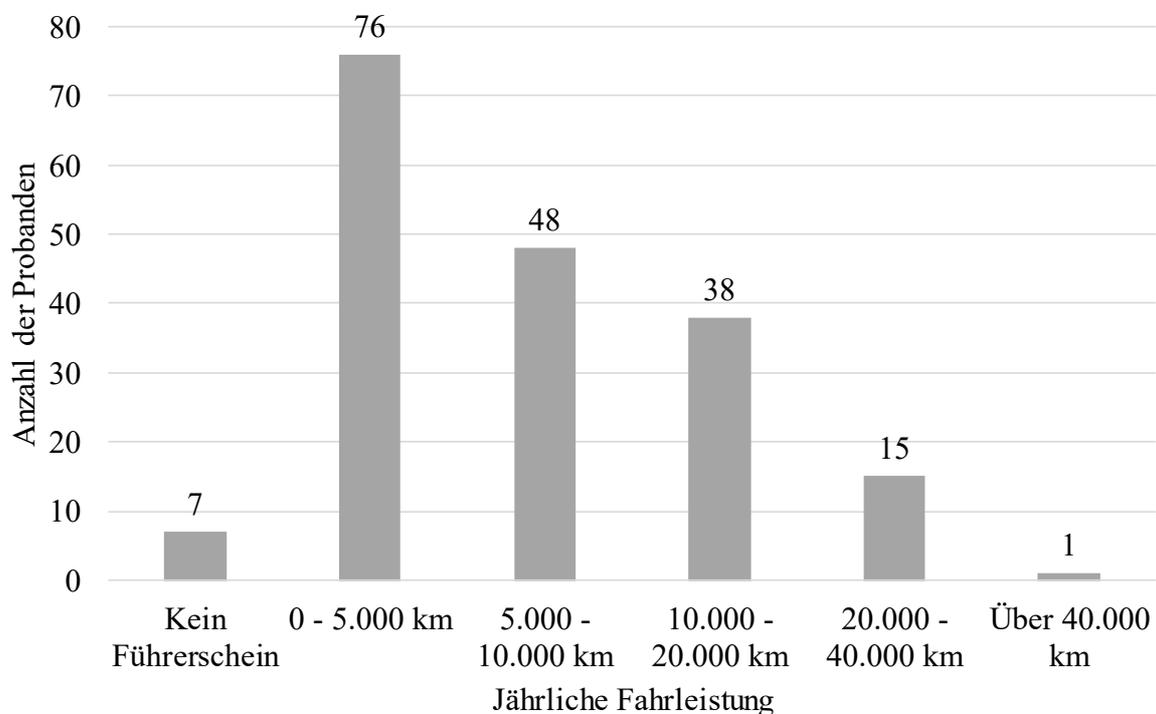


Abbildung 18: Jährliche Fahrleistung der Probanden bei Studie 1

Quelle: Eigene Darstellung

Von den 197 komplett ausgefüllten Fragebögen verblieben nach der Datenbereinigung 185. Diese 185 Fragebögen stellen die Datenbasis für alle folgenden Analysen dar. Unter den 185 Teilnehmern befinden sich 53 Frauen (28,6 %), 124 Männer (67,0 %) und 8 Probanden (4,3 %) ohne Geschlechtsangabe. Das Durchschnittsalter beträgt 20,6 Jahre, im Median 20 Jahre und liegt in einer Spanne zwischen 17 und 29 Jahren. Mit 178 Probanden besitzt die Mehrheit (96,2 %) einen Führerschein und zeigen mit durchschnittlich 4,19 von 5 Punkten (SD = 1,092) eine hohe Freude am Fahren. Dennoch besitzen nur 61 Probanden (33,0 %) ein eigenes Auto. Die individuelle Fahrleistung beträgt bei der Mehrheit der Probanden jährlich zwischen 0 und 5.000 km. Nur ein Proband fährt in einem Jahr mehr als 40.000 km (siehe Abbildung 18). Tabelle 11 fasst die Beschreibung der Stichprobe zusammen.

	Anzahl / Wert	Anteil
Gültige Fragebögen	185	93,9 %
Frauen	53	28,6 %
Männer	124	67,0 %
Ohne Geschlechtsangabe	8	4,3 %
Alter (Mittelwert)	20,6 Jahre	
Führerschein vorhanden	178	96,2 %
Kein Führerschein	7	3,8 %
Freude am Fahren (Mittelwert)	4,19 von 5 Punkten	
Eigenes Auto	61	33,0 %
Kein eigenes Auto	124	67,0 %

Tabelle 11: Deskriptive Statistik der Probanden für Studie 1

Quelle: Eigene Darstellung

5.4.2 PLS-SEM Pfadmodell

Entsprechend der Definition der Hypothesen und des Forschungsmodells wurde das in Abbildung 19 dargestellte Pfadmodell mit SmartPLS 3 (Ringle et al., 2015) erstellt. Die Indikatoren sind jeweils mit der Abkürzung des zugehörigen Konstruktes und einer laufenden Nummer bezeichnet. Das Suffix „R“ für „reversed“ bei BI2R gibt an, dass dieser Indikator aufgrund der inversen Formulierung neu kodiert wurde. Wurde BI2R mit 1 („Fully disagree“) bewertet, führt dies zu einer Neukodierung mit dem Wert 5 („Fully agree“). Analog führt eine Bewertung von 2 zu einem Wert von 4. Der Indikator ANX1 war als Kontrollfrage im Fragebogen doppelt enthalten. Für die Berechnung des Modells wurde der Mittelwert aus beiden Antworten gebildet. Die Antworten 2 und 4 auf ANX1 führen also beispielsweise zu einem Wert von 3.

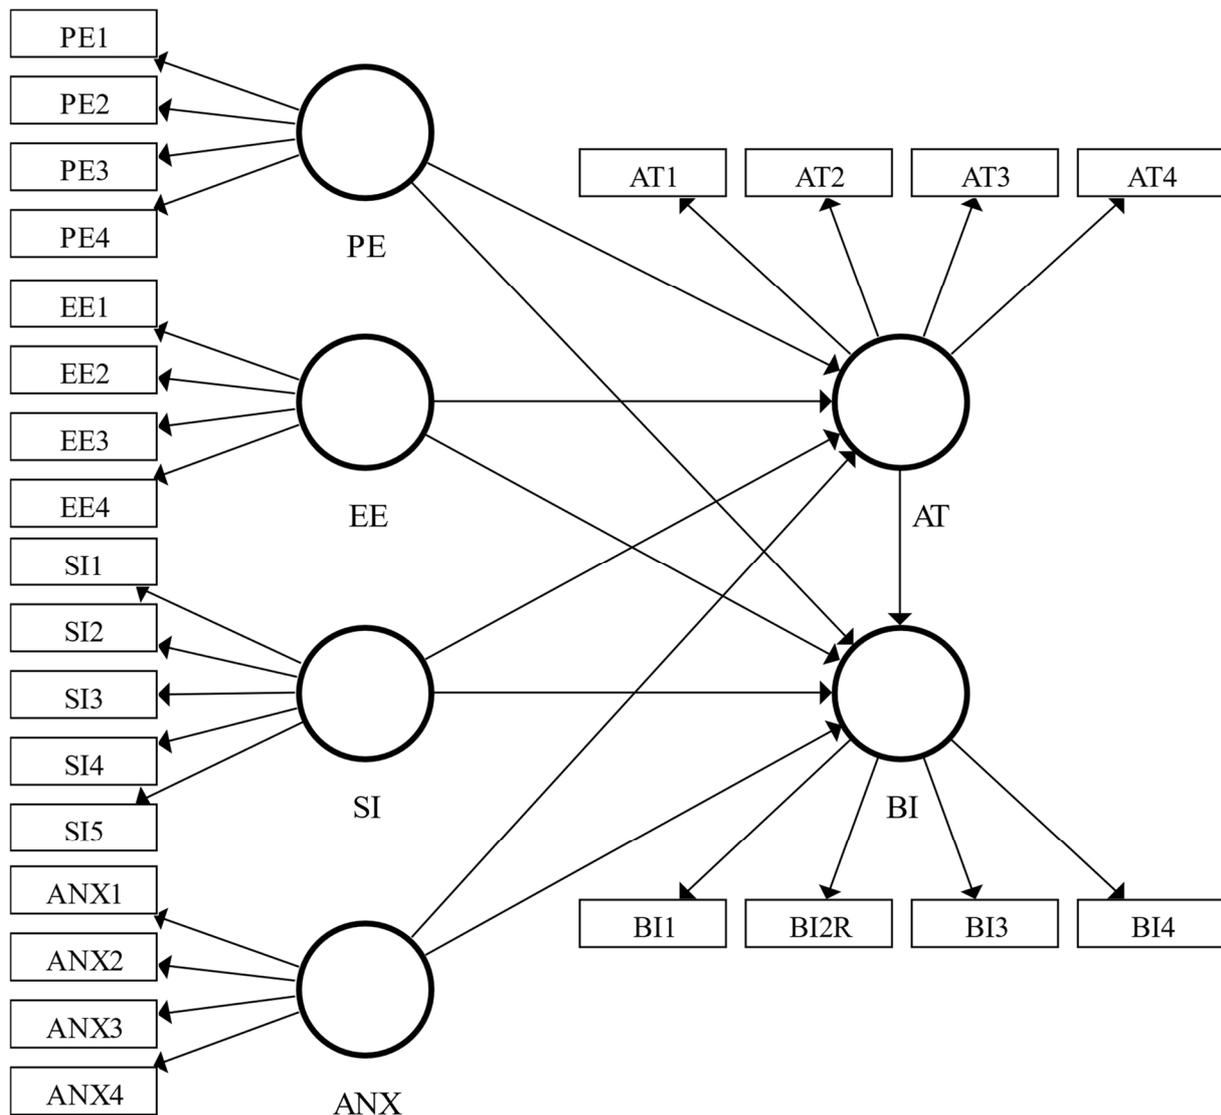


Abbildung 19: Initiales Pfadmodell der Studie 1

Quelle: Eigene Darstellung

Alle Konstrukte des Modells sind, wie in Abbildung 19 dargestellt, reflektiv gemessen. Die Ausführung des PLS-SEM Algorithmus ist konvergiert nach sieben Iterationen, sodass eine stabile Lösung erreicht wurde (Hair et al., 2017, S. 106f).

5.4.3 Evaluation des Messmodells

In diesem Abschnitt führen wir die Evaluation des Messmodells anhand der in Abschnitt 4.2.5 beschriebenen Kriterien durch. Die Evaluation des Messmodells umfasst die Prüfung der Internen-Konsistenz-Reliabilität, der Konvergenzvalidität und der Diskriminanzvalidität anhand jeweils mehrerer Kriterien. Zur Berechnung der hierfür benötigten Werte verwenden wir SmartPLS 3 (Ringle et al., 2015).

Im ersten Schritt der Evaluation des Messmodells untersuchen wir die *Interne-Konsistenz-Reliabilität*. Cronbachs Alpha ($\alpha = 0,922$) für BI ist im problematischen Bereich über 0,90. Dies deutet darauf hin, dass die Indikatoren semantisch zu redundant sind, was zu Problemen bei der Inhaltsvalidität sowie zu stark korrelierten Fehlertermen führen kann (Hair et al., 2017, S. 97).

Wir untersuchen daher die Indikatoren von BI auf Multikollinearität mittels VIF. Der Indikator BI1 hat den höchsten VIF-Wert von 5,201. BI1 erhöht somit den Standardfehler um das 2,281-fache. Wir entscheiden uns daher nach Prüfung der Inhaltsvalidität zur Entfernung des Indikators BI1 aus dem Modell. Durch die Entfernung des Indikators sinkt der Wert für Cronbachs Alpha für BI mit 0,879 in den zufriedenstellenden Bereich. Auch die Composite-Reliabilität liegt nach der Entfernung von BI1 mit 0,881 im zufriedenstellenden Bereich. Die VIF-Werte für die Indikatoren von BI haben sich nun deutlich verbessert und sind nun alle unter dem Schwellwert von 5. Nach Entfernung des Indikators BI1 betrachten wir die Interne-Konsistenz-Reliabilität daher als gegeben.

	Ladungen	t-Werte	95 % Konfidenzintervalle	p < 0,05
ANX2 <- ANX	0,736	12,521	[0,585;0,821]	Ja
ANX3 <- ANX	0,820	19,583	[0,715;0,881]	Ja
ANX4 <- ANX	0,845	19,020	[0,729;0,908]	Ja
AT1 <- AT	0,818	29,163	[0,755;0,866]	Ja
AT3 <- AT	0,767	18,313	[0,670;0,834]	Ja
AT4 <- AT	0,910	70,664	[0,880;0,931]	Ja
BI2R <- BI	0,909	60,723	[0,874;0,934]	Ja
BI3 <- BI	0,908	50,031	[0,863;0,937]	Ja
BI4 <- BI	0,873	41,319	[0,827;0,909]	Ja
EE1 <- EE	0,767	16,380	[0,653;0,838]	Ja
EE2 <- EE	0,827	27,420	[0,758;0,877]	Ja
EE3 <- EE	0,856	35,449	[0,800;0,896]	Ja
EE4 <- EE	0,791	14,759	[0,650;0,868]	Ja
PE1 <- PE	0,785	17,135	[0,673;0,853]	Ja
PE2 <- PE	0,792	22,346	[0,704;0,846]	Ja
PE3 <- PE	0,869	28,683	[0,789;0,911]	Ja
PE4 <- PE	0,795	24,637	[0,712;0,845]	Ja
SI1 <- SI	0,771	22,048	[0,687;0,829]	Ja
SI2 <- SI	0,783	25,779	[0,705;0,831]	Ja
SI3 <- SI	0,747	16,062	[0,643;0,820]	Ja
SI4 <- SI	0,720	14,787	[0,606;0,798]	Ja
SI5 <- SI	0,764	19,689	[0,670;0,823]	Ja

Tabelle 12: Äußere Ladungen bei Studie 1

Quelle: Eigene Darstellung

Im zweiten Schritt der Evaluation des Messmodells untersuchen wir die *Konvergenzvalidität*. Dazu betrachten wir die Ladungen aller Indikatoren. Die Ladungen von ANX1 und AT2 liegen mit 0,664 beziehungsweise 0,637 unterhalb des Schwellwertes von 0,70. Sowohl durch das Entfernen von ANX1 als auch AT2 ist die Inhaltsvalidität der jeweiligen Konstrukte nicht beeinträchtigt und die Werte für Cronbachs Alpha und der Composite-Reliabilität von ANX und AT überschreiten den Schwellwert von 0,90 nicht. Wir entfernen daher die Indikatoren ANX1 und AT2 aus dem Modell. Die Ladungen der verbleibenden Indikatoren, sowie deren

t -Werte sind in Tabelle 12 abgebildet. Tabelle 12 enthält außerdem die mittels BCa-Bootstrapping mit 5.000 Subsamples ermittelten Bias-korrigierten Konfidenzintervalle. In der letzten Spalte befindet sich weiterhin die Information, ob die Ladungen zum gewählten Signifikanzniveau von 0,05 signifikant sind.

Da alle Indikatorladungen über dem Schwellwert von 0,70 liegen, muss folglich auch die AVE aller Konstrukte über dem Schwellwert von 0,50 liegen. Dies ist bei allen Konstrukten der Fall, wie Tabelle 13 zeigt. Die Werte für Cronbachs Alpha, Composite-Reliabilität und AVE nach Entfernung der Indikatoren BI1, ANX1 und AT2 sind in Tabelle 13 aufgelistet. Da alle Kriterien für die Konvergenzvalidität erfüllt sind, betrachten wir diese als gegeben.

	Cronbachs Alpha	Composite-Reliabilität	AVE
ANX	0,727	0,754	0,843
AT	0,780	0,802	0,872
BI	0,879	0,881	0,925
EE	0,827	0,832	0,885
PE	0,826	0,829	0,885
SI	0,816	0,823	0,871

Tabelle 13: Ergebnisse zur Internen-Konsistenz-Reliabilität bei Studie 1

Quelle: Eigene Darstellung

Im dritten Schritt der Evaluation des Messmodells untersuchen wir die *Diskriminanzvalidität* anhand von drei Ansätzen. Zunächst betrachten wir hierfür die Ladungen und Kreuzladungen der Indikatoren in Tabelle 14. Alle Ladungen der Indikatoren auf das eigene Konstrukt, die in der Tabelle grau hinterlegt sind, sind größer als alle Kreuzladungen der Indikatoren zu anderen Konstrukten. Anhand der Kreuzladungstabelle können wir daher keine Probleme bei der Diskriminanzvalidität identifizieren.

	ANX	AT	BI	EE	PE	SI
ANX2	0,736	-0,133	-0,274	-0,354	-0,111	-0,111
ANX3	0,820	-0,200	-0,347	-0,377	-0,254	0,029
ANX4	0,845	-0,308	-0,360	-0,292	-0,115	-0,066
AT1	-0,371	0,818	0,536	0,499	0,519	0,436
AT3	-0,025	0,767	0,485	0,152	0,272	0,465
AT4	-0,257	0,910	0,674	0,325	0,434	0,496
BI2R	-0,373	0,568	0,909	0,252	0,357	0,492
BI3	-0,381	0,589	0,908	0,311	0,368	0,500
BI4	-0,356	0,674	0,873	0,333	0,472	0,578
EE1	-0,362	0,312	0,335	0,767	0,301	0,181
EE2	-0,346	0,310	0,268	0,827	0,341	0,104
EE3	-0,316	0,388	0,264	0,856	0,351	0,177
EE4	-0,327	0,293	0,208	0,791	0,340	-0,025
PE1	-0,206	0,351	0,347	0,326	0,785	0,271
PE2	-0,162	0,395	0,347	0,307	0,792	0,259
PE3	-0,154	0,423	0,342	0,356	0,869	0,258
PE4	-0,132	0,445	0,412	0,339	0,795	0,417
SI1	-0,093	0,374	0,503	0,077	0,287	0,771
SI2	-0,150	0,445	0,578	0,064	0,324	0,783
SI3	0,090	0,416	0,309	0,101	0,265	0,747
SI4	-0,048	0,366	0,372	0,151	0,250	0,720
SI5	0,027	0,495	0,409	0,168	0,291	0,764

Tabelle 14: Kreuzladungstabelle für Studie 1

Quelle: Eigene Darstellung

Der zweite Ansatz zur Untersuchung der Diskriminanzvalidität ist das Fornell-Larcker-Kriterium. Dieses besagt, dass die Quadratwurzel der AVE eines Konstruktes größer ist als alle Korrelationen zu anderen Konstrukten. Dies können wir anhand Tabelle 15 prüfen. Auf der Diagonalen der Tabelle ist jeweils die Quadratwurzel der AVE eingetragen. In den anderen Feldern stehen jeweils die Korrelationswerte. Anhand Tabelle 15 ist ersichtlich, dass das Fornell-Larcker-Kriterium erfüllt ist. Wir können daher auch anhand dieses Ansatzes keine Probleme bei der Diskriminanzvalidität identifizieren.

	ANX	AT	BI	EE	PE	SI
ANX	0,802					
AT	-0,280	0,834				
BI	-0,413	0,684	0,897			
EE	-0,416	0,405	0,335	0,811		
PE	-0,200	0,501	0,449	0,410	0,811	
SI	-0,056	0,556	0,587	0,145	0,377	0,757

Tabelle 15: Fornell-Larcker-Kriterium bei Studie 1

Quelle: Eigene Darstellung

Da mit den vorherigen Ansätzen zur Untersuchung der Diskriminanzvalidität gegebenenfalls nicht alle Probleme erkannt werden, betrachten wir noch die HTMT-Verhältnisse, die in Tabelle 16 abgebildet sind. Alle Werte liegen unter dem konservativen Grenzwert von 0,85. Der höchste HTMT-Wert liegt bei 0,814 zwischen BI und AT. Zusätzlich führen wir ein Bootstrapping mit 5.000 Subsamples durch, um die BCa-korrigierten Konfidenzintervalle für die HTMT-Werte zu prüfen. Das Konfidenzintervall für das HTMT-Verhältnis zwischen BI und AT reicht von 0,703 bis 0,906 und auch die anderen Konfidenzintervalle beinhalten die 1 nicht.

	ANX	AT	BI	EE	PE	SI
ANX						
AT	0,375					
BI	0,509	0,814				
EE	0,547	0,482	0,386			
PE	0,259	0,606	0,52	0,497		
SI	0,151	0,696	0,672	0,197	0,448	

Tabelle 16: HTMT-Verhältnisse bei Studie 1

Quelle: Eigene Darstellung

Nachdem wir die Indikatoren BI1, ANX1 und AT2 nach sorgfältiger Prüfung entfernt haben, sind alle Kriterien zur Evaluation des Messmodells erfüllt. Daher können wir mit der Evaluation des Strukturmodells fortfahren.

5.4.4 Evaluation des Strukturmodells

In diesem Abschnitt führen wir die Evaluation des Strukturmodells anhand der in Abschnitt 4.2.7 beschriebenen Kriterien durch. Die Evaluation des Strukturmodells umfasst die Prüfung der Multikollinearität der Konstrukte, der Bestimmtheitsmaße R^2 der endogenen Konstrukte, der f^2 -Effektstärken der exogenen Konstrukte, der Prognoserelevanz anhand des Stone-Geisser Q^2 und der q^2 -Effektstärken der exogenen Konstrukte. Zur Berechnung der hierfür benötigten Werte verwenden wir SmartPLS 3 (Ringle et al., 2015).

Zunächst prüfen wir das Strukturmodell auf *Kollinearität*. Hierfür ermitteln wir die VIF-Werte zwischen jeweils allen Treiberkonstrukten der endogenen Konstrukte AT und BI. Die VIF-Werte sind in Tabelle 17 dargestellt. Alle VIF-Werte liegen klar unterhalb des Grenzwertes 5. Daraus schlussfolgern wir, dass kein kritisches Maß an Kollinearität zwischen den Treiberkonstrukten vorliegt.

	AT	BI
ANX	1,212	1,243
AT		1,893
EE	1,399	1,469
PE	1,375	1,477
SI	1,167	1,522

Tabelle 17: Innere VIF Werte bei Studie 1

Quelle: Eigene Darstellung

Im nächsten Schritt prüfen wir die *Pfadkoeffizienten* des Strukturmodells. Hierzu führen wir zunächst ein BCa-Bootstrapping mit 5.000 Subsamples durch. Dadurch erhalten wir die *t*-Werte und *p*-Werte der Pfadkoeffizienten sowie die Konfidenzintervalle für die Pfadkoeffizienten, die in Tabelle 18 dargestellt sind. Die Pfadkoeffizienten EE → BI und PE → BI sind nicht signifikant. Auch deren Pfadkoeffizienten sind mit -0,020 beziehungsweise 0,083 relativ niedrig. Die Bias-korrigierten 95 % Konfidenzintervalle von [-0,130;0,084] für EE → BI und [-0,023;0,193] für PE → BI deuten ebenfalls auf einen geringen direkten Einfluss von EE beziehungsweise PE auf BI hin. Alle weiteren Pfadkoeffizienten sind signifikant zum definierten Signifikanzniveau von 0,05. Das Ergebnis spiegelt sich auch in den *t*-Werten wider, die bei allen signifikanten Pfadkoeffizienten über 1,96 liegen. Die 95 % Konfidenzintervalle der signifikanten Pfadkoeffizienten enthalten die 0 nicht und bewegen sich in plausiblen Wertebereichen.

	Pfadkoeffizienten	t-Werte	p-Werte	95 % Konfidenzintervalle	p < 0,05
ANX -> AT	-0,129	2,176	0,030	[-0,240;-0,011]	Ja
ANX -> BI	-0,276	4,656	0,000	[-0,389;-0,158]	Ja
AT -> BI	0,393	5,485	0,000	[0,251;0,533]	Ja
EE -> AT	0,193	2,772	0,006	[0,057;0,330]	Ja
EE -> BI	-0,020	0,359	0,720	[-0,130;0,084]	Nein
PE -> AT	0,232	3,499	0,000	[0,108;0,368]	Ja
PE -> BI	0,083	1,501	0,134	[-0,023;0,193]	Nein
SI -> AT	0,433	7,429	0,000	[0,313;0,540]	Ja
SI -> BI	0,325	5,305	0,000	[0,206;0,444]	Ja

Tabelle 18: Pfadkoeffizienten des Strukturmodells bei Studie 1

Quelle: Eigene Darstellung

Im nächsten Schritt überprüfen wir die *totalen Effekte*, die sich aus den indirekten und direkten Effekten zusammensetzen. Dazu verwenden wir die Ergebnisse des bereits durchgeführten BCa-Bootstrappings mit 5.000 Subsamples, die in Tabelle 19 abgebildet sind. Im Falle der Effekte auf das Konstrukt AT und des Effektes von AT auf BI entsprechen die totalen Effekte den Pfadkoeffizienten, da hier keine indirekten Effekte vorhanden sind. Diese sind daher nicht in der Tabelle 19 enthalten. Wie der direkte Effekt ist auch der totale Effekt von EE auf BI nicht signifikant. Der totale Effekt von PE auf BI ist hingegen signifikant.

	Totale Effekte	t-Werte	p-Werte	95 % Konfidenzintervalle	p < 0,05
ANX -> BI	-0,327	5,858	0,000	[-0,432;-0,216]	Ja
EE -> BI	0,056	0,919	0,358	[-0,063;0,178]	Nein
PE -> BI	0,174	2,871	0,004	[0,058;0,295]	Ja
SI -> BI	0,495	10,085	0,000	[0,399;0,591]	Ja

Tabelle 19: Totale Effekte bei Studie 1

Quelle: Eigene Darstellung

Die Untersuchung der *indirekten Effekte* wird benötigt für die Untersuchung der Mediationen (Hair et al., 2017, S. 193ff). Alle indirekten Effekte von EE, PE und SI auf BI sind signifikant wie in Tabelle 20 ersichtlich. Nur der indirekte Effekt von ANX auf BI ist knapp nicht signifikant. Das BCa-korrigierte Konfidenzintervall enthält jedoch nicht die 0 und spricht für das Vorhandensein eines geringen indirekten Effektes. Somit handelt es sich um eine schwache komplementäre Mediation zwischen ANX und BI. Bei EE und PE handelt es sich um ausschließlich indirekte Mediationen, da die indirekten Effekte jeweils signifikant aber die direkten Effekte nicht signifikant sind. Bei SI sind sowohl der indirekte als auch der direkte Effekt signifikant. Daher handelt es sich wie bei ANX um eine komplementäre Mediation, die auf mögliche weitere Mediationen hinweist, die im Modell nicht berücksichtigt wurden.

	Indirekte Effekte	t-Werte	p-Werte	95 % Konfidenzintervalle	p < 0,05
ANX -> BI	-0,051	1,924	0,054	[-0,110;-0,007]	Nein
EE -> BI	0,076	2,591	0,010	[0,027;0,146]	Ja
PE -> BI	0,091	3,058	0,002	[0,042;0,162]	Ja
SI -> BI	0,170	4,172	0,000	[0,099;0,261]	Ja

Tabelle 20: Indirekte Effekte bei Studie 1

Quelle: Eigene Darstellung

Die Interpretation der Höhe der direkten, indirekten und totalen Effekte befindet sich im Diskussionsteil für diese Studie in Abschnitt 5.5. Damit ist die Untersuchung der Pfadkoeffizienten abgeschlossen.

Wir Berechnen nun das *Bestimmtheitsmaß* R^2 für die beiden endogenen Konstrukte BI und AT. Dieses hat für AT den Wert $R^2 = 0,472$ und für BI den Wert $R^2 = 0,604$. Somit ist die Prognoseleistung des Modells für AT als nahezu moderat und für BI zwischen moderat und substanzieller Prognoseleistung zu bewerten. Im Kontext aktueller Akzeptanzstudien sind die

Werte als sehr gut zu bewerten (Dwivedi et al., 2019; Venkatesh et al., 2012). Zur besseren Vergleichbarkeit mit den weiteren Studien dieser Dissertation berechnen wir auch das adjustierte Bestimmtheitsmaß für die endogenen Konstrukte. Dieses hat für AT den Wert $R_{adj}^2=0,460$ und für BI den Wert $R_{adj}^2=0,593$.

Im nächsten Schritt bewerten wir die f^2 -Effektstärken der Konstrukte. Diese sind in Tabelle 21 dargestellt. Entsprechend der Ladungen von EE \rightarrow BI und PE \rightarrow BI sind auch die Effektstärken sehr niedrig. Gemäß den Richtlinien für Effektstärken gibt es keinen Effekt von EE und PE auf BI, da deren f^2 Werte kleiner als 0,02 sind. Die Effekte von ANX, EE und PE auf AT sind als klein zu bewerten, da sie zwischen 0,15 und 0,02 liegen. Mittlere Effekte gibt es von SI auf AT sowie von ANX, AT und SI auf BI. Große Effektstärken sind im Modell nicht enthalten. Der größte Effekt ist zwischen SI und AT mit einem Wert von $f^2 = 0,305$.

	AT	BI
ANX	0,026	0,155
AT		0,206
EE	0,051	0,001
PE	0,074	0,012
SI	0,305	0,175

Tabelle 21: f^2 -Effektstärken bei Studie 1

Quelle: Eigene Darstellung

Für die Analyse der *Prognoserelevanz* des Strukturmodells führen wir ein Blindfolding mit einer Auslassungsdistanz von $D = 7$ durch. Auf Basis des Blindfoldings ermitteln wir das Stone-Geisser Q^2 für die beiden endogenen Konstrukte. Für AT erhalten wir einen Q^2 -Wert von 0,294 und für BI beträgt der Q^2 -Wert 0,451. Beide Werte sind somit deutlich über 0, was die Prognoserelevanz des Strukturmodells bezüglich der endogenen Variablen belegt.

Zuletzt berechnen wir noch die q^2 -Effektstärken. Diese sind in Tabelle 22 dargestellt. Die q^2 -Effektstärken verhalten sich ähnlich zu den f^2 -Effektstärken. Auch hier ist der Effekt von SI auf AT mit 0,150 der stärkste Effekt, der allerdings gerade noch als mittlerer Effekt einzustufen ist. Alle q^2 -Effektstärken sind geringer als die f^2 -Effektstärken. Keinen Effekt auf BI haben bei dieser Auswertung ebenfalls EE und PE. Zusätzlich hat EE hier auch keinen Effekt auf AT.

	AT	BI
ANX	0,004	0,087
AT		0,113
EE	0,017	0,000
PE	0,034	0,004
SI	0,150	0,095

Tabelle 22: q^2 -Effektstärken bei Studie 1

Quelle: Eigene Darstellung

Somit ist die Evaluation des Strukturmodells abgeschlossen. Abbildung 20 zeigt das finale Pfadmodell zur Prognose der Technologieakzeptanz für Innovationen am Beispiel autonomer Fahrzeuge. Die Abbildung enthält die Ladungen der Indikatoren, die jeweils auf dem Pfeil zwischen dem Indikator und dem zugehörigen Konstrukt stehen. Auf den Pfeilen zwischen den Konstrukten stehen die Pfadkoeffizienten. In den Kreisen, die die endogenen Konstrukte repräsentieren, ist jeweils das Bestimmtheitsmaß R^2 eingetragen.

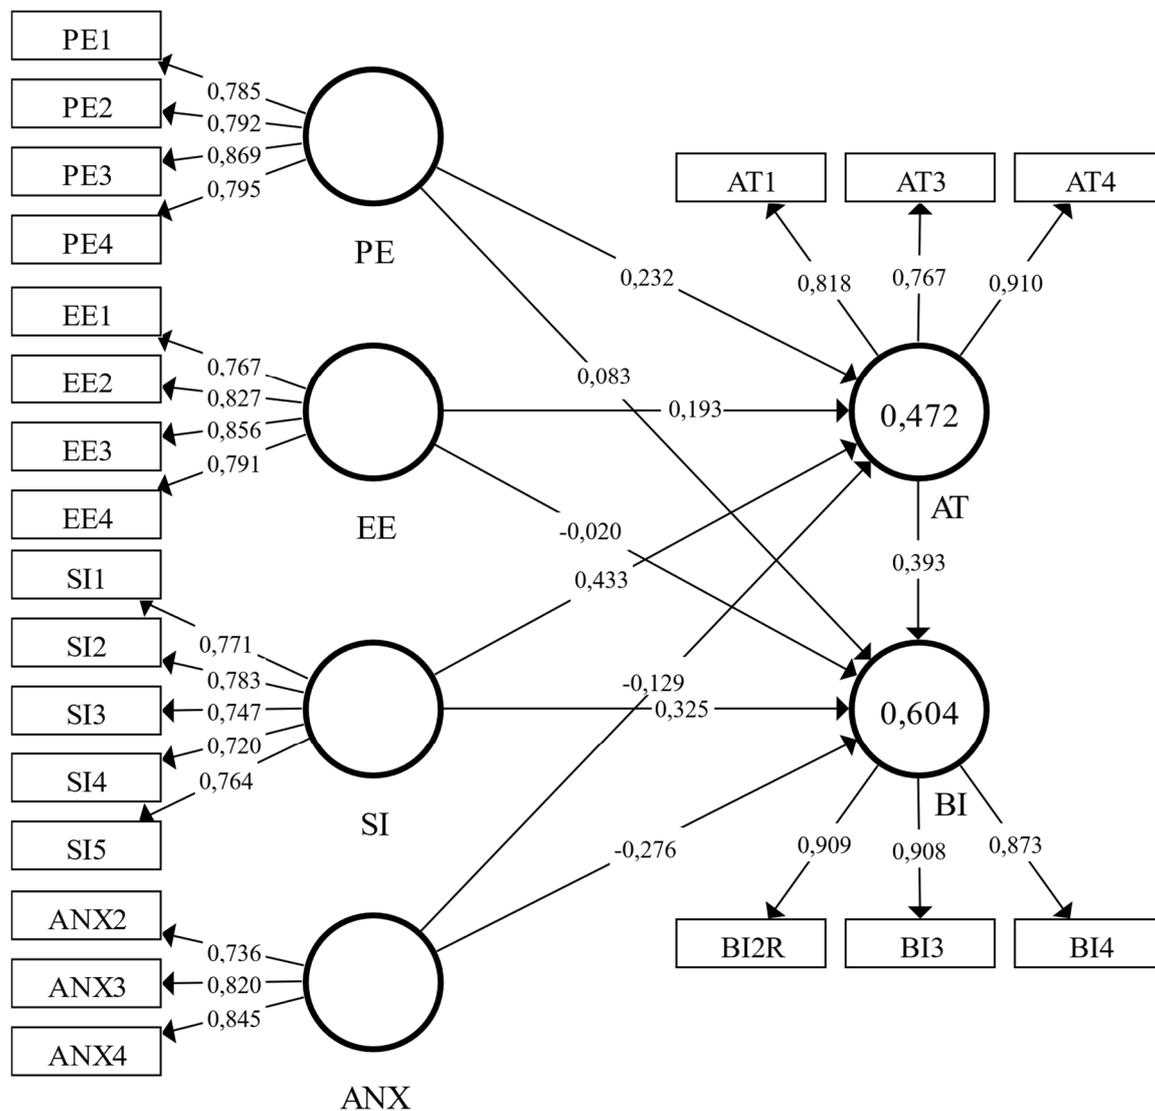


Abbildung 20: Finales Pfadmodell der Studie 1

Quelle: Eigene Darstellung

5.4.5 Vergleich mit dem UTAUT Modell

Zum Vergleich mit dem originalen UTAUT Modell entfernen wir die Konstrukte ANX und AT aus dem Pfadmodell und erhalten somit das in Abbildung 21 dargestellte originale UTAUT Modell. Im Folgenden evaluieren wir das UTAUT Mess- und Strukturmodell anhand derselben Kriterien wie für das Modell zur Prognose der Akzeptanz von Innovationen auf Basis derselben erhobenen Daten.

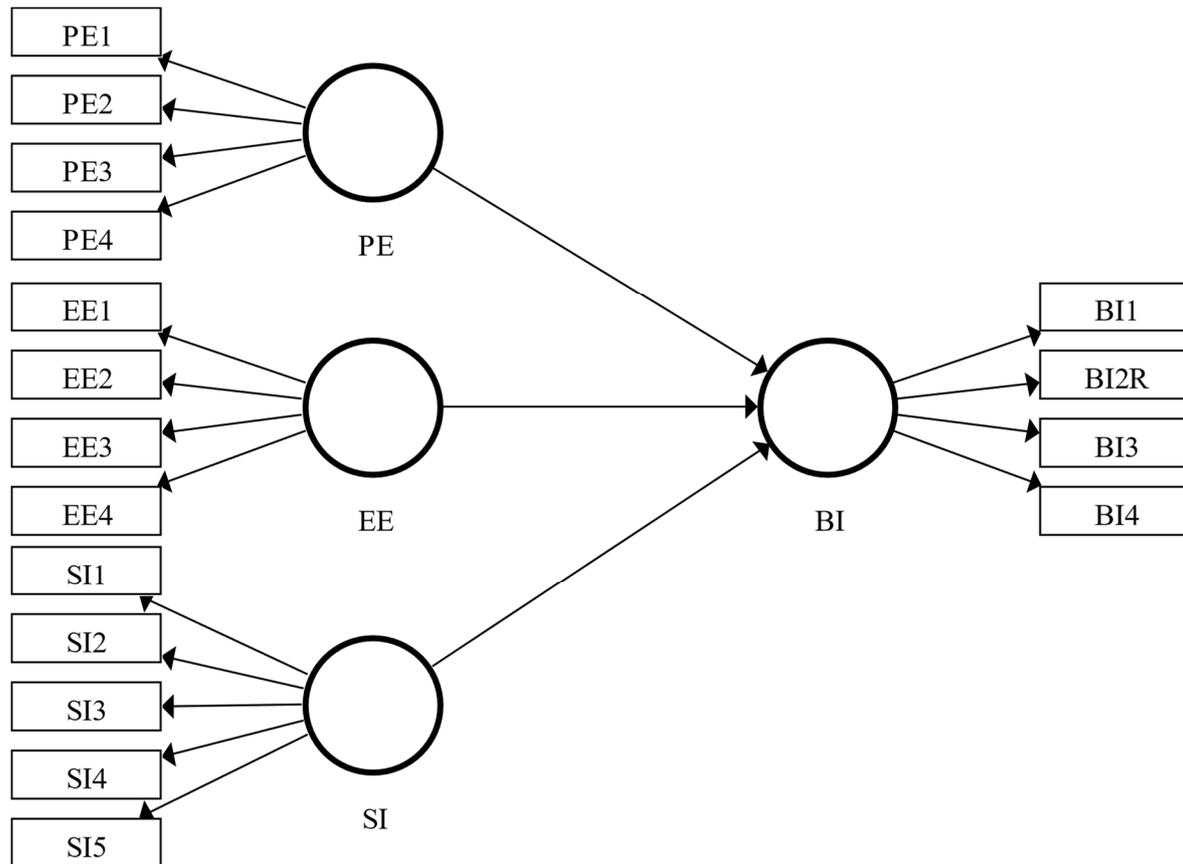


Abbildung 21: Pfadmodell des UTAUT Vergleichsmodells für Studie 1

Quelle: Eigene Darstellung

Evaluation des Messmodells

Wir haben zunächst das Messmodell des UTAUT Vergleichsmodells anhand der Internen-Konsistenz-Reliabilität, der Konvergenzvalidität und der Diskriminanzvalidität untersucht. Die Ergebnisse für Cronbachs Alpha und die Composite-Reliabilität unterscheiden sich nicht von den Ergebnissen für PE, EE, SI und BI in Tabelle 13. Somit unterscheiden sich die Modelle bezüglich der Internen-Konsistenz-Reliabilität nicht.

Zur Prüfung der *Konvergenzvalidität* untersuchen wir die Indikatorladungen. Diese sind in Tabelle 23 dargestellt. Die Tabelle enthält außerdem die mittels BCa-Bootstrapping mit 5.000 Subsamples ermittelten *t*-Werte und die Bias-korrigierten Konfidenzintervalle. In der letzten Spalte befindet sich weiterhin die Information, ob die Ladungen zum gewählten Signifikanzniveau von 0,05 signifikant sind.

	Ladungen	t-Werte	95 % Konfidenzintervalle	p < 0,05
BI2R <- BI	0,905	55,628	[0,868;0,933]	Ja
BI3 <- BI	0,906	46,405	[0,857;0,936]	Ja
BI4 <- BI	0,877	42,783	[0,829;0,910]	Ja
EE1 <- EE	0,795	17,755	[0,682;0,862]	Ja
EE2 <- EE	0,823	23,582	[0,735;0,876]	Ja
EE3 <- EE	0,840	27,128	[0,768;0,888]	Ja
EE4 <- EE	0,776	11,869	[0,606;0,863]	Ja
PE1 <- PE	0,790	17,662	[0,681;0,858]	Ja
PE2 <- PE	0,789	21,181	[0,688;0,844]	Ja
PE3 <- PE	0,864	25,884	[0,778;0,910]	Ja
PE4 <- PE	0,797	23,140	[0,710;0,851]	Ja
SI1 <- SI	0,805	25,424	[0,729;0,858]	Ja
SI2 <- SI	0,817	29,761	[0,752;0,863]	Ja
SI3 <- SI	0,711	12,047	[0,565;0,797]	Ja
SI4 <- SI	0,701	12,498	[0,572;0,787]	Ja
SI5 <- SI	0,730	14,490	[0,605;0,807]	Ja

Tabelle 23: Äußere Ladungen des UTAUT Vergleichsmodells bei Studie 1

Quelle: Eigene Darstellung

Wie in Tabelle 23 ersichtlich, liegen alle äußeren Ladungen des UTAUT Vergleichsmodells über dem Schwellwert von 0,70. Zum Vergleich der Ladungen zwischen unserem Modell und des UTAUT Vergleichsmodells, sind die jeweiligen Konfidenzintervalle der Ladungen in Tabelle 24 nebeneinander dargestellt. Gibt es keine Überlappung der Konfidenzintervalle, unterscheiden sich die Ladungen signifikant zum Signifikanzniveau von 0,05. Jedoch überlappen sich alle Konfidenzintervalle aller äußeren Ladungen. Somit gibt es keinen signifikanten Unterschied bei den äußeren Ladungen zwischen unserem Modell und dem UTAUT Vergleichsmodell.

	Modell	UTAUT Vergleichsmodell	Überlappung
BI2R <- BI	[0,874;0,934]	[0,868;0,933]	Ja
BI3 <- BI	[0,863;0,937]	[0,857;0,936]	Ja
BI4 <- BI	[0,827;0,909]	[0,829;0,910]	Ja
EE1 <- EE	[0,653;0,838]	[0,682;0,862]	Ja
EE2 <- EE	[0,758;0,877]	[0,735;0,876]	Ja
EE3 <- EE	[0,800;0,896]	[0,768;0,888]	Ja
EE4 <- EE	[0,650;0,868]	[0,606;0,863]	Ja
PE1 <- PE	[0,673;0,853]	[0,681;0,858]	Ja
PE2 <- PE	[0,704;0,846]	[0,688;0,844]	Ja
PE3 <- PE	[0,789;0,911]	[0,778;0,910]	Ja
PE4 <- PE	[0,712;0,845]	[0,710;0,851]	Ja
SI1 <- SI	[0,687;0,829]	[0,729;0,858]	Ja
SI2 <- SI	[0,705;0,831]	[0,752;0,863]	Ja
SI3 <- SI	[0,643;0,820]	[0,565;0,797]	Ja
SI4 <- SI	[0,606;0,798]	[0,572;0,787]	Ja
SI5 <- SI	[0,670;0,823]	[0,605;0,807]	Ja

Tabelle 24: Vergleich der Konfidenzintervalle der äußeren Ladungen für Studie 1

Quelle: Eigene Darstellung

Als zweites Kriterium für die Konvergenzvalidität untersuchen wir die AVE-Werte aller Konstrukte. Diese sind in Tabelle 25 dargestellt. Alle AVE-Werte liegen über dem Grenzwert von 0,50 und unterscheiden sich nicht signifikant von den AVE-Werten unseres Modells in Tabelle 13.

	Cronbachs Alpha	Composite-Reliabilität	AVE
BI	0,879	0,881	0,804
EE	0,827	0,832	0,654
PE	0,826	0,829	0,657
SI	0,816	0,823	0,569

Tabelle 25: Ergebnisse zur Internen-Konsistenz-Reliabilität des UTAUT Vergleichsmodell bei Studie 1

Quelle: Eigene Darstellung

Im dritten Schritt der Evaluation des Messmodells untersuchen wir die *Diskriminanzvalidität* anhand von drei Ansätzen. Zunächst betrachten wir hierfür die Ladungen und Kreuzladungen der Indikatoren in Tabelle 26. Alle Ladungen der Indikatoren auf das eigene Konstrukt, die in der Tabelle grau hinterlegt sind, sind größer als alle Kreuzladungen der Indikatoren zu anderen Konstrukten. Anhand der Kreuzladungstabelle können wir daher für das UTAUT Vergleichsmodell wie bei unserem finalen Modell keine Probleme bei der Diskriminanzvalidität identifizieren.

	BI	EE	PE	SI
BI2R	0,905	0,256	0,358	0,499
BI3	0,906	0,314	0,369	0,514
BI4	0,877	0,342	0,473	0,585
EE1	0,336	0,795	0,301	0,184
EE2	0,269	0,823	0,340	0,099
EE3	0,265	0,840	0,352	0,170
EE4	0,208	0,776	0,341	-0,032
PE1	0,348	0,323	0,790	0,272
PE2	0,347	0,301	0,789	0,259
PE3	0,343	0,358	0,864	0,256
PE4	0,415	0,340	0,797	0,420
SI1	0,504	0,082	0,290	0,805
SI2	0,580	0,073	0,325	0,817
SI3	0,310	0,097	0,267	0,711
SI4	0,373	0,155	0,253	0,701
SI5	0,410	0,170	0,290	0,730

Tabelle 26: Kreuzladungstabelle des UTAUT Vergleichsmodells für Studie 1

Quelle: Eigene Darstellung

Der zweite Ansatz zur Untersuchung der Diskriminanzvalidität ist das Fornell-Larcker-Kriterium. Dieses besagt, dass die Quadratwurzel der AVE eines Konstruktes größer ist als alle Korrelationen zu anderen Konstrukten. Dies können wir anhand Tabelle 27 prüfen. Auf der Diagonalen der Tabelle ist jeweils die Quadratwurzel der AVE eingetragen. In den anderen Feldern stehen jeweils die Korrelationswerte. Anhand Tabelle 27 ist ersichtlich, dass das Fornell-Larcker-Kriterium erfüllt ist. Wir können für das UTAUT Vergleichsmodell wie beim Modell zur Prognose der Akzeptanz von Innovationen keine Probleme bei der Diskriminanzvalidität identifizieren.

	BI	EE	PE	SI
BI	0,897			
EE	0,342	0,809		
PE	0,452	0,409	0,811	
SI	0,598	0,145	0,380	0,754

Tabelle 27: Fornell-Larcker-Kriterium des UTAUT Vergleichsmodells bei Studie 1

Quelle: Eigene Darstellung

Das dritte Kriterium für Diskriminanzvalidität erfordert die Untersuchung der HTMT-Verhältnisse. Diese unterscheiden sich nicht von den Ergebnissen für PE, EE, SI und BI in Tabelle 16. Damit die die Prüfung der Messmodelle abgeschlossen. Wie beim Modell zur Prognose der Akzeptanz von Innovationen konnten wir keine Probleme des Messmodells

feststellen. Weiterhin unterscheiden sich die äußeren Ladungen zwischen den beiden Modellen nicht signifikant voneinander. Wir prüfen und vergleichen daher im nächsten Schritt die Strukturmodelle.

Evaluation des Strukturmodells

Die Evaluation des Strukturmodells umfasst die Prüfung der Multikollinearität der Konstrukte, der Bestimmtheitsmaße R^2 der endogenen Konstrukte, der f^2 -Effektstärken der exogenen Konstrukte, der Prognoserelevanz anhand des Stone-Geisser Q^2 und der q^2 -Effektstärken der exogenen Konstrukte. Zur Berechnung der hierfür benötigten Werte verwenden wir SmartPLS 3 (Ringle et al., 2015).

Zunächst prüfen wir das Strukturmodell auf *Kollinearität*. Hierfür ermitteln wir die VIF-Werte zwischen allen Treiberkonstrukten des endogenen Konstruktes BI. Die VIF-Werte sind in Tabelle 28 dargestellt. Alle VIF-Werte liegen klar unterhalb des Grenzwertes 5. Daraus schlussfolgern wir, dass kein kritisches Maß an Kollinearität zwischen den Treiberkonstrukten von BI vorliegt.

	BI
EE	1,201
PE	1,374
SI	1,169

Tabelle 28: Innere VIF Werte des UTAUT Vergleichsmodells bei Studie 1

Quelle: Eigene Darstellung

Im nächsten Schritt prüfen wir die Pfadkoeffizienten des Strukturmodells. Hierzu führen wir zunächst ein BCa-Bootstrapping mit 5.000 Subsamples durch. Dadurch erhalten wir die t -Werte und p -Werte der Pfadkoeffizienten sowie die Konfidenzintervalle für die Pfadkoeffizienten, die in Tabelle 29 dargestellt sind. Alle Pfadkoeffizienten sind signifikant zum definierten Signifikanzniveau von 0,05. Das Ergebnis spiegelt sich auch in den t -Werten wider, die bei allen Pfadkoeffizienten über 1,96 liegen. Die 95 % Konfidenzintervalle der Pfadkoeffizienten enthalten die 0 nicht und bewegen sich in plausiblen Wertebereichen.

	Pfadkoeffizienten	t-Werte	p-Werte	95 % Konfidenzintervalle	p < 0,05
EE -> BI	0,195	3,258	0,001	[0,076;0,310]	Ja
PE -> BI	0,182	2,790	0,005	[0,056;0,312]	Ja
SI -> BI	0,501	10,732	0,000	[0,399;0,585]	Ja

Tabelle 29: Pfadkoeffizienten des UTAUT Vergleichsmodells bei Studie 1

Quelle: Eigene Darstellung

Das UTAUT Modell zeigt somit die erwarteten Ergebnisse, die sich aber von unserem Modell zur Prognose der Akzeptanz von Innovationen unterscheiden und somit zu anderen Schlussfolgerungen hinsichtlich des Einflusses von EE führen würde. Der Effekt von EE → BI

aus dem UTAUT Modell entspricht ungefähr dem direkten Effekt von EE → AT im Modell zur Prognose der Akzeptanz von Innovationen. Der totale Effekt von EE → BI unterscheidet sich, allerdings nicht signifikant auf Basis der Bootstrapping Konfidenzintervalle, vom berechneten Wert im UTAUT Modell. Allerdings ist dadurch der totale Effekt von EE → BI im Modell zur Prognose der Akzeptanz von Innovationen nicht signifikant und bei UTAUT hingegen schon. Die beiden Pfadkoeffizienten des UTAUT Modells zwischen PE → BI und SI → BI sind hingegen annähernd gleich groß und nicht signifikant unterschiedlich auf Basis der Bootstrapping Konfidenzintervalle.

Wir Berechnen nun das *Bestimmtheitsmaß* R^2 für das endogene Konstrukt BI. Dieses hat den Wert $R^2 = 0,449$. Somit besitzt das Modell nach Faustregel eine schwache Prognoseleistung und ist im Vergleich mit dem Modell zur Prognose der Akzeptanz von Innovationen ($R^2 = 0,604$) deutlich geringer. Zur besseren Vergleichbarkeit mit den weiteren Studien dieser Dissertation berechnen wir auch das adjustierte Bestimmtheitsmaß für BI. Dieses hat den Wert $R_{adj}^2=0,440$ und ist damit ebenfalls deutlich geringer ($R_{adj}^2=0,593$).

Im nächsten Schritt bewerten wir die *f²-Effektstärken* der Konstrukte. Diese sind in Tabelle 30 dargestellt. Die Effekte von EE und PE auf BI sind als klein zu bewerten, da sie mit $f^2 = 0,058$ beziehungsweise $f^2 = 0,044$ zwischen 0,15 und 0,02 liegen. Der größte Effekt ist von SI auf BI mit $f^2 = 0,390$, der als großer Effekt einzuordnen ist. Wie bei den Pfadkoeffizienten entspricht der Effekt von EE auf BI im UTAUT Vergleichsmodell eher dem Effekt zwischen EE und AT im Modell zur Prognose der Akzeptanz von Innovationen. Dies ist bei den Effektstärken auch bei PE und SI der Fall.

	BI
EE	0,058
PE	0,044
SI	0,390

Tabelle 30: *f²-Effektstärken* des UTAUT Vergleichsmodells bei Studie 1

Quelle: Eigene Darstellung

Sowohl ANX als auch AT im Modell zur Prognose der Akzeptanz von Innovationen weisen hohe *f²-Effektstärken* auf, wie in Tabelle 21 ersichtlich. Sie leisten daher einen hohen Beitrag zur Varianzerklärung von R^2 und verbessern somit den Erklärungsgehalt des Modells. Entfernen wir ANX aus dem Modell zur Prognose der Akzeptanz von Innovationen, erhalten wir einen R^2 -Wert für BI von 0,544, der zwar deutlich niedriger aber immer noch deutlich größer ist als der Wert des UTAUT Vergleichsmodells ($R^2 = 0,449$). Auch das Entfernen von AT aus dem Modell zur Prognose der Akzeptanz von Innovationen reduziert das R^2 von BI deutlich auf 0,528.

Wie bei dem Modell zur Prognose der Akzeptanz von Innovationen führen wir für die Analyse der Prognoserelevanz des Strukturmodells ein Blindfolding mit einer Auslassungsdistanz von $D = 7$ durch. Auf Basis des Blindfoldings ermitteln wir einen Wert für das Stone-Geisser Q^2 des endogenen Konstruktes BI von 0,331. Dieser Wert ist zwar über 0, was die

Prognoserelevanz des Strukturmodells bezüglich der endogenen Variablen belegt, aber deutlich geringer als im Modell zur Prognose der Akzeptanz von Innovationen ($Q^2 = 0,451$). Somit besitzt das UTAUT Vergleichsmodell eine geringere Prognoserelevanz.

Zuletzt berechnen wir noch die q^2 -Effektstärken. Diese sind in Tabelle 31 dargestellt. Die q^2 -Effektstärken verhalten sich ähnlich zu den f^2 -Effektstärken. Auch hier ist der Effekt von SI auf BI mit 0,162 der stärkste Effekt, der als mittlerer Effekt einzustufen ist. Alle q^2 -Effektstärken sind geringer als die f^2 -Effektstärken. Keinen Effekt auf die Prognoserelevanz des Modells bezüglich BI hat bei dieser Auswertung PE.

	BI
EE	0,023
PE	0,016
SI	0,162

Tabelle 31: q^2 -Effektstärken des UTAUT Vergleichsmodells bei Studie 1

Quelle: Eigene Darstellung

Somit sind die Evaluation und der Vergleich des Strukturmodells abgeschlossen. Abbildung 22 zeigt das finale Pfadmodell des UTAUT Vergleichsmodells der Studie 1. Die Abbildung enthält die Ladungen der Indikatoren, die jeweils auf dem Pfeil zwischen dem Indikator und dem zugehörigen Konstrukt stehen. Auf den Pfeilen zwischen den Konstrukten stehen die Pfadkoeffizienten. Die Kreise repräsentieren die endogenen Konstrukte, in denen jeweils das Bestimmtheitsmaß R^2 eingetragen ist.

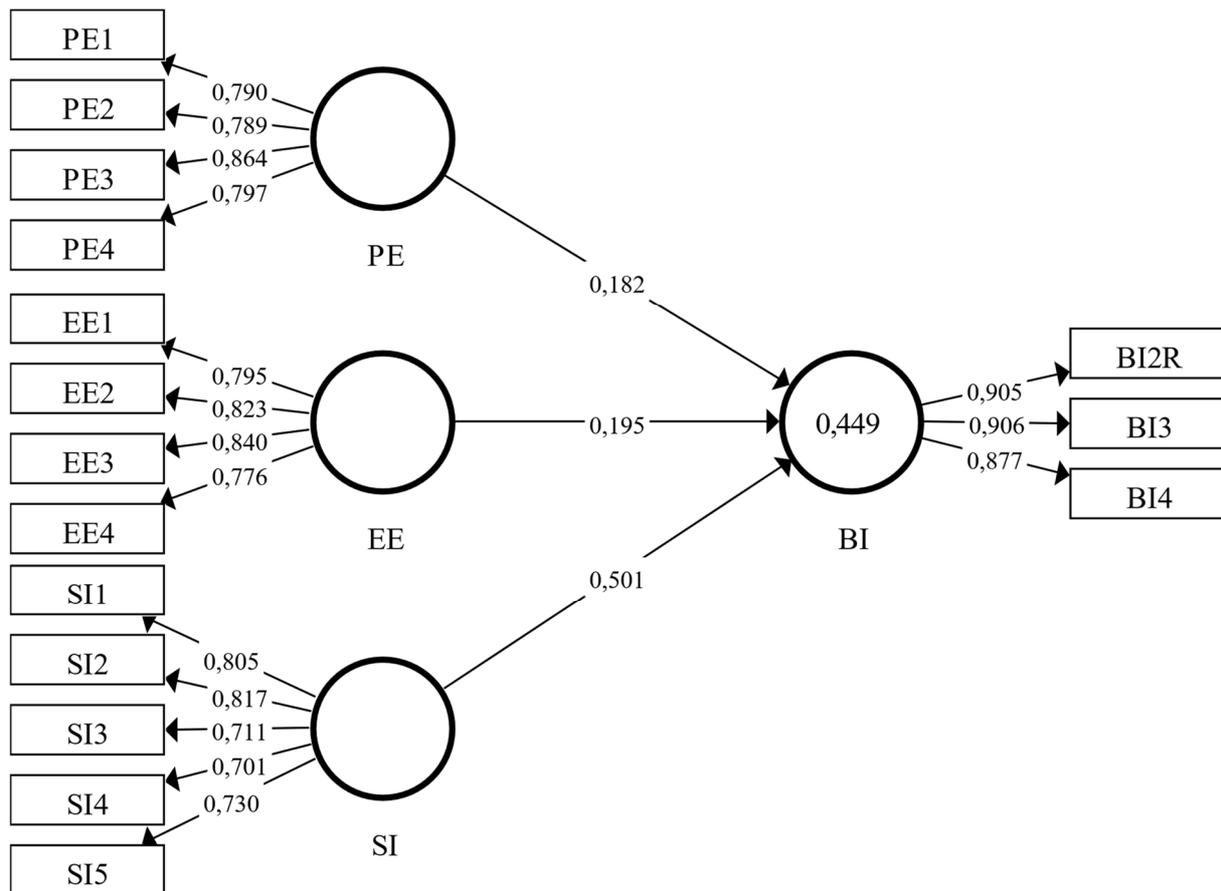


Abbildung 22: Finales Pfadmodell des UTAUT Vergleichsmodells der Studie 1

Quelle: Eigene Darstellung

5.5 Diskussion

Die Auswertung der Ergebnisse der Studie zeigt, dass die Angst vor der Nutzung (ANX) und die Einstellung zur Nutzung (AT) zusätzliche wichtige Einflussfaktoren für die Prognose der Akzeptanz von Innovationen darstellen und zu einem detaillierteren Verständnis der Nutzungsintention führen. Zudem konnten wir zeigen, dass AT nicht nur ein direkter Einflussfaktor der verhaltensbasierten Nutzungsintention ist, sondern auch den Effekt von Leistungserwartung (PE), Aufwandserwartung (EE), sozialen Einflüssen (SI) und Angst vor der Nutzung (ANX) mediiert. Durch die Erweiterung des UTAUT Modells konnten wir, verglichen mit dem ursprünglichen UTAUT Modell mit $R^2 = 0,449$, ein deutlich höheres R^2 von 0,604 für BI erreichen. Dies ist auch im Vergleich mit anderen Studien ein hoher Wert (Dwivedi et al., 2019; Venkatesh et al., 2012). Insbesondere im Hinblick auf neue Technologien kann das entwickelte Modell daher bereits in einem frühen Stadium der Produktentwicklung zur Prognose der Akzeptanz von Innovationen verwendet werden. Im Folgenden diskutieren wir die Ergebnisse im Detail.

Die Leistungserwartung ist eines der zentralen Konstrukte der Akzeptanzforschung. Der Zusammenhang zwischen Leistungserwartung und Nutzungserwartung gilt als gesichert (Benbasat & Barki, 2007). Wir konnten für die Prognose der Akzeptanz von Innovationen zeigen, dass die Leistungserwartung nicht direkt auf die Nutzungsintention wirkt. Der direkte Effekt ist mit einem Pfadkoeffizienten von 0,083 gering und nicht signifikant ($p = 0,134$). Auch

anhand der Effektstärke von $f^2 = 0,012$ gibt es keinen direkten Effekt auf die Nutzungsintention. Es gibt jedoch einen signifikanten indirekten Effekt über die Einstellung zur Nutzung ($p = 0,002$), die zu einem signifikanten totalen Effekt auf die Nutzungsintention von 0,174 ($p = 0,004$) führt. Die Einstellung zur Nutzung mediiert also den Effekt der Leistungserwartung auf die Nutzungsintention. Der totale Effekt entspricht ungefähr dem direkten Effekt der Leistungserwartung auf die Nutzungsintention im UTAUT Vergleichsmodell von 0,182 ($p = 0,005$). Das Ergebnis kann somit als konsistent mit dem UTAUT Vergleichsmodell betrachtet werden und liefert ein zusätzliches Verständnis, wie die Leistungserwartung bei neuen Technologien auf die Nutzungsintention wirkt. Entsprechend der Ergebnisse müssen wir die Hypothese H1 (PE \rightarrow BI) ablehnen und können Hypothese H6 (PE \rightarrow AT) bestätigen.

Durch die Verwendung der Gewichte der Indikatoren, die durch den PLS Algorithmus berechnet werden, können wir zudem den nicht-standardisierten Score für das Konstrukt ermitteln. Dazu multiplizieren wir das Gewicht des Indikators mit dem Wert des Indikators und addieren die Werte für alle Indikatoren eines Konstruktes. Dies führen wir für jeden Probanden durch und berechnen anschließend den Mittelwert über alle Probanden. Den Mittelwert über alle Probanden transformieren wir, sodass wir einen relativen Wert zwischen 0 und 100 erhalten. Alle Konstruktwerte sind in Abbildung 23 dargestellt.

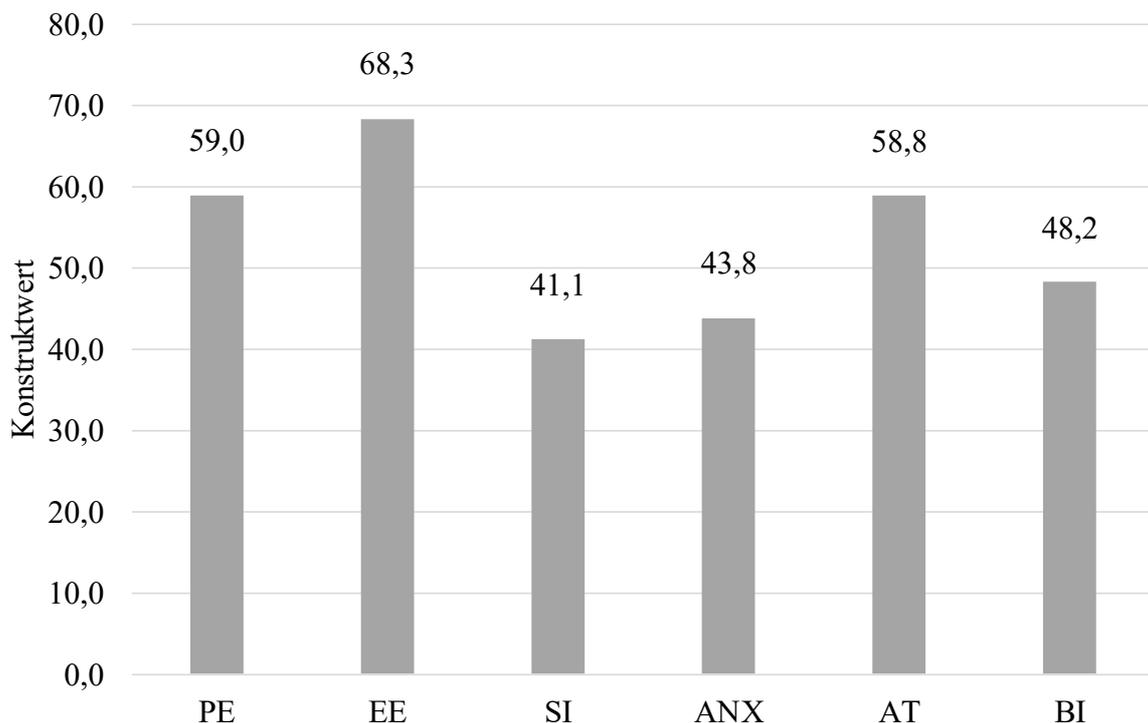


Abbildung 23: Konstruktwerte der Studie 1

Quelle: Eigene Darstellung

Für die Leistungserwartung beträgt der Wert im Durchschnitt über alle Probanden 59,0. Durch autonome Fahrzeuge wird also zwar eine Verbesserung der Leistung erwartet, dieser Wert ist allerdings noch gering in Anbetracht der erwarteten Vorteile durch diese Technologie. Weitere

Studien sollten untersuchen, warum die erwartete Leistung nicht höher bewertet wird. Dazu sollten die erwarteten Vorteile von autonomen Fahrzeugen detaillierter untersucht werden.

Neben der Leistungserwartung gilt auch die Aufwandserwartung als eines der zentralen Konstrukte der Akzeptanzforschung. Auch hierfür liefert unsere Studie interessante Erkenntnisse für neue Technologien. Die Aufwandserwartung hat in unserer Studie mit 0,076 nur einen geringen, aber signifikanten ($p = 0,010$) und positiven indirekten Effekt auf die Nutzungsintention. Sowohl der direkte Effekt ($p = 0,720$) als auch der totale Effekt ($p = 0,358$) sind aber minimal und nicht signifikant. Hier unterscheidet sich das Modell zur Prognose der Akzeptanz von Innovationen deutlich vom UTAUT Vergleichsmodell, in dem die Aufwandserwartung einen Pfadkoeffizienten von 0,195 ($p = 0,001$) aufweist. Nach UTAUT würden wir durch eine Erhöhung der Benutzerfreundlichkeit eine direkte Auswirkung auf die Nutzungsintention erwarten. Im Modell zur Prognose der Akzeptanz von Innovationen wirkt sich eine Verbesserung der Benutzerfreundlichkeit nur auf die Einstellung zu Nutzung aus, die allerdings auch einen großen Effekt auf die tatsächliche Nutzung hat (Dwivedi et al., 2019). Der Pfadkoeffizient $EE \rightarrow AT$ liegt mit 0,193 sehr nahe am Pfadkoeffizienten $EE \rightarrow BI$ mit 0,195. In einem Feldexperiment konnte gezeigt werden, dass sich die Benutzerfreundlichkeit erst nach der Verwendung autonomer Fahrzeuge auf die Nutzungsintention auswirkt (Xu et al., 2018). Somit lässt sich dieses Ergebnis in Einklang mit der bisherigen Forschung bringen, wohingegen das UTAUT Vergleichsmodell möglicherweise zu falschen Schlüssen führen würde. Wie bei der Leistungserwartung deutet auch dieses Ergebnis auf eine bessere Erklärung der Nutzungsintention von neuen Technologien hin. Auf Basis dieser Ergebnisse müssen wir auch Hypothese H2 ($EE \rightarrow BI$) ablehnen und können Hypothese H7 ($EE \rightarrow AT$) bestätigen.

