

Elektromobile Flotten im lokalen Energiesystem mit Photovoltaik- einspeisung unter Berücksichtigung von Unsicherheiten

zur Erlangung des akademischen Grades eines
Doktors der Wirtschaftswissenschaften

(Dr. rer. pol.)

von der KIT-Fakultät für Wirtschaftswissenschaften
des Karlsruher Instituts für Technologie (KIT)

genehmigte

Dissertation

von

Katrin Seddig

aus Dresden

Tag der mündlichen Prüfung: 11. Juni 2019

Erster Gutachter: Prof. Dr. Wolf Fichtner

Zweiter Gutachter: Prof. Dr. Hartmut Schmeck

Danksagung

Die vorliegende Dissertation entstand während meiner Zeit als wissenschaftliche Mitarbeiterin am Lehrstuhl für Energiewirtschaft des Instituts für Industriebetriebslehre und Industrielle Produktion (IIP) am Karlsruher Institut für Technologie (KIT) und am Energy Solution Center.

Mein erster Dank gilt Herrn Professor Dr. Wolf Fichtner für das jederzeit konstruktive Feedback zu meiner Arbeit und das entgegengebrachte Vertrauen. Mein ausdrücklicher Dank gilt meinem Gruppenleiter Herrn PD Dr. Patrick Jochem für die zahlreichen Ratschläge und vielen inhaltlichen Diskussionen bei der Anfertigung dieser Arbeit. Für das angenehme Arbeitsklima sowie die Freiheiten bei der Erstellung der Dissertation möchte ich beiden von Herzen danken.

Rückblickend ist die Zeit für mich wie im Fluge vergangen und eine lange Reise zu Ende gegangen. Allen Wegbegleitern auf dieser, meiner Reise möchte ich herzlich danken und euch viel Erfolg für eure Vorhaben wünschen. Angefangen von meinen derzeitigen und ehemaligen Kollegen und in vielen Fällen mittlerweile Freunden am IIP und der Gruppe TE. Ein besonderer Dank für die angeregten Diskussionen, die Kickerrunden und die Zusammenarbeit gilt Alex, Anni, Carmen, Christoph, Elias, Flo, Fritz, Jann, Joris, Kai, Kira, Manuel, Marina, Max, Richard, Sascha und Thorben.

Ferner bedanke ich mich beim ensoc Team. Danke Markus für die vielen inspirierenden und bereichernden Gespräche zu den vielseitigsten Themen; Flo für dein Initiativegeist und deine coole Art, die viele Tage im Büro erheitert haben und Sascha für deine Begeisterung für IT, Filme, Serien und gemeinsame Sportaktivitäten. Ebenfalls bedanke ich mich bei Anand für die Ermöglichung eines Forschungsaufenthaltes am Lawrence Berkeley National Laboratory in Kalifornien, USA.

Zu guter Letzt danke ich meinen Freunden, allen voran Leo, die mich stets durch die Höhen und Tiefen bei der Erstellung dieser Dissertation begleitet haben und für angenehme Abwechslung in meinem Alltag gesorgt haben. Mein innigster Dank gilt meiner Familie, die mich mit Rat und Tat begleitet haben und auf deren bedingungslose Unterstützung ich mich immer verlassen kann.

Karlsruhe, im April 2019, Katrin Seddig

Inhaltsverzeichnis

Inhaltsverzeichnis	i
Abbildungsverzeichnis	v
Tabellenverzeichnis	ix
Abkürzungsverzeichnis	xi
1 Einleitung	1
1.1 Motivation	1
1.2 Zielsetzung und Forschungsfragen	3
1.3 Aufbau der Arbeit	5
2 Die Rolle der Elektromobilität im zukünftigen Energiesystem	7
2.1 Energiewirtschaftliche Betrachtung	7
2.1.1 Wandel des Energiesystems	8
2.1.2 Stromerzeugung, Transport und Verteilung	9
2.1.3 Energiemärkte, Vertrieb und Handel	10
2.1.4 Das energiewirtschaftliche Zieldreieck	13
2.2 Erneuerbare Energien und Emissionen	17
2.2.1 Photovoltaik	19
2.2.2 Wind	20
2.2.3 Emissionen	20
2.3 Elektromobilität und Elektrofahrzeuge	22
2.3.1 E-Pkw-Entwicklung und -Potenziale	23
2.3.2 Mobilitätsverhalten	25
2.3.3 E-Pkw-Konzepte	28
2.3.4 Auswirkungen von E-Pkw auf das Energiesystem	30
2.3.5 Ladesteuerungsmechanismen	35
2.3.6 E-Pkw-Kostenentwicklung/-Wirtschaftlichkeit	37
2.4 Ladeinfrastruktur	38
2.4.1 Park- und Ladeorte	38
2.4.2 Anforderungen an die Ladeinfrastruktur	41
2.4.3 Ladesäulen	42
2.4.4 Digitalisierung und Informations- und Kommunikationstechnologien	44
2.4.5 Kosten der Ladeinfrastruktur	46
2.5 Geschäftsmodelle für E-Pkw	46
2.5.1 Entwicklung von Geschäftsmodellen	47
2.5.2 Konzepte für Elektromobilitätsdienstleistungen im Hinblick auf das Stromnetz	48

3	Entwicklung des deterministischen und stochastischen Optimierungsmodells	51
3.1	Herleitung des Modellierungsansatzes	51
3.1.1	Modellanforderungen	51
3.1.2	Überblick über relevante Modellierungsansätze	53
3.1.3	Auswahl des Modellierungsansatzes	54
3.2	Grundlagen der Optimierung	55
3.2.1	Grundlagen der Optimierungsverfahren	55
3.2.2	Stochastische Optimierung	57
3.2.3	Anwendungen im Bereich des Lademanagements von Elektrofahrzeugen ..	61
3.2.4	Auswahl der verwendeten Optimierungsmethoden	62
3.3	Stochastische Modellierung	63
3.3.1	Stochastischer Prozess	64
3.3.2	Wahrscheinlichkeitsverteilungen.....	64
3.3.3	Monte Carlo Simulation	66
3.4	Aufbau der gemischt-ganzzahligen linearen Optimierung	67
3.4.1	Modellannahmen	67
3.4.2	Zielfunktion	69
3.4.3	Nebenbedingungen	70
3.5	Aufbau der zweistufigen stochastischen Optimierung.....	72
3.5.1	Modellannahmen	72
3.5.2	Zielfunktion	74
3.5.3	Nebenbedingungen	78
3.5.4	Modellbewertung.....	80
4	Stand der Wissenschaft	83
4.1	Smart Grids und Energiemanagement	83
4.2	Flexible Lasten von E-Pkw	85
4.3	E-Pkw in Parkhäusern.....	85
4.4	Stochastische Programmierung und Modellierung von Unsicherheiten	86
4.5	Abgrenzung und Forschungslücke.....	88
5	Fallstudie eines Parkhauses mit synergetischer Ladeinfrastruktur und PV-Anlage	93
5.1	Spezifizierung der Rahmenbedingungen im Parkhaus	93
5.2	Charakterisierung elektromobiler Flotten	95
5.2.1	Kurzzeit-/Gelegenheitsparker	95
5.2.2	Dauerparker/Pendler.....	98
5.2.3	Unternehmensflotte/gewerbliche Flotte	100
5.3	Modellierung der Elektrofahrzeuge	103
5.3.1	Fahrtmodell	103
5.3.2	Unsichere Energienachfrage.....	107
5.4	PV-Modell	108
5.4.1	Intermittierender Charakter von PV	109

5.4.2	Unsichere PV-Stromerzeugung	111
5.4.3	PV-Prognose.....	113
5.4.4	Größendimensionierung der PV-Anlage	114
5.4.5	CO ₂ -Einsparpotenzial	114
5.5	Ladestrategien.....	116
5.5.1	Optimiertes Laden	116
5.5.2	Referenzfall: Unkontrolliertes Laden	118
5.6	Modellvarianten.....	118
5.6.1	Überblick der Parametrisierung	119
5.6.2	Bewertung der Methoden	120
5.7	Modellumsetzung	120
5.7.1	Grundlegende technische Modellbeschreibung	120
5.7.2	Modellstruktur und -umsetzung.....	124
5.7.3	Latin Hypercube Sampling	128
5.7.4	Implementierung der Wahrscheinlichkeitsverteilung – Kerndichteschätzer	129
6	Modellgestützte Analysen der Fallstudie	131
6.1	Lastverschiebepotenzial elektromobiler Flotten	131
6.1.1	Unkontrolliertes Laden	132
6.1.2	Auswirkungen von Ladeleistungen	133
6.1.3	Einfluss von Preissignalen	136
6.1.4	Einfluss von Anschlussleistungen	138
6.1.5	Auswirkungen der PV-Stromerzeugung.....	140
6.2	Flottenbetrachtung.....	142
6.2.1	Netznutzung.....	143
6.2.2	Stromkosten.....	145
6.3	Einfluss von Unsicherheiten auf die Ergebnisse.....	149
6.3.1	PV-Integrationspotenzial unter Unsicherheit.....	150
6.3.2	Bewertung der Unsicherheiten	151
6.3.3	Modellbewertung des stochastischen Ansatzes	154
6.4	Integration von PV und CO ₂ -Emissionen	154
6.4.1	Eigennutzung der PV-Stromerzeugung	155
6.4.2	CO ₂ -Einsparpotenzial	156
6.5	Geschäftsmodelle eines Parkhausbetreibers	156
6.5.1	Konzept für Parkhausbetreiber	157
6.5.2	Tarifkonzepte für Parkhauskunden mit Elektrofahrzeug	159
6.5.3	Übertragung der Tarifkonzepte auf die Fallstudie	161
6.5.4	Einsatz von Parkhaus mit Solardach.....	161
6.6	Kritische Würdigung	162
6.6.1	Kritische Betrachtung des entwickelten Modells	162
6.6.2	Übertragbarkeit auf andere Bereiche und Regionen.....	166

7 Schlussbetrachtung und Ausblick	169
7.1 Zusammenfassung	169
7.2 Erkenntnisse.....	173
7.3 Ausblick und weiterführende Forschungsmöglichkeiten.....	175
Anhang A	181
Anhang B.....	184
Literaturverzeichnis.....	187

Abbildungsverzeichnis

Abbildung 1.1:	Treibhausgasemissionen nach Sektoren in Deutschland im Jahr 2017	1
Abbildung 2.1:	Das energiewirtschaftliche Zieldreieck	14
Abbildung 2.2:	Anteil der Energieträger an der Bruttostromerzeugung in Deutschland im Jahr 2017	18
Abbildung 2.3:	Anteil der EE an der Bruttostromerzeugung in Deutschland im Jahr 2017	18
Abbildung 2.4:	Entwicklung der installierten Leistung von PV (2005 – 2017)	19
Abbildung 2.5:	CO ₂ -Emissionen der Stromerzeugung von Deutschland im Jahr 2017	21
Abbildung 2.6:	Vermiedene Treibhausgas-Emissionen durch die Nutzung EE im Jahr 2017 (Netto-Bilanz)	21
Abbildung 2.7:	Entwicklung der Anzahl von E-Pkw in Deutschland (2010 - 2017)	24
Abbildung 2.8:	Wegzwecke nach Verkehrsaufkommen und Verkehrsleistung	26
Abbildung 2.9:	Übersicht der Antriebskonzepte	29
Abbildung 2.10:	Schematische Darstellung von Lastverschiebepotenzialen	32
Abbildung 2.11:	Möglichkeiten der Integration von E-Pkw zur Lastverschiebung	32
Abbildung 2.12:	Parkorte von Fahrzeugen	39
Abbildung 2.13:	Parkhausbetreiber im Kontext des Marktes	49
Abbildung 5.1:	Schematische Darstellung der Fallstudie	94
Abbildung 5.2:	Verteilung der Ankunftszeiten und Aufenthaltsdauern der Gelegenheitsparker im Beispielparkhaus an einem Werktag	96
Abbildung 5.3:	Verteilung der Distanzen der Gelegenheitsparker und zugehörige 1D KDE	98
Abbildung 5.4:	Verteilung der Ankunftszeit und Aufenthaltszeiten der Dauerparker im Beispielparkhaus an einem Werktag	99
Abbildung 5.5:	Verteilung der Distanzen der Dauerparker und zugehörige 1D KDE	100
Abbildung 5.6:	Verteilung und KDE der Abfahrts- und Ankunftszeiten sowie der Distanzen der Unternehmensflottenbuchungen an einem Werktag	102
Abbildung 5.7:	3D-Verteilung der Abfahrts- und Ankunftszeiten sowie der Distanzen der Unternehmensflottenbuchungen an einem Werktag	103
Abbildung 5.8:	Auswahlalgorithmus zur Erstellung der synthetischen Fahrprofile	105
Abbildung 5.9:	Boxplot der durchschnittlichen Energienachfrage je Kunde für die drei E-Pkw Flotten	106
Abbildung 5.10:	Boxplot der Unsicherheit der Energienachfrage je E-Pkw und pro Flotte	108

Abbildung 5.11: Boxplot der Globalstrahlung über den Tagesverlauf des gesamten Jahres 2013 für die Stadt Stuttgart	109
Abbildung 5.12: Darstellung der realen vs. der Day-Ahead vorhergesagten PV-Stromerzeugung von der TransnetBW in den Sommermonaten des Parkhauses des Jahres 2013.....	110
Abbildung 5.13: Boxplotdarstellung des Prognosefehlers der PV-Stromerzeugung durch Zeitreihenanalyse von 2011 – 2017 im TransnetBW Einzugsgebiet.....	111
Abbildung 5.14: Boxplotdarstellung des Prognosefehlers der PV-Stromerzeugung mit Anwendung des GMM-basierten Ansatzes	112
Abbildung 5.15: Medianwerte EPEX SPOT Kurven (25 % bzw. 75 % Quantil schattierter Bereich) für Sommer- und Wintertage im Jahr 2013	117
Abbildung 5.16: Zusammenhang der Modellkomponenten	125
Abbildung 5.17: Überblick über den Ablauf der deterministischen Optimierung mit perfekter Information	126
Abbildung 5.18: Überblick über die Optimierung für das Modell mit der Day-Ahead PV-Voraussicht.....	127
Abbildung 5.19: Überblick über die stochastische Optimierung unter Berücksichtigung der Unsicherheiten der Energienachfrage und der PV-Stromerzeugung	127
Abbildung 6.1: Unkontrollierte Lastkurve der drei E-Pkw Flotten mit 22 kW Ladeleistung (Linie – Mittelwert; schattierter Bereich – 25 %- und 75 %-Quantil).....	133
Abbildung 6.2: Unkontrollierte Lastkurven für die drei E-Pkw Flotten mit jeweils 3,7 kW Ladeleistung	134
Abbildung 6.3: Unkontrollierte Lastkurven für die drei E-Pkw Flotten mit jeweils 11 kW Ladeleistung	134
Abbildung 6.4: Optimierung: Violinplot der durchschnittlichen Ladekosten der verschiedenen Flotten und lokalen Ladeleistungen (3,7; 11; 22 kW)	136
Abbildung 6.5: Optimierte Lastkurven der Flotten basierend auf dem durchschnittlichen Sommer EPEX SPOT-Preis	137
Abbildung 6.6: Optimierte Lastkurven der Flotten basierend auf dem durchschnittlichen Winter EPEX SPOT-Preis.....	137
Abbildung 6.7: Violinplot der durchschnittlichen Stromkosten je Flotte für Sommer vs. Winter EPEX SPOT-Preise, links (i) Optimierung, rechts (ii) Unkontrolliertes Laden.....	138
Abbildung 6.8: Optimierung: Violinplot zum Vergleich der Ladekosten für alle Flotten zusammen je Anschlussleistung (150, 200, 250 kW).....	139
Abbildung 6.9: Unkontrolliertes Laden: Violinplot der Ladekosten für alle Flotten zusammen je Anschlussleistung (150, 200, 250 kW).....	140

Abbildung 6.10: Optimierung: Violinplot der Ladekosten je Flotte basierend auf drei unterschiedlich großen PV-Modulen.....	141
Abbildung 6.11: Unkontrolliertes Laden: Violinplot der gesamten Ladekosten je Flotte basierend auf drei unterschiedlich großen PV-Modulen	142
Abbildung 6.12: Optimierung: Violinplot der Ausnutzung des erzeugten PV-Stromes sowie der Anteile vom Netz zum Laden für die einzelnen Flotten mit insgesamt 150 Kunden	143
Abbildung 6.13: Optimierung: Violinplot der Ausnutzung des erzeugten PV-Stromes sowie der Anteile vom Netz zum Laden für die einzelnen Flotten mit insgesamt (i) 75 Kunden, links und (ii) 225 Kunden, rechts	144
Abbildung 6.14: Unkontrolliertes Laden: Violinplot der Energienachfrage des erzeugten PV-Stromes sowie der Anteile vom Netz zum Laden für die einzelnen Flotten mit insgesamt 150 Kunden.....	145
Abbildung 6.15: Optimierung: Boxplot der durchschnittlichen Stromkosten mit Unterscheidung der Stromquelle je Flotte mit insgesamt 150 Kunden	146
Abbildung 6.16: Optimierung: Boxplot der gesamten Ladekosten der einzelnen Flotten mit jeweils insgesamt 75, 150 und 225 Kunden	148
Abbildung 6.17: Unkontrolliertes Laden: Boxplot der gesamten Ladekosten der einzelnen Flotten mit jeweils insgesamt 75, 150 und 225 Kunden.....	149
Abbildung 6.18: Boxplot der Ausnutzung des erzeugten Stromes von PV basierend auf den unterschiedlichen Methoden und PV-Voraussicht Ansätzen	150
Abbildung 6.19: Boxplot der gesamten Flottenladekosten für die verschiedenen methodischen Ansätze ohne Unsicherheiten	152
Abbildung 6.20: Boxplot der Abweichungskosten der Ansätze Day-Ahead vs. GMM-basierte PV-Voraussicht	153
Abbildung 6.21: Boxplot basierend auf den gesamten Flottenladekosten inklusive der Abweichungskosten für die verschiedenen methodischen Ansätze	153
Abbildung 6.22: Optimierte Lastkurven bzgl. Strom-Preis und PV-Einspeisung für die drei E-Pkw Flotten mit 22 kW Ladeleistung und großem PV-Modul.....	155
Abbildung 6.23: Mögliches Produktdesign für Parkhauskunden unter Berücksichtigung der Kundenflexibilität und der Tarifkomplexität.....	160
Abbildung A.1: Konvergenztest (zentraler Grenzwertsatz) zur Ermittlung der Simulationsgröße mit 150 Simulationen und 125 SAA Szenarien und insgesamt 75 Kunden	181
Abbildung A.2: Konvergenztest (Gesetz der großen Zahl) zur Ermittlung der Simulationsgröße mit 150 Simulationen und 125 SAA Szenarien und insgesamt 75 Kunden	182

Abbildung A.3: Konvergenztest (zentraler Grenzwertsatz) zur Ermittlung der Simulationsgröße mit 300 Simulationen und 125 SAA Szenarien und insgesamt 150 Kunden	182
Abbildung A.4: Konvergenztest (Gesetz der großen Zahl) zur Ermittlung der Simulationsgröße mit 300 Simulationen und 125 SAA Szenarien und insgesamt 150 Kunden	183
Abbildung B.1: 2D KDE von der Ankunftszeit und der Aufenthaltsdauer der Gelegenheitsparker, sowie die jeweilige 1D KDE	185
Abbildung B.2: 2D KDE von der Ankunftszeit und der Aufenthaltsdauer der Pendler, sowie die jeweilige 1D KDE	185

Tabellenverzeichnis

Tabelle 2.1:	Überblick über eine Auswahl an reinen E-Pkw Modellen inkl. technischer Details und Listenpreise im Jahr 2018	30
Tabelle 2.2:	Lademodi nach IEC 61851-1	43
Tabelle 2.3:	Elemente eines Geschäftsmodells	48
Tabelle 3.1:	Nomenklatur (MILP)	69
Tabelle 3.2:	Nomenklatur (SMILP)	73
Tabelle 4.1:	Übersicht relevanter Arbeiten im Kontext von Lademanagementsystemen für E-Pkw unter Unsicherheiten	90
Tabelle 5.1:	Durchschnittliche CO ₂ -Emissionen des Energiemixes für ausgewählte Länder im Jahr 2016.....	115
Tabelle 5.2:	Übersicht der Parametrisierung der verschiedenen Ansätze	119
Tabelle 5.3:	Auszug der benutzten Bibliotheken in Python	122
Tabelle 5.4:	Überblick zu den Modellgrößen anhand der Anzahl der Variablen und durchschnittlichen Rechenzeiten für die unterschiedlichen Strategien und Kundenanzahl.....	123
Tabelle 5.5:	Vergleich der Ergebnisse des SMILP Ansatzes unter Anwendung der LHS und MCS Methode	129
Tabelle 6.1:	Übersicht der durchschnittlichen Stromkosten des unkontrollierten Ladens sowie Optimierung je Flotte mit insgesamt 75, 150 und 225 Kunden mit Unterscheidung der Stromquelle, (a) Netz (oben) sowie (b) PV + Netz (unten)	147
Tabelle 6.2:	Güte des stochastischen Ansatzes	154
Tabelle 6.3:	Überblick der eingesparten CO ₂ -Emissionen je Flotte und Tag mit Unterscheidung zwischen Optimierung und unkontrolliertem Laden bewertet mit Sommer- und Winter-EPEX SPOT-Preisen.....	156
Tabelle 6.4:	Überblick der Komponenten des Geschäftsmodellkonzepts für einen Parkhausbetreiber für die nachfrageseitige Flexibilisierung	158
Tabelle 6.5:	Möglichkeiten und Herausforderungen von Parkhäusern mit Solardächern.....	162

Abkürzungsverzeichnis

AC	Alternating current, engl. für Wechselstrom
AFAP	As fast as possible, engl. für Ladestrategie ‘so schnell wie möglich‘
ALAP	As late as possible, engl. für Ladestrategie ‘so spät wie möglich‘
BEV	Battery electric vehicle, engl. für batterieelektrisches Fahrzeug
CCS	Combined charging system, engl. für Schnellladesystem
CO ₂	Kohlenstoffdioxid
CPP	Critical peak pricing, engl. für Bepreisung kritischer Spitzenlasten
DC	Direct current, engl. für Gleichstrom
DR	Demand Response, engl. für Laststeuerung
DSM	Demand Side Management, engl. für Nachfragesteuerung
EE	Erneuerbare Energien
EEV	Expected result of the expected value problem
EEX	European Energy Exchange, engl. für europäische Energiebörse
EM	Expectation Maximization, engl. für Name eines Algorithmus
ENTSO-E	European Network of Transmission System Operators for Electricity, engl. für Verband europäischer Übertragungsnetzbetreiber
EnWG	Energiewirtschaftsgesetz
EPEX	European Power Exchange, engl. für europäische Strombörse
E-Pkw	Elektro-Personenkraftwagen
EU	Europäische Union
EU-ETS	Europäischer Emissionszertifikatehandel
EVPI	Expected Value of Perfect Information, engl. für Wert der vollständigen Information
EVU	Energieversorgungsunternehmen
FCEV	Fuel cell electric vehicle, engl. für Brennstoffzellenfahrzeug
FCFS	First Come First Serve, engl. für Ladestrategie ‚den ersten zuerst bedienen‘
GMM	Gaussian Mixture Model, engl. für Mischverteilung
GWh	Gigawattstunde
HEV	Hybrid electric vehicle, engl. für Hybridfahrzeug
IKT	Informations- und Kommunikationstechnologie
ISO	International Organization for Standardization, engl. für Internationale Organisation für Normung
KDE	Kernel Density Estimation, engl. für Kerndichteschätzer

Kfz	Kraftfahrzeug
KiD	Kraftfahrzeugverkehr in Deutschland (Studie)
kW	Kilowatt
kWh	Kilowattstunde
LHS	Latin Hypercube Sampling
LVP	Lastverschiebepotenzial
MCP	Market clearing price, engl. für Markträumungspreis
MCS	Monte Carlo Simulation
MiD	Mobilität in Deutschland (Studie)
MILP	Mixed Integer Linear Programming, engl. für gemischt-ganzzahlige lineare Optimierung
ML	Maximum-Likelihood
MOP	Deutsches Mobilitätspanel (Studie)
NEFZ	Neuer Europäischer Fahrzyklus
NPE	Nationale Plattform Elektromobilität (von 2009-2017)
OCPP	Open charge point protocol, engl. für Freier Ladepunkt Kommunikationsstandard
ÖPNV	Öffentlicher Personennahverkehr
OR	Operations Research
OTC	Over the counter, engl. für außerbörslicher Handel
PDF	Probability density function, engl. für Wahrscheinlichkeitsdichtefunktion
PHEV	Plug-in hybrid electric vehicle, engl. für Plug-In-Hybridfahrzeug
PSO	Particle swarm optimization, engl. für Partikelschwarmoptimierung
PV	Photovoltaik
REEV	Range extender electric vehicle, engl. für E-Pkw mit Reichweitenverlängerung
RMSE	Root mean square error, engl. für mittlere quadratische Prognosefehler
RP	Zielfunktionswert der here-and-now Entscheidung mit rekursivem Problem
RTP	Real time pricing, engl. für Echtzeit-Bepreisung
SAA	Sample Average Approximation
SMILP	Stochastic Mixed-Integer Linear Programming, engl. für stochastische gemischt-ganzzahlige lineare Optimierung
SOC	State of charge, engl. für Batteriezustand
TCO	Total cost of ownership, engl. für Gesamtkosten des Betriebs
TOU	Time of use, engl. für Nutzungszeit(tarif)

TWh	Terawattstunde
US	United States, engl. für Vereinigte Staaten
USD	US Dollar
V2G	Vehicle-to-Grid, engl. für Fahrzeug ans Netz
VSS	Value of Stochastic Solution, engl. für Wert der stochastischen Lösung
WEC	World Energy Council, engl. für Weltenergieerat
WLTP	Worldwide harmonized Light vehicles Test Procedure, engl. für weltweit einheitliches Leichtfahrzeuge-Testverfahren
WS	Wait-and-see value, engl. für Wert des Abwartens eines stochastischen Programmes

1 Einleitung

1.1 Motivation

Die Elektromobilität stellt ein wesentliches Element zur Erreichung der internationalen und damit auch deutschen Klimaziele dar. Elektrofahrzeuge (E-Pkw) stoßen im Vergleich zu Verbrennerfahrzeugen im Fahrbetrieb keine Schadstoffe aus (vgl. BMU, 2019b) und können in diesem Zusammenhang einen wichtigen Beitrag zur Emissionsreduktion leisten. Die deutsche Bundesregierung hat bereits 2010 das Ziel formuliert, dass es bis 2020 eine Million E-Pkw in Deutschland geben soll. 2018 wurde diese Vorgabe auf 2022 verschoben (vgl. WiWo, 2018). Gerade die drohenden Fahrverbote für Dieselfahrzeuge in einigen Regionen Deutschlands beschleunigen Überlegungen zu alternativen Antriebsmöglichkeiten (vgl. BMU, 2018). Wird der Blick auf den Transportsektor gelegt, wird deutlich, dass dieser neben dem Energiesektor einen großen Teil zu den Treibhausgasemissionen von insgesamt 904,7 Mio. Tonnen CO₂-Äquivalente im Jahr in Deutschland beiträgt. Die Abbildung 1.1 verdeutlicht die Situation im Jahr 2017. Der Ölverbrauch ist ein Aspekt, der sich in den CO₂-Emissionen, dem Klimagas mit dem größten Anteil am anthropogenen Klimawandel, widerspiegelt.




Abbildung 1.1: Treibhausgasemissionen nach Sektoren in Deutschland im Jahr 2017;
Datenquelle: UBA (2018b)

Im Rahmen der Energiewende in Deutschland wird als eines der Ziele die Reduktion der CO₂-Emissionen durch vermehrte Energiebereitstellung aus erneuerbaren Energien (EE) vorgegeben. So lag die Bruttostromerzeugung aus erneuerbaren Energiequellen 1990 bei 3,6 %, im Jahr 2017 bei 33,3 % und das aktuelle Ziel ist es, 80 % am

Bruttostromverbrauch bis 2050 zu erreichen (vgl. AG Energiebilanzen e.V., 2018). Mit dem hohen Anteil der Stromerzeugung aus Sonne (6,1 %) und Wind (16,2 %) geht eine fluktuierende und nicht perfekt vorhersehbare Stromerzeugung einher. Diese Entwicklung wird voraussichtlich den Bedarf an Energiespeichern im Stromnetz erhöhen (vgl. Denholm und Hand, 2011). Aus technischer Sicht scheinen E-Pkw aufgrund der langen Parkzeiten (durchschnittlich 23 Stunden pro Tag) und der hohen Energiespeicherkapazität die Schwankungen der EE in Zukunft mit ausgleichen zu können (vgl. BMVBS, 2010; Babrowski et al., 2015). Lastverschiebepotenziale (LVP) werden dabei eine große Bedeutung erlangen. Die Kombination von beiden Trends (Elektrifizierung von Autos sowie Energiewende) und damit einhergehend die Synergien zwischen lokal erzeugtem Strom aus erneuerbaren Energiequellen sowie der Steuerung der Ladung der E-Pkw kann eine doppelte Dividende bieten: Verringerung der Abregelung der Stromerzeugung aus erneuerbaren Energiequellen und Abnahme der negativen Umweltauswirkungen von Personenkraftwagen.

Immer mehr Länder, vor allem China und Norwegen, setzen aktuell auf die Elektromobilität. Vorreiterländer, wie beispielsweise Norwegen, haben neben hohen Subventionen weitere steuerliche Vergünstigungen für die Elektromobilitätsnutzer eingeführt (vgl. IEA, 2018b). In Deutschland hingegen steigen die Verkaufszahlen für die E-Pkw derzeit nur langsam an. Die Bundesregierung hat zur Erhöhung der Attraktivität der E-Pkw daher Förderprogramme aufgelegt (vgl. PTJ, 2019; BMU, 2019). Ferner gewinnt die Elektromobilität durch jüngste Trends, wie sinkende Batteriepreise an Attraktivität (vgl. Schmidt et al., 2017). Ebenfalls tragen technologische Verbesserungen in Form der Einführung von Standards für die Kommunikation zwischen Elektrofahrzeug, Ladestation und Betreiber, die koordinierte Ladeprozesse ermöglichen, zu positiven Effekten bei (vgl. Sachs et al., 2016). Die Errichtung einer Ladeinfrastruktur im öffentlichen und halböffentlichen Parkraum, beispielsweise in Parkhäusern, ist ein wichtiger Aspekt für eine verstärkte Verbreitung der E-Pkw. Zusätzliche Maßnahmen hinsichtlich der Interoperabilität, d.h. Hardware- und Softwareinteroperabilität, Vereinheitlichung von Abrechnungsstandards der Ladevorgänge und ein verbesserter Zugang zu Ladesäulen können die Etablierung der Elektromobilität beschleunigen.

Einige Akteure des Stromsystems sehen jedoch nicht nur die Chancen der Elektromobilität, sondern stehen höheren Marktanteilen von E-Pkw eher skeptisch gegenüber, da diese eine zusätzliche Last im Energiesystem darstellen. Die E-Pkw haben einen hohen Strombedarf während der Abendstunden, wenn sie unkontrolliert zu Hause aufgeladen werden. Gelingt es jedoch diese Ladevorgänge in Zeit und Last zu steuern,

ist die daraus resultierende Lastflexibilität hoch (vgl. Babrowski et al., 2015) und könnte einige Herausforderungen, die durch schwankende Stromerzeugung durch Sonne und Wind entstehen, verringern.

Innerhalb dieses Forschungsthemas, dem Laden von E-Pkw mit fluktuierender Erzeugung, gibt es viele unsichere Faktoren, die berücksichtigt werden müssen. So kann die Nachfrageseite stochastisch sein. Dieses beruht beispielsweise auf den noch unbekanntem Ladebedarf. Ebenfalls können Flotten, die in dieser Arbeit als verschiedene Nutzergruppen mit ähnlichen Fahrprofilen verstanden werden, unterschiedliche Charakteristika aufweisen. Die Produktionsseite unterliegt auch Unsicherheiten. Insbesondere die Erzeugung der erneuerbaren Energien kann schwanken, zum Beispiel bei Photovoltaik (PV)-Anlagen, deren Produktion direkt von der Sonneneinstrahlung und damit vom Wetter abhängt (vgl. Ji und Chee, 2011). Die Prognose von Ladevorgängen von E-Pkw und die Einspeisung der EE ist daher mit großen Unsicherheiten, z. B. Plug-in-Zeiten von E-Pkw oder lokalen Wolkenbewegungen, verbunden.

Die Beschäftigung mit der Elektromobilität ist ein zukunftsweisendes Forschungsgebiet und ein Schlüssel für eine klimafreundliche Gestaltung der Umwelt. Das Thema ist somit facettenreich und die hier aufgeführten Aspekte sollten in einer Systemanalyse Berücksichtigung finden, damit im künftigen Energiesystem das nachhaltige Potenzial der E-Pkw bestmöglich genutzt werden kann.

1.2 Zielsetzung und Forschungsfragen

Aufgrund der aufgezeigten Entwicklung befasst sich diese Arbeit mit den Auswirkungen der Elektromobilität auf das lokale Energiesystem unter Unsicherheit. Hierbei soll detailliert untersucht werden, inwieweit verschiedene E-Pkw Flotten zur Lastverschiebung genutzt werden können. Die Fallstudie ist ein Parkhaus. Ausgehend von drei unterschiedlichen E-Pkw Flotten (Pendler-, Gelegenheitsparker- und Unternehmensflotte), die eine gemeinsame Ladeinfrastruktur benutzen, wird unter Berücksichtigung technischer Restriktionen hinterfragt, wie sich unterschiedliche Ladestrategien auswirken. Dies erfordert die Entwicklung mehrerer Ansätze basierend auf unterschiedlichen Methoden. Damit können verschiedene Aspekte, z. B. die konkrete Modellierung unterschiedlicher Elektrofahrzeugflotten sowie die stochastischen Erzeugungsprofile von PV erarbeitet und integriert werden. Den zu entwickelnden Ansätzen liegt eine Vielzahl an Datenquellen zu Grunde, die dazu beitragen sollen, eine möglichst hohe Aussagekraft der durchzuführenden Analysen zu gewährleisten. Darauf

aufbauend besteht ein weiteres Ziel der Arbeit darin, die verschiedenen Methoden miteinander zu vergleichen und das Potenzial zur Lastverschiebung zu beziffern. Die Möglichkeit, die einzelnen Flotten mit möglichst dem lokal erzeugten PV-Strom zu laden, wird dabei ebenfalls betrachtet. Die Entwicklung eines möglichen Geschäftsmodells für Parkhausbetreiber, um die Faktoren verschiedener Konzepte in der Praxis möglichst gut abzubilden und die Ladeflexibilitäten der Parkhauskunden zu nutzen, soll diese Arbeit abrunden.

Ausgehend von den oben genannten Zielstellungen ergeben sich mehrere Forschungsfragen für diese Arbeit:

- I. Was sind die relevanten Charakteristika bei der Modellierung von E-Pkw Flotten?
- II. Wie können Unsicherheiten bei der Prognose von Stromerzeugung durch PV im stochastischen Modell berücksichtigt werden?
- III. Wie hoch ist das Lastverschiebepotenzial von verschiedenen E-Pkw Flotten, wenn unkontrolliertes Laden mit einer wirtschaftlich optimierten Ladestrategie verglichen wird?
- IV. Wie viel Prozent der lokalen Stromerzeugung durch PV kann zum Laden der E-Pkw Flotten genutzt werden, wenn eine maximierende PV-Auslastung und eine unkontrollierte Ladestrategie verglichen werden?
- V. Wie hoch sind die Unterschiede, wenn verschiedene methodische Ansätze (deterministische Optimierung vs. stochastische Optimierung) miteinander verglichen werden, um die E-Pkw Flotten kostenminimal zu laden?
- VI. Welche Faktoren beeinflussen E-Pkw Kunden (E-Pkw Besitzer), damit sie ihre Ladeflexibilität einem Aggregator anbieten und was sollten Tarife entsprechend berücksichtigen?

Somit ist es das Ziel der Arbeit, ein Modell zu entwickeln, das zur Identifizierung der Lastverschiebepotenziale von elektromobilen Flotten unter besonderer Berücksichtigung der Integration von Stromerzeugung durch PV unter Unsicherheit genutzt werden kann. Daraus sollen Ansätze für die Implementierung eines möglichen Geschäftsmodells für einen Parkhausbetreiber hergeleitet werden.

1.3 Aufbau der Arbeit

Die Arbeit ist in sowohl theoretische als auch anwendungsbezogene Teile gegliedert. Ausgehend von allgemeinen Ausführungen zur Elektromobilität soll das Verständnis für diese Thematik gelegt werden. Darauf aufbauend werden Kenntnisse zur Optimierung und Modellierung vermittelt. Diese stellen die Grundlage dafür dar, dass im weiteren Verlauf das neu zu entwickelnde Modell nachvollzogen werden kann. Im Rahmen der Fallstudie, die Daten aus einem Stuttgarter Parkhaus verwendet, werden verschiedene Analysen durchgeführt. Anschließend werden die gewonnenen Erkenntnisse diskutiert und ausgewertet.

Die Arbeit ist wie folgt gegliedert:

Zunächst wird im Kapitel 2 die Rolle der Elektromobilität im zukünftigen Energiesystem aufgezeigt. Themenschwerpunkte bilden darin erneuerbare Energien und CO₂-Emissionen sowie energiewirtschaftliche Betrachtungen. Neben der Elektromobilität im Allgemeinen stehen die E-Pkw, die Ladeinfrastruktur und Geschäftsmodelle im Fokus.

Das Kapitel 3 bildet das methodische Fundament. Darin werden neben der Herleitung des Modellierungsansatzes, die Grundlagen der Optimierung und die stochastische Modellierung erläutert. Darauf aufbauend wird ausführlich das entwickelte deterministische und stochastische Optimierungsmodell beschrieben.

Im Kapitel 4 findet eine wissenschaftliche Einordnung der vorliegenden Arbeit statt und es werden verwandte Arbeiten aufgezeigt. Darauf aufbauend wird die Forschungslücke abgeleitet und eine Abgrenzung zu der bestehenden Literatur vorgenommen.

Die Datengrundlage und die Fallstudie mit den dazugehörigen Analysen und Ladestrategien werden im Kapitel 5 zusammengefasst. Die Rahmenbedingungen werden dargelegt und die verschiedenen Elemente der Studie näher ausgeführt: die Charakterisierung und Modellierung der drei elektromobilen Flotten, die Unsicherheitsbetrachtungen bei der Energienachfrage, die methodischen Vergleiche zu den PV-Vorhersagemodellen, der Modellaufbau und die -umsetzung sowie die einzelnen Modellvarianten und berücksichtigten Methoden.

Im Kapitel 6 werden die Ergebnisse der Modellvariationen diskutiert. Dabei werden mehrere Schwerpunkte gelegt: neben der methodischen Bewertung die Untersuchung

von unterschiedlichen Einflussfaktoren auf das LVP der drei E-Pkw Flotten, deren Charakterisierung und die PV-Integrations- sowie CO₂-Reduktionspotenziale. Ebenfalls wird ein kurzer Exkurs zu möglichen Geschäftsmodellen für Parkhausbetreiber gegeben. Ferner erfolgt eine umfassende kritische Würdigung des gewählten Vorgehens in Bezug auf die entwickelten Ansätze und die Ergebnisse.

Die im Rahmen dieser Arbeit gewonnenen Erkenntnisse werden abschließend im Kapitel 7 zusammengefasst. Ein Ausblick auf den zukünftigen Forschungsbedarf rundet die Ausführungen ab.

2 Die Rolle der Elektromobilität im zukünftigen Energiesystem

Dieses Kapitel widmet sich sowohl den energiewirtschaftlichen Rahmenbedingungen als auch der Rolle der Elektromobilität und der gemeinsamen Schnittmenge, um die Arbeit entsprechend einzubetten. Zunächst charakterisiert der Abschnitt 2.1 die energiewirtschaftlichen Grundlagen mit dem aktuellen Wandel des Energiesystems sowie die zugrunde gelegten Marktmechanismen. Als zweiter Punkt werden in Abschnitt 2.2 die EE und die CO₂-Emissionen näher erläutert. Ab dem Abschnitt 2.3 rückt die Elektromobilität in den Fokus des Kapitels. Zuerst werden Auswirkungen für Deutschland betrachtet, bevor dann der Blick auf den E-Pkw fällt, inklusive der technischen Seite der Elektrofahrzeuge und der Ladestrategien. Die Ladeinfrastruktur und die dazugehörigen Komponenten, wie verschiedene Ladeorte oder Ladesäulen und dazugehörige Kommunikationsmodelle werden im Abschnitt 2.4 vorgestellt. Den Abschluss bildet ein kurzer Exkurs zu den vorherrschenden Geschäftsmodellen im Bereich der Elektromobilität im Abschnitt 2.5.

2.1 Energiewirtschaftliche Betrachtung

Die Energiewende führt zu einer starken Veränderung des Elektrizitätsmarktes in den letzten Jahren auf der Erzeugungs- als auch der Nachfrageseite in Deutschland. Zu den Zielen der Energiewende und des Energiekonzepts von 2010 zählen u. a. (vgl. BMWi, 2018b; Bundesregierung, 2010)

- den Bruttostromverbrauch aus EE auf 40 – 45 % bis 2025 zu erhöhen,
- im Vergleich 2008 zu 2050 den Primärenergieverbrauch um 50 % zu senken sowie
- eine Reduktion der Treibhausgasemissionen um 40 % bis 2020 in Bezug auf das Jahr 1990 zu erreichen.

Die Rahmenbedingungen der deutschen Stromerzeugung haben sich nach der Nuklearkatastrophe in Fukushima im Jahr 2011 verändert. Es wurden acht Kernkraftwerke

sofort abgeschaltet und alle weiteren Kernkraftwerke sollen bis 2022 stufenweise folgen. Dieses Vorgehen im Kontext der Energiewende soll mit ein Treiber für Energieeffizienz, Innovationen und Digitalisierung sowie Modernisierung sein (vgl. BMWi, 2018b; Bundesregierung, 2018).

Die Liberalisierung der Elektrizitätsmärkte war eine weitere wichtige Veränderung nicht nur in Deutschland, sondern auch in Europa. Dieser Prozess, der Öffnung der Energiemärkte, wurde mit der ersten EU-Energiebinnenmarkttrichtlinie im Jahre 1998 eingeleitet und über die Jahre hinweg weiterentwickelt. Es erfolgte eine entsprechende Umsetzung der Richtlinien im deutschen Energiewirtschaftsgesetz (EnWG). Damit wurden die formalen Voraussetzungen geschaffen, dass Verbraucher die Möglichkeit haben, ihren Energielieferanten frei zu wählen. Es entstand ein wettbewerblicher Rahmen, der dazu führte, dass Haushaltskunden ihren Anbieter für die Strom- und Gasversorgung in den letzten Jahren immer häufiger (aber immer noch auf niedrigem Niveau) gewechselt haben (vgl. BNE, 2018).

2.1.1 Wandel des Energiesystems

Zentrale Entwicklungen, die den Wandel des Energiesystems verdeutlichen, sind:

- ein kontinuierlicher Ausbau der EE und Rückgang des Einsatzes konventioneller Energieträger,
- eine erhöhte dezentrale Erzeugung und Einspeisung in das Stromnetz, verbunden mit einem Ausbau der Energienetze und
- die Zunahme volatiler Erzeugung durch EE.

Eine Energieversorgung, die auf einer Umstellung hin zu EE beruht, weg von fossilen und nuklearen Brennstoffen, geht mit einem Strukturwandel einher, welcher diverse neue Herausforderungen mit sich bringt. Die jahrzehntelange zentrale Erzeugung in Großkraftwerken ist zwar weiterhin vorhanden, nimmt aber ab. Der Strom wird vermehrt über viele, kleine Anlagen dezentral erzeugt. Der eingespeiste Strom muss trotzdem weite Strecken überwinden, denn die Verbraucherzentren liegen in Süddeutschland, während die meiste Windkraft im Norden produziert wird. Unterdessen müssen die konventionelle Erzeugung und der Verbrauch flexibler werden (vgl. BMWi, 2018b). Dies beruht insbesondere auf der Tatsache, dass die Erzeugung von Wind- und Solarenergie großen zeitlichen Schwankungen unterliegt und nur schwer prognostizierbar ist. Für einen sicheren und zuverlässigen Netzbetrieb stellt das eine

Herausforderung dar (vgl. Konstantin, 2017). Es müssen die Ein- und Auspeisung ins bzw. aus dem Netz synchron sein, um Frequenz und Spannung stabil halten zu können. Um auf einen Überschuss oder ein Defizit an Energie zu reagieren, können Netze durch Speicher und ein adaptives Lastmanagement ergänzt werden. Darüber hinaus sind weiterhin flexible Kraftwerke notwendig, wie bspw. Pumpspeicherkraftwerke oder andere Kraftwerke, die schnell Lasten variieren können, z. B. Gasturbinenkraftwerke (vgl. Bundesregierung, 2018; Konstantin, 2017). Es findet somit ein struktureller Wandel der Angebots- und Nachfrageseite statt. Besonders stehen Industrie und Haushalte im Fokus für ein Lastmanagement, um damit die Nachfrageseite zu flexibilisieren. Im Kontext von Lastverschiebemaßnahmen wird auch das gesteuerte Laden von E-Pkw analysiert, welches als zentraler Aspekt dieser Arbeit im Abschnitt 2.3.4 detailliert vorgestellt wird.

2.1.2 Stromerzeugung, Transport und Verteilung

Verschiedene Spannungsebenen der Übertragungs- und Verteilnetze ermöglichen den Transport von Strom vom Kraftwerk zum Verbraucher. Die Netzebenen der Stromerzeugung sind dabei in Deutschland wie folgt untergliedert (vgl. Schellong, 2016; Schwab, 2017):

- Transport- oder Höchstspannungsnetze (220 und 380 kV), darin speisen große Kraftwerke, wie auch große Windparks in den vier Regelzonen derzeit etwa 60 % des öffentlichen Bedarfs an elektrischer Energie ein.
- Hochspannungsnetze (60 bis 110 kV) leiten die Energie an lokale Verteilnetzbetreiber sowie Sondervertragskunden, wie z. B. Kliniken, Universitäten oder große Industrieunternehmen mit eigener 110 kV Übergabestation weiter. Bespeist wird das Verteilnetz darüber hinaus über mittlere konventionelle Kraftwerke und zunehmend auch über EE-Anlagen.
- Mittelspannungsnetze (6 bis 30 kV) beziehen die elektrische Energie aus den vorgelagerten Hochspannungsnetzen. Zudem speisen kleinere Kraftwerke, beispielsweise Gas-, Wasser- oder Pumpspeicherkraftwerke ihre elektrische Energie ein. Des Weiteren speisen ebenfalls Windkraftanlagen, Biogasanlagen und große PV-Anlagen (z. B. Freiflächen PV) in das Mittelspannungsnetz ein.

- Niederspannungsnetze (230 oder 400 V) leiten die Energie an den Endabnehmer weiter. Sie beziehen ihre Energie aus dem vorgelagerten Mittelspannungsnetz sowie von kleinen dezentralen Kraftwerken oder EE-Anlagen, z. B. PV auf einzelnen Häusern. Aufgrund des Anstiegs von PV-Anlagen auf Dächern in den letzten Jahren, nimmt der Anteil der Stromerzeugung im Niederspannungsnetz zu.

Die 220 kV- und 380 kV-Transportnetze ermöglichen den Stromtransport und gewährleisten dadurch die Durchleitung der erzeugten Energie. In Deutschland obliegt der Netzbetrieb den vier Übertragungsnetzbetreibern in ihren jeweiligen Regelzonen: Tennet TSO, 50Hertz Transmission, Amprion sowie TransnetBW. Zusätzlich ist das deutsche Energienetz in das europäische Verbundsystem European Network of Transmission System Operators for Electricity (ENTSO-E) eingebunden. Dem gegenüber sind Verteilnetzbetreiber für die Netze von bis zu 110 kV verantwortlich (vgl. Schellong, 2016; Schwab, 2017).

Netzbetreiber sind verpflichtet, neben der Verteilung und Übertragung der elektrischen Energie, Systemdienstleistungen zur Qualitätssicherung der Stromversorgung zu erbringen. Dazu zählen die Frequenz-, Spannungshaltung, Versorgungswiederaufbau nach Störungen sowie die Betriebsführung (vgl. Konstantin, 2017). Zu den Systemdienstleistungen trugen als Hauptkostenblöcke im Jahr 2016 insbesondere der Einsatz und die Vorhaltung der Netzreservekraftwerke (ca. 285 Mio. Euro), der Redispatch mit rund 220 Mio. Euro sowie die Regelleistungsvorhaltung mit insgesamt 198 Mio. Euro bei (vgl. Bundesnetzagentur und Bundeskartellamt, 2017).

2.1.3 Energiemärkte, Vertrieb und Handel

Im Energiemarkt sind mehrere Akteure (Netzbetreiber, Erzeuger, Lieferanten, Kunden, Energiebörse und sonstige Akteure, wie Portfoliomanager, Makler und Broker) aktiv (vgl. Konstantin, 2017). Die Aufgabe der Erzeuger ist es den Strom zu produzieren und diesen an die Händler zu liefern oder auch ihren eigenen Bedarf damit zu sichern. Typischerweise sind das Verbundunternehmen mit Kraftwerksparks oder Kleinproduzenten mit dezentralen Anlagen. Die Energiebörse stellt den finanziellen, technischen und rechtlichen Marktplatz für alle zugelassenen Handelsteilnehmer dar. Denn seit der Liberalisierung des Marktes sind Strom und Gas Handelsware geworden. Lieferanten sind Händler oder Kraftwerksbetreiber, die Strom verkaufen oder kaufen, d. h. sie müssen 15-minütige Fahrpläne für die Entnahme und Einspeisung

bereitstellen. An der Energiebörse ‚European Energy Exchange‘ (EEX), an der europäischen Strombörse ‚European Power Exchange‘ (EPEX)¹ sowie am außerbörslichen Markt, over the counter (OTC), findet der Stromhandel in Deutschland statt. Des Weiteren wird der Handel mit Emissionsberechtigungen ebenfalls an der EEX auf dem Spot- und Terminmarkt abgewickelt (vgl. Konstantin, 2017).

Die Großhandelsmärkte werden in Abhängigkeit des zeitlichen Horizontes zwischen Lieferung und Vertragsabschluss in die folgenden zwei Märkte untergliedert:

- Terminmarkt: Dieser Markt deckt den Handel von Energieprodukten für langfristige Geschäfte ab, die einen Zeithorizont von bis zu sechs Jahren besitzen.
- Spotmarkt: Kurzfristige Geschäfte werden über den Spotmarkt als Handelsplatz abgedeckt. Dieser ist nochmal in Intraday- und Day-Ahead-Markt aufgliedert. Auf dem Day-Ahead Strom-Spotmarkt wird der Strom für den nächsten Tag gehandelt. Diese Transaktionen geschehen u. a. auf viertelstündlicher Basis. Der kontinuierliche Intraday-Markt dient den kurzfristigen Geschäften von bis zu 5 Minuten vor Lieferung innerhalb einer Regelzone (vgl. EPEX, 2019).

Der Terminmarkt hat derzeit ein größeres Handelsvolumen als der Spotmarkt. Der EEX Terminmarkt belief sich im Jahr 2016 auf 1.466 TWh. Abhängig vom Berichtsjahr macht der Day-Ahead-Markt 85-90 % des Geschäftes auf den EPEX Spot-Märkten aus. Somit hat der Intraday-Markt eine geringere Liquidität. Im Jahr 2016 betrug das Handelsvolumen auf dem Day-Ahead-Markt an der EPEX SPOT 235 TWh und auf dem Intraday-Markt 41 TWh (vgl. Bundesnetzagentur und Bundeskartellamt, 2017).

Der Marktpreis auf dem Day-Ahead-Markt ergibt sich für jede Viertelstunde aus dem Schnittpunkt zwischen Angebots- und Nachfragekurve, dieser stellt den Gleichgewichtspreis, den market clearing price (MCP) dar. Die Angebotskurve spiegelt dabei die Merit Order wider, welche abhängig von den jeweiligen Grenzkosten der Erzeugung ist. Die Angebote auf dem Day-Ahead-Markt werden in Abhängigkeit der Grenzkosten der Stromerzeugungsanlagen abgegeben. Entsprechend der Nachfrage wird der Marktpreis dann ermittelt (vgl. Konstantin, 2017).

¹ Es bestehen gesellschaftliche Verbindungen zwischen EEX und EPEX SPOT. Letztere gehört zur EEX.

Zusätzlich ist die Vermarktung des Stromes noch über außerbörsliche Geschäfte (OTC) möglich. Diese sind bilaterale, frei verhandelbare Stromgeschäfte, die nicht über die Börse abgewickelt werden, dennoch finanzielle Transaktionen zwischen Teilnehmern am Finanzmarkt darstellen. Vertragsdetails über Laufzeit, Menge, Sonderklauseln werden in Rahmenverträgen festgehalten (vgl. Konstantin, 2017). Dieser Markt beinhaltet das größte Handelsvolumen von ca. 5.758 TWh für das Jahr 2016 (vgl. Bundesnetzagentur und Bundeskartellamt, 2017).

Durch den Intraday-Markt können nicht alle Netzabweichungen zwischen Einspeisung und Entnahme ausgeglichen werden. Daher müssen die Übertragungsnetzbetreiber eingreifen und in solchen Fällen das Gleichgewicht in ihrer Regelzone wiederherstellen. Dabei ist insbesondere die Frequenzhaltung wichtig. Plötzliche Laständerungen können dazu führen, dass die Netzfrequenz von ihrem zu haltenden Sollwert von 50 Hz und dem dazugehörigen permanenten Rauschen von $\pm 0,05$ Hz abzuweichen beginnt. Sind die Frequenzabweichungen größer als 0,05 Hz, dann ist der Betriebszustand gestört und je nach Ausprägung kann das im Extremfall bis zu einem Netzzusammenbruch führen (vgl. Swider, 2006). Die Abweichungen von mehr als 100 mHz betragen nur circa 30 h/a (vgl. Schwab, 2017). Um den Frequenzabweichungen entgegen zu wirken, sind die Übertragungsnetzbetreiber zu jeder Zeit verpflichtet drei Regelleistungen bereit zu halten, welche sich hinsichtlich Reaktionsgeschwindigkeit und Leistungs- sowie Verwendungsdauern unterscheiden und wie folgt gekennzeichnet sind (vgl. Konstantin, 2017; Bundesnetzagentur, 2019):

- Beim Auftreten einer Störung muss Primärregelreserve in 30 Sekunden aktivierbar sein und für ein Minimum von 15 Minuten vorgehalten werden. Die Primärregelreserve wird sofort und vollautomatisch abgerufen, sobald eine Gleichgewichtsstörung auftritt. Insgesamt wird die vorzuhaltende Primärregelreserve auf zurzeit 3.000 MW im gesamten ENTSO-E Verbundnetz bemessen.
- Sekundärregelreserve ist innerhalb von 5 Minuten in voller Höhe bereitzustellen.
- Tertiärregelung oder Minutenreserve soll spätestens nach 15 Minuten die Sekundärreserve ablösen. Zum Einsatz kommen nach einer manuellen Aktivierung insbesondere Pumpspeicher- und Gasturbinenkraftwerke.

Es findet eine Unterscheidung zwischen positiver und negativer Regelenergie statt. Übersteigt die eingespeiste Energie die zum selben Zeitpunkt entnommene Energie

im Netz, liegt ein Leistungsüberschuss im Netz vor. In dieser Situation benötigt der Netzbetreiber negative Regelleistung bspw. durch Stromabnehmer, um dem Netz kurzfristig Strom zu entziehen. Gibt es eine nicht prognostizierte, erhöhte Stromnachfrage, die nicht von der zu erwartenden Einspeisung gedeckt wird, ist positive Regelleistung erforderlich. In diesem Fall benötigt der Netzbetreiber kurzfristig bspw. zusätzliche Einspeisung von Energie in das Netz (vgl. Schwab, 2017).

Ein aktueller Trend der Energieversorger ist gekennzeichnet durch das zunehmende Interesse an der Nutzung von Demand Response (DR)-Programmen, um Erzeugung und Nachfrage effizienter aufeinander abzustimmen. Mit Hilfe von Anreiz- und preisbasierten DR-Programmen soll eine Nachfragesteuerung ermöglicht werden (vgl. Paterakis et al., 2017).

2.1.4 Das energiewirtschaftliche Zieldreieck

Schon lange verfolgt die Bundesregierung das energiewirtschaftliche Zieldreieck (vgl. BMWi, 2018b). Dieses spiegelt die folgenden drei Ziele wider (siehe Abbildung 2.1):

- sicher – steht für die Versorgungssicherheit und damit für die Zuverlässigkeit,
- sauber – beinhaltet die Umweltverträglichkeit und die Nachhaltigkeit sowie
- bezahlbar – bezieht sich auf die Wirtschaftlichkeit.

Oftmals wird dieses Dreieck auch Energie Trilemma genannt (vgl. Gunningham, 2013). Es gibt dafür einen eigenen internationalen Index, den World Energy Trilemma Index, des World Energy Council (WEC), welcher die Balance der drei Zielgrößen für die jeweiligen Energiesysteme der Länder beobachtet. Deutschland belegte im Jahr 2017 Platz sechs, Dänemark ist Spitzenreiter von den 125 bewerteten Ländern (vgl. World Energy Council, 2017). Die Begrifflichkeit des Trilemmas beruht auf der Konkurrenz zwischen den drei Dimensionen. Die geometrische Figur der drei gleichen Seiten suggeriert eine Gleichrangigkeit der Ziele, aber dennoch kollidieren die Ziele auch miteinander. Ein Beispiel dafür ist die Stromerzeugung mit einem Kohlekraftwerk, welches zu niedrigen variablen Kosten produziert, relativ zuverlässig ist, aber einen hohen Ausstoß an CO₂-Emissionen hat. Es gibt ein Trade-Off, also einen Zielkonflikt, zwischen den drei Dimensionen.



**Abbildung 2.1: Das energiewirtschaftliche Zieldreieck;
Quelle: nach Hauff et al. (2011)**

Inzwischen gibt es nach Hauff et al. (2011) eine Erweiterung auf ein energiepolitisches Zielviereck, welches die gesellschaftliche Akzeptanz miteinschließt.² Einen möglichen Lösungsansatz zur Bewertung des Energie-Trilemmas liefern Heffron et al. (2015), die als Bindeglied der drei Dimensionen die ‚Energiegerechtigkeit‘ sehen und dafür entsprechend eine Metrik einführen. Diese beurteilt mit Hilfe eines Dreiecksdiagramms den idealen Punkt zwischen den drei Dimensionen des Energie-Trilemmas und inwieweit davon abgewichen wird. Zur Berechnung der Metrik, welche aus verschiedenen Parametern besteht, wird auf unterschiedliche Kennzahlen zurückgegriffen. Dazu zählen u. a. nationale Energiegerechtigkeit, Energiegerechtigkeit für verschiedene Arten von Energieinfrastrukturen und deren wirtschaftliche Bewertung. Diese Metrik ist komplexer als die des WEC.

Die Kombination der drei Komponenten sowie die Verbindung mit Geschäftsmodellen wird in dieser Arbeit aufgegriffen und im Abschnitt 2.3.4 ebenfalls auf die Elektromobilität bezogen.

2.1.4.1 Versorgungssicherheit – Zuverlässigkeit

Als Versorgungssicherheit wird die dauerhafte und nachhaltige Bedarfsdeckung bezeichnet. Des Weiteren zählen die folgenden vier Aspekte zum Thema Versorgungssicherheit im Kontext der Elektrizitätsversorgung dazu (vgl. BNetzA, 2018):

- die Vorhaltung der Transportkapazitäten für den Elektrizitätstransport,

² Im weiteren Verlauf der Ausführungen steht das energiewirtschaftliche Zieldreieck im Fokus. Der Aspekt der Akzeptanz wird im Ausblick der Arbeit wieder aufgegriffen.

- die Notwendigkeit ausreichender Erzeugungskapazitäten zur Befriedigung der Elektrizitätsnachfrage,
- die Gewährleistung der Netz-/ Systemstabilität durch belastbare Regelungsmechanismen sowie
- eine Absicherung gegen Eingriffe Dritter durch eine hinreichende technische Systemsicherheit.

Redispatch und Netzstabilisierungsmaßnahmen haben in den letzten Jahren zugenommen. Von 2014 auf 2015 hat sich die Redispatchgesamtmenge auf 16.000 GWh verdreifacht (vgl. BNetzA, 2016). Der Redispatch ist notwendig, um die Nachfrage und das Angebot an Elektrizität im Übertragungsnetz auszugleichen. Einhergehend mit der Versorgungssicherheit ist die Notwendigkeit des Ausbaus der überregionalen Übertragungsnetze sowie der lokalen Verteilnetze verbunden (vgl. BMWi, 2018b). Somit spielt die netzseitige Betrachtung eine wichtige Rolle, wenn von Versorgungssicherheit gesprochen wird.

Die Versorgungssicherheit in Deutschland ist im internationalen Vergleich auf einem hohen Niveau. Im Jahr 2014 kam es zu einer durchschnittlichen Versorgungsunterbrechung von 12 Minuten, gerechnet auf alle angeschlossenen Letztverbraucher innerhalb eines Jahres. Dieser Wert ist im Gegensatz zu Italien mit 41 Minuten oder die USA mit 114 Minuten vergleichsweise niedrig (vgl. BMWi, 2017).