Mit den Gewichten der Indikatoren ermitteln wir einen transformierten Konstruktwert 68,6 von 100 für die Aufwandserwartung. Dieser Wert ist hoch und deutet daraufhin, dass eine hohe Bedienerfreundlichkeit bei autonomen Fahrzeugen antizipiert wird. Wie in Abschnitt 5.3 erläutert, sprechen viele Gründe für eine verbesserte Benutzerfreundlichkeit. Autonome Fahrzeuge können wie Taxis oder öffentliche Verkehrsmittel verwendet werden. Es ist jedoch interessant, dass die Vorteile bezüglich der Aufwandserwartung deutlich höher als die Vorteile bezüglich der Leistungserwartung bewertet werden. Dies könnte beispielsweise an den Erfahrungen mit bereits genutzten Fahrerassistenzsystemen liegen. Assistenzsysteme wie der Tesla Autopilot bieten bisher nur einen Bruchteil der Leistung zukünftiger autonomer Fahrzeuge, sind aber benutzerfreundlich bei der Anwendung. Zukünftige Forschung sollte diesen Zusammenhang zwischen bisherigen Erfahrungen mit ähnlichen Technologien und der Bewertung der neuen Technologie genauer untersuchen.

Die sozialen Einflüsse haben in den beiden verglichenen Modellen einen großen Effekt auf die Nutzungsintention. Im Modell zur Prognose der Akzeptanz von Innovationen beträgt der Pfadkoeffizient zwischen den sozialen Einflüssen und der Nutzungsintention 0,325 ($p < 0,001$) und ist somit nach der Nutzungseinstellung der zweitstärkste Einflussfaktor der Nutzungsintention. Der totale Effekt der sozialen Einflüsse auf die Nutzungsintention entspricht mit 0,495 ($p < 0,001$) ungefähr dem direkten Effekt im UTAUT Vergleichsmodell mit 0,501 ($p < 0,001$). Dies deutet darauf hin, dass bei neuen Technologien die sozialen Einflüsse mit Abstand der wichtigste Faktor für die Akzeptanz sind. Solange keine eigenen

Erfahrungen bezüglich der neuen Technologie gesammelt werden können, verlassen sich Individuen stärker auf die Bewertung durch ihr soziales Umfeld. Diese Erkenntnis lässt sich auch aus dem UTAUT Vergleichsmodell ableiten. Das neue Modell bietet hingegen mit der Aufteilung des Effektes auf die Nutzungseinstellung und die Nutzungsintention ein tieferes Verständnis dieses Effektes. Anhand der Ergebnisse können wir sowohl Hypothese H3 (SI → BI) als auch Hypothese H8 (SI → AT) bestätigen.

Für die sozialen Einflüsse ergibt sich ein Konstruktwert von 41,1. Dies deutet darauf hin, dass das soziale Umfeld der Probanden eher einen negativen Einfluss auf die Akzeptanz autonomer Fahrzeuge ausübt. Dies könnte damit zusammenhängen, dass sich Bedenken und Risiken in sozialen Netzwerken verstärken und schnell ausbreiten (Frewer, Miles & Marsh, 2002; Kasperson et al., 1988; Kasperson & Kasperson, 1996; Renn, Burns, Kasperson, Kasperson & Slovic, 1992). Solange keine eigenen Erfahrungen durch Erprobung autonomer Fahrzeuge gesammelt werden können, werden die sozialen Einflüsse vermutlich weiterhin einen großen Effekt auf die Nutzungsintention ausüben und sich der Konstruktwert nicht wesentlich verbessern. Zukünftige Forschung sollte den Einfluss des sozialen Umfelds auf die Akzeptanzprognose näher untersuchen.

Die Angst vor der Nutzung ist nicht im UTAUT Vergleichsmodell enthalten. Im Modell zur Prognose der Akzeptanz von Innovationen hat das Konstrukt sowohl einen Effekt auf die Einstellung zur Nutzung mit einem Pfadkoeffizienten von -0,129 ($p = 0,030$) als auch auf die Nutzungsintention mit einem Pfadkoeffizienten von -0,276 ($p < 0,001$). Die Angst vor der Nutzung ist somit das einzige Konstrukt, das einen stärkeren direkten Effekt auf die Nutzungsintention hat als auf die Einstellung zur Nutzung. Nach der Einstellung zur Nutzung und den sozialen Einflüssen ist die Angst vor der Nutzung der dritte wesentliche Einflussfaktor für die Akzeptanz und leistet einen wichtigen Beitrag zur Erklärung der Nutzungsintention. Ohne das Konstrukt verringern sich zudem die R^2 -Werte der Nutzungseinstellung und der Nutzungsintention auf 0,457 (AT) beziehungsweise 0,544 (BI). Daraus folgern wir, dass die Angst vor der Nutzung ein sinnvoller Bestandteil des Modells ist. Weiterhin können wir sowohl Hypothese H4 (ANX → BI) als auch Hypothese H9 (ANX → AT) bestätigen.

Der Konstruktwert für die Angst vor der Nutzung beträgt 43,8 und befindet sich damit im neutralen bis leicht positiven Bereich. Die Probanden fürchten sich somit im Moment nicht vor autonomen Fahrzeugen, was die Akzeptanz in verschiedener Hinsicht negativ beeinflussen würde. Dies mag auch daran liegen, dass autonome Fahrzeuge zum Zeitpunkt der Studiendurchführung noch kaum auf öffentlichen Straßen getestet werden. Daher besteht kaum ein Risiko, dass jemand in einem Unfall mit einem autonomen Fahrzeug zu Schaden kommt. Sobald autonome Fahrzeuge umfangreicher auf öffentlichen Straßen getestet werden, könnte es durch die höhere Exposition zu einem Anstieg der Risikowahrnehmung kommen, wie in Abschnitt 2.4 beschrieben. Dies wiederum könnte die Angst vor der Nutzung erhöhen. Auch weitere medienwirksame Unfälle mit zunehmend automatisierten Fahrzeugen könnten das Vertrauen in die Technologie beschädigen und die Angst vor der Nutzung erhöhen. Damit eine hohe Akzeptanz bei der Markteinführung autonomer Fahrzeuge erreicht werden kann, sollte daher insbesondere im Hinblick auf die bereits angesprochene Verstärkung und schnelle Ausbreitung von Risiken in sozialen Netzwerken auf Unfälle und Bedenken durch die

Bevölkerung reagiert werden. Diese möglichst schnell zu erfassen und angemessen darauf zu reagieren könnte sich maßgeblich auf die Akzeptanz von autonomen Fahrzeugen auswirken.

Der letzte Einflussfaktor für die Nutzungsintention ist die Einstellung zur Nutzung, die ebenfalls nicht im UTAUT Modell enthalten ist. Bereits bei der Diskussion der vorherigen Ergebnisse wird die zentrale Bedeutung des Konstruktes deutlich. Zusätzlich ist die Einstellung zur Nutzung sogar noch vor den sozialen Einflüssen mit einem Pfadkoeffizienten von 0,393 ($p < 0,001$) der stärkste Einflussfaktor der Nutzungsintention und beeinflusst zudem die tatsächliche Nutzung direkt (Dwivedi et al., 2019). Entfernen wir die Einstellung zur Nutzung aus dem Modell, sinkt der R^2 -Wert der Nutzungsintention auf 0,528. Somit können wir zeigen, dass die Einstellung zur Nutzung nicht nur eine sinnvolle Erweiterung des UTAUT Modells für die Untersuchung bestehender Systeme darstellt, sondern auch für die Prognose der Akzeptanz von Innovationen einen wichtigen Beitrag leistet. Mit einem R^2 -Wert von 0,472 können wir mit dem Modell zur Prognose der Akzeptanz von Innovationen die Einstellung zur Nutzung bereits gut erklären. Wir empfehlen trotzdem eine detailliertere Untersuchung der Einflussfaktoren für die Einstellung zur Nutzung, um den R^2 -Wert weiter zu erhöhen. Aufgrund des signifikant positiven Einflusses der Einstellung zur Nutzung auf die Nutzungsintention können wir Hypothese H5 (AT \rightarrow BI) bestätigen.

Ein Wert von 58,8 für das Konstrukt deutet auf eine eher positive Einstellung zur Nutzung autonomer Fahrzeuge hin. Entsprechend unserer Hypothesen H6 - H9 resultiert dies aus einer erhöhten Leistungserwartung, einer hohen erwarteten Benutzerfreundlichkeit und geringer Angst vor der Nutzung. Der geringe Konstruktwert und der starke Effekt der sozialen Einflüsse bewirken hingegen eine relative Absenkung der Einstellung zur Nutzung. Um die Einstellung zur Nutzung zu verbessern, kann jeweils wie beschrieben auf die Einflussfaktoren eingewirkt werden. Der R^2 -Wert von 0,472 deutet jedoch darauf hin, dass weitere Einflussfaktoren der Nutzungseinstellung existieren. Zukünftige Studien sollten diese analysieren und weitere Einflussmöglichkeiten auf die Nutzungseinstellung identifizieren.

Die Nutzungsintention ist ein wichtiger Prädiktor für die Akzeptanz und Bestandteil sowohl des Modells zur Prognose der Akzeptanz von Innovationen als auch des UTAUT Vergleichsmodells. Durch Hinzunahme der Konstrukte Angst vor der Nutzung und Einstellung zur Nutzung sowie weiterer Pfade im Modell, konnten wir den R^2 -Wert des UTAUT Vergleichsmodells von 0,449 auf 0,604 deutlich erhöhen. Ein R^2 -Wert von 0,604 ist im Vergleich mit anderen Akzeptanzstudien ein sehr guter Wert (Dwivedi et al., 2019; Venkatesh et al., 2012).

Mit 48,2 erhalten wir für das Konstrukt der Nutzungsintention einen leicht negativen Wert. Hauptsächlichste Ursache hierfür ist der geringe Konstruktwert und der hohe Pfadkoeffizient für soziale Einflüsse. Die Ergebnisse lassen keine Begeisterung für autonome Fahrzeuge erkennen. In Anbetracht der enormen Investitionen in diese Technologie wird hier seitens der daran arbeitenden Firmen auf einen Anstieg der Nutzungsintention spekuliert, sobald die Markteinführung autonomer Fahrzeuge näher rückt. Wie erläutert kann dies vereinzelt durch die verbesserte Erprobbarkeit und den zunehmenden Kontakt mit autonomen Fahrzeugen im

eigenen Umfeld der Fall sein. Andererseits könnten jedoch negative Erfahrungen durch Unfälle die Einstellung zur Nutzung und die Nutzungsintention verringern.

Von den neun theoretisch hergeleiteten Hypothesen konnten wir sieben annehmen und mussten zwei aufgrund mangelnder empirischer Evidenz ablehnen, wie Abbildung 24 zeigt. Bei den beiden abgelehnten Hypothesen handelt es sich jedoch gerade um die etabliertesten Einflussfaktoren der Akzeptanz (Benbasat & Barki, 2007). Die Akzeptanzforschung beschäftigt sich im Wesentlichen mit bereits bestehenden Systemen wohingegen das Ziel unserer Studie die Prognose der Akzeptanz von Innovationen lautet. Weiterhin konnten wir durch die Untersuchung der indirekten und totalen Effekte die Abweichungen erklären, mit Ausnahme des Effektes der Aufwandserwartung. Erste Feldstudien mit autonomen Fahrzeugen kommen aber zu ähnlichen Ergebnissen (z. B. Xu et al., 2018). Vor der erstmaligen Nutzung autonomer Fahrzeuge beeinflusst die Aufwandserwartung die Nutzungsintention nicht, danach jedoch schon. Weitere Studien sollten untersuchen, ob dies auch bei anderen Technologien in einem frühen Entwicklungsstadium der Fall ist.

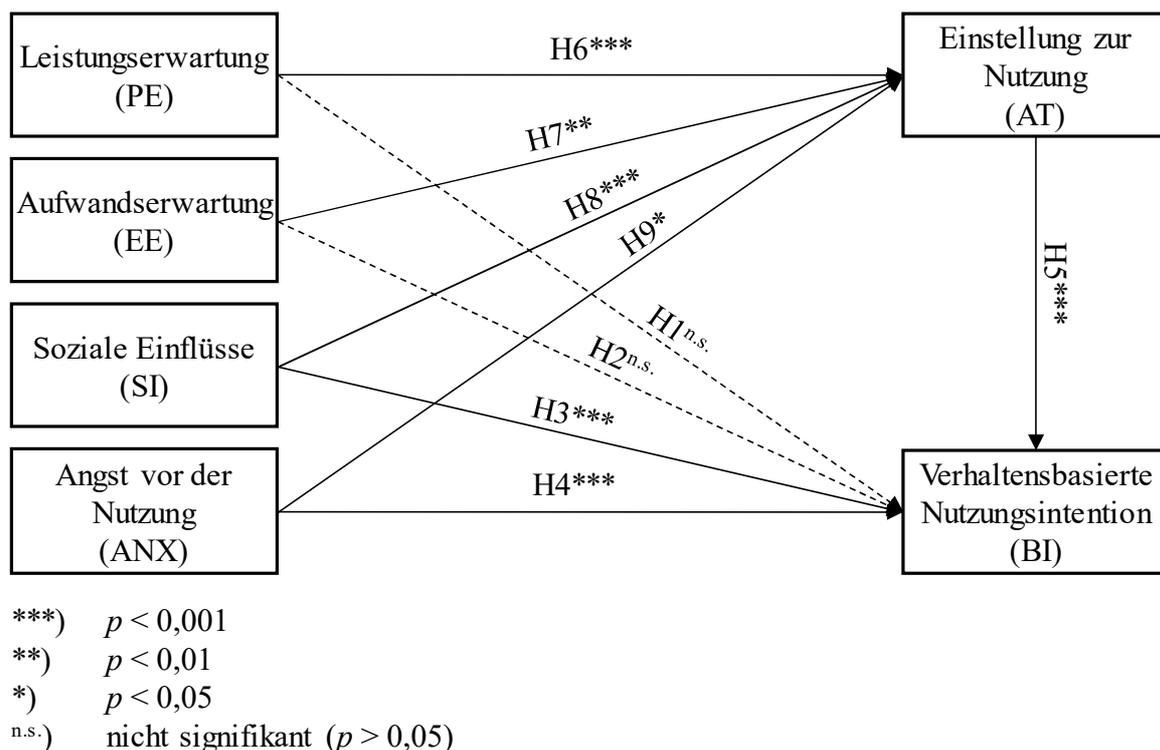


Abbildung 24: Ergebnisse zum Forschungsmodell der Studie 1

Quelle: Eigene Darstellung

Wie in Abschnitt 5.1 erläutert verfolgen wir mit dem Modell zu Prognose der Akzeptanz von Innovationen ein anderes Ziel als bisherige Akzeptanzmodelle. Zudem führen wir die Akzeptanzmessung bereits vor der Markteinführung einer Innovation durch, also früher im Innovationsprozess als üblich in der Akzeptanzforschung. Die Abweichungen gegenüber den bisherigen Akzeptanzmodellen sind daher erwartet und als positiv zu bewerten. Sie deuten darauf hin, dass wir einen neuen Forschungskontext identifiziert haben und somit einen

wichtigen Theoriebeitrag zur Akzeptanzforschung leisten (Alvesson & Kärreman, 2007). Mit unseren Ergebnissen können wir zudem einen Zusammenhang mit den etablierten Theorien herstellen.

Wie in diesem Abschnitt diskutiert, kann das Modell zur Prognose der Akzeptanz von Innovationen verwendet werden, um bereits zu einem frühen Zeitpunkt im Entwicklungsprozess und insbesondere vor der Markteinführung Einsicht in den aktuellen Stand der Akzeptanz einer zukünftigen Innovation zu erhalten. Dadurch können Probleme bei der Akzeptanz identifiziert und frühzeitig darauf reagiert werden. Für den Untersuchungsgegenstand des autonomen Fahrens konnten wir zeigen, dass eine leicht unterdurchschnittliche Akzeptanz erreicht werden würde, hauptsächlich aufgrund negativer sozialer Einflüsse. Leistungserwartung und die erwartete Benutzerfreundlichkeit von autonomen Fahrzeugen sind zwar überdurchschnittlich (PE) oder sogar hoch (EE), allerdings ist der Einfluss auf die Nutzungsintention noch gering.

Um die Akzeptanz zu erhöhen, könnte durch eine Verbesserung der Einstellung zur Nutzung und der sozialen Einflüsse die stärksten direkten Effekte auf die Nutzungsintention erzielt werden. Um die Angst vor der Nutzung nicht zu erhöhen, sollte bei der Erprobung autonomer Fahrzeuge weiterhin die Sicherheit im Vordergrund stehen. Unfälle könnten die Akzeptanz autonomer Fahrzeuge nachhaltig negativ beeinflussen und sogar Widerstandsverhalten auslösen wie in Abschnitt 2.4 erläutert. Eine vorschnelle Einführung automatisierter Fahrfunktionen macht auch in Anbetracht des geringen Effektes der Leistungserwartung wenig Sinn. Dies würde womöglich nur die Erwartungen erhöhen, die dann aufgrund mangelnder Systemreife nicht erfüllt werden können.

Neben den bereits diskutierten Vorschlägen für weitere Forschungsvorhaben sollte die Generalisierbarkeit des Modells zur Prognose der Akzeptanz von Innovationen untersucht werden. Hierfür sollten weitere zukünftige Innovationen in unterschiedlichen Phasen des Innovationsprozesses mit dem Modell zur Prognose der Akzeptanz von Innovationen untersucht werden. Um zu prüfen, ob die in dieser Studie prognostizierten Werte zutreffen, müssen weitere Akzeptanzstudien mit einigem zeitlichem Abstand bis zur Einführung autonomer Fahrzeuge durchgeführt werden. Insofern sich bei diesen Studien Unterschiede bei den Pfadkoeffizienten oder den Konstruktwerten zeigen, sollten mögliche externe Einflussfaktoren, wie beispielsweise Unfälle mit autonomen, hochautomatisierten oder aktiven FAS, geprüft werden.

Im Rahmen der in diesem Kapitel vorgestellten Studie 1 dieser Dissertation konnte das theoretisch hergeleitete Forschungsmodell zur Prognose der Akzeptanz von Innovationen empirisch validiert werden. Damit die Ergebnisse auf die Bevölkerung generalisiert werden können, sind jedoch weitere repräsentativen Stichproben erforderlich. Besonders hervorzuheben ist in diesem Zusammenhang, eine Verzerrung der Stichprobe dieser Studie in Richtung junger, männlicher Probanden. Mit repräsentativeren Daten sollten auch Moderationseffekte durch Alter und Geschlecht getestet werden. Nach der Markteinführung der Innovation sollten zudem auch eigene Erfahrungen mit der Technologie als moderierender Effekt berücksichtigt werden.

5.6 Fazit

In diesem Kapitel haben wir ein Modell zur Prognose der Akzeptanz von Innovationen basierend auf dem UTAUT Modell vorgestellt und dieses mit dem ursprünglichen UTAUT Modell verglichen. Das Modell erweitert das UTAUT Modell um die beiden Konstrukte Angst vor der Nutzung und Einstellung zur Nutzung. Durch eine Online-Umfrage mit 197 Teilnehmern konnten wir zeigen, dass das Modell zur Prognose der Akzeptanz von Innovationen eine sinnvolle Erweiterung des UTAUT Modells ist. Weiterhin konnten wir zeigen, dass es sich bei der Prognose der Akzeptanz von Innovationen um einen neuen Kontext für die Akzeptanzforschung handelt und leisten somit einen Beitrag zur Akzeptanzforschung.

Die Angst vor der Nutzung beeinflusst die Nutzungsintention sowohl direkt als auch indirekt über die Einstellung zur Nutzung. Das Hinzufügen der Einstellung der Nutzung zum Modell zeigt, dass Leistungs- und Aufwandserwartung bei neuen Technologien in einem frühen Entwicklungsstadium nur indirekt die Nutzungsintention beeinflussen aber primär die Einstellung zur Nutzung. Auf Basis des UTAUT Vergleichsmodells wären wir von einem direkten Effekt ausgegangen. Somit dient das Modell zur Prognose der Akzeptanz von Innovationen als Einstiegspunkt zur Anwendung etablierter Methoden der Akzeptanzforschung in einem frühen Zeitpunkt der Entwicklung neuer Technologien. Durch den Anwendungsfall der autonomen Fahrzeuge konnten wir zudem Erkenntnisse zum aktuellen Stand der Akzeptanz dieser aufstrebenden Technologie gewinnen und Handlungsempfehlungen zur Erhöhung der Akzeptanz ableiten.

6 Studie 2: Technologieakzeptanz nach UTAUT2

Im vorherigen Kapitel haben wir ein Modell zur Prognose der Akzeptanz von Innovationen auf Basis von UTAUT vorgestellt und anhand des Anwendungsbeispiels autonomer Fahrzeuge evaluiert. Im Rahmen der in diesem Kapitel beschriebenen Studie 2 dieser Dissertation überprüfen wir die Eignung des UTAUT2 Modells (Venkatesh et al., 2012) zur Prognose der Akzeptanz von Innovationen anhand des Anwendungsbeispiels autonomer Fahrzeuge. Hierzu wird eine Online-Umfrage mittels eines strukturierten Fragebogens durchgeführt. Die Umfrage erfolgte 180 Tage nachdem Studie 1 durchgeführt wurde. Mit den erhobenen Daten evaluieren wir das UTAUT2 Modell und vergleichen die Ergebnisse mit Studie 1 dieser Dissertation.

Im folgenden Abschnitt 6.1 beschreiben wir die Motivation und Ziele dieser Studie. In Abschnitt 6.2 leiten wir das Forschungsmodell und die darin enthaltenen Hypothesen her. Im darauffolgenden Abschnitt 6.3 operationalisieren wir die Konstrukte für den Fragebogen und beschreiben unser methodisches Vorgehen. In Abschnitt 6.4 berichten wir die Ergebnisse der Studie, die wir im darauffolgenden Abschnitt 6.5 diskutieren. Wir beenden dieses Kapitel mit einem Fazit in Abschnitt 6.6.

6.1 Motivation

Wie in Abschnitt 2.2.4 erläutert ist UTAUT2 eine Weiterentwicklung des UTAUT Modells mit einem besonderen Fokus auf den Consumer-Bereich, wohingegen UTAUT ursprünglich für einen betrieblichen Kontext zur Befragung von Mitarbeitern erstellt wurde (Venkatesh et al., 2012). Die UTAUT2 Studie untersucht beispielsweise die Akzeptanz für mobiles Internet bei Endverbrauchern, während bei der UTAUT Studie die Akzeptanz neuer betrieblicher Systeme bei den Mitarbeitern untersucht wurde, die diese Systeme für berufliche Zwecke verwenden sollten. Da das autonome Fahren eine Technologie für Endverbraucher darstellt, ist das UTAUT2 Modell dazu geeignet, deren Akzeptanz zu untersuchen. Ob es auch dazu geeignet ist, die Akzeptanz einer Innovation vor deren Marktreife zu prognostizieren, prüfen wir in dieser Studie am Beispiel des autonomen Fahrens.

Das UTAUT2 Modell enthält die zusätzlichen Einflussfaktoren der hedonischen Motivation, Preis-Leistungs-Verhältnis und Gewohnheit (Venkatesh et al., 2012). Weiterhin gibt es nach UTAUT2 einen direkten Effekt von den unterstützenden Bedingungen auf die Nutzungsintention. Somit besitzt die Nutzungsintention im UTAUT2 Modell neben der Leistungserwartung, Aufwandserwartung und sozialen Einflüssen vier neue direkte Einflussfaktoren, was einer beträchtlichen Erweiterung des UTAUT-Modells entspricht. Das in Kapitel 5 vorgestellte Modell zur Prognose der Akzeptanz von Innovationen beinhaltet mit der Angst vor der Nutzung und der Einstellung zur Nutzung nur zwei neue Konstrukte, wie in Abbildung 17 ersichtlich. Wir erwarten daher zusätzliche Einblicke für die Prognose der Akzeptanz von Innovationen.

Das Hinzufügen von zusätzlichen Konstrukten führt allerdings nicht immer zu einem besseren Modell (Hair et al., 2017, S. 171). Auch das Hinzufügen von nicht-signifikanten Konstrukten, die mit dem endogenen Konstrukt leicht korrelieren, erhöht beispielsweise den R^2 -Wert. Daher

gilt es abzuwägen, ob die zusätzlichen Konstrukte im UTAUT2 Modell einen sinnvollen Beitrag zur Prognose der Akzeptanz von Innovationen leisten. So ist es zum Beispiel unklar, inwiefern das Preis-Leistungs-Verhältnis in einer frühen Phase der Technologieentwicklung bereits abschätzbar ist. Aufgrund der zusätzlichen Konstrukte bei dieser Studie erwarten wir dennoch einen höheren R^2 -Wert für die Nutzungsintention, den wir allerdings kritisch untersuchen werden.

Das Ziel von Studie 2 dieser Dissertation ist es, auf Basis der zusätzlichen Konstrukte mit Einfluss auf die Nutzungsintention im UTAUT2 Modell zusätzliche Einsichten für die Prognose der Akzeptanz von Innovationen zu erlangen. Mit den erhobenen Daten evaluieren wir das UTAUT2 Modell und vergleichen die Ergebnisse der Evaluation sowie die Schlussfolgerungen, die wir mit dem Modell zur Prognose der Akzeptanz von Innovationen in Kapitel 5 beschreiben.

6.2 Forschungsmodell

Das Forschungsmodell dieser Studie basiert auf dem UTAUT2 Modell (Venkatesh et al., 2012), welches wir in Abschnitt 2.2.4 vorgestellt haben. Wir übernehmen alle Konstrukte des Modells außer dem Nutzungsverhalten, da dieses für neue Technologien vor deren Verfügbarkeit noch nicht erhoben werden kann. Wie im UTAUT Modell beeinflussen die Leistungserwartung, die Aufwandserwartung und soziale Einflüsse die Nutzungsintention. Unterstützende Bedingungen sind zwar Bestandteil des UTAUT Modells, beeinflussen aber nicht die Nutzungsintention, sondern nur das Nutzungsverhalten. Im UTAUT2 Modell beeinflussen die unterstützenden Bedingungen sowohl das Nutzungsverhalten als auch die Nutzungsintention. Dies ist auch beim neuen Konstrukt der Gewohnheit der Fall. Die neuen Konstrukte hedonische Motivation und Preis-Leistungs-Verhältnis beeinflussen jeweils lediglich die Nutzungsintention und nicht das Nutzungsverhalten.

Die Konstrukte *Leistungserwartung*, *Aufwandserwartung* und *soziale Einflüsse*, sowie deren Effekt auf die Nutzungsintention haben wir bereits in den Abschnitten 2.2 und 5.2 erläutert. Deren zentrale Rolle im Akzeptanzprozess wurde schon vielfach nachgewiesen (Dwivedi et al., 2019; Williams et al., 2015). In Studie 1 dieser Dissertation in Kapitel 5 konnten zeigen, dass Leistungserwartung und Aufwandserwartung keinen signifikanten direkten Effekt auf die Nutzungsintention ausüben, wenn die Einstellung zur Nutzung Teil des Modelles ist und den Effekt auf die Nutzungsintention vollständig mediiert. Da die Einstellung zur Nutzung nicht Teil des UTAUT2 Modelles ist, erwarten wir signifikante direkte Effekte von der Leistungserwartung und der Aufwandserwartung auf die Nutzungsintention. Der direkte Effekt der sozialen Einflüsse auf die Nutzungsintention ist in Studie 1 sowohl mit als auch ohne das Konstrukt der Nutzungseinstellung signifikant. Auf Basis der Ergebnisse von Studie 1 und den UTAUT (Venkatesh et al., 2003) und UTAUT2 (Venkatesh et al., 2012) Modellen formulieren wir die folgenden Hypothesen:

H1: Je höher die Leistungserwartung einer neuen Technologie ist, desto höher ist die verhaltensbasierte Nutzungsintention für diese Technologie.

H2: Je benutzerfreundlicher eine neue Technologie ist, desto höher ist die verhaltensbasierte Nutzungsintention für diese Technologie.

H3: Je positiver der soziale Einfluss durch die Nutzung einer neuen Technologie ist, desto höher ist die verhaltensbasierte Nutzungsintention für diese Technologie.

Im Gegensatz zur UTAUT Studie beeinflussen *unterstützende Bedingungen* im UTAUT2 Modell die Nutzungsintention direkt (Venkatesh et al., 2012). Unterstützende Bedingungen umfassen Ressourcen und Möglichkeiten zur Unterstützung für die Nutzung eines Produktes (Venkatesh et al., 2012). Dies kann beispielsweise die technische Infrastruktur sein, die für die Nutzung eines Produktes erforderlich ist (Venkatesh et al., 2003). Im UTAUT Modell gibt es keinen direkten Einfluss der unterstützenden Bedingungen auf die Nutzungsintention mit der Begründung, dass diese im betrieblichen Kontext für alle weitgehend gleich verfügbar sind (Venkatesh et al., 2012). Für Endanwender können die unterstützenden Bedingungen hingegen eher unterschiedlich verfügbar sein. Im Falle einer neuen Technologie sind die Ressourcen und Möglichkeiten zur Unterstützung jedoch für alle zunächst nur sehr begrenzt verfügbar. Gerade die Innovatoren und frühe Übernehmer des Diffusionsmodells müssen hier zunächst Pionierarbeit leisten und sind oft auf sich allein gestellt, was die unterstützenden Bedingungen zur Nutzung von Innovationen betrifft (Rogers, 2003, S. 248f). Erst später können unterstützende Bedingungen in Anspruch genommen werden. Wir rechnen daher eher mit einem geringen Effekt der unterstützenden Bedingungen für die Prognose der Akzeptanz von Innovationen, die sich noch in einer frühen Phase der Entwicklung befinden. Wenn jedoch unterstützende Bedingungen für eine neue Technologie bereits absehbar sind, wirken sich diese entsprechend dem UTAUT2 Modell positiv auf die Nutzungsintention aus. Wir formulieren daher die folgende Hypothese:

H4: Je mehr unterstützenden Bedingungen für die Nutzung einer neuen Technologie vorhanden sind, desto höher ist die verhaltensbasierte Nutzungsintention.

Das Konstrukt der *hedonischen Motivation* ist das erste der neuen Konstrukte des UTAUT2 Modells. Hedonische Motivation umfasst Faktoren wie Genuss oder Spaß bei der Nutzung (Venkatesh et al., 2012). In der Literatur wird die hedonische Motivation auch als wahrgenommenes Vergnügen bezeichnet (Adams, Nelson & Todd, 1992; Taylor & Todd, 1995). Im Rahmen von Konsumforschung und der Untersuchung von Informationssystemen für Endanwender beeinflusst dieser Faktor maßgeblich die Nutzungsintention (Brown & Venkatesh, 2005). Im Falle von neuen Technologien ist gerade auch dieser Faktor von entscheidender Bedeutung. In einer frühen Phase der Technologieentwicklung sind die konkreten Vorteile in Form der Leistungserwartung oder Bedienaufwände für die Allgemeinheit häufig nicht bekannt. Die hedonische Motivation hingegen kann sich bereits früh manifestieren. Dies zeigt sich beispielsweise im *Hype Zyklus Modell* des Marktforschungsinstitutes Gartner, das den zeitlichen Verlauf der Erwartungen an eine neue Technologie beschreibt (Krcmar, 2015, S. 356f). Nach dem Innovationsauslöser sind die Erwartungen an eine neue Technologie noch gering. Sie steigen aber stark an und münden in den Gipfel der überzogenen Erwartungen. Die überzogenen Erwartungen basieren nicht auf objektiven Kriterien wie Leistungserwartung und der Aufwandserwartung, sondern auf

Kriterien wie der hedonischen Motivation. Bei den ersten Einsätzen einer Innovation erfolgt daher häufig eine Ernüchterung, die im *Tal der Ernüchterung* mündet. Nach dieser Phase erfolgt ein rationalerer Umgang mit der Innovation bis schließlich das Plateau der Produktivität erreicht wird, auf dem die Vor- und Nachteile einer Innovation hinlänglich bekannt sind. Abbildung 25 zeigt das Hype-Zyklus Modell, welches die Erwartungen an eine Innovation im zeitlichen Verlauf betrachtet. Darauf aufbauend formulieren wir die folgende Hypothese:

H5: Je höher die hedonische Motivation für die Nutzung einer neuen Technologie, desto höher ist die verhaltensbasierte Nutzungsintention.

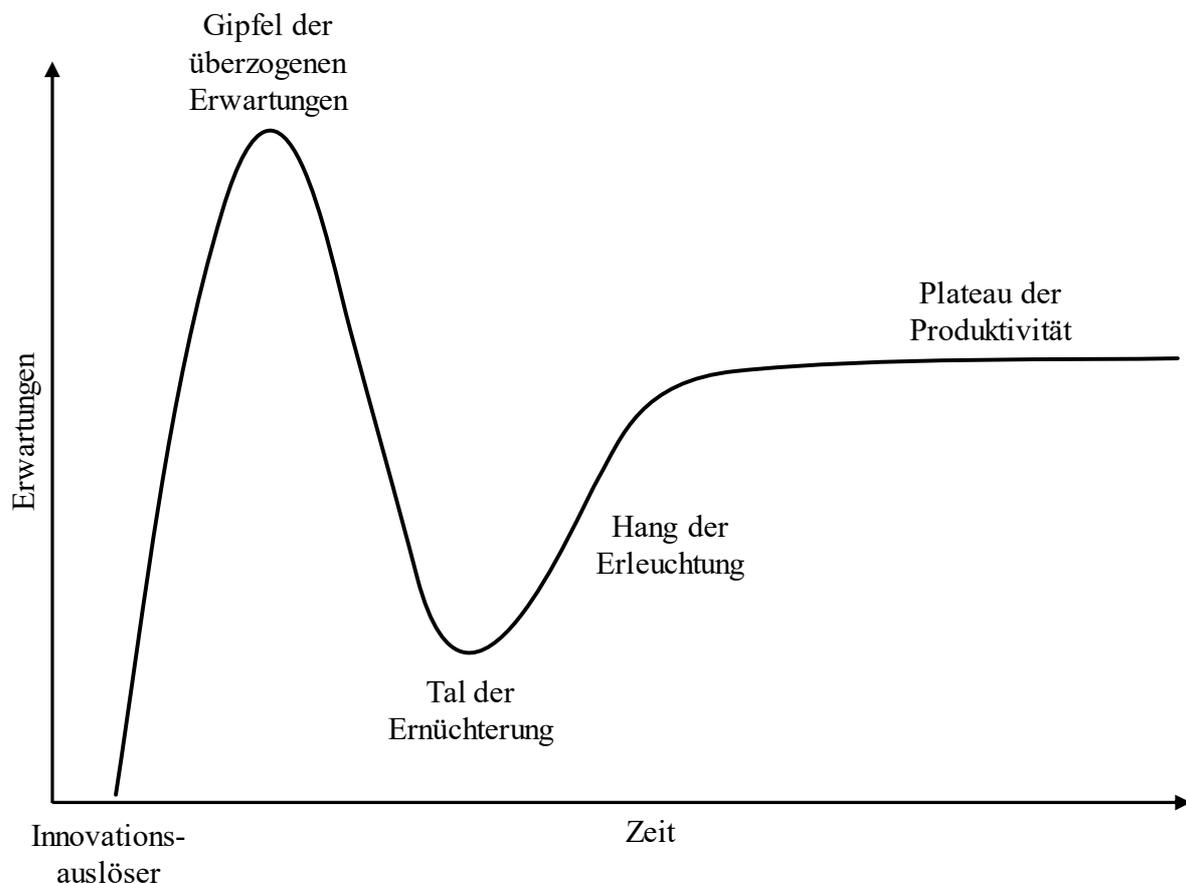


Abbildung 25: Hype Zyklus Modell

Quelle: In Anlehnung an Krcmar (2015, S. 356)

Das zweite neue Konstrukt des UTAUT2 Modells ist das *Preis-Leistungs-Verhältnis*. Im betrieblichen Kontext findet die Kostenbetrachtung häufig vorgelagert zur Nutzung statt und oft nicht durch die zukünftigen Nutzer selbst. Für die Nutzer des Systems in einem betrieblichen Kontext ist daher die Kostenbetrachtung für die Nutzungsintention nicht relevant und daher im UTAUT Modell nicht enthalten (Venkatesh et al., 2012). Im privaten Umfeld hingegen ist das Preis-Leistungs-Verhältnis eines der zentralen Faktoren für die Nutzungsentscheidung, da ein Individuum zwischen dem Nutzen eines Produktes und Opportunitätskosten abwägt, die dafür zu erbringen sind (Dodds, Monroe & Grewal, 1991; Venkatesh et al., 2012).

Opportunitätskosten insofern, da beispielsweise das benötigte Geld für den Kauf auch für andere Dinge verwendet werden könnte, die ebenfalls einen Nutzen bieten (Mankiw & Taylor, 2012, S. 4ff). Die zentrale Rolle des Preis-Leistungs-Verhältnisses spiegelt sich auch im UTAUT2 Modell wider: Nach der Gewohnheit ist das Preis-Leistungs-Verhältnis der zweitstärkste Einflussfaktor der Nutzungsintention (Venkatesh et al., 2012). Für die Prognose der Akzeptanz einer Innovation vermuten wir jedoch eher einen geringen Effekt auf die Nutzungsintention, da sowohl der Preis als auch die Leistung vor Marktstart noch weitgehend unbekannt sind. Entsprechend des UTAUT2 Modells formulieren wir die folgende Hypothese:

H6: Je besser das Preis-Leistungs-Verhältnis einer neuen Technologie, desto höher ist die verhaltensbasierte Nutzungsintention.

Die *Gewohnheit* ist das dritte neue Konstrukt des UTAUT2 Modells. Gewohnheit ist definiert als die Einschätzung des mit der neuen Technologie verbundenen Automatismus der Nutzung. Anders als die Nutzungserfahrung können die Probanden dies auch bereits vor der Verfügbarkeit einer neuen Technologie sinnvoll beantworten (Davis & Venkatesh, 2004). Neben der verhaltensbasierten Nutzungsintention und der Einstellung zur Nutzung beeinflusst die Gewohnheit die tatsächliche Nutzung direkt (Venkatesh et al., 2012) und kann somit für die Prognose der tatsächlichen Nutzung verwendet werden. Auch vor diesem Hintergrund ist die Untersuchung der Gewohnheit zur Prognose der Akzeptanz von Innovationen von Relevanz. Wir formulieren daher die folgende Hypothese:

H7: Je höher die Gewohnheit zur Nutzung einer neuen Technologie, desto höher ist die verhaltensbasierte Nutzungsintention.

Das in Abbildung 26 dargestellte Forschungsmodell fasst die sieben Hypothesen zusammen, die wir in diesem Abschnitt hergeleitet haben.

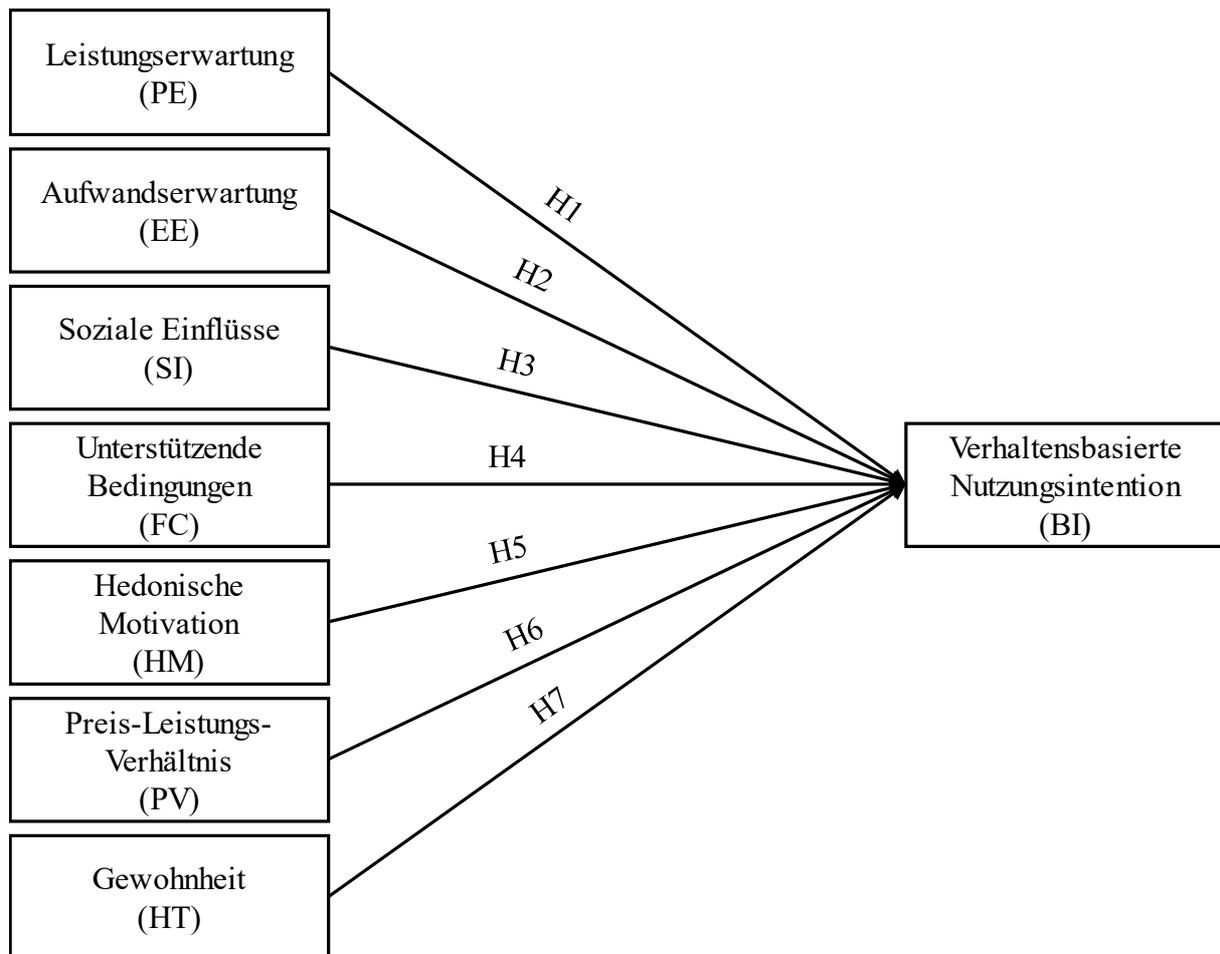


Abbildung 26: Forschungsmodell der Studie 2

Quelle: Eigene Darstellung

6.3 Material und Methoden

Die im vorherigen Abschnitt beschriebenen Hypothesen prüfen wir mittels eines strukturierten Fragebogens, wie in Abschnitt 4.1 erläutert. Der strukturierte Fragebogen wird in Form eines Online-Fragebogens an die Probanden verteilt. Hierfür nutzen wir die Software LimeSurvey. Die Probanden erhalten einen Link zur Umfrage per E-Mail mit der Bitte, die Umfrage auszufüllen. Zur Beantwortung der Fragen zur Akzeptanz autonomer Fahrzeuge dient eine Likert-Skala mit sieben Punkten von 1 = „*Strongly disagree*“, was einer vollständigen Ablehnung der Aussage entspricht, bis 7 = „*Strongly agree*“, also einer vollständigen Zustimmung. Die dazwischenliegenden Skalenelemente wurden nicht benannt, damit eine äquidistante Verteilung der Antwortoptionen angenommen werden kann. Um Reihenfolgeeffekte zu vermeiden, wurde die Fragenreihenfolge für die Fragen bei jedem Probanden zufällig beim Start der Umfrage festgelegt. Die Umfrage enthält neben den Fragen zu Akzeptanz auch Fragen zu Alter, Geschlecht, Fahrerfahrung und Autobesitz. Weiterhin erheben wir die bisherigen Erfahrungen der Probanden mit autonomen Fahrzeugen sowie eine Selbsteinschätzung des Fachwissens zu autonomen Fahrzeugen, Informationstechnologie, Ingenieurwissenschaft und Autos im Allgemeinen. Für eine Einschätzung der Marktteilnehmer, die an autonomen Fahrzeugen arbeiten, befragen wir die Probanden außerdem zu den führenden

Entwicklern autonomer Fahrzeuge und welche davon sichere autonome Fahrzeuge entwickeln werden. Der Fragebogenteil zur Akzeptanz von Studie 2 befindet sich in Anhang B.

Wir messen die Konstrukte reflektiv und verwenden die Originalfragen der UTAUT2 Studie mit Ausnahme des Indikators PE4 bei der Leistungserwartung, wie wir in Abschnitt 6.3.1 erläutern werden. Die aufgrund von Validitätsproblemen entfernten Indikatoren des UTAUT2 Modells PE2 und HT4 verwenden wir nicht (Venkatesh et al., 2012). Die Operationalisierung der Konstrukte erfolgt mittels etablierter Indikatoren, die theoretisch fundiert sind und bereits empirisch validiert wurden. Diese passen wir für den Anwendungsfall autonomer Fahrzeuge jeweils nur an. Zur besseren Lesbarkeit sind die Konstrukte wie folgt abgekürzt:

- PE (Performance Expectancy) steht für die Leistungserwartung
- EE (Effort Expectancy) steht für die Aufwandserwartung
- SI (Social Influence) steht für Soziale Einflüsse
- FC (Facilitating Conditions) steht für Unterstützende Bedingungen
- HM (Hedonic Motivation) steht für die hedonische Motivation zur Nutzung
- PV (Price Value) steht für das Preis-Leistungs-Verhältnis
- HT (Habit) steht für Gewohnheit
- BI (Behavioral Intention) steht für die Nutzungsintention

Die UTAUT2 Studie, die wir zur Operationalisierung aller Konstrukte verwenden, untersucht die Akzeptanz von mobilem Internet bei Privatpersonen (Venkatesh et al., 2012). Im Gegensatz zu UTAUT misst das UTAUT2 Modell die Akzeptanz nicht in einem betrieblichen Kontext. Daraus leiten sich neue Wirkbeziehungen ab wie beispielsweise der direkte Effekt der unterstützenden Bedingungen auf die Nutzungsintention. Es lassen sich außerdem neue Konstrukte wie das Preis-Leistungs-Verhältnis, das in einem betrieblichen Kontext weniger relevant ist, ableiten. Durch den neuen Kontext wird das Verständnis der Akzeptanz erweitert und ein Ausgangspunkt für weitere Forschungsvorhaben im Consumer Umfeld geschaffen (Venkatesh et al., 2012).

Der Zweck von UTAUT war die Kombination der damals aktuellen Forschungsergebnisse der Technologieakzeptanzforschung in ein gemeinsames Modell zu konsolidieren (Venkatesh et al., 2003). Das so entstandene UTAUT Modell fasst die damals acht weitverbreitetsten Modelle der Technologieakzeptanz zusammen. Vor dem UTAUT Modell bestand Unklarheit, welches Modell für die Untersuchung der Akzeptanz verwendet werden sollte und ausgehend von welchem Modell weitere Forschungsvorhaben zur Modellergänzung gestartet werden sollten (Venkatesh, Thong & Xu, 2016). Das UTAUT2 Modell entstand ebenfalls mit dem Ziel, die von UTAUT ausgehenden Forschungspfade erneut zusammenzuführen (Venkatesh et al., 2012). Aufgrund des breiten wissenschaftlichen Zuspruchs und der Anwendung des UTAUT Modells, gab es seit dessen Veröffentlichung im Jahr 2003 zahlreiche Forschungsvorhaben, die auf UTAUT basieren. Im Rahmen dieser Forschungsvorhaben wurden dem UTAUT Modell weitere Einflussfaktoren und Wirkbeziehungen für die Technologieakzeptanz hinzugefügt. Das UTAUT2 Modell integriert diese mit dem Ziel, im Consumer Bereich erneut einen einheitlichen Ausgangspunkt für zukünftige Forschungsvorhaben zu schaffen (Venkatesh et al., 2012).

Die UTAUT2 Studie von Venkatesh et al. (2012) vergleicht das UTAUT Modell mit dem UTAUT2 Modell. Da das UTAUT Modell eine Teilmenge des UTAUT2 Modells ist, können die beiden Modelle gut miteinander verglichen werden. Werden den erhobenen Daten in der UTAUT2 Studie das UTAUT Modell zugrunde gelegt, wird ein R^2 -Wert für die Nutzungsintention von 0,35 erreicht. Dies entspricht ungefähr dem Wert der ursprünglichen UTAUT Studie von $R^2 = 0,31$ (Venkatesh et al., 2003). Werden alle Moderationseffekte berücksichtigt, erhöht sich der R^2 -Wert auf 0,56. Mit dem UTAUT2 Modell hingegen wird ein R^2 von 0,44 erreicht, wenn nur direkte Effekte berücksichtigt werden und ein R^2 -Wert von 0,74 mit allen Moderationseffekten (Venkatesh et al., 2012). Weiterhin sind alle neuen Wirkbeziehungen des UTAUT2 Modells signifikant zum Signifikanzniveau von 0,05. Somit konnte gezeigt werden, dass die Erweiterungen des UTAUT Modells im Consumer Kontext sinnvoll sind und sich das Verständnis der Nutzungsintention durch das UTAUT2 Modell verbessert (Venkatesh et al., 2012).

Wir verwenden in Studie 2 dieser Dissertation das UTAUT2 Modell um zu prüfen, welche der Modellerweiterungen des UTAUT Modells auch für das Modell zur Prognose der Akzeptanz von Innovationen sinnvoll sind, das wir in Kapitel 5 vorgestellt haben. Wir verwenden die Operationalisierung der Indikatoren des UTAUT2 Modells, um mögliche Unterschiede durch eine abweichende Operationalisierung in den Ergebnissen auszuschließen zu können. Im Vergleich zur Studie 1 dieser Dissertation in Kapitel 5 verwenden wir für die autonomen Fahrzeuge den Begriff „*self-driving cars*“ anstatt „*autonomous driving*“, da diese Bezeichnung zum Zeitpunkt der Erstellung von Studie 2 häufig in den Medien verwendet wird. Wir erläutern den Untersuchungsgegenstand zum eindeutigen Verständnis nochmals im Fragebogen mit folgender Beschreibung (NHTSA, 2013; Yeomans, 2014):

Self-driving cars are capable of driving unaided for the entire journey with no human intervention. The self-driving car is designed to perform all safety-critical driving functions (e.g., braking, accelerating, steering) and monitor roadway conditions for an entire trip. The driver only needs to provide destination or navigation input, but is not expected to be available for control at any time during the trip.

Entsprechend der Beschreibung sind autonome Fahrzeuge in der Lage, die gesamte Fahrt ohne menschliches Zutun selbstständig zu bewältigen (Yeomans, 2014). Das autonome Fahrzeug ist so konzipiert, dass es alle sicherheitskritischen Fahrfunktionen (z. B. Bremsen, Beschleunigen, Lenken) ausführt und die Fahrbahnbedingungen während der gesamten Fahrt überwacht (NHTSA, 2013). Der Fahrer muss nur Ziel- oder Navigationseingaben vornehmen, aber es wird nicht erwartet, dass er während der Fahrt jederzeit für die Kontrolle zur Verfügung steht. Dies entspricht der Beschreibung der in Abschnitt 3.2 vorgestellten SAE Stufe 5 der Fahrzeugautomatisierung.

6.3.1 Operationalisierung der Leistungserwartung (PE)

Die Operationalisierung von PE ist in Tabelle 32 abgebildet. PE1 bis PE3 sind aus dem UTAUT2 Originalfragebogen abgeleitet (Venkatesh et al., 2012). Der vierte Indikator des Konstruktes PE zeigte Validitätsprobleme in der UTAUT2 Studie und wurde daher von

Venkatesh et al. (2012) für die Datenauswertung entfernt. Der entfernte Indikator lautet im originalen Wortlaut: „*Using mobile Internet increases my chances of achieving things that are important to me.*“ Als Ersatz für den Indikator verwenden wir stattdessen den Indikator PE2 aus Studie 1 dieser Dissertation. Im Übrigen sind auch die Indikatoren PE2 und PE3 in Studie 1 enthalten, wie in Tabelle 32 ersichtlich. Nur PE1 hat keine Entsprechung bei den Indikatoren des PE Konstruktes in Studie 1. Mit PE1 wird allgemein die Nützlichkeit autonomer Fahrzeuge für den Alltag abgefragt, ohne auf konkrete Aspekte einzugehen. Dadurch wird eine alltägliche Verwendung impliziert, die auch bei autonomen Fahrzeugen gegeben sein könnte.

Nr.	Frage in Fragebogen	Originalfrage	Indikator in Studie 1
PE1	I will find self-driving cars useful in my daily life.	I find mobile Internet useful in my daily life. (Venkatesh et al., 2012)	Nicht vorhanden
PE2	Using self-driving cars will help me accomplish things more quickly.	Using mobile Internet helps me accomplish things more quickly. (Venkatesh et al., 2012)	PE1
PE3	Using self-driving cars will increase my productivity.	Using mobile Internet increases my productivity. (Venkatesh et al., 2012)	PE3
PE4	I will save time by using self-driving cars.	I save time by using a mobile device. (Carlsson et al., 2006)	PE2

Tabelle 32: Operationalisierung von PE für Studie 2

Quelle: Eigene Darstellung

6.3.2 Operationalisierung der Aufwandserwartung (EE)

Die Operationalisierung von EE entspricht im Wesentlichen der Operationalisierung der Studie 1, wie in Tabelle 33 ersichtlich. Die Indikatoren bezeichnen wir entsprechend des UTAUT2 Modells (Venkatesh et al., 2012), wodurch sich eine andere Reihenfolge der Indikatoren als in Studie 1 dieser Dissertation ergibt, wie in Tabelle 33 ersichtlich. Allerdings wird die Reihenfolge der Indikatoren im Fragebogen für jeden Probanden zufällig generiert und ist daher nur für die Datenauswertung von Relevanz.

Nr.	Frage in Fragebogen	Originalfrage	Indikator in Studie 1
EE1	Learning how to use self-driving cars will be easy for me.	Learning how to use mobile Internet is easy for me. (Venkatesh et al., 2012)	EE4
EE2	My interaction with self-driving cars will be clear and understandable.	My interaction with mobile Internet is clear and understandable. (Venkatesh et al., 2012)	EE1
EE3	I will find self-driving cars easy to use.	I find mobile Internet easy to use. (Venkatesh et al., 2012)	EE3
EE4	It will be easy for me to become skillful at using self-driving cars.	It is easy for me to become skillful at using mobile Internet. (Venkatesh et al., 2012)	EE2

Tabelle 33: Operationalisierung von EE für Studie 2

Quelle: Eigene Darstellung

6.3.3 Operationalisierung der sozialen Einflüsse (SI)

Dem Konstrukt SI sind im UTAUT2 Modell nur drei Indikatoren zugewiesen, wie in Tabelle 34 ersichtlich. SI1 und SI2 sind auch im Fragebogen zu Studie 1 dieser Dissertation enthalten. Der neue Indikator SI3 beschreibt, dass Individuen, deren Meinung der Proband schätzt, es vorziehen, wenn der Proband die neue Technologie nutzen würde. Somit ist der Indikator ähnlicher zu SI1 und SI2 als es die Indikatoren SI3-SI5 der Studie 1 sind. Diese beziehen sich auf Prestige und Status, der mit der Nutzung der neuen Technologie verbunden sind. Die größere Ähnlichkeit könnte sich in einer höheren Internen-Konsistenz-Reliabilität von SI äußern. Zu ähnliche Indikatoren können jedoch auch zu Problemen bei der Inhaltsvalidität (Rossiter, 2002) und zu stark korrelierten Fehlertermen führen (Drolet & Morrison, 2001; Hayduk & Littvay, 2012), was sich in überhöhten Werten bei der Internen-Konsistenz-Reliabilität von über 0,90 andeutet (Hair et al., 2017, S. 97).

Nr.	Frage in Fragebogen	Originalfrage	Indikator in Studie 1
SI1	People who are important to me will think that I should use self-driving cars.	People who are important to me think that I should use mobile Internet. (Venkatesh et al., 2012)	SI2
SI2	People who influence my behavior will think that I should use self-driving cars.	People who influence my behavior think that I should use mobile Internet. (Venkatesh et al., 2012)	SI1
SI3	People whose opinions that I value will prefer that I use self-driving cars.	People whose opinions that I value prefer that I use mobile Internet. (Venkatesh et al., 2012)	Nicht vorhanden

Tabelle 34: Operationalisierung von SI für Studie 2

Quelle: Eigene Darstellung

6.3.4 Operationalisierung der unterstützenden Bedingungen (FC)

Das Konstrukt FC hat im UTAUT Modell keinen direkten Einfluss auf die Nutzungsintention und ist nicht Teil des Modells zur Prognose der Akzeptanz von Innovationen, das wir in Kapitel 5 erläutern. Wie im Abschnitt 6.2 erläutert, rechnen wir mit einem eher geringen Einfluss des FC Konstruktes auf BI, da wie bei der UTAUT Originalstudie von Venkatesh et al. (2003) die unterstützenden Bedingungen für autonome Fahrzeuge unter den Probanden vermutlich relativ ähnlich verteilt und eher gering sind. Dennoch sind die Indikatoren auch für eine noch nicht nutzbare Technologie sinnvoll operationalisierbar wie in Tabelle 35 ersichtlich. FC1 adressiert die verfügbaren Ressourcen zur Nutzung einer neuen Technologie, beispielsweise in Form von Handbüchern, Schulungen oder Informationen im Internet zum Zeitpunkt der Nutzung. Ergänzt wird FC1 vom bereits vorhandenen Wissen zur Nutzung in FC2, das somit nicht extra für die Nutzung angeeignet werden muss. Auch FC4 beschreibt eine Informationsquelle für die Nutzung einer neuen Technologie: Andere Personen, die die neue Technologie sowie deren Nutzung erklären können, wenn es zu Schwierigkeiten kommt. Der Indikator FC3 unterscheidet sich etwas von den restlichen Indikatoren und beschreibt die Kompatibilität der neuen Technologie mit bereits vorhandenen Technologien, die der Proband verwendet.

Nr.	Frage in Fragebogen	Originalfrage
FC1	I will have the resources necessary to use self-driving cars.	I have the resources necessary to use mobile Internet. (Venkatesh et al., 2012)
FC2	I will have the knowledge necessary to use self-driving cars.	I have the knowledge necessary to use mobile Internet. (Venkatesh et al., 2012)
FC3	Self-driving cars will be compatible with other technologies I use.	Mobile Internet is compatible with other technologies I use. (Venkatesh et al., 2012)
FC4	I will be able to get help from others when I have difficulties using self-driving cars.	I can get help from others when I have difficulties using mobile Internet. (Venkatesh et al., 2012)

Tabelle 35: Operationalisierung von FC für Studie 2

Quelle: Eigene Darstellung

6.3.5 Operationalisierung der hedonischen Motivation (HM)

Die Operationalisierung von HM mit drei Indikatoren ist in Tabelle 36 abgebildet. Bei HM handelt es sich um ein neues Konstrukt des UTAUT2 Modells, das aufgrund des Fokus auf den Consumer Bereich neu hinzugefügt wurde (Venkatesh et al., 2012). HM umfasst nicht-funktionale Aspekte einer neuen Technologie, die mit Freude oder Vergnügen verbunden sind (van der Heijden, 2004). Die Technologie wird also nicht nur eingesetzt, um möglichst schnell eine Aufgabe zu erfüllen, wie im Falle von PE oder möglichst einfach zu einer Lösung zu kommen, wie im Falle von EE. Stattdessen ist Nutzung an sich für das Individuum erstrebenswert, wie dies beispielsweise im Rahmen von Heim- und Freizeitaktivitäten der Fall ist (van der Heijden, 2004). Der Indikator HM1 fragt dementsprechend ab, ob die Verwendung der neuen Technologie lustig wäre oder mit Spaß verbunden ist. Einen ähnlichen Aspekt adressiert auch der Indikator HM2, der das Vergnügen bei der Nutzung beinhaltet. Der dritte Indikator HM3 beinhaltet die Unterhaltsamkeit der Verwendung, wie dies beispielsweise beim Lesen einer guten Geschichte der Fall ist.

Nr.	Frage in Fragebogen	Originalfrage
HM1	Using self-driving cars will be fun.	Using mobile Internet is fun. (Venkatesh et al., 2012)
HM2	Using self-driving cars will be enjoyable.	Using mobile Internet is enjoyable. (Venkatesh et al., 2012)
HM3	Using self-driving cars will be very entertaining.	Using mobile Internet is very entertaining. (Venkatesh et al., 2012)

Tabelle 36: Operationalisierung von HM für Studie 2

Quelle: Eigene Darstellung

6.3.6 Operationalisierung des Preis-Leistungs-Verhältnisses (PV)

Das Konstrukt PV ist ein Teil des UTAUT2 Modells und folglich ebenfalls im Fragebogen von Studie 2 dieser Dissertation enthalten, auch wenn vor Marktstart der neuen Technologie noch keine konkreten Preise bekannt sind. Aufgrund der Formulierung der Indikatoren sind die Fragen zu PV zwar anwendbar aber für Probanden womöglich schwierig zu beantworten, wie in Abschnitt 6.2 erläutert. Tabelle 37 zeigt die Operationalisierung von PV mit drei Indikatoren. PV1 beschreibt, dass die neue Technologie angemessen bepreist sein wird und beinhaltet somit noch nicht explizit die Gegenüberstellung zum Wert. Dies ist beim Indikator PV2 der Fall, der beschreibt, dass autonome Fahrzeuge einen guten Gegenwert für das für die Nutzung erforderliche Geld liefern. Auch PV3 enthält explizit den Vergleich von Preis und Leistung. Der Indikator beschreibt, dass man für den erwarteten (Endkunden-) Preis autonomer Fahrzeuge einen guten Gegenwert erhalten wird.

Nr.	Frage in Fragebogen	Originalfrage
PV1	Self-driving cars will be reasonably priced.	Mobile Internet is reasonably priced. (Venkatesh et al., 2012)
PV2	Self-driving cars will be a good value for the money.	Mobile Internet is a good value for the money. (Venkatesh et al., 2012)
PV3	At the expected price, self-driving cars will provide a good value.	At the current price, mobile Internet provides a good value. (Venkatesh et al., 2012)

Tabelle 37: Operationalisierung von PV für Studie 2

Quelle: Eigene Darstellung

6.3.7 Operationalisierung der Gewohnheit (HT)

Das letzte neue UTAUT2 Konstrukt ist HT, das wir entsprechend Tabelle 38 operationalisieren. Bei HT handelt es sich sowohl um einen direkten Einflussfaktor für BI als auch um einen direkten Einflussfaktor für die tatsächliche Nutzung (Kim & Malhotra, 2005; Kim, Malhotra & Narasimhan, 2005; Limayem, Hirt & Cheung, 2007). Obwohl die neue Technologie noch nicht verfügbar ist, adressieren die Indikatoren die Einschätzung der Probanden, inwiefern die Nutzung zur Gewohnheit werden könnte. Der Indikator HT1 fragt dies auch direkt so ab. HT2 beschreibt, dass die Nutzung der neuen Technologie zur Sucht werden könnte, obwohl die Nutzung freiwillig erfolgt. Bei HT3 hingegen ist der Proband zur Nutzung autonomer Fahrzeuge verpflichtet, beispielsweise aufgrund von Regularien oder mangels Alternativen.

Nr.	Frage in Fragebogen	Originalfrage
HT1	The use of self-driving cars will become a habit for me.	The use of mobile Internet has become a habit for me. (Venkatesh et al., 2012)
HT2	I will be addicted to using self-driving cars.	I am addicted to using mobile Internet. (Venkatesh et al., 2012)
HT3	I will have to use self-driving cars.	I must use mobile Internet. (Venkatesh et al., 2012)

Tabelle 38: Operationalisierung von HT für Studie 2

Quelle: Eigene Darstellung

6.3.8 Operationalisierung der Nutzungsintention (BI)

Die Operationalisierung von BI entspricht im Wesentlichen der Operationalisierung der Studie 1, wie in Tabelle 39 ersichtlich. Allerdings wurde BI in Studie 1 mit vier Indikatoren operationalisiert. BI2R aus Studie 1 dieser Dissertation kann keinem der Indikatoren des UTAUT2 Modells zugeordnet werden und auch die anderen Indikatoren sind etwas anders formuliert. Beispielsweise beschreibt BI1, dass der Proband die neue Technologie in Zukunft nutzen möchte, wohingegen BI1 aus Studie 1 sich etwas konkreter auf die Nutzung in den nächsten Monaten bezieht. Der Indikator BI2 beschreibt die tägliche Nutzung der neuen Technologie, immer wenn dies möglich ist. Bei BI4 Studie 1 wird hingegen ein Wechsel zur neuen Technologie beschrieben. Der Indikator BI3 enthält zusätzlich zum Indikator aus Studie 1 eine Angabe zur Nutzungshäufigkeit, und zwar, dass das Individuum eine häufige Nutzung der neuen Technologie plant.

Nr.	Frage in Fragebogen	Originalfrage	Indikator in Studie 1
BI1	I intend to use self-driving cars in the future.	I intend to continue using mobile Internet in the future. (Venkatesh et al., 2012)	BI1
BI2	I will always try to use self-driving cars in my daily life.	I will always try to use mobile Internet in my daily life. (Venkatesh et al., 2012)	BI4
BI3	I plan to use self-driving cars frequently.	I plan to continue to use mobile Internet frequently. (Venkatesh et al., 2012)	BI3

Tabelle 39: Operationalisierung von BI für Studie 2

Quelle: Eigene Darstellung

6.4 Ergebnisse

6.4.1 Erhebung und Prüfung der Daten

Im Zeitraum vom 28.01.2016 bis zum 02.02.2016 haben insgesamt 154 Probanden an der Online-Umfrage teilgenommen. Diese Studie wurde somit 180 Tage nach Studie 1 dieser Dissertation durchgeführt, die wir in Kapitel 5 beschreiben.

Die Bereinigung der Daten fand anhand der Kontrollfrage statt, die für jeden Probanden an einer anderen zufällig bestimmten Position im Fragebogen positioniert wurde (Hair et al., 2017, S. 50f). Alle Probanden haben die Kontrollfrage richtig beantwortet. Es konnten auch keine Antwortmuster, wie beispielsweise durch Straight-Lining, in den Umfragedaten identifiziert werden. Somit konnte der komplette Datensatz verwendet werden.