Unter staatlicher Aufsicht, in Form der Bundesnetzagentur, liegt die Wahrung der Versorgungsqualität. Versorgungsqualität ist der Oberbegriff für Spannungs- und Servicequalität (Vertrags-, Störungs-, Abrechnungsmanagement) sowie Zuverlässigkeit und wird zusätzlich mit Hilfe der folgenden Kriterien bewertet (vgl. Schwab, 2017):

- Sicherheit, d. h. die Versorgung bleibt gewährleistet beim Auftreten einer Störung und dabei ohne Überlastung eines Betriebsmittels. Dieses geschieht mit dem (n-1)-Prinzip, d. h. bei einem Ausfall einer Komponente ist weiterhin ein sicherer Betrieb gewährleistet.
- Zuverlässigkeit quantifiziert die Versorgungsunterbrechung anhand der Dauer nach bzw. bei einer Störung. Je nach Spannungsebene unterscheiden sich die tolerierbaren Zeitspannen.

- Verfügbarkeit quantifiziert inwieweit ein Kraftwerk oder Betriebsmittel innerhalb eines Betriebszeitraums (z. B. ein Jahr) zur Verfügung steht oder stand.

2.1.4.2 Wirtschaftlichkeit

Der Weltenergieericht achtet bei der Preisgestaltung der Stromversorgung insbesondere auf die Bezahlbarkeit für die Bevölkerung (vgl. World Energy Council, 2017). Ein Aspekt sind hierbei die Gesamtkosten der Stromversorgung, dazu zählen u. a. die Stromgestehungskosten. Werden die EE näher betrachtet, dann stehen insbesondere Integrationskosten im Vordergrund. Hierzu zählen insbesondere Mehrkosten für den Netzausbau, mögliche benötigte Speicher und Reserven.

Die Strompreise für Haushaltskunden setzen sich aus drei wesentlichen Faktoren zusammen. Zum einen sind das die Kosten für Beschaffung und Vertrieb des Stromes sowie zum anderen die Entgelte für die Netznutzung. Als letztes kommen staatlich veranlasste Preisbestandteile dazu, welche beispielsweise Steuern oder EEG-Umlagen sind. Dabei entfielen auf die staatlich veranlassten Bestandteile über 50 % des Strompreises im Jahr 2017 in Deutschland. Der Bestandteil der Beschaffung und des Vertriebes kann unterschiedlich hoch sein, je nach Stromanbieter. Dieser Bestandteil gilt als Wettbewerbsanteil, da Kunden ihren Stromliefervertrag frei wählen können. Mit 21 % stellt der sogenannte Wettbewerbsanteil den geringsten Anteil des HH-Preises dar. Auf die Netzentgelte entfielen 25 % des Strompreises (vgl. BMWi, 2018a).

2.1.4.3 Umweltverträglichkeit – Nachhaltigkeit

Oftmals wird mit dem Begriff der Umweltverträglichkeit die Reduktion der CO₂-Emissionen verbunden. Dies greift aber zu kurz, da bspw. auch die Steigerung von Energieeffizienz positive Effekte hat, die zu berücksichtigen sind. Dazu könnte zählen, dass der Wirkungsgrad erhöht wird. Damit kann bei gleicher eingesetzter Energiemenge mehr produziert werden bzw. bei geringerer Energienachfrage die Produktion reduziert werden (vgl. Pittel, 2012). Des Weiteren enthält die Begrifflichkeit Nachhaltigkeit insbesondere die EE, d. h. einen möglichst hohen Anteil an EE an der Stromerzeugung. Dadurch reduzieren sich die CO₂-Emissionen der Erzeugung, wie im späteren Verlauf in Abschnitt 2.2.3 noch verdeutlicht wird. Zusätzlich ist ein Vorteil der EE, dass die Grenzkosten nahezu mit Null angesetzt werden. Ebenso sind die Stromgestehungskosten in den letzten Jahren erheblich gesunken und konkurrieren nun mit denen fossiler Kraftwerke (vgl. Fraunhofer ISE, 2018). Nachteilhaft kann wiederum die Lokalität der Erzeugung gesehen werden und der damit verbundene

Transportbedarf sowie die Abregelung aufgrund der geringen Steuerbarkeit der Erzeugung.

Einen weiter zu berücksichtigenden Aspekt bilden die E-Pkw. Es wird im Verkehrssektor der Umstieg auf abgasfreie bzw. abgasarme Fahrzeuge gefördert. Dadurch soll sich die Luftqualität verbessern, insbesondere in Ballungszentren. Für E-Pkw wurde ein finanzieller Kaufanreiz eingeführt (vgl. Bundesregierung, 2018). E-Pkw können neben den reduzierten Emissionen und geringerer nationaler Ölabhängigkeit ebenfalls durch die Reduktion des Lärms, zumindest innerhalb der Stadtgrenzen bei niedrigeren Geschwindigkeiten, zur Verbesserung der Lebensverhältnisse beitragen (vgl. Fraunhofer ISE, 2018).

2.2 Erneuerbare Energien und Emissionen

Mit dem Ziel der Bundesregierung den Anteil der EE am Bruttostromverbrauch im Jahre 2020 auf 35 % zu erhöhen, vollzieht Deutschland immer weiter die Energiewende und geht einen Schritt in Richtung einer nachhaltigen Energiezukunft (vgl. BMWi, 2017). Im Jahr 2017 belief sich der Anteil der EE am Bruttostromverbrauch von Deutschland zum ersten Mal über 35 %, nämlich 36,2 % und somit wurde ein erstes Teilziel der Energiewende erreicht. Als langfristiges Ziel ist dann 80 % am Bruttostromverbrauch bis 2050 von EE bzw. 60 % Anteil an EE am Bruttoendenergieverbrauch vorgesehen (vgl. UBA, 2018).

In Abbildung 2.2 ist der Anteil der Energieträger an der Bruttostromerzeugung von 654 TWh in Deutschland im Jahr 2017 zu sehen. Die EE haben einen Beitrag von 217,9 TWh geliefert (vgl. UBA und AGEE, 2018).

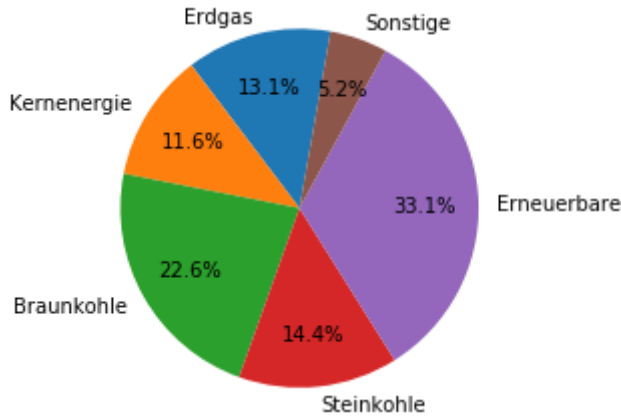


Abbildung 2.2: Anteil der Energieträger an der Bruttostromerzeugung in Deutschland im Jahr 2017; Datenquelle: UBA und AGEE (2018)

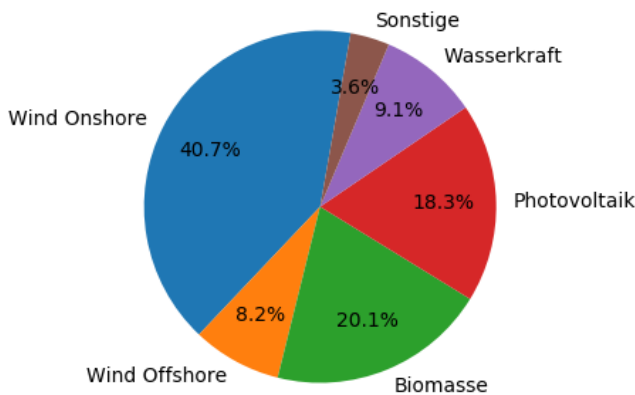


Abbildung 2.3: Anteil der EE an der Bruttostromerzeugung in Deutschland im Jahr 2017; Datenquelle: UBA und AGEE (2018)

Dabei wird in der Abbildung 2.3 deutlich, dass Wind und PV die Energieträger sind, die einen hohen Beitrag an der EE-Stromerzeugung für Deutschland leisten. Wind onshore ist weiterhin stärkste erneuerbare Quelle. Trotz dem steigenden Erzeugungsanteil an EE in Deutschland sinken die CO₂-Emissionen relativ langsam (siehe Abschnitt 2.2.3). Im Energieerzeugungsmix steigt mit einem zunehmenden Anteil an EE eine fluktuierende Einspeisung. Für die Gewährleistung eines stabilen und sicheren Energienetzes sind weiterhin, wie bereits im Abschnitt 2.1 erwähnt, u. a. flexible Kraftwerke oder Laststeuerung notwendig.

2.2.1 Photovoltaik

In Deutschland liefert PV einen immer größeren Beitrag zur Stromversorgung. Dieser Trend beruht auf einer steigenden Anzahl an installierter Leistung an PV, in Abbildung 2.4 dargestellt.




Abbildung 2.4: Entwicklung der installierten Leistung von PV (2005 – 2017); Datenquelle: UBA und AGEE (2018)

Die Stromerzeugung aus PV unterliegt Schwankungen, sowohl über den Tages- als auch den Jahresverlauf. Mit zunehmend verbesserten Wetterprognosen wird die Vorhersage der Stromerzeugung jedoch planbar. Die Prognosegüte und damit die Abweichungen zwischen den Vorhersagen und den real eingetretenen Werten sind deutlich von dem Vorhersagehorizont abhängig (vgl. Magdowski und Kaltschmitt, 2017). Daher ist es ein wichtiger Aspekt die auftretenden Planungsunsicherheiten mit zu berücksichtigen.

Die Stromerzeugung aus PV-Anlagen wird von verschiedenen Faktoren bestimmt. Der zu erwartende Ertrag, der durch eine PV-Anlage erzielt wird, ist im Wesentlichen durch die Globalstrahlung des jeweiligen Ortes bestimmt. Je höher die Globalstrahlung, desto mehr Strom kann erzeugt werden. Die horizontale Globalstrahlungssumme variiert in Deutschland von 950 kWh/m²/a in den nördlichen Gefilden, währenddessen Süddeutschland mit bis zu 1.250 kWh/m²/a rechnen kann (vgl. Fraunhofer ISE, 2012). Die Nennleistung von PV-Modulen wird in Watt-peak (W_p) angegeben und beschreibt die Spitzenleistung, die diese unter optimalen Bedingungen erreichen kann. Neben dem Aspekt des Wirkungsgrades sind für die Effizienz der PV-Module ebenfalls Faktoren, wie die PV-Modulausrichtung (Azimut), der Degradierungsgrad

der PV-Module, die Verschmutzung oder die Verschattung der Anlage relevant (vgl. Fraunhofer ISE, 2014).

2.2.2 Wind

Die Stromerzeugung aus Wind findet hauptsächlich in den Nordgebieten von Deutschland statt, sowohl mit Onshore als auch Offshore Anlagen. Die Verbraucherschwerpunkte liegen hingegen eher in Süddeutschland. Somit stellt dieses Ungleichgewicht von Stromnachfrage und Windangebot eine Herausforderung an Kraftwerks- und Netzbetreiber dar. Für Investitionsentscheidungen sind neben windreichen Standorten und installierten Windleistungen, ebenso der Stromtransport in andere Regionen, der Stromnetzausbau und die Akzeptanz bedeutsam.

Im weiteren Verlauf der Arbeit steht eine lokale Energieversorgung im Vordergrund. Da das Fallbeispiel in Süddeutschland liegt, ist insbesondere die dort verstärkt auftretende PV-Stromerzeugung von Interesse und Wind findet in den Ausführungen keine Berücksichtigung mehr.

2.2.3 Emissionen

Die CO₂-Emissionen in Deutschland sollen bis 2050 gegenüber 1990 um 80 bis 95 % reduziert werden. Ein Vergleich der Jahre 2015 und 1990 zeigt, dass der Treibhausgasausstoß bereits um 27 % zurückgegangen ist (vgl. BMWi, 2017). Doch in den Jahren 2014 bis 2017 stagniert der Rückgang der Treibhausgas-Emissionen, so dass Deutschland bis 2017 seine Emissionen gegenüber 1990 nur um 27,7 % gesenkt hat (vgl. Agora Energiewende, 2018). Somit rückt das Ziel von 40 % Reduktion im Jahre 2020 in weite Ferne. Die Abbildung 2.5 zeigt in Abhängigkeit vom Energieträger die CO₂-Emissionen der Stromerzeugung für Deutschland im Jahr 2017. Die Stromerzeugung hat im Jahr 2017 insgesamt 292 Mio. t an CO₂-Emissionen verursacht. Die durchschnittliche Emissionsintensität des Strommixes³ hat einen fallenden Trend und befindet sich im Jahr 2017 bei ca. 500 g CO₂/kWh (vgl. Agora Energiewende, 2018; IEA, 2018a).

³ Dieser Wert ist auf den inländischen Nettostromverbrauch bezogen.




Abbildung 2.5: CO₂-Emissionen der Stromerzeugung von Deutschland im Jahr 2017;
Datenquelle: Agora Energiewende (2018)




Abbildung 2.6: Vermiedene Treibhausgas-Emissionen durch die Nutzung EE im Jahr 2017 (Netto-Bilanz);
Datenquelle: UBA und AGEE (2018)

Die Abbildung 2.6 zeigt die Netto-Bilanz der vermiedenen Treibhausgas-Emissionen im Jahr 2017 durch die Nutzung von EE in den Sektoren Strom- und Wärmeerzeugung sowie Verkehr. Insgesamt konnten rund 178,6 Mio. Tonnen CO₂-Äquivalente vermieden werden. Entsprechend der dargestellten Grafik wird deutlich, dass insbesondere Wind Onshore als auch Biomasse zur Reduktion beitragen.

Wie bereits im Abschnitt 2.1.3 kurz aufgegriffen gibt es einen CO₂-Emissionshandel. Der Emissionsrechtehandel ist ein marktwirtschaftliches Instrument, welches dazu beitragen soll, das Klima zu schützen und die umweltschädlichen Emissionen zu reduzieren und zu begrenzen. Das europäische Emissionshandelssystem (EU-ETS) trat 2005 in Kraft. Die Funktionsweise des EU-ETS beruht dabei auf dem „cap and trade“ Ansatz. Es wird eine Emissionsobergrenze (cap) für die regulierten Sektoren und die emissionshandlungspflichtigen Anlagen vom EU-ETS festgelegt. Diese werden als handelbare Rechte ausgegeben und können auf dem Markt frei gehandelt werden. Dadurch entsteht ein Preis für die Treibhausgasemissionen sowie ein Anreiz für die

Unternehmen, ihren Ausstoß zu reduzieren (vgl. Schwab, 2017; BMU, 2013; Umweltbundesamt, 2017).

Das Beispiel des eingeführten EU-ETS zeigt, dass die externen Effekte⁴ und somit die volkswirtschaftlichen Auswirkungen Berücksichtigung finden, um damit die Umwelt nachhaltiger zu gestalten. D. h. es werden immer mehr die CO₂-Vermeidungskosten⁵ mitberücksichtigt. Dennoch ist fraglich, inwieweit der aktuelle Zertifikatspreis mit unter 20 € pro Tonne CO₂-Äquivalent den zukünftigen Schäden des Klimawandels gerecht wird (vgl. EEX, 2018).

Die Förderung von EE führt dazu, dass durch sog. Lerneffekte Kosten gesenkt werden und somit diese Technologien für die Zukunft attraktiver werden (vgl. Schmidt et al., 2017). Dies bewirkt, dass ein weiterer Bereich erschlossen wird, um CO₂ zu vermeiden. Insbesondere werden aber auch Anreize für die Unternehmen geschaffen, Emissionsreduktionsmaßnahmen durchzuführen.

Durch die Verwendung von E-Pkw können weitere Emissionsreduktionspotenziale genutzt werden, dieses bezieht sich dann insbesondere auf den Verkehrssektor. Dennoch ist gerade mit der aktuellen Debatte bzgl. Feinstaubbelastungen die Wirkung auch hinsichtlich anderer Emissionen nicht zu vernachlässigen. Die E-Pkw können dabei jedoch nur einen Teil zur Lösung beitragen. (vgl. Umweltbundesamt, 2018).

2.3 Elektromobilität und Elektrofahrzeuge

Bis Anfang 2018 ist der weltweite Bestand an E-Pkw auf über 3,2 Mio. Fahrzeuge gestiegen. Im weltweiten Vergleich befindet sich Deutschland bzgl. der Absatztrends von Elektroautos (E-Pkw, PHEV) des Jahres 2017 mit ca. 55.000 neuzugelassenen Fahrzeugen auf dem vierten Platz. Spitzenreiter ist China, wo allein im Jahr 2017 579.000 Fahrzeuge ausgeliefert wurden, was rund die Hälfte des weltweiten Absatzes ausmacht. Die USA (195.000 Fahrzeuge) und Norwegen (62.000 Fahrzeuge) folgten auf den Plätzen zwei und drei (vgl. ZSW, 2018; IEA, 2018). In Bezug auf den Anteil

⁴ „Externe Effekte sind unmittelbare Auswirkungen der ökonomischen Aktivitäten eines Wirtschaftssubjektes (Unternehmen, private und öffentliche Haushalte) auf die Produktions- oder Konsummöglichkeiten anderer Wirtschaftssubjekte, ohne dass eine adäquate Kompensation erfolgt. Je nach Wirkungsrichtung lassen sich positive externe Effekte (externe Nutzen) und negative externe Effekte (externe Kosten) unterscheiden. Diese Definition geht historisch auf die wohlfahrtstheoretischen Überlegungen von Pigou (1912) zurück.“ (vgl. Krewitt und Schlomann, 2006, S. 1)

⁵ Die CO₂-Vermeidungskosten sind die effektiven Kosten, welche pro Tonne vermiedener CO₂-Emissionen durch eine Klimaschutzmaßnahme benötigt werden (vgl. Paschotta, 2018).


der Elektroautos an den gesamten Neuzulassungen ist Norwegen (39 %) vor den Niederlanden (11,7 %) und vor Schweden (6,3 %) auf den vorderen Plätzen im Jahre 2017 zu finden. Deutschland ordnet sich mit 1,6 % auf dem 8. Platz ein (vgl. IEA, 2018b).

Im Bereich der Elektromobilität ist in den nächsten Jahren global mit einer dynamischen wirtschaftlichen und technischen Entwicklung zu rechnen. Elektromobilität ist ein elementarer Bestandteil der sich weltweit vollziehenden Mobilitätswende, hin zu einer klimafreundlicheren Mobilität (vgl. NPE, 2016).

2.3.1 E-Pkw-Entwicklung und -Potenziale

Im Jahre 2009 wurde der Nationale Entwicklungsplan Elektromobilität von der Bundesregierung verabschiedet mit dem gesetzten Ziel, dass 1 Million E-Pkw auf den deutschen Straßen bis zum Jahr 2020 zugelassen sein sollen (vgl. Bundesregierung, 2009). Bis zum 1. Januar 2018 wurden insgesamt 53.861 E-Pkw sowie 236.710 Hybrid-Fahrzeuge (HEV) und darunter 44.419 Plug-In Hybrid Fahrzeuge (PHEV) zugelassen (vgl. KBA, 2018). Die Entwicklung des Fahrzeugbestands zwischen 2008 und 2017 an E-Pkw (und HEV mit PHEV) ist in Abbildung 2.7 dargestellt.

Der erste verbrennungsmotorbetriebene Pkw wurde in Deutschland gebaut und bei der Elektromobilität soll Deutschland nun auch eine Vorreiterrolle übernehmen. Neben absatzstarken chinesischen Marken (BYD, BAIC) ist mit Tesla in den USA ein Pionier vertreten, der im Jahr 2017 über 100.000 E-Pkw verkauft hat. Die deutschen Marken wie BMW oder VW reichen mit Absatzzahlen von 67.940 bzw. 52.520 noch nicht ganz an diese Spitzenwerte heran (vgl. ZSW, 2018).



**Abbildung 2.7: Entwicklung der Anzahl von E-Pkw in Deutschland (2010 - 2017);
Datenquelle: KBA (2018)**

Auch 2018 ist der Markthochlauf in Deutschland noch hinter den Erwartungen zurückgeblieben. Ein Problem ist auf Herstellerseite zu sehen. Die Nachfrage ist aktuell größer als das Angebot an E-Pkw. Die Lieferzeiten belaufen sich auf mehrere Monate bis fast ein Jahr (vgl. Spiegel Online, 2018). Andere Hindernisse sind die Anschaffungsausgaben für das Fahrzeug, die limitierte Reichweite sowie die noch nicht ausreichend zuverlässige Ladeinfrastruktur (vgl. NPE, 2014). Aufgrund von Lernkurven- sowie Skaleneffekten kann insbesondere bei den Batteriekosten erwartet werden, dass sich diese reduzieren (vgl. Schmidt et al., 2017). Die Batteriereichweite und die dazugehörige Energiedichte können durch technologische Entwicklungen weiter verbessert werden. Dazu zählen ebenfalls Fortschritte und Optimierungen bei Systemintegration, Zellen und Batteriemanagementsystemen. Des Weiteren können Aspekte wie eine längere Lebensdauer der Batterie und insbesondere eine verkürzte Ladezeit positive Auswirkungen auf die E-Pkw Entwicklung haben. Es wird zwischen 2020 und 2030 mit einem Durchbruch der Elektromobilität gerechnet (vgl. NPE, 2016). Neben dem Fahrzeugangebot ist der Nutzer ein entscheidender Erfolgsfaktor für die weitere Entwicklung der Elektromobilität. Die Kaufentscheidung hängt von drei Hauptfaktoren ab – der Preis des E-Pkw, der Reichweite des E-Pkw und damit einhergehend die Verfügbarkeit der Ladeinfrastruktur. Entsprechende Maßnahmenpakete werden länderspezifisch mit Berücksichtigung der lokalen, ökologischen und ökonomischen Rahmenbedingungen eingeleitet. Die Förderung der Elektromobilität kann auf ein umfangreiches Instrumentarium zurückgreifen. Hierzu zählen monetäre Anreize durch Kaufprämien oder Steuervorteile genauso wie nicht-monetäre Instrumente, wie Sondernutzungsrechte (vgl. NPE, 2014). Die Wettbewerbsfähigkeit der E-

Pkw ist im Vergleich zu den Fahrzeugen mit Verbrennungsmotoren noch ausbaufähig. Zu den Aspekten zählen neben dem Verkaufspreis und der Reichweite ebenso eine nutzergerechte Variantenvielfalt. Dahingehend haben deutsche Hersteller, wie BMW, Daimler und Volkswagen, weitere Modelle in den Segmenten der (teil-) elektrisch angetriebenen Fahrzeuge angekündigt, d. h. sie bereiten eine Anpassung ihrer Produktpalette vor (vgl. Clausen, 2018).


Einer Studie der Boston Consulting Group zufolge werden ab circa 2025 noch geringere total cost of ownership (TCO), Gesamtbetriebskosten, aufgrund von sinkenden Batteriekosten und steigenden Kraftstoffpreisen, zu einem stärkeren Zuwachs an E-Pkw führen. Der rechtliche Rahmen, welcher den CO₂-Ausstoß immer weiter reguliert, wird ebenfalls einen positiven Impuls liefern (vgl. BCG, 2018). Ab 2020 gelten für Neuwagenzulassung die CO₂-Zielwerte von 95 g CO₂/km. Ein neuer CO₂-Flottengrenzwert ist nach 2020 wahrscheinlich (vgl. VDA, 2017). Für 2030 wird ein Zielwert von unter 70 g CO₂/km anvisiert, da die CO₂-Emissionen der Pkw im Vergleich zum Jahr 2021 auf 37,5 % gesenkt werden sollen (vgl. Reuters, 2018). Zudem kann der rechtliche Rahmen z. B. Steuern auf die Fahrzeugzulassung erheben und dadurch Einfluss nehmen. Die Prognosen für Elektro- und Hybridantriebe in Europa erreichen Marktanteile von über 40 % im Jahr 2030 (vgl. IEA, 2018b).

Im energiewirtschaftlichen Bereich gibt es Möglichkeiten, welche derzeit noch ungenutzt sind, um Steuerungsmechanismen und damit auch das Potenzial der E-Pkw weiter voranzutreiben. Denn häufig besitzen die E-Pkw durchschnittliche Batteriezustände, state of charge (SOC), von über 70 %, bei Tesla Roadster wurden sogar bis zu 85 % beobachtet. Hinzukommt, dass die E-Pkw ca. 40 % des Tages am Netz angeschlossen sind, davon nur ein Viertel der Zeit zum Laden nutzen, der Rest der Zeit könnte für ein LVP verwendet werden (vgl. Brandt et al., 2017).


2.3.2 Mobilitätsverhalten

In Deutschland gibt es über 45 Mio. Pkw und der Bestand an Kraftfahrzeugen (Kfz) beläuft sich auf knapp 56 Mio. im Jahr 2017 (vgl. KBA, 2018). Das Mobilitätsverhalten hat sich seit den 90er Jahren bis 2010 nur gering verändert, wenn das Mobilitätspanel herangezogen wird. Insbesondere Mobilitätskenngrößen, wie Anzahl Wege, Verkehrsleistung oder Verkehrsbeteiligung sind ähnlich innerhalb dieser Jahre. Dennoch sind Trends zu erkennen. Beispiele dafür sind eine Zunahme des öffentlichen Personennahverkehrs (ÖPNV) und der Fahrradnutzung oder eine leichte Abnahme der zurückgelegten Wege (vgl. BMVBS, 2011).

Wird die Mobilitätsstudie ‚Kraftfahrungsverkehr in Deutschland‘ 2010, welche den Fokus auf den Wirtschaftsverkehr legt, näher untersucht, dann belaufen sich die gesamten durchschnittlich zurückgelegten Pkw Strecken auf ca. 33 km pro Tag. Die Hälfte einzelner Wege beläuft sich auf weniger als 10 km (vgl. BMVBS, 2012a). An den Wochenenden und Feiertagen werden die Fahrzeuge weniger bewegt als unter der Woche von Montag bis Freitag.



(a) Wegzwecke



(b) Personenkilometer



Abbildung 2.8: Wegzwecke nach Verkehrsaufkommen und Verkehrsleistung; Datenquelle: BMVBS (2012a)

Für die Ermittlung der Alltagsmobilität der Bevölkerung von Deutschland wurde eine Vielzahl an Studien durchgeführt. Mit diesen Daten kann die Verkehrsinfrastruktur entsprechend den Bedürfnissen der Bevölkerung gestaltet werden. Beispiele für Mobilitätsstudien sind:

- MiD (Mobilität in Deutschland): Im Jahr 2002, 2008 und 2017 fanden diese Erhebungen statt. Sie dienten zur Ableitung von Erkenntnissen über die Alltagsmobilität in Deutschland von unterschiedlichen Bevölkerungsgruppen und Regionen. Die Basisstichprobe umfasste knapp 26.000 Haushalten. Zwischen Juni 2016 und September 2017 wurden ca. 155.000 Haushalte in Deutschland befragt (vgl. BMVBS, 2010; BMVi, 2018b).

- MOP (Deutsches Mobilitätspanel) ist eine seit 1994 jährlich durchgeführte Paneluntersuchung zum Verkehrsverhalten von Deutschland. Dies ist eine tagebuchgestützte Befragung von ca. 1000 Haushalten, die ihre Mobilität eine Woche aufzeichnen (vgl. BMVBS, 2011).
- KiD (Kraftfahrungsverkehr in Deutschland): Wie bereits erwähnt, wurde diese Studie im Jahr 2002 sowie im Jahr 2010 durchgeführt. Über 70.000 Stichprobenfahrzeuge vermitteln einen Überblick über das Mobilitätsverhalten in Deutschland und zwar flächendeckend sowie insbesondere des Wirtschaftsverkehrs (vgl. BMVBS, 2012b).

Die verschiedenen Wegzwecke sind in der Abbildung 2.8 dargestellt. Von Interesse sind dabei ebenfalls die verschiedenen Nutzergruppen auf die im Folgenden eingegangen wird.

2.3.2.1 Pendlerverkehr

Im Datensatz vom KiD 2010 sowie vom MOP 2008 sind die häufigsten Fahrtzwecke der Weg zur Arbeit oder der Weg nach Hause. Demnach nimmt die Gruppe der Pendler einen signifikanten Anteil des deutschen Verkehrs ein. Die Zahl der Pendler steigt ständig. Im Jahr 2000 waren es in Deutschland noch 53 %, die in eine andere Gemeinde pendeln, demgegenüber sind es im Jahr 2016 schon 60 % aller Arbeitnehmer und insgesamt rund 18,4 Mio. Menschen. Die zurückgelegte Distanz hat sich dabei ebenfalls erhöht auf nun mehr durchschnittlich knapp 17 km (vgl. FAZ, 2017). Davon fahren 68 % mit dem Auto zur Arbeitsstätte (vgl. Wiwo, 2017).

In ersten Studien zu CO₂-Emissionsminderungspotenzialen durch E-Pkw im Pendlerverkehr, wie z. B. von Ensslen et al. (2017), sind die Einsparpotenziale von CO₂ durch E-Pkw bei Pendlern im grenzüberschreitenden Verkehr untersucht worden und erste Ergebnisse wurden daraus abgeleitet. Gerade durch die hohe Regelmäßigkeit erscheinen diese Fahrten sehr für die Elektromobilität geeignet.

2.3.2.2 Gewerbliche Flotten

Bei den Neuzulassungen des deutschen Automobilmarktes machen ca. ein Drittel der Fahrzeuge private Halter aus. Die restlichen zwei Drittel sind gewerblich registrierte Flotten. Dazu zählen Dienstwagen und Fuhrparkfahrzeuge, insbesondere für Unternehmen von Autovermietung, Handwerk oder Vertrieb. Jedoch verbleiben die gewerblichen Fahrzeuge nicht lange im Besitz der Unternehmen, weswegen knapp 90 %

des gesamten Fahrzeugbestands von Deutschland in Besitz von privaten Haltern sind (vgl. KBA, 2018b; Statista, 2018b).

Die Elektrifizierung des gewerblichen Verkehrs hat mehrere Vorteile. Laut Ketelaer et al. (2014) zählen dazu die relativ hohe jährliche Kilometerleistung, welche die TCO reduziert, die Regelmäßigkeit der Nutzung, die Planbarkeit mit Hilfe eines Flottenmanagers sowie E-Pkw spezifische Vorteile. Somit ist es nicht verwunderlich, dass bspw. bei Kurierdiensten vermehrt E-Pkw oder E-Vans Einzug in die Flotten halten. Die Routen sind vorher relativ fixiert und entsprechend sind die Fahrzeuge planbar. Ein Beispiel dafür sind die Streetscooter von der Deutschen Post DHL Group. Zusätzlich zählen E-Bikes und E-Trikes zur Elektroflotte der Deutschen Post DHL Group, welche sie zur aktuell größten Elektroflotte Deutschlands macht (vgl. DPDHL, 2018).

2.3.3 E-Pkw-Konzepte

Als E-Pkw⁶ wird i. d. R. ein Pkw verstanden, welcher einen elektrischen Antriebsstrang besitzt. Zu den elektromobilen Antriebskonzepten zählen neben anderen Fahrzeugtypen wie Busse, Lastkraftwagen, vor allem die Zweiräder, wie E-bikes, Pedelecs oder elektrifizierte Motorroller. Zusätzlich gibt es eine Reihe an elektrifizierten Antriebssträngen im Segment der Pkw. Micro-, Mild- und Vollhybride repräsentieren Konzepte, in denen der Verbrennungsmotor der Hauptantrieb ist, deswegen findet sich auch der Begriff autarke Hybride wieder (vgl. Hofmann, 2014). Micro-Hybride haben einen kleinen E-Antrieb mit 2-3 kW, eine start-stopp Vorrichtung und eine eingeschränkte Rekuperation. Dadurch können zwischen 5 – 10 % des Verbrauchs (NEFZ basiert)⁷ eingespart werden. Die Mild-Hybride zeichnen sich durch eine Rekuperation und elektrifizierte Fahrten bei niedrigen Geschwindigkeiten aus. Die Verbrauchseinsparungen liegen hier bei ca. 10 – 20 %. Der Full-Hybrid hat eine Batteriekapazität von max. 5 kWh und dadurch wird es möglich kurze Strecken mit Elektroantrieb zurückzulegen. Der Toyota Prius ist ein bekannter Vertreter dieses Fahrzeugtyps (vgl. Hofmann, 2014).

Die folgende Abbildung 2.9 zeigt die verschiedenen Antriebskonzepte der Fahrzeuge. Es kann zwischen PHEV, batterieelektrischen Fahrzeugen (reine Elektrofahrzeuge, BEV bzw. E-Pkw), Hybridfahrzeugen (parallele HEV), serielle Hybriden (E-Pkw mit

⁶ In dieser Arbeit werden nur BEV näher untersucht.

⁷ Die CO₂-Emissionen können reduziert werden, da der Stromverbrauch vom Netz mit 0 g CO₂/km angenommen wird.

Reichweitenverlängerung, REEV), Brennstoffzellenfahrzeugen (FCEV) unterschieden werden. BEV haben einen rein-elektrischen Antriebsstrang. Bei PHEV und REEV gibt es zusätzlich zum Ladestecker noch die Möglichkeit, das Auto zu betanken. REEV haben einen rein elektrischen Antrieb, sind demnach als E-Pkw konzipiert und besitzen zusätzlich einen modifizierten Verbrennungsmotor, welcher nur die Batterie lädt, aber nicht die Achse antreibt und damit zur Erhöhung der Reichweite beiträgt. HEV, welche keinen Ladestecker besitzen, können durch den elektrischen Antrieb verbrauchsoptimierter betrieben werden und dadurch den Kraftstoffbedarf reduzieren. FCEV werden über den Energieträger Wasserstoff versorgt und mit Hilfe einer Brennstoffzelle wird dieser in elektrische Energie umgewandelt. Konventionelle Fahrzeuge beruhen lediglich auf dem Verbrennungsmotor (vgl. e-mobil BW, 2015).

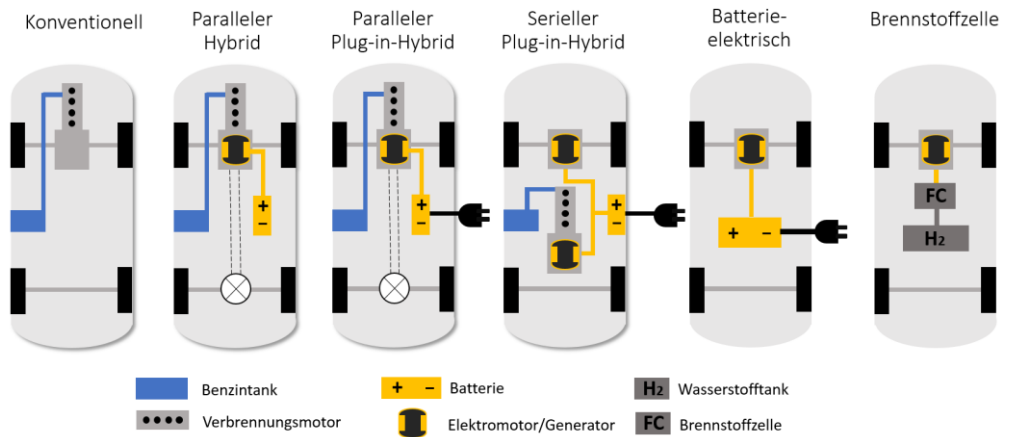


Abbildung 2.9: Übersicht der Antriebskonzepte;
Quelle: nach e-mobil BW (2015)

Die Tabelle 2.1 gibt einen Überblick über eine Auswahl an verschiedenen Modellen von E-Pkw im Jahr 2018. Als technische Daten sind E-Pkw-spezifische Parameter, wie die Batteriekapazität, die Verbrauchsangabe und dadurch theoretisch bedingte Reichweite angegeben. Die Reichweite der einzelnen Modelle wurde auf Basis verschiedener Fahrzyklen berechnet. Der Neue Europäische Fahrzyklus (NEFZ) stand häufig in der Kritik, da er nicht mehr das aktuelle, durchschnittliche Fahrverhalten repräsentiert und wurde inzwischen durch den Worldwide Harmonized Light Vehicles Test Procedures (WLTP) ersetzt. Dieser zeichnet sich durch dynamischere Fahr-situationen und eine vereinheitlichte internationale Messprozedur aus. Ab 2020 ist das Ziel der EU-Kommission, dass nur noch der WLTP der Standard für die

Fahrzeugzielerreichung ist und nicht mehr der NEFZ (vgl. VDA, 2017). Nach Angaben der Autohersteller ist die Reichweite von anderen Faktoren zusätzlich beeinflussbar. Testberichten von E-Pkw-Nutzern ist zu entnehmen, dass die Reichweite ebenfalls von anderen Aspekten, wie weiteren Verbrauchern (z. B. Klimaanlage, Radio, Navigation), äußeren Einflüssen, wie Wetter, Gegenwind, Verkehrsfluss oder dem eigenen Fahrstil abhängig ist (vgl. Radgen et al., 2018).

Tabelle 2.1: Überblick über eine Auswahl an reinen E-Pkw Modellen inkl. technischer Details und Listenpreise im Jahr 2018; Datenquelle: (Model3.info, 2018), (Nissan, 2018), (Volkswagen, 2018), (Renault, 2017), (Smart, 2018), (BMW, 2018), (KIA, 2018)

Fahrzeug	Batteriekapazität [kWh]	Verbrauchsangabe [kWh/100 km]	Reichweite ⁸ [km]	Leistung [kW]	Leergewicht [kg]	Listenpreis [€]
BMW i3	27,2	13,1	290	125	1320	37.550
Kia Soul EV	30	14,3	250	81,4	~ 1600	29.490
Nissan Leaf	40	20,6	415 ⁹	110	~ 1600	31.950
Renault Zoe	22	13,3	240	68	1545	29.690
Smart EQ fortwo	17,6	12,9	160	60	1085	21.940
Tesla Model 3	50	14,1	350 ¹⁰	192	1610	36.930
VW Golf	35,8	12,7	300	100	1615	35.900

2.3.4 Auswirkungen von E-Pkw auf das Energiesystem

Die zunehmende Aktivität in Forschung und Entwicklung im Bereich der E-Pkw basiert, neben dem Ziel der Treibhausgasreduktion im Verkehrssektor, nicht zuletzt auf dem Flexibilisierungsbedarf der Nachfrageseite, wie im Abschnitt 2.1 bereits aufgegriffen wurde. Somit findet sowohl eine Beeinflussung des Transportsektors als auch der Energiewirtschaft statt. Zusätzlich ist für die Analyse der Auswirkungen von E-Pkw auf das Energiesystem eine Ansicht mit mehreren Perspektiven notwendig. Es sind dabei die techno-ökonomischen Dimensionen relevant bei der Betrachtung (vgl. Jochem, 2016). Ebenfalls ist der Technologiegrad zu berücksichtigen. Dieser bezieht sich beispielsweise auf die Ladeinfrastruktur als auch auf den Netzausbau. Zusätzlich

⁸ Die Reichweite bezieht sich auf NEFZ, sofern nichts anderes angegeben ist.

⁹ Die Reichweite von bis zu 415 km bezieht sich auf den städtischen WLTP -Zyklus.

¹⁰ Basierend auf US-Standards.

sind aber auch Smart Meter und ein Ausbau der Kommunikations- und Steuerungstechnologien notwendig, um ein intelligentes, vernetztes Stromnetz voranzutreiben (vgl. Mwasilu et al., 2014). Der Kontext der E-Pkw in Bezug auf das energiewirtschaftliche Dreieck wird in folgenden Ausführungen ebenfalls aufgegriffen.

2.3.4.1 Demand Side Management

Die meisten Fahrzeuge haben am Tag eine Stillstandszeit von 95 % (vgl. Ehsani et al., 2012). Dies bedeutet, dass die E-Pkw über 23 h parken und im Verlaufe jenes Zeitraumes kann die Batteriekapazität flexibel genutzt werden. Hierbei kann ein Demand Side Management (DSM) zum Einsatz kommen, welches vier mögliche Ansätze enthält: Effizienzsteigerung, Einsparungen, Eigenproduktion oder Lastmanagement. Zum letzten zählt das DR, welches eine direkte Laststeuerung oder Anreize umfasst (vgl. Paterakis et al., 2017). Die Idee ist nicht neu, denn es liegt nahe, diese Kapazitäten zu nutzen und die Zeitpunkte des Ladens der E-Pkw flexibel – nach verschiedenen Gesichtspunkten – zu gestalten. Ist die Parkdauer länger als die Ladedauer der E-Pkw, dann wird von einem sogenannten LVP gesprochen. Unter dem Begriff des LVP wird eine zeitlich verschiebbare Last, aber in bestimmten Grenzen, verstanden (vgl. Paetz et al., 2013). Dabei liegt das maximal vorhandene LVP, wie in Abbildung 2.10 dargestellt, zwischen dem frühesten möglichen Ladezeitpunkt, wenn die Ladestrategie as fast as possible (AFAP) angewendet wird und dem spätesten möglichen Ladezeitpunkt, der as late as possible (ALAP) Ladestrategie bezeichnet wird. Dabei ist es möglich den Ladevorgang zu unterbrechen und in mehrere kleinere Ladevorgänge aufzuteilen. Hierfür müssen technische Aspekte, wie die Unterbrechungsmöglichkeit, die Leistungsgrenzen als auch der Zeithorizont berücksichtigt werden. Nähere Ausführungen zu den Ladestrategien folgen im Abschnitt 2.3.5.





Abbildung 2.10: Schematische Darstellung von Lastverschiebepotenzialen

Zur Anwendung können die LVP von E-Pkw kommen, um die fluktuierende Einspeisung durch EE auszugleichen und so deren Integration in das Stromnetz zu erleichtern. Diese Tatsache kann zur Stabilisierung und Sicherung des Netzes beitragen. Die Lastverschiebung kann so genutzt werden, dass beispielsweise Niedriglasten oder Lastspitzen vermieden werden („valley filling“ bzw. „peak shaving“), wie die Abbildung 2.11 veranschaulicht (vgl. Jochem et al., 2014). Zur Lastverschiebung sollte der Rahmen zur Umsetzung bzgl. der Energienachfrage, des Zeithorizonts, die Lastgrenzen sowie ein möglicher vorgegebener Lastverlauf als auch Unterbrechungsmöglichkeiten bekannt sein.



**Abbildung 2.11: Möglichkeiten der Integration von E-Pkw zur Lastverschiebung;
Quelle: nach Jochem et al. (2014)**

Es existieren weitere allgemeinere Konzepte in Bezug auf das LVP zur Nachfragesteuerung, z. B. strategische Laststeigerung oder strategische Lastminderung (vgl. Gellings und Smith, 1989). Die letzten beiden Arten werden in dieser Arbeit nicht

berücksichtigt, weil sie vorrangig der Verbrauchersteuerung dienen. Es wird davon ausgegangen, dass der Verbrauch der E-Pkw extern gegeben ist und keine flexible Steuerung erfolgt, damit die Nutzerwünsche komplett und ohne Einschränkungen erfüllt werden.

Zur Laststeuerung können verschiedene Anreize über Preise gegeben werden, als eine Möglichkeit, den Kunden zu einer Änderung des Nutzerverhaltens zu motivieren. Es gibt unterschiedliche Ansätze diese Preise zu gestalten, als Beispiel sind die folgenden drei Preiskonzepte genannt (vgl. Paterakis et al., 2017):

- Real time pricing (RTP), der Preis, der den Kunden weitergegeben wird, orientiert sich an den Preisen der Strombörse und ändert sich meist stündlich.
- Time of use (TOU) sind Tarife mit unterschiedlichen Preisstufen und Zeitintervallen, bei denen die Schwankungen von Erzeugung, Verbrauch über den Tag als auch durch Jahreszeiten Berücksichtigung finden können.
- Critical peak pricing (CPP), berücksichtigt kritische Lastspitzen, d. h. ein hoher Energieverbrauch soll vermieden werden. Es ist eine spezielle Form des TOU Tarifs. Dieser Tarif findet häufig eine maximale Anzahl von Tagen im Jahr statt mit einer kurzen Ankündigungsfrist.

Die Quantifizierung von LVP ist schwierig, da diese von vielen Einflussfaktoren und Parametern abhängig ist. LVP werden nicht nur von technischen Faktoren geprägt, sondern auch von ökonomischen Größen, wie bspw. Preisanreizen oder Investitionen in die Infrastruktur, die die Lastverschiebung erst ermöglicht. Akzeptanzeinflüsse und andere Hürden bei der Einführung zählen ebenfalls zu den zu berücksichtigenden Faktoren.

2.3.4.2 E-Pkw im Kontext des energiewirtschaftlichen Zieldreiecks

Die drei Aspekte des energiewirtschaftlichen Zieldreiecks – Zuverlässigkeit, Wirtschaftlichkeit und Nachhaltigkeit – lassen sich ebenfalls auf die Elektromobilität übertragen.

Die erste Komponente – Zuverlässigkeit – hat mehrere Teilaspekte. Zum einen können die E-Pkw dazu beitragen, dass das Energiesystem stabilisiert wird, wie im Abschnitt 2.3.4.1 geschildert. Dabei blieb aber die Frage der Zuverlässigkeit des zu Verfügung gestellten Stromes der E-Pkw außer Acht. Wie sicher bzw. zuverlässig sind die Einspeisungen des Stromes durch E-Pkw? Kann sowohl der Zeitpunkt als auch

die Menge sicher eingeplant werden? Unsicherheiten spielen eine wichtige Rolle im Kontext der Elektromobilität, finden bis jetzt aber wenig Berücksichtigung. Die Unsicherheiten sind aber nicht nur auf der Seite des Netzes bei der Einspeisung des Stromes zu finden, sondern auch auf Seiten des Nutzers. Hat der Besitzer eines E-Pkw die Sicherheit, dass sein Auto zur gewünschten Zeit mit der entsprechend angefragten Leistung geladen ist? Ladesäulen mit hoher Ladeleistung und eingebauter intelligenter Ladesteuerung können dazu beitragen, die Versorgungssicherheit auf der Seite der Nutzer zu erhöhen. Damit die Versorgungssicherheit aus Netzsicht weiterhin gewährleistet ist, sollten aber gleichermaßen keine neuen Lastspitzen hinzukommen.

Wird ein Blick in die Zukunft geworfen und die Milliarden Kilometer an Fahrleistungen im Jahr anstelle von Verbrennerfahrzeugen durch E-Pkw zurückgelegt, dann stellt der erhöhte Energiebedarf wiederum eine Herausforderung an das Stromnetz dar. Im Jahr 2030 wird weltweit mit einem Bedarf von über 400 TWh an Elektrizität gerechnet (vgl. IEA, 2018). Nicht zuletzt spielt dann wieder der Strommix eine Rolle. Denn trotz des erhöhten Energiebedarfs sollten in Deutschland die Nachhaltigkeitsziele mit einem EE-Energieanteil von über 80 % bei der Stromerzeugung im Jahr 2050 erfüllt werden (vgl. Clausen, 2018). Mit der Zunahme an leistungsstarken Wallboxen in Deutschland in privaten Haushalten geht schon jetzt eine Prognoseschwierigkeit für die Netzbetreiber einher, sofern es sich um eine Wallbox mit einer Leistung bis 11 kW handelt, bedarf es bisher auch keiner Genehmigung durch den Netzbetreiber (vgl. ADAC, 2019). Dahingehend gilt es die Messeinrichtungen in den Verteilnetzen auszubauen.

Nachhaltigkeit bei E-Pkw hängt nicht zuletzt von dem genutzten Energiemix beim Ladevorgang ab. Die Elektromobilität steht allgemein im Zusammenhang mit einer Reduktion an CO₂- und anderen Treibhausgasemissionen sowie der verringerten Ölabhängigkeit. Die Reduktion der Lärmemissionen ist ebenfalls nicht zu vernachlässigen. Diese ist aber insbesondere bei niedrigen Geschwindigkeiten relevant. Bei höheren Geschwindigkeiten nehmen der Roll- und Luftwiderstand erheblich zu und sind die entscheidenderen Komponenten der Lärmemission und nicht mehr der Antrieb. Somit kann der Einsatz von E-Pkw zur Entlastung von Innenstädten beitragen sowie zur Vermeidung von potenziellen Fahrverboten (vgl. Clausen, 2018).

Bei einer gesamten Umweltbetrachtung sind beginnend mit der Produktion bis zum nachhaltigen Recycling ganzheitliche Umweltkonzepte notwendig, mit standardisierten Prüfverfahren sowie Sicherheitsanforderungen (vgl. NPE, 2017). Somit sollte die gesamte Wertschöpfungskette bzgl. CO₂-Emissionen bewertet werden (vgl. Clausen,

2018), um damit die well-to-wheel Emissionen ebenfalls zu berücksichtigen (vgl. IEA, 2018). Somit könnten ebenfalls entsprechende Lebenszyklusanalysen durchgeführt werden (vgl. Bicer und Dincer, 2016). Die Herstellung und technologische Entwicklung der Batterien spielt dabei eine entscheidende Rolle. Daran anknüpfend ist auch der Einsatz von Second-life Batterien zu nennen (vgl. BuW (Begleit- und Wirkungsforschung Schaufenster Elektromobilität), 2016).

Aktuell werden in Deutschland zusätzliche Verkaufsanreize durch das im Jahr 2015 in Kraft getretene Elektromobilitätsgesetz geschaffen. Dadurch sollen Elektroautos attraktiver gemacht werden. Zu den Vergünstigungen zählen beispielsweise die Erlaubnis zur Nutzung von Busspuren oder eigene Parkplätze mit Ladestationen (vgl. Bundesregierung, 2018).

Zukünftig könnten die E-Pkw Nutzer den Preis beeinflussen, sobald Services im Kontext von Elektromobilität angeboten werden. Geschäftsmodelle für die nachfrageseitige Flexibilisierung können zu einem erhöhten Handlungsspielraum beitragen. Werden konventionelle Fahrzeuge mit E-Pkw verglichen, so haben letztere noch höhere Gesamtbetriebskosten (vgl. Tober, 2016). Die Ladeinfrastruktur ist ebenfalls bei Wirtschaftlichkeitsbetrachtungen nicht zu vernachlässigen. Diese sollte bedarfsgerecht ausgebaut werden. Wenn E-Pkw im Kontext des smart grids¹¹ betrachtet werden, sollten sowohl für Fahrzeugbesitzer als auch für Netzbetreiber Anreize geschaffen werden, die die Erzielung eines ökonomischen Mehrwerts ermöglichen. Die Potenziale verschiedener Maßnahmen wurden schon theoretisch untersucht (z. B. Dallinger et al., 2015). Die genaue Umsetzung in der Praxis hingegen lässt noch viele Fragen offen bei der konkreten Umsetzung von Geschäftsmodellen. Ansätze dafür sind z. B. in Ensslen et al. (2014) oder Brandt et al. (2017) zu finden.

2.3.5 Ladesteuerungsmechanismen

Ladevorgänge von E-Pkw können unterschiedlichen Ladestrategien unterliegen und entsprechend mit Ladesteuerungsmechanismen gesteuert werden. In dem vorangestellten Abschnitt wurde die Bedeutung des LVP bereits erörtert und zwei mögliche Ladestrategien (AFAP, ALAP) aufgezeigt. Mögliche Anwendungsfälle können bspw. die Reduktion der Spitzenlast des Netzes oder die Integration von EE sein. Bei der

¹¹ Unter einem smart grid wird ein intelligentes Stromnetz verstanden, welches die Erzeugung, den Verbrauch und die Speicherung kombiniert und über eine zentrale Steuerung diese optimal aufeinander abstimmt (vgl. Umweltbundesamt, 2013).

indirekten Ladesteuerung werden Anreize i. d. R. in Form von Tarifen gesetzt, um das Kundenverhalten zu beeinflussen. Diese erleichtert die Planbarkeit der Lasten, dennoch liefert es keine Planungssicherheit, wie bei der direkten Ladesteuerung. In diesem Fall kann bewusst aus Energieversorgersicht gesteuert werden und ein entsprechendes smart charging (intelligentes Laden nach ISO 15118, siehe Abschnitt 2.4.3.1) erzwungen werden. Dabei müssen sowohl die E-Pkw als auch die Ladeinfrastruktur über entsprechende Informations- und Kommunikationstechnologien (IKT) verfügen.

Ungesteuertes Laden hat die einfachste technische Umsetzung und dabei wird der Kunde in seinem Ladeverhalten nicht beeinflusst. Das ungesteuerte Laden geht davon aus, dass ein E-Pkw an eine Ladestation kommt und entsprechend der aktuell verfügbaren Leistung das Laden mit maximaler Leistung beginnt. Einige rudimentäre Lade-strategien, wie beispielsweise die Heuristik ‚first come first serve‘ (FCFS¹²) oder das gleichmäßige Aufteilen der vorhandenen Leistung auf mehrere Ladesäulen, wenn sich jene einen gemeinsamen Netzanschluss teilen, existieren bereits. Diese haben allerdings die Nachteile, dass i. d. R. weder Preise, Standzeiten oder Kundenpräferenzen berücksichtigt werden. Die Ladestrategie AFAP ist eine spezielle Form des ungesteuerten Ladens, bei der davon ausgegangen wird, dass die E-Pkw sofort nach dem Anschließen an eine Ladestation mit voller Leistung laden können. Bei der ALAP Ladesteuerung ist das Parkzeitfenster des Kunden bekannt sowie der Ladebedarf und die zur Verfügung stehende Leistung. Somit kann zum spätmöglichsten Zeitpunkt während der Aufenthaltsdauer des Kunden geladen werden.

Die Technologie der Rückspeisung wurde schon kurz im Abschnitt 2.3.4.2 aufgegriffen. Mit der sogenannten Vehicle-to-Grid (V2G) Technologie gibt es viele Einsatzmöglichkeiten für den E-Pkw, z. B. als Speicher, um als kurzfristiger Puffer zu dienen. Eine der ersten Untersuchungen bzgl. der Netzauswirkungen haben Kempton und Tomić (2005) durchgeführt. V2G wird in der Arbeit nicht weiter berücksichtigt, da aktuell noch nicht viele E-Pkw auf dem Markt sind, die diese Technologie besitzen und die generelle Wirtschaftlichkeit noch hinterfragt wird (vgl. Kaschub et al., 2016).

¹² FCFS ist ungesteuertes Laden unter Berücksichtigung der Netzlast (erstes Fahrzeug, welches nicht mehr laden kann, fängt erst an zu laden, wenn seine gewünschte Leistung durch Beendigung des Ladeprozesses eines oder mehrerer anderer Fahrzeuge wieder verfügbar ist). Somit beginnt bei FCFS der Ladevorgang der E-Pkw direkt nachdem sie an die Ladesäule angeschlossen wurden und ausreichend Leistung zur Verfügung steht.

2.3.6 E-Pkw-Kostenentwicklung/-Wirtschaftlichkeit

Die Gesamtbetriebskosten - TCO¹³ - der E-Pkw sind derzeit noch höher als von konventionellen Fahrzeugen. Selbst bei Zugrundelegung einer überdurchschnittlichen Fahrleistung liegen die E-Pkw im Wirtschaftlichkeitsvergleich hinten, obwohl gerade dann geringere Brennstoffpreise oder geringere Instandhaltungskosten angesetzt werden können (vgl. Radgen, 2018). Mit entsprechenden monetären Anreizen kann dieser Ausgangszustand verbessert werden. Dazu zählen auch Anreize für die Ladeinfrastruktur (vgl. Ensslen et al., 2018). Wird die Entwicklung der TCO näher betrachtet, dann ist abzusehen, dass sich die Kosten in den nächsten Jahren reduzieren werden. Die Erreichung der Preisparität der TCO zu konventionellen Fahrzeugen ist abhängig von mehreren Faktoren. Dazu zählen die Batteriepreise, die Größe des Autos, Brennstoffpreise und jährliche Kilometerleistung. Einige Variablen, die die TCO Differenz zwischen den Antriebstechnologien beeinflussen sind, regionenspezifisch und können sich unterschiedlich entwickeln. Beispiele dafür sind Strom- oder Brennstoffpreise sowie zurückgelegte jährliche Kilometer oder Autotyp (vgl. IEA, 2018b).

Bei den Batterien¹⁴ sind der Herstellungsprozess und das Design komplex. Vier Komponenten sind als Haupttreiber für die Kosten von der IEA (2018b) identifiziert worden: die chemische Zusammensetzung, die Kapazität der Batterie, die Herstellungskapazitäten der Fabriken und die Ladegeschwindigkeit. Häufig ist bei den Kosten der Batterien nicht eindeutig angegeben, ob es sich um eine einzelne Zelle oder den Batteriepack handelt. Von einem positiven Trend der Entwicklung ausgehend, wird von der EU im Jahr 2030 mit Batteriepackpreisen von circa 75 €/kWh gerechnet (vgl. Omar, 2018). Diese Tendenz wird insbesondere von Studien, die nach 2015 erhoben wurden, bestätigt (vgl. Tsiropoulos et al., 2018). Für einen Überblick zu den aktuellen Listenpreisen von verschiedenen Fahrzeugmodellen dient die Tabelle 2.1.

¹³ Die TCO berücksichtigen nicht nur die Investitionen, sondern ebenfalls Kosten der Nutzung, wie Wartung, Brennstoffkosten oder jährliche Steuern.

¹⁴ Die Lithium-Ionen-Batterien gehören zu den Sekundärenbatterien. Diese bestehen aus einer oder mehreren zusammenschalteten galvanischen Zellen. Module entstehen durch die Parallel- oder Serienschaltung von einzelnen Zellen. Mehrere Module werden wiederum zu einem Batteriesystem (Batteriepack) verbaut (vgl. Ketterer et al., 2009).

2.4 Ladeinfrastruktur

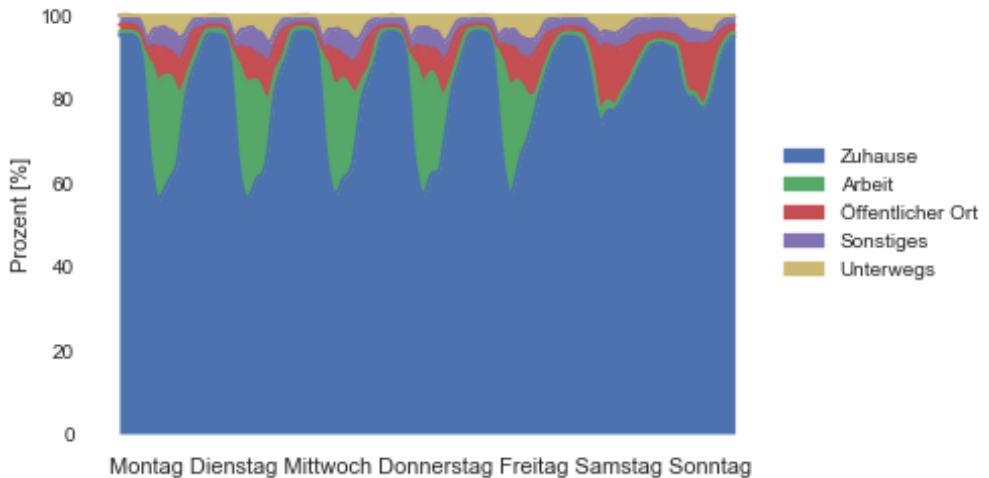
Bis 2020 soll in Deutschland der Aufbau von mindestens 15.000 Ladesäulen mit insgesamt 300 Millionen Euro vom BMVI gefördert werden. Die Ladestationen sollen dabei öffentlich zugänglich sein. Das Ziel ist eine bedarfsgerechte und flächendeckende Ladeinfrastruktur für E-Pkw in Deutschland zu installieren. Gelder sind sowohl für Normalladung als auch für Schnellladung vorgesehen (vgl. BMVI, 2018). Im Jahr 2018 beläuft sich die Zahl der bereits existierenden Ladestationen auf knapp 9.000 (vgl. Statista, 2018b). Bei der Entwicklung der Ladeinfrastruktur wird zwischen den drei Kategorien – Gelegenheits-, Primär- und Schnellladen – unterschieden (vgl. Rahman et al., 2016). Nicht zuletzt ist es wichtig eine Ladeinfrastruktur zu Hause, am Arbeitsplatz und im öffentlichen Raum anzubieten, welche für die Nutzer frei zugänglich ist (vgl. Hardman et al., 2018).

Weitere Konzepte neben dem konduktiven Laden (physische Verbindung über elektrische Kontakte) für die Energiezufuhr für E-Pkw sind induktives Laden über Induktionsspulen im Boden oder ein Austausch der leeren mit einer vollen Batterie. In dieser Arbeit werden nur kabelgebundene Ladesäulen berücksichtigt, induktives Laden oder Batterieaustauschsysteme spielen derzeit eine untergeordnete Rolle bzw. befinden sich noch in einer frühen Entwicklungsphase, so dass diese hier keine weitere Betrachtung finden.

2.4.1 Park- und Ladeorte

Abhängig von der Nutzung der Fahrzeuge unterscheiden sich auch die Ladeinfrastruktur und die entsprechenden Ladeorte. Im Bereich der Ladeinfrastruktur für die E-Pkw wird zwischen drei oder vier Typen von Ladepunkten unterschieden (siehe Kley et al., 2011). Die Ladestationen sind entweder uneingeschränkt oder eingeschränkt zugänglich. Dazu zählen der halböffentliche Bereich und der öffentliche Bereich, der Arbeitsplatz sowie der häusliche Bereich. Diese Ladeinfrastruktur kann teilweise von verschiedenen Typen von E-Pkw genutzt werden. In einer Übersicht von Rahman et al. (2016) werden die Bereiche etwas anders spezifiziert – zu Hause, Apartmentgebäude, Gewerbegebäude – lassen sich aber den zuvor definierten Ladeorten ebenfalls, zumindest teilweise, zuordnen. Die verschiedenen Ladestationen lassen sich durch unterschiedliche Eigenschaften und auch Anforderungen charakterisieren. Dabei sind die Ausstattungen hinsichtlich der IKT sowie der Ladeleistung als auch der Wahl der

Strom- und Abrechnungsanbieter sehr vielgestaltig. Die Nutzer haben ebenfalls eigene Bedürfnisse, z. B. aufgrund ihrer Standzeiten.