Unter den 154 Teilnehmern befinden sich 38 Frauen (24,7 %) und 116 Männer (75,3 %). Im Vergleich zur Studie 1 ist der Frauenanteil also noch etwas geringer (28,6 % Frauen, 67,0 % Männer und 4,3 % ohne Geschlechtsangabe). Das Durchschnittsalter beträgt 20,4 Jahre, im Median 20 Jahre und liegt in einer Spanne zwischen 17 und 37 Jahren. Die Probanden dieser Studie sind also noch etwas jünger als die Probanden der Studie 1 (Mittelwert = 20,6 Jahre, Median = 20 Jahre). Mit 131 Probanden besitzen 85,1 % aller Studienteilnehmer einen Führerschein und somit deutlich weniger als in Studie 1 (96,2 %). Trotzdem besitzen 54 Probanden (35,1 %) ein eigenes Auto und somit mehr als in Studie 1 (33 %). Die Probanden mit Führerschein besitzen diesen durchschnittlich seit 2,86 Jahren. Tabelle 40 fasst die Daten zur Stichprobe zusammen.

	Anzahl	Anteil
Gültige Fragebögen	154	100 %
Frauen	38	24,7 %
Männer	116	75,3 %
Alter (Mittelwert)	20,4 Jahre	
Führerschein vorhanden	131	85,1 %
Kein Führerschein	23	14,9 %
Fahrerfahrung (Mittelwert)	2,86 Jahre	
Eigenes Auto	54	35,1 %
Kein eigenes Auto	100	64,9 %

Tabelle 40: Deskriptive Statistik zu den Probanden von Studie 2

Quelle: Eigene Darstellung

6.4.2 Erfahrung und Fachwissen

Sechs Probanden (3,90 %) gaben an, bereits erste Erfahrungen mit autonomen Fahrzeugen gesammelt zu haben. Die Erfahrungen konnten in einem Freitextfeld näher erläutert werden. Es wurden folgende Erfahrungen angegeben:

- Proband 1: ACC in einem BMW der 7er Serie
- Proband 2: ACC von VW und Parkassistent von Mercedes
- Proband 3: Autopilot von Tesla
- Proband 4: Auto mit Spurhalteassistent, automatischer Bremse und ACC
- Proband 5: Mitarbeit in einer Forschungsabteilung von BMW zum hochautomatisierten Fahren
- Proband 6: Werkstudent bei Audi

Entsprechend der SAE Definition (Tabelle 1) handelt es sich jedoch wahrscheinlich bei allen sechs Probanden nicht um autonomes Fahren. Bei ACC handelt es sich um ein Fahrerassistenzsystem (SAE Stufe 1), da nur die Längsführung des Fahrzeuges in geeigneten Situationen übernommen wird. Beim Parkassistent handelt es sich um eine Teilautomatisierung (SAE Stufe 2). Der Fahrer übergibt beim Parken die Quer- und Längsführung dem System. Der Fahrer ist in der Regel aber zu jeder Zeit verantwortlich für das unfallfreie Einparken, muss das System also permanent überwachen beim Parkvorgang. Bei den Probanden 3 und 4 handelt es sich um Teilautomatisierung (SAE Stufe 2), da trotz Übernahme der Quer- und Längsführung weiterhin der Fahrer zur Überwachung des Systems verantwortlich ist. Proband 5 erwähnt in seiner Antwort explizit den Schwerpunkt hochautomatisiertes Fahren (SAE Stufe 3), bei dem der Fahrer in bestimmten Situationen das System nicht überwachen muss, bis eine Übernahmeaufforderung durch das System erfolgt. Proband 6 hat seine Werkstudententätigkeit nicht näher erläutert.

Fachwissen	Autos	Ingenieurwissenschaft	Informationstechnologie	Autonome Fahrzeuge
1 = Überhaupt kein Fachwissen	6	13	1	21
2	26	33	5	33
3	28	38	12	31
4	21	39	25	19
5	36	22	66	36
6	24	5	31	10
7 = Sehr gutes Fachwissen	13	4	14	4

Tabelle 41: Fachwissen im Bereich autonomer Fahrzeuge und angrenzenden Gebieten bei Studie 2

Quelle: Eigene Darstellung

Um das Fachwissen zu autonomen Fahrzeugen weiter zu differenzieren, haben wir die Probanden ihr Fachwissen zu autonomen Fahrzeugen, Informationstechnologie,

Ingenieurwissenschaft und Autos im Allgemeinen selbst einschätzen lassen mittels einer 7-Punkte Likert Skala. Das Fachwissen im Bereich Informationstechnologie ($M = 4,942$, $SD = 1,200$) wurde dabei von den Probanden am höchsten eingeschätzt. Auch das Fachwissen im Automobilbereich liegt über dem Skalendurchschnitt von 4 Punkten ($M = 4,162$, $SD = 1,678$). Unter dem Skalendurchschnitt liegen dicht beieinander das Fachwissen bezüglich selbstfahrender Kraftfahrzeuge ($M = 3,403$, $SD = 1,635$) und Ingenieurwissenschaft ($M = 3,357$, $SD = 1,403$). Tabelle 41 zeigt die Verteilung der Antworten. Die Auswertung der Selbsteinschätzung des Fachwissens ist in Tabelle 42 zusammengefasst.

Fachwissen	M	SD
Autonome Fahrzeuge	3,403	1,635
Informationstechnologie	4,942	1,200
Ingenieurwissenschaft	3,357	1,403
Autos	4,162	1,678

Tabelle 42: Auswertung des Fachwissens bei Studie 2

Quelle: Eigene Darstellung

Bezüglich der Entwicklung autonomer Fahrzeuge als führend bewerten die Probanden IT-Firmen wie Apple oder Google ($N = 82$). Besonders über das Google Car wird in diesem Zusammenhang häufig berichtet. Mit einigem Abstand werden deutsche Autohersteller ($N = 35$) und neue Mobilitätsanbieter ($N = 27$) genannt. Nur wenige Probanden votieren für internationale Autohersteller ($N = 5$), neue Startups ($N = 2$) und andere ($N = 3$). Unter der Option „Andere“ wurde in allen drei Fällen Kooperationen aus mehreren Firmen angegeben. In einem Fall wurde konkret die Zusammenarbeit eines traditionellen Autoherstellers mit einer IT-Firma angegeben. Zulieferern von Autoherstellern spricht keiner der Probanden eine Führungsrolle zu.

Betrachtet man nun die Einschätzung der Probanden, wer führend bei der Entwicklung von *sicheren* autonomen Fahrzeugen ist, so ergibt sich eine interessante Änderung. Mit großem Abstand werden nun die deutschen Autohersteller als führend bewertet ($N = 96$). Es folgen IT-Firmen ($N = 35$) und neue Mobilitätsanbieter ($N = 12$). Wenige Stimmen entfallen erneut auf internationale Autohersteller ($N = 8$), neue Startups ($N = 2$) und andere ($N = 1$). Die Erläuterung für „Andere“ gibt „Testsieger“ als führend bei der Sicherheit an. Der Proband wünscht sich also Vergleichstests für autonome Fahrzeuge, die ähnlich wie bei heutigen Crashtests die Sicherheit von autonomen Fahrzeugen bewerten. Auch bei *sicheren* autonomen Fahrzeugen werden Zulieferer von Autoherstellern nicht genannt. Abbildung 27 visualisiert die Ergebnisse der Auswertung.

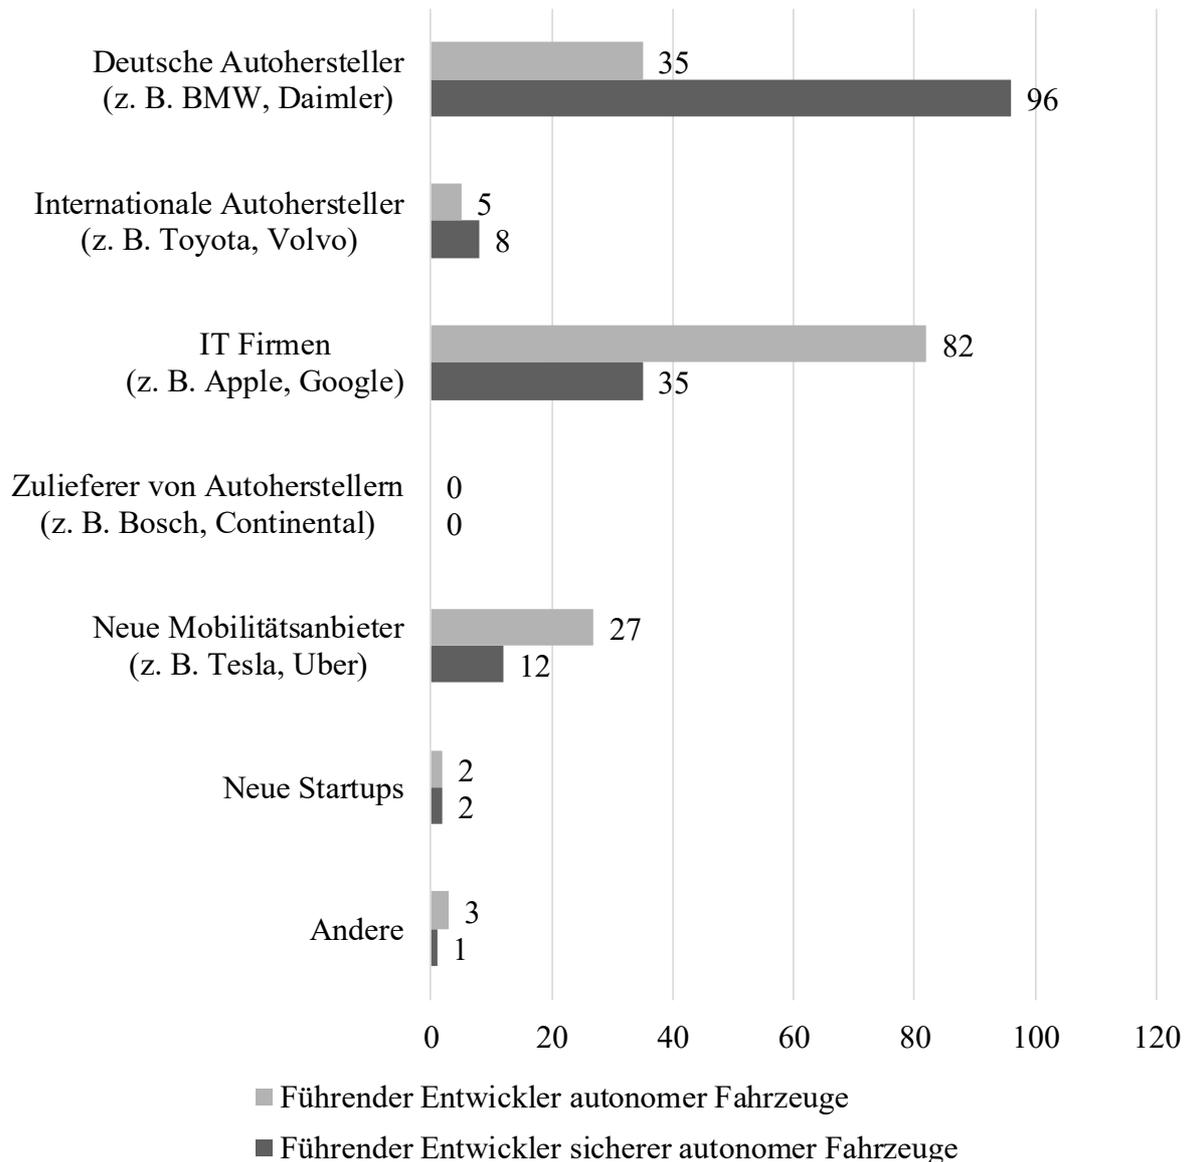


Abbildung 27: Führender Entwickler (sicherer) autonomer Fahrzeuge

Quelle: Eigene Darstellung

Die Möglichkeit, die Auswahl des führenden Entwicklers von (sicheren) autonomen Fahrzeugen zu begründen wurde von 61 Probanden genutzt. Davon enthielten 55 Antworten (90 %) verwertbare Informationen. 13 Probanden beschreiben, dass etablierte Fahrzeughersteller die größte Erfahrung haben, sichere Fahrzeuge oder Fahrerassistenzsysteme in Serie zu produzieren und daher die führenden Entwickler autonomer Fahrzeuge sein werden. 11 der 13 Probanden beziehen sich dabei explizit auf deutsche Hersteller. Ein Proband schreibt hierzu beispielsweise „[...] *The German car manufacturers have the most experience in assistance systems and building cars and all of them develop their own thing, so [I think] that they will [be] successful.*“

Ein wesentlicher Punkt, der für etablierte Fahrzeughersteller spricht, ist die Erfahrung in der Produktion von Fahrzeugen, die den großen IT-Firmen fehlt und von acht Probanden angesprochen wurde: „*I think the German car companies have the experience and knowledge*

companies like Apple can never acquire in the next 50 years [...]“. Dazu gehört insbesondere ein Mangel an Erfahrung bei der Serienproduktion von Fahrzeugen: *„I dont [sic] think Google could manage to build cars in large n[um]bers without the help of a car manufacturer.“* Es wird auch darauf hingewiesen, dass nicht nur die Software ein gutes Fahrzeug ausmacht: *„[...] So there is more to do for a[n] overall good car [...]“.*

Dennoch sehen 12 Probanden in ihren Begründungen große IT-Firmen wie Google als führende Entwickler autonomer Fahrzeuge. Die Probanden nennen als Begründung hierfür den technologischen Vorsprung beispielsweise durch präzises Kartenmaterial (Google Maps) und erste Prototypen (Google Car), die große IT-Firmen bereits ausgiebig testen. Ein Proband schreibt hierzu beispielsweise: *„Google [is] already testing [the] Google Car on public roads [...]“.* Ein weiterer Proband schreibt zum Google Car: *„Google is the only known company to me that already has a quite successful self-driving car project.“* Die Bekanntheit des Google Car unter den Probanden deutet auch darauf hin, dass dieses seitens Googles gut vermarktet wird.

Die Motive von großen IT-Firmen für die Entwicklung autonomer Fahrzeuge werden unterschiedlich eingeschätzt. Ein Proband vermutet, dass große IT-Firmen gar kein Interesse hätten, selbst autonome Fahrzeuge zu verkaufen: *„[...] I highly doubt, that Apple, Google and so on will put much emphasis on doing so [...]“.* Stattdessen vermutet der Proband, dass große IT-Firmen sich rein auf den Softwareteil fokussieren werden: *„[...] [T]hey might very well be the leading innovators when it comes down to the programming part [...]“.* Ein Proband vermutet, ein weiterer Beweggrund von Google für die Entwicklung autonomer Fahrzeuge könnte der Zugang zu den durch autonome Fahrzeuge generierten Daten sein: *„[...] außerdem hat Google von autonomen Autos einen großen eigenen Vorteil. (v. a. Für Google Maps)“* (die Antwort des Probanden erfolgte auf Deutsch).

Weitere 12 Probanden sehen in ihrer Begründung ebenfalls große IT-Firmen im Vorteil. Diese führen an, dass aufgrund der Komplexität des autonomen Fahrens viel IT-Knowhow und ein großes Budget erforderlich ist. Ein Proband schreibt hierzu: *„[The necessary IT] can only be developed by a company with experience and a big budget [...]“.* Es werden auch konkrete Beispiele für die hohe Investitionsbereitschaft großer IT-Firmen genannt: *„[...] Apple lately hired lots of innovators from a self driving motorcycle company [...]“.* Die Antworten implizieren auch, dass es etablierten Herstellern an IT-Knowhow oder Investitionsbereitschaft mangelt.

Auch für die Branche relativ neuen Firmen wie Tesla wird von vier Probanden eine Chance auf die Technologieführerschaft eingeräumt, insbesondere aufgrund der Bekanntheit des Autopiloten und der Innovativität von Tesla: *„[...] They already have made it possible for their cars to drive without help with their latest software update. As shown in many videos, it works without any problems [...].“* Oder auch: *„[...] Tesla has the innovative power and also capital to adapt to new technologies very quickly, it's entire business model is actually based on innovation [...].“* Auch die große Bereitschaft von neuen Firmen Risiken einzugehen wird angesprochen: *„[...] it is uncertain if the great amount of risk that Tesla or Uber are taking in this field will make them the leading innov[a]tors. [...]“.*

Drei Probanden vermuten, dass die etablierten Hersteller gar kein Interesse daran haben, führender Hersteller von autonomen Fahrzeugen zu sein, da kein Markt hierfür existiert: „*It doesn't seem [sic] like companies like BMW or VW are willing to be a leader in this area*“. Die bestehenden Kunden würden lieber selbst fahren: „*[...] traditionally you drive cars by yourself. [...]*“. Sobald eine genügend große Nachfrage nach autonomen Fahrzeugen existiert, werden auch die etablierten Hersteller diese anbieten: „*[...] they'll be a big player at this market one day if the demand is big enough.*“ Als weiteres Hindernis für die etablierten Hersteller werden deren hoher Qualitätsanspruch genannt, die einen frühen Markteintritt verhindern: „*German car manufacturers [sic] will fear being [sic] labeled as unable to build a self-driving car if they release it to[o] early [...]*“.

Entsprechend der Meinung von 11 Probanden werden große IT-Firmen, neue Mobilitätsanbieter oder Start-Ups zumindest zur Entwicklung autonomer Fahrzeuge beitragen oder diese für neue Geschäftsmodelle nutzen, jedoch nicht selbst produzieren. Ein Proband schreibt hierzu: „*[...] I am convinced that startups increase the safety as it's mostly startups nowadays innovating existing products/business [...]*“. Häufig wird hier auch eine Zusammenarbeit mit den etablierten Fahrzeugherstellern genannt. Ein Proband führt aus, dass Firmen durch Aufgeschlossenheit und Kooperationen Vorteile bei der Entwicklung autonomer Fahrzeuge haben werden: „*[...] We can't really say who will win in the end, but the ones who cooperate and are open minded surely have a bigger advantage.*“

6.4.3 PLS-SEM Pfadmodell

Entsprechend der Definition der Hypothesen und des Forschungsmodells wurde das in Abbildung 28 dargestellte Pfadmodell mit SmartPLS 3 (Ringle et al., 2015) erstellt. Die Indikatoren sind jeweils mit der Abkürzung des zugehörigen Konstruktes und einer laufenden Nummer bezeichnet. Alle Konstrukte des Modells sind, wie in Abbildung 28 dargestellt, reflektiv gemessen. Die Ausführung des PLS-SEM Algorithmus ist konvergiert nach sieben Iterationen, sodass eine stabile Lösung erreicht wurde (Hair et al., 2017, S. 106f).

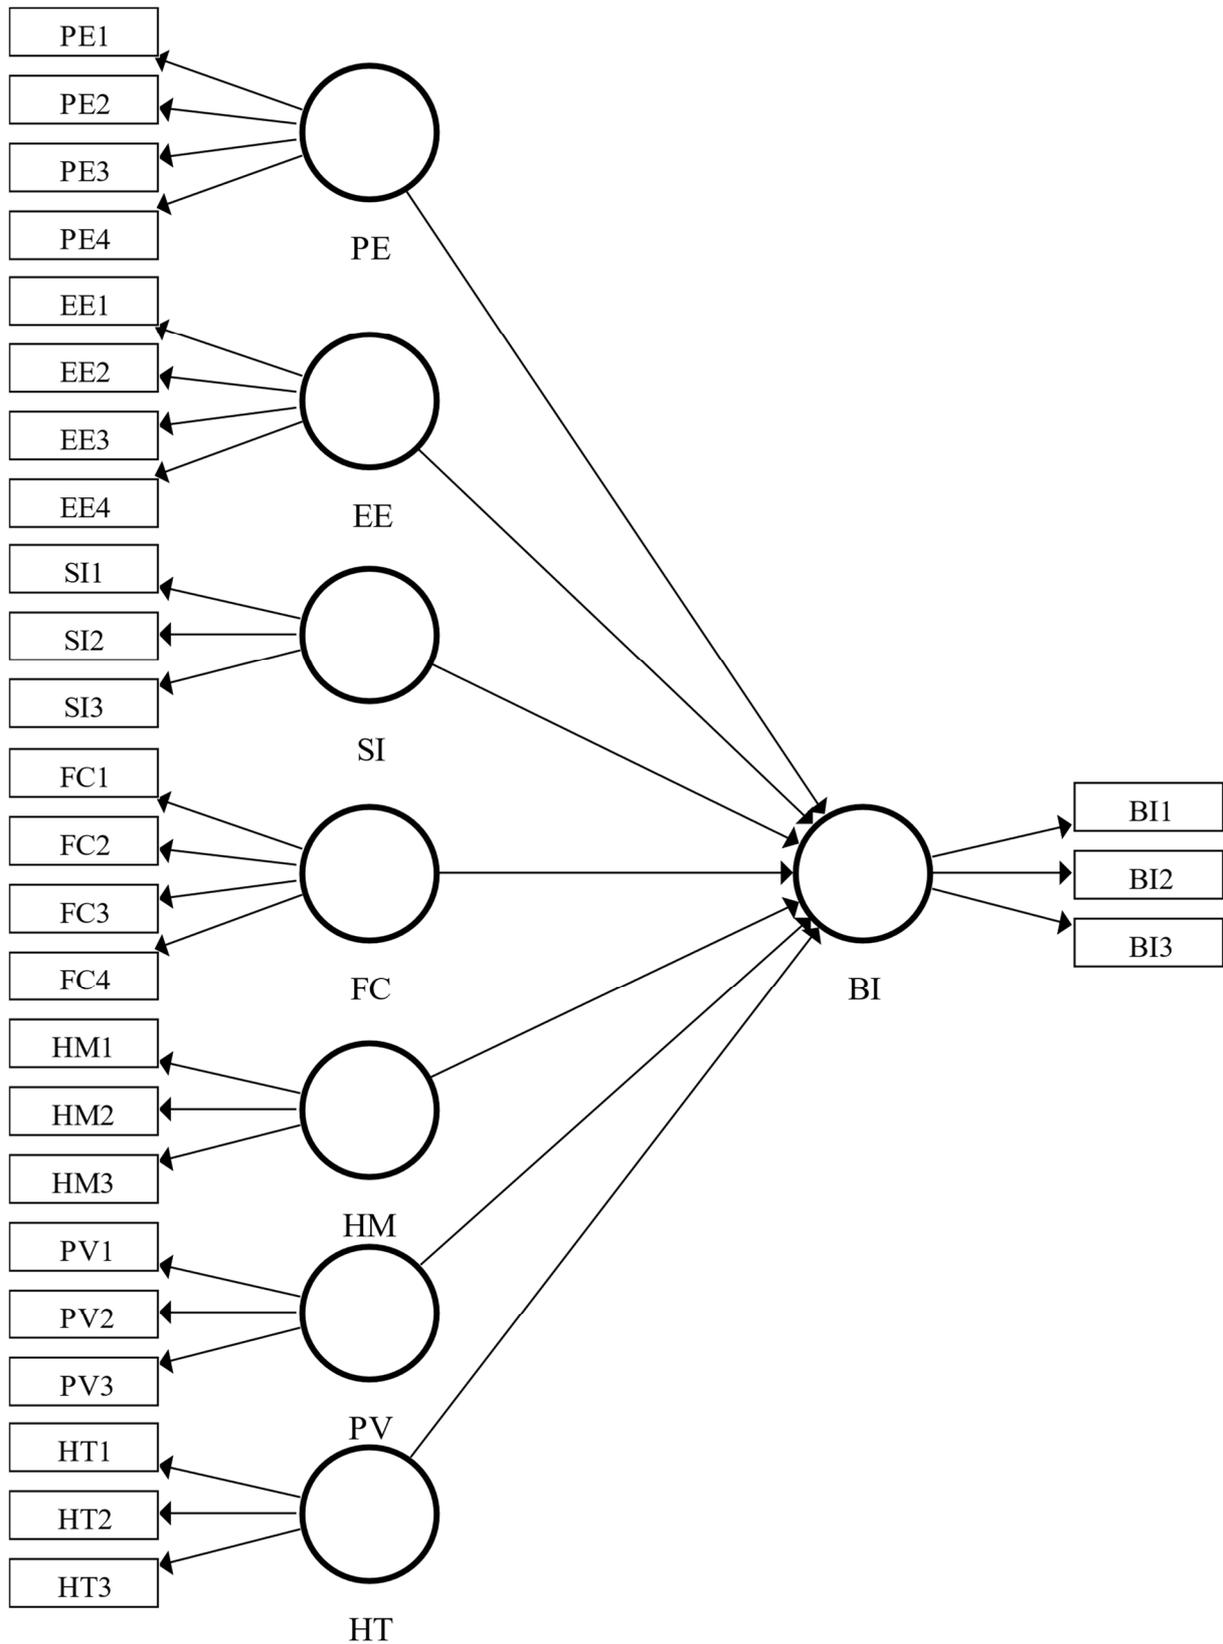


Abbildung 28: Initiales Pfadmodell der Studie 2

Quelle: Eigene Darstellung

6.4.4 Evaluation des Messmodells

In diesem Abschnitt führen wir die Evaluation des Messmodells anhand der in Abschnitt 4.2.5 beschriebenen Kriterien durch. Die Evaluation des Messmodells umfasst die Prüfung der Internen-Konsistenz-Reliabilität, der Konvergenzvalidität und der Diskriminanzvalidität anhand jeweils mehrerer Kriterien. Zur Berechnung der hierfür benötigten Werte verwenden wir SmartPLS 3 (Ringle et al., 2015).

Im ersten Schritt der Evaluation des Messmodells untersuchen wir die *Interne-Konsistenz-Reliabilität*. Cronbachs Alpha und die Composite-Reliabilität ist für FC unterhalb der akzeptablen Bereiche: $\alpha = 0,545 < 0,60$ und $\rho_C = 0,697 < 0,70$. Nur durch Entfernen der zwei Indikatoren FC1 und FC4 kann ein akzeptabler, aber niedriger Wert von $\alpha = 0,622$ erreicht werden. Somit betrachten wir die Interne-Konsistenz-Reliabilität nachdem wir FC1 und FC4 entfernt haben als hinreichend vorhanden.

Im zweiten Schritt der Evaluation des Messmodells untersuchen wir die *Diskriminanzvalidität* anhand von drei Ansätzen. Zunächst betrachten wir die HTMT-Verhältnisse. Diese liegen für HT und BI mit 0,941 sowie für EE und FC mit 0,946 über dem oberen Grenzwert von 0,90. Zur Behandlung des Problems prüfen wir die Entfernung von Indikatoren aus dem Modell um die durchschnittlichen Monotrait-Heteromethod-Korrelationen zu erhöhen und die durchschnittlichen Heteromethod-Heterotrait-Korrelationen zu verringern (Hair et al., 2017, S. 104). Auf Basis dieses Ansatzes und unter Berücksichtigung von Interner-Konsistenz-Reliabilität und Inhaltsvalidität entfernen wir die Indikatoren BI2 und EE4. Dies verbessert die HTMT-Verhältnisse zwischen HT und BI auf 0,897 und zwischen EE und FC auf 0,898. Somit liegen beide Werte unter dem oberen Grenzwert von 0,90 wie in Tabelle 43 ersichtlich.

	BI	EE	FC	HM	HT	PE	PV	SI
BI								
EE	0,378							
FC	0,284	0,898						
HM	0,635	0,231	0,151					
HT	0,897	0,282	0,247	0,567				
PE	0,766	0,372	0,406	0,468	0,665			
PV	0,564	0,257	0,108	0,319	0,744	0,477		
SI	0,528	0,177	0,076	0,190	0,780	0,473	0,617	

Tabelle 43: HTMT-Verhältnisse der Studie 2

Quelle: Eigene Darstellung

Zusätzlich führen wir für die Untersuchung der Diskriminanzvalidität ein Bootstrapping mit 5.000 Subsamples durch, um die BCa-korrigierten Konfidenzintervalle für die HTMT-Werte zu erhalten. Die 95 % BCa-korrigierten Konfidenzintervalle für den HTMT-Wert der beiden vorher problematischen Konstruktkombinationen lauten [0,720;1,099] für FC und EE sowie [0,785;1,016] für HT und BI. Somit ist in beiden Fällen die 1 im Konfidenzintervall enthalten. Im Hinblick auf die Auswirkung der Entfernung von weiteren Indikatoren auf die Interne-

Konsistenz-Reliabilität, die Inhaltsvalidität und der geringen Überschreitung des Grenzwertes entscheiden wir uns zunächst, keine weiteren Indikatoren aufgrund des HTMT-Kriteriums zu entfernen und prüfen die Diskriminanzvalidität mit zwei weiteren Ansätzen. Die Interne-Konsistenz-Reliabilität ist nach Entfernung der Indikatoren FC1, FC4, BI1 und EE4 weiterhin gegeben, wie in Tabelle 44 ersichtlich.

	Cronbachs Alpha	Composite-Reliabilität	AVE
BI	0,825	0,919	0,851
EE	0,739	0,847	0,650
FC	0,622	0,828	0,709
HM	0,871	0,920	0,794
HT	0,623	0,792	0,561
PE	0,817	0,878	0,643
PV	0,798	0,879	0,708
SI	0,862	0,915	0,783

Tabelle 44: Ergebnisse zur Internen-Konsistenz-Reliabilität bei Studie 2

Quelle: Eigene Darstellung

Zur weiteren Prüfung der Diskriminanzvalidität berechnen wir zunächst die Kreuzladungstabelle, die in Tabelle 45 dargestellt ist. Alle Ladungen der Indikatoren auf das eigene Konstrukt, die in der Tabelle grau hinterlegt sind, sind größer als alle Kreuzladungen der Indikatoren zu anderen Konstrukten. Anhand der Kreuzladungstabelle können wir daher keine weiteren Probleme bei der Diskriminanzvalidität identifizieren. Insbesondere die problematischen Konstruktkombinationen EE und FC sowie HT und BI zeigen keine Auffälligkeiten in der Kreuzladungstabelle.

	BI	EE	FC	HM	HT	PE	PV	SI
BI1	0,923	0,306	0,237	0,533	0,602	0,601	0,421	0,380
BI3	0,922	0,282	0,169	0,476	0,646	0,582	0,456	0,445
EE1	0,145	0,773	0,570	0,081	0,077	0,156	0,016	-0,081
EE2	0,269	0,760	0,443	0,110	0,262	0,286	0,284	0,240
EE3	0,305	0,881	0,533	0,197	0,091	0,260	0,114	0,003
FC2	0,229	0,606	0,937	0,138	0,148	0,239	0,089	0,008
FC3	0,118	0,414	0,735	-0,059	0,057	0,256	0,019	0,045
HM1	0,487	0,175	0,030	0,916	0,421	0,402	0,303	0,183
HM2	0,552	0,273	0,185	0,895	0,435	0,366	0,263	0,124
HM3	0,400	-0,032	-0,030	0,861	0,346	0,304	0,193	0,130
HT1	0,655	0,291	0,257	0,487	0,839	0,482	0,475	0,382
HT2	0,377	0,018	-0,017	0,284	0,693	0,295	0,374	0,414
HT3	0,425	0,024	-0,028	0,184	0,707	0,313	0,350	0,495
PE1	0,620	0,244	0,209	0,369	0,466	0,804	0,367	0,360
PE2	0,438	0,255	0,150	0,281	0,382	0,806	0,275	0,271
PE3	0,472	0,282	0,340	0,249	0,379	0,802	0,337	0,372
PE4	0,491	0,203	0,206	0,380	0,370	0,795	0,271	0,272
PV1	0,273	-0,009	-0,021	0,094	0,390	0,278	0,754	0,443
PV2	0,478	0,166	0,076	0,258	0,476	0,342	0,884	0,461
PV3	0,408	0,281	0,107	0,333	0,489	0,368	0,879	0,397
SI1	0,419	0,125	0,062	0,110	0,521	0,353	0,533	0,882
SI2	0,352	0,021	0,003	0,163	0,506	0,357	0,405	0,868
SI3	0,410	0,088	-0,005	0,164	0,449	0,356	0,408	0,904

Tabelle 45: Kreuzladungstabelle für Studie 2

Quelle: Eigene Darstellung

Im dritten Ansatz zur Untersuchung der Diskriminanzvalidität prüfen wir zuletzt noch das Fornell-Larcker-Kriterium. Dieses besagt, dass die Quadratwurzel der AVE eines Konstruktes größer ist als alle Korrelationen zu anderen Konstrukten. Auch hier prüfen wir mit einem besonderen Augenmerk die problematischen Konstruktkombinationen EE und FC sowie HT und BI. Sowohl für die problematischen Konstruktkombination als auch die restlichen Konstrukte ist das Fornell-Larcker-Kriterium erfüllt, was wir anhand der Tabelle 46 prüfen können: Auf der Diagonalen der Tabelle ist jeweils die Quadratwurzel der AVE eingetragen und in den anderen Feldern stehen jeweils die Korrelationswerte. Aufgrund der Ergebnisse betrachten wir die Diskriminanzvalidität als hinreichend gegeben und untersuchen im nächsten Schritt die Konvergenzvalidität des Messmodells.

	BI	EE	FC	HM	HT	PE	PV	SI
BI	0,922							
EE	0,318	0,806						
FC	0,220	0,623	0,842					
HM	0,547	0,173	0,082	0,891				
HT	0,676	0,187	0,135	0,454	0,749			
PE	0,642	0,306	0,282	0,405	0,504	0,802		
PV	0,476	0,194	0,075	0,288	0,541	0,395	0,841	
SI	0,447	0,092	0,024	0,163	0,555	0,402	0,510	0,885

Tabelle 46: Fornell-Larcker Kriterium bei Studie 2

Quelle: Eigene Darstellung

Zur Evaluation der *Konvergenzvalidität* betrachten wir die Ladungen aller Indikatoren. Die Ladungen der Indikatoren, sowie deren *t*-Werte sind in Tabelle 47 abgebildet. Die Tabelle enthält außerdem die mittels BCa-Bootstrapping mit 5.000 Subsamples ermittelten Bias-korrigierten Konfidenzintervalle. In der letzten Spalte befindet sich weiterhin die Information, ob die Ladungen zum gewählten Signifikanzniveau von 0,05 signifikant sind. Die Ladung von HT2 liegt mit $l = 0,693$ unterhalb des Schwellwertes von 0,70. Ein Entfernen des Indikators führt jedoch dazu, dass die Grenzwerte für die Interne-Konsistenz-Reliabilität unterschritten werden. Da die Ladung zudem über dem Grenzwert von 0,40 liegt, behalten wir den Indikator im Modell. Als zweites Kriterium für die Konvergenzvalidität berechnen wir die AVE für alle Konstrukte. Alle AVE-Werte liegen oberhalb des Grenzwertes von 0,50 wie in Tabelle 44 ersichtlich. Somit sehen wir die Konvergenzvalidität des Messmodells als hinreichend gegeben.

Mit der Prüfung von Interner-Konsistenz-Reliabilität, Diskriminanzvalidität und Konvergenzvalidität ist die Evaluation des Messmodells abgeschlossen. Die Probleme des Messmodells konnten weitgehend beseitigt werden, indem wir nach sorgfältiger Abwägung die Indikatoren FC1, FC4, BI2 und EE4 entfernt haben. Einzig die 95 % BCa-korrigierten Konfidenzintervalle für die HTMT-Werte der Konstruktkombinationen FC und EE, sowie für HT und BI deuten noch auf mögliche Probleme bei der Diskriminanzvalidität hin. Diese können wir allerdings nicht beheben, ohne das Messmodell bezüglich anderer Kriterien zu verschlechtern. Weiterhin zeigten die Kreuzladungstabelle und das Fornell-Larcker-Kriterium keine Probleme bei der Diskriminanzvalidität auf. Daher fahren wir mit der Evaluation des Strukturmodells fort.

	Ladungen	t-Werte	95 % Konfidenzintervalle	p < 0,05
BI1 <- BI	0,923	65,064	[0,888;0,945]	Ja
BI3 <- BI	0,922	65,350	[0,888;0,945]	Ja
EE1 <- EE	0,773	8,984	[0,548;0,882]	Ja
EE2 <- EE	0,760	8,901	[0,547;0,890]	Ja
EE3 <- EE	0,881	19,894	[0,776;0,946]	Ja
FC2 <- FC	0,937	8,263	[0,780;1,000]	Ja
FC3 <- FC	0,735	3,899	[0,141;0,905]	Ja
HM1 <- HM	0,916	62,820	[0,882;0,940]	Ja
HM2 <- HM	0,895	56,906	[0,858;0,922]	Ja
HM3 <- HM	0,861	29,432	[0,792;0,906]	Ja
HT1 <- HT	0,839	30,492	[0,770;0,882]	Ja
HT2 <- HT	0,693	8,535	[0,489;0,808]	Ja
HT3 <- HT	0,707	12,845	[0,567;0,789]	Ja
PE1 <- PE	0,804	27,033	[0,730;0,850]	Ja
PE2 <- PE	0,806	18,087	[0,699;0,875]	Ja
PE3 <- PE	0,802	22,288	[0,718;0,861]	Ja
PE4 <- PE	0,795	21,027	[0,703;0,855]	Ja
PV1 <- PV	0,754	12,837	[0,614;0,840]	Ja
PV2 <- PV	0,884	45,178	[0,834;0,915]	Ja
PV3 <- PV	0,879	27,600	[0,801;0,925]	Ja
SI1 <- SI	0,882	30,896	[0,810;0,926]	Ja
SI2 <- SI	0,868	25,128	[0,783;0,919]	Ja
SI3 <- SI	0,904	50,198	[0,863;0,935]	Ja

Tabelle 47: Äußere Ladungen bei Studie 2

Quelle: Eigene Darstellung

6.4.5 Evaluation des Strukturmodells

In diesem Abschnitt führen wir die Evaluation des Strukturmodells anhand der in Abschnitt 4.2.7 beschriebenen Kriterien durch. Die Evaluation des Strukturmodells umfasst die Prüfung der Multikollinearität der Konstrukte, der Bestimmtheitsmaße R^2 der endogenen Konstrukte, der f^2 -Effektstärken der exogenen Konstrukte, der Prognoserelevanz anhand des Stone-Geisser Q^2 und der q^2 -Effektstärken der exogenen Konstrukte. Zur Berechnung der hierfür benötigten Werte verwenden wir SmartPLS 3 (Ringle et al., 2015).

Zunächst prüfen wir das Strukturmodell auf *Kollinearität*. Hierfür ermitteln wir die VIF-Werte zwischen allen Treiberkonstrukten des endogenen Konstruktes BI. Die VIF-Werte sind in Tabelle 48 dargestellt. Alle VIF-Werte liegen klar unterhalb des Grenzwertes 5. Daraus schlussfolgern wir, dass kein kritisches Maß an Kollinearität zwischen den Treiberkonstrukten von BI vorliegt.

	BI
EE	1,726
FC	1,701
HM	1,386
HT	2,060
PE	1,620
PV	1,608
SI	1,688

Tabelle 48: Innere VIF Werte bei Studie 2

Quelle: Eigene Darstellung

Im nächsten Schritt prüfen wir die *Pfadkoeffizienten* des Strukturmodells. Hierzu führen wir zunächst ein BCa-Bootstrapping mit 5.000 Subsamples durch. Dadurch erhalten wir die *t*-Werte und *p*-Werte der Pfadkoeffizienten sowie die Konfidenzintervalle für die Pfadkoeffizienten, die in Tabelle 49 dargestellt sind. Mit $EE \rightarrow BI$, $FC \rightarrow BI$, $PV \rightarrow BI$ und $SI \rightarrow BI$ sind vier der sieben Pfadkoeffizienten nicht signifikant. Die Pfadkoeffizienten $HM \rightarrow BI$, $HT \rightarrow BI$ und $PE \rightarrow BI$ sind hingegen höchst signifikant ($p < 0.001$). Das Ergebnis spiegelt sich auch in den *t*-Werten wider, die bei allen signifikanten Pfadkoeffizienten über 1,96 liegen. Die 95 % Konfidenzintervalle der signifikanten Pfadkoeffizienten enthalten die 0 nicht und bewegen sich in plausiblen Wertebereichen.

	Pfadkoeffizienten	t-Werte	p-Werte	95 % Konfidenzintervalle	p < 0,05
EE -> BI	0,109	1,665	0,096	[-0,019;0,238]	Nein
FC -> BI	-0,002	0,036	0,971	[-0,131;0,112]	Nein
HM -> BI	0,228	3,707	0,000	[0,107;0,352]	Ja
HT -> BI	0,335	4,559	0,000	[0,194;0,480]	Ja
PE -> BI	0,299	4,289	0,000	[0,159;0,430]	Ja
PV -> BI	0,056	0,867	0,386	[-0,072;0,181]	Nein
SI -> BI	0,065	0,905	0,366	[-0,072;0,209]	Nein

Tabelle 49: Pfadkoeffizienten des Strukturmodells bei Studie 2

Quelle: Eigene Darstellung

Die *totalen Effekte* entsprechen jeweils den direkten Effekten, da keine *indirekten Effekte* im Modell enthalten sind. Somit entfällt die Analyse der totalen Effekte und Mediationen. Die Interpretation der Höhe der Effekte befindet sich im Diskussionsteil für diese Studie. Somit ist die Untersuchung der Pfadkoeffizienten abgeschlossen.

Wir Berechnen nun das *Bestimmtheitsmaß* R^2 für das endogene Konstrukt BI. Dieses hat den Wert $R^2 = 0,634$. Somit besitzt das Modell eine moderate Prognoseleistung. Im Kontext bisheriger Akzeptanzstudien ist der Wert als sehr gut zu bewerten (Dwivedi et al., 2019; Venkatesh et al., 2012). Zur besseren Vergleichbarkeit mit den weiteren Studien dieser

Dissertation berechnen wir auch das adjustierte Bestimmtheitsmaß für BI. Dieses hat den Wert $R_{adj}^2=0,616$.

	BI
EE	0,019
FC	0,000
HM	0,102
HT	0,149
PE	0,151
PV	0,005
SI	0,007

Tabelle 50: f^2 -Effektstärken bei Studie 2

Quelle: Eigene Darstellung

Im nächsten Schritt bewerten wir die f^2 -Effektstärken der Konstrukte. Diese sind in Tabelle 50 dargestellt. Entsprechend der Ladungen von EE \rightarrow BI, FC \rightarrow BI, PV \rightarrow BI und SI \rightarrow BI sind auch die Effektstärken sehr niedrig. Entsprechend der Richtlinien für Effektstärken gibt es keinen Effekt von EE, FC, PV und SI auf BI, da deren f^2 Werte kleiner als 0,02 sind. Die Effekte von HM und HT auf BI sind als klein zu bewerten, da sie mit $f^2 = 0,102$ beziehungsweise $f^2 = 0,149$ zwischen 0,15 und 0,02 liegen. Der größte Effekt ist von PE auf BI mit $f^2 = 0,151$, der als mittlerer Effekt einzuordnen ist.

Für die Analyse der *Prognoserelevanz* des Strukturmodells führen wir ein Blindfolding mit einer Auslassungsdistanz von $D = 6$ durch. Die Division der Anzahl der Beobachtungen durch D darf nicht ganzzahlig sein. Daher können wir nicht $D = 7$ wie in Studie 1 wählen. Dies wirkt sich allerdings nicht auf die Vergleichbarkeit der Ergebnisse aus. Auf Basis des Blindfoldings ermitteln wir einen Wert für das Stone-Geisser Q^2 des endogenen Konstruktes BI von 0,482. Dieser Wert ist deutlich über 0, was die Prognoserelevanz des Strukturmodells bezüglich der endogenen Variablen belegt.

	BI
EE	0,000
FC	-0,006
HM	0,030
HT	0,041
PE	0,044
PV	0,000
SI	-0,001

Tabelle 51: q^2 -Effektstärken bei Studie 2

Quelle: Eigene Darstellung

Zuletzt berechnen wir noch die q^2 -Effektstärken. Diese sind in Tabelle 51 dargestellt. Die q^2 -Effektstärken von FC und SI auf BI sind negativ und deuten somit auf ein Overfitting des Modells hin. Da diese Effekte, wie auch der Effekt von SI auf BI, betragsmäßig unter dem Grenzwert von 0,02 liegen, handelt es sich auch hier nach Definition um keinen Effekt. Bei den q^2 -Effektstärken ist der Effekt von PE auf BI mit $q^2 = 0,044$ der stärkste Effekt, der allerdings auch noch als kleiner Effekt einzustufen ist. Alle q^2 -Effektstärken sind geringer als die f^2 -Effektstärken wie auch bereits in Studie 1.

Somit ist die Evaluation des Strukturmodells abgeschlossen. Abbildung 29 zeigt das finale Pfadmodell der Technologieakzeptanz nach UTAUT2 für autonome Fahrzeuge. Die Abbildung enthält die Ladungen der Indikatoren, die jeweils auf dem Pfeil zwischen dem Indikator und dem zugehörigen Konstrukt stehen. Auf den Pfeilen zwischen den Konstrukten stehen die Pfadkoeffizienten. Im endogenen Konstrukt BI ist das Bestimmtheitsmaß R^2 eingetragen.

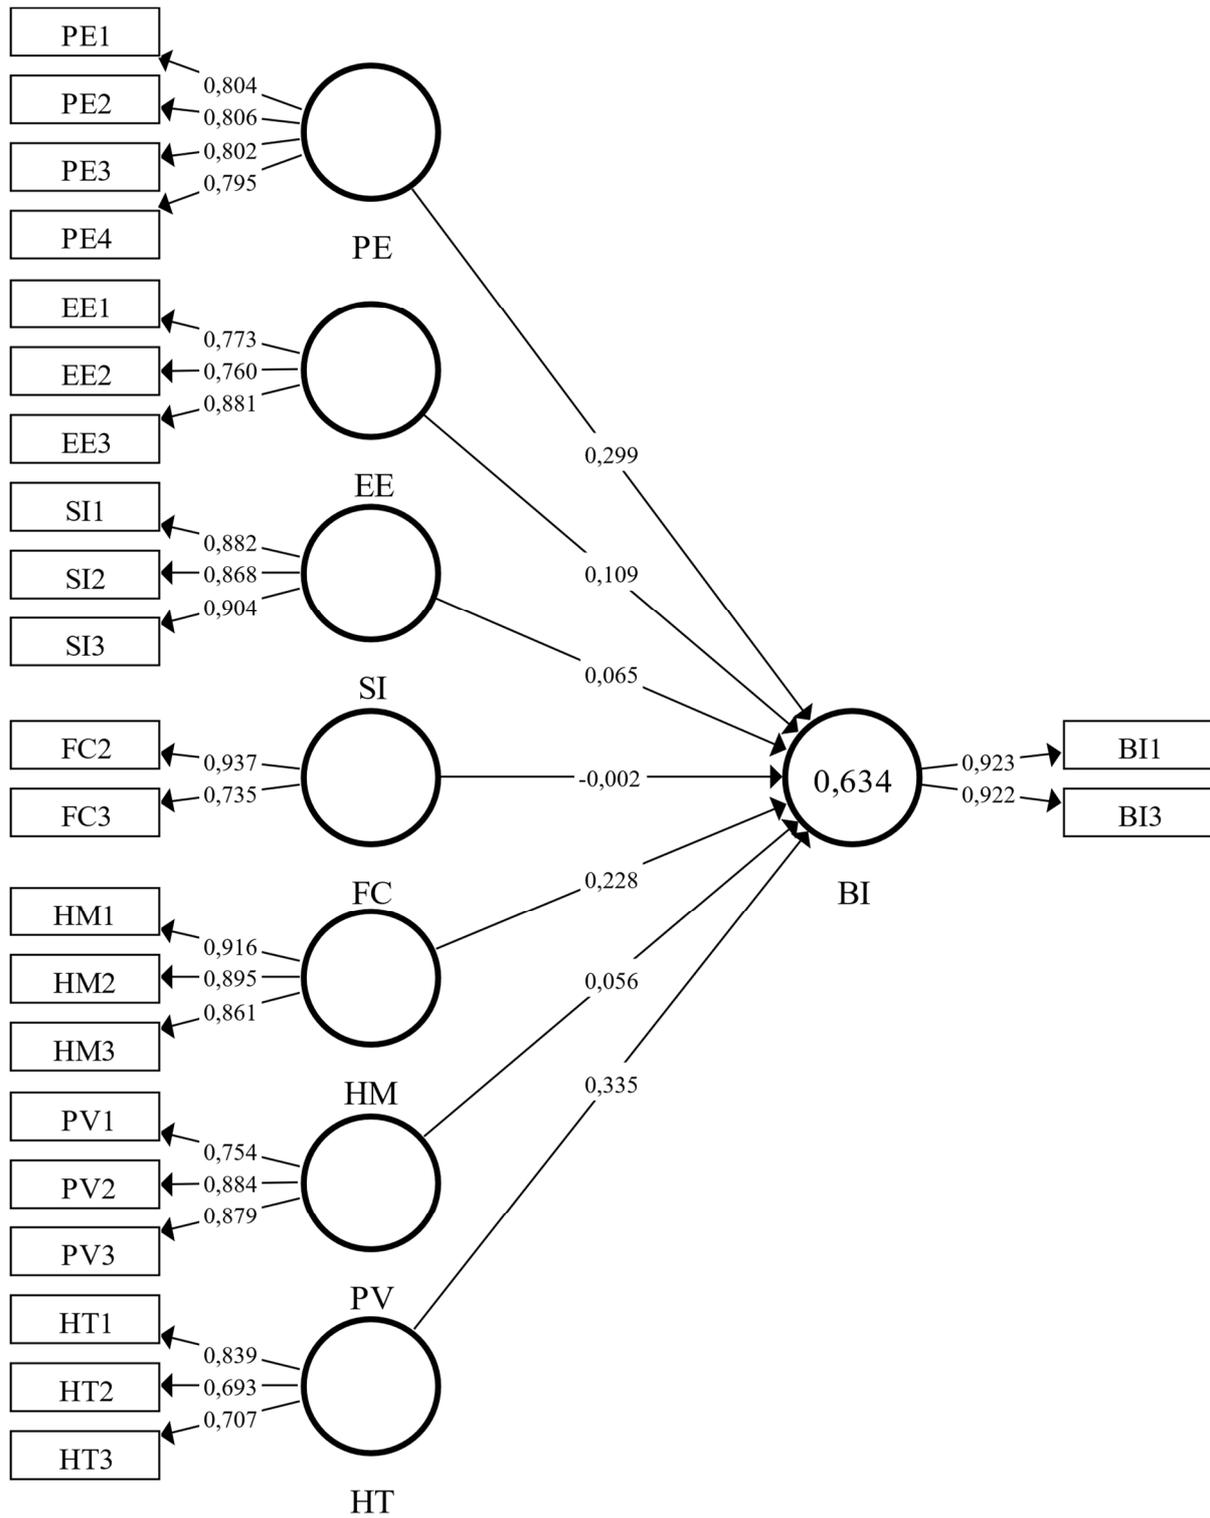


Abbildung 29: Finales Pfadmodell der Studie 2

Quelle: Eigene Darstellung

6.5 Diskussion

Die Auswertung der Ergebnisse der Studie zeigt, dass die hedonische Motivation und die Gewohnheit zusätzliche Einflussfaktoren für die Prognose der Akzeptanz von Innovationen darstellen könnten. Zwei weitere neue Konstrukte des UTAUT2 Modells, die unterstützenden Bedingungen und das Preis-Leistungs-Verhältnis, scheinen nur eine geringe Bedeutung für die Prognose der Akzeptanz von Innovationen zu haben. Mit dem UTAUT2 Modell konnten wir im Vergleich zur Studie 1 ($R^2 = 0,604$) einen etwas höheren R^2 -Wert für die Nutzungsintention von 0,634 erreichen. Der R^2 -Wert ist im Vergleich zu anderen Studien ebenfalls als sehr gut zu bewerten und ist deutlich höher als in der UTAUT2 Studie ($R^2 = 0,44$). Sowohl bei der Evaluation des Messmodells als auch bei der Evaluation des Strukturmodells berechneten wir jedoch einige kritische Werte, die auf Probleme bei der Anwendung des Modells für die Prognose der Akzeptanz von Innovationen hindeuten. Somit erscheint die unangepasste Anwendung des UTAUT2 Modells zur Prognose der Akzeptanz von Innovationen nicht empfehlenswert. Im Folgenden diskutieren wir die Ergebnisse im Detail.

Der Effekt der Leistungserwartung auf die Nutzungsintention ist mit einem Pfadkoeffizienten von 0,299 ($p < 0,001$) sogar höher als im UTAUT Vergleichsmodell der Studie 1 ($l = 0,182$) und ähnlich hoch wie der Effekt der Leistungserwartung auf die Nutzungseinstellung ($l = 0,232$) im Modell zur Prognose der Akzeptanz von Innovationen. Somit zeigt sich in allen bisherigen Auswertungen, dass es sich bei der Leistungserwartung um ein wichtiges Konstrukt für die Prognose der Akzeptanz von Innovationen handelt. Bei der Leistungserwartung konnten wir in beiden getesteten Modellen der Studie 1 und auch in dieser Studie keine Probleme mit dem Messmodell identifizieren. Dies deutet darauf hin, dass sich Individuen bereits vor Marktstart einer neuen Technologie eine Meinung zur Leistungserwartung gebildet haben, diese auch ausdrücken können und dass sich die Einschätzung der Leistungserwartung signifikant direkt oder indirekt auf die Nutzungsintention auswirkt. Somit können wir Hypothese H1 (PE \rightarrow BI) bestätigen.

Durch die Verwendung der Gewichte der Indikatoren, die durch den PLS Algorithmus berechnet werden, können wir zudem den nicht-standardisierten Score für das Konstrukt ermitteln. Dazu multiplizieren wir das Gewicht des Indikators mit dem Wert des Indikators und addieren die Werte für alle Indikatoren eines Konstruktes. Dies führen wir für jeden Probanden durch und berechnen anschließend den Mittelwert über alle Probanden. Den Mittelwert über alle Probanden transformieren wir, sodass wir einen Wert zwischen 0 und 100 erhalten. Alle Konstruktwerte sind in Abbildung 30 dargestellt.

Für die Leistungserwartung beträgt der Konstruktwert im Durchschnitt über alle Probanden 62,3. Der Wert für die Leistungserwartung ist somit etwas höher als in Studie 1 (PE = 59,0). Auch dieser Wert ist noch gering in Anbetracht der erwarteten Vorteile durch diese Technologie. Weitere Studien sollten untersuchen, wie sich die Leistungserwartung im zeitlichen Verlauf weiter verändert und was mögliche Auslöser für diese Veränderungen sind.

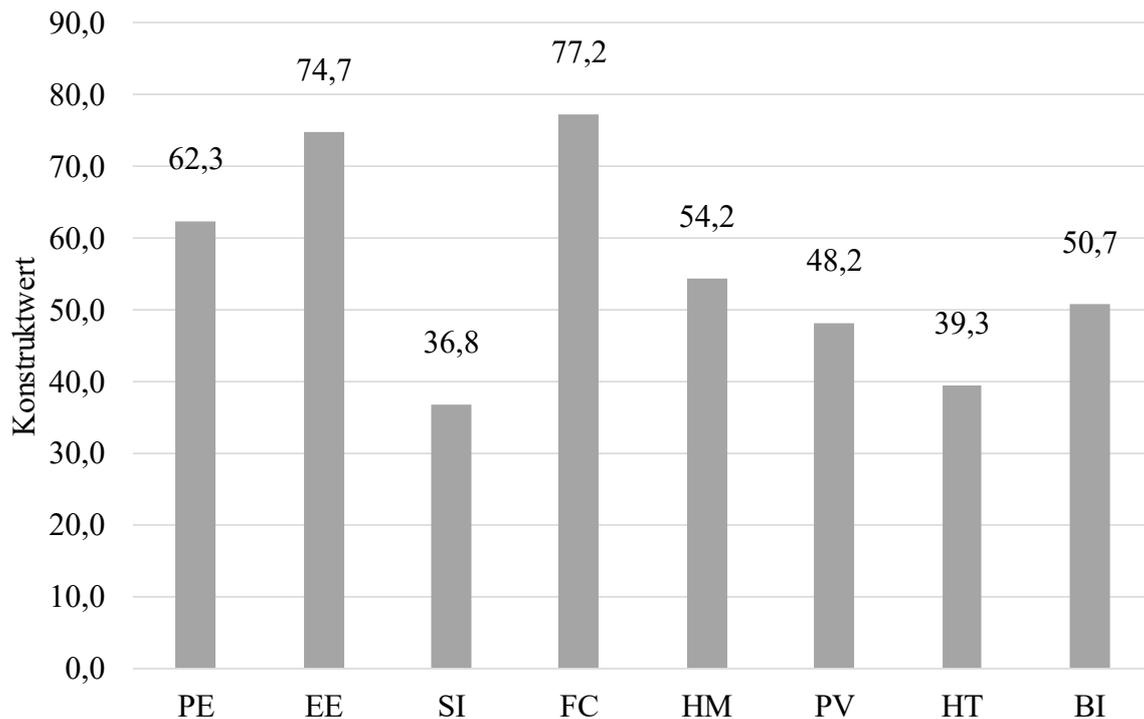


Abbildung 30: Konstruktwerte der Studie 2

Quelle: Eigene Darstellung

Der Pfadkoeffizient der Aufwandserwartung ist mit 0,109 gering und nicht signifikant ($p = 0,096$). Auch im Modell zur Prognose der Akzeptanz von Innovationen ist der totale Effekt der Aufwandserwartung auf die Nutzungsintention mit 0,056 ähnlich gering. Deutlich größer ist der Effekt auf die Nutzungseinstellung in Studie 1 ($l = 0,193$) und auch im UTAUT Vergleichsmodell der Studie 1 erhalten wir für die Aufwandserwartung einen Pfadkoeffizienten von 0,195. Bei näherer Analyse des Modells zeigt sich, dass das Konstrukt der hedonischen Motivation zu diesem geringen Pfadkoeffizienten führt. Entfernen wir die hedonische Motivation aus dem Modell, so steigt der Pfadkoeffizient der Aufwandserwartung auf den Wert 0,130. Dieser Wert steigt auch nicht mehr wesentlich an, wenn wir alle Konstrukte außer die UTAUT Konstrukte PE, EE und SI aus dem Modell entfernen ($l = 0,143$). Wir vermuten daher einen ähnlichen Effekt wie im Modell zur Prognose der Akzeptanz von Innovationen, in dem die Aufwandserwartung die Nutzungseinstellung über die Einstellung zur Nutzung nur indirekt beeinflusst.

Die Definitionen von hedonischer Motivation und der Nutzungseinstellung ähneln sich. Dies äußert sich beispielsweise auch dadurch, dass der Indikator HM1 dem Indikator AT3 entspricht. Wir sehen in diesem Ergebnis ein weiteres Argument für die Verwendung des Modells zur Prognose der Akzeptanz von Innovationen, da es die Integration der Aufwandserwartung in die Akzeptanzprognose ermöglicht. Wie in Abschnitt 5.5 erläutert, deuten erste Feldstudien darauf hin, dass sich die Aufwandserwartung erst nach der Verwendung autonomer Fahrzeuge auf die Nutzungsintention auswirkt. Für die Prognose der Akzeptanz von Innovation ist es daher erforderlich, dass die Aufwandserwartung berücksichtigt werden kann. Dies ist im Modell zur Prognose der Akzeptanz von Innovationen durch den signifikanten Effekt auf die

Nutzungseinstellung der Fall. Aufgrund der Ergebnisse dieser Studie müssen wir H2 (EE → BI) aber ablehnen.

Mit den Gewichten der Indikatoren ermitteln wir einen transformierten Konstruktwert für die Aufwandserwartung von 74,7 von 100. Dieser Wert ist nochmals höher als in Studie 1 (EE = 68,6), wirkt sich dafür aber kaum auf die Nutzungsintention aus. Aufgrund der Ergebnisse von Studie 1 dieser Dissertation vermuten wir dennoch einen signifikanten indirekten Effekt auf die Akzeptanz autonomer Fahrzeuge. Gingen wir von den Ergebnissen von Studie 2 aus, könnte die Benutzerschnittstelle autonomer Fahrzeuge beliebig komplex gestaltet werden. Spätestens bei Markteinführung autonomer Fahrzeuge können wir aber davon ausgehen, dass bisherige Akzeptanzmodelle wieder anwendbar sind und eine umständliche Bedienung auf Ablehnung stoßen würde. Zukünftige Forschung sollte den Zusammenhang zwischen Aufwandserwartung, hedonischer Motivation und Nutzungseinstellung weiter untersuchen.

Auch die sozialen Einflüsse sind mit einem Pfadkoeffizienten von 0,065 sehr gering und nicht signifikant ($p = 0,366$). Dieses Ergebnis steht im Gegensatz zu den Ergebnissen von Studie 1 dieser Dissertation, bei der die sozialen Einflüsse sowohl im Modell zur Prognose der Akzeptanz von Innovationen als auch im UTAUT Vergleichsmodell den stärksten Einflussfaktor bilden. Der totale Effekt der sozialen Einflüsse auf die Nutzungsintention im Modell zur Prognose der Akzeptanz von Innovationen beträgt 0,495 und der direkte Effekt im UTAUT Vergleichsmodell beträgt 0,501. Wie bei der Aufwandserwartung konnten wir bei den sozialen Einflüssen ein Konstrukt identifizieren, das den Pfadkoeffizienten deutlich reduziert. Bei den sozialen Einflüssen ist dies allerdings nicht die hedonische Motivation, sondern die Gewohnheit. Entfernen wir die Gewohnheit aus dem Modell, so erhöht sich die Pfadkoeffizient der sozialen Einflüsse auf 0,175. Der Wert ist zwar immer noch deutlich geringer als die Pfadkoeffizienten der Studie 1 aber zumindest signifikant ($p = 0,024$). Auch in diesem Fall vermuten wir einen Zusammenhang zwischen den beiden Konstrukten, den wir allerdings nicht mit den Daten der Studie 1 untersuchen können. Allerdings zeigen frühere Studien, dass soziale Einflüsse Gewohnheiten wie das Rauchen (Foss, 1973) aber auch die gewohnheitsmäßige Nutzung von Informationssystemen (de Guinea & Markus, 2009) beeinflussen können. Aufgrund der Ergebnisse dieser Studie müssen wir H3 (SI → BI) ablehnen.

Für die sozialen Einflüsse ergibt sich ein Konstruktwert von 36,8 von 100. Wie in der Studie 1 dieser Dissertation deutet dies darauf hin, dass das soziale Umfeld der Probanden eher einen negativen Einfluss auf die Akzeptanz autonomer Fahrzeuge ausübt. Im Vergleich zur Studie 1 ist der Wert sogar nochmals ein wenig niedriger (SI = 41,1). Anhand des berechneten Pfadkoeffizienten von 0,065 wäre der Einfluss allerdings so gering, dass er nicht berücksichtigt werden müsste. Wie im Falle der Aufwandserwartung wäre dies für die Prognose der Akzeptanz von Innovationen nicht zielführend. Spätestens nach dem Marktstart autonomer Fahrzeuge werden die sozialen Einflüsse gemäß etablierter Akzeptanzmodelle wie UTAUT oder UTAUT2 eine wichtige Rolle für deren Akzeptanz einnehmen (Venkatesh et al., 2003, 2012). Auch hier ist das Modell zur Prognose der Akzeptanz von Innovationen von Vorteil, da es die sozialen Einflüsse entsprechend ihres zukünftig zu erwartendem Einfluss auf die Akzeptanz berücksichtigt. Zukünftige Forschung sollte den Zusammenhang zwischen sozialen Einflüssen, Gewohnheit und der Nutzungsintention genauer untersuchen.

Für die unterstützenden Bedingungen haben wir einen geringen Einfluss auf die Nutzungsintention bereits erwartet, wie in Abschnitt 6.2 erläutert. Der Wert des Pfadkoeffizienten ist mit $-0,002$ ($p = 0,971$) aber betragsmäßig sogar noch geringer als erwartet und sogar leicht negativ. Dies deutet darauf hin, dass die unterstützenden Bedingungen in einer frühen Phase der Technologieentwicklung noch nicht relevant für die Akzeptanz der Technologie erscheinen. Es genügt die unterstützenden Bedingungen zu schaffen oder bereitzustellen, wenn die Technologie für die Allgemeinheit nutzbar wird. Vorher ist womöglich gar nicht hinreichend bekannt, welche unterstützenden Bedingungen überhaupt für die Technologie relevant sind. Wir sehen daher keine Veranlassung die unterstützenden Bedingungen in das Modell zur Prognose der Akzeptanz von Innovationen zu integrieren. Im Gegenteil könnten die Fragen die Probanden sogar verwirren und zu höheren Abbruchquoten führen. Darauf deuten auch die Probleme bei der Internen-Konsistenz-Reliabilität dieser Studie hin, die wir nur durch Entfernen von zwei der vier Indikatoren von den unterstützenden Bedingungen auf ein akzeptables Niveau heben konnten. Entsprechend der Ergebnisse lehnen wir H4 (FC \rightarrow BI) daher ab.

Der Konstruktwert für die unterstützenden Bedingungen beträgt 77,2. Die Probanden sind also optimistisch, dass genügend unterstützende Bedingungen vorhanden sein werden, sobald autonome Fahrzeuge verfügbar sind. Dies können beispielsweise entsprechende Gesetze oder Trainings, vergleichbar mit einer Fahrschule, sein. Zudem zeichnet sich ab, dass Fahrzeuge zunehmend mit dem Smartphone gesteuert werden können. Mittels kostenloser Apps können zum Zeitpunkt dieser Studie bereits Fahrzeuge mit dem Smartphone geöffnet (Lekach, 2018) oder aus einer Parklücke herausgefahren werden (Tesla Motors, 2016). Es müssen also keine zusätzlichen Geräte gekauft werden. Auch bei autonomen Fahrzeugen wäre es plausibel, dass diese mit dem Smartphone herbeigerufen werden können und die Zieleingabe für die Navigation ebenfalls über das Smartphone erfolgen kann. Somit wären autonome Fahrzeuge entsprechend FC3 auch kompatibel mit anderen Technologien, die die Probanden nutzen. Es ist zwar sinnvoll, sich bereits während der Entwicklung einer neuen Technologie über die unterstützenden Bedingungen Gedanken zu machen. Allerdings werden die unterstützenden Bedingungen erst zu einem späteren Zeitpunkt, vermutlich erst zum Marktstart einer Innovation, relevant.

Die hedonische Motivation ist mit einem Pfadkoeffizienten von $0,228$ ($p < 0,001$) ein signifikanter Einflussfaktor der Nutzungsintention. Dieses Konstrukt ist nicht im UTAUT Modell enthalten und ähnelt dem Konstrukt der Nutzungseinstellung im Modell zur Prognose der Akzeptanz von Innovationen. Wie in Abschnitt 6.2 erläutert, sehen wir in der hedonischen Motivation eine mögliche Ergänzung des Modells, da dieses ähnlich wie die Angst vor der Nutzung eine affektive Komponente in das Akzeptanzmodell einbringt. Affektive Komponenten sind wichtig, insbesondere in frühen Phasen der Technologieentwicklung, wenn die Leistungserwartung einer neuen Technologie noch nicht abgeschätzt werden kann. Sie kann allerdings auch zu einer Fehleinschätzung einer Technologie führen und sollte daher auch kritisch untersucht werden. Eine hohe hedonische Motivation kann sich dennoch förderlich auf die Akzeptanz einer neuen Technologie auswirken, da diese zu Aufmerksamkeit führt und die Neugierde von Innovatoren oder der frühen Übernehmer entsprechend der Diffusionstheorie wecken könnte. Eine hohe hedonische Motivation kann auch helfen, über anfängliche

enttäuschte Erwartungen an die Leistung einer neuen Technologie hinwegzusehen, solange die Technologie noch nicht das Plateau der Produktivität erreicht hat. Auf Basis der beschriebenen Ergebnisse können wir somit H5 (HM → BI) bestätigen.