**Abbildung 2.12: Parkorte von Fahrzeugen;
Datenquelle: nach MOP (2008)**

In Abbildung 2.12 ist die Verteilung der Parkorte von Fahrzeugen über den Tagesverlauf dargestellt. Ersichtlich wird, dass sich ein Großteil der Fahrzeuge nicht bewegen und sie wohl zu Hause parken. Die Datenerhebung spiegelt das Parkverhalten der Nutzer wider. Es ist weiterhin ersichtlich, dass 85 % der Parkorte entweder zu Hause oder am Arbeitsplatz sind und nur 15 % öffentliche Parkorte über den gesamten Tagesverlauf von E-Pkw genutzt werden (vgl. MOP, 2008).

2.4.1.1 Laden im halböffentlichen Bereich – Parkhaus

Befinden sich die Ladestellen auf privatem oder gepachtetem Gelände, können diese in Abhängigkeit der Nutzungsbedingungen der Grundstücksbesitzer für E-Pkw potenziell zugänglich sein. Parkhäuser, Park & Ride Parkplätze, Sport- oder Supermarktparkplätze sind Beispiele dafür.

In dieser Arbeit steht das Laden von E-Pkw im Parkhaus im Vordergrund. Deswegen wird im Rahmen der Abhandlung jener Bereich erweitert dargestellt, da mehrere Nutzergruppen im Parkhaus integriert werden.

Eine Identifikation zur Nutzung ist oftmals notwendig, bspw. durch ein einmaliges Parkticket oder RFID-Karten für regelmäßige Nutzer. Die Abrechnung wird häufig

vom Anbieter individuell übernommen als Serviceleistung zur Kundenbindung. Das Angebot an Ladesäulen, der IKT Ausstattung und der dazugehörigen Ladeleistung kann variieren. Es gibt möglicherweise eine intelligente Netzanbindung. Die Standzeiten hängen stark von der Nutzergruppe ab. Analog verhält es sich mit dem LVP, welches von der Standzeit des jeweiligen Nutzers geprägt wird.

2.4.1.2 Laden im öffentlichen Bereich

Ladeinfrastruktur, die sich im öffentlichen Bereich befindet, oftmals am Straßenrand, ist für die Öffentlichkeit frei zugänglich und besitzt einen unbeschränkten Nutzerkreis. Die Betreiber der Ladesäulen haben häufig ein eigenes Abrechnungssystem eingerichtet.

Sowohl die Ladestationen in Parkhäusern als auch im öffentlichen Bereich besitzen ein geringes LVP, aufgrund von niedrigen Parkdauern (Ausnahmen mit längeren Parkdauern sind z. B. Park & Ride Parkplätze). Diese Ladesäulen werden oftmals als Kunden-Attrahierungsmaßnahme installiert.

Schnellladesäulen sind eine besondere Form der Ladesäulen im öffentlichen Bereich. Dieses Konzept ist analog zu unseren heutigen Tankstellen, d. h. zugänglich für jedes Fahrzeug, auf einem z. B. angemieteten Gelände. Dabei liegen kurze Standzeiten gekoppelt mit geringen Ladezeiten zu Grunde. Dadurch ist kein LVP vorhanden und es wird eine hohe Last in kurzer Zeit erzeugt. Es wird i. d. R. ein direktes Abrechnungssystem genutzt, welches durch Barzahlung oder durch einen Anbieter abgedeckt ist. Der Bedarf an Schnellladesäulen ist insbesondere an Autobahnen gegeben, um wieder größere Reichweiten zurücklegen zu können nach einer relativ kurzen Ladezeit (vgl. NPE, 2015).

2.4.1.3 Laden am Arbeitsplatz – Gewerblich

Das Laden am Arbeitsplatz zählt ebenfalls zu dem halböffentlichen Laden. Hierbei wird die Ladeinfrastruktur vom Arbeitgeber zur Verfügung gestellt, die Standzeiten sind eher länger und meistens tagsüber, je nach Schichtsystem auch nachts. Zusätzlich können Fuhrparkflotten ebenfalls dort laden. Aufgrund der langen Standzeiten ist dies ein primärer Ladeort, neben zu Hause für E-Pkw.

In Abhängigkeit der Parkdauern sind LVP vorhanden. Die Ladezeiten sind von der Ladeleistung abhängig, aber grundlegend ist die Parkdauer länger als im öffentlichen

Bereich. Hinzu kommt, dass Mitarbeiterfahrzeuge (Arbeitswoche) und auch Firmenflotten (Fuhrparkmanagement mit Reservierungen für Dienstfahrten) eine gewisse Planbarkeit aufweisen und demnach ein hohes LVP besitzen.

2.4.1.4 Laden im privaten Bereich - zu Hause

Liegt der Fokus auf der privaten Fahrzeugnutzung, dann finden die meisten Ladevorgänge zu Hause statt. Privates Laden ist der Hauptfokus für die Mehrheit der heutigen Elektrofahrzeugnutzer (vgl. Hardman et al., 2018). Verschiedene Studien, z. B. Madina et al. (2016) haben die Kostenvorteile durch das Laden zu Hause aufgezeigt.

Ladevorgänge zu Hause sind häufig durch lange Standzeiten und eine eher geringe Ladeleistung gekennzeichnet. Ein eigenes Abrechnungssystem ist nicht zwingend erforderlich und die IKT-Ausstattung kann nach dem persönlichen Bedarf ausgelegt werden.

2.4.2 Anforderungen an die Ladeinfrastruktur

Potenzielle Neukunden eines E-Pkw haben mit dieser Technologie oftmals noch nicht viele Erfahrungen sammeln können. Das Thema der Reichweite spielt dabei keine untergeordnete Rolle. Eine funktionierende, zuverlässige und einfache Ladeinfrastruktur erhöht die Attraktivität des Fahrzeuges. Somit ist eine hohe Verfügbarkeit, Auffindbarkeit, Verlässlichkeit sowie ein einfaches Abrechnungssystem aus Kundensicht wünschenswert. Die öffentlich zugänglichen Ladesäulen machen bei den Ladevorgängen nur ca. 15 % aus. Demnach wird der Großteil der Kunden im privaten Bereich laden (vgl. NPE, 2014). Aktuell stehen einem E-Pkw zum Laden im privaten Bereich (zu Hause und am Arbeitsplatz) im Schnitt über 1,1 Ladesäulen in den meisten Regionen zur Verfügung (vgl. IEA, 2018). Bei der Ladeinfrastruktur ist neben dem Ladeort, der vermehrt zu Hause sein wird, noch der Aspekt der Häufigkeit und Dauer der Ladevorgänge zu beachten. Aufgrund der aktuellen Batterietechnologie und Ladesäulenentwicklung findet der Aufladevorgang häufiger statt als beispielsweise beim konventionellen Tanken. Ebenfalls dauert der Vorgang länger (vgl. Clausen, 2018). Die Psychologie der Kunden, insbesondere bzgl. der Reichweitenangst ist nicht vernachlässigbar und sollte bei dem Ausbau der Ladeinfrastruktur berücksichtigt werden (vgl. Guo et al., 2018).

Aus energiewirtschaftlicher Perspektive bedarf es wiederum anderer Anforderungen an die Ladeinfrastruktur. Dazu zählen die Gewährleistung der Versorgungssicherheit,

d. h. ein stabiles Netz und keine größeren Lastspitzen. Wird das Laden zu Hause betrachtet, dann wird der E-Pkw über den häuslichen Netzanschluss versorgt und mit einer Ladevorrichtung von bis zu 11 kW bedarf es bisher auch keiner Genehmigung durch den Netzbetreiber (vgl. ADAC, 2019). Für den (halb-) öffentlichen Raum sind Konzepte bzgl. der Abrechnung, der Rolle der Ladeinfrastrukturbetreiber sowie Stromlieferanten erforderlich. Weitere Aspekte dazu erfolgen im Verlauf dieses Kapitels.

2.4.3 Ladesäulen

E-Pkw können sowohl mit Gleichstrom (direct current – DC) als auch Wechselstrom (alternating current – AC) aufgeladen werden. Das Schnellladen wird heute in der Regel mit Gleichstrom durchgeführt und erreicht Leistungen von über 22 kW. Dieses bedeutet kürzere Wartezeiten für den Kunden während des Ladevorgangs. Das Normalladen, welches mit Wechselstrom betrieben wird und Leistungen von bis zu 22 kW hat, ist hauptsächlich für Standorte vorgesehen, an denen der Nutzer länger parkt (vgl. BMVi, 2018).

Der Typ-2-Stecker ist als Standardladestecker für Wechsel- sowie Drehstromanschlüsse vorgesehen innerhalb der EU. Dieser ermöglicht sowohl ein- als auch zwei- und dreiphasiges Laden. Das combined charging system (CCS) ist als Richtlinie seit 2014 für das Schnellladen mit Gleichstrom von Deutschland und der EU eingeführt worden. Andere Technologien, wie das Supercharger-System von Tesla oder der CHAdeMO-Standard von Japan sind ebenfalls für Gleichstromschnellladesysteme verbreitet (vgl. NPE, 2014).

Mit der Einführung verschiedener Normen soll der Markt weiter geöffnet und die Interoperabilität gewährleistet sowie eine Investitionssicherheit geschaffen werden (vgl. NPE, 2017). Dieses ist insbesondere wichtig, um die verschiedenen Akteure miteinander zu vereinen.

Die Normenreihe IEC 63110 wird von dem VDE entwickelt, um ein standardisiertes Management der Ladeinfrastruktur zu ermöglichen. Die Ziele dieser Norm bestehen darin, die Daten- und Kommunikationsflüsse zwischen den verschiedenen Akteuren abzudecken. Berücksichtigung finden bei der Entwicklung ebenfalls die IT-Sicherheit sowie die Verbindung von Elektromobilität und smart grid. Die Netzintegration der Elektromobilität soll durch eine möglichst einheitlich beschriebene Ladeschnittstelle erleichtert werden. Dabei ist eine volkswirtschaftlich sinnvolle Balance zwischen

Verfügbarkeit mit maximaler Ladeleistung und Netzausbau zu finden (vgl. VDE, 2017).

2.4.3.1 Kommunikation zwischen Fahrzeug und Ladesäule

Die Standardisierung der Hardware als auch Software-Schnittstelle bildet einen wichtigen grundlegenden Rahmen für den Fortschritt der Elektrifizierung. Dazu zählen sowohl die fahrzeugseitigen Komponenten als auch die der Ladesäule. Die International Organization for Standardization (ISO) IEC 15118 ist hauptsächlich für die Kommunikation zwischen Ladeinfrastruktur (Ladesäule) und Fahrzeug (E-Pkw, PHEV) zuständig (vgl. ISO, 2013). Darin sind die Kommunikationsprotokolle spezifiziert, die beispielsweise ein automatisiertes Lastmanagement sowie den Bezahlvorgang steuern (vgl. NPE, 2017).

Die Tabelle 2.2 gibt einen detaillierten Überblick in Bezug auf die verschiedenen Ladebetriebsarten nach der IEC Norm 61851-1. Ab Mode 2 können E-Pkw und Ladeinfrastruktur analog kommunizieren, ab Mode 3 ist eine vollständige Kommunikation möglich. Diese erfolgt über Pulsweiten- und Amplitudenmodulation (vgl. Mültin, 2014). Für Mode 1-3 wird Wechselstrom, alternating current (AC), genutzt. Mode 4 hingegen benötigt Gleichstrom, direct current (DC).

**Tabelle 2.2: Lademodi nach IEC 61851-1;
Datenquelle: Schäuble et al. (2016), Mouli et al. (2016)**

Lademodus	Phase	max. Strom	max. Spannung	max. Leistung
Mode 1 (AC)	1	16 A	230 V	3,7 kW
	3	16 A	230 V	11 kW
Mode 2 (AC)	1	32 A	230 V	7,4 kW
	3	32 A	230 V	22 kW
Mode 3 (AC)	1	63 A	400 V	14,5 kW
	3	63 A	400 V	43,5 kW
Mode 4 (DC)	-	400 A	1000 V	380 kW

Weitere Eingabeschnittstellen oder Anmeldesysteme (z. B. RFID-Leser) sind für die Kommunikation zwischen Ladeinfrastruktur und Nutzer notwendig. Diese können sowohl über die Ladesäule, das Fahrzeug oder andere Geräte angesteuert werden. Neben

den Kommunikationsvorrichtungen gibt es Sicherungsvorkehrungen, da die Ladesäulen ebenfalls minimale und maximale Ladeleistung besitzen. Zusätzlich existiert eine Schaltschütze, die das Ein- und Ausschalten der elektrischen Leistung reguliert.

2.4.3.2 Datenaustausch zwischen Ladesäule und Backendsystem

Eine weitere Kommunikation ist zwischen Ladesäule und zentralem Backendsystem erforderlich. Dieser Datenaustausch ist notwendig, um Informationen bzgl. Abrechnung, Authentifizierung, aber auch die Übermittlung von Ladeplänen weiterzugeben. Der Vorgang erfolgt mittels dem Open Charge Point Protocol (OCPP). Der aktuelle Standard ist das OCPP 2.0. Diese Software unterstützt die Anforderungen für intelligentes Laden nach ISO 15118. Durch die Übermittlungsmöglichkeit von Preiskurven oder Ladeplänen wurde die Voraussetzung für die Umsetzung eines intelligenten Energie- und Lademanagementsystems geschaffen (vgl. Open Charge Alliance, 2018).

2.4.4 Digitalisierung und Informations- und Kommunikationstechnologien

Das Bindeglied zwischen der Ladeinfrastruktur, dem Energiesystem und den Fahrzeugen stellt die IKT dar (vgl. NPE, 2017). Einhergehend mit der Zunahme an IKT verläuft die Digitalisierung, welche eine neue Dynamik in der Energiewirtschaft und damit auch bei der Energiewende entfaltet. Bei der Digitalisierung werden drei Stufen durchlaufen (vgl. Krickel, 2015):

- Es werden analoge Prozesse digitalisiert und verbessert.
- Einführung neuer Produkte und Prozesse, die lediglich digital möglich sind, dabei bleiben die Geschäftsmodelle ähnlich sowie die
- Erweiterung oder Verdrängung bisheriger Geschäftsmodelle durch neue digitale Märkte und Geschäftsmodelle.

Es entstehen Fragen: Welche Geschäftsmodelle werden sich behaupten oder wie werden die großen Datenmengen aus dem Netzbetrieb oder von Smart Metern (sog. intelligente Zähler) effizient verarbeitet? Insbesondere Smart Meter werden als Schlüsseltechnologie für die Digitalisierung gesehen. Diese liefern Informationen über den tatsächlichen Energieverbrauch, ermöglichen eine effiziente Netzsteuerung und bieten aufgrund der Fülle an Daten die Möglichkeit für neue Geschäftsmodelle. Durch

die Digitalisierung erodieren sowohl Branchen- als auch Wertschöpfungsgrenzen. Die Elektromobilität ist ein Beispiel für die Öffnung einer neuen Branche, aufgrund der Umfassung von mehreren Wertschöpfungsstufen (vgl. BDEW, 2018; Krickel, 2015).

IKT ermöglichen ein Smart Grid, ein intelligentes Stromnetz, in dem Daten und Energie transportiert werden und letztendlich auch die Durchführung von DSM oder DR. Ziel ist es, eine sichere Energieversorgung auf Basis von effizienten sowie zuverlässigen Systembetrieben zu erlangen. Für die Umsetzung von DR-Maßnahmen sind mehrere Aspekte im Bereich der IKT von Bedeutung. Für die Implementierung von DR-Strategien sind eine dafür entsprechende Infrastruktur notwendig, wie Smart Meter, welche Bi-direktional kommunizieren können, eine Steuerungs- sowie Kommunikationsinfrastruktur sowie einheitliche Standards und Protokolle. Dadurch soll eine Interoperabilität zwischen den Systemen ermöglicht werden (vgl. Paterakis et al., 2017).

Generell erlauben IKT in der Elektromobilität die Kommunikation von E-Pkw mit Smart Grids und auch dem Smart Home, also dem intelligenten privaten Haushalt. IKT kann genutzt werden, um das Laden an öffentlich zugänglichen genauso wie privaten Ladepunkten zu steuern. Hinzu kommt die Vernetzung der Ladeinfrastruktur- und Energieanbieter sowie Fahrzeughersteller zu eRoaming Plattformen. Die Notwendigkeit ergibt sich, um interoperables Laden, und dieses herstellerübergreifend, zu ermöglichen. Dadurch werden den Nutzern anbieterübergreifende Abrechnungsverfahren als auch Authentifizierung angeboten. Letzteres ist über verschiedene Kanäle möglich: bspw. per Geldkarte, direkten Zahlungsmethoden, RFID-Karten, mit einer App auf dem Smartphone oder via Plug & Charge. Ein Ziel soll es sein, offene Kommunikationsschnittstellen für die internationale Vernetzung von Mobilitätsdienstleistungen zu etablieren (vgl. NPE, 2017).

Erste einheitliche Roaming Plattformen, wie bspw. Intercharge oder Hsubject wurden bereits errichtet (vgl. Intercharge, 2018; Hsubject, 2018). Hsubject ist ein Vorreiter für eRoaming, welches für eine europaweit vernetzte Elektromobilität steht, und international der größte digitale B2B-Marktplatz für Dienstleistungen rund um das Laden von E-Pkw ist. Das Ziel ist die Ermöglichung eines einfachen Zugangs zur Ladeinfrastruktur für die E-Pkw Nutzer und somit den Alltag für Elektromobilität anwenderfreundlicher zu gestalten. An Hsubject beteiligten sich bis zum Jahr 2018 schon über 300 Partner auf drei Kontinenten. Konkret heißt das, dass mit einem Vertrag bei Hub-

ject der Zugang zu verschiedenen öffentlich zugänglichen Ladestationen unterschiedlicher Anbieter, die Partner der Hubeject-Plattform sind, für die Nutzer offen ist (vgl. Hubeject, 2018).

Weitere derzeitige Anbieter sind z. B. The Mobility House für intelligente Lade-, Speicher- und Energielösungen (vgl. The Mobility House, 2018). Andere neuartige Konzepte sind beispielsweise Abrechnungsmodelle für Elektromobilität mit Hilfe von Blockchains umzusetzen (vgl. PwC, 2016) oder auf Verteilnetzebene ein Blockchain-basiertes Engpassmanagement durchzuführen, welches die Kommunikation zwischen den Akteuren unterstützt (vgl. dena, 2019).

2.4.5 Kosten der Ladeinfrastruktur

Die Kosten der Ladeinfrastruktur sind stark davon abhängig, welche Ladesäuleninfrastruktur umgesetzt wird. Mit zunehmend höheren technischen Anforderungen gemäß der Modi von IEC 61851 nehmen die Kosten zu. Für die Gesamtkosten müssen sowohl die Betriebskosten als auch die Anschaffungskosten berücksichtigt werden. Zu den Betriebskosten zählen Wartungs-, Kommunikationskosten oder Stellplatzmiete. Bei den Anschaffungskosten gehören die Komponenten bzgl. Infrastruktur-, Kommunikations-, Abrechnungshardware dazu genauso wie mögliche Ladekabel, Leistungselektronik. Hinzukommen können auch noch Tiefbauarbeiten sowie Netzanschlusskosten (vgl. Kley, 2011; NPE, 2015).

Fahrzeughersteller bieten mittlerweile häufig schon verschiedene Wallboxen für ihre Kunden der Elektromobilität an. Bei Smart kostet beispielsweise eine Wallbox mit Ladesteckdose 773,50 €, wohingegen eine Wallbox von BMW 927 € kostet (vgl. Smart, 2018; BMW, 2018). Diese Ladevorrichtungen befinden sich am unteren Ende der Preisrange. Das obere Ende bilden verschiedene Schnellladesäulen mit Kosten von ca. 35.000 € (vgl. NPE, 2015). Weitere Kostenschätzungen können dem NPE (2015) mit Prognosen für 2020 entnommen werden, dabei ist ein fallender Trend der Kosten zu erkennen.

2.5 Geschäftsmodelle für E-Pkw

Die Veränderungen im Energie- und auch Mobilitätssektor aufgrund der steigenden Anzahl an E-Pkw spiegelt sich ebenfalls in dem Bereich der Geschäftsmodelle wider. Es werden neue Ansätze entwickelt, die diese Herausforderungen berücksichtigen. Im

Folgendes wird zunächst auf die allgemeine Entwicklung von Geschäftsmodellen eingegangen sowie danach auf ein mögliches Konzept für Elektromobilitätsdienstleistungen.

2.5.1 Entwicklung von Geschäftsmodellen

Nachdem die Innovationswelle der digitalen Netzwerke und Software stattgefunden hat, ist nun die 6. Welle der Nachhaltigkeit und Erneuerbare Energien erreicht (vgl. Hargroves und Smith, 2005). Aktuell vorhandene Geschäftsmodelle bilden oftmals noch nicht den Mehrwert, der durch neuartige, nachhaltige Technologien geschaffen wird, ab. Daher ist die Entwicklung von Geschäftsmodellen für innovative Konzepte erforderlich, um den entsprechenden Anforderungen gerecht zu werden. Somit sollten Geschäftsmodellinnovationen für die nachhaltigen Technologien, neben den positiven Effekten auf die Umwelt, auch neue Werte für die Kunden schaffen – dies steigert deren Akzeptanz erheblich (vgl. Bohnsack et al., 2014). Dabei besteht aber die Herausforderung, diese entsprechend zu gestalten, so dass die positiven Werte für die sozialen und Umweltaspekte auch in eine Generierung an Gewinn für das Unternehmen mündet (vgl. Bocken et al., 2014). Dazu kommen weitere Komponenten die grüne oder nachhaltige Geschäftsmodelle ermöglichen (vgl. Nair und Paulose, 2014; Boons und Lüdeke-Freund, 2013).

Für die Entwicklung eines Geschäftsmodells gibt es verschiedene Ansätze in der Literatur, die jeweils verschiedene Elemente beinhalten. In Osterwalder et al. (2005) ist ein praxisorientierter Ansatz zu finden, wie die Entwicklung eines Geschäftsmodells aussehen kann. Die zu berücksichtigenden Elemente sind eine Synthese aus den existierenden Geschäftsmodellen der Literatur, deswegen wird im weiteren Verlauf näher auf das Modell von Osterwalder (2004) eingegangen. Dabei verstehen Osterwalder et al. (2005) unter einem Geschäftsmodell ein Grundprinzip, nach dem durch eine Organisation Werte erfasst, vermittelt und geschaffen werden. Ein Geschäftsmodell ist ein konzeptuelles Tool bzw. ein Werkzeug welches Elemente enthält, die die Geschäftslogik und die darin enthaltenen Beziehungen der Firma widerspiegelt. In Osterwalder (2004) werden vier Säulen (Produkt, Kundenschnittstelle, Infrastrukturmanagement sowie finanzielle Aspekte) und darin enthalten neun Bausteine identifiziert, auf denen ein Geschäftsmodell aufgebaut sein sollte. Diese sind in folgender Tabelle 2.3 dargestellt.

Tabelle 2.3: Elemente eines Geschäftsmodells
Quelle: nach Osterwalder (2004)

Säule	Baustein	Beschreibung
Produkt	Wertangebote	Das Wertangebot stellt das Verständnis über den Nutzen eines Produkts oder einer Dienstleistung für den Kunden dar.
	Zielkunden	Das Kundensegment, das die Firma zufrieden stellen und einen Mehrwert anbieten möchte.
Kunden-schnittstelle	Vertriebskanal	Über den Vertriebskanal werden die Kunden erreicht.
	Kundenbeziehung	Die Kundenbeziehung beschreibt die Art der Beziehung zwischen der Firma und ihren Kunden.
Infrastrukturmanagement	Schlüsselressourcen	Es wird das Arrangement von Ressourcen und Aktivitäten angeführt, um Nutzen für die Kunden zu erzeugen.
	Partnerschaften	Partnerschaften sind ein Netzwerk aus Kooperationsvereinbarungen mit anderen Unternehmen.
	Kernkompetenzen	Diese beinhalten die Aktivitäten des Unternehmens, die notwendig sind, um einen Mehrwert für den Kunden zu schaffen.
Finanzielle Aspekte	Erlösmodell	Das Erlösmodell beschreibt die verschiedenen Wege, wie ein Unternehmen Einkünfte erzeugt.
	Kostenstruktur	Darin sind alle für das Geschäftsmodell anfallenden Kosten enthalten.

2.5.2 Konzepte für Elektromobilitätsdienstleistungen im Hinblick auf das Stromnetz

Zu den Geschäftsmodellen für nachhaltige Technologien kann in vielen Aspekten die Elektromobilität eingeordnet werden (vgl. Bohnsack et al., 2014). Gleichfalls sind Konzepte, um die vorhandenen, flexiblen Lastgänge der E-Pkw für ein Lademanagement zu nutzen, nicht neu. Diese Ideen reichen von der Anbietung von Ancillary Service bis hin zu der Speicherung und Nutzung von E-Pkw-Kapazitäten für den Ausgleich der EE (vgl. Juul et al., 2015).

Das Anwendungsfeld Parkhaus ist bereits in der Literatur zu finden: z. B. bei Brandt et al. (2017). Im Folgenden wird ein daran anknüpfendes Konzept vorgestellt, bei dem der Parkhausbetreiber als Zwischenhändler agiert (siehe Abbildung 2.13). Die Idee dahinter ist, dass dieser als Aggregator fungiert und somit als Schnittstelle zwischen

Angebots- und Nachfrageseite dient. Wird die Angebotsseite untersucht, so könnten zukünftig Parkhausbetreiber mit konventionellen Anlagen, wie bspw. Gas- und Pumpwasserspeicherkraftwerken, welche ebenfalls schnell Energie zur Verfügung stellen, konkurrieren. Dabei sind auf dem Energiemarkt insbesondere Frequenzregelungen (positive wie auch negative Regelung) notwendig, um den entsprechenden Bedarf an Netzstabilisierungsmaßnahmen abzudecken. Im Vergleich zu den konventionellen Anlagen hat hier ein Parkhausbetreiber, als Zwischenhändler, den Vorteil, dass er keine Investitionen für die Fahrzeuge (sondern für die IKT und den Bau der Ladesäuleninfrastruktur) hat, weil er nicht der Besitzer der Fahrzeuge ist, hingegen die Kraftwerke erst gebaut werden müssen. Jedoch sind ausreichend E-Pkw Kunden für die nachfrageseitige Flexibilisierung zum Lastmanagement zu integrieren, damit entsprechende Flexibilität am Energiemarkt angeboten werden kann (vgl. Brandt et al., 2017).

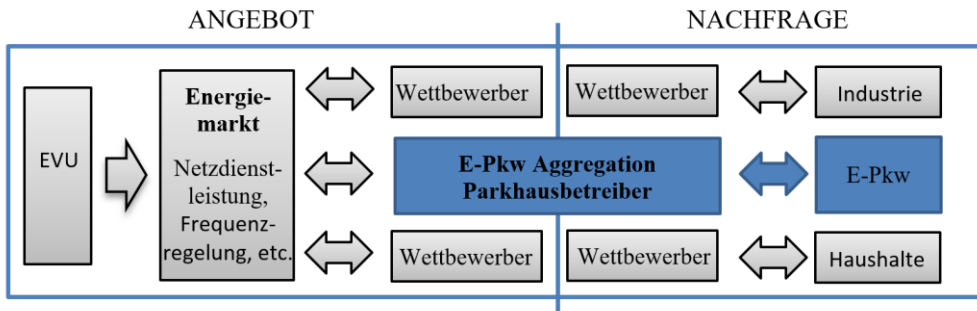


Abbildung 2.13: Parkhausbetreiber im Kontext des Marktes
Quelle: nach Brandt et al. (2017)

Ein ganzheitlicher Ansatz für die Entwicklung eines Geschäftsmodells für E-Pkw ist in Kley et al. (2011) zu finden. Darin sind die Grundlagen zur Erstellung solcher Lösungen beschrieben. Weitere Entwicklungen von mehr spezifischen Konzepten existieren z. B. in Salah et al. (2016), die das Design von Energiedienstleistungen für Kunden näher analysieren oder für Elektromobilitätsdienstleistungen rund um die Nutzung von E-Pkw (vgl. Stryja et al., 2015). Diese Studien verwenden die Morphologische Box als methodischen Ansatz für eine systematische Darstellung der entwickelten Geschäftsmodelle und der dazugehörigen Lösungen. Eine Studie von Weiller und Neely (2014) beschäftigt sich mit den verschiedenen Dienstleistungen von E-Pkw die angeboten werden.

In Marinelli et al. (2017) wird ein möglicher Ansatz zur Abschätzung des Flexibilitätspotenzials von E-Pkw im Verteilnetz vorgestellt. Für verschiedene Länder werden

die aktuellen Regularien des Marktes näher beleuchtet und darauf basierend Handlungsempfehlungen mit einem entsprechenden Ablaufplan abgeleitet.

Madina et al. (2016) betrachten existierende Methoden für Geschäftsmodelle. Dabei werden drei Ladestandorte – zu Hause, Autobahn, Halb-Öffentlich – näher analysiert. Zu letzterem können u. a. Parkhäuser (siehe Abschnitt 2.4.1) zählen. Ein Ergebnis dieser Studie war, dass für die Profitabilität des Parkhausbetreibers eine höhere Nutzung der Ladesäulen relevant ist. Wurden die gesamten Betriebskosten betrachtet, dann war das präferierte Ladeszenario zu Hause. Weitere qualitative Untersuchungen von Geschäftsmodellen für E-Pkw sind z. B. Bohnsack et al. (2014), Cherubini et al. (2015).

In Salah und Flath (2016) wird ein ‚deadline differentiated‘ Preisschema im Kontext eines Parkhauses angewendet, um flexible Lasten zu intensivieren. Als Ergebnis konnte festgestellt werden, dass das Preislevel stark von den Kosten der konventionellen Erzeugung sowie der lokalen PV-Stromerzeugung abhängt. Brandt et al. (2017) untersuchen ein Geschäftsmodell, in dem aggregierte E-Pkw im Kontext eines Parkhauses genutzt werden, um Regelenergie zur Verfügung zu stellen. Die Kernaussage ist, dass die Erlöse sehr gering ausfallen im Vergleich zu den Investitionen für die Infrastruktur und das Laden. Somit ist ein Fazit von Brandt et al. (2017), dass Geschäftsmodelle in diesem Zusammenhang näher untersucht werden müssen, um aussagekräftige Schlussfolgerungen zu ziehen.

3 Entwicklung des deterministischen und stochastischen Optimierungsmodells

Um die relevante Methodik zu ermitteln, müssen zunächst geeignete Modellierungsansätze identifiziert werden. Demnach sollten die Anforderungen an das geplante Modell definiert sein. Somit finden sich am Anfang dieses Kapitels die Vorüberlegungen zur Modellentwicklung wieder. Darauf aufbauend werden die identifizierten Anforderungen an das entwickelte Modell und die methodischen Grundlagen näher untersucht. Für die Auswahl geeigneter Optimierungsverfahren, um die verschiedenen Fragestellungen der zugrundeliegenden Arbeit zu beantworten, bietet der Abschnitt 3.2 einen Überblick. Die Aspekte der stochastischen Modellierung werden im Abschnitt 3.3 abgehandelt. Das übergeordnete Ziel der verschiedenen Optimierungsverfahren liegt in der Minimierung der Ladekosten der externen genutzten Leistung, angepasst an eine bestimmte Fragestellung. Die Abschnitte 3.4 sowie 3.5 stellen jeweils die dazugehörige Modellierung vor und bilden den Abschluss des Kapitels. Teilweise beruhen Inhalte vom Abschnitt 3.5 auf der Veröffentlichung von Seddig et al. (2019b).

3.1 Herleitung des Modellierungsansatzes

Dieser Arbeit liegen verschiedene Fragestellungen (vgl. Abschnitt 1.2) zu Grunde, die einer differenzierten Betrachtung bedürfen. Bei der Modellierung müssen Aspekte wie die Richtigkeit, Zulässigkeit sowie Zweckmäßigkeit des zu entwickelnden Modells Berücksichtigung finden (vgl. Struckmeier, 2017). Darauf aufbauend werden die Modellanforderungen definiert und auf Basis einer Gegenüberstellung von verschiedenen Modellierungsansätzen entsprechende Methoden identifiziert, die auf die jeweiligen Untersuchungsfragen anwendbar sind. Abschließend stehen dann die Grundlagen für das neue Modellierungskonzept fest.

3.1.1 Modellanforderungen

Die Erarbeitung des Modells erfolgt innerhalb der Systemgrenzen eines Parkhauses mit lokaler PV-Stromerzeugung auf dem Parkhausdach. Somit sollten bestimmte

Gegebenheiten Berücksichtigung finden, wie beispielsweise eine Begrenzung der Anschlussleistung aufgrund eines vorhandenen Transformators im Parkhaus. Diese kann sich auf die Annahme von Ladevorgängen auswirken. Sobald einmal Garantien zugesprochen werden, dass ein Fahrzeug geladen wird, sind diese auch einzuhalten. Weitere technische Restriktionen müssen abgebildet werden. Dazu zählen sowohl die Ladeleistung der Ladesäulen als auch das Ladeverhalten der E-Pkw. Diese und andere Nebenbedingungen haben Auswirkungen auf die Wahl des Modellierungsansatzes.

Die Aufbereitung der verschiedenen Inputdaten benötigt eine aufgeschlüsselte Betrachtungsweise. Zum einen inwieweit die stochastischen Komponenten der Parameter und Variablen Berücksichtigung finden, zum anderen aber auch der Umgang mit Unsicherheiten, die auftreten können. Eine realitätsnahe und differenzierte Darstellung des Mobilitätsverhaltens der einzelnen E-Pkw Flotten sowie der Energieerzeugung und Prognose der Erzeugung von PV sollten abbildbar sein.

Für diese Arbeit ist ein wichtiger Aspekt, dass es eine zentrale Ladestrategie gibt, damit das Ladeverhalten der aggregierten E-Pkw zentral von beispielsweise einem Parkhausbetreiber gesteuert werden kann. Das Ziel ist unter Unsicherheit die Ladekosten zu minimieren, was aus der Perspektive des Gesamtsystems geschehen soll. Es ist eine zentrale Steuerung aller verschiedenen Flottenfahrzeuge notwendig, um die synergetische Ladeinfrastruktur zwischen den einzelnen Flotten zu koordinieren. Eine ausreichende zeitliche Auflösung, z. B. 15 Minuten, ist erforderlich. Dadurch lassen sich sowohl das Park- und Ladeverhalten der E-Pkw, mit dazugehörigen Lastspitzen, gut erfassen sowie die schwankende PV-Stromerzeugung als auch die Preise des Energiemarkts abbilden.

Des Weiteren ist festzuhalten, dass für die Erstellung von Ergebnissen und die Generierung von Aussagen die Realität möglichst vollständig und genau abzubilden ist. Dennoch sind für die Modellkomplexität Abwägungen bzgl. Vereinfachungen zu treffen, wie bspw. die Nutzung von Ganzzahligkeitsbedingungen. Zusammenfassend können die folgenden Anforderungen an das zu entwickelnde Modell im Hinblick auf die gestellten Forschungsfragen, wie folgt formuliert werden:

- Realitätsnahe Abbildung des Mobilitätsverhaltens von E-Pkw;
- Charakterisierung von verschiedenen Flotten durch diverse Mobilitätsdaten;
- Berücksichtigung technischer Aspekte eines Parkhauses, von Ladesäulen und von E-Pkw;

- Abbildung eines Wochentages mit 24 h und einer hohen zeitlichen Auflösung;
- Nutzung von verschiedenen Stromquellen für die Ladevorgänge (Netz vs. PV-Eigenerzeugung);
- Prognose von PV-Stromerzeugung;
- Möglichkeit zur Szenario- und Sensitivitätsanalyse bzgl. unterschiedlicher Parameterauslegung;
- Abwägung zwischen Exaktheit und Komplexität des Modells;
- Optimale Lastverschiebung und Ermittlung von LVP der Ladevorgänge hinsichtlich verschiedener Signale sowie die
- Berücksichtigung von Unsicherheiten zum Entscheidungszeitpunkt für eine höhere Prognosegenauigkeit.

3.1.2 Überblick über relevante Modellierungsansätze

Modellierungsansätze gehen bei der Modellentwicklung von realen Problemen aus, abstrahieren diese bis zu einem bestimmten Grade und nutzen dabei z. B. statistische Verfahren, vergangene Trends oder Annahmen. Zur spezifischeren Modellentwicklung zählen u. a. die Fragestellungen zu präzisieren, auf bekannte Modelle zurückzugreifen, wenn möglich, die benötigten Informationen zu definieren und anschließend in Modellparametern und -variablen zu übertragen (vgl. Struckmeier, 2017). In der Energiewirtschaft sind Top-down und Bottom-up Modelle weit verbreitete Ansätze (vgl. Herbst et al., 2012). Letztere repräsentieren die Realität durch eine heterogene Charakteristik von sozioökonomischen oder technischen Prozessen, auf einer disaggregierten Datenbasis beruhend, meist auf einen speziellen Sektor fokussierend. Top-down Modelle beruhen hingegen auf historischen Daten von Preisen, Nachfrage, Einkommen oder anderen Faktoren, die beispielsweise Technologien oder Sektoren abbilden. Dieses findet oft auf makroökonomischer Ebene statt und mit aggregierten Daten (vgl. Jochem et al., 2017).

Eine Option der Modellierungsansätze stellen Optimierungs- oder Simulationsmodelle dar. Letztere sind ein weit verbreitetes Analyseinstrument für eine flexible Analyse und Darstellung von realen Systemen (vgl. Waldmann und Helm, 2016). Es bietet eine recht gute Möglichkeit, Systeme bzgl. unterschiedlicher Fragestellungen und Entscheidungsvarianten zu analysieren (vgl. Suhl und Mellouli, 2013). Optimierungsmodelle hingegen nutzen formal beschriebene Probleme anhand von Zielfunktionen,

Entscheidungsvariablen und Nebenbedingungen, um ein Ergebnis unter Berücksichtigung des zulässigen Wertebereiches zu ermitteln (vgl. Suhl und Mellouli, 2013). Es gibt eine breite Vielfalt an Lösungsansätzen bzw. -verfahren. Dazu zählen z. B. die lineare Optimierung, die nichtlineare Optimierung, die gemischt-ganzzahlige lineare Optimierung (MILP), die stochastische Optimierung, Heuristiken oder Metaheuristiken, die u. a. in den Review-Arbeiten von Yang et al. (2015) oder Hu et al. (2016) für den Bereich der Integration der E-Pkw ins Energienetz näher vorgestellt wurden.

Für die Modellierung und Abbildung von Zufallsphänomenen sowie von Unsicherheiten, bietet sich die stochastische Modellierung an. Es können Standardverteilungen für eine spezifischere Abbildung von einzelnen Aspekten genutzt werden. Diese eignen sich besonders, indem sie gewisse Gegebenheiten repräsentieren und durch charakteristische Parameter, die ermittelt werden müssen, bestimmbar sind (vgl. Werners, 2013). Häufig werden Poisson-Verteilungen genutzt, um das Ankunftsverhalten z. B. in Warteschlangensystemen realitätsnah abzubilden (vgl. Werners, 2013). Weitere Standardverteilungen, wie Exponential-, Gleich- oder Normalverteilung, finden ebenfalls Anwendung zur Beschreibung des Ladeverhaltens von E-Pkw (vgl. Hu et al., 2016). Es gibt aber nicht nur parametrische Wahrscheinlichkeitsverteilungen, sondern auch nicht-parametrische, wie die Kerndichteschätzung, die genutzt werden (vgl. Iversen et al., 2014).

Jeder der vorgestellten Modellierungsansätze hat Vor- und Nachteile. Mit dem Blick auf die Anforderungen der hier zugrundeliegenden Zielstellung ist es erforderlich, die verschiedenen Modellsegmente miteinander zu vereinen. Entsprechend wird auf mehrere Modellierungsansätze zurückgegriffen. Bei der disaggregierten Datenlage, ist ein Bottom-up Ansatz zielführend. Des Weiteren sind sowohl Eigenschaften der Simulation als auch der Optimierung relevant. Stochastische Eigenschaften sollten ebenfalls berücksichtigt werden. Die konkrete Auswahl des Modellierungsansatzes wird im folgenden Abschnitt näher ausgeführt.

3.1.3 Auswahl des Modellierungsansatzes

Damit die Anforderungen aus Abschnitt 3.1.1 Berücksichtigung finden können, scheint es für die Entwicklung des Modells sinnvoll, sowohl die Ansätze der Simulation als auch der Optimierung zu kombinieren. Beides dient einer besseren Darstellung von realitätsnahen und zukünftigen Szenarien. Es findet eine deterministische Optimierung statt und um die Unsicherheiten expliziter zu integrieren, wurde zusätz-

lich eine stochastische Optimierung angewendet. Für die Umsetzung der verschiedenen Methoden sind die einzelnen Modellsegmente aufeinander abgestimmt. Die Auswahl der Simulation beruht zum einen auf der Datenlage und dem Blick auf ein Parkhaus, so dass ein Bottom-up Verfahren Anwendung findet. Zum anderen ist aber ebenso von Interesse, wie kostenminimales oder CO₂-armes Laden aussehen kann und damit ist die Optimierung relevant. Die Auswahl geht ebenfalls mit der Beantwortung der Forschungsfragen einher. Es wird ein Tag in 15-minütigen Schritten global optimiert. Zusätzlich wird dieser Tag mehrmals simuliert. Für eine Simulation spricht die Möglichkeit, die zukünftige Infrastruktur und Dimension der E-Pkw abzubilden und Prognosen abzugeben. Dahingehend sind ebenfalls Sensitivitätsanalysen sinnvoll, um die Empfindlichkeit der Ergebnisse gegenüber von Änderungen der Parameter zu erhalten. Hinzu kommt die stochastische Komponente. Weder das Verhalten der E-Pkw ist komplett deterministisch darstellbar, noch die PV-Stromerzeugung, wenn man den nächsten Tag abbilden möchte. Somit muss mit Unsicherheiten umgegangen werden. Die realitätsgetreue Darstellung der verschiedenen Ausgangsdaten mit Hilfe von Wahrscheinlichkeitsverteilungen ist ebenfalls eine weitere wichtige Modellierungskomponente. Detailliertere Ausprägungen der jeweiligen Methoden werden in den folgenden Abschnitten (3.2 und 3.3) weiter vertieft, damit eine geeignete Auswahl getroffen werden kann.

3.2 Grundlagen der Optimierung

Die Anwendung von Optimierungsverfahren dient der Entwicklung von Lösungen für vorliegende Problemstellungen und wird zur Entscheidungsunterstützung herangezogen. Abhängig von der Problemformulierung finden unterschiedliche Lösungsverfahren ihre Anwendung. In dieser Arbeit werden verschiedene Optimierungsmodelle genutzt, welche auf verschiedenen Grundlagen aufgebaut sind und im Folgenden näher ausgeführt werden.

3.2.1 Grundlagen der Optimierungsverfahren

Die Auswahl der verschiedenen Optimierungsverfahren ist von der Art des Problems und der zugrundeliegenden Formulierung abhängig. In der Optimierung wird eine Zielfunktion definiert, die das zu lösende Problem formalisiert und dieses kann entweder minimiert oder maximiert werden. Die Entscheidungsvariablen bilden die Freiheitsgrade der Zielfunktion ab. Die Zielfunktion unterliegt häufig Nebenbedingungen,

welche die möglichen Werte der Entscheidungsvariablen einschränken (vgl. Suhl und Mellouli, 2013).

Die Klassifizierung von Optimierungsmethoden und -problemen kann auf Basis verschiedener Aspekte erfolgen (vgl. Papageorgiou et al., 2012). In Abhängigkeit von der Problemformulierung sind es z. B. lineare oder nichtlineare Optimierungsmodelle. Die Klassifizierung ist neben den gewählten Variablen abhängig von den Nebenbedingungen, welche aus linearen oder nichtlinearen Gleichungen oder Ungleichungen bestehen können. Dabei besteht die Möglichkeit sowohl Probleme mit als auch ohne Nebenbedingungen zu formulieren (vgl. Luenberger und Ye, 2016). Bei den Variablen wird zwischen reellen, ganzzahligen, binären und gemischt-ganzzahligen Variablen unterschieden. Es ist bei der Formulierung von Problemstellungen mit binären, natürlichen, ganzzahligen als auch reellen Variablen von der gemischt-ganzzahligen (lineare) Optimierung die Rede. Ebenfalls gibt es multikriterielle Optimierungsprobleme, bei denen nicht nur eine Zielfunktion vorliegt (vgl. Nickel et al., 2014).

Es kann auf heuristische oder exakte Verfahren zurückgegriffen werden. Die Nutzung von exakten Verfahren dient zur Findung einer globalen optimalen Lösung, sofern eine existiert. Wird der Rechenaufwand zu groß, da die exakten Verfahren häufig exponentielle Rechenzeiten aufgrund der Problemformulierung besitzen, kommen Heuristiken zum Einsatz. Diese Verfahren haben einen akzeptablen Aufwand, jedoch wird nicht zwangsläufig eine optimale, aber oftmals eine ‚gute‘ Lösung ermittelt (vgl. Nickel et al., 2014).

Ein weit verbreitetes Optimierungsverfahren ist die lineare Optimierung. Durch effiziente Lösungsverfahren und eine einfache Modellbildung zeichnet sich diese aus. Lösungsverfahren komplexerer Probleme, wie die nichtlineare oder gemischt-ganzzahlige Optimierung, ziehen die lineare Optimierung häufig als Hilfsmittel heran (vgl. Nickel et al., 2014).

Heuristiken sind Verfahren, die einen Algorithmus anwenden, mit dem durch systematisches Vorgehen eine Lösung gefunden wird. Jedoch besitzen die heuristischen Verfahren keine Optimalitätsgarantie. Ein Anwendungsaspekt für deterministische heuristische Verfahren ist die relativ kurze Laufzeit zur Ermittlung einer Lösung des zugrundeliegenden Problems. Die Qualität (Güte) der Problemlösung kann durch den Vergleich mit anderen Heuristiken oder ggf. durch die Abweichung von der optimalen Lösung beurteilt werden (vgl. Werners, 2013).

Problemstellungen mit Ganzzahligkeitsbedingungen sind i. d. R. schwieriger zu lösen als lineare Probleme, da kein polynomieller Algorithmus für diesen Fall bekannt ist und gehören daher zu den sogenannten harten, NP-vollständigen Problemen. Es werden mehrere Lösungstechniken für die Lösung solcher Probleme benutzt (vgl. Suhl und Mellouli, 2013). Wie bei der linearen Optimierung ist der Lösungsraum durch einen konvexen Polyeder begrenzt, jedoch lässt sich die zulässige Menge nicht als Durchschnitte von endlich vielen Halbräumen darstellen. Bei der gemischt-ganzzahligen Optimierung wird zur Lösungsfindung oftmals zunächst die LP-Relaxation und dann der Branch and Bound Algorithmus oder das Schnittebenenverfahren zur Anwendung gebracht (vgl. Suhl und Mellouli, 2013; Nickel et al., 2014).

3.2.2 Stochastische Optimierung

Existieren Unsicherheiten im Entscheidungsproblem gibt es verschiedene Herangehensweisen, um diese zu berücksichtigen. Die stochastische Optimierung (bzw. Programmierung) ist der Teil des Operations Research (OR), der sich damit beschäftigt, wie Unsicherheiten in den Entscheidungsprozess integriert werden (vgl. King und Wallace, 2012). Unsicherheiten können als Informationen beschrieben werden, die nicht genau bekannt sind, zu dem Zeitpunkt, an dem die Entscheidung getroffen werden muss. Dabei gibt es eine hohe Spannbreite von strukturellen Aspekten, sowohl bei der Problemformulierung als auch der Modellierung von Unsicherheiten, die Anwendung finden. Abhängig von der Beziehung der zufälligen Elemente zueinander spiegelt diese sich in der Vielfalt der stochastischen Programmierungsmodelle wider. Die Auswirkungen können sich sowohl in der Zielfunktion des Entscheidungsprozesses als auch in den Nebenbedingungen der Entscheidungen befinden (vgl. Birge und Louveaux, 2011).

Eine auftretende Schwierigkeit ist bei realen Entscheidungssituationen ein geeignetes Wahrscheinlichkeitsmodell zu identifizieren. Ein erster Schritt dafür ist beispielsweise die Unsicherheit als Zufallsvariablen oder Zufallsprozesse mit einer entsprechenden Wahrscheinlichkeitsverteilung zu beschreiben. Dieser Schritt kann durch statistische Methoden oder Parameterschätzung geschehen. Als zweiter Schritt erfolgt die Szenariogenerierung. Dabei wird hier angenommen, dass die Verteilung der stochastischen Variable bekannt ist, aber nicht der aktuelle Wert (vgl. Pflug und Pichler, 2014).

Die stochastische Programmierung differenziert zwischen den here-and-now und den wait-and-see Entscheidungen. Bei dem wait-and-see Ansatz wird davon ausgegangen,

dass die Entscheidung erst dann getroffen werden muss, wenn die unsichere Eingangsgröße eingetreten ist. Somit gibt es keine Unsicherheit mehr und es ist ein deterministisches Problem. Daher kann mit der perfekten Voraussicht und dem vollen Informationsstand die Optimallösung bestimmt werden. Im Falle von here-and-now wird jedoch die Auswahl getroffen, bevor die unsichere Entscheidungsvariabel eingetreten ist (vgl. Birge und Louveaux, 2011).

Bei zweistufigen stochastischen Optimierungsproblemen mit Rekurs werden, wie vom Namen abgeleitet, die Entscheidungen in zwei Gruppen eingeteilt (vgl. Shapiro et al., 2009):

- Die first-stage Entscheidung ist der erste Teil, in dem eine Entscheidung getroffen wird, ohne dass die Unsicherheit berücksichtigt wird, da die Realisierung der Zufallsgröße ω noch nicht bekannt ist (siehe Gleichung 3.1). Somit ist das die here-and-now Entscheidung.
- Die second-stage Entscheidung findet unter der Annahme statt, dass die Zufallsgröße ω bekannt ist und wird daher auch wait-and-see Entscheidung genannt. Die Entscheidungsvariablen der zweiten Stufe werden auch als Rekurs-Variablen bezeichnet.

Neben den zweistufigen stochastischen Optimierungsproblemen gibt es ebenfalls die mehrstufige stochastische Optimierung. Dies ist der Fall, wenn über die Zeit Entscheidungsprobleme vorliegen, die mehrere Entscheidungen zu verschiedenen Zeitpunkten umfassen. Somit liegen bei den mehrstufigen Problemen mehrere rekursive Probleme vor. Diese können in Blöcke zusammengefasst werden, so dass sie dann mit einem zweistufigen stochastischen Optimierungsproblem abbildbar sind (vgl. Birge und Louveaux, 2011).

3.2.2.1 Zwei- und mehrstufige stochastische Optimierung

Optimierung unter Unsicherheit mit Berücksichtigung von zwei oder mehreren Stufen wurde vor über 60 Jahren von Dantzig (1955) eingeführt. Bei der Optimierung unter Unsicherheit werden Modellparameter als nicht genau bekannt betrachtet. Häufig werden die Unsicherheiten mit Hilfe der Wahrscheinlichkeitstheorie abgebildet (vgl. Zimmermann, 2008). Es werden bei der stochastischen Programmierung die Entscheidungsvariablen diskreten Zeitpunkten des Planungszeitraumes zugewiesen, bei denen Entscheidungen stattfinden. Im Abschnitt 3.2.2 wurde das Thema der zwei- und mehrstufigen stochastischen Programme bereits eingeführt. Mehrstufige Entscheidungs-

probleme sind u. a. darauf angelegt, reale Probleme zu lösen. Dabei ist es insbesondere wichtig die Realität in einer geeigneten Art und Weise abzubilden, so dass die Ergebnisse des Modells zur Entscheidungsunterstützung des realen Problems herangezogen werden können (vgl. Pflug und Pichler, 2014).

Liegt nun der Fokus auf ein zweistufiges stochastisches Programm mit Rekurs, so gilt (vgl. Birge und Louveaux, 2011):

$$\begin{aligned} \min c^T x + E_\omega Q(x, \omega) \\ \text{unter } Ax = b \\ x \geq 0 \end{aligned} \quad (3.1)$$

wobei $Q(x, \omega)$ die Rekursfunktion darstellt und dieses Unterproblem ist wie folgt formuliert:

$$Q(x, \omega) = \min \{q(\omega)^T\} | Wy(\omega) = h(\omega) - T(\omega)x, y(\omega) \geq 0 \} \quad (3.2)$$

Es wird ersichtlich, dass die Erststufen-Entscheidung x unter der Berücksichtigung von y und ω zu wählen ist. Die Rekursfunktion wird mit ihrem Erwartungswert in dem zweistufigen stochastischen Programm berücksichtigt und beinhaltet dabei die Zufallsgröße ω . Das Unterproblem $Q(x, \omega)$ enthält den Teil der Zielfunktion, welches von den zufallsbehafteten Kosten q abhängt. Die Nebenbedingungen $Wy(\omega) = h(\omega) - T(\omega)x$ enthalten ebenfalls stochastische Parameter sowie die von Unsicherheit geprägten Variablen. Die Entscheidungsvariablen der zweiten Stufe nennt man auch Rekurs-Variablen und sind mit y bezeichnet. Diese Rekurs-Variablen sind abhängig von der Erststufen-Entscheidung x sowie der Realisierung der Zufallsgröße ω .

Die Gleichungen (3.1) und (3.2) können umformuliert werden, damit das zweistufige stochastische Programm als deterministisches Äquivalent gelöst werden kann. Das ist möglich, wenn sich die zufälligen Ereignisse mit endlich vielen Szenarien abbilden lassen. In dem Fall steigt die Anzahl der Nebenbedingungen, da die Nebenbedingungen der zweiten Stufe nun für alle Szenarios und damit Realisationen der Zufallsgröße ω erfüllt werden müssen. Entsprechend ist das Problem der deterministischen äquivalenten Formulierung, dass diese in Abhängigkeit von der Szenarioanzahl, sehr groß werden können. Zur Lösung dieser Problemformulierung gibt es verschiedene Ansätze, bspw. die L-shaped Methode, die eine Benders-Zerlegung ist und zu den Dekompositionsverfahren zählt (vgl. Schade, 2012).

Zweistufige stochastische Probleme können u. a. mithilfe von Monte Carlo Sampling Techniken, durch die die Abbildung einer diskreten Menge an Szenarien relativ effizient möglich ist, gelöst werden. Diese sogenannte Sample Average Approximation Methode wird im folgenden Abschnitt näher beschrieben (vgl. Shapiro, 2008).

3.2.2.2 Sample Average Approximation Methode

Der Ansatz der Sample Average Approximation (SAA) Methode wird vor allem bei der stochastischen Programmierung mit zwei- oder mehrstufigen Problemen angewendet. Dabei wird die Monte Carlo Simulationsmethode genutzt, um den Erwartungswert der Rekursfunktion zu schätzen (vgl. Shapiro, 2006). Die erwartete Zielfunktion des stochastischen Problems wird approximiert durch eine Stichprobenschätzung, die von einer Stichprobenerhebung abgeleitet wurde. Dabei wird angenommen, dass die N Szenarien der SAA Formulierung aus unabhängig und identisch verteilten Zufallsvariablen bestehen und damit als Voraussetzung eine gleiche Eintrittswahrscheinlichkeit der SAA Szenarien besitzen. Eine der Eigenschaften der SAA Methode für zweistufige stochastische Probleme ist die Konvergenz zur optimalen Lösung (vgl. Kim et al., 2011). Das resultierende SAA Problem kann mit Hilfe von deterministischen Optimierungstechniken gelöst werden (vgl. Verweij et al., 2003).

Des Weiteren sind Szenarioreduktionsverfahren eine Option, die Größe des SAA Problems zu reduzieren. Zur Anwendung kommen z. B. Vorwärts- oder Rückwärtsalgorithmus. Ersterer sucht das Szenario, welches die Summe der Abstände zu allen anderen Szenarios mit Hilfe eines heuristischen Ansatzes minimiert. Der Rückwärtsalgorithmus reduziert die Szenarios auf Basis der Auswahl der geringsten Kosten des nächstgelegenen Szenarios (vgl. Schade, 2012). Eine weitere Übersicht gibt Dupacová et al. (2000).

Ursprünglich basiert die SAA Methode auf der Methode des Monte Carlo Samplings als einen Schätzer für den erwarteten optimalen Wert der Zielfunktion. Die Grundidee ist, die Verteilung der Stichprobenerhebung nah an der ursprünglichen Wahrscheinlichkeitsverteilung zu realisieren. Für das vorliegende stochastische Problem wird das Latin Hypercube Sampling genutzt, welches erstmalig von McKay et al. (1979) vorgestellt wurde. Das LHS ist eine Methode zur Ermittlung von Zufallsstichproben. Bei dieser Methode wird schon mit einer geringen Stichprobenanzahl der Parameterraum repräsentativ erfasst. Der Vorteil der Nutzung von LHS ist, dass diese Methode schneller konvergiert als beispielsweise die Random Sampling Methode und eine ge-

ringere Varianz aufweist (vgl. McKay et al., 1979; Stein, 1987). Bei der Vorgehensweise der LHS Methode wird die kumulierte Verteilungsfunktion in gleich große Segmente aufgeteilt. Danach wird ein Punkt zufällig aus jeder Partition gezogen. Dadurch spiegeln die darstellenden Werte jedes Intervalls die zugrunde liegende Eingabewahrscheinlichkeitsverteilung gut wider (vgl. Homem-De-Mello et al., 2011). Auf dieses Verfahren wird zurückgegriffen, um sowohl eine Varianzreduktion zu erreichen, als auch eine Verringerung der Anzahl der durchzuführenden Szenarien zu ermöglichen, um somit die Rechenintensität der stochastischen Optimierung zu verringern. Ebenfalls werden die Eigenschaften und Konvergenzannahmen von Kleywegt et al. (2002) als Voraussetzung genutzt. Mit der Anwendung der LHS Methode wird das zu grundliegende Problem mit Hilfe der SAA Methode effizienter und genauer gelöst (siehe Abschnitt 5.7.3).

3.2.3 Anwendungen im Bereich des Lademanagements von Elektrofahrzeugen

Die verschiedenen vorgestellten Methoden der Optimierung und damit einhergehend mathematischen Modellierungen finden bereits Anwendung im Kontext des Lademanagements von E-Pkw. Im Folgenden werden einige typische Anwendungen vorgestellt, die insbesondere der Fragestellung der Minimierung der Ladekosten der E-Pkw nachgehen. In diesem Zusammenhang wird von einer zentralen Steuerung der aggregierten E-Pkw durch einen Flottenbetreiber ausgegangen. Er erhält alle relevanten Informationen für den Input (z. B. Fahrprofile der E-Pkw, Batteriemodell, Elektrizitätspreise, Netzrestriktionen), um damit entsprechende Entscheidungen über das Ladeverhalten der E-Pkw zu treffen.

Die Lineare Optimierung kann zur Anwendung kommen, um beispielsweise den Batteriezustand und das dazugehörige Ladeverhalten des E-Pkw zu charakterisieren, damit die Ladekosten der E-Pkw minimiert werden (vgl. Sundström und Binding, 2012). Dieses lineare Optimierungsmodell findet die optimale Lösung in einer relativ kurzen Rechenzeit. In der Arbeit von Sundström und Binding (2012) wird die quadratische Optimierung genutzt, um das Batterieladmodell abzubilden. Dieses Verfahren führt zu einer Erhöhung der Rechenzeit um das 819-fache im Vergleich zur linearen Optimierung. Das Ergebnis der optimalen Lösungen ändert sich nur geringfügig, weswegen die Vorzüge der quadratischen Programmierung die Nachteile der Rechenzeit nicht aufwiegen würden.

Die Anwendung von MILP ist erforderlich, sobald Binär- oder Integer-Variablen für die Problemformulierung notwendig sind. Im Bereich des Ladeverhaltens von E-Pkw kommt dieses insbesondere zur Bestimmung von diskreten Zuständen, wie Fahren, Parken, Laden, Entladen, Annahme oder Ablehnung von Ladeanfragen zum Einsatz (vgl. Hu et al., 2016).

Die stochastische Programmierung findet erst in jüngerer Vergangenheit vermehrt Anwendung, da die Mehrheit der Forschung noch auf vollkommene Information und deterministische Annahmen setzt. Um jedoch realistische Szenarios darzustellen, werden Unsicherheiten z. B. im Lademanagement von E-Pkw durch stochastische Methoden abgebildet (vgl. Hu et al., 2016; Wu und Sioshansi, 2017).

3.2.4 Auswahl der verwendeten Optimierungsmethoden

Die formulierten Forschungsfragen im Abschnitt 1.2 beinhalten verschiedene zu berücksichtigende Faktoren. Im Abschnitt 3.1 findet eine Spezifizierung für die Anforderung an das Modell statt. Darauf basierend sind die methodischen Aspekte, der in den vorangestellten Abschnitten aufgezeigten verschiedenen Möglichkeiten der Optimierung, noch im Detail zu definieren.