Der Konstruktwert für die hedonische Motivation beträgt 54,2 und befindet sich somit ähnlich wie die Angst vor der Nutzung in Studie 1 dieser Dissertation im neutralen bis leicht positiven Bereich. Der Hype in Form von überzogenen Erwartungen scheint also bei autonomen Fahrzeugen zum Zeitpunkt der Studiendurchführung noch nicht begonnen zu haben, auch wenn bereits erste Anzeichen hierfür bei fortschrittlichen Fahrerassistenzsystemen erkennbar sind, wie in den Abschnitten 3.3 und 3.6 erläutert. Damit die Erwartungen der Nutzer von autonomen Fahrzeugen bei Marktstart nicht enttäuscht werden, sollten die Einschätzungen potenzieller Nutzer überwacht werden und gegebenenfalls mit zielgerichteten Informationskampagnen gegengesteuert werden. Eine Möglichkeit übersteigerte Erwartungen früh zu erkennen, könnte die Erhebung der hedonischen Motivation bieten. Andererseits könnten aber auch die Erwartungen qualitativ, beispielsweise mit sozialen Medien, erhoben und mit den tatsächlichen Eigenschaften einer Innovation abgeglichen werden. In jedem Fall scheint die hedonische Motivation ein relevantes Konstrukt zur Prognose der Akzeptanz von Innovationen zu sein. Aus diesem Grund sollte zukünftige Forschung die Integration hedonischer Motivation in das Modell zur Prognose der Akzeptanz von Innovationen untersuchen.

Der Pfadkoeffizient des Preis-Leistungs-Verhältnisses deutet mit 0,056 ($p = 0,386$) eher darauf hin, dass die Nutzungsintention in einer frühen Phase der Technologieentwicklung, wie in Abschnitt 6.2 bereits vermutet, noch nicht von primärer Relevanz ist. Auch direkt nach dem Marktstart einer Innovation sind die ersten Konsumenten in Form der Innovatoren und der frühen Übernehmer entsprechend der Diffusionstheorie dazu bereit, einen höheren Preis zu bezahlen und gegebenenfalls über Leistungsmängel hinwegzusehen, wie in Abschnitt 2.3.4 erläutert. Der niedrige Pfadkoeffizient könnte auch auf Probleme der Probanden hindeuten, das Preis-Leistungs-Verhältnis einzuschätzen, denn nach der Gewohnheit sollte das Preis-Leistungs-Verhältnis der zweitstärkste Einflussfaktor für die Nutzungsintention sein gemäß der UTAUT2 Studie. Für Probleme bei der Einschätzung des Preises spricht auch, dass die Preise und Bezahlmodelle von Innovationen häufig erst kurz vor deren Marktstart bekanntgegeben werden. Dennoch sollte der Preis nicht völlig bei der Entwicklung einer neuen Technologie vernachlässigt werden, da es für den kommerziellen Markterfolg entscheidend ist, auch die frühe und die späte Mehrheit von der Technologie zu überzeugen, wie in Abschnitt 2.3 erläutert. Es sollte also zumindest eine Planung erstellt werden, wie die Kosten nach dem Marktstart reduziert werden können, um die preissensiblere Kundschaft erreichen zu können. Idealerweise ist die Innovation aber bereits zu Beginn günstiger als vergleichbare Produkte und Dienstleistungen. Aufgrund der Ergebnisse lehnen wir somit H6 (PV → BI) ab.

Aufgrund der Unsicherheit der Preisabschätzung ist auch der Konstruktwert für das Preis-Leistungs-Verhältnis mit Vorsicht zu betrachten. Dieser beträgt 48,2 und befindet sich somit im neutralen Bereich. Zum Zeitpunkt der Studie sind noch keine Preise für autonome Fahrzeuge bekannt. Es ist auch vorstellbar, dass autonome Fahrzeuge in der Regel gar nicht gekauft, sondern bei Bedarf über Plattformen gebucht und genutzt werden, wie in Abschnitt 2.3.5 erläutert. Aufgrund der Unsicherheit der Preisgestaltung erscheint der Konstruktwert

realistisch. Es gibt eine leichte Tendenz dazu, dass autonome Fahrzeuge zu Beginn nicht direkt ein gutes Preis-Leistungs-Verhältnis bieten werden. In Anbetracht der hohen Hardwareanforderungen und Ausgaben für Forschung und Entwicklung vermuten die Probanden entweder eine gute Leistung oder antizipieren bereits neue Geschäftsmodelle und Preissenkungen. Aufgrund des technologischen Fortschrittes ist zu erwarten, dass die Hardwareanforderungen von autonomen Fahrzeugen für heutige Maßstäbe zwar hoch erscheinen, aber im Laufe der Zeit gemäß Moore's Law mit Standardkomponenten erreicht werden können (Krcmar, 2015, S. 325–327). Die Software für autonomes Fahren nutzt sich nicht ab und kann mit Grenzkosten nahe Null vervielfältigt werden (Krcmar, 2015, S. 11ff). Bei entsprechenden Verkaufszahlen können die hohen Kosten für die Erstellung der Software, sowie deren Wartung und Weiterentwicklung auf viele Kunden umgelegt werden. Die Preisfindung bei autonomen Fahrzeugen könnte dies berücksichtigen und initial mit geringeren Gewinnmargen arbeiten, um bereits kurz nach Marktstart eine hohe Diffusionsrate zu erreichen. Für die Preise der reinen Nutzung autonomer Fahrzeuge würde es vermutlich ausreichen, wenn sich diese zunächst im Bereich der öffentlichen Verkehrsmittel bewegen (Schade & Schlag, 2003). In Verbindung mit erhöhtem Komfort, würden autonome Fahrzeuge vermutlich bevorzugt aus der Perspektive des Preis-Leistungs-Verhältnisses.

Der letzte Einflussfaktor für die Nutzungsintention im UTAUT2 Modell ist die Gewohnheit. Diese ist mit einem Pfadkoeffizienten von 0,335 ($p < 0,001$) der stärkste Einflussfaktor der Nutzungsintention. Obwohl die Technologie noch nicht verfügbar ist, können die Probanden bereits einschätzen, dass sie diese aus Gewohnheit nutzen werden. Womöglich vergleichen die Probanden dies mit ihrer täglichen Pendelstrecke, bei der man üblicherweise sein bevorzugtes Verkehrsmittel nutzt, ohne darüber nachzudenken. Dennoch fiel den Probanden die Unterscheidung zwischen Gewohnheit und Nutzungsintention schwer, was sich in einem initial überhöhten HTMT-Wert zeigte. Erst die Anpassung des Konstruktes der Nutzungsintention durch Entfernen von BI2 führte dazu, dass der HTMT Wert sich auf einen gerade noch akzeptablen Wert reduzierte. Zusätzlich gibt es eine Interaktion zwischen den sozialen Einflüssen, die in Kombination mit dem Konstrukt der Gewohnheit keinen signifikanten Effekt mehr auf die Nutzungsintention ausüben. Daher könnte die Untersuchung des Zusammenhangs zwischen sozialen Einflüssen, Gewohnheit und der Nutzungsintention im Kontext von Innovationen zu interessanten Erkenntnissen führen. Anhand des UTAUT2 Modells ist somit H7 (HT → BI) anzunehmen.

Ein Wert von 39,3 für das Konstrukt deutet darauf hin, dass die Probanden sich eher nicht vorstellen können, dass autonomes Fahren zur Gewohnheit werden könnte und selbst zu fahren zur Ausnahme wird. In Anbetracht der Vorteile autonomer Fahrzeuge wäre es jedoch fragwürdig, dass diese nicht gewohnheitsmäßig genutzt werden, sobald sie verfügbar sind. Entsprechend des im Abschnitt 2.3.5 beschriebenen Schlussfolgerungen zur Diffusion wäre es denkbar, dass es aufgrund der Probleme des Mischverkehrs zur Einrichtung von Automatisierungszonen kommt, in denen nur noch automatisiert gefahren werden darf, bis hin zu einem kompletten Verbot des manuellen Fahrens. Dann wären einige Ziele vermutlich nur noch umständlich mit anderen Verkehrsmitteln zu erreichen. Alternativ könnte es aufgrund sozialen Drucks gegen das Ausführen einer Tätigkeit, die den Fahrer selbst und auch andere Verkehrsteilnehmer in Gefahr bringt, zu einer Ablösung manuellen Fahrens kommen. Wenn

diese und weitere Faktoren zusammenkommen, wird sich allmählich Druck für die Änderung etablierter Gewohnheiten bei der Verkehrsmittelwahl aufbauen.

Die Nutzungsintention ist sowohl in den Modellen UTAUT und UTAUT2 sowie im Modell zur Prognose der Akzeptanz von Innovationen der wichtigste Einflussfaktor für die Nutzungsintention und somit das zentrale Konstrukt für die Prognose der Akzeptanz von Innovationen. Durch Hinzunahme der Konstrukte der unterstützenden Bedingungen, der hedonischen Motivation, des Preis-Leistungs-Verhältnisses und der Gewohnheit konnte der R^2 -Wert für die Nutzungsintention gegenüber dem UTAUT Vergleichsmodell in Studie 1 dieser Dissertation von 0,449 auf 0,634 zwar deutlich erhöht werden, allerdings auf Kosten der Generalisierbarkeit für neue Anwendungskontexte wie der Prognose der Akzeptanz von Innovationen. Die zusätzlichen Einflussfaktoren der Nutzungsintention erscheinen bis auf die Ausnahme der hedonischen Motivation problematisch, da sie zu widersprüchlichen Ergebnissen führen. Wie in Abschnitt 6.1 erläutert, führt das Hinzufügen von neuen Konstrukten nicht automatisch zu besseren Modellen, auch wenn einzelne Kennzahlen sich dadurch verbessern, wie beispielsweise die R^2 -Werte der endogenen Konstrukte.

Mit 50,7 erhalten wir für das Konstrukt der Nutzungsintention einen leicht positiven Wert, der sich im Vergleich zu Studie 1 dieser Dissertation somit leicht verbessert ($BI = 48,2$). Im Vergleich zu Studie 1 haben sich auch die Konstruktwerte für PE und EE verbessert, allerdings für SI leicht verschlechtert. Laut der Modellschätzung wird BI hauptsächlich beeinflusst von PE, HM und HT. Anhand der Konstruktwerte tragen PE und HM zu einer positiven Entwicklung von BI bei, wohingegen HT diese durch einen unterdurchschnittlichen Konstruktwert etwas bremst. Von den sieben vom UTAUT2 Modell übernommenen Hypothesen konnten wir nur drei annehmen und mussten vier aufgrund der Ergebnisse unserer Studie ablehnen. Abbildung 31 zeigt die angenommenen und die abgelehnten Hypothesen.

Neben den neuen Einflussfaktoren der Nutzungsintention der unterstützenden Bedingungen und dem Preis-Leistungs-Verhältnis ist auch der Einfluss durch die Aufwandserwartung und sozialen Einflüsse nicht signifikant. Dies steht im Widerspruch zu den Ergebnissen von Studie 1 dieser Dissertation und ist auch im Hinblick auf die etablierten Modelle der Akzeptanzforschung problematisch. Zusammen mit weiteren Erkenntnissen bei der Untersuchung des Messmodells deutet dies darauf hin, dass das UTAUT2 Modell für die Prognose der Akzeptanz von Innovationen nicht geeignet ist. Dennoch konnten wir anhand der erhobenen Daten ein detaillierteres Verständnis der Konstrukte und deren Zusammenspiel im Kontext von Technologien in einem frühen Entwicklungsstadium erlangen. Zudem konnten wir mit der hedonischen Motivation eine mögliche Erweiterung des Modells zur Prognose der Akzeptanz von Innovationen identifizieren.

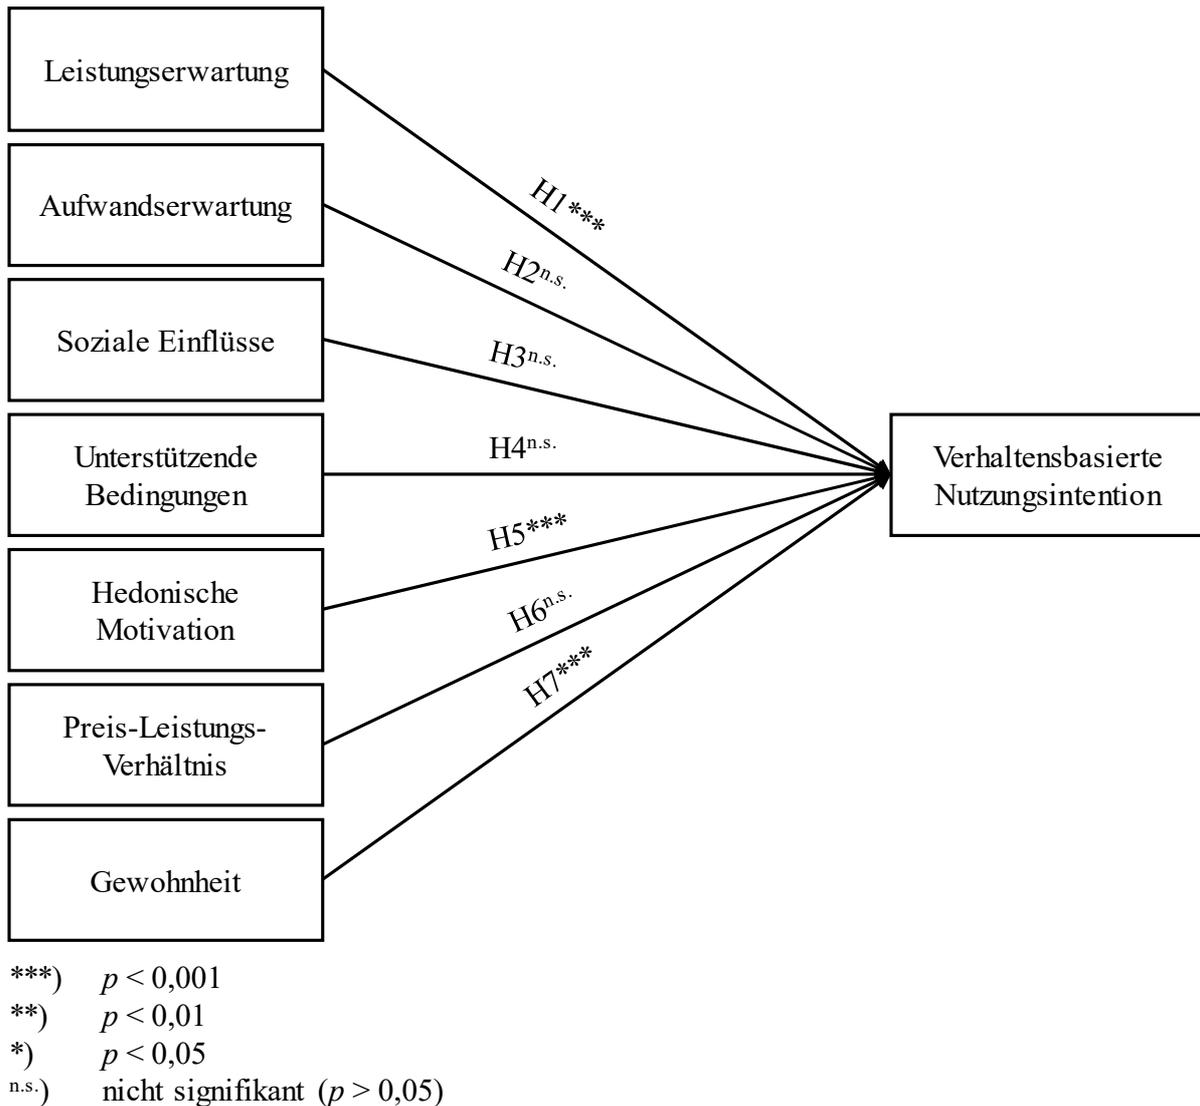


Abbildung 31: Ergebnisse zum Forschungsmodell von Studie 2

Quelle: Eigene Darstellung

Zukünftige Studien zur Untersuchung von neuen Technologien oder zur Prognose der Akzeptanz von Innovationen sollten daher auf dem UTAUT Modell oder dem Modell zur Prognose der Akzeptanz von Innovationen aufbauen, das wir in Kapitel 5 vorgestellt haben. Weiterhin sollten zukünftige Studien zur Akzeptanz autonomer Fahrzeuge auf Basis dieser Modelle die Nutzungsintention mit einigem zeitlichem Abstand bis nach der Einführung autonomer Fahrzeuge mehrmals erneut untersuchen, um Veränderungen bei den Konstruktwerten und den Pfadkoeffizienten im zeitlichen Verlauf erfassen zu können. Zukünftige Studien zur Prognose der Akzeptanz von Innovationen sollten zudem Moderationseffekte durch Alter und Geschlecht berücksichtigen. Auch erste Erfahrungen mit einer neuen Technologie oder verwandten Technologien könnten als moderierender Effekt berücksichtigt werden.

6.6 Fazit

In diesem Kapitel haben wir die Anwendbarkeit des UTAUT2 Modells für die Prognose der Akzeptanz von Innovationen geprüft. Durch eine Studie mit 154 Teilnehmern, die wir 180 Tage nach Studie 1 durchgeführt haben, konnten wir einige Probleme mit dem UTAUT2 Modell in diesem Kontext identifizieren. Diese traten auf in Form von Schwellwertunterschreitungen wie beispielsweise bei der Internen-Konsistenz-Reliabilität oder Schwellwertüberschreitungen bei den HTMT-Verhältnissen zwischen den Konstrukten Gewohnheit und Nutzungsintention sowie der Aufwandserwartung und den unterstützenden Bedingungen. Vor dem Hintergrund, dass wir die Konstrukte nur mit etablierten Skalen operationalisiert haben, sind Probleme des Messmodells ungewöhnlich. Auch das Strukturmodell erscheint problematisch. So mussten wir vier von sieben UTAUT2 Hypothesen ablehnen. Insbesondere die Effekte der Aufwandserwartung und sozialer Einflüsse auf die Nutzungsintention sind nicht signifikant und würden daher in der Prognose der Akzeptanz von Innovationen mit dem UTAUT2 Modell nicht berücksichtigt.

Wie im vorherigen Abschnitt erläutert, lassen sich die Probleme im Strukturmodell auf die neuen Konstrukte des UTAUT2 Modells zurückführen und teilweise mit unseren Ergebnissen der Studie 1 erklären. Obwohl der R^2 -Wert für die verhaltensbasierte Nutzungsintention mit 0,634 vielversprechend erscheint, sprechen die Validitätsprobleme und Widersprüchlichkeiten in Mess- und Strukturmodell gegen die Verwendung des UTAUT2 Modells zur Prognose der Akzeptanz von Innovationen. Mit Studie 2 dieser Dissertation konnten wir dennoch weitere Einblicke in die Akzeptanz von neuen Technologien gewinnen und Weiterentwicklungsmöglichkeiten des Modells zur Prognose der Akzeptanz von Innovationen ableiten. Anhand des UTAUT2 Modells konnten wir zudem weitere Aspekte der Akzeptanz von autonomen Fahrzeugen mit einer neuen Stichprobe untersuchen, die voraussichtlich bei der Marktreife autonomer Fahrzeuge relevant werden.

7 Studie 3: Gesellschaftliche Akzeptanz

Das Ziel der im Folgenden beschriebenen Studie 3 dieser Dissertation ist es, das Modell der gesellschaftlichen Akzeptanz von Siegrist (2000) für die Prognose der Akzeptanz von Innovationen zu verwenden. Dieses Modell basiert nicht auf den Technologieakzeptanzmodellen, die wir in den Studien 1 und 2 dieser Dissertation verwenden. Im Zentrum der gesellschaftlichen Akzeptanz stehen konkrete Risiko- und Nutzenaspekte einer neuen Technologie. Wie in den Studien 1 und 2 untersuchen wir in Studie 3 die Eignung des Modells der gesellschaftlichen Akzeptanz zur Prognose der Akzeptanz von Innovationen anhand des Anwendungsbeispiels autonomer Fahrzeuge. Hierzu wird eine Online-Umfrage mittels eines strukturierten Fragebogens 163 Tage nach Studie 2 durchgeführt. Mit den erhobenen Daten evaluieren wir das Modell der gesellschaftlichen Akzeptanz und vergleichen die Ergebnisse mit den ersten beiden Studien.

Im folgenden Abschnitt 7.1 beschreiben wir Motivation und Ziele dieser Studie. In Abschnitt 7.2 leiten wir das Forschungsmodell und die darin enthaltenen Hypothesen her. Im darauffolgenden Abschnitt 7.3 operationalisieren wir die Konstrukte für den Fragebogen und beschreiben unser methodisches Vorgehen. In Abschnitt 7.4 berichten wir die Ergebnisse der Studie, die wir im darauffolgenden Abschnitt 7.5 diskutieren. Wir beenden dieses Kapitel mit einem Fazit in Abschnitt 7.6.

7.1 Motivation

Der Erfolg aufstrebender Technologien, wie autonomes Fahren oder Gentechnik, basiert maßgeblich auf den Einschätzungen der Öffentlichkeit zu deren Nutzen und den damit verbundenen Risiken (Siegrist, 2000). Im Vergleich zu den in den vorherigen beiden Studien als Grundlage verwendeten Modellen UTAUT und UTAUT2, bezieht sich das Modell der gesellschaftlichen Akzeptanz auf spezifische Risiko- und Nutzenaspekte der zu untersuchenden Technologie. Entscheidend hierbei ist, dass für die gesellschaftliche Akzeptanz nicht der objektive Nutzen und die objektiven Risiken gegenübergestellt werden, sondern deren subjektive Wahrnehmung. Diese kann sich deutlich von den objektiven Einschätzungen von Experten unterscheiden, wie in Abschnitt 2.4 erläutert.

Im Gegensatz zur Untersuchung der *Technologieakzeptanz* ist es auf dem Forschungsgebiet der *gesellschaftlichen Akzeptanz* üblich, dass neue Technologien untersucht werden, bevor sie für die breite Öffentlichkeit verfügbar sind, beispielsweise im Umfeld von Informations- und Kommunikationstechnologie, Gentechnik oder Klonen (Gupta et al., 2011). Ziel dieser Studie ist es daher, den wahrgenommenen Nutzen und die wahrgenommenen Risiken autonomer Fahrzeuge zu erheben und auf deren Basis die gesellschaftliche Akzeptanz zu prognostizieren. Mit den erhobenen Daten evaluieren wir das Modell der gesellschaftlichen Akzeptanz und prüfen dessen Anwendbarkeit zur Prognose der Akzeptanz von Innovationen. Zudem ermitteln wir Handlungsempfehlungen auf Basis der Ergebnisse und identifizieren weitere Forschungsbedarfe.

7.2 Forschungsmodell

Das Forschungsmodell dieser Studie basiert auf dem Modell der gesellschaftlichen Akzeptanz, welches wir in Abschnitt 2.4.1 vorgestellt haben (Siegrist, 2000). Wir konzentrieren uns auf die Auswirkungen der Risiko- und Nutzenwahrnehmung auf die gesellschaftliche Akzeptanz. Ebenfalls im Modell der gesellschaftlichen Akzeptanz enthalten ist der Effekt des Vertrauens auf Risiko- und Nutzenwahrnehmung, den wir in dieser Studie nicht untersuchen. Das Forschungsmodell dieser Studie unterscheidet sich damit deutlich von den Forschungsmodellen der Studien 1 und 2 dieser Dissertation, wodurch wir einen weiteren Erkenntnisgewinn zur Prognose der Akzeptanz von Innovationen erwarten.

Die öffentliche Wahrnehmung einer Technologie ist entscheidend dafür, ob die Gesellschaft die Technologie akzeptiert oder ablehnt (Siegrist et al., 2007). Wesentliche Faktoren in der öffentlichen Wahrnehmung sind dabei die Risiko- und Nutzenwahrnehmung sowie die Abwägung zwischen beiden Faktoren. Wird eine Technologie als nützlich angesehen und mit einem geringen Risiko assoziiert, so wird eine Technologie eher akzeptiert (Siegrist, Cvetkovich & Roth, 2000). Wird eine Technologie jedoch als riskant betrachtet und gleichzeitig nur ein geringer Nutzen wahrgenommen, so führt dies zur Ablehnung oder sogar Widerstandsverhalten.

Gemäß des Risiko Thermostates nach Adams (1999) kann beispielsweise regelmäßige Nutzung einer Technologie ohne Unfall sowohl die individuelle Risikoneigung bezüglich der Technologie erhöhen, als auch deren Risikowahrnehmung reduzieren. Bei aufstrebenden Technologien in einem frühen Entwicklungsstadium können allerdings aufgrund mangelnder Verfügbarkeit von Erprobungsmöglichkeiten für die breite Öffentlichkeit noch keine eigenen Nutzungserfahrungen gesammelt werden. Die öffentliche Wahrnehmung basiert daher hauptsächlich auf Meinungen und der Einstellung zur Technologie anstatt auf objektiven Kriterien.

Ist die subjektive Wahrnehmung der Risiken zu hoch oder sind Nutzen und Risiken ungleich verteilt, sodass beispielsweise die direkte Nutzung einer Technologie kaum Risiken birgt aber bei vermeintlich unbeteiligten Individuen große Risiken erzeugt, so kann dies nicht nur in einen Mangel an Akzeptanz sondern sogar zu aktivem Widerstandsverhalten führen wie in Abschnitt 2.4 erläutert. Widerstandsverhalten kann sich zum Beispiel in Protesten von besorgten Bürgern gegen Gen-, Nano- oder Atomtechnologie äußern. Indirekt können sich die Proteste aufgrund mangelnder gesellschaftlicher Forschungsförderung auf die Weiterentwicklung potentiell vielversprechender neuer Technologie auswirken (Currall et al., 2006). In einer frühen Phase einer aufstrebenden Technologie könnte erheblicher Widerstand aus der Gesellschaft auch dazu führen, dass es eine Technologie erst gar nicht zur Marktreife schafft. Entsprechend des Modells der gesellschaftlichen Akzeptanz (Siegrist, 2000) formulieren wir somit die folgenden Hypothesen:

H1: Je positiver die Nutzenwahrnehmung einer neuen Technologie, desto höher ist die verhaltensbasierte Nutzungsintention für diese Technologie.

H2: Je negativer die Risikowahrnehmung einer neuen Technologie, desto niedriger ist die verhaltensbasierte Nutzungsintention für diese Technologie.

Diese beiden Hypothesen, die wir in diesem Abschnitt hergeleitet haben, bilden unser Forschungsmodell, das in Abbildung 32 dargestellt ist.

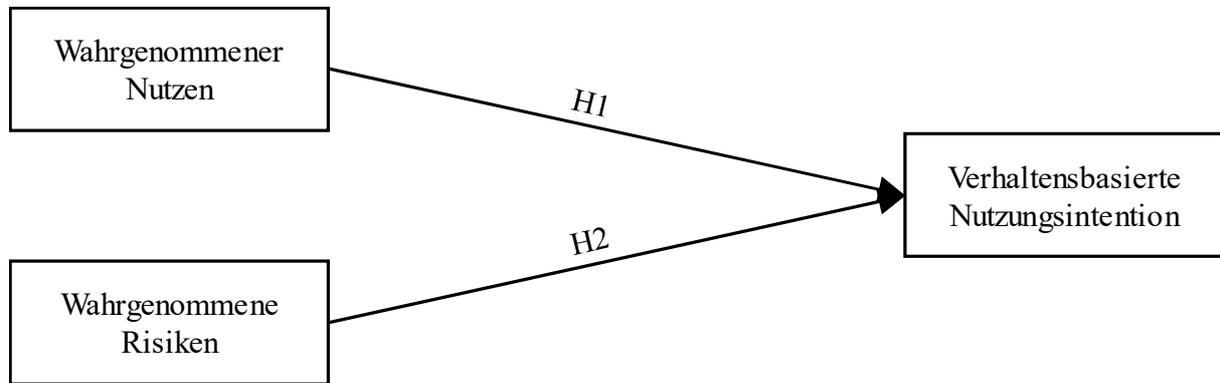


Abbildung 32: Forschungsmodell der Studie 3

Quelle: In Anlehnung an Siegrist (2000)

7.3 Material und Methoden

Die im vorherigen Abschnitt beschriebenen Hypothesen prüfen wir mittels eines strukturierten Fragebogens, wie in Abschnitt 4.1 erläutert. Der Fragebogen wird in Form eines Online-Fragebogens an die Probanden verteilt. Hierfür nutzen wir die Software LimeSurvey. Die Probanden erhalten einen Link zur Umfrage per E-Mail mit der Bitte, die Umfrage auszufüllen. Um Reihenfolgeeffekte zu vermeiden, wurde die Fragenreihenfolge für die Fragen bei jedem Probanden zufällig beim Start der Umfrage festgelegt. Die Umfrage enthält neben den Fragen zur Akzeptanz auch Fragen zu Alter, Geschlecht, Fahrerfahrung und Autobesitz. Weiterhin erheben wir die bisherigen Erfahrungen der Probanden mit autonomen Fahrzeugen und verwandten Technologien wie autonomen Zügen sowie eine Selbsteinschätzung des Fachwissens zu autonomen Fahrzeugen, Informationstechnologie, Ingenieurwissenschaft und Autos im Allgemeinen. Für eine Einschätzung der Marktteilnehmer, die an autonomen Fahrzeugen arbeiten, befragen wir die Probanden außerdem zu den führenden Entwicklern autonomer Fahrzeuge und welche davon sichere autonome Fahrzeuge entwickeln werden.

Kurz vor der geplanten Durchführung der Studie wurde der erste tödliche Unfall mit einem aktiven Tesla Model S Autopiloten bekannt, der in den Medien viel diskutiert wurde. Diesen Unfall erläutern wir näher in Abschnitt 3.3. Daher befragen wir die Probanden auch nach Unfällen mit autonomen Fahrzeugen: „*Have you heard of any incidents of self-driving cars recently?*“ Zur Auswahl stehen die Antwortoptionen „*Yes*“ und „*No*“. Antworten die Probanden mit „*Yes*“, öffnet sich ein Freitextfeld mit der Bitte, den Unfall kurz zu beschreiben: „*Please describe the incident(s) briefly.*“ Da schon alleine die Frage nach diesem Unfall bereits einen Einfluss auf die Beantwortung der Fragen zu Risiko- und Nutzenwahrnehmung haben könnte, wurde sie erst am Ende des Fragebogens gestellt.

Im Gegensatz zu den Studien 1 und 2 dieser Dissertation messen wir in dieser Studie alle drei Konstrukte formativ. Allerdings ist es für die Evaluation des Messmodells erforderlich, die Konstrukte zusätzlich reflektiv zu messen, wie in Abschnitt 4.2.6 erläutert. Die Operationalisierung der Risiko- und Nutzenwahrnehmung basiert im Wesentlichen auf Publikationen, die im Rahmen des von der Daimler und Benz Stiftung geförderten Projektes „Autonomes Fahren – Villa Ladenburg“ entstanden sind (Maurer, Gerdes, Lenz & Winner, 2015). Das Projekt beschäftigt sich mit technischen, rechtlichen und gesellschaftlichen Aspekten autonomen Fahrens. Die Ergebnisse des Projektes wurden kurz vor der Planung von Studie 3 publiziert und liefern somit einen umfassenden und aktuellen Einblick in die bekannten Risiken und den Nutzen autonomer Fahrzeuge. Anders als bei reflektiven Messmodellen, bei der jeder Indikator alle Aspekte eines Konstruktes abdeckt, decken die Indikatoren bei formativen Messmodellen jeweils einen Teilaspekt des Konstruktes ab. Somit ist es erforderlich, dass die Indikatoren einen möglichst großen Bereich des Konstruktes abdecken. Durch die interdisziplinäre Untersuchung autonomer Fahrzeuge im Projekt „Autonomes Fahren – Villa Ladenburg“, sind wir zuversichtlich, dass die aus den Publikationen des Projektes abgeleiteten Indikatoren einen großen Bereich der Konstrukte abdecken. Wir verifizieren diese Annahme anhand einer Redundanzanalyse bei der Evaluation des Messmodells, die wir in Abschnitt 4.2.6 erläutert haben.

Für die Operationalisierung der reflektiven Konstrukte sowie für die reflektive und formative Messung der Nutzungsintention verwenden wir etablierte Indikatoren, die theoretisch fundiert sind und bereits empirisch validiert wurden. Diese passen wir für den Anwendungsfall autonomer Fahrzeuge entsprechend an. Zur besseren Lesbarkeit sind die Konstrukte wie folgt abgekürzt:

- PB (Perceived Benefits) steht für wahrgenommener Nutzen
- PB_Environment (Perceived Benefits for Environment) steht für wahrgenommener Nutzen für die Umwelt
- PB_Companies (Perceived Benefits for Companies) steht für wahrgenommener Nutzen für Unternehmen
- PB_Society (Perceived Benefits for Society) steht für wahrgenommener Nutzen für die Gesellschaft
- PB_User (Perceived Benefits for Users) steht für wahrgenommener Nutzen für die Nutzer
- PR (Perceived Risks) steht für wahrgenommene Risiken
- PR_System (Perceived System Risks) steht für Risiken, die durch das System des autonomen Fahrzeugs ausgelöst werden
- PR_Companies (Perceived Risks for Companies) steht für wahrgenommene Risiken für Unternehmen
- PR_Society (Perceived Risks for Society) steht für wahrgenommene Risiken für die Gesellschaft
- PR_Environment (Perceived Risks for Environment) steht für wahrgenommene Risiken für die Umwelt
- PR_Passive (Perceived Passive Risks) steht für wahrgenommene passive Risiken

- PR_Psych (Perceived Psychological Risks) steht für wahrgenommene Risiken, die auf psychologischen Faktoren basieren
- PB_PR (Perceived Benefits Perceived Risk tradeoff) steht für die Abwägung zwischen wahrgenommenem Nutzen und Risiko
- BI (Behavioral Intention) steht für die Nutzungsintention
- BI_R (Behavioral Intention Reflective) steht für die reflektiv gemessene Nutzungsintention

Die Fragebogenteile zu Nutzenwahrnehmung, Risikowahrnehmung und Nutzenintention von Studie 3 befinden sich in Anhang C.

7.3.1 Operationalisierung der Nutzenwahrnehmung (PB)

Die Nutzenwahrnehmung haben wir entsprechend der Tabelle 52 mit einem formativen Messmodell operationalisiert. Die Indikatoren zur Nutzenwahrnehmung gliedern sich in vier Bereiche: Nutzen für die Nutzer autonomer Fahrzeuge (PB1, PB3 und PB7), Nutzen für die Umwelt (PB2 und PB8), Nutzen für Unternehmen (PB4) und Nutzen für die Gesellschaft (PB5 und PB6). Zur Beantwortung der Fragen zur Nutzenwahrnehmung autonomer Fahrzeuge dient eine Likert-Skala mit fünf Punkten von 1 = „*no benefit at all*“, was auf eine sehr geringe Nutzenwahrnehmung hindeutet, bis 5 = „*very high benefit*“, also einer sehr hohen Nutzenwahrnehmung. Die dazwischenliegenden Skalenelemente wurden nicht benannt, damit eine äquidistante Verteilung der Antwortoptionen angenommen werden kann.

Für die Nutzer von autonomen Fahrzeugen entsteht Nutzen durch eine erhebliche Verringerung von Verkehrsunfällen (*PB1*). Damit verbunden ist eine Verringerung von Verkehrstoten, verletzten Personen oder Sachschäden (Grunwald, 2016, S. 645). Weiterhin ermöglichen autonome Fahrzeuge allen Insassen, die Fahrzeit besser zu nutzen (*PB3*) um beispielsweise zu schlafen, zu arbeiten oder zu spielen (Winner & Wachenfeld, 2016, S. 270). Bisher kann der Fahrer diesen Tätigkeiten nicht nachgehen. Autonome Fahrzeuge werden auch mit neuen Mobilitätsdienstleistungen einhergehen (*PB7*), die den Besitz eines eigenen Fahrzeuges immer weniger erfordern um individuelle Mobilitätsbedarfe zu erfüllen (Fraedrich & Lenz, 2016).

Für die Umwelt entsteht Nutzen durch eine effizientere Nutzung der bestehenden Verkehrswege, beispielsweise kann ein autonomes Fahrzeug potenziell schneller fahren, da es bezüglich Sensorik und Reaktionszeit dem Menschen überlegen ist (*PB2*). Durch Kommunikation mit anderen Fahrzeugen und der Infrastruktur, sogenannte *Car-to-X Kommunikation*, kann ein autonomes Fahrzeug vorausschauender als der Mensch fahren und sich somit gleichmäßiger fortbewegen, was zu weniger Staus führen könnte. Insgesamt verbessert sich dadurch die Umweltbilanz von Fahrzeugen (Grunwald, 2016, S. 647). Wie im vorherigen Absatz erläutert, werden neue Mobilitätsdienstleistungen durch autonome Fahrzeuge ermöglicht (*PB8*). Durch *Car Sharing* kann ein autonomes Fahrzeug durch mehrere Personen genutzt werden. Weiterhin können mittels *Ride Sharing* (Teil-) Strecken gemeinsam zurückgelegt werden. Für die Umwelt ergibt sich daraus der Nutzen, dass weniger Ressourcen für den Fahrzeugbau benötigt werden, sowie weniger Emissionen pro Kopf für Fahrten entstehen (Pavone, 2016).

Nr.	Frage in Fragebogen	Bereich	Quelle
PB1	For users: Self-driving cars could lead to a major reduction in the number of traffic accidents and thus less harm to life, health, and valuables.	PB_User	(Grunwald, 2016, S. 645)
PB2	For the environment: Self-driving cars promise greater efficiency, reduced congestion, and better environmental performance.	PB_Environment	(Grunwald, 2016, S. 647)
PB3	For users: Self-driving cars allow people to make better use of their time while driving (e.g., sleep, work, or play while driving).	PB_User	(Winner & Wachenfeld, 2016, S. 270)
PB4	For companies: If a company succeeds in developing self-driving cars, it could vastly increase their market share and profits.	PB_Companies	(Grunwald, 2016, S. 648)
PB5	For society: Self-driving cars can lead to the emergence of new fields of activity and job opportunities.	PB_Society	(Grunwald, 2016, S. 649)
PB6	For society: Self-driving cars promise greater accessibility for people with (temporarily) reduced mobility, such as young, elderly, or sick people.	PB_Society	(Grunwald, 2016, S. 650)
PB7	For users: Self-driving cars will lead to mobility services that offer individual mobility without owning a car.	PB_User	(Fraedrich & Lenz, 2016)
PB8	For the environment: Sharing of self-driving cars will reduce the total amount of cars and leads to better utilization of cars.	PB_Environment	(Pavone, 2016)

Tabelle 52: Operationalisierung von PB für Studie 3

Quelle: Eigene Darstellung

Von autonomen Fahrzeugen profitieren auch Unternehmen (*PB4*). Einerseits können neue Unternehmen entstehen, die innovative Mobilitätsdienstleistungen anbieten. Andererseits können auch bestehende Unternehmen wie beispielsweise Fahrzeughersteller mit Mobilitätsdienstleistungen ein weiteres Standbein aufbauen, das weniger konjunkturabhängig ist. Darüber hinaus können sich Hersteller autonomer Fahrzeuge mit dieser Technologie auf dem Markt differenzieren, zum Beispiel über einen besonders komfortablen Fahrstil oder zusätzlicher Fahrzeugausstattung wie Betten oder hochwertigen Unterhaltungssystemen für alle Insassen des Fahrzeuges (Grunwald, 2016, S. 648).

Die Auswirkungen von autonomen Fahrzeugen auf die Gesellschaft werden teilweise kontrovers diskutiert. Ein Diskussionspunkt ist der Wegfall von Arbeitsplätzen im Bereich der Logistik, wie zum Beispiel Lastwagenfahrer, oder im Bereich der Personenbeförderung, wie

Taxi- oder Busfahrer. Demgegenüber stehen jedoch auch neue Arbeitsstellen, die durch autonome Fahrzeuge entstehen könnten (PB5), beispielsweise für deren Steuerung und Überwachung sowie für die Entwicklung, Test und Herstellung der benötigten Software für autonome Fahrzeuge (Grunwald, 2016, S. 649). Weiterhin ermöglichen autonome Fahrzeuge die Erfüllung von Mobilitätsbedarfen von Personen mit eingeschränkten Möglichkeiten (PB6), wie zum Beispiel jungen Personen unterhalb des Führerscheinalters, älteren Personen mit gesundheitlichen Problemen und kranken Personen sowie Personen mit Behinderungen. Somit leisten autonome Fahrzeuge einen Beitrag zur Inklusion verschiedener Personengruppen mit (temporär) eingeschränkter Mobilität (Grunwald, 2016, S. 650).

Für die Redundanzanalyse der Nutzenwahrnehmung verwenden wir das Single-Item Konstrukt PB_PR, das eine Abwägung zwischen wahrgenommenem Nutzen und Risiko beinhaltet. Der zugehörige Indikator „riskbenefit“ für das Konstrukt PB_PR lautet: „*The benefits outweigh the risks of self-driving cars.*“ Die Probanden können die Aussage, ob die Vorteile autonomer Fahrzeuge die Risiken überwiegen, mit einer fünfstufigen Likert-Skala von 1 = „*strongly disagree*“ also starker Ablehnung bis 5 = „*strongly agree*“ also starker Zustimmung zur Aussage beantworten. Die dazwischenliegenden Skalenelemente wurden nicht benannt, damit eine äquidistante Verteilung der Antwortoptionen angenommen werden kann.

7.3.2 Operationalisierung der Risikowahrnehmung (PR)

Die Risikowahrnehmung haben wir entsprechend Tabelle 53 mit einem formativen Messmodell operationalisiert. Die Indikatoren zur Risikowahrnehmung gliedern sich in sechs Bereiche: Risiken, die durch das System des autonomen Fahrzeugs ausgelöst werden (PR1, PR2 und PR4), Risiken für Unternehmen (PR5 und PR6), Risiken für die Gesellschaft (PR7, PR8 und PR9), Risiken für die Umwelt (PR12), passive Risiken (PR3, PR10 und PR11) und Risiken, die auf psychologischen Faktoren basieren (PR13 und PR14). Zur Beantwortung der Fragen zur Risikowahrnehmung autonomer Fahrzeuge dient eine Likert-Skala mit fünf Punkten von 1 = „*no risk at all*“, was auf eine sehr geringe Risikowahrnehmung hindeutet, bis 5 = „*very high risk*“, also einer sehr hohen Risikowahrnehmung. Die dazwischenliegenden Skalenelemente wurden nicht benannt, damit eine äquidistante Verteilung der Antwortoptionen angenommen werden kann.

Nr.	Frage in Fragebogen	Bereich	Quelle
PR1	Self-driving cars could be faced with unforeseen situations which are unmanageable for the automation.	PR_System	(Grunwald, 2016, S. 645)
PR2	Accidents may occur which are specific to self-driving cars and which would be unlikely to occur with a human driver.	PR_System	(Grunwald, 2016, S. 645)
PR3	Technology-caused accidents which affect the users of self-driving cars as passengers and their environment.	PR_Passive	(Grunwald, 2016, S. 646)
PR4	Simultaneous breakdown or malfunctioning of a large number of self-driving cars based on the same software problem.	PR_System	(Grunwald, 2016, S. 647)
PR5	The return on investment may not be on the expected scale or in the expected timeframe due to self-driving cars failing to catch on a large scale.	PR_Companies	(Grunwald, 2016, S. 648)
PR6	Even after a successful market launch of self-driving cars, incidents can occur which could pose a major risk for the affected brands.	PR_Companies	(Grunwald, 2016, S. 648)
PR7	Comprehensive introduction of self-driving cars would affect the labor market (e.g., truck drivers, taxi drivers).	PR_Society	(Grunwald, 2016, S. 649)
PR8	Increased costs of individual mobility due to the costs of self-driving cars.	PR_Society	(Grunwald, 2016, S. 650)
PR9	The electronic trail of self-driving cars could lead to a complete movement profile of their users.	PR_Society	(Grunwald, 2016, S. 651)
PR10	Small technical failures or random events can lead to system instability through complex chain reactions and positive feedback.	PR_Passive	(Grunwald, 2016, S. 651)
PR11	Susceptibility to terrorist attacks (e.g., in the form of a cyber-terror attack).	PR_Passive	(Grunwald, 2016, S. 651f.)
PR12	Self-driving cars will lead to an increase of individual transport and, thus, to an increase of overall traffic.	PR_Environment	(Heinrichs, 2016)
PR13	Self-driving cars will take away a lot of control from the drivers (e.g., which route to take at which speed).	PR_Psych	(Woisetschläger, 2016)
PR14	Self-driving cars will be less fun / enjoyable than driving manually.	PR_Psych	(Venkatesh et al., 2012)

Tabelle 53: Operationalisierung von PR für Studie 3

Quelle: Eigene Darstellung

Eine große Herausforderung bei der Entwicklung autonomer Fahrzeuge ist das Training der Algorithmen mit möglichst unterschiedlichen Fahrsituationen (*PR1*). Die Algorithmen generieren auf Basis der Trainingsdaten ein Modell, das dann für die Steuerung des Fahrzeuges verwendet wird. Allerdings ist die Abstraktionsfähigkeit der Algorithmen begrenzt und besonders ungewöhnliche Fahrsituationen könnten für autonome Fahrzeuge nicht beherrschbar sein. Weiterhin müssen die Algorithmen die Sensordaten korrekt interpretieren, was beispielsweise bei schwierigen Lichtverhältnissen oder starkem Schneefall ebenfalls zu Problemen führen könnte (Grunwald, 2016, S. 645). Diesbezüglich ist der Mensch den autonomen Fahrzeugen noch überlegen. Eine fehlerhafte Interpretation der Situation oder eine falsche Reaktion des Systems könnte daher zu Unfällen führen (*PR2*), die mit einem menschlichen Fahrer nicht passieren würden (Grunwald, 2016, S. 645). So kam es zu dem im Abschnitt 3.3 erläuterten ersten tödlichen Unfall mit dem Tesla Autopilot, bei dem das System einen kreuzenden Sattelschlepper aufgrund einer fehlerhaften Interpretation von Kameradaten nicht erkannte. Autonome Fahrzeuge bergen auch das Risiko, dass ein Softwarefehler zu einem gleichzeitigen Ausfall einer großen Anzahl von autonomen Fahrzeugen führt (*PR4*). Je nachdem wie hoch die Marktdurchdringung autonomer Fahrzeuge in dieser Situation ist, könnte dies einen hohen Anteil der individuellen Mobilität ohne Vorwarnung zum Erliegen bringen (Grunwald, 2016, S. 647).

Für Unternehmen stellt sich bei der Entwicklung neuer Technologie die Frage, ob sich die Entwicklung lohnt (*PR5*), also ob die Entwicklungskosten geringer als die zu erwartenden Einnahmen in einem definierten Zeitraum sind. Firmen tätigen hohe Investitionen in die Entwicklung autonomer Fahrzeuge und es kann Stand 2019 noch Jahre dauern, bis Serienreife erreicht wird. Demgegenüber steht auch ein hoher Nutzen autonomer Fahrzeuge. Dennoch ist noch nicht absehbar, ob autonome Fahrzeuge von der breiten Bevölkerung akzeptiert werden und somit die Entwicklungskosten in einem absehbaren Zeitraum erwirtschaftet werden können (Grunwald, 2016, S. 648). Auch die Zeit direkt nach der Markteinführung autonomer Fahrzeuge birgt diesbezüglich Gefahren. Werden diese beispielsweise aufgrund von Termin- oder Kostendruck zu früh auf den Markt gebracht, könnten Unfälle die Folge sein (*PR6*). Dies würde einerseits den Hersteller der betroffenen Fahrzeuge direkt oder in Form von Imageverlust und Regressansprüchen betreffen. Andererseits könnte aber auch die Technologie an sich in Verruf geraten, was Widerstand in der Gesellschaft zur Folge haben kann (Grunwald, 2016, S. 648).

Wie bei der Nutzenwahrnehmung im vorherigen Abschnitt 7.3.1 erläutert, werden die Effekte von autonomen Fahrzeugen auf den Arbeitsmarkt kontrovers diskutiert (*PR7*). Einerseits entstehen durch autonome Fahrzeuge neue Arbeitsplätze, andererseits sind diese teilweise hochspezialisiert, wie beispielsweise Softwareentwickler mit fundierten Kenntnissen in Statistik und maschinellen Lernverfahren. Entsprechende Stellen sind im Jahr 2019 bereits schwer zu besetzen. Zusätzliche offene Stellen in diesem Bereich würden den Mangel an entsprechend qualifizierten Bewerbern weiter verschärfen. Zudem können die Arbeitnehmer aus den wegfallenden Bereichen nur schwer in die neu entstehenden Berufe wechseln. Viele Positionen in den neuen Bereichen erfordern ein abgeschlossenes Studium sowie einschlägige Arbeitserfahrung (Grunwald, 2016, S. 649).

Weiterhin besteht die Möglichkeit, dass die Kosten für individuelle Mobilität durch autonome Fahrzeuge weiter steigen (*PR8*). Entstehende Kosten für die Entwicklung autonomer Fahrzeuge müssen zunächst von den Herstellern wieder erwirtschaftet werden. Somit ist zu erwarten, dass der Preis autonomer Fahrzeuge im Vergleich zu konventionellen Fahrzeugen zunächst höher sein wird. Um den Preis autonomer Fahrzeuge zu reduzieren, könnten Hersteller die Entwicklungskosten auch auf nicht-autonome Fahrzeuge umlegen. Somit würden auch die Preise konventioneller Fahrzeuge beziehungsweise der Mobilität im Allgemeinen steigen. Mobilitätsdienstleistungen wie Car Sharing oder Ride Sharing verursachen kontinuierliche und bedarfsabhängige Kosten. Über einen längeren Zeitraum von mehreren Jahren hinweg betrachtet, können Mobilitätsdienstleistungen dadurch teurer werden als der einmalige Kauf eines autonomen Fahrzeuges. Personen könnten also in vermeintlich günstig erscheinende Mobilitätsdienstleistungen gelockt werden und schlussendlich aber deutlich mehr bezahlen (Grunwald, 2016, S. 650).

Ein weiteres kontrovers diskutiertes Thema ist die Verwendung der Daten, die bei autonomen Fahrten erzeugt werden (*PR9*). Diese entstehen bei jeder Fahrt und dienen beispielsweise dazu, das Kartenmaterial und die Fahrleistung autonomer Fahrzeuge zu verbessern sowie Staus und andere Verkehrshindernisse zu erkennen, vorherzusagen oder sogar zu verhindern. Die Erhebung dieser Daten ist somit sinnvoll und teilweise notwendig. Die Datenerhebung, beispielsweise mit einer Blackbox wie bei Flugzeugen, könnte gesetzlich vorgeschrieben werden. Die erhobenen Daten könnten aber nicht nur im Sinne der Nutzer Verwendung finden. Mit den Daten könnten beispielsweise auch detaillierte Bewegungsprofile von Personengruppen oder sogar einzelner Personen erstellt und missbräuchlich verwendet werden (Grunwald, 2016, S. 651).

Auch für die Umwelt könnten autonome Fahrzeuge negative Konsequenzen haben (*PR12*). Die zusätzlichen Möglichkeiten zur Erfüllung individueller Mobilitätsbedarfe durch autonome Fahrzeuge könnten die Nutzung von anderen, umweltfreundlicheren Verkehrsmitteln kabbalisieren. So könnte sein, dass Menschen sich lieber vom eigenen autonomen Fahrzeug direkt vor der eigenen Haustür abholen und bis zum Eingang der Arbeitsstelle fahren lassen als die elektrifizierte S-Bahn mit zahlreichen anderen Menschen und gegebenenfalls beengten Platzverhältnissen zu nutzen. Anstatt der bei beim Indikator PB8 beschriebenen Vorteile könnte daher auch genau das Gegenteil der Fall sein (Heinrichs, 2016).

Neben den Gefahren, die durch die aktive Nutzung autonomer Fahrzeuge ausgelöst werden, gibt es auch passive Risiken für autonome Fahrzeuge. So könnten Störungen in der von autonomen Fahrzeugen verwendeten Infrastruktur den Betrieb autonomer Fahrzeuge und deren Insassen gefährden (*PR3*). Beispielsweise könnte eine Ampel, die im Mischbetrieb autonomer und nicht-autonomer Fahrzeuge noch erforderlich ist, ein falsches Signal an ein autonomes Fahrzeug übermitteln und dadurch einen Unfall auf einer Kreuzung verursachen (Grunwald, 2016, S. 646). Weiterhin könnten kleine technische Ausfälle oder Zufallsereignisse durch komplexe Kettenreaktionen und positive Rückkopplungseffekte zur Instabilität des kompletten Verkehrssystems führen (*PR10*), was auch den Betrieb autonomer Fahrzeuge betreffen könnte (Grunwald, 2016, S. 651). Autonome Fahrzeuge könnten auch Ziel von Terroranschlägen werden (*PR11*). Diese könnten beispielsweise in Form einer Hackerattacke und aufgrund der

erforderlichen Vernetzung autonomer Fahrzeuge globale Ausmaße annehmen (Grunwald, 2016, S. 651f.).

Weiterhin könnten auch Risiken autonomer Fahrzeuge, die auf psychologischen Faktoren basieren, wahrgenommen werden. Nicht mehr selbst fahren zu können oder zu dürfen ist für viele eine beängstigende Vorstellung (*PR13*). Auch mangelnde Eingriffsmöglichkeiten während der Fahrt werden eher kritisch wahrgenommen. Dies ist auf den psychologischen Faktor des Kontrollverlustes zurückzuführen (Woisetschläger, 2016). Auch wenn autonomes Fahren deutlich sicherer sein wird als selbst zu fahren, so erzeugt der Gedanke, sich komplett auf ein System verlassen zu müssen ein ungutes Gefühl. Zudem ist selbst zu fahren für viele mit hedonischen Aspekten verbunden (*PR14*). Autofahren wird von vielen mit Spaß und Freude verbunden, auch wenn dies in manchen Situationen, zum Beispiel im Stau, nicht der Fall ist. Während in bestimmten Situationen eine Automatisierung also als wünschenswert betrachtet wird, erscheint der Umstieg auf ein autonomes Fahrzeug aus hedonischen Aspekten weniger erstrebenswert (Venkatesh et al., 2012).

Autonome Fahrzeuge erfüllen einige der Kriterien, die zu erhöhter Risikowahrnehmung führen. Diese Aspekte lassen sich in drei Dimensionen aufteilen: *Unbekanntheit*, *Exposition* und *Schrecklichkeit* (Jungermann & Slovic, 1993). Autonome Fahrzeuge sind eine neue Technologie, die noch nicht erprobbar ist und daher für viele Menschen unbekannt und nicht einschätzbar ist. Nach der Einführung autonomer Fahrzeuge und einem Mischverkehr mit herkömmlichen Fahrzeugen sind potenziell alle Verkehrsteilnehmer den Risiken und Gefahren, die mit dieser Technologie einhergehen, ausgesetzt. Bei Unfällen im öffentlichen Straßenverkehr mit autonomen Fahrzeugen bei Geschwindigkeiten von 100 km/h und mehr sind tödliche Unfälle nicht auszuschließen. Zudem erfolgt die Exposition gegenüber autonomen Fahrzeugen nicht freiwillig. Nutzen von autonomen Fahrzeugen haben im ersten Schritt nur diejenigen, die diese Fahrzeuge auch tatsächlich verwenden. Weiterhin steigt mit der Anzahl autonomer Fahrzeuge auf den Straßen das potenzielle Risiko weiter an. Autonome Fahrzeuge, bei denen nur noch das Ziel der Reise eingegeben werden muss und die gegebenenfalls kein Lenkrad oder Pedale aufweisen, sind nicht mehr kontrollierbar, was ebenfalls zur Schrecklichkeit der Technologie beiträgt. Wir rechnen daher eher mit einer übersteigerten Risikowahrnehmung, die sich anhand erhöhter Konstruktwerte der Risikowahrnehmung zeigen könnte.

Für die Redundanzanalyse der Risikowahrnehmung verwenden wir dasselbe Single-Item Konstrukt *PB_PR* wie bei der Nutzenwahrnehmung im vorherigen Abschnitt 7.3.1 beschrieben, das eine Abwägung zwischen wahrgenommenem Nutzen und Risiko beinhaltet.

7.3.3 Operationalisierung der Nutzungsintention (BI)

Die Operationalisierung der Nutzungsintention basiert auf fünf Studien zum autonomen Fahren und einer Frage aus dem UTAUT2 Modell (BI1), wie in Tabelle 54 ersichtlich. Für die Redundanzanalyse messen wir die Nutzungsintention mit den Indikatoren BI1, BI2 und BI4 reflektiv. Im Strukturgleichungsmodell für diese Studie verwenden wir für die Nutzungsintention ein formatives Messmodell bestehend aus den Indikatoren BI3, BI5, BI6, BI7, BI8, BI9 und BI10. Zur Beantwortung der Fragen zur Nutzungsintention autonomer

Fahrzeuge dient eine Likert-Skala mit fünf Punkten von 1 = „*strongly disagree*“, was einer starken Ablehnung der Aussage entspricht, bis 5 = „*strongly agree*“, also einer starken Zustimmung. Die dazwischenliegenden Skalenelemente wurden nicht benannt, damit eine äquidistante Verteilung der Antwortoptionen angenommen werden kann.

Nr.	Konstrukt	Frage in Fragebogen	Quelle
BI1	BI_R	I intend to use self-driving cars in the future.	(Venkatesh et al., 2012)
BI2	BI_R	I would buy a self-driving car in the future.	(Piao et al., 2016)
BI3	BI	I would use a self-driving car if am not able to drive by myself (e.g., sick, drunk).	(Haboucha et al., 2017)
BI4	BI_R	If my car could drive autonomously, I would not drive by myself most of the time.	(Nees, 2016)
BI5	BI	If my car could drive autonomously, I would enable autonomous driving on the highway.	(Payre et al., 2014)
BI6	BI	If my car could drive autonomously, I would enable autonomous driving in the city.	(Piao et al., 2016)
BI7	BI	If my car could drive autonomously, I would enable autonomous driving for parking.	(Payre et al., 2014)
BI8	BI	If my car could drive autonomously, I would enable autonomous driving if I feel tired	(Payre et al., 2014)
BI9	BI	I would only use a self-driving car if I could still drive by myself.	(Payre et al., 2014)
BI10	BI	I would move to a more rural area if I had a self-driving car.	(Heinrichs, 2016)

Tabelle 54: Operationalisierung von BI und BI_R für Studie 3

Quelle: Eigene Darstellung

Die drei Fragen zur reflektiven Messung der Nutzungsintention mit dem Konstrukt BI_R beziehen sich allgemein auf die Nutzung autonomer Fahrzeuge. Der Indikator *BI1* beschreibt die Nutzung autonomer Fahrzeuge in der Zukunft, da diese zum Zeitpunkt der Studie noch nicht verfügbar sind. Mit diesem Indikator sind also auch zukünftige Mobilitätsdienstleistungen abgedeckt. Der Indikator *BI2* bezieht sich hingegen auf den einmaligen Kauf eines autonomen Fahrzeuges mit anschließender Nutzung. Beide Indikatoren treffen keine Aussage zur Nutzung von Fahrzeugen, die der Proband noch selbst fahren kann, und zusätzlich auf Wunsch auch autonom fahren können. Dies wird mit dem Indikator *BI4* adressiert, bei dem sich die Probanden bei einer Wahlmöglichkeit die meiste Zeit für eine autonome Fahrt entscheiden würden, wenn ihr Fahrzeug sowohl das Selbstfahren als auch autonomes Fahren unterstützt.

Die Indikatoren des formativ gemessenen Konstruktes BI beziehen sich jeweils auf konkrete Aspekte der Nutzung. *BI3* beschreibt die Nutzung eines autonomen Fahrzeuges in Situationen, in denen der Fahrer nicht (mehr) Fahrtüchtig ist, also beispielsweise bei einem zu hohen

Blutalkoholspiegel oder einer Erkrankung und möglicherweise in Verbindung mit Medikamenten, die die Fahrtüchtigkeit beeinträchtigen. Eine ähnliche Situation beschreibt der Indikator *BI8*. In diesem Fall fühlt sich der Fahrer aufgrund von Müdigkeit nicht mehr in der Lage, ein Fahrzeug zu führen und müsste ohne ein autonomes Fahrzeug möglicherweise eine Pause einplanen oder sogar eine Übernachtung. Die Indikatoren *BI5*, *BI6* und *BI7* adressieren die Präferenz autonomen Fahrens in konkreten Fahrsituationen: Fahren auf einer Schnellstraße (*BI5*), Fahren in der Stadt (*BI6*) und beim Einparken (*BI7*). Um den psychologischen Faktor des Kontrollverlustes bei autonomen Fahrzeugen zu adressieren, der bei *PR13* erläutert wurde, könnte die Möglichkeit auch in einem autonomen Fahrzeug noch selbst das Steuer übernehmen ein wichtiger Faktor für die Akzeptanz autonomer Fahrzeuge sein, wie im Indikator *BI9* beschrieben. Der Indikator *BI10* beschreibt schließlich das Inkaufnehmen längerer Fahrtstrecken mit autonomen Fahrzeugen durch den Umzug in ein ländlicheres Gebiet.

7.4 Ergebnisse

7.4.1 Erhebung und Prüfung der Daten

Im Zeitraum vom 15.07.2016 bis zum 27.07.2016 haben insgesamt 196 Probanden an der Online-Umfrage teilgenommen. Diese Studie wurde also 169 Tage nach Studie 1 durchgeführt. Um eine hohe Datenqualität zu gewährleisten und falsche Schlüsse zu vermeiden, wurden die Antworten aller Probanden anhand von zwei Kriterien geprüft (Hair et al., 2017, S. 50f):

- Die Online-Umfrage enthielt zwei Kontrollfragen, die für jeden Probanden zufällig im Fragebogen für die gesellschaftliche Akzeptanz autonomer Fahrzeuge positioniert wurden. Diese Fragen erfordern das Anklicken einer bestimmten Antwortoption, damit Probanden ausgeschlossen werden können, die willkürlich auf Antwortoptionen klicken. Sieben Probanden wurden aufgrund von Abweichungen bei den vorgegebenen Antwortoptionen ausgeschlossen.
- Eine genaue Betrachtung der Bearbeitungszeit des Fragebogens zeigte weitere ungewöhnliche Fälle. Drei Probanden haben den Fragebogen in unter 4 Minuten beantwortet. Der Median der Bearbeitungszeit beträgt 14,28 Minuten. Da eine komplette und sorgfältige Beantwortung des Fragebogens in unter 4 Minuten sehr unwahrscheinlich ist, haben wir diese drei Probanden entfernt. Ein weiterer Proband benötigte 57,94 Minuten. Die zweitlängste Bearbeitungszeit lag bei 46,34 Minuten. Wir vermuten daher eine starke Ablenkung oder anderweitige Probleme des Probanden während oder mit der Beantwortung der Fragen und schließen diesen daher ebenfalls aus.

Von den 196 komplett ausgefüllten Fragebögen werden daher 185 für die weiteren Analysen verwendet.

Unter den 185 Teilnehmern befinden sich 56 Frauen (30,3 %) und 129 Männer (69,7 %). Somit ist in Studie 3 dieser Dissertation der Frauenanteil unter den Probanden im Vergleich zu den Studien 1 und 2 am höchsten (Studie 1: 28,6 %, Studie 2: 24,7 %). Das Durchschnittsalter beträgt 20,8 Jahre, im Median 20 Jahre und liegt in einer Spanne zwischen 18 und 30 Jahren. Der Median des Alters ist somit in allen drei Studien gleich. Das Durchschnittsalter ist in dieser

Studie am höchsten (Studie 1: 20,6 Jahre, Studie 2: 20,4 Jahre). Mit 176 Probanden besitzen 95,1 % aller Studienteilnehmer einen Führerschein und somit ähnlich viele wie in Studie 1 (96,2 %) aber deutlich mehr als in Studie 2 (85,1 %). Mit 73 Probanden (39,5 %) besitzen in dieser Studie im Vergleich zu Studie 1 (33,0 %) und Studie 2 (35,1 %) anteilmäßig die meisten Probanden ein eigenes Auto. Tabelle 55 fasst die Daten zur Stichprobe zusammen.

	Anzahl	Anteil
Gültige Fragebögen	185	94,4 %
Frauen	56	30,3 %
Männer	129	69,7 %
Alter (Mittelwert)	20,8 Jahre	
Führerschein vorhanden	176	95,1 %
Kein Führerschein	9	5,9 %
Eigenes Auto	73	39,5 %
Kein eigenes Auto	112	60,5 %

Tabelle 55: Deskriptive Statistik zu den Probanden von Studie 3

Quelle: Eigene Darstellung

Tabelle 56 enthält Informationen zur Fahrerfahrung und Fahrleistung der Probanden. Die Probanden mit Führerschein besitzen diesen im Mittel seit 3,44 Jahren (SD = 2,28 Jahre). Die jährliche Fahrleistung beträgt bei Probanden mit Führerschein durchschnittlich 7.682 km (SD = 10.301 km), maximal 50.000 km pro Jahr und minimal 0 km pro Jahr trotz Führerschein. Im Durchschnitt pendeln die Probanden 10,0 km (SD = 12,3 km) und maximal 70,0 km zur Arbeit oder Ausbildungsstätte. Hierfür benötigen sie durchschnittlich 23,0 Minuten (SD = 16,5 Minuten).

	Mittelwert	Standardabweichung
Fahrerfahrung	3,44 Jahre	2,28 Jahre
Jährliche Fahrleistung	7.682 km	10.301 km
Pendeldistanz	10,0 km	12,3 km
Pendeldauer	23,0 Minuten	16,5 Minuten

Tabelle 56: Fahrerfahrung und Fahrleistung der Probanden von Studie 3

Quelle: Eigene Darstellung

7.4.2 Erfahrung und Fachwissen

In diesem Online-Fragebogen gaben 34 Probanden (18,4 %) an, bereits erste Erfahrungen mit autonomen Fahrzeugen und verwandten Technologien wie autonomen Zügen gemacht zu haben. Die Frage nach den Erfahrungen ist breiter formuliert als in Studie 2 und inkludiert auch Erfahrungen mit anderen autonomen Fahrzeugtypen. Aus den Beschreibungen der Probanden ist ersichtlich, dass es sich dabei in den meisten Fällen um autonome Züge handelt (N = 28). In einem Fall wurde die Teilnahme an einem Seminar zum autonomen Fahren angegeben.

Wiederum ein Proband gab an, an Bord eines Segelbootes mit einem Autopiloten gewesen zu sein. Vier Probanden gaben Erfahrungen mit Autos an, die fortschrittliche Assistenzsysteme besitzen wie Park- und Spurhalteassistenten, einen adaptiven Tempomat, sowie Kombinationen dieser Systeme.