Aufgrund der gegebenen Rahmenbedingungen des zu untersuchenden Lademanagements von E-Pkw in einem Parkhaus existieren daraus resultierend Restriktionen, die entsprechend in der Optimierung Berücksichtigung finden müssen. Betroffen ist z. B. die Einhaltung der vorhandenen Anschlussleistungsgrenzen, so dass nicht alle Ladeanfragen bedient werden können. Daher ist es erforderlich eine Binärvariable einzuführen, die erfasst, ob Ladeanfragen der verschiedenen Flotten der E-Pkw erfolgreich waren oder nicht. Aus diesem Grund kommt für das zu entwickelnde Modell die lineare Optimierung nicht in Frage, da verschiedene Variablentypen erforderlich sind. Es bieten sich eher die komplexeren, gemischt-ganzzahligen linearen Optimierungsmodelle an. Das zu entwickelnde MILP deckt den Teil der Anforderungen ab, in denen perfekte Informationen und noch keine Unsicherheiten vorliegen. Somit kann der Benchmark Fall ermittelt werden, um das deterministische Optimum zu bestimmen.

Ein weiterer Aspekt, der im Abschnitt 3.1 behandelt wird, ist die Nutzung von Wahrscheinlichkeitsverteilungen für verschiedene Parameter des zu entwickelnden Modells. Um die stochastische Natur der Parameter abzubilden, ist, wie bereits aufgegriffen, eine Simulation notwendig. Somit müssen die Optimierungen mit den Simulationen gekoppelt werden. Zusätzlich wird angenommen, dass es zwei Phasen

bei der Durchführung des Modells gibt. Die erste Phase beinhaltet die Einplanung der Ladevorgänge der E-Pkw und dann in der zweiten Phase die tatsächliche Realisierung, bei denen Abweichungen durch eine veränderte Energienachfrage und eine veränderte PV-Stromerzeugung eintreten können. Um explizit die Unsicherheiten durch Abweichungen von eingeplanten und realisierten Variablen zu berücksichtigen, muss zusätzlich die stochastische Optimierung angewendet werden. Da es sich um zwei Phasen bei der Entscheidung handelt, kann die zweistufige stochastische Optimierung herangezogen werden. Das stochastische Problem beinhaltet ebenfalls Binärvariablen, demnach handelt es sich um ein zweistufiges stochastisches gemischt-ganzzahliges lineares Optimierungsproblem (SMILP). Teilweise wurde schon auf Aspekte der stochastischen Optimierung eingegangen, weitere notwendige stochastische Modellierungsinhalte werden im folgenden Abschnitt 3.3 dargelegt.

Ein letzter Aspekt, der aus den Überlegungen vom Abschnitt 3.1 umgesetzt werden sollte, ist die Nachstellung des Ladeverhaltens ohne Ladesteuerung. Hierfür wird unkontrolliertes Laden als Referenzfall betrachtet, welcher aber nicht den Anspruch einer optimalen Lösung besitzt, sondern das angenommene Ladeverhalten darstellt. Diese Fallgestaltung wird im Abschnitt 5.5.2 näher spezifiziert.

3.3 Stochastische Modellierung

Der Entscheidungsprozess zur Beantwortung von Fragestellungen geschieht selten mit vollständiger Sicherheit und ist daher nicht adäquat mit einem deterministischen Modell abbildbar. So gibt es Informationen, die nicht gänzlich bekannt sind oder es liegen nur mögliche Auskommen vor. Stochastische Programmierung ist hierfür ein Ansatz, um Unsicherheiten in Entscheidungsprobleme zu integrieren (vgl. King und Wallace, 2012; Kall und Mayer, 2011). Damit können zufallsabhängige Einflüsse oftmals detaillierter abgebildet werden, wenn stochastische Modelle genutzt werden (vgl. Werners, 2013). Die relevanten Merkmale werden häufig mithilfe von Zufallsvariablen beschrieben. Diese werden in einem neuen Wahrscheinlichkeitsraum abgebildet, welcher die Zielgröße beschreibt und dabei eine simplere Struktur hat als der zugrundeliegende Wahrscheinlichkeitsraum (vgl. Cramer und Kamps, 2008). Ein häufiges Vorgehen ist es, sich dem Wert der Unsicherheit der unbekannt Parameter durch Schätzungen oder Erwartungswerte anzunähern und im Nachgang mit Korrekturwerten, die Abweichung möglichst gering zu halten (vgl. Marti, 2008).

Bei der stochastischen Modellierung, die im Abschnitt 3.2.2 schon aufgegriffen wurde, ist zwischen verschiedenen Teilaspekten zu unterscheiden. Detailliertere Abbildungsmöglichkeiten der verschiedenen Arten von Unsicherheiten, Prognosen und die Modellierung stochastischer Einflüsse werden im Folgenden vorgestellt. Dazu zählen u. a. Wahrscheinlichkeitsverteilungen, um die Daten entsprechend abzubilden.

3.3.1 Stochastischer Prozess

Kenngrößen von stochastischen Systemen sind hauptsächlich die Erwartungswerte von Zufallsvariablen. Deren Verteilungen beschreiben die zeitliche Entwicklung eines Systems. Demnach wird ein stochastischer Prozess betrachtet. Darunter wird eine Menge an Zufallsvariablen und eine Menge von Zeitpunkten verstanden. Es gibt mehrere Beispiele für stochastische Prozesse. So zählen Markov-Ketten zu den zeit-disreten und homogene Poisson-Prozesse zählt zu den zeit-stetigen stochastischen Prozessen. Diese sind wichtige Analyseinstrumente, die vermehrt in diversen Bereichen Anwendung finden (vgl. Waldmann und Stocker, 2013).

3.3.2 Wahrscheinlichkeitsverteilungen

Das Verhalten von Zufallsgrößen wird durch stochastische Prozesse, formuliert als mathematische Modelle, beschrieben. Für die weitere Herangehensweise ist es wichtig, für die vorhandenen Daten die entsprechende PDF zu schätzen. Zur Schätzung von Dichtefunktionen können zwei verschiedene Ansätze gewählt werden – parametrisch vs. nicht-parametrisch.

In dieser Arbeit werden verschiedene Variablen und Parameter definiert sowie unterschiedliche Quellen als Inputdaten genutzt. Um die Realität bestmöglich abzubilden, müssen das entwickelte Modell und die dazugehörigen Parameter entsprechend kalibriert werden. Für die Abdeckung einer gewissen Spannbreite können Wahrscheinlichkeitsverteilungen genutzt werden. Insbesondere in Kombination mit der Simulation ist eine Analysemöglichkeit gegeben. Meistens haben die Inputgrößen einen stochastischen Charakter, somit können sie mit einer Wahrscheinlichkeitsverteilung und als Zufallsvariable beschrieben werden (vgl. Suhl und Mellouli, 2013). Um Zufallsphänomene zu modellieren, sind manche Verteilungen besonders geeignet, weil diese durch bestimmte Gegebenheiten repräsentiert sind und durch charakteristische Parameter, welche ermittelt werden müssen, angebar sind (vgl. Werners, 2013). Wie

oben beschrieben, ist es weit verbreitet, auf bekannte Wahrscheinlichkeitsverteilungen zurückzugreifen. Davon wird eine Auswahl im Folgenden vorgestellt, die insbesondere im Kontext der Modellierung von E-Pkw sowie von PV-Stromerzeugung verbreitet sind.

3.3.2.1 Parametrische Verteilungen

Der parametrische Ansatz versucht mit gegebenen parametrischen Verteilungen, wie z. B. der Normalverteilung, die entsprechenden Schätzer vom Mittelwert μ und der Varianz σ^2 der zugrundeliegenden Daten zu ermitteln. Diese Schätzer werden dann für die Normalverteilung und für die zugrundeliegenden Daten genutzt, um eine passende PDF zu erstellen.

Die Normalverteilung zählt zu den wichtigsten und bekanntesten Verteilungen. Dieser Umstand beruht u. a. darauf, dass sich einige andere Verteilungen durch die Normalverteilung approximieren lassen. Ebenfalls können viele Daten von empirischen Verteilungen ausreichend gut durch eine Normalverteilung approximiert werden (vgl. Fahrmeir et al., 2010). Für den breiten Bereich der Modellierung von E-Pkw können Normalverteilungen genutzt werden. Beispielsweise bei der Modellierung der Vorhersage der Lastprofile (vgl. Uhrig et al., 2015) oder der zurückgelegten Distanzen (vgl. Hou et al., 2015). Oftmals findet die Modellierung als Normalverteilung Anwendung, um das Rauschen von Unsicherheiten darzustellen, beispielsweise bei Mohammadi et al. (2014) oder Soares et al. (2016).

Die Exponentialverteilung wird häufig gewählt, um Ankunftszeiten darzustellen (vgl. Suhl und Mellouli, 2013). Die Ausführungen von Aghaei et al. (2016) beinhalten ein Beispiel für die Abbildung der Ankunftszeiten der Fahrzeuge. Ladezeiten können beispielsweise mit einer Exponentialverteilung modelliert sein (vgl. Yu et al., 2011). Ebenfalls nutzen einzelne Arbeiten die Exponentialverteilung, um die Parkdauer entsprechend darzustellen (vgl. Tang et al., 2013).

Die Poisson-Verteilung ist eine diskrete Wahrscheinlichkeitsverteilung und eignet sich, um Zählvorgänge zu modellieren. Dabei wird die mögliche Anzahl an eintretenden Ereignissen in einem Zeitintervall gezählt (vgl. Fahrmeir et al., 2010). Verschiedene Arbeiten greifen auf die Poisson-Verteilung oder den Poisson-Prozess zurück, um die Ankunftszeit der E-Pkw zu modellieren (vgl. Zhu et al., 2012; Tushar et al., 2014; Tang et al., 2013).

Die Weibullverteilung ist eine stetige Verteilung und wird häufig für die Modellierung von Lebensdauern von Bauteilen genutzt (vgl. Waldmann und Helm, 2016). Für die

Modellierung der Ladezeiten von E-Pkw wurde z. B. in Khoo et al. (2014) auf eine Weibullverteilung zurückgegriffen. In der Arbeit von Druiitt und Früh (2012) wurden die zurückgelegten Pkw Distanzen mithilfe einer Weibullverteilung modelliert. Ebenfalls können Datenreihen von PV-Erzeugung abgebildet werden (vgl. Honarmand et al., 2015). Plötz et al. (2017) modellieren mit der Weibullverteilung die täglich zurückgelegten Distanzen.

Der Nachteil der parametrischen Verteilungen ist vor allem, dass basierend auf den vorhandenen Daten die entsprechenden Parameter ermittelt werden müssen. Damit werden die Ursprungsdaten nur approximiert dargestellt und es wird nicht die genaue Verteilung wiedergegeben.

3.3.2.2 Nicht-parametrische Verteilungen

Die nicht-parametrische Schätzung der PDF wird insbesondere dann verwendet, wenn die Daten nicht offensichtlich einer bestimmten parametrischen Verteilung folgen (vgl. Silverman, 1998; Gentle et al., 2011).

Als ein Vertreter der nicht parametrischen Verteilung zählt die Methode des Kerndichteschätzers. Dieses Verfahren ermöglicht eine Schätzung der unbekanntem Wahrscheinlichkeitsverteilung einer stetigen Zufallsvariable. Dafür wird zum einen ein Kern (z. B. Gauß-, Gleichverteilt- oder Cauchy-Kern) definiert und zum anderen die Bandbreite, welche entscheidend für die Approximationsqualität ist (vgl. Wand und Jones, 1995). Beispiele im Kontext der Elektromobilität liefern Iversen et al. (2014), welche die Kerndichteschätzung anwenden, um die empirische Verteilung der Distanzen bestmöglich abzubilden oder Paterakis und Gibescu (2016), die Charakteristika von Elektromobilitätsflotten aus empirischen Daten mit der Kerndichteschätzung darstellen. Die Verfügbarkeit von E-Pkw pro Stunde wurde in der Arbeit von Li et al. (2016) mit KDE modelliert.

3.3.3 Monte Carlo Simulation

Als Monte Carlo Simulation (MCS) oder stochastische Simulation wird eine Simulation bezeichnet, in der stochastische Einflüsse Berücksichtigung finden. Es wird dabei eine gewisse Anzahl an Zufallsexperimenten sowohl durchgeführt als auch ausgewertet (vgl. Werners, 2013). Die MCS wird genutzt, wenn der Input als auch der Output aus verschiedenen Verteilungen besteht. Die Ausgangsdaten liegen dann in einer experimentellen Verteilung vor, welche auf einer theoretischen Verteilung, der zugrun-

deliegende gegebenen Input-Verteilung beruht. Diese experimentelle Output-Verteilung nähert sich nach dem Gesetz der großen Zahlen den Ausgangsdaten mit der dazugehörigen Input-Verteilung an (vgl. Suhl und Mellouli, 2013).

Weitere Anwendungsmöglichkeiten der MCS sind beispielsweise Sensitivitäts- oder Szenarioanalysen. Mit Hilfe der letzteren kann bewertet werden, in welchen Bereichen Parameter sich bewegen und inwieweit sich diese auf die Ergebnisse auswirken können. Szenarioanalysen generieren ein mögliches Set an zukünftigen Ergebnissen von Verteilungen und tragen damit als eine mögliche Lösung zum Entscheidungsprozess bei (vgl. King und Wallace, 2012).

MCS halten schon länger Einzug in dem Forschungsgebiet der Elektromobilität. Es existiert eine große Auswahl an Arbeiten mit verschiedenen Anwendungsbereichen z. B. Faddel et al. (2017), Uhrig et al. (2014) oder Wang et al. (2018).

3.4 Aufbau der gemischt-ganzzahligen linearen Optimierung

Die im vorigen Abschnitt 3.2 beschriebenen Methoden finden nun eine konkrete Anwendung für die formulierten Fragestellungen der vorliegenden Arbeit. Es wird zunächst das Optimierungsmodell mit perfekter Information in den Vordergrund gestellt. Diese deterministische Optimierung dient zur Ermittlung der, unter den gegebenen Voraussetzungen, minimalen Ladekosten der E-Pkw. Dieses stellt den Benchmark dar, damit die Kosten ohne Unsicherheit und mit voller Information als Vergleich genutzt werden können. Das Modell bildet damit die Rahmenbedingungen der Fallstudie im Parkhaus näher ab (vgl. Kapitel 5). In dem Parkhaus nutzen verschiedene elektromobile Flotten eine gemeinsame Ladeinfrastruktur mit einer restriktiven Anschlussleistung.

3.4.1 Modellannahmen

Um den zugrundeliegenden Forschungsfragen aus Kapitel 1 gerecht zu werden, wird ein Zeithorizont von einem Tag mit 24 h und 15-minütigen Zeitschritten gewählt. Damit den formulierten Wahrscheinlichkeitsverteilungen Rechnung getragen werden kann, wird der eine Tag mehrmals mit einer MCS simuliert. Die Anzahl an Simulationen beträgt 150 und wurde anhand von Konvergenztests (siehe Anhang A) ermittelt. Dem Modell unterliegen die folgenden Annahmen:

- a) Es gibt eine perfekte Informationsvoraussicht im Benchmark Fall.
- b) E-Pkw können maximal an den Ladesäulen mit 3,7 kW oder 11 kW oder 22 kW laden, die Ladeleistung ist von der gewählten Parametrisierung abhängig.
- c) E-Pkw und Ladesäulen nutzen die gleiche Ladeleistung und entsprechenden Lademodi.
- d) Mögliche Lademodi der Ladesäulen sind Mode 1 oder Mode 2 (3,7 kW; 11 kW; 22 kW).
- e) Der Batteriezustand kann zwischen 0 % und 100 % liegen.
- f) Zeithorizont ist von 0:00 Uhr bis 24:00 Uhr eines Tages.
- g) Die zeitliche Auflösung beträgt 15 min Zeitschritte.
- h) Ein Auswahlalgorithmus stellt sicher, dass die Parkdauer länger als die Ladedauer ist (vgl. Abschnitt 5.3.1).
- i) Die Batterie lädt konstant, ohne Abfall der Leistung.
- j) Der zugeteilte Ladebedarf der E-Pkw muss erfüllt werden.
- k) Die angenommenen Ladeanfragen bzgl. der Energienachfrage der E-Pkw müssen erfüllt werden.
- l) Es gibt an jedem Parkplatz im Parkhaus eine Ladesäule.
- m) Es wird ein beliebiger Wochentag zwischen Montag und Freitag abgebildet.
- n) Die Batteriekapazität beträgt für alle E-Pkw 24 kWh.
- o) Der durchschnittliche Energieverbrauch liegt bei 20 kWh/ 100 km oder 0,2 kWh/ km.
- p) Die drei gemeinsam untersuchten Flotten haben eine gleiche Priorität.
- q) Eine Hälfte der Unternehmensflotte lädt vom Ankommen bis 24 Uhr, die andere ab 0:00 Uhr bis zur Abfahrt vom Parkhaus, welches eine zufällige Aufteilung ist.
- r) Es stehen zwei Stromquellen zum Laden zur Verfügung, einerseits Strom aus dem Netz und andererseits der erzeugte PV-Strom.
- s) Die Erzeugung des PV-Stromes wird mit Grenzkosten von Null angesetzt.
- t) Es werden nur positive EPEX SPOT-Preise betrachtet.

Die gesamte Nomenklatur für das MILP ist in Tabelle 3.1 angegeben.

Tabelle 3.1: Nomenklatur (MILP)**Entscheidungsvariablen**

x	Externe Ladeleistung vom Netz [kW]
q	Binärvariable bzgl. Annahme einer Ladeanfrage $\{0,1\}$
d	Gesamte E-Pkw Nachfrage der drei Flotten [kWh]
p	Ladeleistung [kW]

Deterministische Parameter

c_t	EPEX SPOT-Preis pro Zeitschritt t [ct/kWh]
a	Abweichungsstrafkosten Nachfrage, positives Balancing
b	Abweichungsstrafkosten Angebot, negatives Balancing
l	Annahmequote aller Ladeanfragen
g	Anzahl aller Ladeanfragen der E-Pkw der drei Flotten
h	Anzahl der Zeitschritte pro Stunde
v	E-Pkw Ladebedarf von jedem Fahrzeug aus allen drei E-Pkw Flotten [kWh]
PV	Erzeugte PV-Leistung [kW]
GW	Globale Anschlussleistung des Transformators [kW]
LW	Lokale Anschlussleistung von Ladesäulen und E-Pkw [kW]

Indizes

t	Index für Zeitschritte
i	Index für Anzahl an Ladeanfragen der E-Pkw der drei Flotten

3.4.2 Zielfunktion

In dieser Arbeit liegt der Fokus auf den Ladekosten der E-Pkw. Die Zielfunktion minimiert die Ausgaben für den nachgefragten Strom, der extern vom Netz zur Verfügung gestellt wird. Dieses dient der wirtschaftlichen Bewertung des Lademanagements. Die Kosten sind durch EPEX SPOT-Preise c_t in €/MWh gegeben und die Zielfunktion ist wie folgt formuliert:

$$\min_x C = \sum_t c_t \cdot x_t \quad (3.3)$$

Das Problem ist als eine gemischt-ganzzahlige lineare Optimierung formuliert.

Der erzeugte Strom von PV wird mit keinen Kosten angesetzt und somit werden die Grenzkosten ebenfalls mit Null bewertet. Bei der Optimierung wird durch die Annahme des kostenlosen PV-Stromes zunächst der erzeugte Strom von PV genutzt. Es findet somit eine Maximierung der Auslastung des erzeugten PV-Stromes statt. Bezogen auf den gesamten Optimierungszeitraum laden die E-Pkw somit bevorzugt mit

Strom von der lokalen PV-Anlage und erst als zweite Stromquelle wird sich des Netzes bedient. Gleichzeitig findet eine Optimierung für den zusätzlich benötigten Strom aus dem Netz statt (siehe Gleichung (3.3)). Dabei gilt die Annahme, dass der erzeugte PV-Strom nur für den Eigenverbrauch genutzt wird.

3.4.3 Nebenbedingungen

An erster Stelle steht die Einhaltung der gegebenen physischen Anschlussleistung, die im Parkhaus vorliegt und vorgegeben ist durch die maximale Leistung des Transformators. Eine Überschreitung der Grenze könnte die Sicherungen überlasten und dadurch zu einem kompletten Stromausfall für das Parkhaus führen. Dies wäre ein hohes Risiko für das Parkhaus, da somit nicht nur die Ladeprozesse der E-Pkw abgebrochen werden, sondern insbesondere das Lüftungs- und das Beleuchtungssystem zum Erliegen kommen würden. Die Leistungsgrenze wird je nach Modellvariation durch eine zusätzliche Erzeugung von PV erhöht. Weitere technische Parameter, die berücksichtigt werden müssen, sind zum einen die Einhaltung der Grenzen der Batteriekapazität. Diese kann weder unter 0 % liegen, noch kann die Batterie überladen werden, sondern das Maximum liegt bei 100 % der entsprechend gewählten Batteriekapazität von 24 kWh. Des Weiteren ist die Ladeleistung der Ladesäulen und der E-Pkw zu berücksichtigen. Es stehen verschiedene Lademodi (vgl. Abschnitt 2.4.3.1) für die Ladesäulen zur Verfügung. Entsprechend ändert sich die maximale Ladeleistung p der Ladesäule. Somit kann ein E-Pkw nur in den Leistungsgrenzen (0 kW und {3,7 kW; 11 kW; 22 kW}) der Ladesäule geladen werden.

Hinzukommt, dass die Summe der nachgefragten Energie aller E-Pkw identisch zu den geladenen Energien der Batterien sein muss. Dieses garantiert ebenfalls, dass angenommene Ladeanfragen auch komplett entsprechend des angefragten Ladebedarfs geladen werden.

Die Fahrzeuge stellen eine Energieanfrage an das Lademanagementsystem. Werden mit der Anfrage Nebenbedingungen verletzt, dann werden die entsprechenden Energieanfragen abgelehnt. Der Zustand tritt insbesondere ein, wenn die Lastgrenze der Anschlussleistung erreicht ist. Somit können Ladeanfragen im vornherein abgelehnt werden, wenn ersichtlich wird, dass keine erfolgreiche Bedienung möglich ist.

Die zuvor beschriebenen Restriktionen werden nun formalisiert und dem Optimierungsprogramm liegen entsprechend die folgenden Nebenbedingungen zugrunde:

$$\sum_t \frac{1}{h} \cdot p_{i,t} = d_i \quad \forall i \quad (3.4)$$

$$d_i = q_i \cdot v_i \quad \forall i \quad (3.5)$$

$$\sum_i q_i \geq l \cdot g \quad (3.6)$$

$$\sum_i p_{i,t} \leq GW \quad \forall t \quad (3.7)$$

$$p_{i,t} \leq LW_{i,t} \quad \forall i, t \quad (3.8)$$

$$p_{i,t} \geq 0 \quad \forall i, t \quad (3.9)$$

$$x_t \geq 0 \quad \forall t \quad (3.10)$$

$$x_t = \sum_i p_{i,t} - PV_t \quad \forall t \quad (3.11)$$

Die Nebenbedingung (3.4) stellt sicher, dass die Summe aller Ladeanfragen (welche durch die Ladeleistung $p_{i,t}$, für jeden Zeitschritt t und jedes Fahrzeug i abgebildet wird) der Energienachfrage d_i auch alle angenommenen Anfragen beinhaltet. Der Parameter h bildet die Anzahl der Zeitschritte pro Stunde ab, damit findet eine entsprechende Umrechnung von kW in kWh statt. Die Variable d_i wird durch die Binärvariable q_i und die dazugehörige Ladenergieanfrage v_i definiert, wie in der Gleichung (3.5) formalisiert. Damit es eine Möglichkeit gibt, nicht alle Anfragen anzunehmen, wurde eine mindest Erfolgsquote l eingeführt. Das Problem bleibt lösbar, falls alle Nebenbedingungen erfüllbar sind, insbesondere muss die Summe der Ladeleistungen immer unter der Trafoleistung bleiben. Somit ergibt sich die Binärvariable q_i auf Basis der festgesetzten Mindesterfolgsquote l und der Summe aller Anfragen g der einzelnen Fahrzeuge der drei Benutzergruppen, siehe Gleichung (3.6). Die Summe der Ladeleistung $p_{i,t}$ jedes Fahrzeuges i ist für jeden Zeitschritt t durch die Anschlussleistung GW des Transformators limitiert, welches durch die Nebenbedingung (3.7) abgebildet ist. Des Weiteren ist die Ladeleistung $p_{i,t}$ jedes Fahrzeuges i für jeden Zeitschritt t durch die lokale Ladeleistung $LW_{i,t}$ begrenzt, Gleichung (3.8). Zusätzliche Nebenbedingungen sind, dass die Variablen Ladeleistung $p_{i,t}$ und die extern benötigte Ladeleistung x_t positiv sind und somit keine negativen Werte annehmen können, Gleichung (3.9) bzw. (3.10). Die extern benötigte Ladeleistung x_t wird durch Gleichung (3.11) eingeführt und resultiert aus der

Differenz zwischen der Summe aller Ladeleistungen $p_{i,t}$ und dem erzeugten PV-Strom, PV , der für den Eigenverbrauch vorgesehen ist.

3.5 Aufbau der zweistufigen stochastischen Optimierung

Damit die zugrundegelegten Unsicherheiten, wie in den vorherigen Abschnitten 3.2 und 3.3 erläutert, Berücksichtigung finden, wird eine stochastische Problemformulierung herangezogen. Im Folgenden wird der genutzte Lösungsansatz der zweistufigen stochastischen Optimierung mit Anwendung der Latin Hypercube Sampling (LHS) basierten SAA Methode näher ausgeführt. Zunächst wird der Ansatz für einen stochastischen Parameter formuliert, nämlich die Unsicherheit in der erzeugten PV-Leistung. Dabei verändert sich das stochastische Problem bzgl. Entscheidungsvariablen und Nebenbedingungen so, dass diese zusätzlich von den SAA Szenarien abhängig sind, ansonsten aber unverändert bleiben. In einem weiteren Schritt wird ein zweiter stochastischer Parameter eingeführt, nämlich eine Unsicherheit in der Energienachfrage der Fahrzeugladeanfragen. Es ergeben sich drei verschiedene Ausprägungen, abhängig je nach Flotte. Diese Formulierung hat zur Auswirkung, dass die Entscheidungsvariablen der zweiten Stufe des stochastischen Problems Binärvariable enthalten, die nicht nur in der Zielfunktion abgebildet ist, sondern auch in den Nebenbedingungen, was die Komplexität des Problems deutlich erhöht und im Folgendem ausführlicher betrachtet wird. Neben der mathematischen Beschreibung des Modells wird ebenfalls die Bewertung der Unsicherheit aufgegriffen.

3.5.1 Modellannahmen

Die getroffenen Annahmen (b) – (t) vom MILP (vgl. Abschnitt 3.4.1) behalten ihre Gültigkeit, hinzu kommen die folgenden Annahmen:

- u) Es liegt nur noch teilweise perfekte Information vor.
- v) Unsicherheiten treten bei der Energienachfrage der E-Pkw auf.
- w) Die Vorhersage der PV-Stromerzeugung unterliegt Unsicherheiten.

Die gesamte Nomenklatur für das SMILP ist in Tabelle 3.2 angegeben. Sie enthält die definierten Variablen, Parameter und Indizes des Modells. Es sind zwei Gruppen von Variablen definiert. Diejenigen, die sich auf die erste Stufe beziehen, die der here-and-now Entscheidung entspricht und der andere Satz von Variablen, welcher Bezug

auf die Entscheidung der zweiten Stufe nimmt. Diese ähneln der Entscheidung der ersten Stufe, sie stellen jedoch die rekurse Entscheidung der zweiten Stufe dar. Daher wird neben der Indexierung mit dem SAA Szenario j , die hochgestellte Bezeichnung *scen* eingeführt.

Tabelle 3.2: Nomenklatur (SMILP)

Erste Stufe Entscheidungsvariablen	
x	Externe Ladeleistung vom Netz [kW]
q	Binärvariable bzgl. Annahme einer Ladeanfrage {0,1}
d	Gesamte E-Pkw Nachfrage der drei Flotten [kWh]
p	Ladeleistung [kW]
Zweite Stufe Entscheidungsvariablen	
x^{scen}	Externe Ladeleistung vom Netz, SAA Szenario [kW]
d^{scen}	Gesamte E-Pkw Nachfrage der drei Flotten, SAA Szenario [kWh]
p^{scen}	Ladeleistung, SAA Szenario [kW]
s	Binärvariable bzgl. Annahme einer Ladeanfrage im SAA Szenario {0,1}
e	Hilfsvariable für SAA Szenario
Deterministische Parameter	
c_t	EPEX SPOT-Preis pro Zeitschritt t [ct/kWh]
a	Abweichungsstrafkosten Nachfrage, positives Balancing
b	Abweichungsstrafkosten Angebot, negatives Balancing
f	Strafkosten für Nichterfüllung einer Ladeanfrage im SAA Szenario [ct]
l	Annahmequote aller Ladeanfragen
g	Anzahl aller Ladeanfragen der E-Pkw der drei Flotten
h	Anzahl der Zeitschritte pro Stunde
v	E-Pkw Ladebedarf [kWh]
PV	Erzeugte PV-Leistung [kW]
GW	Globale Anschlussleistung des Transformators [kW]
LW	Lokale Anschlussleistung von Ladesäulen und E-Pkw [kW]
N	Anzahl der Szenarios von SAA
Stochastische Parameter	
v^{scen}	E-Pkw Ladebedarf, SAA Szenario [kWh]
PV^{scen}	Erzeugte PV-Leistung, SAA Szenario [kW]
Indizes	
t	Index für Zeitschritte
i	Index für Anzahl an Ladeanfragen der E-Pkw der drei Flotten
j	Index für die Anzahl der Szenarios für SAA

Die Parameter sind in zwei Gruppen unterteilt. Die ersten, sogenannten deterministischen Parameter, umfassen die Systemzustandsinformation, wie die vorhergesagte PV-Stromerzeugung oder die geplante E-Pkw Nachfrage, jedes E-Pkw der drei untersuchten Flotten. Darüber hinaus werden Modellparameter wie Ladegrenzen lokaler

und globaler Art zur Verfügung gestellt. Die zweite Parametergruppe, die stochastischen Parameter, sind analog zu den deterministischen Zustandsparametern. Sie stellen jedoch die Systemstufe der zweiten Stufe dar und haben daher die hochgestellte Bezeichnung *scen*, da sie innerhalb der rekursen Entscheidung unbekannt sind.