Fachwissen	Autos	Ingenieurswissenschaft	Informationstechnologie	Autonome Fahrzeuge
1 = Überhaupt kein Fachwissen	7	1	12	4
2	74	30	106	38
3	132	105	150	87
4	164	188	172	180
5	180	300	90	230
6	120	150	48	186
7 = Sehr gutes Fachwissen	0	14	7	77

Tabelle 57: Fachwissen im Bereich autonomer Fahrzeuge und angrenzenden Gebieten bei Studie 3

Quelle: Eigene Darstellung

Um das Fachwissen zu autonomen Fahrzeugen weiter zu differenzieren, haben wir die Probanden ihr Fachwissen zu autonomen Fahrzeugen, Informationstechnologie, Ingenieurwissenschaft und Autos im Allgemeinen mittels einer 7-Punkte Likert Skala selbst einschätzen lassen. Das Fachwissen im Bereich Autos ($M = 4,335$, $SD = 1,454$) wurde dabei von den Probanden am höchsten eingeschätzt. Auch das Fachwissen im Bereich Informationstechnologie liegt über dem Skalendurchschnitt von 4 Punkten ($M = 4,259$, $SD = 1,21$). Unter dem Skalendurchschnitt liegen das Fachwissen bezüglich autonomer Fahrzeuge ($M = 3,659$, $SD = 1,378$) und Ingenieurwissenschaft ($M = 3,162$, $SD = 1,275$). Tabelle 57 zeigt die Verteilung der Antworten. Die Auswertung der Selbsteinschätzung des Fachwissens sind in Tabelle 58 zusammengefasst.

Kenntnisse	M	SD
Autonome Fahrzeuge	3,659	1,378
Informationstechnologie	4,259	1,210
Ingenieurwissenschaft	3,162	1,275
Autos	4,335	1,454

Tabelle 58: Auswertung des Fachwissens bei Studie 3

Quelle: Eigene Darstellung

Im Vergleich zur Studie 2 schätzen die Probanden ihr Fachwissen im Bereich Informationstechnologie deutlich schlechter ein ($M = 4,942$, $SD = 1,200$). Auch zum Fachgebiet der Ingenieurwissenschaft schätzen sich die Probanden in dieser Studie etwas schlechter ein als die Probanden der Studie 2 ($M = 3,357$, $SD = 1,403$). Bei Kenntnissen über

autonome Fahrzeuge ($M = 3,403$, $SD = 1,635$) und Autos im Allgemeinen ($M = 4,162$, $SD = 1,678$) sehen sich die Probanden dieser Studie aber im Vorteil gegenüber den Probanden der Studie 2.

Bei der Frage zur Unfallkenntnis mit autonomen Fahrzeugen, gaben 129 Umfrageteilnehmer (69,7 %) an, kürzlich von Unfällen mit autonomen Fahrzeugen gehört zu haben. Dabei nannten 115 der Probanden explizit Tesla in der Unfallbeschreibung. Neun Probanden beschrieben Unfälle mit dem Google Car und ein Proband nannte Uber. Weiterhin wurde in zwölf Fällen kein konkreter Hersteller genannt aber teilweise der Tesla Unfall beschrieben. Die Unfallkenntnis werden wir bei der Diskussion der Ergebnisse berücksichtigen.

Als die führenden Entwickler von autonomen Fahrzeugen betrachten die Probanden neue Mobilitätsanbieter (133 Stimmen) und IT-Firmen (131 Stimmen). Im Gegensatz zur ähnlichen Frage in Studie 2 ist hier auch eine Mehrfachauswahl von Antwortoptionen möglich. Die jahrelange Erfahrung der traditionellen deutschen Autohersteller bei der Produktion von Fahrzeugen scheint für die Probanden weniger ausschlaggebend zu sein als die gut sichtbaren Fortschritte der neuen Mobilitätsanbieter und von IT-Firmen, die Prototypen autonomer Fahrzeuge auf öffentlichen Straßen testen. Gegebenenfalls bewirken auch die geringen ingenieurwissenschaftlichen Fachkenntnisse der Probanden eine Unterschätzung der Komplexität der Automobilherstellung.

Traditionelle deutsche Autohersteller erreichen mit einigem Abstand zur Spitze mit 87 Stimmen nur den dritten Platz. Ebenfalls mit einigem Abstand folgen neue Startups auf Platz vier mit 36 Stimmen. Obwohl hier keine Aussagen zu den Kompetenzen der Unternehmen getroffen werden kann, sprechen sich dennoch etwa ein Fünftel der Probanden dafür aus, dass neue Startups eine führende Rolle bei der Entwicklung autonomer Fahrzeuge haben werden. Neue Startups wurden jedoch nie als einzige Option selektiert. Dies impliziert, dass nach Einschätzung unserer Umfrageteilnehmer neue Startups nur in Kooperation mit anderen Marktteilnehmern autonome Fahrzeuge entwickeln können.

Mit 18 Stimmen trauen Zulieferern von Autoherstellern nur wenige Probanden eine Führungsrolle bei autonomen Fahrzeugen zu, auch wenn diese maßgeblich an der Entwicklung von Assistenzsystemen beteiligt sind. Zuletzt können nur noch traditionelle japanische Autohersteller eine nennenswerte Anzahl an Stimmen der Probanden für sich verbuchen. Mit 15 Stimmen werden die Chancen ähnlich zu den Zuliefererfirmen eingeschätzt. Auf den letzten drei Plätzen folgen traditionelle Hersteller aus den USA (4 Stimmen), andere traditionelle Autohersteller aus Europa (1 Stimme) und andere internationale traditionelle Autohersteller. Abbildung 33 fasst die Ergebnisse noch einmal grafisch zusammen.

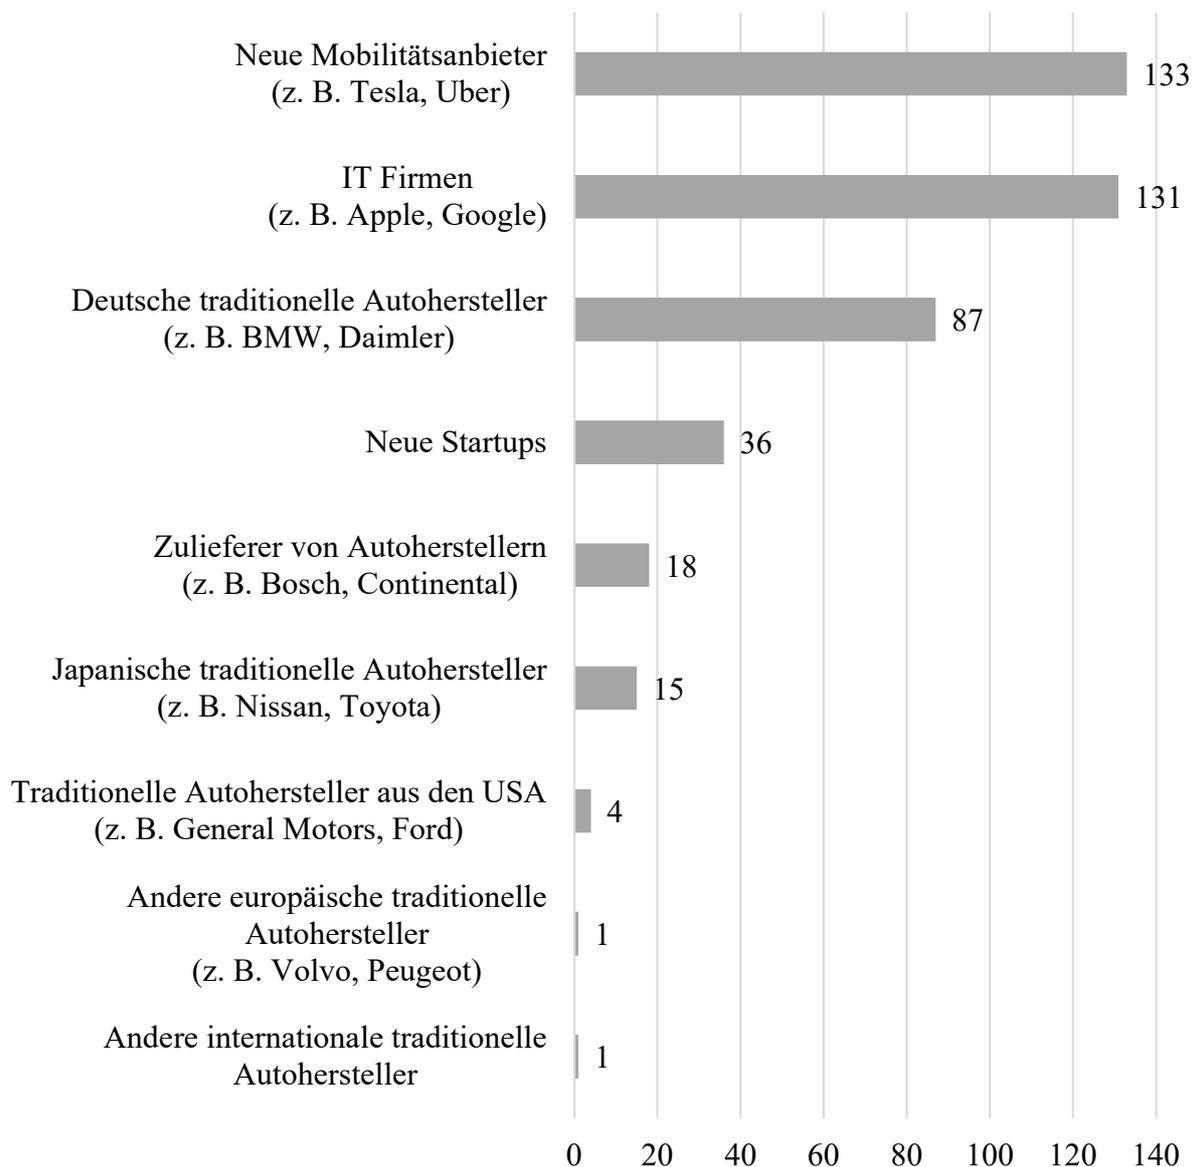


Abbildung 33: Führende Entwickler autonomer Fahrzeuge (Mehrfachauswahl möglich)

Quelle: Eigene Darstellung

7.4.3 PLS-SEM Pfadmodell

Entsprechend der Definition der Hypothesen und des Forschungsmodells wurde das in Abbildung 34 dargestellte Pfadmodell mit SmartPLS 3 (Ringle et al., 2015) erstellt. Die Indikatoren sind jeweils mit der Abkürzung des zugehörigen Konstruktes (BI) oder des Konstruktes höherer Ordnung (PB und PR) und einer laufenden Nummer bezeichnet. Wie in Abbildung 34 ersichtlich, sind alle Konstrukte formativ gemessen. Die Konstrukte höherer Ordnung PB und PR enthalten jeweils alle Indikatoren der Konstrukte niedrigerer Ordnung. Zur besseren Lesbarkeit sind die Indikatoren in Abbildung 34 ausgeblendet. Das „[+]“ Zeichen bei PB und PR deutet auf die Ausblendung hin. Die Ausführung des PLS-SEM Algorithmus ist konvergiert nach 123 von 300 Iterationen, sodass eine stabile Lösung erreicht wurde (Hair et al., 2017, S. 106f).

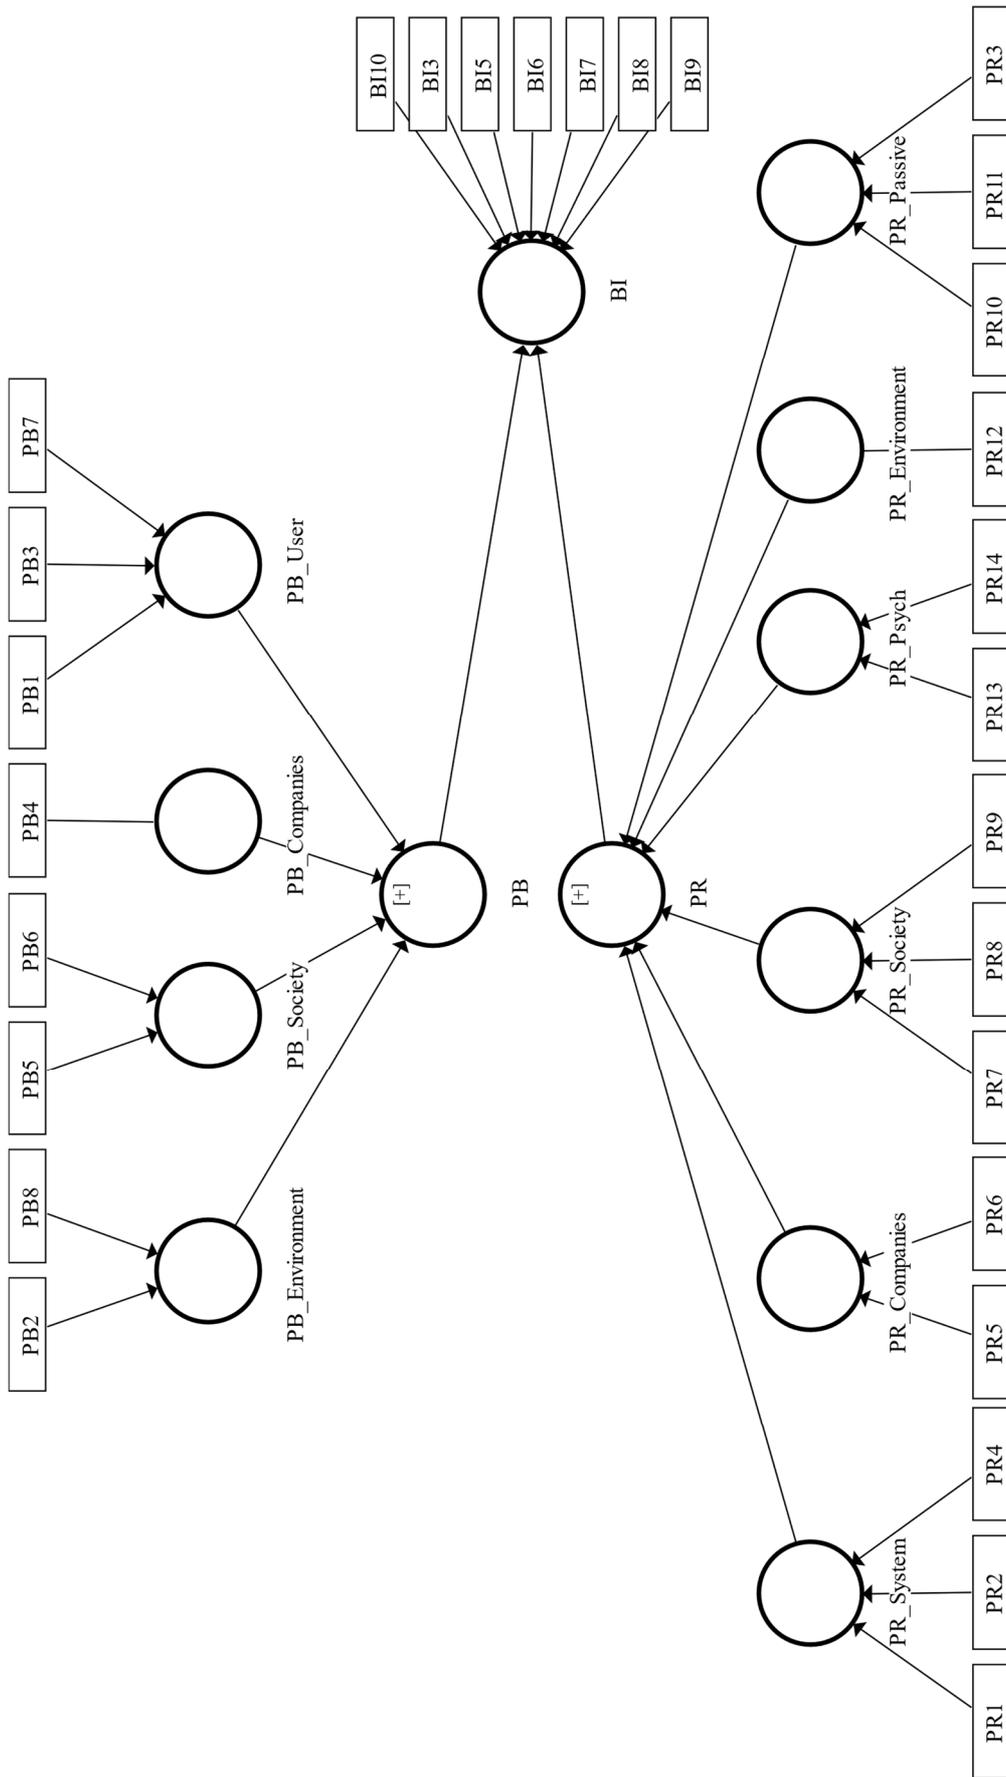


Abbildung 34: Initiales Pfadmodell der Studie 3

Quelle: Eigene Darstellung

7.4.4 Evaluation des Messmodells

In diesem Abschnitt führen wir die Evaluation des Messmodells anhand der in Abschnitt 4.2.6 beschriebenen Kriterien durch. Die Evaluation des Messmodells umfasst die Prüfung der Konvergenzvalidität, Kollinearität und Gewichte der Indikatoren.

Im ersten Schritt der Evaluation des Messmodells untersuchen wir die *Konvergenzvalidität*. Hierzu führen wir zwei Redundanzanalysen durch, bei der wir die formativ gemessenen Konstrukte mit einer reflektiven Messung der Konstrukte mit separaten Pfadmodellen vergleichen. Das Pfadmodell zur Redundanzanalyse von BI mit den Ergebnissen der PLS-SEM Modellschätzung ist in Abbildung 35 dargestellt.

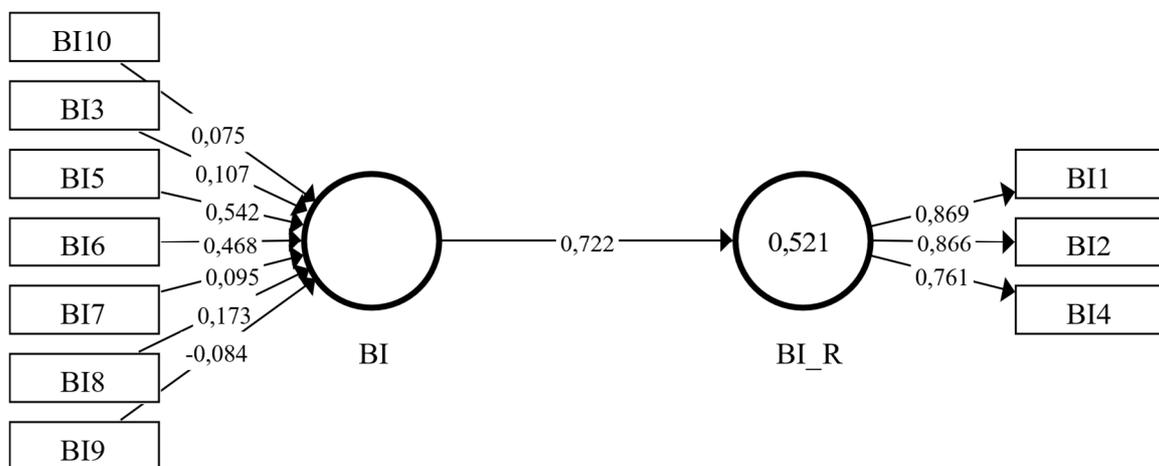


Abbildung 35: Redundanzanalyse von BI bei Studie 3

Quelle: Eigene Darstellung

Für die Redundanzanalyse von BI untersuchen wir zunächst das Messmodell der reflektiven Messung von BI in Form des Konstruktes BI_R. Sowohl das Cronbachs Alpha wie auch die Composite Reliabilität liegen mit Werten von $\alpha = 0,778$ beziehungsweise $\rho_c = 0,872$ im zufriedenstellenden Bereich. Somit ist die Interne-Konsistenz-Reliabilität gegeben. Alle Ladungen der Indikatoren von BI_R liegen im zufriedenstellenden Bereich über dem Grenzwert von 0,70, wie in Abbildung 35 ersichtlich. Folglich liegt die AVE von BI_R mit 0,695 ebenfalls über dem Grenzwert von 0,50. Daraus folgern wir die Konvergenzvalidität des Messmodells von BI_R. Eine Untersuchung der Diskriminanzvalidität ist nicht erforderlich. Somit können wir keine Probleme des Messmodells von BI_R identifizieren. Die reflektive Messung von BI_R ist also für die Redundanzanalyse verwendbar.

Wie in Abbildung 35 ersichtlich, liegt der Pfadkoeffizient zwischen BI und BI_R über dem Grenzwert von 0,70. Die formative Messung von BI erklärt mit $R^2 = 0,521$ ausreichend Varianz des Konstruktes. Somit ist die Konvergenzvalidität von BI auf Basis der Redundanzanalyse hinreichend vorhanden.

Im nächsten Schritt prüfen wir die Konvergenzvalidität von PB und PR in einem Schritt. Wir haben das Verhältnis von PB und PR mittels eines globalen Items „riskbenefit“ gemessen, dass

eine Abwägung zwischen Nutzen und Risiken abfragt, was dem Zweck der Messung von PB und PR für diese Studie entspricht. Das Pfadmodell zur Redundanzanalyse von PB und PR mit den Ergebnissen der PLS-SEM Modellschätzung ist in Abbildung 36 dargestellt.

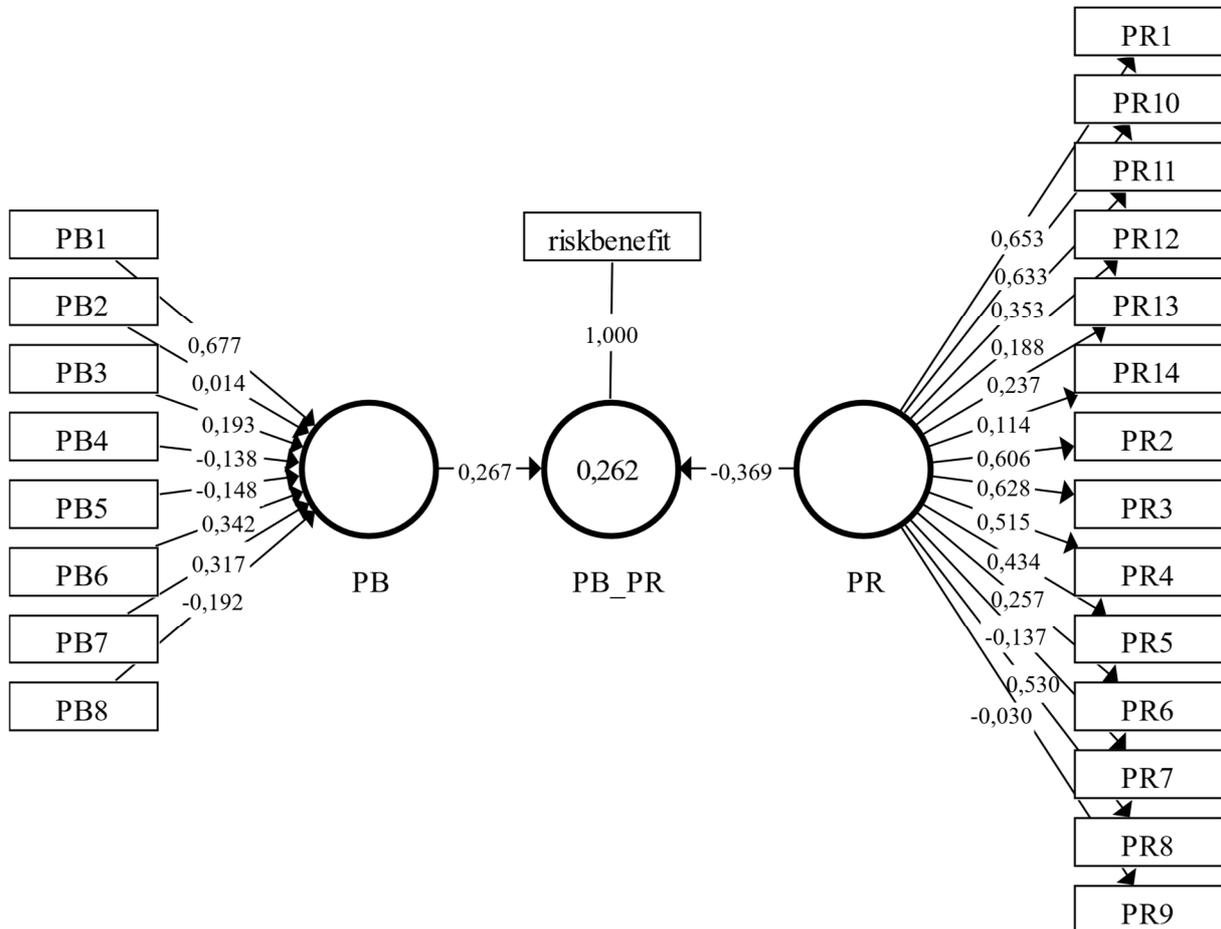


Abbildung 36: Redundanzanalyse von PB und PR bei Studie 3

Quelle: Eigene Darstellung

Wie in Abbildung 36 ersichtlich, kann mittels PB und PR nicht der benötigte Grenzwert für das R^2 von PB_PR erreicht werden. Dies kann verschiedene Ursachen haben. Das globale Item kann einerseits nicht geeignet sein, um die gesamte Varianz von PB_PR abzudecken. Andererseits können aber auch nicht alle Aspekte von PB_PR durch die Indikatoren abgedeckt werden. Aus den Pfadkoeffizienten von 0,267 (PB → PB_PR) und -0,369 (PR → PB_PR) ergibt sich ein R^2 von 0,262, was immerhin einer schwachen Prognoseleistung entspricht. Aus welchem der beiden Gründe die Konvergenzvalidität von PB und PR nicht erreicht wird, können wir anhand der erhobenen Daten nicht beantworten und werden dies bei der Diskussion der Ergebnisse entsprechend berücksichtigen.

Im zweiten Schritt der Evaluation des Messmodells prüfen wir die *Kollinearitätsstatistik* der Indikatoren, die in Tabelle 59 dargestellt ist. Alle VIF-Werte liegen klar unterhalb des Grenzwertes 5. Daraus schlussfolgern wir, dass kein kritisches Maß an Kollinearität zwischen den Indikatoren vorliegt.

Indikator	VIF	Indikator	VIF	Indikator	VIF	Indikator	VIF
BI10	1,030	PB4	1,000	PR10	1,457	PR4	1,076
BI3	1,760	PB4	1,117	PR11	1,113	PR4	1,321
BI5	1,217	PB5	1,088	PR11	1,277	PR5	1,083
BI6	1,349	PB5	1,158	PR12	1,000	PR5	1,334
BI7	1,265	PB6	1,088	PR12	1,135	PR6	1,083
BI8	1,913	PB6	1,321	PR13	1,044	PR6	1,383
BI9	1,036	PB7	1,173	PR13	1,178	PR7	1,077
PB1	1,135	PB7	1,431	PR14	1,044	PR7	1,208
PB1	1,386	PB8	1,078	PR14	1,114	PR8	1,030
PB2	1,078	PB8	1,239	PR2	1,145	PR8	1,308
PB2	1,312	PR1	1,205	PR2	1,412	PR9	1,067
PB3	1,138	PR1	1,379	PR3	1,214	PR9	1,205
PB3	1,205	PR10	1,291	PR3	1,620		

Tabelle 59: Kollinearitätsstatistik der Indikatoren bei Studie 3

Quelle: Eigene Darstellung

Für die Prüfung der *Signifikanz und Relevanz der Indikatoren* führen wir im letzten Schritt der Evaluation des Messmodells ein BCa-Bootstrapping mit 5.000 Subsamples durch. Hiermit erhalten wir die Gewichte und Ladungen der Indikatoren sowie deren p -Werte, die wir für die Evaluation benötigen. Für die Evaluation untersuchen wir nur die Konstrukte niedrigerer Ordnung von PB und PR sowie BI. Die relevanten Ergebnisse des Bootstrappings sind in Tabelle 60 dargestellt. Die relevanten problematischen Werte sind zur besseren Erkennbarkeit jeweils grau hinterlegt.

Nur Gewichte und Indikatoren von Konstrukten, die mit mehr als einem Indikator gemessen wurden, können in diesem Schritt überprüft werden. Bei Single-Item-Konstrukten sind Gewicht und Ladung jeweils als 1 definiert. Bei den Indikatoren von BI haben BI3, BI7, BI8 und BI10 jeweils nicht-signifikante Gewichte. Die Ladungen von BI3, BI7 und BI8 liegen jedoch oberhalb des Grenzwertes von 0,50. Bei BI10 ist weder die Ladung $\geq 0,50$, noch ist die Ladung signifikant unterschiedlich von 0. BI10, hat somit keinen empirischen Erklärungsgehalt für BI und sollte daher aus dem Modell entfernt werden (Hair et al., 2017, S. 130f).

	Gewichte	t-Werte	p-Werte	Ladungen	t-Werte	p-Werte
BI10 -> BI	-0,189	1,313	0,189	-0,166	1,082	0,279
BI3 -> BI	0,125	0,610	0,542	0,555	3,445	0,001
BI5 -> BI	0,350	2,040	0,041	0,591	3,838	0,000
BI6 -> BI	0,388	3,216	0,001	0,724	7,621	0,000
BI7 -> BI	0,164	0,935	0,350	0,517	3,626	0,000
BI8 -> BI	0,287	1,637	0,102	0,680	5,417	0,000
BI9 -> BI	-0,322	2,376	0,018	-0,408	2,702	0,007
PB1 -> PB_User	0,693	4,759	0,000	0,860	8,056	0,000
PB2 -> PB_Environment	0,861	4,160	0,000	0,949	4,765	0,000
PB3 -> PB_User	0,457	2,396	0,017	0,685	4,373	0,000
PB4 <- PB_Companies	1,000			1,000		
PB5 -> PB_Society	0,078	0,353	0,724	0,356	1,610	0,107
PB6 -> PB_Society	0,975	8,207	0,000	0,997	9,528	0,000
PB7 -> PB_User	0,174	0,911	0,362	0,523	3,057	0,002
PB8 -> PB_Environment	0,328	1,511	0,131	0,560	2,584	0,010
PR1 -> PR_System	0,393	1,250	0,211	0,710	2,823	0,005
PR10 -> PR_Passive	0,298	0,839	0,402	0,687	2,215	0,027
PR11 -> PR_Passive	0,340	1,058	0,290	0,568	2,012	0,044
PR12 <- PR_Environment	1,000			1,000		
PR13 -> PR_Psych	0,959	3,694	0,000	0,990	4,242	0,000
PR14 -> PR_Psych	0,147	0,408	0,683	0,344	1,010	0,313
PR2 -> PR_System	0,566	1,827	0,068	0,767	2,803	0,005
PR3 -> PR_Passive	0,687	2,002	0,045	0,877	2,798	0,005
PR4 -> PR_System	0,453	1,391	0,164	0,634	2,104	0,035
PR5 -> PR_Companies	1,010	4,202	0,000	0,999	4,438	0,000
PR6 -> PR_Companies	-0,040	0,105	0,916	0,239	0,652	0,514
PR7 -> PR_Society	0,160	0,609	0,543	0,132	0,509	0,611
PR8 -> PR_Society	0,931	3,051	0,002	0,854	2,937	0,003
PR9 -> PR_Society	0,464	1,729	0,084	0,396	1,528	0,127

Tabelle 60: Initiale Gewichte und Ladungen der Indikatoren bei Studie 3

Quelle: Eigene Darstellung

Bei den Konstrukten niedrigerer Ordnung von PB (PB_Environment, PB_Companies, PB_Society und PB_User) haben die Indikatoren PB5, PB7 und PB8 jeweils nicht-signifikante Gewichte. Die Ladungen von PB7 und PB8 liegen jedoch über dem Grenzwert von 0,50. Nur PB5 hat eine Ladung von 0,356 und liegt unter dem Grenzwert. Bei den Konstrukten niedrigerer Ordnung von PR (PR_System, PR_Companies, PR_Society, PR_Environment, PR_Passive und PR_Psych) haben die Indikatoren PR1, PR2, PR4, PR6, PR7, PR9, PR10, PR11 und PR14 nicht-signifikante Gewichte. Von diesen Indikatoren besitzen PR1, PR2, PR4, PR10 und PR11 Ladungen über 0,50. Die restlichen Indikatoren PR6, PR7, PR9 und PR14 haben sowohl

Ladungen unter dem Grenzwert von 0,50, die zudem nicht-signifikant sind. Die Indikatoren BI10, PB5, PR6, PR7, PR9 und PR14 haben somit keinen empirischen Erklärungsgehalt und sollten daher aus dem Modell entfernt werden (Hair et al., 2017, S. 130f).

Durch das Entfernen der Indikatoren bleibt die Konvergenzvalidität von BI erhalten. Der für die Redundanzanalyse relevante Pfadkoeffizient zwischen BI und BI_R sinkt nur marginal von 0,722 auf 0,720 ($R^2 = 0,518$), was ebenfalls für die Entfernung des Indikators spricht. Bei der Redundanzanalyse von PB und PR verringert sich das R^2 von 0,262 auf 0,232. Die Pfadkoeffizienten reduzieren sich beide betragsmäßig auf 0,286 bei $PB \rightarrow PB_PR$ und auf -0,324 bei $PR \rightarrow PB_PR$. Daher ist die Problematik der Konvergenzvalidität bei PB und PR weiterhin vorhanden.

Mit dem modifizierten Modell führen wir nun erneut ein BCa-Bootstrapping mit 5.000 Subsamples durch, um die Auswirkungen auf die Signifikanz und Relevanz der Indikatoren zu prüfen. Wie in Tabelle 61 ersichtlich, gibt es zwar einige nicht-signifikante Gewichte (grau hinterlegt), jedoch sind die Ladungen der nicht-signifikanten Gewichte alle über dem Grenzwert von 0,50. Somit müssen keine weiteren Indikatoren aus dem Modell entfernt werden.

Mit der Prüfung von Konvergenzvalidität, Kollinearität sowie der Signifikanz und Relevanz der Indikatoren ist die Evaluation des Messmodells abgeschlossen. Aufgrund mangelnder empirischer Relevanz zur Messung der Konstrukte PB, PR und BI wurden BI10, PB5, PR6, PR7, PR9 und PR14 entfernt. Mit dem angepassten Modell fahren wir nun mit der Evaluation des Strukturmodells fort.

	Gewichte	t-Werte	p-Werte	Ladungen	t-Werte	p-Werte
BI3 -> BI	0,117	0,621	0,535	0,578	3,867	0,000
BI5 -> BI	0,307	1,884	0,060	0,576	4,050	0,000
BI6 -> BI	0,386	3,079	0,002	0,739	7,654	0,000
BI7 -> BI	0,198	1,067	0,286	0,542	3,546	0,000
BI8 -> BI	0,318	1,845	0,065	0,692	5,821	0,000
BI9 -> BI	-0,337	2,263	0,024	-0,425	2,605	0,009
PB1 -> PB_User	0,662	4,708	0,000	0,845	7,847	0,000
PB2 -> PB_Environment	0,839	5,376	0,000	0,937	7,010	0,000
PB3 -> PB_User	0,447	2,659	0,008	0,685	5,145	0,000
PB4 <- PB_Companies	1,000			1,000		
PB6 -> PB_Society	1,000			1,000		
PB7 -> PB_User	0,235	1,331	0,183	0,571	3,581	0,000
PB8 -> PB_Environment	0,363	1,918	0,055	0,589	3,250	0,001
PR1 -> PR_System	0,346	1,179	0,239	0,676	2,805	0,005
PR10 -> PR_Passive	0,297	0,827	0,408	0,687	2,268	0,023
PR11 -> PR_Passive	0,352	1,139	0,255	0,578	2,081	0,037
PR12 <- PR_Environment	1,000			1,000		
PR13 -> PR_Psych	1,000			1,000		
PR2 -> PR_System	0,563	2,125	0,034	0,754	3,350	0,001
PR3 -> PR_Passive	0,680	2,283	0,022	0,872	3,344	0,001
PR4 -> PR_System	0,506	1,626	0,104	0,674	2,316	0,021
PR5 -> PR_Companies	1,000			1,000		
PR8 -> PR_Society	1,000			1,000		

Tabelle 61: Finale Gewichte und Ladungen der Indikatoren bei Studie 3

Quelle: Eigene Darstellung

7.4.5 Evaluation des Strukturmodells

In diesem Abschnitt führen wir die Evaluation des Strukturmodells anhand der in Abschnitt 4.2.7 beschriebenen Kriterien durch. Die Evaluation des Strukturmodells umfasst die Prüfung der Multikollinearität der Konstrukte, der Bestimmtheitsmaße R^2 der endogenen Konstrukte, der f^2 -Effektstärken der exogenen Konstrukte, der Prognoserelevanz anhand des Stone-Geisser Q^2 und der q^2 -Effektstärken der exogenen Konstrukte. Zur Berechnung der hierfür benötigten Werte verwenden wir SmartPLS 3 (Ringle et al., 2015).

Zunächst prüfen wir das Strukturmodell auf *Kollinearität*. Hierfür ermitteln wir die VIF-Werte zwischen den Treiberkonstrukten von BI sowie jeweils zwischen den Konstrukten niedrigerer Ordnung von PB und PR. Die VIF-Werte sind in Tabelle 62 dargestellt. Alle VIF-Werte liegen klar unterhalb des Grenzwertes 5. Daraus schlussfolgern wir, dass kein kritisches Maß an Kollinearität zwischen den Treiberkonstrukten vorliegt.

	BI	PB	PR
PB	1,038		
PB_Companies		1,079	
PB_Environment		1,358	
PB_Society		1,257	
PB_User		1,540	
PR	1,038		
PR_Companies			1,160
PR_Environment			1,082
PR_Passive			1,562
PR_Psych			1,077
PR_Society			1,198
PR_System			1,683

Tabelle 62: Innere VIF Werte bei Studie 3

Quelle: Eigene Darstellung

Im nächsten Schritt prüfen wir die Pfadkoeffizienten des Strukturmodells. Hierzu führen wir zunächst ein BCa-Bootstrapping mit 5.000 Subsamples durch. Dadurch erhalten wir die *t*-Werte und *p*-Werte der Pfadkoeffizienten sowie die Konfidenzintervalle für die Pfadkoeffizienten, die in Tabelle 63 dargestellt sind. Mit PB_Companies → PB, PB_Environment → PB, PB_Society → PB, PR_Companies → PR, PR_Environment → PR, PR_Passive → PR, PR_Society → PR und PR_System → PR sind acht der 12 Pfadkoeffizienten nicht signifikant. Die Pfadkoeffizienten PB → BI, PR → BI, PB_User → PB, PR_Psych → PR sind jeweils signifikant.

	Pfadkoeff.	t-Werte	p-Werte	95 % Konfidenzintervalle
PB -> BI	0,521	7,285	0,000	[0,324;0,632]
PB_Companies -> PB	-0,021	0,172	0,863	[-0,259;0,217]
PB_Environment -> PB	-0,115	0,713	0,476	[-0,363;0,211]
PB_Society -> PB	0,267	1,290	0,197	[-0,118;0,673]
PB_User -> PB	0,916	7,223	0,000	[0,663;1,082]
PR -> BI	-0,258	3,051	0,002	[-0,365;0,275]
PR_Companies -> PR	0,311	1,732	0,083	[0,017;0,713]
PR_Environment -> PR	0,204	0,861	0,389	[-0,258;0,655]
PR_Passive -> PR	0,067	0,310	0,756	[-0,262;0,533]
PR_Psych -> PR	0,510	2,491	0,013	[0,195;0,909]
PR_Society -> PR	0,066	0,263	0,792	[-0,479;0,510]
PR_System -> PR	0,475	1,832	0,067	[-0,023;0,933]

Tabelle 63: Pfadkoeffizienten des Strukturmodells bei Studie 3

Quelle: Eigene Darstellung

Im nächsten Schritt überprüfen wir die *totalen Effekte*, die sich aus den indirekten und direkten Effekten zusammensetzen. Dazu verwenden wir die Ergebnisse des bereits durchgeführten BCa-Bootstrappings mit 5.000 Subsamples, die in Tabelle 63 abgebildet sind. Alle totalen Effekte, mit Ausnahme des Effektes von PB_User auf BI, sind nicht-signifikant, wie in Tabelle 64 ersichtlich. Allerdings enthält das BCa-korrigierte 95 % Konfidenzintervall von PR_Psych die 0 nicht und kann somit ebenfalls als von 0 unterschiedlich betrachtet werden.

	Totale Effekte	t-Werte	p-Werte	95 % Konfidenzintervalle
PB_Companies -> BI	-0,011	0,174	0,862	[-0,125;0,118]
PB_Environment -> BI	-0,060	0,701	0,483	[-0,206;0,109]
PB_Society -> BI	0,139	1,259	0,208	[-0,062;0,363]
PB_User -> BI	0,478	5,413	0,000	[0,304;0,641]
PR_Companies -> BI	-0,080	1,406	0,160	[-0,206;0,020]
PR_Environment -> BI	-0,053	0,712	0,477	[-0,199;0,093]
PR_Passive -> BI	-0,017	0,250	0,802	[-0,175;0,084]
PR_Psych -> BI	-0,132	1,925	0,054	[-0,278;-0,012]
PR_Society -> BI	-0,017	0,221	0,825	[-0,158;0,145]
PR_System -> BI	-0,122	1,487	0,137	[-0,290;0,028]

Tabelle 64: Totale Effekte bei Studie 3

Quelle: Eigene Darstellung

Die Untersuchung der *indirekten Effekte* wird benötigt für die Untersuchung der Mediationen (Hair et al., 2017, S. 193ff). Die indirekten Effekte entsprechen den totalen Effekten, da keine Pfade von den Konstrukten niedrigerer Ordnung im Pfadmodell enthalten sind. Auf Basis der Ergebnisse handelt es sich bei PB_User → BI und PR_Psych → BI jeweils um komplementäre Mediationen, was wiederum auf mögliche weitere Mediationen hinweist, welche im Modell nicht berücksichtigt wurden. Die Interpretation der Höhe der direkten, indirekten und totalen Effekte befindet sich im Diskussionsteil für diese Studie. Damit ist die Untersuchung der Pfadkoeffizienten abgeschlossen.

Wir berechnen nun das *Bestimmtheitsmaß* R^2 für das endogene Konstrukt BI. Dieses hat den Wert $R^2 = 0,390$. Somit besitzt das Modell eine schwache Prognoseleistung. Im Kontext bisheriger Akzeptanzstudien liegt dieser Wert allerdings im erwarteten Bereich (Venkatesh et al., 2003, 2012). Zur besseren Vergleichbarkeit mit den weiteren Studien dieser Dissertation berechnen wir auch das adjustierte Bestimmtheitsmaß für BI. Dieses hat den Wert $R_{adj}^2=0,383$. Da es sich bei PB und PR um Konstrukte höherer Ordnung handelt, ist die Auswertung des R^2 hier nicht sinnvoll.

Im nächsten Schritt bewerten wir die *f²-Effektstärken* der Konstrukte. Da diese auf dem R^2 -Wert basieren, ist eine Auswertung der f^2 -Werte von Konstrukten niedrigerer Ordnung ebenfalls nicht sinnvoll. Für PB erhalten wir einen Wert von $f^2 = 0,429$, was einem großen Effekt entspricht. Der Effekt von PR ist mit $f^2 = 0,105$ als klein zu bewerten. Dies zeigt, dass PB einen deutlich

größeren Anteil der Varianz von BI erklärt als PR. Die Prognoseleistung des Modells basiert also zum größeren Anteil auf PB als auf PR.

Für die Analyse der *Prognoserelevanz* des Strukturmodells führen wir ein Blindfolding mit einer Auslassungsdistanz von $D = 7$ durch. Auf Basis des Blindfoldings ermitteln wir einen Wert für das Stone-Geisser Q^2 des endogenen Konstruktes BI von 0,106. Dieser Wert ist deutlich über 0, was die Prognoserelevanz des Strukturmodells bezüglich der endogenen Variablen belegt. Auch die Werte von PB ($Q^2 = 0,266$) und PR ($Q^2 = 0,145$) liegen deutlich über 0.

Zuletzt berechnen wir noch die q^2 -Effektstärken. Diese sind in Tabelle 65 dargestellt. Bei den q^2 -Effektstärken ist der Effekt von PB auf BI mit $q^2 = 0,119$ der stärkste Effekt, der allerdings auch noch als kleiner Effekt einzustufen ist. Weitere kleine Effekte ($0,15 > q^2 \geq 0,02$) gibt es zwischen PB_Environment und PB, PB_User und PB sowie zwischen PB_User und BI. Allerdings ist der Effekt zwischen PB_Environment und PB negativ, was auf Overfitting hindeutet. Die Werte der anderen q^2 -Effektstärken in Tabelle 65 deuten darauf hin, dass es ansonsten keine weiteren Effekte durch exogene Konstrukte auf die Prognoserelevanz gibt. (Hair et al., 2017, S. 106f).

	PB	PR	BI
PB			0,119
PB_Companies	0,003		-0,001
PB_Environment	-0,026		-0,003
PB_Society	0,016		0,002
PB_User	0,044		0,060
PR			0,006
PR_Companies		0,009	0,001
PR_Environment		-0,019	-0,004
PR_Passive		-0,011	-0,002
PR_Psych		0,008	0,013
PR_Society		-0,005	-0,002
PR_System		0,016	0,000

Tabelle 65: q^2 -Effektstärken bei Studie 3

Quelle: Eigene Darstellung

Somit ist die Evaluation des Strukturmodells abgeschlossen. Abbildung 37 zeigt das finale Pfadmodell der gesellschaftlichen Akzeptanz für autonome Fahrzeuge. Die Abbildung enthält die Ladungen der Indikatoren, die jeweils auf dem Pfeil zwischen dem Indikator und dem zugehörigen Konstrukt stehen. Auf den Pfeilen zwischen den Konstrukten stehen die Pfadkoeffizienten. In den Kreisen, die die endogenen Konstrukte repräsentieren, ist jeweils das Bestimmtheitsmaß R^2 eingetragen.

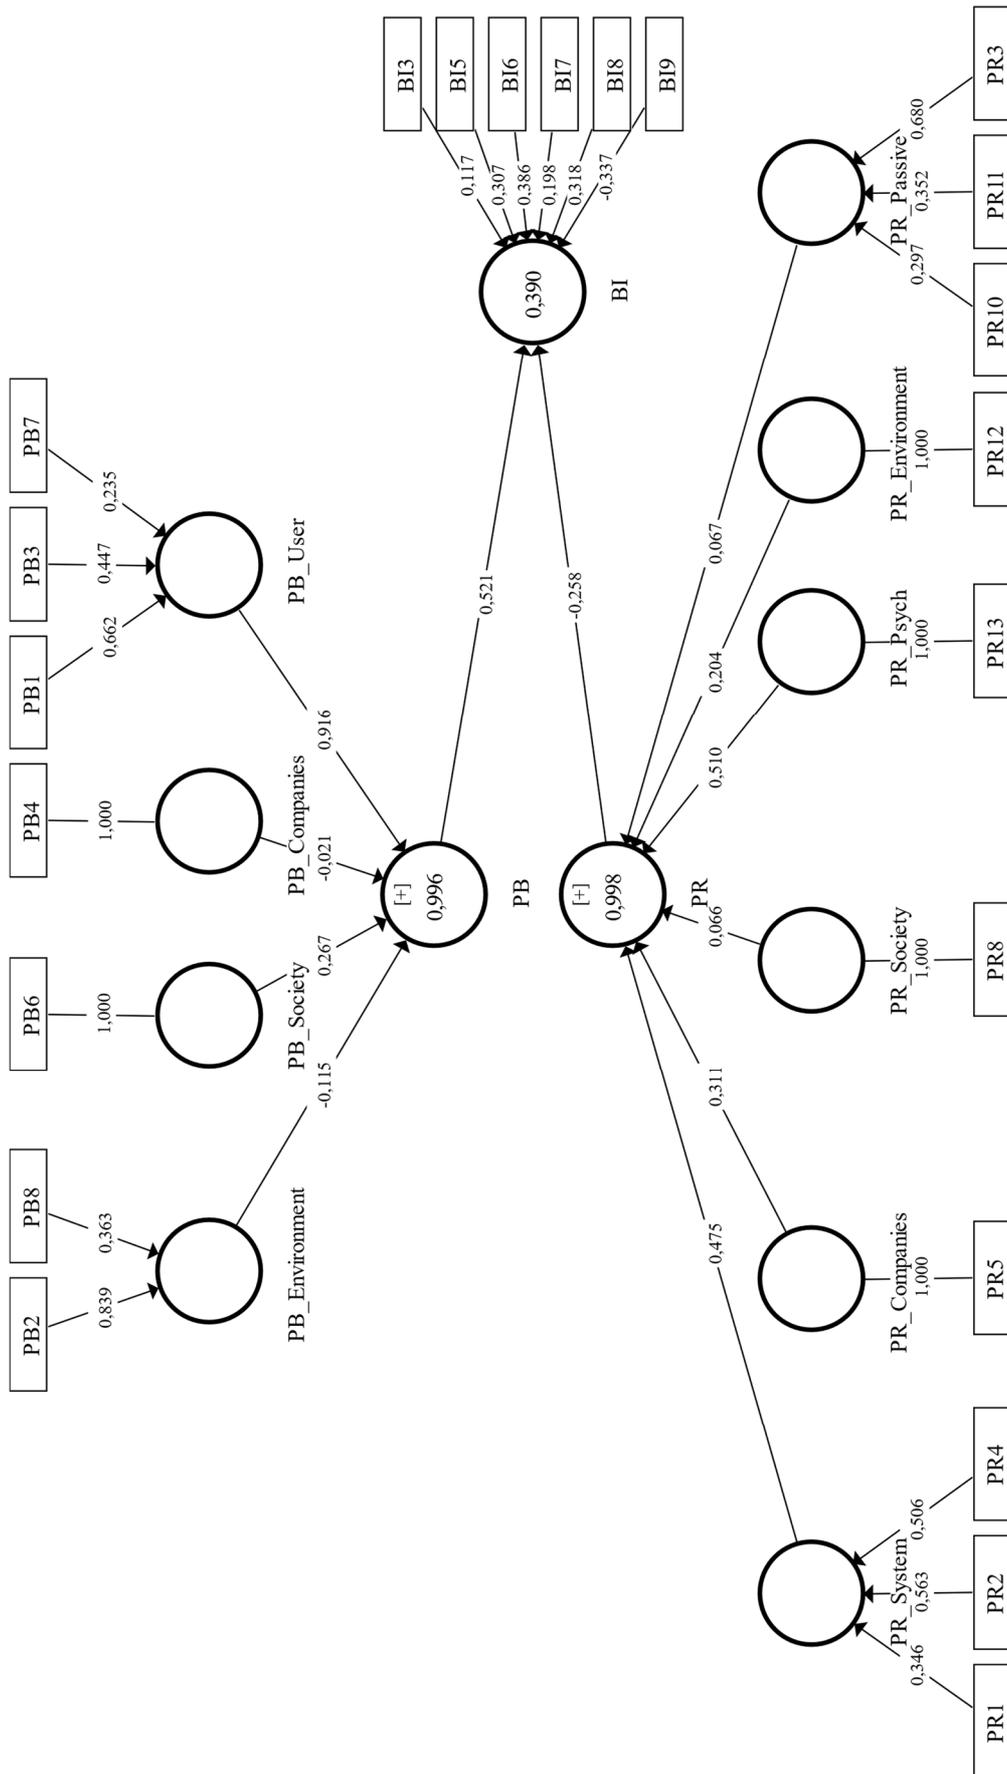


Abbildung 37: Finales Pfadmodell der Studie 3

Quelle: Eigene Darstellung

7.5 Diskussion

Die Auswertung der Ergebnisse der Studie zeigt, dass die Nutzungsintention zum Zeitpunkt der Studiendurchführung deutlich stärker vom wahrgenommenen Nutzen beeinflusst wird als von den wahrgenommenen Risiken. Dies deutet auf übersteigerte Erwartungen an diese Technologie hin. Wenn autonome Fahrzeuge die Erwartungen der Gesellschaft nicht erfüllen, kann dies zu Problemen bei der Akzeptanz führen. Am stärksten beeinflussen die Nutzungswahrnehmung die Vorteile für die Nutzer autonomer Fahrzeuge, was plausibel erscheint. Der Effekt der wahrgenommenen Risiken auf die Nutzungsintention ist etwas weniger als halb so groß wie der Effekt des wahrgenommenen Nutzens. Auch dieses Ergebnis erscheint plausibel, da Risiken in der Zukunft liegen. Mögliche Risiken werden durch den sogenannten „not in my backyard“ (NIMBY) Effekt, als weniger schlimm eingeschätzt (Kasperson et al., 1988). Den stärksten Einfluss auf die Akzeptanz haben die Risiken, die auf psychologischen Faktoren basieren, insbesondere in Form des Kontrollverlustes, der bei autonomen Fahrzeugen wahrgenommen wird.

Der R^2 -Wert für die Nutzungsintention ist mit 0,390 deutlich geringer als in den ersten beiden Studien, liegt aber dennoch im akzeptablen Bereich für Akzeptanzstudien. So erreicht beispielsweise die UTAUT Studie von Venkatesh et al. (2003) nur einen R^2 -Wert für die Nutzungsintention von 0,31. Sowohl bei der Evaluation des Messmodells als auch bei der Evaluation des Strukturmodells berechneten wir einige kritische Werte, die wir bei der Interpretation und Diskussion der Daten berücksichtigen müssen. Auf Basis der Ergebnisse der Studie ist die Untersuchung von Risiko- und Nutzenwahrnehmungen allerdings vielversprechend und scheint bisher noch nicht ausreichend erforscht zu sein. Die Nutzenwahrnehmung ist mit einem Pfadkoeffizienten von 0,521 ($p < 0,001$) ein starker Einflussfaktor für die Nutzungsintention. Auch die Effektstärke auf die Nutzungsintention von $f^2 = 0,429$ entspricht einem großen Effekt. Somit können wir H1 (PB \rightarrow BI) bestätigen.

Bei den Indikatoren für die Nutzenwahrnehmung hat sich PB5 als problematisch herausgestellt und musste entfernt werden. Wie in Abschnitt 7.3 erläutert, sind die Probanden vermutlich indifferent bezüglich der neu entstehenden und der wegfallenden Arbeitsplätze. Von den vier Teilbereichen der Nutzenwahrnehmung weist ausschließlich PB_User einen signifikanten Pfadkoeffizienten auf, der mit einem Wert von 0,916 ($p < 0,001$) auch sehr hoch ausfällt. Zweitstärkster Einflussfaktor ist der Nutzen für die Gesellschaft mit einem Pfadkoeffizienten von 0,267 ($p = 0,197$). Der Indikator mit dem höchsten Gewicht ist PB1 mit einem Wert von 0,610. Somit sehen die Probanden in der Verringerung der Verkehrsunfälle den stärksten Nutzen von autonomen Fahrzeugen.

Zweitstärkster Indikator mit einem Gewicht von 0,410 ist PB3. Der Indikator beschreibt die zusätzlichen Möglichkeiten, um die Fahrzeit besser zu nutzen, wenn man nicht selbst fahren muss. Auf der anderen Seite gibt es aber auch Indikatoren, die negative Gewichte aufweisen, wie beispielsweise PB8 mit einem Gewicht von -0,100. Für die Probanden erscheint die Vorstellung, das autonome Fahrzeug mit anderen zu teilen wohl als nicht erstrebenswert. Auch PB2 wird mit einem Gewicht von -0,062 eher negativ bewertet. Den Vorteilen für die Umwelt durch die höhere Effizienz autonomer Fahrzeuge steht das potenziell höhere

Verkehrsaufkommen gegenüber, wenn jeder sein eigenes autonomes Fahrzeug besitzt und dieses auch nicht bereit ist zu teilen. Die Erhöhung des Marktanteils und der Profite von Unternehmen, die autonome Fahrzeuge entwickeln, beeinflusst die Nutzenwahrnehmung mit einem Gewicht von $-0,021$ nur marginal, tendenziell sogar eher negativ. Dies deutet darauf hin, dass die Probanden dem kommerziellen Erfolg autonomer Fahrzeuge eher skeptisch gegenüberstehen. Alle Indikatorgewichte von PB sind in Abbildung 38 dargestellt.

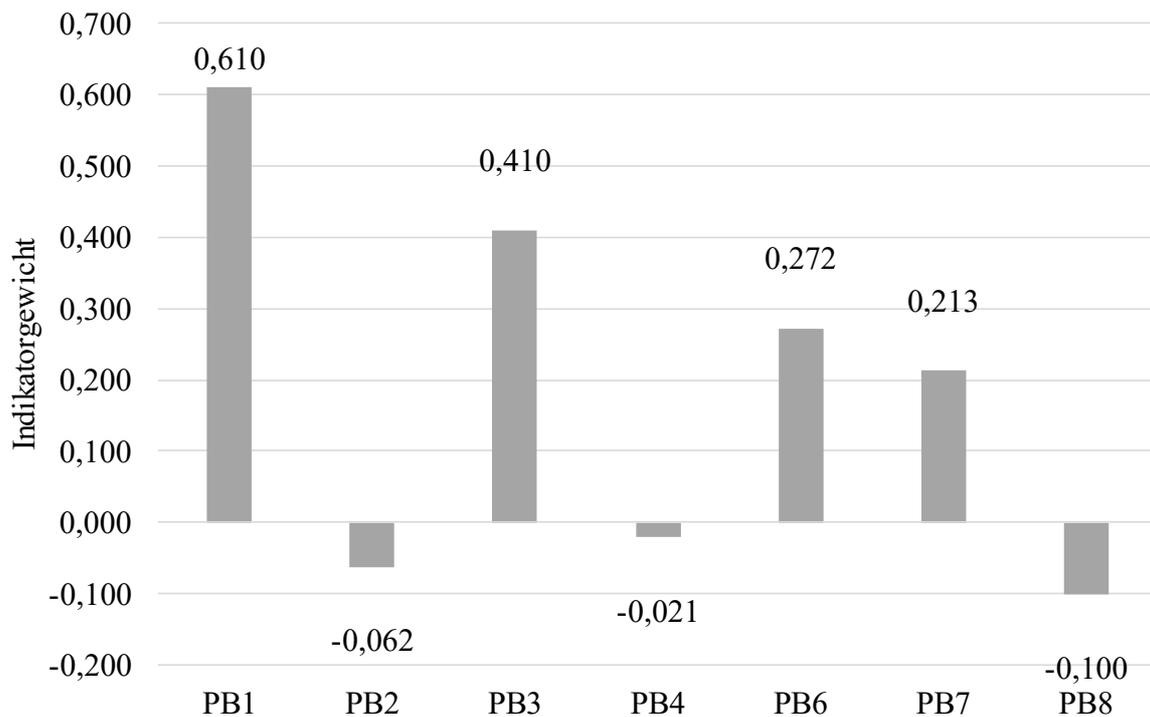


Abbildung 38: Indikatorgewichte von PB bei Studie 3

Quelle: Eigene Darstellung

Durch die Verwendung der Gewichte der Indikatoren, die durch den PLS Algorithmus berechnet werden, können wir zudem den nicht-standardisierten Score für das Konstrukt ermitteln. Dazu multiplizieren wir das Gewicht des Indikators mit dem Wert des Indikators und addieren die Werte für alle Indikatoren eines Konstruktes. Dies führen wir für jeden Probanden durch und berechnen anschließend den Mittelwert über alle Probanden. Den Mittelwert über alle Probanden transformieren wir, sodass wir einen Wert zwischen 0 und 100 erhalten. Alle Konstruktwerte sind in Abbildung 39 dargestellt. Für die Nutzenwahrnehmung beträgt der Konstruktwert im Durchschnitt über alle Probanden 69,7. Die Probanden nehmen die Vorteile autonomer Fahrzeuge also bereits als deutlich positiv wahr.

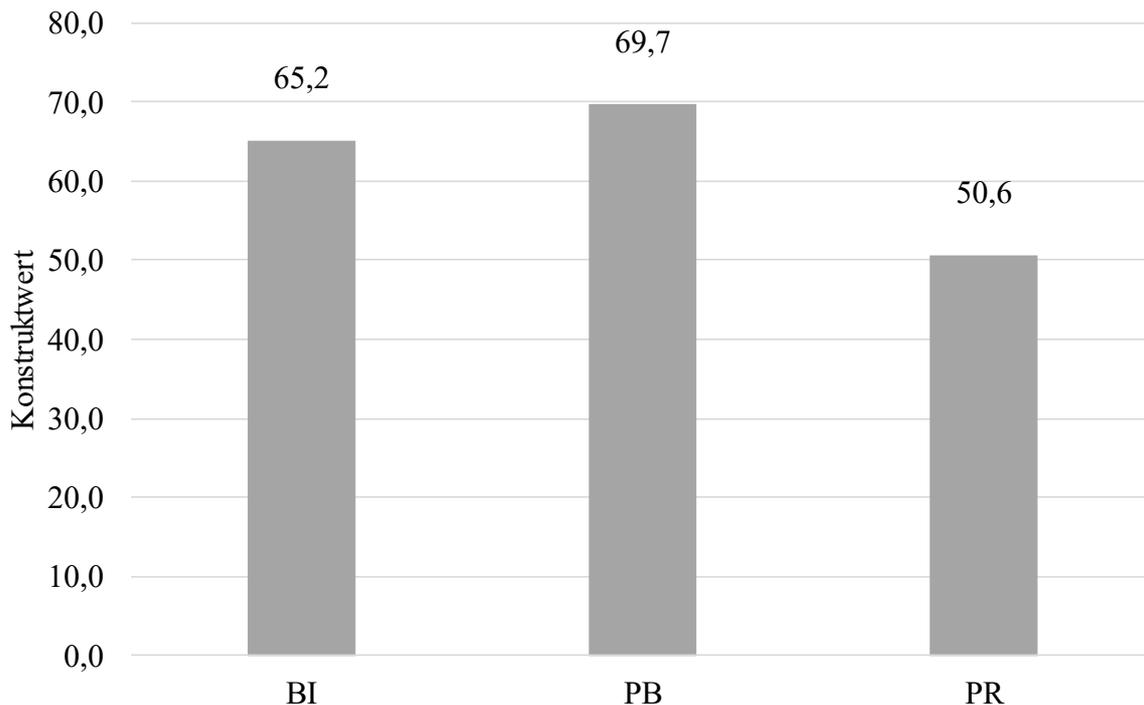


Abbildung 39: Konstruktwerte der Studie 3

Quelle: Eigene Darstellung

Mit einem Pfadkoeffizienten von $-0,258$ ($p = 0,002$) beeinflusst die Risikowahrnehmung die Nutzungsintention etwas weniger als halb so stark als die Nutzenwahrnehmung. Die Effektstärke der Risikowahrnehmung beträgt nur $f^2 = 0,105$, was nur als kleiner Effekt zu bewerten ist. Dennoch können wir H2 (PR \rightarrow BI) bestätigen.

Bei den Indikatoren für die Risikowahrnehmung haben sich PR6, PR7, PR9 und PR14 als problematisch herausgestellt und mussten entfernt werden. Käme es zu Unfällen nach dem Marktstart von autonomen Fahrzeugen, hätten die Probanden nur wenig Verständnis für Unternehmen, die diese verkaufen (PR6). Wie bei der Nutzenwahrnehmung sind die Probanden auch bei der Risikowahrnehmung indifferent bezüglich des Einflusses von autonomen Fahrzeugen auf den Arbeitsmarkt, entsprechend PR7. Auch das Risiko der Erstellung von Bewegungsprofilen beeinflusst die Risikowahrnehmung der Probanden nicht. Im Hinblick auf den teilweise sorglosen Umgang mit Ortungsdiensten auf Smartphones sowie der Erfassung der Bewegungsdaten von Fahrzeugen erscheint dieses Ergebnis für PR9 plausibel. Zusätzlich zeigt sich auch die Bereitschaft in der Gesellschaft, die eigenen Daten weiterzugeben, wenn dafür ein Mehrwert erwartet werden kann, wie dies beispielsweise auch bei sozialen Medien der Fall ist.

Überraschend hingegen ist das Ergebnis für PR14, einem Indikator, der die hedonische Motivation zur Nutzung autonomer Fahrzeuge betrifft. Die hedonische Motivation ist in Studie 2 ein signifikanter Einflussfaktor der Nutzungsintention. Wir vermuten, dass hedonische Aspekte eher als Vorteil betrachtet werden, also beispielsweise hedonische Tätigkeiten während der Fahrt ausüben zu können, anstatt sich primär auf die Fahraufgabe konzentrieren zu müssen (PB3).

Von den sechs Teilbereichen der Risikowahrnehmung weist ausschließlich PR_Psych einen signifikanten Pfadkoeffizienten von 0,510 ($p = 0,013$) auf. Zweitstärkster Einflussfaktor sind Risiken, die durch das System des autonomen Fahrzeugs ausgelöst werden (PR_System), der mit einem Pfadkoeffizienten von 0,475 allerdings knapp nicht signifikant ($p = 0,067$) ist. Der mit Abstand einflussreichste Indikator der Risikowahrnehmung mit einem Gewicht von 0,504 ist PR13, der das Risiko des Kontrollverlustes beschreibt. Wie in Abschnitt 7.3 erläutert, ist der Kontrollverlust der Dimension der „Schrecklichkeit“ eines Risikos zuzuordnen. Autonome Fahrzeuge sollten daher bei deren Markteinführung den Insassen zumindest das Gefühl vermitteln, die Kontrolle über das Fahrzeug zu besitzen. Beispielsweise könnten die ersten autonomen Fahrzeuge noch einen manuellen Fahrmodus besitzen. Fahrzeuge ohne Lenkrad und Pedale auszuliefern, wie beim Google Car, könnte die Käufer eher abschrecken. Sobald jedoch zunehmend Erfahrungen mit autonomen Fahrzeugen gemacht wurden, können zu einem späteren Zeitpunkt die Kontrollmöglichkeiten allmählich reduziert werden. Allerdings könnten Unfälle mit autonomen Fahrzeugen diesen Zeitpunkt deutlich in die Zukunft verschieben gemäß des Risiko Thermostates (Adams, 1999).

Als zweitgrößtes Risiko betrachten die Probanden mit einem Gewicht von 0,311, dass sich die hohen Investitionen von Unternehmen in die Entwicklung autonomer Fahrzeuge nicht auszahlen werden. Dies hat sich bereits bei der Nutzenwahrnehmung mit dem Indikator PB4 angedeutet. Erst danach folgt mit dem drittstärksten Gewicht von 0,266 der Indikator PR2 mit dem Risiko zusätzlicher Unfälle, die mit einem menschlichen Fahrer nicht passiert wären. In Anbetracht der hohen Gewichtung des Indikators PB1 scheinen die Probanden vordergründig einen Sicherheitsgewinn durch autonome Fahrzeuge wahrzunehmen und dadurch Unfälle in Kauf zu nehmen, die mit einem menschlichen Fahrer nicht passiert wären - vielleicht auch unter der Annahme, dass diese Unfälle deutlich seltener und weniger folgenschwer sind als heutige Verkehrsunfälle.

Am wenigsten beeinflusst wird die Risikowahrnehmung vom Indikator PR10, der das Risiko von Kettenreaktionen beschreibt, die den Betrieb autonomer Fahrzeuge gefährden könnten. Die Gewichtung des Indikators ist mit -0,013 sogar leicht negativ. Vor dem Hintergrund zahlreicher kleiner Unfälle oder anderer Vorkommnisse im Straßenverkehr, die durch menschliches Versagen ausgelöst werden, könnten autonome Fahrzeuge dieses Risiko verringern. Somit erscheint die Einschätzung der Probanden plausibel. Alle Indikatorgewichte von PR sind in Abbildung 40 dargestellt. Der Konstruktwert für die Risikowahrnehmung beträgt im Durchschnitt über alle Probanden 50,6. Die Probanden stehen den Risiken autonomer Fahrzeuge also neutral gegenüber.

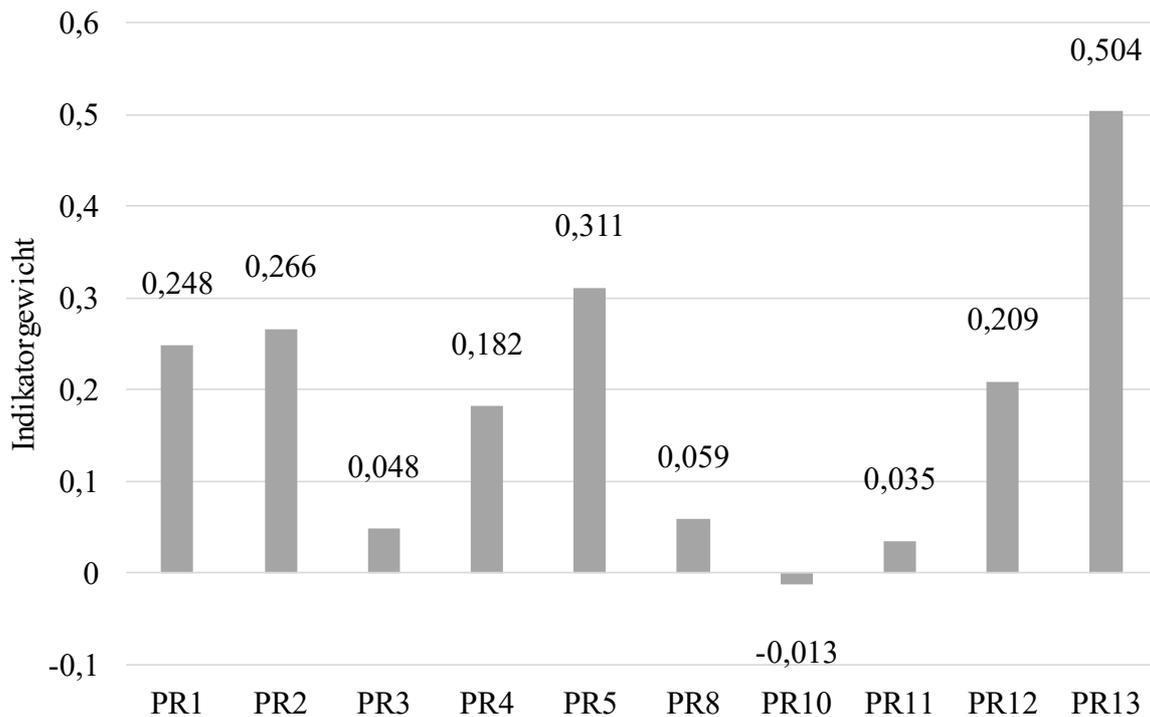


Abbildung 40: Indikatorgewichte von PR bei Studie 3

Quelle: Eigene Darstellung

Bei der Auswertung der Risiko- und Nutzenwahrnehmung fallen die zahlreichen nicht-signifikanten Werte auf. Dies deutet darauf hin, dass bei der Konzeption dieser Studie viele Faktoren berücksichtigt wurden, die zwar theoretisch fundiert sind, aber nicht den Wahrnehmungen der Probanden entsprechen. Dies zeigt sich auch in der Redundanzanalyse, bei der wir sowohl für die Risikowahrnehmung als auch für die Nutzenwahrnehmung einen Mangel an Konvergenzvalidität identifizieren konnten. Gemäß des bei der Redundanzanalyse ermittelten R^2 -Wertes für PB_PR von 0,262 haben wir nur etwa ein Viertel der Faktoren identifiziert, die für die Abwägung zwischen Risiko und Nutzen von autonomen Fahrzeugen erforderlich sind. Ein weiteres Indiz ist der niedrige R^2 -Wert der Nutzungsintention. Wir folgern daher, dass es weiteren Forschungsbedarf für die Ermittlung und Quantifizierung der relevanten Faktoren für die Risiko- und Nutzenwahrnehmung autonomer Fahrzeuge in der Bevölkerung gibt.

Bei der formativen Messung der Nutzungsintention konnten wir mit BI10 auch einen problematischen Indikator identifizieren. Für die Probanden ist es also nicht relevant, dass mit autonomen Fahrzeugen Wohnraum in Randgebieten von Städten attraktiver werden würde. Dies kann aber auch auf die Stichprobe mit eher jüngeren Teilnehmern zurückzuführen sein. Der Indikator mit der höchsten Gewichtung bei der Nutzungserwartung ist BI6 mit einem Wert von 0,385. Die Probanden würden autonome Fahrzeuge daher vorzugsweise im Stadtverkehr verwenden wollen. Den betragsmäßig zweitgrößten Einflussfaktor beschreibt der Indikator BI9. Probanden, die sich die Möglichkeit wünschen bei autonomen Fahrzeugen auch noch selbst das Steuer übernehmen zu können, haben eher eine geringere Nutzungsintention, was sich im Gewicht des Indikators von -0,337 zeigt. Bei der Nutzungsintention fällt auf, dass sich die Gewichte betragsmäßig nicht so sehr unterscheiden wie bei den anderen Konstrukten. Das

deutet darauf hin, dass möglicherweise noch ein besonders ansprechendes Anwendungsszenario autonomer Fahrzeuge fehlt, welches die Probanden begeistert. Alle Indikatorgewichte von BI sind in Abbildung 41 dargestellt.

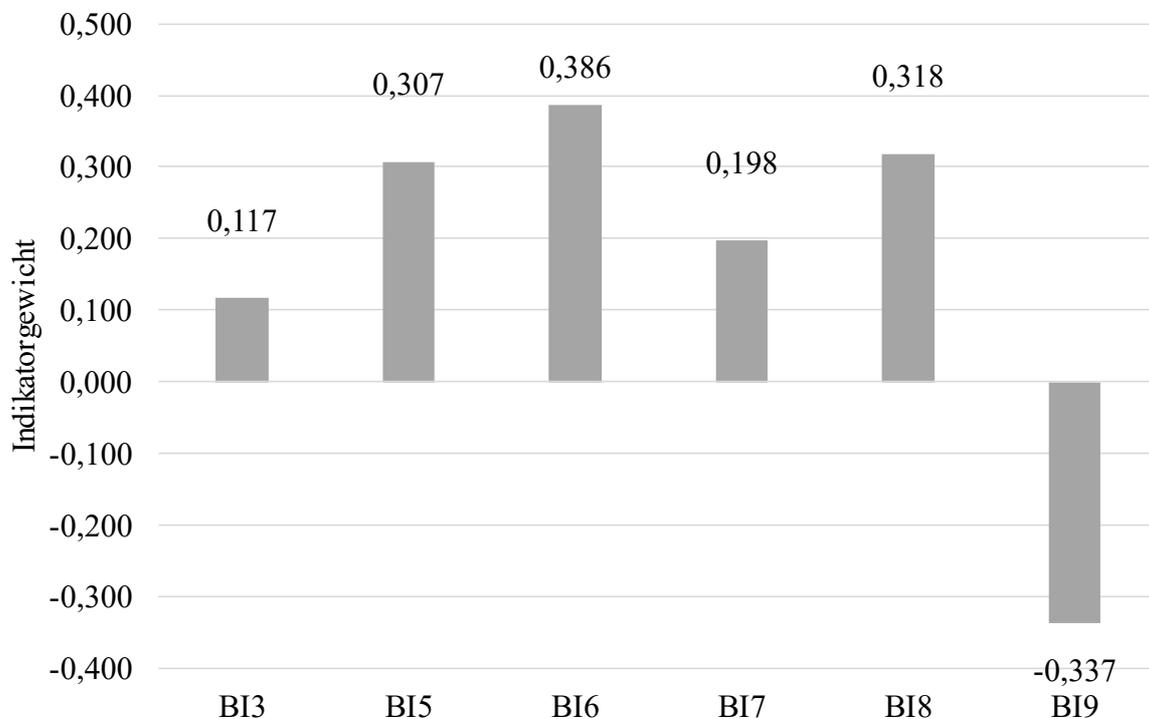


Abbildung 41: Indikatorgewichte von BI bei Studie 3

Quelle: Eigene Darstellung

Der Konstruktwert für die Nutzungsintention von 65,2 ist deutlich höher als in den ersten beiden Studien (Studie 1: 48,2; Studie 2: 50,8). Auch wenn wir die reflektive Messung BI_R der Nutzungsintention für die Modellschätzung verwenden, erhalten wir einen Konstruktwert von 61,9 für BI_R. Wie in Abschnitt 7.3 erläutert, vermuten wir einen Einfluss des tödlichen Unfalls mit einem Tesla Model S, der kurz vor Durchführung von Studie 3 bekannt wurde. Berechnen wir den Konstruktwert für BI_R nur für Probanden, denen der Unfall nicht bekannt war, so erhalten wir einen Wert von 53,9. Dieser Wert entspricht ungefähr dem Anstieg der Nutzungsintention von Studie 1 (BI = 48,2) zur Studie 2 (BI = 50,8). Berechnen wir den Konstruktwert nur für Probanden, denen der Unfall bekannt war, so erhalten wir einen Konstruktwert von 65,4. Ein Mann-Whitney U Test zeigt zudem, dass der Gruppenunterschied signifikant ist ($p = 0,002$). Somit können wir den Anstieg der Nutzungsintention auf zwei Effekte zurückführen: einen zeitlichen Effekt und die Unfallkenntnis. Interessant ist auch, dass sich die Unfallkenntnis positiv auf die Nutzungsintention auswirkt. Als Ursache vermuten wir ein gesteigertes Interesse an autonomen Fahrzeugen und deren Potentiale, ausgelöst durch die mediale Berichterstattung.

Risiko- und Nutzenwahrnehmung verhalten sich konsistent zur Veränderung der Nutzungsintention durch den Unfall. So ist der Konstruktwert für die Risikowahrnehmung mit

48,1 signifikant geringer ($p < 0,001$) bei den Probanden mit Unfallkenntnis als bei den Probanden ohne Unfallkenntnis mit einem Wert von 56,9. Der Konstruktwert für die Nutzenwahrnehmung beträgt bei Probanden mit Unfallkenntnis 71,8 und bei Probanden ohne Unfallkenntnis 64,9 ($p = 0,002$). Tabelle 66 fasst die Ergebnisse des Vergleichs der Konstruktwerte von Probanden mit und ohne Unfallkenntnis zusammen. Aufgrund dieser Ergebnisse sollten sich zukünftige Forschungsvorhaben mit der Identifikation relevanter Ereignisse beschäftigen und den Effekt von Medien auf Risiko- und Nutzenwahrnehmung sowie die Nutzungsintention untersuchen.

	Mit Unfallkenntnis	Ohne Unfallkenntnis	<i>p</i>-Wert
Anzahl der Probanden	129	56	
Konstruktwert von PB	71,8	64,9	0,002
Konstruktwert von PR	48,1	56,9	< 0,001
Konstruktwert von BI	66,2	62,0	0,100
Konstruktwert von BI_R	65,4	53,9	0,002

Tabelle 66: Vergleich der Konstruktwerte mit und ohne Unfallkenntnis bei Studie 3

Quelle: Eigene Darstellung

Anhand der vorliegenden Daten können wir beide Hypothesen der Studie bestätigen. Sowohl die Risiko- als auch die Nutzenwahrnehmung beeinflussen die verhaltensbasierte Nutzungsintention signifikant, wie in Abbildung 42 ersichtlich. Der Einfluss der Nutzenwahrnehmung auf die Akzeptanz ist zum Zeitpunkt der Studiendurchführung bei autonomen Fahrzeugen allerdings deutlich größer als der Einfluss der Risikowahrnehmung. Dies ist ein Hinweis auf hohe Erwartungen an autonome Fahrzeuge, die bei der Markteinführung zum Problem werden könnten. Wir konnten somit zeigen, dass das Modell der gesellschaftlichen Akzeptanz mit Einschränkungen bereits in einem frühen Stadium der Entwicklung einer neuen Technologie angewendet werden kann. Insbesondere die Konvergenzvalidität konnte nicht nachgewiesen werden. Dennoch konnten wir plausible Erkenntnisse bezüglich der Risiken und dem Nutzen autonomer Fahrzeuge erhalten. Dies kann auch damit zusammenhängen, dass die Probanden zumindest ein intuitives Verständnis des Untersuchungsgegenstandes hatten. Unbekanntere Technologien könnten von einer zufälligen Stichprobe aus der Bevölkerung womöglich nicht so gut eingeschätzt werden.

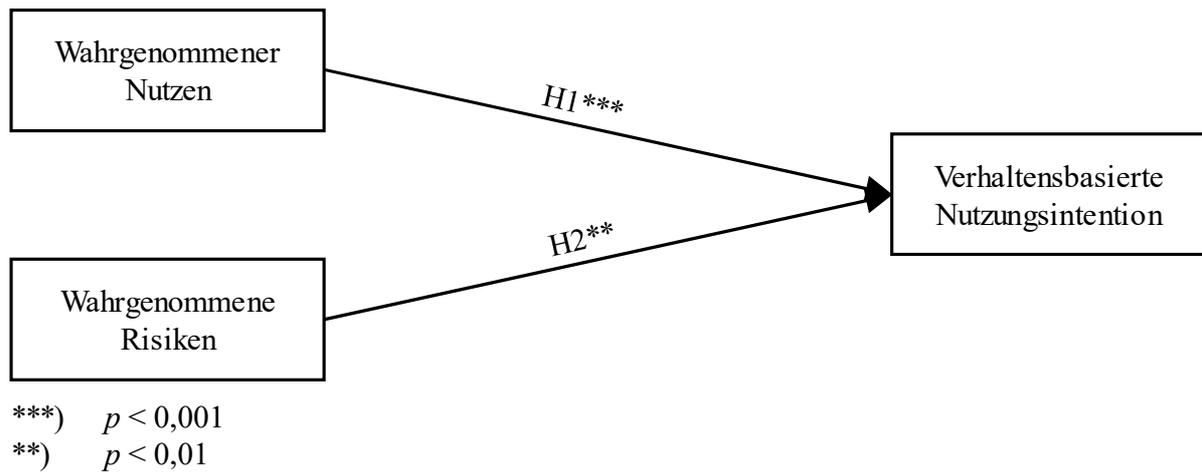


Abbildung 42: Ergebnisse zum Forschungsmodell der Studie 3

Quelle: Eigene Darstellung

7.6 Fazit

Mit der in diesem Kapitel vorgestellten Studie haben wir die Prognose der Akzeptanz von Innovationen am Beispiel autonomer Fahrzeuge auf Basis der Risiko- und Nutzenwahrnehmung untersucht. Durch die Befragung von 196 Teilnehmern, die wir 163 Tage nach Studie 2 durchgeführt haben, konnten wir detaillierte Erkenntnisse zu Risiko- und Nutzenwahrnehmung sowie zur Akzeptanz autonomer Fahrzeuge erhalten. Die Studie zeigt aber auch auf, dass Risiken und Nutzen autonomer Fahrzeuge noch nicht vollständig bekannt sind. So konnten wir durch eine Redundanzanalyse zeigen, dass wir nur etwa ein Viertel der Faktoren zur Erklärung der Risiko- und Nutzenwahrnehmung identifiziert haben, obwohl wir diese aus aktuellen Forschungsergebnissen hergeleitet haben. Zusätzlich ist auch der R^2 -Wert für die Nutzungsintention mit 0,390 deutlich geringer als in den Studien 1 ($R^2 = 0,604$) und 2 ($R^2 = 0,634$) dieser Dissertation.

Der Mehrwert dieser Studie ergibt sich aus der Identifikation der Risiken und des Nutzens autonomer Fahrzeuge sowie der Ermittlung des Einflusses auf die Nutzungsintention anhand empirischer Daten. Da die Anwendung des Modells der gesellschaftlichen Akzeptanz bereits im Vorfeld umfangreiche Forschungsvorhaben zur Identifikation der Risiken und des Nutzens einer Innovation bedarf, erscheint dieser Ansatz im Hinblick der geringen Prognoserelevanz des Modells ($R^2 = 0,390$) nicht praktikabel. Dennoch konnten wir mit Studie 3 zusätzliche Einblicke in die Prognose der Akzeptanz erhalten.

Wir konnten zeigen, dass die Akzeptanz im zeitlichen Verlauf mit dem Näherrücken der Marktreife autonomer Fahrzeuge und damit einhergehender zunehmender Berichterstattung graduell zunimmt. Viel stärker können allerdings Ereignisse die Risiko- und Nutzenwahrnehmung sowie die Akzeptanz beeinflussen, wie wir anhand des Unfalls mit einem Tesla Model S mit aktivem Autopiloten nachweisen konnten, der sich kurz vor der Studiendurchführung ereignete. Zukünftige Forschung sollte sich daher mit der Entwicklung von Methoden beschäftigen, mit denen solche Ereignisse erkannt und eingeschätzt werden können, um gegebenenfalls schnell und gezielt darauf reagieren zu können.

8 Studie 4: Akzeptanzprognose mit sozialen Medien

In einem frühen Stadium der Entwicklung neuer Technologien besteht oft eine große Unsicherheit über ihren zukünftigen Erfolg (Heidenreich & Kraemer, 2016). Unternehmen können diese Unsicherheit verringern, indem sie Kunden früh in den Innovationsprozess integrieren (Rese, Sänn & Homfeldt, 2015). In Studie 3 konnten wir zeigen, dass Risiko- und Nutzenwahrnehmungen zentrale Determinanten für die Akzeptanz neuer Technologien sind. Allerdings sind Risiko und Nutzen autonomer Fahrzeuge noch nicht vollständig bekannt, wie ebenfalls in Studie 3 gezeigt. In diesem Kapitel identifizieren und quantifizieren wir Risiko und Nutzen autonomer Fahrzeuge. Als Datenquelle verwenden wir die Social Media Plattform Twitter, von der wir automatisiert Daten zu relevanten Suchbegriffen abrufen und speichern. Die so erhobenen Daten klassifizieren wir mit maschinellen Lernverfahren und werten sie mit statistischen Methoden aus. Die Datenerhebung beginnt 128 Tage vor Studie 1 am 03.03.2015 und endet 85 Tage nach Studie 3 am 21.10.2016.

Im folgenden Abschnitt 8.1 beschreiben wir Motivation und Ziele dieser Studie. In Abschnitt 8.2 stellen wir ein neues Verfahren zur Akzeptanzprognose mit sozialen Medien vor, das wir für diese Studie erstellt haben. Im darauffolgenden Abschnitt 8.3 präsentieren wir die Ergebnisse des neuen Verfahrens. In Abschnitt 8.4 diskutieren wir das neue Verfahren und die Ergebnisse dieser Studie. Wir beenden dieses Kapitel mit einem Fazit in Abschnitt 8.5.

Die Ergebnisse in diesem Kapitel wurden bereits vorab veröffentlicht von Kohl, Knigge, Baader, Böhm & Krcmar (2018) und Kohl, Mostafa, Böhm & Krcmar (2017).

8.1 Motivation

Autonome Fahrzeuge sind in den letzten Jahren zu einem vieldiskutierten Thema geworden. Ethische, regulatorische und Haftungsaspekte (Gogoll & Müller, 2017; Zmud & Sener, 2017), die sich damit beschäftigen, wer fährt und wer die Verantwortung für Unfälle übernimmt, werden kontrovers diskutiert. Dennoch scheinen die Firmen, die an autonomen Fahrzeugen arbeiten, davon überzeugt zu sein, dass autonome Fahrzeuge die Zukunft der Mobilität sein werden. Darauf deuten beträchtliche Investitionen in diese Technologie hin. Dabei wird oft unterschätzt, dass sich die Bedenken und Einschätzungen der Öffentlichkeit bei neuen Technologien häufig von den Bewertungen der Experten unterscheiden (Blake, 1995; Piao et al., 2016).

Mit den ersten Fahrerassistenzsystemen hat Conover (1994) bereits diskutiert, dass das Verhältnis des wahrgenommenen Risikos im Vergleich zum Nutzen entscheidungsrelevant sein könnte. Untersuchungen zu anderen Technologien zeigen auch, dass Risiko- und Nutzenwahrnehmungen zentrale Determinanten ihrer öffentlichen Akzeptanz sind (Butakov & Ioannou, 2015; Siegrist, 2000). Die öffentliche Wahrnehmung von Risiko und Nutzen bestimmt daher, ob autonome Fahrzeuge eingesetzt werden und ist damit ein entscheidender Faktor, der insbesondere bei der initialen Akzeptanz neuer Technologien wie autonomer Fahrzeuge berücksichtigt werden muss (Bansal & Kockelman, 2018; Butakov & Ioannou, 2015; Pendleton et al., 2015).

Nur wenige Studien befassen sich mit der öffentlichen Wahrnehmung und der Akzeptanz von autonomen Fahrzeugen, insbesondere über Ländergrenzen hinweg und im zeitlichen Verlauf. Wir begegnen diesem Mangel an empirischen Studien, indem wir einen neuen Ansatz zur Messung und Reaktion auf öffentliche Wahrnehmungen aufzeigen, der die Stimme des Kunden oder auch „voice of the customer“ (VOC) berücksichtigt. Dieser Ansatz gibt uns die Möglichkeit, die riesigen Mengen an öffentlich zugänglichen Daten in sozialen Medien zu nutzen, um die Akzeptanz von Innovationen zu prognostizieren. Folgende forschungsleitende Fragestellungen werden durch Studie 4 dieser Dissertation adressiert:

FF3.1: Wie können wir die öffentliche Wahrnehmung von autonomen Fahrzeugen messen, um deren Akzeptanz zu antizipieren?

FF3.2: Wie beeinflussen Ereignisse die öffentliche Wahrnehmung von autonomen Fahrzeugen?

Die übliche Methode zur Messung der Akzeptanz ist die Befragung von Probanden bezüglich deren Einstellung zum Akzeptanzobjekt mittels Fragebogen. In den Studien 1-3 dieser Dissertation konnten wir damit bereits wertvolle Erkenntnisse zur Prognose der Akzeptanz von Innovationen erhalten. Unsere Studien zeigten aber auch die Limitationen dieses Vorgehens auf. Beispielsweise konnten wir in der Studie 3 dieser Dissertation nur knapp ein Viertel der relevanten Risiko- und Nutzenaspekte für die Probanden auf Basis umfangreicher Vorarbeiten identifizieren. Aufgrund dieses Ergebnisses leiten einen weiteren Bedarf an explorativen und qualitativen Studien ab, die auch generell in einem frühen Stadium einer neuen Technologie empfohlen werden (König & Neumayr, 2017).

Durch die Entwicklung einer neuen Methode zur Akzeptanzprognose mit sozialen Medien vermeiden wir bekannte Probleme bei der Untersuchung sozialwissenschaftlicher Phänomene mittels Fragebögen, wie beispielsweise die Methodenverzerrung und die Einheitsmethodenvarianz (Sharma et al., 2009). Die Methodenverzerrung bezeichnet die Beeinflussung der Antworten von Probanden durch das Messinstrument, also beispielsweise einem Fragebogen. Da bei der Akzeptanzforschung häufig Fragebögen als Messinstrument verwendet werden, kann zusätzlich die Einheitsmethodenvarianz die Ergebnisse verfälschen. Da in den Studien 1-3 dieser Dissertation bereits Fragebögen zur Datenerhebung verwendet wurden, kann durch die Anwendung des in diesem Kapitel entwickelten Verfahrens der Ergebnisverzerrung durch Einheitsmethodenvarianz entgegengewirkt werden.

Um die FF3.1 und FF3.2 zu beantworten, haben wir ein Verfahren für die automatische Identifikation und Analyse von Beiträgen zu Risiken und Nutzen von Technologien erstellt, der auf kurzen Textnachrichten der Social Media Plattform Twitter basiert. Diese kurzen Textnachrichten werden auch als *Tweets* bezeichnet und werden mit dem neuen Verfahren automatisiert mittels Text-Mining analysiert. Text-Mining ermöglicht allgemein die Extraktion von Wissen aus Textdokumenten (Tan 1999), wozu auch insbesondere die Sentimentalanalyse gehört (Hopkins & King, 2010). Wir nutzen die Social-Media-Plattform Twitter, um einen konstanten Meinungsfluss über autonome Fahrzeuge zu erhalten. Basierend auf den identifizierten Risiken und Nutzen autonomer Fahrzeuge können wir Ereignisse und Themen,

die für die Akzeptanz zukünftiger Innovationen entscheidend sind, detektieren und unterstützen damit das Management neuer Technologien.

Die Stimme zukünftiger Kunden bietet interessante Forschungsmöglichkeiten für neue Technologien (Griffin & Hauser, 1993). Die Risiko- und Nutzenwahrnehmung zukünftiger Kunden dürfte eine zentrale Rolle bei der Akzeptanz von autonomen Fahrzeugen spielen (Ward, Raue, Lee, D'Ambrosio & Coughlin, 2017). Schon vor der öffentlichen Verfügbarkeit neuer Technologien könnten die Risiko- und Nutzenwahrnehmungen überwacht werden, um Probleme mit einer neuen Technologie oder ihrer öffentlichen Wahrnehmung zu identifizieren. Frühere Forschungsarbeiten haben bereits klassische qualitative explorative Analysen von Textdaten über die Risiko- und Nutzenwahrnehmung von autonomen Fahrzeugen durchgeführt und gezeigt, dass dies ein vielversprechender Ansatz ist (Bazilinsky, Kyriakidis & de Winter, 2015; Fraedrich & Lenz, 2014). Bisher war hierfür jedoch eine manuelle Kodierung aller Daten erforderlich, was einerseits umständlich und zeitaufwändig und andererseits fehleranfällig ist (Bazilinsky et al., 2015). Darüber hinaus schlagen frühere Studien vor, die Wahrnehmungen im Laufe der Zeit zu untersuchen, da sie sich wahrscheinlich ändern werden, wenn die Endanwender mit autonomen Fahrzeugen besser vertraut sind (Haboucha et al., 2017; Kauer et al., 2012; König & Neumayr, 2017). Es wird außerdem vorgeschlagen, die Auswirkungen kritischer Vorfälle mit autonomen Fahrzeugen auf die öffentliche Wahrnehmung zu untersuchen (Woisetschläger, 2016). Basierend auf früheren Forschungsvorhaben zu autonomen Fahrzeugen formulieren wir drei Propositionen, mit denen wir FF3.1 und FF3.2 adressieren:

P1: Algorithmen des maschinellen Lernens können verwendet werden, um die Risiko- und Nutzenwahrnehmung der Öffentlichkeit bezüglich autonomer Fahrzeuge auf Twitter zu analysieren.

P2a: Nachrichten über die Vorteile von autonomen Fahrzeugen (z. B. mehr Sicherheit, geringere Mobilitätskosten) erhöhen die Nutzenwahrnehmung von autonomen Fahrzeugen.

P2b: Nachrichten über die Risiken von autonomen Fahrzeugen (z. B. Unfälle, Hackerangriffe) erhöhen die Risikowahrnehmung von autonomen Fahrzeugen.

8.2 Material und Methoden

Das in diesem Abschnitt vorgestellte Verfahren ist theoretisch in der quantitativen Inhaltsanalyse (Neuendorf, 2016) begründet, die es ermöglicht, quantitative Datenanalysen auf Basis qualitativer Daten durchzuführen und bisherige qualitative Ansätze zu erweitern (Bazilinsky et al., 2015; Fraedrich & Lenz, 2014). Während die Inhaltsanalyse bisher hauptsächlich zur Analyse unstrukturierter Daten aus sozialen Medien verwendet wurde (McCorkindale, 2010), automatisieren wir den Großteil des Kodierungsprozesses durch ein maschinelles Lernverfahren. Der Ansatz ähnelt der Sentimentanalyse, die häufig im Bereich der Marketingforschung eingesetzt wird (Okazaki, Diaz-Martin, Rozano & Menendez-Benito, 2014). Das dabei verwendete maschinelle Lernverfahren hat den Vorteil, dass nur ein kleiner Teil der Daten manuell kodiert werden muss. Die manuell kodierten Daten werden in Trainings-

und Testdaten aufgeteilt und für die Erstellung eines Modells zur automatischen Klassifizierung der verbleibenden unklassifizierten Daten verwendet.

Wir folgen dem von Okazaki et al. (2014) vorgeschlagenen Analyseprozess zur Sentimentanalyse. Er besteht aus Datenextraktion, Datenaufbereitung, Modellgenerierung, Modellvalidierung und Modellanwendung wie in Abbildung 43 dargestellt. Unser Ansatz zur Analyse der Risiko- und Nutzenwahrnehmung ähnelt der Sentimentanalyse, was es uns ermöglicht, einen bewährten Prozess zur Analyse der Daten zu verwenden. Leichte Variationen im Prozess der Sentimentanalyse, wie beispielsweise die Kombination der Schritte Modellgenerierung und Validierung (z. B. Feldman, 2013), sollten für die Ergebnisse unerheblich sein. Daher sehen wir keine Einschränkung durch die Wahl eines bestimmten Analyseprozesses insofern dieser auf einem etablierten, systematischen Vorgehen basiert.

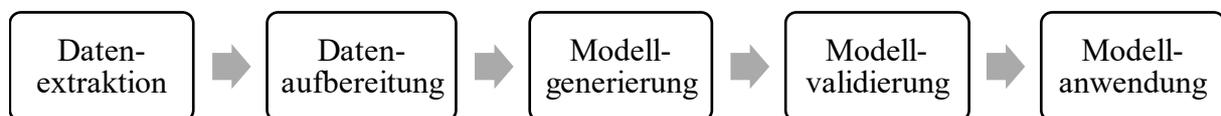


Abbildung 43: Prozess der Datenanalyse

Quelle: Eigene Darstellung in Anlehnung an Okazaki et al. (2014, S. 475)

Wir haben den Prozess von Okazaki et al. (2014) wie folgt implementiert: Zunächst extrahieren wir Tweets über die Twitter Search API (Datenextraktion) in Abschnitt 8.2.1. Um die Datenqualität zu verbessern, die Dimensionalität zu reduzieren und eine Fehlklassifizierung zu vermeiden, verarbeiten wir die Daten vor (Datenaufbereitung), wie in Abschnitt 8.2.2 beschrieben. Mit den aufbereiteten Daten trainieren wir ein Modell mittels eines maschinellen Lernverfahrens (Modellgenerierung) und validieren dieses mittels Kreuzvalidierung (Modellvalidierung). Diese Schritte erläutern wir in Abschnitt 8.2.3. Anschließend wenden wir das trainierte Modell an, um die Tweets zu klassifizieren (Modellanwendung) und erhalten so die Ergebnisse in Abschnitt 8.3.

8.2.1 Datenextraktion

Unser Datensatz umfasst englischsprachige Tweets über autonome Fahrzeuge, die über die Twitter Search API (Twitter, 2016a) abgerufen wurden. Darüber hinaus haben wir eine Java-Anwendung entwickelt, da die Twitter Search API nur den Abruf von Tweets erlaubt, die nicht älter als 1 Woche sind (Twitter, 2016b). Eine aussagekräftige Längsschnittanalyse erfordert jedoch die Möglichkeit, Tweets für längere Zeiträume zu sammeln, indem die Tweets täglich gesammelt und in einer Datenbank gespeichert werden. Als Datenbank wird eine MongoDB NoSQL-Datenbank verwendet, um die kompletten Tweets zu speichern, die von der Twitter Search API zurückgegeben wurden, einschließlich ihres Erstellungsdatums, des Benutzernamens des Tweet-Erstellers, des Nachrichtentextes und einer eindeutigen Kennung des Tweets. Die Tweets werden dann in eine In-Memory-Datenbank übertragen, um sie effizient zu verarbeiten. Wir haben eine SAP HANA-Datenbank SPS10 mit 1 TB RAM und 32 CPU-Kernen verwendet. Diese wurde uns durch das Future SOC Lab der

Hasso-Plattner-Institut für Softwaresystemtechnik GmbH kostenlos zur Verfügung gestellt (Knigge, Kohl, Baader, Kienegger & Krcmar, 2016a, 2016b). SAP HANA bietet eine R-Integration, die es uns ermöglicht, die Daten über externe R-Bibliotheken zu verarbeiten. Der R-Server wurde auf einer virtuellen Maschine installiert, die mit der SAP HANA-Datenbank verbunden ist. Die Datenerhebung für diese Analyse haben wir am 03.03.2015 begonnen, die letzten Tweets wurden am 21.10.2016 gesammelt. Wir haben die folgenden Suchanfragen (SQ für „Search Query“) in unseren Twitter Search API-Anfragen verwendet:

- SQ1: self driving OR driverless OR autonomous OR automated
- SQ2: tesla OR google OR apple OR icar OR ford OR opel OR gm OR general motors
- SQ3: volkswagen OR vw OR daimler OR mercedes OR benz OR bmw OR audi OR porsche

Die Suchanfragen wurden vor der Datenerfassung festgelegt. Sie bestehen aus einer Kombination von themenbezogenen Keywords (SQ1), Namen von US-Unternehmen, die an autonomen Fahrzeugen arbeiten, US-Autoherstellern (SQ2) sowie deutschen Automobilherstellern (SQ2 und SQ3). Insbesondere SQ2 und SQ3 führten zu vielen Tweets, die sich nicht mit autonomen Fahrzeugen beschäftigten. Zu Beginn unserer Recherche im März 2015 wollten wir jedoch sicherstellen, dass die Suchanfragen die relevanten Tweets finden, ohne die Suchanfragen im Laufe der Zeit ändern zu müssen. Für die Datenanalyse wurden die Tweets mit dem folgenden regulären Ausdruck gefiltert:

```
( driver.?less | self.?driving | autonomous.?driving |  
automated.?driving | autonomous.?car | automated.?car )
```

Die Filterung stellt sicher, dass nur Tweets, die einen der folgenden Begriffe enthalten, in die Datenanalyse einbezogen werden: *driverless*, *self-driving*, *autonomous driving*, *automated driving*, *autonomous car* und *automated car*. Der reguläre Ausdruck stellt auch sicher, dass leichte Abweichungen der Begriffe berücksichtigt werden, wie z.B. „*driver-less*“. Insgesamt konnten wir mit unseren Suchbegriffen 1.963.905 Tweets von Twitter sammeln. Durch die Filterung reduzierte sich die Anzahl der relevanten Tweets auf 642.033.

Für das Training des maschinellen Lernverfahrens haben wir einen Datensatz von 7.482 manuell klassifizierten Tweets verwendet, der von Anfang Januar 2010 bis Juni 2014 reicht. Tabelle 67 zeigt die deskriptive Statistik der manuell klassifizierten Tweets. Diesen Datensatz haben wir über die, in die Twitter Website integrierte, Suche nach „Top-Tweets“ erzeugt. Top-Tweets sind „*beliebte Tweets, mit denen sich viele andere Twitter-Nutzer beschäftigt haben und die sie für nützlich halten*“ (Twitter, 2016c). Bei der Analyse dieser Tweets erhielten wir einen Überblick über die Diskussion zu diesem Thema auf Twitter, die bei der Gestaltung dieser Studie hilfreich war. Wir verzichteten jedoch auf eine Analyse dieser Tweets, da sie nur einen kleinen Teil der von Januar 2010 bis Juni 2014 veröffentlichten tatsächlichen Tweets ausmachen und wahrscheinlich durch die von Twitter implementierten und verwendeten proprietären Auswahlalgorithmen stark verzerrt sind. Stattdessen verwenden wir sie als Trainings- und Testdaten für die Klassifizierung des maschinellen Lernverfahrens.

	Anzahl	Anteil
Risiko	751	10,0 %
Nutzen	701	9,37 %
Neutral	6.030	80,6 %

Tabelle 67: Deskriptive Statistik der manuell klassifizierten Tweets

Quelle: Eigene Darstellung

Von den manuell klassifizierten Tweets beschäftigen sich 751 (10,0 %) mit Risiken von autonomen Fahrzeugen. Dem gegenüber stehen 701 (9,37 %) Tweets, die nützliche Aspekte von autonomen Fahrzeugen beschreiben. In den restlichen 1.452 (80,6 %) der Tweets im Trainingsdatensatz waren keine Informationen über die Risiko- und Nutzenwahrnehmung vorhanden und wurden daher als „neutral“ eingestuft. Vorteilhaft für das Training des Modells ist die fast ausgewogene Aufteilung in Risiko-Tweets (51,72 %) und Nutzen-Tweets (48,28 %) unter den nicht-neutralen Tweets.

8.2.2 Datenvorverarbeitung

Um die Dimensionalität der Tweets zu reduzieren und Fehlklassifizierungen zu vermeiden, führen wir eine Vorverarbeitung der Tweets durch, was dem üblichen Vorgehen bei der Textklassifizierung entspricht (Okazaki et al., 2014). Das bedeutet, dass wir Teile der Tweets so ändern, damit diese besser statistisch ausgewertet werden können und dadurch bessere Klassifizierungsergebnisse zu erhalten. Für die Vorverarbeitung verwenden wir das Text-Mining-Paket *tm*, ein Text-Mining-Framework für die Statistiksoftware *R* (Feinerer, Hornik & Meyer, 2008). Mit Hilfe des *tm*-Paketes werden die im Nachfolgenden beschriebenen Datenvorverarbeitungsschritte durchgeführt.

Zuerst werden alle Zeichen in den Tweets in Kleinbuchstaben umgewandelt. Wie die meisten Vorverarbeitungsschritte verringert auch dieser Schritt die Lesbarkeit für den Menschen, verbessert aber die statistische Auswertbarkeit von Texten. Da sich maschinelle Lernverfahren zur Textklassifizierung auf statistische Merkmale der bereitgestellten Textdaten beziehen, verbessert sich dadurch das trainierte Modell. Aus diesem Grund haben wir auch Satzzeichen, Zahlen und Hyperlinks entfernt. Eine Interpunktion ist für die Bestimmung der Klassifizierung der Tweets nicht erforderlich, da wir keine grammatikalische Analyse durchführen. Weiterhin haben wir englische Stoppwörter entfernt, die im *tm*-Paket enthalten sind. Stoppwörter sind Begriffe, die keine relevanten Informationen für die Textklassifikation enthalten (z. B. „a“, „by“ und „was“), so dass sie für die weitere Analyse nicht benötigt werden. Zusätzlich zum Entfernen der englischen Stoppwörter haben wir die twitterspezifischen Stoppwörter „via“ und „rt“ entfernt. Zuletzt haben wir die Stammformreduktion *Snowball* verwendet, mit der Wörter auf ihren Wortstamm reduziert werden (Porter, 2001). „Fahren“, „Fahrer“ und „Fahrt“ würde so beispielsweise auf den gemeinsamen Wortstamm „Fahr“ reduziert.

Die so transformierten Tweets sollten nun hauptsächlich Wörter enthalten, die für die Klassifizierung durch ein maschinelles Lernverfahren sinnvoll sind. Im letzten Schritt haben

wir die textuelle Darstellung der Tweets in eine Dokument-Term-Matrix (DTM) umgewandelt. Im Rahmen unserer Analyse sind Terme einzelne Wörter, was auch als Unigramm bezeichnet wird. Eine DTM ist eine zweidimensionale Matrix, bei der Dokumente (hier: Tweets) den Termen (hier: einzelne Wörter) zugeordnet werden. Die Werte in der DTM unterscheiden sich je nach Verfahren. So kann der Wert beispielsweise der Anzahl der Vorkommen eines Wortes in einem Tweet entsprechen, was als Termhäufigkeit (TF) bezeichnet wird. Wir gewichten bei unserer Analyse jeweils die TF mit der inversen Dokumentenhäufigkeit (IDF), was als TF-IDF bezeichnet wird. Diese berechnet sich wie folgt: Gegeben sei eine Sammlung von Dokumenten D , ein Wort w , und ein einzelnes Dokument $d \in D$, dann ist die TF-IDF definiert als:

$$w_d = f_{w,d} * \log\left(\frac{|D|}{f_{w,D}}\right)$$

Der Faktor $f_{w,d}$ bezeichnet dabei die TF, $|D|$ ist die Gesamtanzahl aller Dokumente und $f_{w,D}$ ist die Anzahl der Vorkommen des Wortes w in allen Dokumenten D (Salton & Buckley, 1988). Die IDF ist im Term der zweite Faktor des Produktes. Die TF-IDF zugrundeliegende Annahme ist, dass Wörter, die in vielen Dokumenten vorkommen, einen geringeren Informationsgehalt besitzen als Wörter, die in wenigen Dokumenten vorkommen. Für den Fall, dass beispielsweise ein Wort in allen Dokumenten vorkommt, also $f_{w,D} = |D|$, nimmt die TF-IDF dieses Wortes für alle Dokumente den Wert 0 an. Das Wort hat somit für die statistische Auswertung der Dokumente keine Bedeutung.

8.2.3 Modellerstellung und -evaluation

Die Grundidee der Textklassifizierung mit einem maschinellen Lernverfahren besteht darin, den Dokumenten automatisch Kategorien zuzuordnen. Bei einem überwachten maschinellen Lernverfahren wird ein kleiner Anteil der zu klassifizierenden Dokumente manuell klassifiziert und für das Training eines Klassifikationsmodells verwendet. Mit dem Klassifikationsmodell kann ein maschinelles Lernverfahren anschließend die unklassifizierten Daten automatisch klassifizieren. Viele verschiedene Algorithmen des maschinellen Lernens könnten für diese Aufgabe verwendet werden, wie Naïve Bayes, Maximum Entropy Classification oder Support Vector Machines (SVM) (Pang, Lee & Vaithyanathan, 2002). Weitere Verfahren basieren auf tiefen neuronalen Netzen, die unter dem Begriff „*deep learning*“ zusammengefasst werden (Huang, Chen, Zheng & Dong, 2017).

Wir haben uns für den Einsatz des SVM-Algorithmus zur Textklassifizierung entschieden, der sich für diese Aufgabe als sehr geeignet erwiesen hat (Joachims, 1998; Pang et al., 2002). Der SVM Algorithmus erfordert keine aufwändige Parametereinstellung und kommt mit großen Merkmalsvektoren gut zurecht, wie es bei Textklassifizierungsproblemen üblich ist (Joachims, 1998). Die Grundidee von SVM ist es, eine Hyperebene zu finden, die die Dokumente (hier die Tweets) nach ihrer Klassifizierung mit einem möglichst großen Abstand trennt (Pang et al., 2002). Abbildung 44 veranschaulicht das Vorgehen des SVM Algorithmus anhand einer Klassifizierung mit zwei *Features*. Die Features entsprechen bei der Textklassifizierung den Termen in der DTM. Der Wert eines Features entspricht den Einträgen in der DTM also beispielsweise der TF oder der TF-IDF. Da wir im Beispiel nur zwei Klassen (rot und grün)

unterscheiden, ist die Hyperebene eine Gerade, die die grünen von den roten Punkten unter Maximierung der Abstände zwischen verschiedenfarbigen Punkten trennt. Zur Klassifizierung verwenden die Library for Support Vector Machines (LIBSVM) Implementierung von SVM (Chang & Lin, 2011).

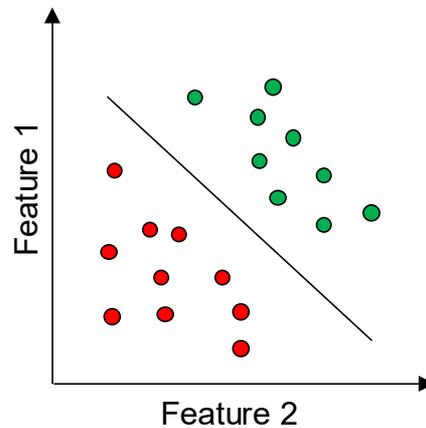


Abbildung 44: Veranschaulichung des SVM Algorithmus

Quelle: Eigene Darstellung

Wir verwenden eine lineare Kernelfunktion, da diese für Datensätze mit vielen Instanzen und Features, wie im Falle der Textklassifizierung, empfohlen wird (Hsu, Chang & Lin, 2016). Weiterhin zeigen auch frühere Studien gute Ergebnisse mit linearen Kernelfunktionen bei der Textklassifizierung (Joachims, 1998). Für lineare Kernelfunktionen kann nur ein Parameter des SVM-Algorithmus variiert werden, der Regularisierungsparameter C . Wir haben mehrere Werte für C im Bereich von 0,03125 bis 100 mit 10-facher Kreuzvalidierung getestet.

Eine k -fache Kreuzvalidierung teilt die Trainingsdaten in k disjunkte, etwa gleich große Teilmengen („folds“) auf (Kohavi, 1995). Das maschinelle Lernverfahren verwendet $k - 1$ Teilmengen für das Training des Modells und die verbleibende Teilmenge als Testdaten um das trainierte Modell beispielweise durch Berechnung der Genauigkeit zu bewerten. Die Genauigkeit ist definiert als die Gesamtzahl der korrekten Klassifizierungen dividiert durch die Anzahl der Instanzen im Datensatz. Dieser Schritt wird k -mal wiederholt, bis alle möglichen Kombinationen aus Trainings- und Testdaten einmal verwendet wurde. Das Ergebnis der Kreuzvalidierung ist beispielsweise die mittlere Genauigkeit der Klassifizierung aller k -Auswertungen.

Basierend auf den Kreuzvalidierungen mit Variation des C -Parameters haben wir beobachtet, dass höhere Werte von C zu einer höheren Klassifizierungsgenauigkeit führen. Höhere Werte von C erhöhen jedoch auch die benötigte Rechenzeit für das Training und verbessern die Klassifizierungsgenauigkeit nur geringfügig nach $C = 64$. Als Kompromiss aus sehr langer Rechenzeit und Klassifikationsgenauigkeit haben wir $C = 94$ ermittelt, das verglichen mit Ergebnissen ähnlicher Studien eine sehr hohe mittlere Genauigkeit von 0,925 aufweist (Sriram, Fuhry, Demir, Ferhatosmanoglu & Demirbas, 2010). Die SVM-Klassifizierung führt

insbesondere zu deutlich besseren Ergebnissen als die Klassifizierung nach handverlesenen Schlüsselwörtern (Pang & Lee, 2008).

Für die zweite Auswertung teilen wir die Trainingsdaten mit einer Zufallsauswahl von 80 % (N = 5.984) der Tweets für das Training des SVM und 20 % (N = 1.496) für die Bewertung der Qualität der Klassifizierung, also Testdaten. Anschließend berechnen wir mehrere Kennzahlen auf der Grundlage der Konfusionsmatrix (siehe Tabelle 68).

Vorhergesagte Klasse	Tatsächliche Klasse		
	Risiko	Nutzen	Neutral
Risiko	108	4	27
Nutzen	3	101	15
Neutral	45	28	1.165

Tabelle 68: Konfusionsmatrix des SVM Algorithmus

Quelle: Eigene Darstellung

Die Genauigkeit der Klassifizierung beträgt 0,918, was in etwa der durchschnittlichen Genauigkeit der Kreuzvalidierung entspricht. Da es deutlich mehr neutrale Tweets als Risiko und Nutzen Tweets gibt, haben wir die „*No-Information-Rate*“ berechnet. Diese geht von einem einfachen Algorithmus aus, der als Vorhersage der Klasse stets die Klasse mit den meisten Elementen vorhersagt. Dies ist hier die neutrale Klasse mit 1.165 oder 80,7 % der Tweets. Somit hat die No-Information-Rate einen Wert von 0,807. Dieser unterscheidet sich signifikant ($p < 0,001$) von der Genauigkeit unseres Verfahrens von 0,918. Weitere Metriken für die Leistung des trainierten Modells wurde mit Hilfe des R-Paketes *caret* (Kuhn, 2008) berechnet und sind in Tabelle 69 abgebildet.

Metrik	Risiko	Nutzen	Neutral	Mittelwert
Sensitivität	0,692	0,759	0,965	0,806
Spezifität	0,977	0,987	0,747	0,904
Positiver Vorhersagewert	0,777	0,849	0,941	0,856
Negativer Vorhersagewert	0,965	0,977	0,837	0,926
Prävalenz	0,104	0,089	0,807	0,333
Detektionsrate	0,072	0,068	0,779	0,306
Prävalenz der Detektion	0,093	0,080	0,828	0,333
Ausgeglichene Genauigkeit	0,835	0,873	0,856	0,855

Tabelle 69: Weitere Metriken des trainierten SVM Modells

Quelle: Eigene Darstellung

Idealerweise sind bei der Textklassifikation alle Kategorien in den Trainingsdaten gleich häufig vertreten. Unsere Trainingsdaten enthalten aber wesentlich mehr neutrale Tweets als Risiko- und Nutzen-Tweets. Dies zeigt sich in der geringeren Sensitivität für die Kategorien Risiko und Nutzen und in der geringeren Spezifität für die neutrale Kategorie. Somit könnten wir einige Tweets beispielsweise fälschlicherweise als neutral klassifizieren. Allerdings unterscheidet sich die Spezifität der Risiko und Nutzen Kategorien nicht wesentlich. Zusätzlich können wir aufgrund der hohen Spezifität für Risiko- und Nutzen-Tweets dennoch davon ausgehen, dass die gefundenen Risiko- und Nutzen-Tweets tatsächlich Risiko und Nutzen von autonomen Fahrzeugen beschreiben. Somit sollte die für diese Studie wesentliche Unterscheidung zwischen Risiko und Nutzen und deren zahlenmäßiges Verhältnis nicht wesentlich verzerrt sein. Für unsere Analysen betrachten wir das Klassifikationsmodell daher als geeignet.

8.3 Ergebnisse

Im Zeitraum vom 03.03.2015 bis 21.10.2016 haben wir 1.963.905 Tweets zum autonomen Fahren aus Twitter extrahiert. Nach einer Filterung der Tweets verblieben 642.033 relevante Tweets, von denen 528.440 (82,3 %) neutral klassifiziert, 50.612 (7,88 %) als Nutzen-Tweets (BT) und 62.981 (9,81 %) als Risiko-Tweets (RT) klassifiziert wurden. Einem Tweet wird immer nur eine Klasse zugeordnet, also entweder neutral, BT oder RT. Sollte es dennoch Tweets im Datensatz geben, die sowohl als BT als auch als RT klassifiziert werden könnten, würde der Algorithmus die am stärksten ausgeprägte Kategorie auswählen. Auf Basis der Anzahl der RT und der BT wird die Risk Rate (RR) und die Benefit Rate (BR) wie folgt berechnet:

$$RR = \frac{|RT|}{|RT|+|BT|} = \frac{62.981}{62.981+50.612} = 0,5544 \quad (1)$$

$$BR = \frac{|BT|}{|RT|+|BT|} = \frac{50.612}{62.981+50.612} = 0,4456 \quad (2)$$

Die RR beschreibt das Verhältnis von Tweets über die Risiken autonomer Fahrzeuge zur Gesamtzahl der Tweets unter Ausschluss der neutralen Tweets, die weder Informationen über Risiken noch Nutzen enthalten. Die BR ist analog definiert und kann auch als $1 - RR$ berechnet werden, wenn RR bereits bekannt ist. Somit gilt:

$$RR + BR = \frac{|RT|}{|RT|+|BT|} + \frac{|BT|}{|RT|+|BT|} = \frac{|RT|+|BT|}{|RT|+|BT|} = 1 \quad (3)$$

Im ersten Schritt berechnen wir eine deskriptive Statistik der gesammelten Tweets für die Jahre 2015 und 2016 (siehe Tabelle 70). Im Jahr 2015 waren 407.179 (83,0 %) der Tweets neutral, 37.891 (7,73 %) sind BT und 45.214 (9,22 %) RT für autonome Fahrzeuge. Die RR im Jahr 2015 entspricht 0,5441 und die BR entspricht somit $1 - 0,5441 = 0,4559$. Im Jahr 2016 waren 121.261 (79,9 %) der Tweets neutral, 12.721 (8,38 %) waren BT und 17.767 (11,7 %) RT. Insgesamt sehen wir in unserer Analyse im Laufe der Jahre einen Trend zu höherer RR.

Durch die Abnahme des Anteils von neutralen Tweets nehmen wir an, dass das Klassifikationsmodell im Laufe der Zeit konstant arbeitet und sich nicht verschlechtert. Das Modell erkennt somit RT und BT aus der Vielzahl der neutralen Tweets auch bei Themenwechseln. Darüber hinaus könnte der geringere Anteil an neutralen Tweets auch

bedeuten, dass zunehmend Risiken und Vorteile von autonomen Fahrzeugen diskutiert werden, eine Folge der sich konkretisierenden Erwartungen.

Jahr	Neutrale Tweets	BT	RT	RR	BR
2015	407.179 83,0 %	37.891 7,73 %	45.214 9,22 %	0,5441	0,4559
2016	121.261 79,9 %	12.721 8,38 %	17.767 11,7 %	0,5828	0,4172
Total	528.440 82,3 %	50.612 7,88 %	62.981 9,81 %	0,5544	0,4456

Tabelle 70: Deskriptive Statistik der Tweets nach Jahr

Quelle: Eigene Darstellung

Die Tatsache, dass sich RR und BR von 2015 bis 2016 nicht wesentlich verändert haben zeigt, dass RR und BR ein robustes Maß zur Quantifizierung der Risiko- und Nutzenwahrnehmung sein könnten. Eine genauere Untersuchung der RR auf Monatsebene zeigt allerdings, dass die RR schwankt. Die Auslöser der Schwankungen und somit die Tweets in diesen Phasen könnten Hinweise auf Ereignisse geben, die die Risiko- und Nutzenwahrnehmung beeinflussen. Diese Annahme wird im Folgenden überprüft. Abbildung 45 zeigt die Entwicklung von RR und BR im zeitlichen Verlauf.

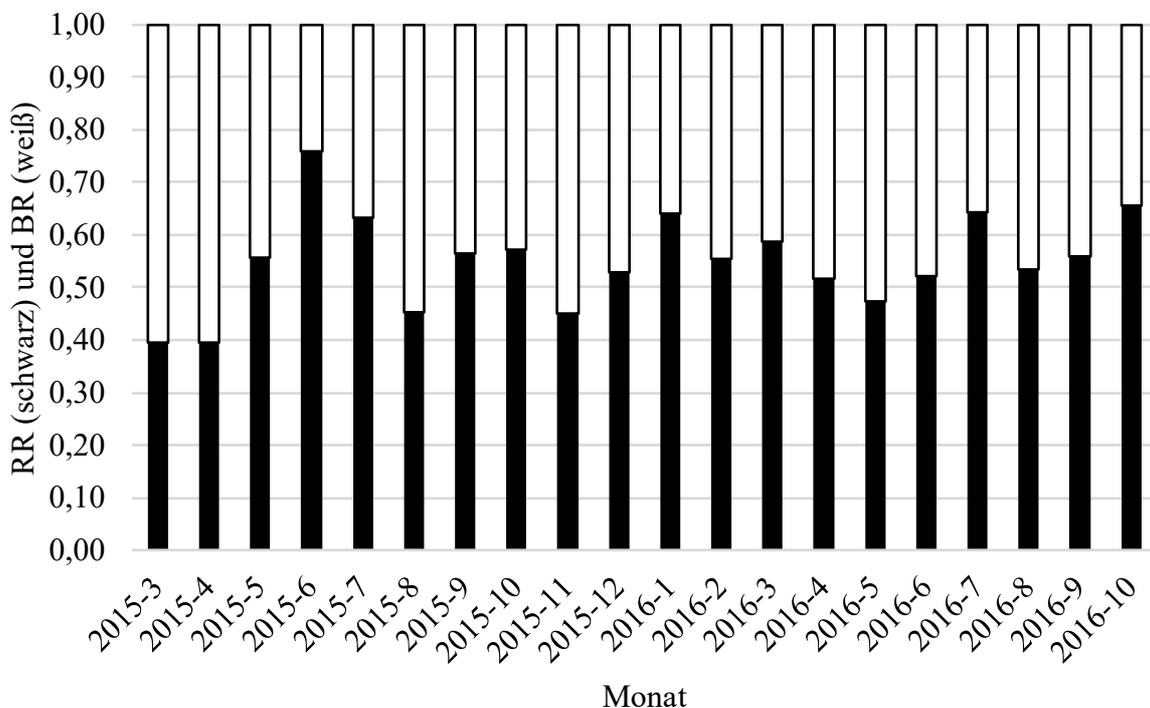


Abbildung 45: RR und BR im zeitlichen Verlauf

Quelle: Eigene Darstellung

Durch die detaillierte Analyse der Tweets können wir verfolgen, wie Twitter-Nutzer auf bestimmte Nachrichtenberichte, Ankündigungen oder andere Ereignisse reagieren und ob die Veränderung der Risiko- und Nutzenwahrnehmung durch diese Ereignisse beeinflusst wird. Wir haben festgestellt, dass es einen Zusammenhang zwischen Ereignissen im Kontext des autonomen Fahrens und der Veränderung von BR und RR gibt. Im Folgenden führen wir einige Beispiele auf.

Im *April 2015* haben wir mehr Tweets über die Vorteile autonomer Fahrzeuge als über Risiken beobachtet, da die RR kleiner als 0,5 ist. In diesem Monat erklärte Google die Nutzung von Solarenergie und Fahrgemeinschaften für ihr autonomes Fahrzeug. Daher hat das Google Car das Potenzial, zum Schutz der Umwelt und zur Entlastung der Großstädte beizutragen. Darüber hinaus berichtete Google, dass ihre autonomen Fahrzeuge die Zahl der Verletzten und Getöteten bei Unfällen reduzieren könnten. Tweets diskutierten diesen Bericht häufig, was einer der Hauptgründe dafür war, dass im April 2015 die RR kleiner als 0,5 war.

Von *Mai bis Juli 2015* stiegen die Tweets mit Risiken an und überwiegen gegenüber den Tweets zum Nutzen autonomer Fahrzeuge. Der Hauptgrund dafür ist, dass Google Daten veröffentlicht hat, die zeigen, dass dessen autonome Fahrzeuge in den letzten 6 Jahren an elf kleinen Unfällen beteiligt waren. Im Juni 2015 startete Google eine Website mit regelmäßigen Berichten zum Google Car, die Unfälle und kritische Ereignisse beinhalten. Im Juli 2015 meldete Google seinen ersten Unfall mit einem Verletzten. Obwohl wir nicht explizit nach Google-bezogenen Beiträgen gefiltert haben, bezogen sich die meisten Tweets in diesem Monat auf Google.

Die Auswertung der Tweets von *August 2015* ergab wieder einen Anstieg der BR. Wir fanden heraus, dass viele Tweets die Ankündigung von autonomen Crash Trucks erwähnten. Diese Lastwagen werden in der Regel auf Baustellen eingesetzt, um die Straßenbauarbeiter vor abgelenkten Fahrern zu schützen, die ansonsten gegebenenfalls ungebremst mit Baustellenfahrzeugen kollidieren könnten oder auch Straßenbauarbeiter verletzen könnten (Rubinkam, 2015). Fahrer von Crash Trucks befinden sich potenziell in einer gefährlichen Situation, sodass der Austausch des Fahrers durch ein autonomes Fahrzeug Leben retten könnte, was in der Öffentlichkeit offensichtlich gut aufgenommen wurde. Der Wegfall eines Arbeitsplatzes wurde in diesem Zusammenhang nicht thematisiert, da es sich vermutlich um eine wenig attraktive und zudem gefährliche Tätigkeit handelt.

Von *September bis Oktober 2015* gab es keine nennenswerten Veränderungen in der RR und auch keine neuen Themen zum Vormonat. Im *November 2015* verabschiedete Nevada Vorschriften für autonome Fahrzeuge, die zu vielen Tweets führen, die als BT eingestuft werden. Von *Dezember 2015 bis April 2016* konnten wir keine zentralen Diskussionsthemen identifizieren. Erst die Nachricht im *April 2016*, dass Google und Chrysler zusammenarbeiten, um autonome Fahrzeuge zu produzieren, löste wieder nennenswerte Diskussionen bis in den *Mai 2016* aus und wurde als BT klassifiziert. Im *Juni 2016* veröffentlichte Volvo & Ericsson eine Vorschau auf intelligentes Medien-Streaming für autonome Fahrzeuge, das zu vielen Tweets führte, die jedoch als neutral eingestuft wurden und somit die RR nicht beeinflussten.

Im *Juli 2016* ereignete sich der erste tödliche Unfall mit aktivem Tesla Autopilot, der auch in Abschnitt 3.3 beschrieben ist. Dieses Ereignis erzeugte einen deutlichen Anstieg der RR und

wurde häufig in Tweets thematisiert, die auch korrekterweise als RT klassifiziert wurden. Insgesamt wurden im *Juli 2016* in unserem Datensatz 631 RT über autonome Fahrzeuge identifiziert, verglichen mit 352 BT was folglich zu einer hohen RR von 0,642 für diesen Monat führte.

Im *August 2016* kündigte Tesla den Zusammenschluss mit Solarcity an, bei dem Tesla ein Aktienpaket von Solarcity im Umfang von 2,6 Milliarden Dollar kaufte. Die Kombination von grüner Stromerzeugung durch Photovoltaik Anlagen, Batteriespeichersystemen und autonomen elektrischen Fahrzeugen erzeugte viel positive Resonanz auf Twitter. Weiterhin wurden autonome Traktoren thematisiert, die die Landwirtschaft revolutionieren könnten. Ford kündigte im August 2016 für das Jahr 2021 autonome Taxis an, woraufhin eine Diskussion über autonom fahrende Wohnzimmer stattfand. Somit gab es viele Gründe für BT. Allerdings wurden in diesem Monat auch viele Tweets über Unfälle mit autonomen Fahrzeugen veröffentlicht. Somit überwogen dennoch die RT, was zu einem RR-Wert von 0,5348 führte.

Im *Oktober 2016*, dem letzten Monat des Untersuchungszeitraumes, werden vor allem Tweets über einen Unfall in Singapur veröffentlicht, bei dem ein autonomes Fahrzeug einen LKW gerammt hat. Dies führte erneut zu einer erhöhten RR von 0,655. Die letzten Tweets im analysierten Datensatz wurden am 21. Oktober veröffentlicht, so dass die Analysen keine Ereignisse nach diesem Datum widerspiegeln.

Im nächsten Schritt analysieren wir die Anzahl der Tweets im zeitlichen Verlauf, wie in Abbildung 46 dargestellt. In der Abbildung sind mehrere Veränderungen in der Anzahl erkennbar. Ein charakteristischer Monat in unserem Datensatz ist November 2015. Eine genaue Untersuchung der Tweets zeigt, dass die International Driverless Cars Conference einen allgemeinen Anstieg der Tweets verursacht hat. Einerseits wurden durch diese Konferenz viele Tweets ausgelöst und andererseits gab es aufgrund der Konferenz vermutlich auch ein erhöhtes Interesse an solchen Tweets. Dadurch wurden viele der ursprünglichen Tweets retweetet, also von interessierten Twitter Nutzern erneut veröffentlicht. Dies führte zu einem starken Anstieg der Tweets zu autonomen Fahrzeugen in diesem Monat. Daraus schließen wir, dass die International Driverless Cars Conference ein zentrales Ereignis im untersuchten Zeitraum darstellt.

Durch die Analyse der Daten haben wir festgestellt, dass die Diskussion über autonome Fahrzeuge vom Google Car dominiert wird, wie bereits in früheren Untersuchungen festgestellt wurde (Woisetschläger, 2016). Im Gegensatz zu den im Jahr 2019 verfügbaren Fahrzeugen mit fortschrittlichen Fahrerassistenzsystemen (SAE Stufe 2), konzentriert sich Google beim Google Car auf die Entwicklung eines autonomen Fahrzeuges der SAE Stufe 5. Somit sind die Insassen des Google Car nicht verpflichtet, die Kontrolle über das Fahrzeug zu jeder Zeit übernehmen zu können. Es muss hier auch von Insassen anstatt von einem Fahrer gesprochen werden, da bei Stufe 5 das Fahrzeug selbst die Rolle und damit auch die volle Verantwortung des Fahrers übernimmt.

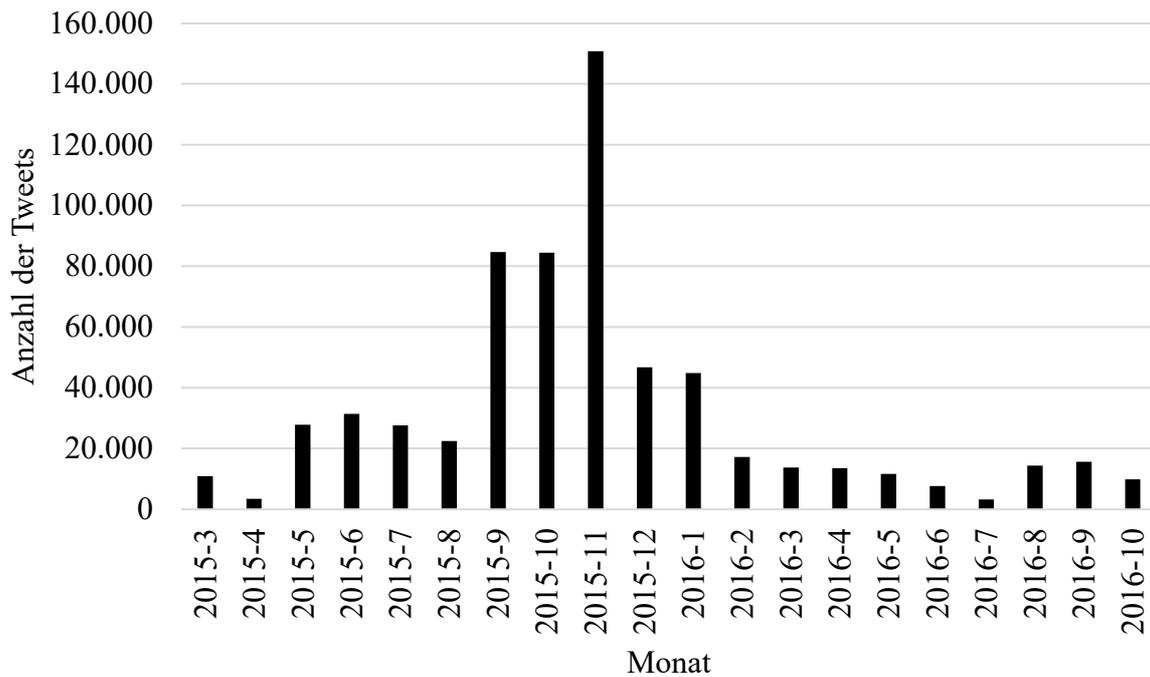


Abbildung 46: Anzahl der Tweets pro Monat

Quelle: Eigene Darstellung

Im untersuchten Zeitraum wurde der Bericht über einen blinden Fahrer des Google Car sehr oft über Twitter geteilt. Dabei handelte es sich um den ersten Fahrer des Google Car, der kein Angestellter von Google war und aufgrund seiner Blindheit nicht selbst fahren kann. Die Fahrt fand bereits 2012 statt und zeigt eindrucksvoll den Unterschied zwischen verfügbarer Fahrzeugautomatisierung und SAE Stufe 5 Automatisierung.

Abbildung 47 zeigt die Gesamtzahl der Tweets für jeden untersuchten Automobilhersteller im Datensatz. Wie in Abschnitt 8.2.1 beschrieben, sind die Namen der Firmen in den Suchanfragen enthalten. Die Dominanz von in den USA ansässigen Unternehmen ist auffallend. Die fünf häufigsten in Tweets genannten Firmen haben ihren Hauptsitz in den USA. Bemerkenswert ist auch, dass IT-Firmen stark mit diesem Thema verbunden sind. Sogar Firmen, die öffentlich selbst gar nicht über eigene Entwicklungen von autonomen Fahrzeugen sprechen wie Apple. Wir haben hier eine weniger deutliche Dominanz erwartet, auch wenn der Datensatz nur englischsprachige Tweets beinhaltet.

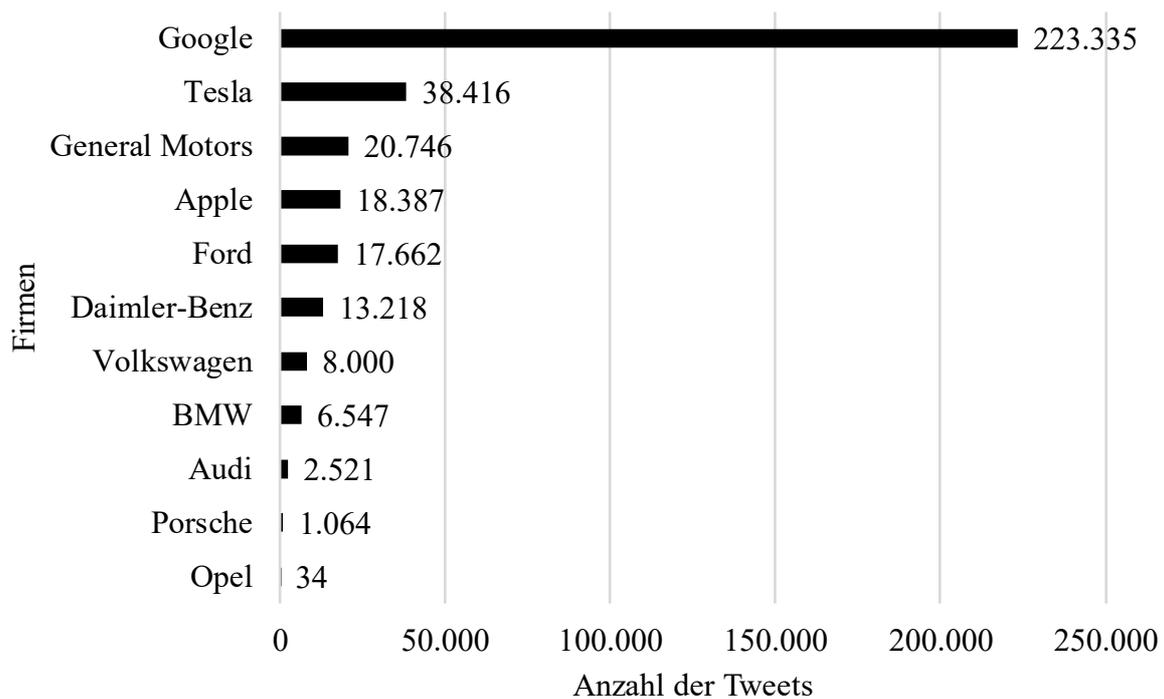


Abbildung 47: Anzahl der Tweets pro Firma

Quelle: Eigene Darstellung

Wir haben unsere Analyse der RR auch auf die Tweets, die Firmennamen enthalten angewendet. Auch hier fanden wir interessante Ergebnisse, wie in Abbildung 48 dargestellt. Die RR ist für fünf traditionelle Automobilhersteller am niedrigsten. Dies könnte darauf hindeuten, dass diese einen Vertrauensvorsprung für die Entwicklung sicherer autonomer Fahrzeuge besitzen. Obwohl es kontroverse Diskussionen zum Tesla Autopilot gibt, liegt die RR von Tesla im Mittelfeld. Zahlreiche BT über Tesla kompensieren die hohe Anzahl von RT. Interessant ist auch, dass traditionelle deutsche Automobilhersteller wie Daimler-Benz, Volkswagen und Audi, die als Innovationsführer für autonome Fahrzeuge in Deutschland gelten, einen hohen RR-Wert haben, was scheinbar im Widerspruch zu den Ergebnissen von Studie 2 dieser Dissertation in Abbildung 27 steht. Allerdings könnten Sicherheitsaspekte bei diesen Herstellern auch einfach deutlich häufiger diskutiert werden, wohingegen sich die Kommunikation bei anderen Herstellern eher auf den Nutzen bezieht. Im Falle von Intelligent Drive von Daimler zum Beispiel ist der Missbrauch des Systems durch Systemeinschränkungen unwahrscheinlicher als beim Tesla-System und sollte bei gleichwertiger Funktionalität daher als sicherer angesehen werden (Kohl et al., 2016). Die Benutzer könnten die zusätzlichen Einschränkungen jedoch als störend und als Kontrollverlust wahrnehmen, wie in Studie 3 dieser Dissertation bereits erläutert.

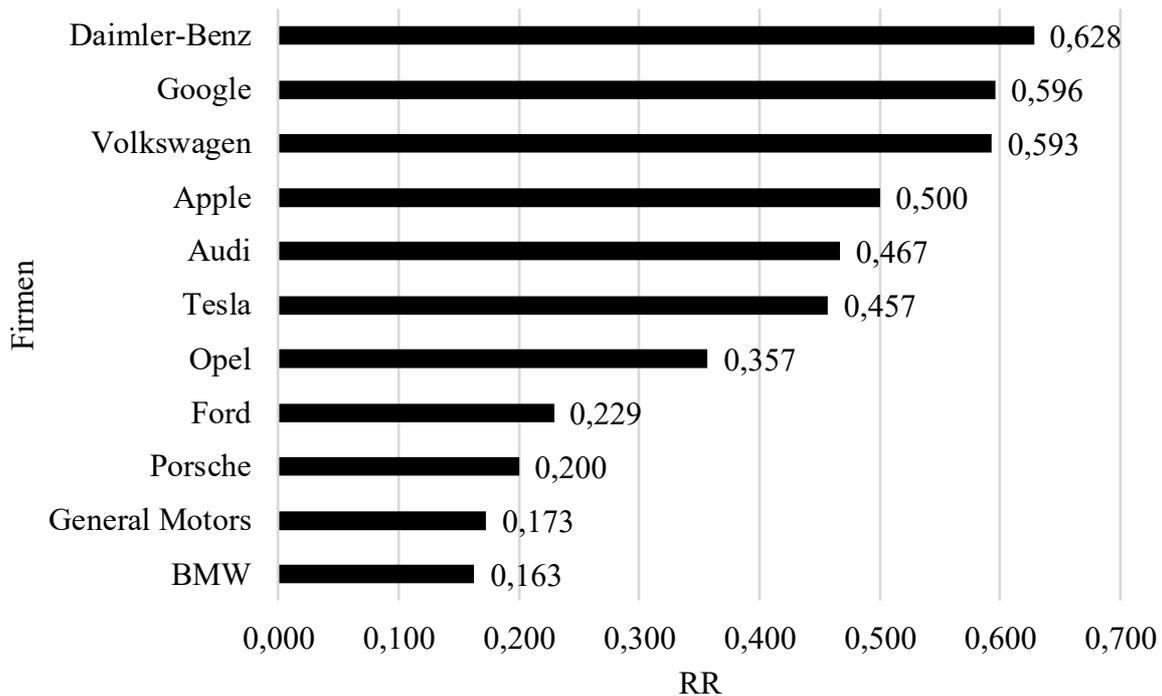


Abbildung 48: RR der Tweets zu Firmen

Quelle: Eigene Darstellung

Im Falle von Google scheinen die Nutzer ebenfalls das Risiko des Kontrollverlustes wahrzunehmen. Diese Wahrnehmung wird bekräftigt durch einen Prototyp des Google Car, das kein Lenkrad mehr aufweist. Darüber hinaus werden die vielen kleineren Unfälle des Google Car in der Öffentlichkeit aufmerksam verfolgt. Allerdings könnten die Analysen für einzelne Hersteller verzerrt sein, da sich die Anzahl zwischen den Herstellern deutlich unterscheidet. Unser Datensatz enthält über 6.500-mal mehr Tweets über Google als über Opel. Die RR führt zu einer ausgewogeneren Vergleichbarkeit, aber der Unterschied sollte bei der Interpretation der Ergebnisse berücksichtigt werden.

8.4 Diskussion

Twitter hat sich oft als wertvolle Datenquelle zur Vorhersage und Überwachung verschiedener Phänomene erwiesen, die von Krankheitsausbrüchen (St Louis & Zorlu, 2012) bis hin zu politischen Wahlen (Tumasjan, Sprenger, Sandner & Welp, 2010) reichen. Trotz ihrer Kürze enthalten Tweets wertvolle Informationen, die in natürlicher Sprache kodiert sind (Pak & Paroubek, 2010). Die Herausforderung besteht darin, diese Informationen aus der enormen Datenmenge auf Twitter zu extrahieren. Hierfür verwenden wir ein etabliertes Vorgehen aus der Sentimentanalyse (Pak & Paroubek, 2010), das wir für die Identifikation von Risiken und Nutzen einer Technologie anpassen. Bei der Sentimentanalyse wird einer gegebenen Aussage nur eine positive oder negative Polarität zugeordnet (Medhat, Hassan & Korashy, 2014). Daraus lassen sich allerdings noch keine Erkenntnisse bezüglich der Risiko- und Nutzenwahrnehmung ableiten.

Die in diesem Kapitel vorgestellte Studie hat einige Limitationen, die wir zunächst erläutern. Zu den neuen Entwicklungen auf Twitter gehören Twitter-Bots, die von realen Personen schwer zu unterscheiden sind (Boshmaf, Muslukhov, Beznosov & Ripeanu, 2011; Haustein et al., 2016) und Internet of Things (IoT) Geräte, die über Twitter kommunizieren (Kranz, Roalter & Michahelles, 2010). Die Ergebnisse von Twitter-Analysen bedürfen daher einer sorgfältigen Prüfung.

Das Ziel von Twitter Bots ist es, die menschliche Kommunikation und den Schreibstil immer besser nachzubilden, sodass deren Tweets nicht mehr von menschlich verfassten zu unterscheiden sind. Forscher sind besorgt über die großflächige Infiltration so genannter „*Socialbots*“, die sehr subtil stattfinden kann (Boshmaf et al., 2011). Socialbots erschweren eine quantitative Analyse. So ist zum Beispiel die reine Analyse einer Anzahl von Beiträgen, nicht nur von Twitter, sondern auch von anderen sozialen Plattformen wie Facebook, nur begrenzt aussagefähig (Haustein et al., 2016). Diese Bedrohungen der Validität der Ergebnisse adressieren wir, indem wir die Ergebnisse dieser Studie mit Ergebnissen von früheren Studien abgleichen, um so eine signifikante Manipulation der Twitter-Daten zu erkennen.

Ein weiteres Problem bei der statistischen Auswertung von Tweets ist, dass keine ungefilterte Kommunikation zwischen den Nutzern stattfindet. Wir beziehen in dieser Studie nur Tweets ein, die von der Twitter Search API zurückgegeben werden. Diese werden durch proprietäre Algorithmen bestimmt und sind somit keine repräsentative Stichprobe der gesamten Tweets (Ruths & Pfeffer, 2014). Darüber hinaus sind Twitter-Nutzer keine repräsentative Stichprobe der Bevölkerung (Ruths & Pfeffer, 2014). Twitter ist dennoch eine wertvolle Quelle für Studien, da auf Twitter ein breites Publikum aus verschiedenen sozialen Milieus und Interessengruppen vertreten ist (Pak & Paroubek, 2010). Wir gehen davon aus, dass Twitter-Nutzer offener für neue Technologien sind, was zu einer erhöhten Nutzenwahrnehmung führen könnte als frühere Umfragen auf der Grundlage repräsentativer Stichproben der Bevölkerung.

Trotz der Einschränkungen des in diesem Kapitel entwickelten Verfahrens ermöglicht es den Zugriff auf die VOC von 321 Millionen aktiven Twitter-Nutzern im Monat (Shaban, 2019), was zu deutlich mehr Aussagen über die Akzeptanz von autonomen Fahrzeugen führt als in früheren Untersuchungen. Um mit den enormen Datenmengen von Twitter arbeiten zu können, haben wir in Studie 4 dieser Dissertation ein maschinelles Lernverfahren zur automatischen Kategorisierung von Tweets verwendet. Dadurch ließ sich der manuelle Kodierungsaufwand deutlich reduzieren, da nur ein Teil der Daten für das Training eines Klassifizierungsmodells manuell kodiert werden muss. Somit kann das Verfahren beispielsweise zur Validierung von per Fragebogen erhobenen Daten dienen, ohne eine erneute aufwendige Datenerhebung durchführen zu müssen.

Zunächst vergleichen wir unsere Ergebnisse mit früheren Untersuchungen. Fraedrich, Cyganski, Wolf & Lenz (2016) stellten in einer in Deutschland durchgeführten Studie fest, dass 46 % der 1.163 Befragten eine positive Assoziation mit autonomen Fahrzeugen hatten. Schoettle & Sivak (2014) befragten 1.533 Personen aus den USA, Großbritannien und Australien zu ihrer Meinung über autonome Fahrzeuge und stellten fest, dass 56,8 % der Befragten zumindest eine leicht positive Meinung hatten. Die in dieser Studie gemessene BR

liegt zwischen 46 % (2015) und 42 % (2016), was nahezu der Studie von Fraedrich et al. (2016) entspricht und etwa 10 % niedriger ist als der Anteil der positiv gestimmten Probanden bei Schoettle & Sivak (2014). Unsere Ergebnisse liegen daher in Bereichen, die bereits in früheren Studien gemessen wurden. Daher sind wir zuversichtlich, dass unsere Daten den Risiko- und Nutzenwahrnehmung der Bevölkerung entsprechen. Somit sehen wir die Proposition P1 bestätigt, dass maschinelle Lernalgorithmen verwendet werden können, um die Risiko- und Nutzenwahrnehmung der Öffentlichkeit bezüglich autonomer Fahrzeuge auf Twitter zu analysieren.

Zweitens zeigt unsere detaillierte Analyse der Tweets, dass Nachrichten und Ereignisse zu autonomen Fahrzeugen auf Twitter diskutiert wurden und RR und BR wie erwartet beeinflusst wurden. Daher haben wir auch Unterstützung für unsere Propositionen P2a und P2b gefunden. Im Folgenden werden unsere Ergebnisse weiter diskutiert und mit früheren Untersuchungen zur Akzeptanz von autonomen Fahrzeugen verknüpft.

Die drei Monate mit der höchsten RR sind Juni 2015 (RR = 0,759), Oktober 2016 (RR = 0,655) und Juli 2016 (RR = 0,642). In allen drei Monaten entstanden die Ausschläge der RR durch die Diskussion von Unfällen, die von autonomen Fahrzeugen verursacht wurden. In fünf von 20 Monaten überwogen die BT (d. h. BR > 0.5), was allerdings auf keine einheitliche Ursache zurückzuführen ist. Wir schließen daraus, dass im untersuchten Zeitraum noch keine Anwendung von autonomen Fahrzeugen diskutiert wurde, die dieser Technologie zum Durchbruch verhelfen könnte. Unfälle hingegen könnten die Akzeptanz autonomer Fahrzeuge durch die direkte Auswirkung auf die RR und somit auch die Risikowahrnehmung erheblich reduzieren.

Angesichts der in dieser Studie ermittelten RR- und BR-Werte kommen wir zu dem Schluss, dass es noch Vorbehalte gegenüber autonomen Fahrzeugen in der Öffentlichkeit gibt. Falls autonome Fahrzeuge zeitnah auf den Markt kämen, wäre die Akzeptanz vermutlich gering und es könnte sich auch Widerstandsverhalten zeigen. In dieser Studie berechneten wir die BR- und RR-Werte zu verschiedenen Zeitpunkten, um die Tweets im zeitlichen Verlauf zu analysieren und fanden einen Anstieg der RR um 7,11 % von 54,4 % (2015) auf 58,5 % (2016). Dies könnte darauf hindeuten, dass die Bedenken der Gesellschaft bisher nicht hinreichend berücksichtigt wurden.

Weiterhin könnte eine soziale Verstärkung der Risikowahrnehmung von autonomen Fahrzeugen die Akzeptanz der Technologie weiter verringern. Unter sozialer Verstärkung von Risiken versteht man die Neigung im sozialen Umfeld, eher über Risiken als dem Nutzen einer Technologie zu sprechen (Kasperson et al., 1988). Wir sehen in vielen Fällen, dass soziale Medien zunehmend zu übertriebenen Risikowahrnehmungen führen und irrationale Verhaltensweisen auslösen. Die Folge könnte sein, dass Unfälle mit autonomen Fahrzeugen die Akzeptanz über alle Hersteller und Anbieter hinweg stark beeinträchtigt.

Wir fanden viele Tweets, die auf eine verzerrte Risikowahrnehmung hindeuteten, beispielsweise „[...] *Google's driverless cars have been involved in four car accidents*“ oder "*CAR CRASH Google Self Driving Cars to Decide if You Live or Die* [...]". Anstatt die Zahl der Unfälle zu erhöhen, könnten autonome Fahrzeuge diese jedoch deutlich reduzieren

(Fagnant & Kockelman, 2015). Auch andere Studien fanden verzerrte Wahrnehmungen, die sich jedoch ändern könnten, wenn zunehmend eigene Erfahrungen mit autonomen Fahrzeugen gemacht wurden (Bansal, Kockelman & Singh, 2016; Woisetschläger, 2016).

In den gesammelten Tweets äußerten viele auch Misstrauen gegenüber den Herstellern autonomer Fahrzeuge und zeigten ihre Präferenz selbst zu Fahren. Zum Beispiel: „*Sorry @google not going to buy a self driving car I like driving and don't trust your technology*“. In diesem Fall wurden offensichtlich die Vorteile von autonomen Fahrzeugen nicht erkannt. Während das Fahren in bestimmten Situationen angenehm sein kann, sind wir oft mit weniger angenehmen Aspekten des Fahrens konfrontiert, wie beispielsweise Verkehrsstaus, lange und monotone Autobahnfahrten oder der Suche nach einem Parkplatz in immer überfüllteren Innenstädten. Diese Bedenken finden wir auch in der Marktforschung, die einen Mangel an emotionaler Bindung durch den Verlust von Fahrspaß beim Selbstfahren eines Autos voraussagt (Olson, 2017). Erste Studien befassen sich bereits mit der Benutzererfahrung in autonomen Fahrzeugen (Niculescu, Dix & Yeo, 2017; Pettersson & Karlsson, 2015; Rödel, Stadler, Meschtscherjakov & Tscheligi, 2014). Um dem Mangel an Fahrspaß entgegenzuwirken, wird vorgeschlagen, den Fahrstil von autonomen Fahrzeugen an den Fahrstil ihrer Nutzer anzupassen (Butakov & Ioannou, 2015; Kraus, Althoff, Heißing & Buss, 2009; Kuderer, Gulati & Burgard, 2015). Um Vertrauensprobleme zu mildern und den Fahrspaß zu erhöhen, empfehlen frühere Untersuchungen, dass die Insassen auch zukünftig die Möglichkeit erhalten sollen, das Fahrzeug selbst zu steuern, wenn sie dies wünschen (Yap, Correia & van Arem, 2016).

In den Tweets wurde auch Bedenken zur Sicherheit und Privatsphäre autonomer Fahrzeuge geäußert, z. B. „*[...] Can #driverless #cars be made safe from hackers?*“ drückt die Angst vor Hackern aus, die die Kontrolle über ein Fahrzeug übernehmen könnten. Hacker könnten sogar Viren implementieren, die sich von Auto zu Auto ausbreiten könnten. Dabei handelt es sich um ein Risiko, das sich aufgrund der zunehmenden Vernetzung von Fahrzeugen als real erweisen könnte (Lee, Gerla, Pau, Lee & Lim, 2016). Diese Hackerangriffe könnten finanzielle und körperliche Schäden bis hin zum Tod von Fahrzeuginsassen und anderen Verkehrsteilnehmern verursachen. Hersteller von autonomen Fahrzeugen müssen sich daher der Gefahr von Hackerangriffen bewusst sein und Strategien entwickeln, diese zu verhindern. Frühere Untersuchungen zeigen, dass Hackerangriffe zu den gefürchtetsten Risiken autonomer Fahrzeuge zählen (Zmud & Sener, 2017).

Was die als BT klassifizierten Tweets betrifft, so gefiel vielen, dass durch den Einsatz autonomer Fahrzeuge Zeit eingespart werden könnte, z. B.: „*Sleepy time in the car for a in back seat. Wish I had a self driving car & I coulda joined em...*“ Die aktuell maximal auf SAE Stufe 2 automatisierten Fahrzeuge erlauben allerdings noch nicht, dass der Fahrer während der Fahrt schläft. Das hält aber viele nicht davon ab, diese Fahrzeuge wie autonome Fahrzeuge zu behandeln, indem sie beispielsweise den Fahrersitz verlassen, während sie auf einer öffentlichen Straße mit der Autopilot-Funktion eines Tesla Modells S fahren (Krok, 2015). Dabei riskieren sie ihr eigenes und das Leben anderer Verkehrsteilnehmer. Kommt es zu einem Unfall, beeinflusst dies möglicherweise unverhältnismäßig stark die Akzeptanz von autonomen Fahrzeugen. Die Hersteller autonomer Fahrzeuge sollten sich dennoch bewusst sein, dass es

den Wunsch gibt während der Fahrt mit einem autonomen Fahrzeug zu schlafen und dies durch einen entsprechend gestalteten Innenraum auch zu ermöglichen, wie mehrere Studien bestätigen (z. B. Cosh, Wordingham & Ramingwong, 2018). Bei Fahrerassistenzsystemen der SAE Stufe 2 muss dies jedoch erkannt und verhindert werden.

Im Allgemeinen sind die Menschen beeindruckt von der Innovationskraft der autonomen Fahrzeuge, z. B.: „[...] *That hyper-futuristic driverless Mercedes has been spotted in San Fran – again [...]*“. Die meisten BT spiegeln zudem die Begeisterung vieler wider, etwas Neues auszuprobieren, z. B.: „[...] *A perk of living near Google... We saw the self-driving car today on the highway!*“ Entwickler von autonomen Fahrzeugen haben erkannt, dass viele von dieser neuen Technologie und den damit verbundenen Vorteilen begeistert sind. Sie investieren daher in die Entwicklung autonomer Fahrzeuge und versprechen bereits Eigenschaften, die jedoch erst in einigen Jahren umgesetzt werden können. Wenn die Kommunikationsstrategien nicht angepasst werden, könnte die positive Begeisterung zu Missverständnissen und Fehlwahrnehmungen des potenziellen Nutzens autonomer Fahrzeuge führen, wie in den Studien 2 und 3 dieser Dissertation erläutert. Die Konzentration auf den Nutzen und sogar die Generierung übertriebener Nutzenwahrnehmungen könnte sich daher insgesamt eher negativ auf die öffentliche Akzeptanz autonomer Fahrzeuge auswirken (Nees, 2016).

8.5 Fazit

Durch die Analyse von 1.963.905 Tweets konnten wir zeigen, dass die Verwendung von maschinellem Lernen zur automatischen Klassifizierung von Beiträgen in sozialen Medien ein vielversprechender Ansatz ist, um Erkenntnisse für die Prognose der Akzeptanz von Innovationen zu erhalten. Auch wenn die Daten von Twitter für bestimmte Verzerrungen anfällig sind, stehen unsere Ergebnisse im Einklang mit früheren Untersuchungen (z. B. Fraedrich et al., 2016; Schoettle & Sivak, 2014).

Das in diesem Kapitel vorgestellte Verfahren hat Vorteile gegenüber anderen Forschungsmethoden. Durch die Verwendung maschineller Lernverfahren reduziert das vorgestellte Verfahren den Zeitaufwand der Kodierung im Rahmen einer quantitativen Inhaltsanalyse beträchtlich und ermöglicht so, die großen Datenmengen aus sozialen Medien für Forschungsvorhaben besser nutzbar zu machen. Die Genauigkeit der Klassifikation auf Basis des maschinellen Lernverfahrens SVM ist hoch und dürfte im Regelfall einer Klassifikation auf Basis von Schlüsselworten überlegen sein. Weiterhin folgen wir mit dem in diesem Kapitel vorgestellten Verfahren dem Aufruf mehrerer Forscher, der Akzeptanzforschung neue Impulse zu geben (Benbasat & Barki, 2007). Darüber hinaus ermöglicht das vorgestellte Verfahren die Messung der Auswirkungen bestimmter Ereignisse auf die öffentliche Wahrnehmung neuer Technologien. Die identifizierten Risiko- und Nutzenaspekte autonomer Fahrzeuge können in Akzeptanzmodelle für autonome Fahrzeuge integriert werden. In Studie 3 konnten wir auf umfangreiche aktuelle Forschungsergebnisse zum autonomen Fahren zurückgreifen, um Risiko- und Nutzenwahrnehmung zu operationalisieren. Mit dem in diesem Kapitel vorgestellten Verfahren konnten wir aber noch weitere Risiko- und Nutzenaspekte identifizieren, die womöglich zu besseren Ergebnissen in Studie 3 hätten führen können. Andere aufstrebende Technologien sind womöglich nicht so gut

erforscht. In diesem Fall könnte das vorgestellte Verfahren als Vorstudie dienen, um relevante Risiko- und Nutzenaspekte zu identifizieren.

Unsere Forschung hat mehrere Auswirkungen auf das Management neuer Technologien. Basierend auf unseren Ergebnissen haben wir festgestellt, dass die Stimme zukünftiger Kunden bereits früh im Entwicklungsprozess einer neuen Technologie berücksichtigt werden sollte. Selbst die objektiv beste Lösung oder überlegene Technologien können scheitern, wenn sie den Kunden nicht ansprechen. Daher ist ein aktives Management der Akzeptanz bereits während der Entwicklung einer neuen Technologie unerlässlich, um das Scheitern von Innovationen zu reduzieren.

Im Falle von autonomen Fahrzeugen müssen Unternehmen ihre Kommunikationsstrategien überdenken, um verzerrten Wahrnehmungen über Nutzen und Risiken von autonomen Fahrzeugen vorzubeugen, die bereits bei den Fahrzeugen mit SAE Stufe 2 Systemen auftreten. Eine Überschätzung des Nutzens kann zu einer missbräuchlichen Verwendung autonomer Fahrzeuge und zur Enttäuschung der Erstnutzer führen. Des Weiteren birgt es erhebliche Risiken bis hin zu tödlichen Unfällen. Eine Überschätzung der Risiken könnte zu Widerstand gegen autonome Fahrzeuge führen, bevor sie überhaupt allgemein verfügbar werden (Kleijnen, Lee & Wetzels, 2009; König & Neumayr, 2017).

Darüber hinaus sollten Hersteller autonomer Fahrzeuge sicherstellen, dass sie das volle Potenzial autonomer Fahrzeuge ausschöpfen, indem sie die in sozialen Medien diskutierten Vorteile, wie sie in dieser Studie beschrieben werden, umsetzen. Erste Feldstudien zeigen, dass die Akzeptanz von autonomen Fahrzeugen nach der Erprobung mit Prototypen steigt (Alessandrini, Holguin & Parent, 2011; Christie, Koymans, Chanard, Lasgouttes & Kaufmann, 2016; Madigan, Louw, Wilbrink, Schieben & Merat, 2017; Pendleton et al., 2015; Portouli et al., 2017). Erprobungsmöglichkeiten können zu einer geringeren Anfälligkeit für verzerrte Wahrnehmungen von autonomen Fahrzeugen führen. Daher sollten Prototypen frühzeitig öffentlich getestet werden können im Rahmen von Veranstaltungen der Hersteller, die Einrichtung zusätzlicher Modellregionen und Teststrecken sowie die Einrichtung von öffentlichen Erprobungszentren für autonome Fahrzeuge.

Des Weiteren haben wir festgestellt, dass das Design der Benutzeroberfläche eine wichtige Rolle für die nächste Generation von Fahrautomatisierungssystemen der Stufe 2 und 3 spielen wird, wie die Risikowahrnehmung des Intelligent Drive Systems von Daimler zeigt. Statt der erhöhten Sicherheit durch Systembeschränkungen nehmen die Anwender vor allem den Kontrollverlust wahr, der die Akzeptanz verringern kann.

Zukünftige Studien basierend auf den in diesem Kapitel vorgestellten Verfahren könnten neben SVM andere maschinelle Lernverfahren verwenden. Deep Learning Ansätze zeigen beispielsweise bei der Sentimentanalyse vielversprechende Ergebnisse (Huang et al., 2017). Wir erwarten jedoch keine wesentlichen Verbesserungen, da die Evaluation des Modells bereits eine vergleichsweise hohe Genauigkeit hat und SVM in der Regel zu den leistungsfähigsten maschinellen Lernverfahren für die Textklassifizierung gehört (Socher, Lin, Ng & Manning, 2011).

Ein Ansatz für weitere Forschungsvorhaben könnte eine Unterteilung von Risiken und Nutzen sein. Wie in Abschnitt 2.4.2 erläutert, bemisst sich die Risikowahrnehmung auf Basis der Schrecklichkeit der Gefahr, der Unbekanntheit der Gefahrenquelle und der Anzahl der exponierten Individuen (Jungermann & Slovic, 1993). Christoph Hohenberger, Spörrle & Welpé (2017) haben den Nutzen von autonomen Fahrzeugen in die Unterkategorien Ökonomie, Zeit und Sicherheit unterteilt. Unterkategorien bedeuten jedoch feinere Abstufungen zwischen den Klassen, die ein maschinelles Lernverfahren erkennen muss. Daraus resultiert eine Abwägung zwischen der Genauigkeit der Klassifikation und dem Erkenntnisgewinn durch die Unterkategorien. Zusätzlich zu den ohnehin vorhandenen Verzerrungen in den Daten aus sozialen Medien, könnten zu viele Fehlklassifikationen falsche Schlussfolgerungen begünstigen. Somit ist die Modellgüte stets kritisch zu evaluieren, bevor ein solches Verfahren angewendet werden kann.

Um eine detaillierte qualitative Analyse der Tweets nach der Klassifizierung zu unterstützen, könnten zukünftige Forschungsvorhaben Topic Modeling verwenden, das eine automatische Vorsortierung der Tweets ermöglicht (Debortoli, Müller, Junglas & Vom Brocke, 2016). Ein nächster Schritt könnte darin bestehen, andere soziale Medien wie Facebook, Reddit, Kommentarbereiche oder Blogs in die Analysen einzubeziehen. Dies würde es ermöglichen, Unterschiede in der Erklärung und Verbreitung von Wahrnehmungen zwischen verschiedenen sozialen Medien zu analysieren. Aufgrund des teilweise deutlich abweichenden Schreibstils und den technischen Zugriffsmöglichkeiten auf Beiträge müsste das vorgestellte Verfahren aber jeweils angepasst werden. Neben der Analyse von Meinungen, die schriftlich zum Ausdruck gebracht werden, kann VOC auch aus anderen Medien wie Sprachaufzeichnungen und Videos extrahiert werden. Brown (2017) beispielsweise verwendet YouTube-Videos zur Analyse von Erfahrungen zur Fahrzeugautomatisierung. Die Einbeziehung verschiedener Quellen kann zu einem breiteren Überblick über Meinungen und Wahrnehmungen führen und dazu beitragen, unser Verständnis für die verschiedenen Aspekte neuer Technologien zu verbessern, die für potenzielle Kunden und die Gesellschaft relevant sind.

9 Zusammenfassung

Im Rahmen dieser Dissertation haben wir vier Studien durchgeführt, um unsere drei forschungsleitenden Fragestellungen zur Prognose der Akzeptanz von Innovationen zu adressieren. Die vier Studien werden in den Kapiteln 5-8 im Detail beschrieben. In diesem Kapitel fassen wir die Ergebnisse der vier Studien zusammen und diskutieren sie im Kontext zueinander sowie in Bezug auf den theoretischen Hintergrund und die forschungsleitenden Fragestellungen.

Im folgenden Abschnitt 9.1 fassen wir zunächst die Studienergebnisse zusammen. Anschließend erläutern wir ausgehend vom theoretischen Hintergrund dieser Dissertation die Beiträge zu Theorie und Praxis in Abschnitt 9.2. In Abschnitt 9.3 weisen wir auf die Limitationen dieser Dissertation hin und zeigen weiteren Forschungsbedarf auf. Wir schließen dieses Kapitel mit einem Fazit in Abschnitt 9.4.

9.1 Zusammenfassung der Studien

Das empirische Fundament dieser Dissertation bilden vier Studien. In den Studien 1-3 haben wir insgesamt 547 Probanden mit strukturierten Fragebögen befragt. Studie 4 basiert auf Daten der Social Media Plattform Twitter, für die wir 1.963.905 Tweets untersucht haben.

Im Folgenden fassen wir, bezugnehmend auf die Forschungsfragen, noch einmal die Studienergebnisse dieser Dissertation zusammen. Die Studien 1-2 haben wir zur Untersuchung der ersten forschungsleitenden Fragestellung durchgeführt:

FF1: Wie kann die Akzeptanz von Innovationen mit Modellen der Technologieakzeptanz prognostiziert werden?

In Studie 1 mit 197 Umfrageteilnehmern haben wir ein Modell zur Prognose der Akzeptanz auf Basis von UTAUT erstellt und unsere Ergebnisse mit dem UTAUT Modell nach Venkatesh et al. (2003) verglichen. Anhand des von uns entwickelten Modells konnten wir die verhaltensbasierte Nutzungsintention deutlich besser erklären als das UTAUT Vergleichsmodell ($R^2 = 0,604$ gegenüber $R^2 = 0,449$). Das Modell zur Prognose der Akzeptanz von Innovationen enthält zwei neuen Konstrukte: Angst vor der Nutzung und Einstellung zur Nutzung. Beide Konstrukte üben einen signifikanten Einfluss auf die Nutzungsintention aus. Zudem nimmt die Einstellung zur Nutzung eine besondere Rolle ein. Es beeinflusst einerseits die Nutzungsintention direkt und andererseits wird es von allen anderen Konstrukten des Modells signifikant beeinflusst. Es mediiert somit die Effekte dieser Konstrukte auf die Nutzungsintention. Wir konnten zeigen, dass die Leistungs- und die Aufwandserwartung die Nutzungsintention bei neuen Technologien nur indirekt über die Nutzungseinstellung beeinflussen.

Studie 2 haben wir 180 Tage nach Studie 1 mit 154 Umfrageteilnehmern durchgeführt. Ziel dieser Studie war die Prognose der Akzeptanz autonomer Fahrzeuge mit dem UTAUT2 Modell nach Venkatesh et al. (2012). Das UTAUT2 Modell ist eine Weiterentwicklung des UTAUT

Modells mit einem Fokus auf den Consumer-Bereich. Wir konnten zeigen, dass wir mit diesem Modell zwar eine etwas höhere Erklärung der Nutzungsintention erreichen ($R^2 = 0,634$), die allerdings mit deutlichen Problemen bei Modellgüte und widersprüchlichen Ergebnissen einhergeht. So mussten wir beispielsweise drei der sieben UTAUT2 Hypothesen ablehnen, wodurch das Modell nicht mehr besonders aussagekräftig ist. Dennoch konnten wir mit dem Konstrukt der hedonischen Motivation ein vielversprechendes Konstrukt identifizieren, dessen Integration in das Modell zur Prognose der Akzeptanz von Innovationen in weiteren Studien geprüft werden sollte.

Auf Basis der ersten beiden Studien dieser Dissertation kommen wir zu dem Schluss, dass subjektive Aspekte wie die Einstellung zur Nutzung oder Meinungen in Form von sozialen Einflüssen im Wesentlichen die Akzeptanz von neuen Technologien determinieren. Objektivere Faktoren wie die Leistungserwartung und die Aufwandserwartung haben vor der Markteinführung einer Innovation nur einen geringen oder indirekten Effekt. Das Modell zur Prognose der Akzeptanz von Innovationen berücksichtigt dies und kann somit zur Prognose der Akzeptanz von neuen Technologien bereits vor deren Markteinführung verwendet werden.

Mit Studie 3 dieser Dissertation adressieren wir die zweite forschungsleitende Fragestellung:

FF2: Wie beeinflussen Risiko- und Nutzenwahrnehmungen die prognostizierte Akzeptanz von Innovationen vor deren Markteinführung?

Studie 3 haben wir 169 Tage nach Studie 2 mit 196 Umfrageteilnehmern durchgeführt. Grundlage für den Fragebogen ist das Modell der gesellschaftlichen Akzeptanz nach Siegrist (2000). Mit dieser Studie konnten wir detaillierte Einblicke in die Bewertung und Relevanz der Risiken und Nutzen autonomer Fahrzeuge erhalten. Als größten Vorteil autonomer Fahrzeuge sehen die Probanden der Studie die Verringerung von Verkehrsunfällen sowie zusätzliche Möglichkeiten, um die Fahrtzeit besser zu nutzen, wenn man nicht selbst fahren muss. Als größtes Risiko wird der Kontrollverlust bei autonomen Fahrzeugen betrachtet, gefolgt von dem Risiko für Unternehmen, dass sich die großen Investitionen in die Entwicklung autonomer Fahrzeuge nicht auszahlen könnten. Primär würden die Probanden die autonomen Fahrzeuge gerne im Stadtverkehr verwenden, also einer anspruchsvollen Fahrsituation. Weniger gefragt ist hingegen die Übergabe der Fahraufgabe auf Schnellstraßen. Individuen, die autonomen Fahrzeugen eher kritisch gegenüberstehen, könnte man überzeugen, wenn autonome Fahrzeuge weiterhin die Möglichkeit böten, selbst zu fahren. Neben diesen detaillierten Einsichten konnten wir allerdings auch zeigen, dass unsere Studie nur 26,2 % der Faktoren zur Erklärung der Risiko- und Nutzenwahrnehmung enthält. Da wir die Faktoren auf Basis aktueller Studien ausgewählt haben, deutet dies auf weiteren Forschungsbedarf hin, den wir mit Studie 4 dieser Dissertation adressieren.

Neben der Bewertung der Risiken und Nutzenpotentiale autonomer Fahrzeuge konnten wir auch zeigen, dass die Akzeptanz autonomer Fahrzeuge zum Zeitpunkt der Studiendurchführung mehr als doppelt so stark von den Nutzenwahrnehmungen beeinflusst wird als von der Risikowahrnehmung. Dies deutet auf möglicherweise übersteigerte Erwartungen gegenüber dieser Technologie hin. Nach der Markteinführung könnten übersteigerte Erwartungen zu

Akzeptanzproblemen führen, wenn sich herausstellt, dass diese Erwartungen nicht erfüllt werden können.

Aufgrund eines Unfalls mit einem Tesla Model S Autopiloten, der kurz vor Studie 3 bekannt wurde, konnten wir über die forschungsleitende Fragestellung hinaus noch weitere Erkenntnisse gewinnen. Ungefähr 70 % der Probanden hatten von dem Unfall gehört. Überraschend zeigte sich, dass sich der Unfall positiv auf Nutzenwahrnehmung und Akzeptanz auswirkte und die Risikowahrnehmung sich verringerte. Die Probanden ohne Unfallkenntnis bewerteten die verhaltensbasierte Nutzungsintention wie es durch die ersten beiden Studien zu erwarten war. Bei Probanden mit Unfallkenntnis hingegen stieg die Nutzungsintention signifikant um über 25 % im Vergleich zu Studie 2. Dies zeigt den starken Effekt, den Ereignisse auf die Akzeptanz von Innovationen ausüben können. Auch vor diesem Hintergrund zeigt sich die Relevanz des in Studie 4 entwickelten Verfahrens, mit dem wir solche Ereignisse detektieren können.

Mit Studie 4 dieser Dissertation adressieren wir die dritte forschungsleitende Fragestellung:

FF3: Wie können soziale Medien für die Prognose der Akzeptanz von Innovationen verwendet werden?

In Studie 4 haben wir ein Verfahren entwickelt, mit dem wir Beiträge aus der Social Media Plattform Twitter extrahieren und weitgehend automatisiert klassifizieren können. Durch die Analyse von 1.963.905 Tweets haben wir in einem Zeitraum von 599 Tagen den zeitlichen Verlauf der Risiko- und Nutzenwahrnehmung von autonomen Fahrzeugen verfolgt. Zudem konnten wir akzeptanzrelevante Ereignisse identifizieren und deren Effekt aufzeigen. Mit der Benefit Rate haben wir weiterhin eine Metrik für die Prognose der Akzeptanz entwickelt. Das neue Verfahren macht die große Anzahl von Beiträgen auf Twitter nutzbar für die Akzeptanzforschung und reduziert die Zeit für die manuelle Datenkodierung, wie beispielsweise bei einer klassischen qualitativen Inhaltsanalyse, beträchtlich.

In Bezug auf die FF3 können wir daher schließen, dass sich die Social Media Plattform Twitter zur Identifikation und Einschätzung von Risiken und Nutzen einer neuen Technologie eignet. In Verbindung mit FF2 schließen wir somit, dass soziale Medien einen Beitrag zur Prognose der Akzeptanz von Innovationen leisten können. Weiterhin konnten wir zeigen, dass sich die Benefit Rate im Bereich von Akzeptanzeinschätzungen autonomer Fahrzeuge aus vorherigen Studien befindet. Daraus folgen wir, dass sich die Benefit Rate als Proxy für die Prognose der Akzeptanz von Innovationen eignet.

9.2 Beiträge zu Theorie und Praxis

Das theoretische Fundament dieser Arbeit bilden die Forschungsgebiete zu Technologieakzeptanz, Diffusionstheorie, gesellschaftlicher Akzeptanz und Risikowahrnehmung. Im Folgenden fassen wir, bezugnehmend auf den theoretischen Hintergrund dieser Dissertation (Kapitel 2), die Beiträge zu Theorie und Praxis dieser Dissertation zusammen.

Die Technologieakzeptanz ist eines der zentralen Schwerpunkte der Wirtschaftsinformatik und beschäftigt sich mit Prognose und Erklärung der individuellen Akzeptanz eines Informationssystems (Abschnitt 2.2). Bei der Diffusionstheorie steht die Änderung der Akzeptanz im zeitlichen Verlauf im Vordergrund. Anhand von Charakteristiken einer Innovation wird der Prozess der Diffusion anhand einer Kategorisierung der Marktteilnehmer beschrieben (Abschnitt 2.3). Das Forschungsgebiet der gesellschaftlichen Akzeptanz betrachtet schließlich die Akzeptanz auf gesellschaftlicher Ebene. Zentrale Elemente für diese Betrachtung sind Risiko- und Nutzenwahrnehmung einer Innovation (Abschnitt 2.4).

Anhand der Literatur und bestehender Studien aus den Forschungsgebieten Technologieakzeptanz, Diffusionstheorie, gesellschaftlicher Akzeptanz und Risikowahrnehmung leiten wir in Kapitel 2 Schlussfolgerungen zur Prognose der Akzeptanz von Innovationen ab, die wir in Kapitel 4 empirisch untersuchen. Anhand der Forschung zur Technologieakzeptanz schlussfolgern wir in Abschnitt 2.2.5, dass die Leistungs- und Aufwandserwartung eine zentrale Rolle für die Prognose der Akzeptanz von Innovationen einnehmen werden. Dieser Zusammenhang gilt in der Technologieakzeptanzforschung als gesichert (Benbasat & Barki, 2007). In Studie 1 konnten wir jedoch zeigen, dass dies bei Technologien vor deren Markteinführung nur indirekt über die Einstellung zur Nutzung der Fall ist. Auch weitere Konstrukte der Akzeptanzmodelle TAM, UTAUT und UTAUT2 lassen sich nicht direkt für die Prognose der Akzeptanz von Innovationen verwenden.

Mit den Studien 1 und 2 dieser Dissertation zeigen wir, dass sich die Technologieakzeptanz von Innovationen anders verhält als die Technologieakzeptanz von bereits verfügbaren Technologien sowohl im beruflichen als auch im Consumer-Bereich. Wir erschließen dadurch einen neuen Kontext für die Technologieakzeptanzforschung und schaffen damit die Grundlage für weitere Forschungsvorhaben zur Prognose der Akzeptanz von Innovationen. Das in Studie 1 erstellte Modell zur Prognose der Akzeptanz von Innovationen bietet für diesen neuen Forschungskontext der Technologieakzeptanz einen gemeinsamen Ausgangspunkt. In Studie 2 identifizieren wir zudem einige Weiterentwicklungsmöglichkeiten des Modells zur Prognose der Akzeptanz von Innovationen anhand des UTAUT2 Modells, insbesondere mit dem Konstrukt der hedonischen Motivation.

Durch die Reflektion der Diffusionstheorie in Bezug auf autonome Fahrzeuge und dem aktuellen Stand der Technik schätzen wir die Diffusionsgeschwindigkeit autonomer Fahrzeuge in Abschnitt 2.3.5 ab. In Bezug auf die Charakteristiken von Innovationen deuten relative Vorteile und geringe Komplexität bei der Nutzung auf eine schnelle Diffusion autonomer Fahrzeuge hin. Mangelnde Kompatibilität, Erprobbarkeit und Beobachtbarkeit könnten sich hingegen als Hindernisse bei der Diffusion herausstellen. Soziale Medien könnten als Kommunikationskanal helfen, diese Hindernisse zu adressieren. Mit Studie 4 zeigen wir ein neues Verfahren, mit dem die Rolle von sozialen Medien bei der Diffusion von Innovationen untersucht werden kann. Weitere Studien nach der Markteinführung autonomer Fahrzeuge mit dem neuen Verfahren könnten den Effekt der Charakteristiken von Innovationen auf die Diffusionsgeschwindigkeit untersuchen, beispielsweise wenn die Erprobbarkeit und die Beobachtbarkeit autonomer Fahrzeuge zunehmen.

Anhand der Kategorisierung der Marktteilnehmer der Diffusionstheorie leiten wir ein mögliches Diffusionsszenario in Abschnitt 2.3.5 ab. Insbesondere die *frühen Übernehmer* sollten kurz nach der Markteinführung autonomer Fahrzeuge in die weitere Entwicklung mit einbezogen werden, damit diese ihre Erfahrungen und Empfehlung in deren sozialen Systemen einbringen. Insofern es zu keinen schwerwiegenden Beeinträchtigungen des Verkehrsflusses und der Verkehrssicherheit kommt, sollten sich autonome Fahrzeuge schnell verbreiten. Eine besondere Herausforderung stellt hierbei der zunehmende Mischverkehr dar. Durch Werbung, Freigabe der Bewegungsdaten und attraktive neue Geschäftsmodelle wie Freemium (Weking et al., 2020) kann anschließend auch die *späte Mehrheit* überzeugt werden, autonome Fahrzeuge zu nutzen. Zusätzlich wird auch der soziale Druck auf die *späte Mehrheit* zunehmen, wenn selbst zu fahren zunehmend als lästige Tätigkeit zur Erfüllung eines Mobilitätsbedürfnisses angesehen wird und es zu Unfällen mit menschlichen Fahrern kommt, die mit autonomen Fahrzeugen nicht passiert wären. Die Unfälle könnten schließlich den Druck der Gesellschaft auf den Gesetzgeber erhöhen, damit dieser es schrittweise verbietet, auf öffentlichen Straßen selbst zu fahren.

Das neue Verfahren zur Akzeptanzprognose in sozialen Medien aus Studie 4 kann den Diffusionsprozess begleiten und dabei helfen, Potentiale und Hindernisse zu erkennen. Die Verwendung von sozialen Medien ermöglicht es, die Einschätzung der *Innovatoren* und *frühen Übernehmer* einer Innovation zu untersuchen. Erkenntnisse aus der Anwendung des Verfahrens können direkt in den weiteren Entwicklungsprozess einfließen oder auch den Ausgangspunkt für einen Dialog mit einflussreichen Marktteilnehmern darstellen. Weiterhin können akzeptanzrelevante und somit auch diffusionsrelevante Ereignisse wie beispielsweise vieldiskutierte Unfälle mit dem neuen Verfahren detektiert werden. Somit bietet sich das Verfahren als Frühwarnsystem für Anbieter, Gesetzgeber und weitere Entscheidungsträger an, um zeitnah auf solche Ereignisse reagieren zu können und Widerstandsverhalten zu vermeiden. Das Verfahren könnte um Sentiment Analysen sowie Topic Modeling ergänzt werden, um ein umfangreicheres Bild der aktuellen Akzeptanzsituation bei Innovationen mit Daten aus sozialen Medien zu erhalten.

Im Forschungsgebiet der gesellschaftlichen Akzeptanz sind Risiko- und Nutzenwahrnehmung zentrale Einflussfaktoren für die Akzeptanz. Das Modell der gesellschaftlichen Akzeptanz von Siegrist (2000), das wir in Abschnitt 2.4.1 erläutern, beinhaltet diesen Zusammenhang. Entscheidend ist dabei, dass sich die Risiko- und Nutzenwahrnehmung oft von der objektiven Einschätzung durch Experten und Fakten unterscheidet. Individuen nutzen unbewusst Heuristiken, um Risiken schnell einzuschätzen und die kognitive Belastung bei Entscheidungen zu reduzieren (Kahneman & Tversky, 1979). Weiterhin ändert sich die Risikowahrnehmung und die Risikoneigung von Individuen durch die Resultate früherer Entscheidungen mit Risiko. Adams (1999, S. 9f) beschreibt das Abwägungsverhalten bei Entscheidungen mit Risiko als Risiko Thermostat. Die Risikowahrnehmung wirkt sich nicht nur auf die Akzeptanz, sondern auch auf Widerstandsverhalten aus. Dieses ist als zusätzliche Reaktion auf eine Technologie separat von der Akzeptanz zu betrachten. Beispielsweise gibt es sowohl widerstandsleistende Nutzer als auch unterstützende Nicht-Nutzer. Zur Bewertung von gesellschaftlicher Akzeptanz und zu erwartendem Widerstand ist daher eine Betrachtung der Risikowahrnehmung ebenfalls von zentraler Bedeutung.

Insbesondere bei der Markteinführung von Innovationen dürften Individuen aufgrund mangelnder eigener Erfahrungen anfällig für Fehleinschätzungen von Risiko und Nutzen der Innovation sein. Daher ist es wichtig, die Meinungen zu Risiko und Nutzen von Innovationen bereits in einer frühen Phase des Produktentwicklungsprozesses zu untersuchen, damit sich nicht falsche Einschätzungen verfestigen. Diese sind nur schwer richtigzustellen und oft bleiben auch im Nachhinein noch Zweifel zurück. Mit dem in Studie 4 vorgestellten Verfahren konnten wir bereits einige Fehleinschätzungen zu Risiko und Nutzen autonomer Fahrzeuge aufzeigen. Insbesondere der Nutzen aktueller Fahrerassistenzsysteme wird oft überschätzt, was fatale Folgen für Fahrer und Fahrzeuginsassen haben kann. Andererseits werden die durch Überschätzung aktueller Fahrerassistenzsysteme ausgelöste Unfälle intensiv diskutiert und womöglich der Technik zugeordnet anstatt dem Fehlverhalten der Fahrer. Daraus kann sich individuelles Misstrauen bis hin zu breitem gesellschaftlichem Widerstand entwickeln. Solche Unfälle müssen sowohl im Hinblick auf die individuellen Schicksale als auch im Hinblick auf gesellschaftliche Akzeptanz und Widerstand vermieden werden.

In dieser Dissertation verwenden wir einen multi-methodischen Ansatz zur Prognose der Akzeptanz von Innovationen am Beispiel autonomer Fahrzeuge. Zur Prognose der Akzeptanz von Innovationen verwenden wir zur Datenerhebung in den Studien 1-3 strukturierte Fragebögen und in Studie 4 ein eigens entwickeltes Verfahren basierend auf der Methode der quantitativen Inhaltsanalyse. Dadurch konnten wir die Prognose der Akzeptanz von Innovationen aus verschiedenen Perspektiven untersuchen und vermindern den Einfluss von Methodenverzerrung und Einheitsmethodenvarianz.

In der Praxis kann das Modell zur Prognose der Akzeptanz von Innovationen und das Verfahren zur Identifikation von Risiko und Nutzen einer neuen Technologie mit sozialen Medien zur frühen Akzeptanzmessung und -prognose in einer frühen Phase der Produktentwicklung verwendet werden. Dadurch ließe sich die Misserfolgsrate von Innovationen verringern und bisher ungenutzte Potentiale neuer Technologien könnten erkannt und genutzt werden. Dies ermöglicht die Erhöhung der für die Diffusion entscheidenden initialen Akzeptanz. Die Verwendung weiterer Forschungsmethoden, beispielsweise Fokusgruppen (Müller-Prothmann & Dörr, 2011), könnten zusätzliche interessante Einsichten gewähren.

Mit den Studien dieser Dissertation liefern wir Forschern und der Praxis empirische Erkenntnisse zu möglichen Akzeptanzhindernissen und Potentialen autonomer Fahrzeuge. Weiterhin leisten wir einen Beitrag zur Akzeptanzforschung, indem wir mit der Prognose der Akzeptanz von Innovationen einen neuen Forschungskontext für die Technologieakzeptanzforschung aufzeigen. Das Modell zur Prognose der Akzeptanz von Innovationen eignet sich als Ausgangspunkt für weitere Forschungsvorhaben in diesem neuen Forschungskontext.

9.3 Limitationen

Im Rahmen dieser Dissertation beschränken wir uns, wie in Abschnitt 2.1 erläutert, auf Produktinnovationen. Weitere Arten von Innovationen wie Dienstleistungsinnovationen und Verfahrensinnovationen sind nicht Gegenstand dieser Dissertation.

Die Ergebnisse der Studien dieser Dissertation basieren nicht auf repräsentativen Stichproben der Bevölkerung. Die Probanden der Studien 1-3 sind im Median 20 Jahre alt und somit jünger als der Bevölkerungsdurchschnitt. Auch Frauen sind mit einem Anteil von maximal 30,3 % (Studie 3) in allen drei Studien unterrepräsentiert. Zudem besitzen alle Probanden die Hochschulreife und sind somit überdurchschnittlich gebildet. Daher können keine für die Bevölkerung repräsentativen Aussagen abgeleitet werden. Aufgrund der ähnlichen Stichproben sind die Studien 1-3 aber gut miteinander vergleichbar. Zukünftige Studien mit dem Ziel repräsentative Erkenntnisse zu erhalten, können auf den Studien dieser Dissertation aufbauen, sollten dann aber Alter und Geschlecht als Moderationseffekte berücksichtigen.

Die Ergebnisse aus Studie 4 basieren auf Daten der Social-Media-Plattform Twitter. Die Gesamtheit der Twitter Nutzer ist nicht repräsentativ für die Bevölkerung. Weiterhin könnten im untersuchten Datensatz von Algorithmen verfasste Beiträge enthalten sein. Die Problematik solcher Algorithmen haben wir in Abschnitt 8.4 diskutiert. Da die Ergebnisse von Studie 4 allerdings im Bereich repräsentativer Studien liegen, vermuten wir nur eine geringe Beeinflussung. Durch die Untersuchung von 1.963.905 Tweets erhalten wir eine deutlich umfangreichere Stichprobe der Bevölkerung als in den Studien 1-3, was das empirische Fundament dieser Dissertation nochmals stärkt. Anknüpfend an Studie 4 könnten weitere Forschungsvorhaben zusätzliche Social-Media Plattformen und soziale Netzwerke zum autonomen Fahren und anderen Innovationen untersuchen.

Autonomes Fahren kann sowohl als inkrementelle Innovation bestehender fortschrittlicher Fahrerassistenzsysteme und bestehender Geschäftsmodelle wie Ridesharing als auch als disruptive Innovation der individuellen Mobilität betrachtet werden (Kohl et al., 2017; Schulz, Gewalt, Böhm & Krcmar, 2020). Bei disruptiven Innovationen könnte ein unüberlegter Einsatz von empirischen Methoden zu falschen Schlussfolgerungen führen, denn initial erfüllen disruptive Innovationen die Kundenwünsche oft schlechter als bestehende Produkte und bedienen eher Nischenmärkte (Bower & Christensen, 1995). Daher sollte man Kundenwünsche nicht unreflektiert übernehmen. Berühmt ist in diesem Kontext die folgende Aussage, die Henry Ford zugeschrieben wird: „*If I had asked people what they wanted, they would have said faster horses.*“ (Walsh, 2017) Dennoch sollte die Meinung der Gesellschaft nicht ignoriert werden, da sich dadurch erhebliche Widerstände aufbauen und die initiale Akzeptanz von Innovationen sehr gering sein könnte, was die Diffusion erheblich erschwert.

Im Rahmen dieser Dissertation untersuchen wir die Prognose der Akzeptanz von Innovationen nur anhand einer neuen Technologie: autonomen Fahrzeugen. Die untersuchte Technologie besitzt zwei Eigenschaften, welche die Untersuchung begünstigen. Einerseits existiert bereits ein intuitives Verständnis von autonomen Fahrzeugen in der Bevölkerung und die Technologie kann mit wenigen Sätzen für Laien verständlich beschrieben werden. Andererseits werden autonome Fahrzeuge bereits rege in der Öffentlichkeit und in sozialen Medien diskutiert. Für die Anwendung des Modells zur Prognose der Akzeptanz von Innovationen auf unbekanntere Technologien bedeutet dies, dass die Probanden vorab detailliert über die Technologie informiert werden müssen. Im Falle des in Kapitel 8 vorgestellten Verfahrens zur Akzeptanzprognose mit sozialen Medien muss gegebenenfalls auf andere Quellen als Twitter

zur Untersuchung einer in der Öffentlichkeit weitgehend unbekanntem Technologie zurückgegriffen werden.

9.4 Fazit

Autonome Fahrzeuge werden nicht unmittelbar die Straßen übernehmen. Wie bei disruptiven Innovationen werden autonome Fahrzeuge zunächst Nischenmärkte in Form von abgesperrten oder speziell ausgewiesenen Strecken unter kontrollierten Bedingungen bedienen. Die dabei gesammelten Erfahrungen und Telemetriedaten sowie technologische Fortschritte im Bereich der Algorithmen, Datenverarbeitungskapazitäten und Sensorik werden autonome Fahrzeuge immer weiter verbessern, bis diese schließlich die Fähigkeiten menschlicher Fahrer erreichen und übertreffen. Erst dann können die Fahrzeuge im öffentlichen Straßenverkehr gefahrlos eingesetzt werden.

Bis autonome Fahrzeuge den öffentlichen Straßenverkehr dominieren, könnte es noch mehrere Jahre oder sogar Jahrzehnte dauern, wenn von der bisherigen Diffusionsrate im Fahrzeugbereich ausgegangen wird. Allerdings ist die Erwartung, dass autonomes Fahren die Anzahl der Verkehrsunfälle drastisch reduziert, ein triftiger Grund für das Streben nach einer schnellen Diffusion. Die Teilnahme am öffentlichen Straßenverkehr ist eine der riskantesten Tätigkeiten im Alltag vieler Individuen. Weiterhin sind Fahrzeughersteller rechtlich verpflichtet, Fahrzeuge auf dem Stand der Technik zu produzieren. Aus ethischer und rechtlicher Sicht entsteht daher die Frage, ob die Nutzung autonomer Fahrzeuge im Ermessen der Verkehrsteilnehmer liegen darf oder vorgeschrieben werden müsste. Gesetzliche Vorgaben könnten die Diffusionsrate deutlich erhöhen, aber auch Widerstandsverhalten in der Bevölkerung auslösen in Form von provozierten Unfällen oder Sabotage.

Mit dem autonomen Fahren gehen auch größere gesellschaftliche Umwälzungen einher. Ein besserer Anschluss für strukturschwache Gebiete, Arbeiten im Auto und der Wegfall von Arbeitsplätzen für Berufsfahrer sind nur einige der Themen, die uns in Zukunft beschäftigen werden (z. B. Milakis, van Arem & van Wee, 2017). Der Ausblick auf solche weitreichenden Veränderungen mag für viele einschüchternd oder sogar beängstigend wirken. Dennoch sind durch die Einführung autonomer Fahrzeuge zahlreiche Vorteile zu erwarten, wie an mehreren Stellen dieser Dissertation erläutert. Die Einführung autonomer Fahrzeuge und eine schnelle Diffusion sollten daher nicht bereits im Vorfeld durch irreführende Kommunikation, unrealistische Prognosen, falschen Versprechungen und einer vorschnellen Einführung von immer fortschrittlicheren Fahrerassistenzsystemen gefährdet werden. Hersteller sollten die zahlreichen Möglichkeiten nutzen, um Kundenfeedback reflektiert in ihre Innovationsprozesse zu integrieren. Diese Empfehlung ist auch auf andere technologische Innovationen anwendbar und kann mit den in der vorliegenden Dissertation gezeigten Methoden unterstützt werden.

Literaturverzeichnis

- Abraham, R., Aier, S. & Winter, R. (2014). Fail Early, Fail Often: Towards Coherent Feedback Loops in Design Science Research Evaluation. *Proceedings of the 35th International Conference on Information Systems (ICIS 2014)*. Auckland, Neuseeland.
- Adams, D. A., Nelson, R. R. & Todd, P. A. (1992). Perceived Usefulness, Ease of Use, and Usage of Information Technology: A Replication. *MIS Quarterly*, 16(2), 227–247. <https://doi.org/10.2307/249577>
- Adams, J. (1995). *Risk*. London, Vereinigtes Königreich: Routeledge.
- Adams, J. (1999). *Risky Business*. London, Vereinigtes Königreich: Adam Smith Institute.
- Adell, E., Várhelyi, A. & Nilsson, L. (2014a). The Definition of Acceptance and Acceptability. In M.A. Regan, T. Horberry & A. Stevens (Hrsg.), *Driver Acceptance of New Technology* (S. 11–21). Surrey, Vereinigtes Königreich: Ashgate.
- Adell, E., Várhelyi, A. & Nilsson, L. (2014b). Modelling Acceptance of Driver Assistance Systems: Application of the Unified Theory of Acceptance and Use of technology. In M.A. Regan, T. Horberry & A. Stevens (Hrsg.), *Driver Acceptance of New Technology* (S. 23–34). Surrey, Vereinigtes Königreich: Ashgate.
- Albaum, G. (1997). The Likert Scale Revisited. *International Journal of Market Research*, 39(2), 1–21. <https://doi.org/10.1177/147078539703900202>
- Alessandrini, A., Holguin, C. & Parent, M. (2011). Advanced transport systems showcased in La Rochelle. *IEEE Conference on Intelligent Transportation Systems (ITSC), Proceedings* (S. 896–900). Washington, USA. <https://doi.org/10.1109/ITSC.2011.6082831>
- Alhakami, A. S. & Slovic, P. (1994). A Psychological Study of the Inverse Relationship Between Perceived Risk and Perceived Benefit. *Risk Analysis*, 14(6), 1085–1096. <https://doi.org/10.1111/j.1539-6924.1994.tb00080.x>
- Alvesson, M. & Kärreman, D. (2007). Constructing mystery: Empirical matters in theory development. *Academy of Management Review*, 32(4), 1265–1281. <https://doi.org/10.5465/AMR.2007.26586822>
- Ambadipudi, A., Heineke, K., Kampshoff, P. & Shao, E. (2017). Gauging the disruptive power of robo-taxis in autonomous driving. *McKinsey Center for Future Mobility*. Zugriff am 20.12.2019. Verfügbar unter: [https://www.mckinsey.com/~/media/McKinsey/Industries/Automotive and Assembly/Our Insights/Gauging the disruptive power of robo taxis in autonomous driving/Gauging-the-disruptive-power-of-robo-taxis-in-autonomous-driving.pdf](https://www.mckinsey.com/~/media/McKinsey/Industries/Automotive%20and%20Assembly/Our%20Insights/Gauging%20the%20disruptive%20power%20of%20robo%20taxis%20in%20autonomous%20driving/Gauging-the-disruptive-power-of-robo-taxis-in-autonomous-driving.pdf)
- Bagozzi, R. P., Yi, Y. & Phillips, L. W. (1991). Assessing Construct Validity in Organizational Research. *Administrative Science Quarterly*, 36(3), 421–458. <https://doi.org/10.2307/2393203>
- Bansal, P. & Kockelman, K. M. (2018). Are we ready to embrace connected and self-driving vehicles? A case study of Texans. *Transportation*, 45(2), 641–675.

<https://doi.org/10.1007/s11116-016-9745-z>

- Bansal, P., Kockelman, K. M. & Singh, A. (2016). Assessing public opinions of and interest in new vehicle technologies: An Austin perspective. *Transportation Research Part C: Emerging Technologies*, 67, 1–14. <https://doi.org/10.1016/j.trc.2016.01.019>
- Bartels, A., Meinecke, M.-M. & Steinmeyer, S. (2015). Fahrstreifenwechsellassistentz. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (3. Auflage, S. 959–974). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_50
- Bartels, A., Rohlfs, M., Hamel, S., Saust, F. & Klauske, L. K. (2015). Querführungsassistentz. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (3. Auflage, S. 937–957). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_49
- Bazilinsky, P., Kyriakidis, M. & de Winter, J. (2015). An International Crowdsourcing Study into People’s Statements on Fully Automated Driving. *Procedia Manufacturing*, 3, 2534–2542. <https://doi.org/10.1016/j.promfg.2015.07.540>
- Becker, F. & Axhausen, K. W. (2017). Literature review on surveys investigating the acceptance of automated vehicles. *Transportation*, 44(6), 1293–1306. <https://doi.org/10.1007/s11116-017-9808-9>
- Becker, J. (2019). Autonomes Fahren - Die Autohersteller haben das Tempo der digitalen Revolution unterschätzt. *Süddeutsche Zeitung*. Zugriff am 9.6.2019. Verfügbar unter: <https://www.sueddeutsche.de/auto/ces-autonomes-fahren-1.4278071>
- Benbasat, I. & Barki, H. (2007). Quo vadis TAM? *Journal of the Association for Information Systems*, 8(4), 211–218.
- Bender, E., Darms, M., Schorn, M., Stählin, U. & Isermann, R. (2007). Antikollisionssystem Proreta–Auf dem Weg zum unfallvermeidenden Fahrzeug. *ATZ - Automobiltechnische Zeitschrift*, 109(4), 337–341. <https://doi.org/10.1007/BF03221883>
- Best, R. J. (2012). *Market-Based Management: Strategies for Growing Customer Value and Profitability* (6. Auflage). Boston, USA: Pearson.
- Blake, E. R. (1995). Understanding outrage: How scientists can help bridge the risk perception gap. *Environmental Health Perspectives*, 103(Suppl 6), 123–125. <https://doi.org/10.2307/3432360>
- Boshmaf, Y., Muslukhov, I., Beznosov, K. & Ripeanu, M. (2011). The socialbot network. *Proceedings of the 27th Annual Computer Security Applications Conference (ACSAC)* (S. 93). New York, USA: ACM Press. <https://doi.org/10.1145/2076732.2076746>
- Bower, J. L. & Christensen, C. M. (1995). Disruptive Technologies: Catching the Wave. *Harvard Business Review*, 73(1), 43–53. [https://doi.org/10.1016/0024-6301\(95\)91075-1](https://doi.org/10.1016/0024-6301(95)91075-1)
- Brown, B. (2017). The Social Life of Autonomous Cars. *Computer*, 50(2), 92–96. <https://doi.org/10.1109/MC.2017.59>
- Brown, S. A. & Venkatesh, V. (2005). Model of Adoption of Technology in Households: A

- Baseline Model Test and Extension Incorporating Household Life Cycle. *MIS Quarterly*, 29(3), 399–426. <https://doi.org/10.2307/25148690>
- Butakov, V. & Ioannou, P. (2015). Driving Autopilot with Personalization Feature for Improved Safety and Comfort. *2015 IEEE 18th International Conference on Intelligent Transportation Systems* (S. 387–393). Las Palmas, Spanien. <https://doi.org/10.1109/ITSC.2015.72>
- Carlsson, C., Carlsson, J., Hyvonen, K., Puhakainen, J. & Walden, P. (2006). Adoption of Mobile Devices/Services - Searching for Answers with the UTAUT. *Proceedings of the 39th Annual Hawaii International Conference on System Sciences (HICSS)* (S. 132a). Kauai, USA. <https://doi.org/10.1109/HICSS.2006.38>
- Castellion, G. & Markham, S. K. (2013). Perspective: New Product Failure Rates: Influence of Argumentum ad Populum and Self-Interest. *Journal of Product Innovation Management*, 30(5), 976–979. <https://doi.org/10.1111/j.1540-5885.2012.01009.x>
- Cenfetelli, R. T. & Bassellier, G. (2009). Interpretation of Formative Measurement in Information Systems Research. *MIS Quarterly*, 33(4), 689–707. <https://doi.org/10.2307/20650323>
- Chang, C. & Lin, C. (2011). LIBSVM: A Library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2, 1–39. <https://doi.org/10.1145/1961189.1961199>
- Chin, W. W. (1998). The partial least squares approach for structural equation modeling. In G.A. Marcoulides (Hrsg.), *Methodology for business and management. Modern methods for business research* (S. 295–336). Lawrence Erlbaum Associates Publishers.
- Choi, J. K. & Ji, Y. G. (2015). Investigating the Importance of Trust on Adopting an Autonomous Vehicle. *International Journal of Human-Computer Interaction*, 31(10). <https://doi.org/10.1080/10447318.2015.1070549>
- Christie, D., Koymans, A., Chanard, T., Lasgouttes, J.-M. & Kaufmann, V. (2016). Pioneering Driverless Electric Vehicles in Europe: The City Automated Transport System (CATS). *Transportation Research Procedia*, 13, 30–39. <https://doi.org/10.1016/j.trpro.2016.05.004>
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* (2. Auflage). Hillsdale, USA: Lawrence Erlbaum Associates.
- Conover, G. D. (1994). The eleven commandments for IVHS. *Proceedings of VNIS'94 - 1994 Vehicle Navigation and Information Systems Conference* (S. 503–506). <https://doi.org/10.1109/VNIS.1994.396893>
- Cornescu, V. & Adam, C.-R. (2013). The Consumer Resistance Behavior towards Innovation. *Procedia Economics and Finance*, 6(13), 457–465. [https://doi.org/10.1016/S2212-5671\(13\)00163-9](https://doi.org/10.1016/S2212-5671(13)00163-9)
- Cosh, K., Wordingham, S. & Ramingwong, S. (2018). Investigating Public Opinion Regarding Autonomous Vehicles: A Perspective from Chiang Mai, Thailand. In K. Kim, H. Kim & N. Baek (Hrsg.), *Lecture Notes in Electrical Engineering* (Band 450, S. 3–10). Singapur,

- Singapur: Springer. https://doi.org/10.1007/978-981-10-6454-8_1
- Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*, *16*(3), 297–334. <https://doi.org/10.1007/BF02310555>
- Currall, S. C., King, E. B., Lane, N., Madera, J. & Turner, S. (2006). What drives public acceptance of nanotechnology? *Nature Nanotechnology*, *1*(3), 153–155. <https://doi.org/10.1038/nnano.2006.155>
- Cvetkovich, G. & Earle, T. (1995). *Social Trust: Toward a Cosmopolitan Society*. Westport, USA: Praeger.
- Davies, A. (2015). Obviously Drivers Are Already Abusing Tesla's Autopilot. *Wired*. Zugriff am 25.11.2015. Verfügbar unter: <http://www.wired.com/2015/10/obviously-drivers-are-already-abusing-teslas-autopilot/>
- Davis, F. D. (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *MIS Quarterly*, *13*(3), 319–340. <https://doi.org/10.2307/249008>
- Davis, F. D., Bagozzi, R. P. & Warshaw, P. R. (1989). User Acceptance of Computer Technology: A Comparison of Two Theoretical Models. *Management Science*, *35*(8), 982–1003.
- Davis, F. D. & Venkatesh, V. (2004). Toward Preprototype User Acceptance Testing of New Information Systems: Implications for Software Project Management. *IEEE Transactions on Engineering Management*, *51*(1), 31–46. <https://doi.org/10.1109/TEM.2003.822468>
- Debortoli, S., Müller, O., Junglas, I. & Vom Brocke, J. (2016). Text Mining For Information Systems Researchers: An Annotated Topic Modeling Tutorial. *Communications of the Association for Information Systems*, *39*, 110–135. <https://doi.org/10.17705/1CAIS.03907>
- Dodds, W. B., Monroe, K. B. & Grewal, D. (1991). Effects of Price, Brand, and Store Information on Buyers' Product Evaluations. *Journal of Marketing Research*, *28*(3), 307–319. <https://doi.org/10.1177/002224379102800305>
- Dörner, K., Schwertberger, W. & Hipp, E. (2015). Bahnführungsassistentz für Nutzfahrzeuge. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (3. Auflage, S. 1009–1027). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_53
- Drolet, A. L. & Morrison, D. G. (2001). Do We Really Need Multiple-Item Measures in Service Research? *Journal of Service Research*, *3*(3), 196–204. <https://doi.org/10.1177/109467050133001>
- Dwivedi, Y. K., Rana, N. P., Jeyaraj, A., Clement, M. & Williams, M. D. (2019). Re-examining the Unified Theory of Acceptance and Use of Technology (UTAUT): Towards a Revised Theoretical Model. *Information Systems Frontiers*, *21*(3), 719–734. <https://doi.org/10.1007/s10796-017-9774-y>
- Etherington, D. (2019). Waymo has now driven 10 billion autonomous miles in simulation. *TechCrunch*. Zugriff am 17.12.2019. Verfügbar unter: <https://techcrunch.com/2019/07/10/waymo-has-now-driven-10-billion-autonomous-miles-in-simulation/>

- Fagnant, D. J. & Kockelman, K. (2015). Preparing a nation for autonomous vehicles: opportunities, barriers and policy recommendations. *Transportation Research Part A: Policy and Practice*, 77, 167–181. <https://doi.org/10.1016/j.tra.2015.04.003>
- Feinerer, I., Hornik, K. & Meyer, D. (2008). Text Mining Infrastructure in R. *Journal of Statistical Software*, 25(5), 1–54. <https://doi.org/10.18637/jss.v025.i05>
- Feldman, R. (2013). Techniques and applications for sentiment analysis. *Communications of the ACM*, 56(4), 82. <https://doi.org/10.1145/2436256.2436274>
- Fenton, R. E. (1970). Automatic vehicle guidance and control—A state of the art survey. *IEEE Transactions on Vehicular Technology*, 19(1), 153–161. <https://doi.org/10.1109/T-VT.1970.23443>
- Fishbein, M. & Ajzen, I. (1975). *Belief, attitude, intention and behavior: an introduction to theory and research*. Reading, USA: Addison-Wesley.
- Fornell, C. (Hrsg.). (1982). *A Second Generation of Multivariate Analysis: Methods*. New York, USA: Praeger Publishers.
- Fornell, C. & Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39. <https://doi.org/10.2307/3151312>
- Foss, R. (1973). Personality, Social Influence and Cigarette Smoking. *Journal of Health and Social Behavior*, 14(3), 279. <https://doi.org/10.2307/2137120>
- Fraedrich, E., Beiker, S. & Lenz, B. (2015). Transition pathways to fully automated driving and its implications for the sociotechnical system of automobility. *European Journal of Futures Research*, 3(1), 11. <https://doi.org/10.1007/s40309-015-0067-8>
- Fraedrich, E., Cyganski, R., Wolf, I. & Lenz, B. (2016). User Perspectives on Autonomous Driving. *Arbeitsberichte 187*. Berlin: Geographisches Institut, Humboldt-Universität.
- Fraedrich, E. & Lenz, B. (2014). Automated Driving: Individual and Societal Aspects. *Transportation Research Record: Journal of the Transportation Research Board*, 2416(1), 64–72. <https://doi.org/10.3141/2416-08>
- Fraedrich, E. & Lenz, B. (2016). Taking a Drive, Hitching a Ride: Autonomous Driving and Car Usage. *Autonomous Driving* (S. 665–685). Berlin, Heidelberg: Springer. https://doi.org/10.1007/978-3-662-48847-8_31
- Frewer, L. J., Miles, S. & Marsh, R. (2002). The Media and Genetically Modified Foods: Evidence in Support of Social Amplification of Risk. *Risk Analysis*, 22(4), 701–711. <https://doi.org/10.1111/0272-4332.00062>
- Frewer, L. J., Scholderer, J. & Bredahl, L. (2003). Communicating about the Risks and Benefits of Genetically Modified Foods: The Mediating Role of Trust. *Risk Analysis*, 23(6), 1117–1133. <https://doi.org/10.1111/j.0272-4332.2003.00385.x>
- Füller, K. (2017). *Customer Integration 4.0: Leveraging Customer Knowledge in Innovation Processes by Using Digital Technologies*. Dissertation, Technische Universität München.

- Fung, B. (2015). People doing „crazy things“ with Tesla’s autopilot are spoiling it for everybody. *The Washington Post*. Zugriff am 2.11.2016. Verfügbar unter: <https://www.washingtonpost.com/news/the-switch/wp/2015/11/05/people-doing-crazy-things-with-teslas-autopilot-are-spoiling-it-for-everybody/>
- Gasser, T. M., Clemens, A., Mihiar, A., Arne, B., Jana, E., Frank, F. et al. (2015). *Rechtsfolgen zunehmender Fahrzeugautomatisierung. Berichte der Bundesanstalt für Straßenwesen, Fahrzeugtechnik, Heft F 83*.
- Gatignon, H. & Robertson, T. S. (1989). Technology Diffusion: An Empirical Test of Competitive Effects. *Journal of Marketing*, 53(1), 35. <https://doi.org/10.2307/1251523>
- Geisser, S. (1974). A predictive approach to the random effect model. *Biometrika*, 61(1), 101–107. <https://doi.org/10.1093/biomet/61.1.101>
- Goffart, K., Schermann, M., Kohl, C., Preißinger, J. & Kremer, H. (2016). Using the Default Option Bias to Influence Decision Making While Driving. *International Journal of Human-Computer Interaction*, 32(1), 39–50. <https://doi.org/10.1080/10447318.2015.1085747>
- Gogoll, J. & Müller, J. F. (2017). Autonomous Cars: In Favor of a Mandatory Ethics Setting. *Science and Engineering Ethics*, 23(3), 681–700. <https://doi.org/10.1007/s11948-016-9806-x>
- Gold, C., Dambock, D., Lorenz, L. & Bengler, K. (2013). „Take over!“ How long does it take to get the driver back into the loop? *Proceedings of the Human Factors and Ergonomics Society Annual Meeting* (Band 57, S. 1938–1942). <https://doi.org/10.1177/1541931213571433>
- Gold, C., Körber, M., Hohenberger, C., Lechner, D. & Bengler, K. (2015). Trust in Automation – Before and After the Experience of Take-over Scenarios in a Highly Automated Vehicle. *Proceedings of the 6th International Conference on Applied Human Factors and Ergonomics (AHFE 2015) and the Affiliated Conferences* (Band 3, S. 3025–3032). <https://doi.org/10.1016/j.promfg.2015.07.847>
- Green, P. E., Krieger, A. M. & Wind, Y. (2003). Thirty Years of Conjoint Analysis: Reflections and Prospects. *Interfaces*, 31(3-Supplement), 56–73. <https://doi.org/10.1287/inte.31.4.56.9676>
- Greis, F. (2019). Staupilot: Der Zulassungstau löst sich langsam auf. *Golem*. Zugriff am 17.12.2020. Verfügbar unter: <https://www.golem.de/news/staupilot-regierung-rechnet-fuer-mitte-2020-mit-automatisierten-autos-1912-145264.html>
- Griffin, A. & Hauser, J. R. (1993). The Voice of the Customer. *Marketing Science*, 12(1), 1–27. <https://doi.org/10.1287/mksc.12.1.1>
- Grunwald, A. (2016). Societal Risk Constellations for Autonomous Driving. Analysis, Historical Context and Assessment. In M. Maurer, J.C. Gerdes, B. Lenz & H. Winner (Hrsg.), *Autonomous Driving* (S. 641–663). Berlin, Heidelberg: Springer. https://doi.org/10.1007/978-3-662-48847-8_30
- de Guinea, A. O. & Markus, M. L. (2009). Why Break the Habit of a Lifetime? Rethinking the

- Roles of Intention, Habit, and Emotion in Continuing Information Technology Use. *MIS Quarterly*, 33(3), 433–444. <https://doi.org/10.2307/20650303>
- Gupta, N., Fischer, A. R. H. & Frewer, L. J. (2011). Socio-psychological determinants of public acceptance of technologies: A review. *Public Understanding of Science*, 21(7), 782–795. <https://doi.org/10.1177/0963662510392485>
- Gupta, N., Fischer, A. R. H. & Frewer, L. J. (2015). Ethics, Risk and Benefits Associated with Different Applications of Nanotechnology: a Comparison of Expert and Consumer Perceptions of Drivers of Societal Acceptance. *NanoEthics*, 9(2), 93–108. <https://doi.org/10.1007/s11569-015-0222-5>
- Haboucha, C. J., Ishaq, R. & Shiftan, Y. (2017). User preferences regarding autonomous vehicles. *Transportation Research Part C: Emerging Technologies*, 78, 37–49. <https://doi.org/10.1016/j.trc.2017.01.010>
- Hair, J. F., Hult, G. T. M., Ringle, C. M., Sarstedt, M., Richter, N. F. & Hauff, S. (2017). *Partial Least Squares Strukturgleichungsmodellierung*. München: Vahlen.
- Hair, J. F., Ringle, C. M. & Sarstedt, M. (2011). PLS-SEM: Indeed a Silver Bullet. *The Journal of Marketing Theory and Practice*, 19(2), 139–152. <https://doi.org/10.2753/MTP1069-6679190202>
- Hansen, S. (2017). Sie sind da! Hochautomatisierter A8. *c't*, 2017/20, 108–112.
- Haustein, S., Bowman, T. D., Holmberg, K., Tsou, A., Sugimoto, C. R. & Larivière, V. (2016). Tweets as impact indicators: Examining the implications of automated “bot” accounts on Twitter. *Journal of the Association for Information Science and Technology*, 67(1), 232–238. <https://doi.org/10.1002/asi.23456>
- Hayduk, L. A. & Littvay, L. (2012). Should researchers use single indicators, best indicators, or multiple indicators in structural equation models? *BMC Medical Research Methodology*, 12(159). <https://doi.org/10.1186/1471-2288-12-159>
- Heidenreich, S. & Kraemer, T. (2016). Innovations-Doomed to Fail? Investigating Strategies to Overcome Passive Innovation Resistance. *Journal of Product Innovation Management*, 33(3), 277–297. <https://doi.org/10.1111/jpim.12273>
- van der Heijden, H. (2004). User Acceptance of Hedonic Information Systems. *MIS Quarterly*, 28(4), 695–704. <https://doi.org/10.2307/25148660>
- Heinrichs, D. (2016). Autonomous Driving and Urban Land Use. *Autonomous Driving* (S. 213–231). Berlin, Heidelberg: Springer. https://doi.org/10.1007/978-3-662-48847-8_11
- Henseler, J., Ringle, C. M. & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115–135. <https://doi.org/10.1007/s11747-014-0403-8>
- Henseler, J., Ringle, C. M. & Sinkovics, R. R. (2009). The Use of Partial Least Squares Path Modeling in International Marketing. *Advances in International Marketing*, 20, 277–319. [https://doi.org/10.1108/S1474-7979\(2009\)0000020014](https://doi.org/10.1108/S1474-7979(2009)0000020014)
- Hilgendorf, E. (2018). Automatisiertes Fahren und Strafrecht - der „Aschaffenburg Fall“.

Deutsche Richterzeitung (DRiZ), 50(2), 66–69.

- Hohenberger, C., Spörrle, M. & Welp, I. M. (2017). Not fearless, but self-enhanced: The effects of anxiety on the willingness to use autonomous cars depend on individual levels of self-enhancement. *Technological Forecasting and Social Change*, 116, 40–52. <https://doi.org/10.1016/j.techfore.2016.11.011>
- Hopkins, D. J. & King, G. (2010). A Method of Automated Nonparametric Content Analysis for Social Science. *American Journal of Political Science*, 54(1), 229–247. <https://doi.org/10.1111/j.1540-5907.2009.00428.x>
- Hsu, C.-W., Chang, C.-C. & Lin, C.-J. (2016). A Practical Guide to Support Vector Classification. *National Taiwan University*. Zugriff am 25.10.2016. Verfügbar unter: <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf>
- Huang, Q., Chen, R., Zheng, X. & Dong, Z. (2017). Deep Sentiment Representation Based on CNN and LSTM. *International Conference on Green Informatics (ICGI)* (S. 30–33). <https://doi.org/10.1109/ICGI.2017.45>
- International Civil Aviation Organization. (2018). Safety Report. Zugriff am 22.6.2019. Verfügbar unter: https://www.icao.int/safety/Documents/ICAO_SR_2018_30082018.pdf
- Ives, B. & Olson, M. H. (1984). User Involvement and MIS Success: A Review of Research. *Management Science*, 30(5), 586–603. <https://doi.org/10.1287/mnsc.30.5.586>
- Iyengar, R., Van den Bulte, C. & Valente, T. W. (2011). Opinion Leadership and Social Contagion in New Product Diffusion. *Marketing Science*, 30(2), 195–212. <https://doi.org/10.1287/mksc.1100.0566>
- Jalonen, H. (2011). The uncertainty of innovation: a systematic review of the literature. *Journal of Management Research*, 4(1). <https://doi.org/10.5296/jmr.v4i1.1039>
- Jiang, Z., Scheibe, K. P., Nilakanta, S. & Qu, X. S. (2017). The Economics of Public Beta Testing. *Decision Sciences*, 48(1), 150–175. <https://doi.org/10.1111/deci.12221>
- Joachims, T. (1998). Text categorization with Support Vector Machines: Learning with many relevant features. In C. Nédellec & C. Rouveirol (Hrsg.), *Machine Learning: ECML-98* (Band 1398, S. 137–142). Berlin, Heidelberg: Springer. <https://doi.org/10.1007/BFb0026683>
- Joshi, K. (1991). A Model of Users' Perspective on Change: The Case of Information Systems Technology Implementation. *MIS Quarterly*, 15(2), 229–242. <https://doi.org/10.2307/249384>
- Jungermann, H. & Slovic, P. (1993). Die Psychologie der Kognition und Evaluation von Risiko. *Risiko und Gesellschaft* (S. 167–207). Wiesbaden: VS Verlag für Sozialwissenschaften. https://doi.org/10.1007/978-3-322-90741-7_7
- Kahneman, D. & Tversky, A. (1979). Prospect Theory: An Analysis of Decision under Risk. *Econometrica*, 47(2), 263–292. <https://doi.org/10.2307/1914185>
- Karnowski, V. (2013). Diffusionstheorie. In W. Schweiger & A. Fahr (Hrsg.), *Handbuch Medienwirkungsforschung* (S. 513–528). Wiesbaden: Springer VS.

https://doi.org/10.1007/978-3-531-18967-3_27

- Kasperson, R. E. & Kasperson, J. X. (1996). The Social Amplification and Attenuation of Risk. *The Annals of the American Academy of Political and Social Science*, 545(1), 95–105. <https://doi.org/10.1177/0002716296545001010>
- Kasperson, R. E., Renn, O., Slovic, P., Brown, H. S., Emel, J., Goble, R. et al. (1988). The Social Amplification of Risk: A Conceptual Framework. *Risk Analysis*, 8(2), 177–187. <https://doi.org/10.1111/j.1539-6924.1988.tb01168.x>
- Katzwinkel, R., Brosig, S., Schroven, F., Auer, R., Rohlf, M., Eckert, G. et al. (2015). Einparkassistent. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (3. Auflage, S. 841–850). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_45
- Kauer, M., Franz, B., Schreiber, M., Bruder, R. & Geyer, S. (2012). User acceptance of cooperative maneuverbased driving - A summary of three studies. *Work*, 41(SUPPL.1), 4258–4264. <https://doi.org/10.3233/WOR-2012-0720-4258>
- Kim, S. S. & Malhotra, N. K. (2005). A Longitudinal Model of Continued IS Use: An Integrative View of Four Mechanisms Underlying Postadoption Phenomena. *Management Science*, 51(5), 741–755. <https://doi.org/10.1287/mnsc.1040.0326>
- Kim, S. S., Malhotra, N. K. & Narasimhan, S. (2005). Research Note—Two Competing Perspectives on Automatic Use: A Theoretical and Empirical Comparison. *Information Systems Research*, 16(4), 418–432. <https://doi.org/10.1287/isre.1050.0070>
- Kleijnen, M., Lee, N. & Wetzels, M. (2009). An exploration of consumer resistance to innovation and its antecedents. *Journal of Economic Psychology*, 30(3), 344–357. <https://doi.org/10.1016/j.joep.2009.02.004>
- Kling, R. (1980). Social Analyses of Computing: Theoretical Perspectives in Recent Empirical Research. *ACM Computing Surveys*, 12(1), 61–110. <https://doi.org/10.1145/356802.356806>
- Knigge, M., Kohl, C., Baader, G., Kienegger, H. & Krcmar, H. (2016a). Sentiment Analysis on Twitter Data Using R Algorithms. In C. Meinel, A. Polze, G. Oswald, R. Strotmann, U. Seibold & B. Schulzki (Hrsg.), *HPI Future SOC Lab: Proceedings 2016* (S. 5–9). Potsdam: Hasso-Plattner-Institut. Verfügbar unter: https://publishup.uni-potsdam.de/opus4-ubp/frontdoor/deliver/index/docId/40678/file/tbhpi_future_soc2016.pdf
- Knigge, M., Kohl, C., Baader, G., Kienegger, H. & Krcmar, H. (2016b). Sentiment Analysis on Twitter Data Using Entity and Fact Extraction. In C. Meinel, A. Polze, G. Oswald, R. Strotmann, U. Seibold & B. Schulzki (Hrsg.), *HPI Future SOC Lab: Proceedings 2016* (S. 139–143). Potsdam: Hasso-Plattner-Institut. Verfügbar unter: https://publishup.uni-potsdam.de/opus4-ubp/frontdoor/deliver/index/docId/40678/file/tbhpi_future_soc2016.pdf
- Kohavi, R. (1995). A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. *International Joint Conference on Artificial Intelligence*, 14(12), 1137–1143. <https://doi.org/10.1067/mod.2000.109031>

- Kohl, C., Knigge, M., Baader, G., Böhm, M. & Krcmar, H. (2018). Anticipating acceptance of emerging technologies using twitter: the case of self-driving cars. *Journal of Business Economics*, 88(5), 617–642. <https://doi.org/10.1007/s11573-018-0897-5>
- Kohl, C., Mostafa, D., Böhm, M. & Krcmar, H. (2017). Disruption of Individual Mobility Ahead? A Longitudinal Study of Risk and Benefit Perceptions of Self-Driving Cars on Twitter. In J.M. Leimeister & W. Brenner (Hrsg.), *Proceedings der 13. Internationalen Tagung Wirtschaftsinformatik (WI 2017)* (S. 1220–1234). St. Gallen, Schweiz. Verfügbar unter: <https://wi2017.ch/images/wi2017-0382.pdf>
- Kohl, C., Schermann, M. & Krcmar, H. (2016). The Effect of System Restrictions on Acceptance of Self-Driving Cars. *DIGIT 2016 Proceedings*. Verfügbar unter: <https://aisel.aisnet.org/digit2016/14/>
- Kollmann, T. (2004). Attitude, adoption or acceptance? Measuring the market success of telecommunication and multimedia technology. *International Journal of Business Performance Management*, 6(2), 133–152. <https://doi.org/10.1504/IJBPM.2004.005012>
- König, M. & Neumayr, L. (2017). Users' resistance towards radical innovations: The case of the self-driving car. *Transportation Research Part F: Traffic Psychology and Behaviour*, 44, 42–52. <https://doi.org/10.1016/j.trf.2016.10.013>
- Körber, M., Gold, C., Lechner, D. & Bengler, K. (2016). The influence of age on the take-over of vehicle control in highly automated driving. *Transportation Research Part F: Traffic Psychology and Behaviour*, 39, 19–32. <https://doi.org/10.1016/j.trf.2016.03.002>
- Kranz, M., Roalter, L. & Michahelles, F. (2010). Things that twitter: social networks and the internet of things. *What can the Internet of Things do for the Citizen (CIoT) Workshop at The Eighth International Conference on Pervasive Computing (Pervasive 2010)*. Helsinki, Finnland.
- Kraus, S., Althoff, M., Heißing, B. & Buss, M. (2009). Cognition and emotion in autonomous cars. *IEEE Intelligent Vehicles Symposium, Proceedings* (S. 635–640). <https://doi.org/10.1109/IVS.2009.5164351>
- Krcmar, H. (2015). *Informationsmanagement* (6. Auflage). Berlin, Heidelberg: Springer.
- Krieger-Lamina, J. (2016). *Vernetzte Automobile*. Wien, Österreich: Institut für Technikfolgen-Abschätzung der Österreichischen Akademie der Wissenschaften. Zugriff am 10.6.2019. Verfügbar unter: <http://epub.oeaw.ac.at/ita/ita-projektberichte/2016-02.pdf>
- Krok, A. (2015). This is the stupidest misuse of Tesla's Autopilot yet. Zugriff am 25.11.2015. Verfügbar unter: <http://www.cnet.com/news/this-is-the-stupidest-misuse-of-teslas-autopilot-yet/>
- Kuderer, M., Gulati, S. & Burgard, W. (2015). Learning driving styles for autonomous vehicles from demonstration. *2015 IEEE International Conference on Robotics and Automation (ICRA)* (S. 2641–2646). Seattle, USA. <https://doi.org/10.1109/ICRA.2015.7139555>
- Kuhn, M. (2008). Building Predictive Models in R Using the caret Package. *Journal Of Statistical Software*, 28(5), 1–26. <https://doi.org/10.1053/j.sodo.2009.03.002>
- Kyriakidis, M., Happee, R. & de Winter, J. C. F. (2015). Public opinion on automated driving:

- Results of an international questionnaire among 5000 respondents. *Transportation Research Part F: Traffic Psychology and Behaviour*, 32, 127–140. <https://doi.org/10.1016/j.trf.2015.04.014>
- Kyriakidis, M., de Winter, J. C. F., Stanton, N., Bellet, T., van Arem, B., Brookhuis, K. et al. (2019). A human factors perspective on automated driving. *Theoretical Issues in Ergonomics Science*, 20(3), 223–249. <https://doi.org/10.1080/1463922X.2017.1293187>
- Langer, I., Abendroth, B. & Bruder, R. (2015). Fahrerzustandserkennung. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (3. Auflage, S. 687–699). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_38
- Lapointe, L. & Rivard, S. (2005). A Multilevel Model of Resistance to Information Technology Implementation. *MIS Quarterly*, 29(3), 461–491. <https://doi.org/10.2307/25148692>
- Lee, E.-K., Gerla, M., Pau, G., Lee, U. & Lim, J.-H. (2016). Internet of Vehicles: From intelligent grid to autonomous cars and vehicular fogs. *International Journal of Distributed Sensor Networks*, 12(9), 241–246. <https://doi.org/10.1177/1550147716665500>
- Lee, Y., Kozar, K. A. & Larsen, K. R. T. (2003). The Technology Acceptance Model: Past, Present, and Future. *Communications of the Association for Information Systems*, 12(1), 752–780. <https://doi.org/10.17705/1CAIS.01250>
- Lekach, S. (2018). BMW's new smartphone car key means you better not lose your phone. *Mashable*. Zugriff am 12.10.2019. Verfügbar unter: <https://mashable.com/2018/02/26/bmw-digital-key-smartphones>
- Lenz, B. & Fraedrich, E. (2015). Gesellschaftliche und individuelle Akzeptanz des autonomen Fahrens. In M. Maurer, J.C. Gerdes, B. Lenz & H. Winner (Hrsg.), *Autonomes Fahren* (S. 639–660). Berlin, Heidelberg: Springer Vieweg. https://doi.org/10.1007/978-3-662-45854-9_29
- Limayem, M., Hirt, S. G. & Cheung, C. M. K. (2007). How Habit Limits the Predictive Power of Intention: The Case of Information Systems Continuance. *MIS Quarterly*, 31(4), 705–737. <https://doi.org/10.2307/25148817>
- Lüke, S., Fochler, O., Schaller, T. & Regensburger, U. (2015). Stauassistentz und -automation. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (3. Auflage, S. 995–1007). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_52
- Madden, T. J., Ellen, P. S. & Ajzen, I. (1992). A Comparison of the Theory of Planned Behavior and the Theory of Reasoned Action. *Personality and Social Psychology Bulletin*, 18(1), 3–9. <https://doi.org/10.1177/0146167292181001>
- Madigan, R., Louw, T., Wilbrink, M., Schieben, A. & Merat, N. (2017). What influences the decision to use automated public transport? Using UTAUT to understand public acceptance of automated road transport systems. *Transportation Research Part F: Traffic Psychology and Behaviour*, 50, 55–64. <https://doi.org/10.1016/j.trf.2017.07.007>
- Mankiw, N. G. & Taylor, M. P. (2012). *Grundzüge der Volkswirtschaftslehre* (5. Auflage).

Stuttgart: Schäffer-Poeschel.

- Marakas, G. & Hornik, S. (1996). Passive resistance misuse: overt support and covert recalcitrance in IS implementation. *European Journal of Information Systems*, 5(3), 208–219. <https://doi.org/10.1057/ejis.1996.26>
- Markus, M. L. (1983). Power, politics, and MIS implementation. *Communications of the ACM*, 26(6), 430–444. <https://doi.org/10.1145/358141.358148>
- Markwalter, B. (2015). The Path to Driverless Cars. *IEEE Consumer Electronics Magazine*, 6(2), 125–126. <https://doi.org/10.1109/MCE.2016.2640625>
- Martinko, M. J., Zmud, R. W. & Henry, J. W. (1996). An attributional explanation of individual resistance to the introduction of information technologies in the workplace. *Behaviour & Information Technology*, 15(5), 313–330. <https://doi.org/10.1080/014492996120085a>
- Martins, C., Oliveira, T. & Popovič, A. (2014). Understanding the Internet banking adoption: A unified theory of acceptance and use of technology and perceived risk application. *International Journal of Information Management*, 34(1), 1–13. <https://doi.org/10.1016/j.ijinfomgt.2013.06.002>
- Matthaei, R., Reschka, A., Rieken, J., Dierkes, F., Ulbrich, S., Winkle, T. et al. (2015). Autonomes Fahren. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (3. Auflage, S. 1139–1165). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_61
- Maurer, M. (2000). *Flexible Automatisierung von Strassenfahrzeugen mit Rechnersehen*. Dissertation, Universität der Bundeswehr München.
- Maurer, M., Gerdes, J. C., Lenz, B. & Winner, H. (Hrsg.). (2015). *Autonomes Fahren: Technische, rechtliche und gesellschaftliche Aspekte*. Berlin, Heidelberg: Springer Vieweg. <https://doi.org/10.1007/978-3-662-45854-9>
- McCorkindale, T. (2010). Can you see the writing on my wall? A content analysis of the Fortune 50's Facebook social networking sites. *Public Relations Journal*, 4(3), 1–14. <https://doi.org/10.1017/CBO9781107415324.004>
- Medhat, W., Hassan, A. & Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams Engineering Journal*, 5(4), 1093–1113. <https://doi.org/10.1016/j.asej.2014.04.011>
- Milakis, D., van Arem, B. & van Wee, B. (2017). Policy and society related implications of automated driving: A review of literature and directions for future research. *Journal of Intelligent Transportation Systems*, 21(4), 324–348. <https://doi.org/10.1080/15472450.2017.1291351>
- Montaguti, E., Kuester, S. & Robertson, T. S. (2002). Entry strategy for radical product innovations: A conceptual model and propositional inventory. *International Journal of Research in Marketing*, 19(1), 21–42. [https://doi.org/10.1016/S0167-8116\(02\)00046-0](https://doi.org/10.1016/S0167-8116(02)00046-0)
- Mou, Y. & Lin, C. A. (2014). Communicating Food Safety via the Social Media: The Role of Knowledge and Emotions on Risk Perception and Prevention. *Science Communication*, 36(5), 593–616. <https://doi.org/10.1177/1075547014549480>

- Müller-Prothmann, T. & Dörr, N. (2011). *Innovationsmanagement*. (G.F. Kamiske, Hrsg.) (4. Auflage). München: Hanser.
- Nees, M. A. (2016). Acceptance of Self-driving Cars. *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 60(1), 1449–1453. <https://doi.org/10.1177/1541931213601332>
- Neuendorf, K. (2016). *The content analysis guidebook* (2. Auflage). London, Vereinigtes Königreich: SAGE Publications.
- Neugebauer, R. (Hrsg.). (2018). *Digitalisierung*. Berlin, Heidelberg: Springer Vieweg. <https://doi.org/10.1007/978-3-662-55890-4>
- NHTSA. (2013). Preliminary Statement of Policy Concerning Automated Vehicles. Washington, DC. Zugriff am 1.9.2016. Verfügbar unter: https://www.nhtsa.gov/staticfiles/rulemaking/pdf/Automated_Vehicles_Policy.pdf
- Niculescu, A. I., Dix, A. & Yeo, K. H. (2017). Are You Ready for a Drive? *Proceedings of the 2017 CHI Conference Extended Abstracts on Human Factors in Computing Systems - CHI EA '17* (S. 2810–2817, Part F1276). New York, USA: ACM Press. <https://doi.org/10.1145/3027063.3053182>
- Norman, G. (2010). Likert scales, levels of measurement and the “laws” of statistics. *Advances in Health Sciences Education*, 15(5), 625–632. <https://doi.org/10.1007/s10459-010-9222-y>
- O'Donnell, J. (2013). Self-driving cars could have long road to acceptance. *USA Today*. Zugriff am 1.8.2016. Verfügbar unter: <http://www.usatoday.com/story/money/cars/2013/06/13/autonomous-vehicles-audi-google-drivers-crashes/2415909/>
- van Offenbeek, M., Boonstra, A. & Seo, D. (2012). Towards integrating acceptance and resistance research: evidence from a telecare case study. *European Journal of Information Systems*, 22(4), 434–454. <https://doi.org/10.1057/ejis.2012.29>
- Okazaki, S., Diaz-Martin, A. M., Rozano, M. & Menendez-Benito, H. (2014). How to mine brand Tweets: Procedural guidelines and pretest. *International Journal of Market Research*, 56(4), 467–489. <https://doi.org/10.2501/IJMR-2014-008>
- Olson, E. L. (2017). Will songs be written about autonomous cars? The implications of self-driving vehicle technology on consumer brand equity and relationships. *International Journal of Technology Marketing*, 12(1), 23. <https://doi.org/10.1504/IJTMKT.2017.081506>
- Pak, A. & Paroubek, P. (2010). Twitter as a Corpus for Sentiment Analysis and Opinion Mining. *Proceedings of the Seventh International Conference on Language Resources and Evaluation (LREC'10)* (S. 1320–1326). Valletta, Malta: European Language Resources Association (ELRA).
- Pang, B. & Lee, L. (2008). Opinion Mining and Sentiment Analysis. *Foundations and Trends in Information Retrieval*, 2(1–2), 1–135. <https://doi.org/10.1561/1500000011>
- Pang, B., Lee, L. & Vaithyanathan, S. (2002). Thumbs up? Sentiment Classification using

- Machine Learning Techniques. *Proceedings of the ACL-02 Conference on Empirical Methods in Natural Language Processing - EMNLP '02* (Band 10, S. 79–86). <https://doi.org/10.3115/1118693.1118704>
- Pavone, M. (2016). Autonomous Mobility-on-Demand Systems for Future Urban Mobility. *Autonomous Driving* (S. 387–404). Berlin, Heidelberg: Springer Vieweg. https://doi.org/10.1007/978-3-662-48847-8_19
- Payre, W., Cestac, J. & Delhomme, P. (2014). Intention to use a fully automated car: Attitudes and a priori acceptability. *Transportation Research Part F: Traffic Psychology and Behaviour*, 27, 252–263. <https://doi.org/10.1016/j.trf.2014.04.009>
- Pendleton, S., Uthaicharoenpong, T., Chong, Z. J., Guo Ming James Fu, Qin, B., Wei Liu et al. (2015). Autonomous golf cars for public trial of mobility-on-demand service. *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (S. 1164–1171). <https://doi.org/10.1109/IROS.2015.7353517>
- Pettersson, I. & Karlsson, I. C. M. (2015). Setting the stage for autonomous cars: A pilot study of future autonomous driving experiences. *IET Intelligent Transport Systems*, 9(7), 694–701. <https://doi.org/10.1049/iet-its.2014.0168>
- Piao, J., McDonald, M., Hounsell, N., Graindorge, M., Graindorge, T. & Malhene, N. (2016). Public Views towards Implementation of Automated Vehicles in Urban Areas. *Transportation Research Procedia*, 14, 2168–2177. <https://doi.org/10.1016/j.trpro.2016.05.232>
- Pomerleau, D. & Jochem, T. (1996). Rapidly adapting machine vision for automated vehicle steering. *IEEE Expert*, 11(2), 19–27. <https://doi.org/10.1109/64.491277>
- Porter, M. F. (2001). Snowball: A language for stemming algorithms. Zugriff am 14.2.2015. Verfügbar unter: <http://snowball.tartarus.org/texts/introduction.html>
- Portouli, E., Karaseitanidis, G., Lytrivis, P., Amditis, A., Raptis, O. & Karaberi, C. (2017). Public attitudes towards autonomous mini buses operating in real conditions in a Hellenic city. *2017 IEEE Intelligent Vehicles Symposium (IV)* (S. 571–576). <https://doi.org/10.1109/IVS.2017.7995779>
- Rajasekhar, M. V & Jaswal, A. K. (2015). Autonomous vehicles: The future of automobiles. *2015 IEEE International Transportation Electrification Conference (ITEC)* (S. 1–6). <https://doi.org/10.1109/ITEC-India.2015.7386874>
- Ram, S. (1989). Successful innovation using strategies to reduce consumer resistance An empirical test. *Journal of Product Innovation Management*, 6(1), 20–34. [https://doi.org/10.1016/0737-6782\(89\)90011-8](https://doi.org/10.1016/0737-6782(89)90011-8)
- Reek, F. (2016). Immer grüne Welle für Audi-Fahrer. *Süddeutsche Zeitung*. Zugriff am 20.12.2017. Verfügbar unter: <http://www.sueddeutsche.de/auto/vernetztes-fahren-immer-gruene-welle-fuer-audi-fahrer-1.3125611>
- Regan, M. A., Horberry, T. & Stevens, A. (2014). Driver Acceptance of New Technology: Overview. In M.A. Regan, T. Horberry & A. Stevens (Hrsg.), *Driver Acceptance of New Technology* (S. 3–8). Surrey, Vereinigtes Königreich: Ashgate.

- Renn, O., Burns, W. J., Kasperson, J. X., Kasperson, R. E. & Slovic, P. (1992). The Social Amplification of Risk: Theoretical Foundations and Empirical Applications. *Journal of Social Issues*, 48(4), 137–160. <https://doi.org/10.1111/j.1540-4560.1992.tb01949.x>
- Reschka, A., Rieken, J. & Maurer, M. (2015). Entwicklungsprozess von Kollisionsschutzsystemen für Frontkollisionen: Systeme zur Warnung, zur Unfallschwereminderung und zur Verhinderung. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (3. Auflage, S. 913–935). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_48
- Rese, A., Sänn, A. & Homfeldt, F. (2015). Customer integration and voice-of-customer methods in the German automotive industry. *International Journal of Automotive Technology and Management*, 15(1), 1–19. <https://doi.org/10.1504/IJATM.2015.067089>
- Riedl, C., Bjelland, J., Canright, G., Iqbal, A., Engø-Monsen, K., Qureshi, T. et al. (2018). Product diffusion through on-demand information-seeking behaviour. *Journal of The Royal Society Interface*, 15(139), 1–8. <https://doi.org/10.1098/rsif.2017.0751>
- Riedl, C., Köbler, F., Goswami, S. & Krcmar, H. (2013). Tweeting to Feel Connected: A Model for Social Connectedness in Online Social Networks. *International Journal of Human-Computer Interaction*, 29(10), 670–687. <https://doi.org/10.1080/10447318.2013.768137>
- Rigdon, E. E. (2012). Rethinking Partial Least Squares Path Modeling: In Praise of Simple Methods. *Long Range Planning*, 45(5–6), 341–358. <https://doi.org/10.1016/j.lrp.2012.09.010>
- Ringle, C. M., Wende, S. & Becker, J.-M. (2015). SmartPLS 3. Verfügbar unter: <http://www.smartpls.com>
- Rödel, C., Stadler, S., Meschtscherjakov, A. & Tscheligi, M. (2014). Towards Autonomous Cars: The Effect of Autonomy Levels on Acceptance and User Experience. *AutomotiveUI '14: Proceedings of the 6th International Conference on Automotive User Interfaces and Interactive Vehicular Applications* (S. 1–8). <https://doi.org/10.1145/2667317.2667330>
- Rogers, E. M. (2003). *Diffusion of innovations* (5. Auflage). New York, USA: Free Press.
- Rönkkö, M. (2019). matrixpls: Matrix-based Partial Least Squares Estimation. *R package*. Zugriff am 12.7.2019. Verfügbar unter: <https://github.com/mronkko/matrixpls>
- Rossiter, J. R. (2002). The C-OAR-SE procedure for scale development in marketing. *International Journal of Research in Marketing*, 19(4), 305–335. [https://doi.org/10.1016/S0167-8116\(02\)00097-6](https://doi.org/10.1016/S0167-8116(02)00097-6)
- Rouff, C. A. (2007). Introduction: DARPA Urban Grand Challenge. *Journal of Aerospace Computing, Information, and Communication*, 4(12), 1046–1046. <https://doi.org/10.2514/1.35396>
- Rubinkam, M. (2015). Driverless truck meant to improve safety in work zones. *Yahoo! News*. Zugriff am 1.8.2016. Verfügbar unter: <https://www.yahoo.com/news/driverless-truck-meant-improve-safety-zones-202055180.html>
- Ruths, D. & Pfeffer, J. (2014). Social media for large studies of behavior. *Science*, 346(6213), 1063–1064. <https://doi.org/10.1126/science.346.6213.1063>

- SAE International. (2018). J3016_201806: Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles. *On-Road Automated Driving (ORAD) committee*. https://doi.org/10.4271/J3016_201806
- Salton, G. & Buckley, C. (1988). Term-weighting approaches in automatic text retrieval. *Information Processing & Management*, 24(5), 513–523. [https://doi.org/10.1016/0306-4573\(88\)90021-0](https://doi.org/10.1016/0306-4573(88)90021-0)
- Sarstedt, M., Ringle, C. M., Henseler, J. & Hair, J. F. (2014). On the Emancipation of PLS-SEM: A Commentary on Rigdon (2012). *Long Range Planning*, 47(3), 154–160. <https://doi.org/10.1016/j.lrp.2014.02.007>
- Sarstedt, M., Wilczynski, P. & Melewar, T. C. (2013). Measuring reputation in global markets—A comparison of reputation measures' convergent and criterion validities. *Journal of World Business*, 48(3), 329–339. <https://doi.org/10.1016/j.jwb.2012.07.017>
- Schade, J. & Schlag, B. (2003). Acceptability of urban transport pricing strategies. *Transportation Research Part F: Traffic Psychology and Behaviour*, 6(1), 45–61. [https://doi.org/10.1016/S1369-8478\(02\)00046-3](https://doi.org/10.1016/S1369-8478(02)00046-3)
- Schermann, M., Hensen, H., Buchmüller, C., Bitter, T., Krcmar, H., Markl, V. et al. (2014). Big Data. *Business & Information Systems Engineering*, 6(5), 261–266. <https://doi.org/10.1007/s12599-014-0345-1>
- Schermann, M., Kohl, C. & Krcmar, H. (2014). Automation & Society: The Case of Highly Automated Driving. *Chair for Information Systems*. Zugriff am 27.11.2019. Verfügbar unter: <https://www.i17.in.tum.de/en/research/projects/finished-projects/automation-society-the-case-of-highly-automated-driving/>
- Schoettle, B. & Sivak, M. (2014). A Survey of Public Opinion About Autonomous and Self-Driving Vehicles in the U.S., the U.K., and Australia. Michigan, USA. Verfügbar unter: <https://deepblue.lib.umich.edu/handle/2027.42/108384>
- Schulz, T., Gewalt, H., Böhm, M. & Krcmar, H. (2020). Smart Mobility: Contradictions in Value Co-Creation. *Information Systems Frontiers*. Information Systems Frontiers. <https://doi.org/10.1007/s10796-020-10055-y>
- Seeger, J. (2018). Strecke für autonomen Elektrobuss in Bad Birnbach erweitert. *Heise Online*. Zugriff am 17.6.2019. Verfügbar unter: <https://www.heise.de/newsticker/meldung/Strecke-fuer-autonomen-Elektrobuss-in-Bad-Birnbach-erweitert-4145750.html>
- Seif, H. G. & Hu, X. (2016). Autonomous Driving in the iCity—HD Maps as a Key Challenge of the Automotive Industry. *Engineering*, 2(2), 159–162. <https://doi.org/10.1016/J.ENG.2016.02.010>
- Shaban, H. (2019). Twitter reveals its daily active user numbers for the first time. *The Washington Post*. Zugriff am 23.8.2019. Verfügbar unter: <https://www.washingtonpost.com/technology/2019/02/07/twitter-reveals-its-daily-active-user-numbers-first-time>
- Sharma, R., Yetton, P. & Crawford, J. (2009). Estimating the Effect of Common Method

- Variance: The Method—Method Pair Technique with an Illustration from TAM Research. *MIS Quarterly*, 33(3), 473–490. <https://doi.org/10.2307/20650305>
- Siegrist, M. (2000). The Influence of Trust and Perceptions of Risks and Benefits on the Acceptance of Gene Technology. *Risk Analysis*, 20(2), 195–204. <https://doi.org/10.1111/0272-4332.202020>
- Siegrist, M., Cousin, M.-E., Kastenholz, H. & Wiek, A. (2007). Public acceptance of nanotechnology foods and food packaging: the influence of affect and trust. *Appetite*, 49(2), 459–66. <https://doi.org/10.1016/j.appet.2007.03.002>
- Siegrist, M., Cvetkovich, G. & Roth, C. (2000). Salient Value Similarity, Social Trust, and Risk/Benefit Perception. *Risk Analysis*, 20(3), 353–362. <https://doi.org/10.1111/0272-4332.203034>
- Siegrist, M., Stampfli, N., Kastenholz, H. & Keller, C. (2008). Perceived risks and perceived benefits of different nanotechnology foods and nanotechnology food packaging. *Appetite*, 51(2), 283–290. <https://doi.org/10.1016/j.appet.2008.02.020>
- Slovic, P. (1987). Perception of risk. *Science*, 236(4799), 280–285. <https://doi.org/10.1126/science.3563507>
- Socher, R., Lin, C. C.-Y., Ng, A. Y. & Manning, C. D. (2011). Parsing natural scenes and natural language with recursive neural networks. *ICML '11 Proceedings of the 28th International Conference on International Conference on Machine Learning* (S. 129–136). <https://doi.org/10.1007/978-3-540-87479-9>
- Spinrad, N. (2014). Google car takes the test. *Nature*, 514(7523), 528–528. <https://doi.org/10.1038/514528a>
- Sriram, B., Fuhry, D., Demir, E., Ferhatosmanoglu, H. & Demirbas, M. (2010). Short text classification in twitter to improve information filtering. *Proceedings of the 33rd International ACM SIGIR Conference on Research and Development in Information Retrieval - SIGIR '10* (S. 841–842). <https://doi.org/10.1145/1835449.1835643>
- St Louis, C. & Zorlu, G. (2012). Can Twitter predict disease outbreaks? *BMJ*, 344(e2353), 1–3. <https://doi.org/10.1136/bmj.e2353>
- Statistisches Bundesamt. (2018). Verkehr im Überblick. Zugriff am 17.6.2019. Verfügbar unter: <https://www.destatis.de/DE/Themen/Branchen-Unternehmen/Transport-Verkehr/Publicationen/Downloads-Querschnitt/verkehr-ueberblick-2080120167004.pdf>
- Stieglitz, S. & Dang-Xuan, L. (2013). Emotions and Information Diffusion in Social Media—Sentiment of Microblogs and Sharing Behavior. *Journal of Management Information Systems*, 29(4), 217–248. <https://doi.org/10.2753/MIS0742-1222290408>
- Stone, M. (1974). Cross-Validatory Choice and Assessment of Statistical Predictions. *Journal of the Royal Statistical Society: Series B (Methodological)*, 36(2), 111–133. <https://doi.org/10.1111/j.2517-6161.1974.tb00994.x>
- Taylor, S. & Todd, P. A. (1995). Understanding Information Technology Usage: A Test of Competing Models. *Information Systems Research*, 6(2), 144–176. <https://doi.org/10.1287/isre.6.2.144>

- Tenenhaus, M., Vinzi, V. E., Chatelin, Y.-M. & Lauro, C. (2005). PLS path modeling. *Computational Statistics & Data Analysis*, 48(1), 159–205. <https://doi.org/10.1016/j.csda.2004.03.005>
- Tesla Motors. (2016). Summon Your Tesla from Your Phone. *Tesla Blog*. Zugriff am 12.10.2019. Verfügbar unter: https://www.tesla.com/de_DE/blog/summon-your-tesla-your-phone
- Tesla Motors. (2017). Model 3 Handbuch. Zugriff am 10.6.2019. Verfügbar unter: https://www.tesla.com/content/dam/tesla/Ownership/Own/model_3_owners_manual_eur_ope_de.pdf
- Thrun, S., Montemerlo, M., Dahlkamp, H., Stavens, D., Aron, A., Diebel, J. et al. (2006). Stanley: The robot that won the DARPA Grand Challenge. *Journal of Field Robotics*, 23(9), 661–692. <https://doi.org/10.1002/rob.20147>
- Treat, J. R., Tumbas, N. S., McDonald, S. T., Shinar, D., Hume, R. D., Mayer, R. E. et al. (1977). Tri-Level Study of the Causes of Traffic Accidents: Final Report. Zugriff am 1.8.2016. Verfügbar unter: <https://trid.trb.org/view.aspx?id=144150>
- Tsugawa, S. (1994). Vision-based vehicles in Japan: machine vision systems and driving control systems. *IEEE Transactions on Industrial Electronics*, 41(4), 398–405. <https://doi.org/10.1109/41.303790>
- Tumasjan, A., Sprenger, T. O., Sandner, P. G. & Welpe, I. M. (2010). Predicting Elections with Twitter: What 140 Characters Reveal about Political Sentiment. *Proceedings of the International AAAI Conference on Web and Social Media*, 4(1). Verfügbar unter: <https://ojs.aaai.org/index.php/ICWSM/article/view/14009>
- Twitter. (2016a). The Search API. Zugriff am 1.8.2016. Verfügbar unter: <https://dev.twitter.com/rest/public/search>
- Twitter. (2016b). Public API: GET search/tweets. Zugriff am 1.8.2016. Verfügbar unter: <https://dev.twitter.com/rest/reference/get/search/tweets>
- Twitter. (2016c). Help Center: The Basics. Zugriff am 1.8.2016. Verfügbar unter: <https://support.twitter.com/articles/131209>
- Venkatesh, Morris, Davis & Davis. (2003). User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, 27(3), 425–478. <https://doi.org/10.2307/30036540>
- Venkatesh, V., Davis, F. D. & Morris, M. G. (2007). Dead Or Alive? The Development, Trajectory And Future Of Technology Adoption Research. *Journal of the Association for Information Systems*, 8(4), 267–286. <https://doi.org/10.1016/j.wneu.2011.04.002>
- Venkatesh, V., Thong, J. Y. L. & Xu, X. (2012). Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology. *MIS Quarterly*, 36(1), 157–178. <https://doi.org/10.2307/41410412>
- Venkatesh, V., Thong, J. Y. L. & Xu, X. (2016). Unified Theory of Acceptance and Use of Technology: A Synthesis and the Road Ahead. *Journal of the Association for Information Systems*, 17(5), 328–376. <https://doi.org/10.17705/1jais.00428>

- Vischers, V. H. M. & Siegrist, M. (2013). How a Nuclear Power Plant Accident Influences Acceptance of Nuclear Power: Results of a Longitudinal Study Before and After the Fukushima Disaster. *Risk Analysis*, 33(2), 333–347. <https://doi.org/10.1111/j.1539-6924.2012.01861.x>
- Vlasic, B. & Boudette, N. E. (2016). As U.S. Investigates Fatal Tesla Crash, Company Defends Autopilot System. *The New York Times*. Zugriff am 1.9.2016. Verfügbar unter: <http://www.nytimes.com/2016/07/13/business/tesla-autopilot-fatal-crash-investigation.html>
- Walsh, C. (2017). On Building A Faster Horse: Design Thinking For Disruption. *Forbes*. Zugriff am 20.11.2019. Verfügbar unter: <https://www.forbes.com/sites/forbesfinancecouncil/2017/10/19/on-building-a-faster-horse-design-thinking-for-disruption/?sh=6387cbfb49f9>
- Ward, C., Raue, M., Lee, C., D'Ambrosio, L. & Coughlin, J. F. (2017). Acceptance of Automated Driving Across Generations: The Role of Risk and Benefit Perception, Knowledge, and Trust. In M. Kurosu (Hrsg.), *Human-Computer Interaction. User Interface Design, Development and Multimodality. HCI 2017. Lecture Notes in Computer Science, vol 10271*. Cham: Springer. https://doi.org/10.1007/978-3-319-58071-5_20
- Weedon, A. (2019). Driverless trains are being embraced around the world - but what could go wrong? *ABC News*. Zugriff am 17.6.2019. Verfügbar unter: <https://www.abc.net.au/news/2019-05-31/driverless-trains-embraced-around-the-globe-what-could-go-wrong/11155858>
- Weking, J., Hein, A., Böhm, M. & Kremer, H. (2020). A hierarchical taxonomy of business model patterns. *Electronic Markets*, 30(3), 447–468. <https://doi.org/10.1007/s12525-018-0322-5>
- Wilhelm, U., Ebel, S. & Weitzel, A. (2015). Funktionale Sicherheit und ISO 26262. *Handbuch Fahrerassistenzsysteme* (S. 85–103). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_6
- Williams, M. D., Rana, N. P. & Dwivedi, Y. K. (2015). The unified theory of acceptance and use of technology (UTAUT): A literature review. *Journal of Enterprise Information Management*, 28(3), 443–448. <https://doi.org/10.1108/JEIM-09-2014-0088>
- Winner, H. (2015). Quo vadis, FAS? In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (3. Auflage, S. 1167–1186). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_62
- Winner, H. & Schopper, M. (2015). Adaptive Cruise Control. In H. Winner, S. Hakuli, F. Lotz & C. Singer (Hrsg.), *Handbuch Fahrerassistenzsysteme* (3. Auflage, S. 851–891). Wiesbaden: Springer Vieweg. https://doi.org/10.1007/978-3-658-05734-3_46
- Winner, H. & Wachenfeld, W. (2016). Effects of Autonomous Driving on the Vehicle Concept. *Autonomous Driving* (S. 255–275). Berlin, Heidelberg: Springer Vieweg. https://doi.org/10.1007/978-3-662-48847-8_13
- Woisetschläger, D. M. (2016). Consumer Perceptions of Automated Driving Technologies: An Examination of Use Cases and Branding Strategies. *Autonomous Driving* (S. 687–706).

Berlin, Heidelberg: Springer Vieweg. https://doi.org/10.1007/978-3-662-48847-8_32

- Xu, Z., Zhang, K., Min, H., Wang, Z., Zhao, X. & Liu, P. (2018). What drives people to accept automated vehicles? Findings from a field experiment. *Transportation Research Part C: Emerging Technologies*, 95, 320–334. <https://doi.org/10.1016/j.trc.2018.07.024>
- Yap, M. D., Correia, G. & van Arem, B. (2016). Preferences of travellers for using automated vehicles as last mile public transport of multimodal train trips. *Transportation Research Part A: Policy and Practice*, 94, 1–16. <https://doi.org/10.1016/j.tra.2016.09.003>
- Yeomans, G. (2014). *Autonomous Vehicles: Handing Over Control: Risks and Opportunities in Insurance*. London, Vereinigtes Königreich. Verfügbar unter: <https://www.lloyds.com/news-and-insights/risk-reports/library/autonomous-vehicles>
- Zmud, J. P. & Sener, I. N. (2017). Towards an Understanding of the Travel Behavior Impact of Autonomous Vehicles. *Transportation Research Procedia*, 25, 2500–2519. <https://doi.org/10.1016/j.trpro.2017.05.281>

Anhang

Anhang A: Fragebogen der Studie 1

Please read the following statements and choose if you agree or disagree.

Please choose the appropriate response for each item:	Fully disagree				Fully agree
PE1: I think that using autonomous driving would enable me to conduct other tasks more quickly.	<input type="checkbox"/>				
PE2: In my opinion, I would save time by using autonomous cars.	<input type="checkbox"/>				
PE3: I think that using autonomous driving would increase my productivity.	<input type="checkbox"/>				
PE4: I think that using autonomous driving would improve my performance.	<input type="checkbox"/>				
EE1: My interaction with autonomous cars would be clear and understandable.	<input type="checkbox"/>				
EE2: It would be easy for me to become skilful at using autonomous driving.	<input type="checkbox"/>				
EE3: I would find autonomous driving easy to use.	<input type="checkbox"/>				
EE4: I think that learning to operate autonomous driving would be easy for me.	<input type="checkbox"/>				
SI1: People who influence my behaviour think that I should use autonomous driving.	<input type="checkbox"/>				
SI2: People who are important to me think that I should use autonomous driving.	<input type="checkbox"/>				
SI3: People in my environment who would use autonomous driving have more prestige than those who do not.	<input type="checkbox"/>				
SI4: People in my environment who would use autonomous driving have a high profile.	<input type="checkbox"/>				
SI5: Having autonomous driving would be a status symbol in my environment.	<input type="checkbox"/>				
ANX1: I would feel apprehensive about using the system.	<input type="checkbox"/>				
ANX2: It scares me to think that a problem or accident might happen by using the system wrongly.	<input type="checkbox"/>				
ANX3: I would hesitate to use the system for fear of making mistakes.	<input type="checkbox"/>				
ANX4: Autonomous driving is somewhat intimidating to me.	<input type="checkbox"/>				
AT1: Using autonomous driving is a good idea.	<input type="checkbox"/>				
AT2: The system makes driving more interesting.	<input type="checkbox"/>				
AT3: Driving with autonomous cars would be fun.	<input type="checkbox"/>				
AT4: I would like driving autonomous cars.	<input type="checkbox"/>				
BI1: If autonomous driving was available, I would intend to use autonomous driving in the next months.	<input type="checkbox"/>				
BI2R: If autonomous driving was available, I would predict I would not use autonomous driving in the next months.	<input type="checkbox"/>				
BI3: If autonomous driving was available, I would plan to use autonomous driving in the next months.	<input type="checkbox"/>				
BI4: If autonomous driving was available, I would intend to switch to autonomous driving.	<input type="checkbox"/>				

Anmerkung: Die grau hinterlegten Indikatoren wurden entfernt.

Anhang B: Fragebogen der Studie 2

Please read the following statements and choose if you agree or disagree.

Please choose the appropriate response for each item:	1: strongly disagree	2	3	4	5	6	7: strongly agree
PE1: I will find self-driving cars useful in my daily life.	<input type="checkbox"/>						
PE2: Using self-driving cars will help me accomplish things more quickly.	<input type="checkbox"/>						
PE3: Using self-driving cars will increase my productivity.	<input type="checkbox"/>						
PE4: I will save time by using self-driving cars.	<input type="checkbox"/>						
EE1: Learning how to use self-driving cars will be easy for me.	<input type="checkbox"/>						
EE2: My interaction with self-driving cars will be clear and understandable.	<input type="checkbox"/>						
EE3: I will find self-driving cars easy to use.	<input type="checkbox"/>						
EE4: It will be easy for me to become skillful at using self-driving cars.	<input type="checkbox"/>						
SI1: People who are important to me will think that I should use self-driving cars.	<input type="checkbox"/>						
SI2: People who influence my behavior will think that I should use self-driving cars.	<input type="checkbox"/>						
SI3: People whose opinions that I value will prefer that I use self-driving cars.	<input type="checkbox"/>						
FC1: I will have the resources necessary to use self-driving cars.	<input type="checkbox"/>						
FC2: I will have the knowledge necessary to use self-driving cars.	<input type="checkbox"/>						
FC3: Self-driving cars will be compatible with other technologies I use.	<input type="checkbox"/>						
FC4: I will be able to get help from others when I have difficulties using self-driving cars.	<input type="checkbox"/>						
HM1: Using self-driving cars will be fun.	<input type="checkbox"/>						
HM2: Using self-driving cars will be enjoyable.	<input type="checkbox"/>						
HM3: Using self-driving cars will be very entertaining.	<input type="checkbox"/>						
PV1: Self-driving cars will be reasonably priced.	<input type="checkbox"/>						
PV2: Self-driving cars will be a good value for the money.	<input type="checkbox"/>						
PV3: At the expected price, self-driving cars will provide a good value.	<input type="checkbox"/>						
HT1: The use of self-driving cars will become a habit for me.	<input type="checkbox"/>						
HT2: I will be addicted to using self-driving cars.	<input type="checkbox"/>						
HT3: I will have to use self-driving cars.	<input type="checkbox"/>						
BI1: I intend to use self-driving cars in the future.	<input type="checkbox"/>						
BI2: I will always try to use self-driving cars in my daily life.	<input type="checkbox"/>						
BI3: I plan to use self-driving cars frequently.	<input type="checkbox"/>						

Anmerkung: Die grau hinterlegten Indikatoren wurden entfernt.

Anhang C: Fragebogen der Studie 3

How do you assess the following benefits associated with self-driving cars for the respective stakeholders?

Please choose the appropriate response for each item:	1: no benefit at all	2	3	4	5: very high benefit
For users: Self-driving cars could lead to a major reduction in the number of traffic accidents and thus less harm to life, health, and valuables.	<input type="checkbox"/>				
For the environment: Self-driving cars promise greater efficiency, reduced congestion, and better environmental performance.	<input type="checkbox"/>				
For users: Self-driving cars allow people to make better use of their time while driving (e.g., sleep, work, or play while driving).	<input type="checkbox"/>				
For companies: If a company succeeds in developing self-driving cars, it could vastly increase their market share and profits.	<input type="checkbox"/>				
For society: Self-driving cars can lead to the emergence of new fields of activity and job opportunities.	<input type="checkbox"/>				
For society: Self-driving cars promise greater accessibility for people with (temporarily) reduced mobility, such as young, elderly, or sick people.	<input type="checkbox"/>				
For users: Self-driving cars will lead to mobility services that offer individual mobility without owning a car.	<input type="checkbox"/>				
For the environment: Sharing of self-driving cars will reduce the total amount of cars and leads to better utilization of cars.	<input type="checkbox"/>				

Anmerkung: Die grau hinterlegten Indikatoren wurden entfernt.

How do you assess the following risks associated with autonomous driving?

Please choose the appropriate response for each item:	1: no risk at all	2	3	4	5: very high risk
Self-driving cars could be faced with unforeseen situations which are unmanageable for the automation.	<input type="checkbox"/>				
Accidents may occur which are specific to self-driving cars and which would be unlikely to occur with a human driver.	<input type="checkbox"/>				
Technology-caused accidents which affect the users of self-driving cars as passengers and their environment.	<input type="checkbox"/>				
Simultaneous breakdown or malfunctioning of a large number of self-driving cars based on the same software problem.	<input type="checkbox"/>				
The return on investment may not be on the expected scale or in the expected timeframe due to self-driving cars failing to catch on a large scale.	<input type="checkbox"/>				
Even after a successful market launch of self-driving cars, incidents can occur which could pose a major risk for the affected brands.	<input type="checkbox"/>				
Comprehensive introduction of self-driving cars would affect the labor market (e.g., truck drivers, taxi drivers).	<input type="checkbox"/>				
Increased costs of individual mobility due to the costs of self-driving cars.	<input type="checkbox"/>				
The electronic trail of self-driving cars could lead to a complete movement profile of their users.	<input type="checkbox"/>				
Small technical failures or random events can lead to system instability through complex chain reactions and positive feedback.	<input type="checkbox"/>				
Suceptibility to terrorist attacks (e.g., in the form of a cyber-terror attack).	<input type="checkbox"/>				
Self-driving cars will lead to an increase of individual transport and, thus, to an increase of overall traffic.	<input type="checkbox"/>				
Self-driving cars will take away a lot of control from the drivers (e.g., which route to take at which speed).	<input type="checkbox"/>				
Self-driving cars will be less fun / enjoyable than driving manually.	<input type="checkbox"/>				

Anmerkung: Die grau hinterlegten Indikatoren wurden entfernt.

Please read the following statements and choose if you agree or disagree.

Please choose the appropriate response for each item:	1 : strongly disagree	2	3	4	5: strongly agree
I intend to use self-driving cars in the future.	<input type="checkbox"/>				
I would buy a self-driving car in the future.	<input type="checkbox"/>				
I would use a self-driving car if am not able to drive by myself (e.g., sick, drunk).	<input type="checkbox"/>				
If my car could drive autonomously, I would not drive by myself most of the time.	<input type="checkbox"/>				
If my car could drive autonomously, I would enable autonomous driving on the highway.	<input type="checkbox"/>				
If my car could drive autonomously, I would enable autonomous driving in the city.	<input type="checkbox"/>				
If my car could drive autonomously, I would enable autonomous driving for parking.	<input type="checkbox"/>				
If my car could drive autonomously, I would enable autonomous driving if I feel tired	<input type="checkbox"/>				
I would only use a self-driving car if I could still drive by myself.	<input type="checkbox"/>				
I would move to a more rural area if I had a self-driving car.	<input type="checkbox"/>				

Anmerkung: Die grau hinterlegten Indikatoren wurden entfernt.