3.5.2 Zielfunktion

3.5.2.1 Zweistufige stochastische Optimierung zur Berücksichtigung von PV Unsicherheiten

Die erste Unsicherheit, die Betrachtung in dem stochastischen Programm findet, ist die fluktuierende Stromerzeugung von PV. Um die Unsicherheit in der Problemformulierung zu berücksichtigen, wird die zweistufige stochastische Optimierung (vgl. Abschnitt 3.3) angewendet. Die Zielfunktion besteht damit aus zwei Termen, dargestellt in Gleichung (3.12). In dem ersten Teil der Minimierungsfunktion findet die here-and-now Entscheidung statt und der benötigte Strom x_t wird entsprechend der EPEX SPOT-Preise c_t eingeplant. Als zweiter Teil fließt in die Zielfunktion der Erwartungswert E der rekursen Entscheidungsvariablen ein.

$$\min_x \sum_t c_t \cdot x_t + E_\omega Q(x, \omega) \quad (3.12)$$

Der zweite Ausdruck ist der rekurse Term. Q stellt dabei die Rekursfunktion dar. Darin werden die rekursen Kosten der stochastischen Variable minimiert. Die rekurse Entscheidungsvariable ist die extern benötigte Energiemenge aus dem Netz x_t . Der Erwartungswert der Kosten durch die unsichere PV Einspeisung kann durch eine repräsentative Stichprobe (,sample average‘) $q_N(x)$ wie folgt

$$q_N(x) = \frac{1}{N} \sum_{j=1}^N Q(x, \omega^j) \quad (3.13)$$

angenommen werden. Der Vektor ω^j steht für ein mögliches Szenarios des gesamten Wahrscheinlichkeitsraumes, also aller Beobachtungen der stochastischen Variable, mit den Szenarien $j = 1, \dots, N$, die mit einer gleichverteilten Wahrscheinlichkeit p_j (Gleichung (3.14)) dahergehen (vgl. Verweij et al., 2003). Dieses Vorgehen bezeichnet die SAA Methode (siehe Abschnitt 3.2.2.2).

$$p_j = \frac{1}{N} \quad (3.14)$$

Für die Szenariogenerierung stehen verschiedene Auswahlverfahren zur Verfügung. Die explizite Beschreibung der PV-Modellierung und die gewählten Modellvarianten sind im nächsten Kapitel 4 zu finden.

$$\min_x \sum_t (c_t \cdot x_t) + \frac{1}{N} \sum_{j=1}^N Q(x, \omega^j) \quad (3.15)$$

Die Formulierung (3.15) entspricht einem zweistufigen stochastischen MILP und wird daher in der Arbeit als SMILP bezeichnet. Die generische Zielfunktion (3.15) unterliegt für die erste Stufe den gleichen Nebenbedingungen ((3.4) - (3.11)) wie im MILP, hinzukommen aber für den rekursiven zweiten Schritt weitere Nebenbedingungen. Diese sind von dem SAA Szenario abhängig und werden für den zweiten Anwendungsfall eines SMILP (vgl. Abschnitt 3.5.2.2 bzw. Abschnitt 3.5.3 für die Nebenbedingungen) näher beschrieben. Dass sich die Nebenbedingungen durch die Unsicherheit der erzeugten PV-Leistung nicht ändern, liegt an der folgenden getroffenen Annahme. Zunächst werden alle Ladeanfragen ohne PV und entsprechend des unkontrollierenden Ladens eingeplant. Somit unterliegen die Ladeanfragen hauptsächlich sowohl der lokalen als auch der globalen Anschlussleistung. Danach wird davon ausgegangen, dass genau 90 % der angenommenen Ladeanfragen für das MILP genutzt werden und diese immer mit dem Transformator abgedeckt werden können. Die PV-Leistung wird demnach als zusätzliche Energiequelle zum Transformator angesehen, so dass Schwankungen von der PV-Stromquelle nicht die Ladeanfragen betreffen, sondern diese sich nur im Preis beim extern benötigten Strom widerspiegeln. Die Ladeanfragen werden wie geplant durchgeführt und nicht verändert, nur der genutzte Strom für den Ladeprozess könnte sich durch die Vorhersageungenauigkeiten der PV-Stromerzeugung ändern. Weitere Ausführungen zu diesem Thema befinden sich in der Veröffentlichung Seddig et al. (2017) und werden in dieser Arbeit nicht weiter erläutert, da diese für die Arbeit nicht relevant sind, sondern nur die Erweiterungen, die im folgenden Abschnitt dargestellt werden.

3.5.2.2 Zweistufige stochastische Optimierung von PV und Flottenenergienachfrage unter Unsicherheit

Dieser Arbeit liegen mehrere Fragestellungen zu Grunde. Die Auswirkungen von Unsicherheiten sind, wie schon im vorherigen Abschnitt ausgeführt, eine davon. Bei der PV-Einspeisung und der Energienachfrage der E-Pkw werden nun die Unsicherheiten

berücksichtigt¹. Beide Komponenten besitzen eine stochastische Charakteristik, von daher soll die dynamische Interaktion beider Faktoren betrachtet werden. Damit werden u. a. die Effekte von Prognosen spezifischer untersucht. Entsprechend wird erneut das Problem als zweistufige stochastische Optimierung formuliert, jedoch finden Anpassungen statt, um auf die zweite stochastische Variable, die unsichere Energienachfrage der E-Pkw, zu reagieren.

Der Hauptunterschied zur stochastischen Charakteristik der Energienachfrage der E-Pkw Ladeanfragen gegenüber der erzeugten PV-Leistung ist, dass diese nicht nur Auswirkungen auf die Zielfunktion hat. Die Zielfunktion der Minimierung der gesamten externen Ladekosten bleibt weiterhin bestehen. Jedoch hat die Unsicherheit in der benötigten Energiemenge ebenfalls einen Effekt auf die verschiedenen hinterlegten Nebenbedingungen. Durch die Veränderung der Energienachfrage müssen bereits zugesprochene Ladefenster neu zugewiesen werden. Die vorher angenommenen lokalen wie globalen Anschlussleistungsbegrenzungen müssen erneut eingehalten werden. In Abhängigkeit wie hoch die Auslastung des Parkhauses und der Ladeinfrastruktur schon ist, führt dies schnell zu den Grenzen der Anschlussleistungen. Insbesondere wird es problematisch, wenn weiterhin die Annahmequote der gleichen Ladeanfragen gewährleistet werden soll.

Die Modellierung der Unsicherheit der Energienachfrage von E-Pkw ist im Kapitel 5.3.2 detailliert beschrieben.

Die Zielfunktion des SMILP und die dazugehörigen Nebenbedingungen werden an die veränderte Ausgangssituation angepasst. Damit die Energienachfrage der E-Pkw vollständig abgedeckt ist, werden entsprechende Korrekturmaßnahmen vorgenommen, was zu Abweichungskosten führt. Der rekursive Term plant entsprechend die zu erwartenden Abweichungskosten ein, unter der Bedingung, dass die Ladekosten minimal werden und der erzeugte PV-Strom maximal genutzt werden kann zum Laden. Somit wird zunächst bei der ersten Stufe der here-and-now Entscheidung versucht, möglichst kostenminimal die Ladevorgänge einzuplanen, damit bei der zweiten Stufe der Entscheidung die zu erwartenden Abweichungskosten ebenfalls minimal berücksichtigt werden können. Es wird dabei angenommen, dass die Möglichkeit der Realisierung über den Tag hin sichergestellt wird. Die zweite Stufe bezieht somit die Abweichungen der geplanten und möglichen Realisierungen der E-Pkw Energiemenge sowie mögliche Ergebnisse für die PV-Stromerzeugung ein.

¹ Diese Inhalte beruhen teilweise auf der Veröffentlichung von Seddig et al. (2019b).

Dabei werden die gleichen Abweichungskosten für den rekursen Term, wie für die nachträgliche Realisierung und dazugehörige Bewertung des Tages angesetzt, damit eine Vergleichbarkeit hergestellt ist. In diesem Fall wird angenommen, dass der Tag der Realisierung mit einem Faktor a für ein Nachfrageüberschuss (oder Angebotsdefizit) und einem Faktor b für ein Nachfragedefizit (bzw. Angebotüberschuss) für das entsprechend erforderliche Balancing bewertet werden. Die Zielfunktion wird um einen zusätzlichen Term erweitert, der einen Bestrafungsterm darstellt, falls eine Lade- nachfrage doch nicht erfüllt werden kann und ist wie folgt formuliert:

$$\min_x C = \sum_t (c_t \cdot x_t) + \frac{1}{N} \sum_j (\sum_t (a \cdot c_t \cdot \text{pos}(x_t^{\text{scen}} - x_t) + b \cdot c_t \cdot \text{neg}(x_t^{\text{scen}} - x_t)) + \sum_i s_{i,j} \cdot f) \quad (3.16)$$

Für den rekursen Term wird wieder die SAA Methode angewendet, um von einer Realisierung mehrere Szenarien zu generieren, die die zu erwartenden abweichenden Energiemengen entsprechend ihres Eintretens einplanen. Dabei findet ebenfalls das LHS statt. Die Anzahl der benötigten Szenarien innerhalb der SAA Methode wurde mit $N = 125$ angenommen (Konvergenztests sind im Anhang A zu finden). Die stochastischen Parameter (unsichere PV-Stromerzeugung, als auch für jede Flotte eine unterschiedliche unsichere Energienachfrage) werden aus einer gemeinsamen Verteilung innerhalb der SAA Methode gezogen (siehe Abschnitt 3.5.2.3). Somit hat es den Vorteil, dass es nur ein Prozess ist. Der Bestrafungsterm ist notwendig, um die Annahmequoten zu regulieren bzw. eine Vergleichbarkeit zwischen den Modellvariationen herzustellen.

3.5.2.3 Modellierung der stochastischen Entscheidungsvariablen

Der stochastische Zustand der Entscheidungsvariable des extern benötigten Stromes x_t^{scen} vom Netz wird durch verschiedene stochastische Zustandsparameter sowie Entscheidungsvariablen beeinflusst, insbesondere von der unsicheren Energienachfrage von jeder der drei E-Pkw Flotten v^{scen} als auch von der unsicheren PV-Stromerzeugung PV^{scen} . Somit wird eine gemeinsame Verteilung für die vier multivariaten Zufallsvariablen erstellt und ein gemeinsames Zufallsziehen aus eben dieser Verteilung durchgeführt. Dieser Vorgang wird über Funktionen der Python Bibliothek `chaospy` modelliert. Eine Eigenschaft von der Bibliothek `chaospy` ist insbesondere die Konstruktion von abhängigen, multivariaten Zufallsvariablen. Das bedeutet, dass eine Verteilung die Abhängigkeiten von anderen Verteilungen abbilden kann. Bei der Erstellung der multivariaten PDF wird die Rosenblatt Transformation genutzt, um die

bedingte Zerlegung der Verteilung konstruieren zu können (vgl. Feinberg und Petter, 2015).

3.5.3 Nebenbedingungen

Für den zweiten Schritt des rekursen Entscheidungsproblems, indem die vier stochastischen Parameter berücksichtigt werden, müssen für die Szenariogenerierung die Nebenbedingungen erweitert werden. Die bereits formulierten Nebenbedingungen (3.4) - (3.11) finden ebenfalls Anwendung, müssen aber angepasst werden mit neuen Variablen sowie Parametern bzgl. der veränderten Energienachfrage als auch der veränderlichen PV-Stromerzeugung. Die somit notwendigen Nebenbedingungen für die zweite Stufe des stochastischen Problems sind analog zu den Nebenbedingungen der ersten Stufe und implizieren damit die gleichen Restriktionen und getroffenen Annahmen. Der Hauptunterschied ist jedoch, dass die Nebenbedingungen der zweiten Stufe abhängig vom SAA Szenario sind und demnach der Index j eingeführt wird. Daraus ergeben sich für das rekurse Entscheidungsproblem die folgenden Nebenbedingungen (3.17) – (3.23):

Es gibt wieder eine Nebenbedingung (Gleichung (3.17)), die sicherstellt, dass die Summe aller Ladungen $p_{i,j,t}^{scen}$ und einer neu eingeführten Hilfsvariablen, dem Fehlerterm $e_{i,j}$, der Nachfrage aller angenommen Ladeanfragen $d_{i,j}^{scen}$ entspricht. Der Parameter h stellt wieder die Anzahl der Zeitschritte pro Stunde für die Umrechnung der Einheiten von kW in kWh dar.

$$\sum_t \frac{1}{h} \cdot p_{i,j,t}^{scen} + e_{i,j} = d_{i,j}^{scen} \quad \forall i, j \quad (3.17)$$

Die nächste Nebenbedingung (3.18) beinhaltet die zwei zusätzlich eingeführten Entscheidungsvariablen der zweiten Stufe, damit die Szenariogenerierung innerhalb der SAA Methode umgesetzt werden kann. Der Fehlerterm $e_{i,j}$ gibt den Wert der ungültigen Anfragen innerhalb der Szenarios der SAA Methode an. Dafür ist eine Indikatorvariable eingeführt worden, die als Binärvariable $s_{i,j}$ hinterlegt ist und bei der Szenariogenerierung der SAA Methode für die Energienachfrage die Annahmequote erfasst. Die Hilfsvariable $e_{i,j}$ bekommt einen entsprechenden positiven Wert oder Null vom Solver zugewiesen. Die Binärvariable $s_{i,j}$ wird genau dann Null gesetzt, wenn alle Ladeanfragen eines SAA Szenarios bedient werden konnten. Falls die Ladeanfragen nicht erfüllbar sind, weil beispielsweise andere Nebenbedingungen nicht eingehalten werden können, wird die Binärvariable auf eins gesetzt (vgl. Gleichung (3.18)).

$$e_{i,j} \leq s_{i,j} \cdot v_{i,j}^{scen} \quad \forall i, j \quad (3.18)$$

Die Gleichung (3.19) beschreibt die Nebenbedingung, dass alle angenommenen Anfragen q_i aus der ersten Stufe ebenfalls für die zweite Stufe mit entsprechendem neuen Ladebedarf $v_{i,j}^{scen}$ eingeplant werden, abgebildet durch die Variable $d_{i,j}^{scen}$, für den gesamten Bedarf der drei E-Pkw Flotten.

$$d_{i,j}^{scen} = q_i \cdot v_{i,j}^{scen} \quad \forall i, j \quad (3.19)$$

Die Transformerkapazität GW besteht weiterhin als Limitierung für die Gesamtheit der Ladevorgänge der E-Pkw, formalisiert in der Gleichung (3.20):

$$\sum_i p_{i,j,t}^{scen} \leq GW \quad \forall j, t \quad (3.20)$$

Die nächste Nebenbedingung, durch Gleichung (3.21) abgebildet, beinhaltet ebenfalls die technischen Restriktionen, dieses Mal sowohl von der Ladesäule als auch vom E-Pkw. Damit wird die Ladeleistung entsprechend dem lokalen Limit $LW_{i,t}$ reguliert:

$$p_{i,j,t}^{scen} \leq LW_{i,t} \quad \forall i, j, t \quad (3.21)$$

Die extern benötigte Ladeleistung vom Netz $x_{j,t}^{scen}$ wird durch die Gleichung (3.22) beschrieben und bildet sich aus der Differenz der gesamten Ladeleistung $p_{i,j,t}^{scen}$ und durch die vom PV-Strom zur Verfügung gestellten Leistung $PV_{j,t}^{scen}$.

$$x_{j,t}^{scen} = \sum_i p_{i,j,t}^{scen} - PV_{j,t}^{scen} \quad \forall j, t \quad (3.22)$$

Abschließend sind noch die Nichtnegativitätsbedingungen (Gleichung (3.23)–(3.25)) der folgenden Variablen zu nennen, damit diese nur positive Werte annehmen können:

$$p_{i,j,t}^{scen} \geq 0 \quad \forall i, j, t \quad (3.23)$$

$$x_{j,t}^{scen} \geq 0 \quad \forall j, t \quad (3.24)$$

$$e_{i,j} \geq 0 \quad \forall i, j \quad (3.25)$$

Durch die veränderliche Energienachfrage im rekursiven Problem ist es nicht mehr gewährleistet, dass alle vorher fest eingeplanten Ladeanfragen und die entsprechende vorgegebene Annahmquote in jedem einzelnen Szenario der SAA Methode erfüllt

sind. Dafür wurden insbesondere der Bestrafungsterm und die zusätzlichen Nebenbedingungen (3.18) und (3.25) eingeführt.

3.5.4 Modellbewertung

3.5.4.1 Bewertung des stochastischen Ansatzes

Zur Beantwortung von Problemstellungen unter Unsicherheit können verschiedene Vorgehensweisen herangezogen werden, um die Realität entsprechend vereinfacht abzubilden. Eine Frage, die auftritt, wenn stochastische Programmierung angewendet wird, ist, inwieweit das Ergebnis der ausgewählten Vorgehensweise der optimalen Lösung nahekommt. Zwei Konzepte können für die theoretische Antwort herangezogen werden. Zur Bewertung des stochastischen Problems werden zwei Gütemaße angewendet. Zum einen ist das der Expected Value of Perfect Information (EVPI) und zum andern der Value of Stochastic Solution (VSS) (vgl. Birge und Louveaux, 2011).

$$EVPI = RP - WS \qquad (3.26)$$

Der EVPI, dargestellt in der Formel (3.26), gibt den Maximalbetrag an, den ein Entscheidungsträger bereit ist zu zahlen, wenn er dafür die vollständige Information der zukünftigen Ereignisse erhält. Der EVPI bildet die Differenz zwischen dem Zielfunktionswert der wait-and-see, WS , Entscheidung und des Zielfunktionswertes der here-and-now Entscheidung mit rekursivem Problem, RP , ab. Der EVPI ist stets positiv und beschreibt damit den durch Unsicherheit auftretenden Verlust (vgl. Birge und Louveaux, 2011).

Das zweite Gütemaß der VSS ist wie folgt definiert:

$$VSS = EEV - RP \qquad (3.27)$$

Der VSS stellt die Kosten für die Nichtberücksichtigung von möglichen Unsicherheiten dar. Der EEV (Expected result of the expected value problem, also das erwartete Ergebnis des Erwartungswertansatzes) beschreibt, wie gut bzw. schlecht die Handlungsempfehlung für das Eintreten eines jeden möglichen Zustandes ist. Der VSS ist also ein Maß, der den Erwartungswertansatz gegenüber dem Wert des stochastischen Programms vergleicht (vgl. Birge und Louveaux, 2011).

Der EVPI stellt somit ein Maß dafür dar, die Zukunft mit Sicherheit zu kennen. Der VSS hingegen schätzt den Wert des Wissens unter Benutzung des Erwartungswertansatzes der zukünftigen Ergebnisse. Beide Werte sind immer positiv.

Zur Bestimmung der Güte der jeweiligen Lösungen in der vorliegenden Arbeit soll nicht nur der EVPI genutzt werden, sondern auch weitere Abweichungskosten (vgl. nächster Abschnitt 3.5.4.2) betrachtet werden. Hiermit können verschiedene untersuchte Modellvariationen miteinander verglichen werden, die näher im Abschnitt 5.6 spezifiziert sind.

3.5.4.2 Bewertung mit Abweichungskosten

Nach der Durchführung der zweistufigen stochastischen Optimierung ist der Zielfunktionswert RP (vgl. Abschnitt 3.5.4.1) der here-and-now Entscheidung mit rekursivem Problem ermittelt worden. Der $EVPI$ kann als Gütemaß für eine Beurteilung des stochastischen Ansatzes herangezogen werden. In der Fallstudie werden mehrere Methoden miteinander verglichen (vgl. Abschnitt 5.6), so dass ein weiterer Kostenterm eingeführt wird.

Das mit Unsicherheit behaftete Modell wird anschließend für den Ansatz mit der Day-Ahead-Vorhersage, der ersten Stufe des SMILP Ansatzes sowie des Referenzfalls des unkontrollierten Ladens nach der Einplanungsphase für den benötigten Strom, noch mit Abweichungskosten für den real eingetretenen Fall eines Tages bewertet. Dafür wird das folgende MILP, mit dem gleichbleibenden Minimierungsziel der Ladekosten, durchgeführt:

$$\min_x \sum_t \left(a \cdot c_t \cdot \text{pos}(x_t^{\text{real}} - x_t) + b \cdot c_t \cdot \text{neg}(x_t^{\text{real}} - x_t) \right) + \sum_i s_i \cdot f \quad (3.28)$$

Die am Vortag eingeplanten Lademengen x_t^{real} und getätigten Kosten werden als Input genutzt. Mit dem durchgeführten MILP sollen die aufgetretenen Abweichungen kostenminimal für die Realisierung des Tages eingeplant werden. Demnach wird der Strom entsprechend der angesetzten Preise gekauft und auch verkauft. Das MILP ist analog mit den Nebenbedingungen (3.17) – (3.25) umgesetzt, jedoch ohne die Abhängigkeit des SAA Szenarios und dem Index j . Durch die erneute Optimierung können die Ladevorgänge (teilweise) neu eingeplant werden, solange die Kosten für den extern benötigten Strom dadurch minimal werden.

Abschließend kann noch gesagt werden, dass die Güte der berechneten Lösung nicht als alleiniges Kriterium relevant ist, sondern auch die Komplexität und der dazugehörige Rechenaufwand des Problems zu beachten ist (vgl. Zimmermann, 2008).

4 Stand der Wissenschaft

Um einen entsprechenden Überblick über den aktuellen Wissensstand zu erhalten und die vorliegende Ausführung von bestehenden Arbeiten abzugrenzen, wird in diesem Kapitel ein Einblick in die vorhandene Literatur gegeben. Hierzu sind die Schwerpunkte erst allgemeiner gefasst, mit Smart Grids und Energiemanagement (Abschnitt 4.1), dann spezifischer auf E-Pkw, insbesondere der Kontext mit E-Pkw Aggregatoren (Abschnitt 4.2), abschließend noch konkreter mit Literatur zu dem Anwendungsfall E-Pkw in Parkhäusern (Abschnitt 4.3). In dem Unterkapitel 4.4 wird sowohl ein methodischer Überblick zu Unsicherheiten als auch zur stochastischen Optimierung eingefügt, um gleichfalls die Modellierungsseite komplett abzudecken. Daraus schlussfolgernd ist die Forschungslücke und das zu entwickelnde Modell mit einer klaren Abgrenzung zu bisherigen Arbeiten im letzten Abschnitt 4.5 abgeleitet worden.

4.1 Smart Grids und Energiemanagement

Gäbe es im Jahr 2020 eine Million Elektrofahrzeuge, dann beläuft sich das theoretische mögliche Speicherpotenzial bei einer Annahme von 20 kWh pro E-Pkw auf 20 GWh, welches theoretisch mehr als 23 h zur Verfügung steht. Mit der Hypothese des stetigen Wachstums und 6 Millionen Fahrzeugen im Jahr 2030, werden Größenordnungen von 120 GWh erreicht. Die Tendenz ist steigend, da die Batteriekapazitäten derzeit größer werden. Diese Entwicklung belegt beispielsweise gerade Tesla mit dem Model 3 (vgl. Köllner, 2017). Dies führt dazu, dass im Themenkreis der Smart Grids die E-Pkw und das Energiemanagement immer häufiger mit aufgegriffen werden. Es gibt eine zahlreiche Anzahl an Veröffentlichungen und Reviews davon, welche verschiedene Aspekte abhandeln. Gerade durch die zusätzliche Last im elektrischen Verteilnetz werden viele technische Untersuchungen veranlasst, damit Effekte, wie Spannungsschwankungen, Transformerverlastungen nicht die Sicherheit oder Zuverlässigkeit des Netzes beeinflussen (vgl. García-Villalobos et al., 2014).

Ein aktueller Literaturreview von Weitzel und Glock (2018) hebt den steigenden Trend des Energiemanagements hervor. Sie zeigen die verschiedenen Ansätze für ein Energiemanagement im Kontext für stationäre, elektrische Energiespeichersysteme, inklusive von E-Pkw auf. Dabei wurden insbesondere Gesichtspunkte der Zielsetzung

und die Systemgrenzen, genauso die mathematische Formulierung und die Optimierungstechnik näher untersucht. Jede dieser Komponenten wurde noch tiefer aufgegliedert und mit weiteren Schlagwörtern belegt. Problemformulierungen sind entweder deterministischer oder stochastischer Natur. Für die Lösung werden bei den Optimierungsverfahren entweder exakte Lösungsansätze, Heuristiken oder Meta-Heuristiken gewählt. Bei dem exakten Lösungsansatz sind die Algorithmen in der Regel in der Lage, die optimale Lösung unter den gegebenen Annahmen zu finden. Es werden LP, MIP oder MILP unter Verwendung von Solvern, welche verschiedene Lösungsverfahren nutzen, angewendet. Dynamische Programmierung wird ebenfalls genutzt, um exakte Ergebnisse zu erzielen. Heuristiken decken eine breite Spannweite von Algorithmen ab, die beispielsweise eigene entwickelte Logiken oder bekannte Methoden, wie greedy-Heuristik und brute-force verfolgen. Der Zeithorizont ist ebenfalls verschieden. Zur Anwendung kommen Day-Ahead Scheduling, Intraday Scheduling sowie die Kombination von beiden. Die zeitliche Auflösung, kann von einer Stunde, mehreren Stunden oder Tagen variieren. Vorhersagen mit entsprechenden Prognosemodellen und korrespondierenden Prognosefehlern werden bei manchen Arbeiten schon mitberücksichtigt.

Optimierungen haben verschiedene Zielformulierungen. Im Mittelpunkt können wirtschaftliche, technische Faktoren oder Umweltaspekte stehen. Die Interaktion mit EE innerhalb eines Smart Grids findet sich bspw. in der Arbeit von Liu et al. (2015) oder Gottwalt et al. (2013) wieder. Die Auswirkungen der Ladevorgänge der E-Pkw auf das Energiesystem wurde von verschiedenen Autoren untersucht. Dallinger et al. (2013) zeigen sowohl für Deutschland als auch Kalifornien eine mögliche Integration von E-Pkw und deren Auswirkungen auf das jeweilige Energiesystem auf. Darin findet ebenfalls eine Berücksichtigung der Integration von EE statt.

Eine Vielzahl von Autoren hat sich inzwischen mit Elektromobilität beschäftigt. Dabei sind verschiedene Vertiefungen und Auslegungen hervorgetreten. Ein Überblick über die verschiedenen Gesichtspunkte, wie E-Pkw in die Wissenschaft einbezogen werden, findet sich in dem Review Paper von Richardson (2013) wieder. Die Nutzung von EE zum Laden von E-Pkw wird in vielen wissenschaftlichen Arbeiten thematisiert (vgl. Schuller et al., 2015). Bei der Lastverschiebung können Aspekte so gewählt werden, dass sie einen unkontrollierten oder kontrollierten sowie dabei einen zentralen vs. dezentralen Ansatz verfolgen.

4.2 Flexible Lasten von E-Pkw

Das Ladeverhalten von E-Pkw wird hauptsächlich für LVP untersucht. Somit hat die Ladekoordinierung von E-Pkw in den letzten Jahren vermehrt Einzug in die wissenschaftlichen Arbeiten erhalten. Die Übersichtsarbeit von Yang et al. (2015) zeigt die verschiedenen Ziele bei der Ladekoordinierung der E-Pkw auf. Viele Ansätze untersuchen die wirtschaftlichen Auswirkungen in unterschiedlichen Marktumgebungen (vgl. Flath et al., 2013). Die wirtschaftlichen Zielgrößen reichen von der Minimierung der Ladekosten, der Betriebskosten oder der Reduktion von elektrischen Erzeugungskosten bis hin zur Steigerung des Gewinns (vgl. Liu et al., 2015). Ein weiteres Thema sind die flexiblen Lasten der E-Pkw, welche zur Netzstabilisierung (vgl. Hu et al., 2014) oder ebenfalls zur Versorgungssicherheit beitragen können (vgl. Bozic und Pantos, 2015). Andere Arbeiten nutzen wiederum die flexiblen Lasten, um damit das Potenzial zur Integration von EE zu bewerten (vgl. Saber und Venayagamoorthy, 2012; Rahbari et al., 2017; Schuller et al., 2015; Li et al., 2012), die Erzeugung der EE maximal auszunutzen (vgl. Schuller und Hoeffler, 2014), andere Effizienz Themen bzgl. EE abzuhandeln oder die Emissionen des Ladens zu reduzieren (vgl. Shaaban und El-Saadany, 2014). Die Teilnahme an DSM- bzw. DR-Programmen wurde schon im vorherigen Abschnitt 4.1 aufgezeigt. Um die Effekte durch E-Pkw Ladekoordinierung zu bündeln, werden vermehrt die Konzepte von E-Pkw Aggregatoren eingeführt (vgl. Perez-Diaz et al., 2018). Dabei liegt der Fokus oftmals auf dem wirtschaftlichen Hintergrund und es gab schon Analysen bzgl. der Teilnahme an Day-Ahead und real-time Märkten (vgl. Wei und Guan, 2014; Ensslen et al., 2017). Die Arbeit von Wei und Guan (2014) gelangte dabei zu der Erkenntnis, dass die Teilnahme an beiden Märkten, verbunden mit der Koordinierung eines Aggregators am wirtschaftlich vorteilhaftesten ist.

4.3 E-Pkw in Parkhäusern

Parkhäuser können im Kontext der Elektromobilität u. a. als lokaler E-Pkw Aggregator angesehen werden. Verschiedene Parkhausstudien im Zusammenhang mit der Integration von E-Pkw existieren schon für Deutschland. Brandt et al. (2017) untersuchen die Möglichkeit, ein Geschäftsmodell für elektromobile Flotten in einem Parkhaus zu erstellen. Ein Ergebnis der Fallstudie ist, dass die Nutzung des Parkhauses als Aggregator zur Teilnahme am Regelenergiemarkt im Moment noch nicht wirtschaftlich ist. Des Weiteren haben Braam et al. (2016) ein MILP angewendet, um das

LVP von 13 E-Pkw in einem Parkhaus zu bewerten. Dabei unterliegt ihr System mehreren Restriktionen aus der Umwelt. Diese beinhalten u. a. die Ladeinfrastruktur oder das Verteilnetz. Hinzu kommt die Annahme der zusätzlichen Stromerzeugung aus PV. Grenzen der Arbeit von Braam et al. (2016) liegen z. B. darin, dass von festen Fahrprofilen ausgegangen wird oder Unsicherheiten in keinerlei Hinsicht Berücksichtigung finden.

Die Arbeiten, die sich mit Parkhäusern beschäftigen, betrachten i. d. R. nur eine Flotte von parkenden E-Pkw. Der Arbeitsplatz (vgl. Tulpule et al., 2013) wird häufig als Ladeort untersucht. Werden beispielsweise Flottenfahrzeuge untersucht, die über Nacht laden (vgl. Detzler, 2017), dann geschieht das nicht im Kontext eines Parkhauses. Es fehlt die Betrachtungsweise des synergetischen Ladens von verschiedenen Flotten von E-Pkw und damit einer höheren Auslastung des Parkhauses.

In Detzler et al. (2015) basiert die Optimierung auf einem evolutionären Algorithmus, um das Lastverschiebeverhalten einer Flotte zu untersuchen. Eine lokale PV-Stromerzeugung wird ebenfalls berücksichtigt. Neben der Abhandlung von Detzler et al. (2015) beschäftigen sich immer mehr Arbeiten mit den Lademöglichkeiten von E-Pkw in Parkhäusern unter Berücksichtigung der Integration von EE. Weitere Publikationen im Kontext des E-Pkw Scheduling, der Integration von PV und einer Parkhausinfrastruktur sind z. B. Honarmand et al. (2014); Figueiredo et al. (2017); Tulpule et al. (2013); Aghajani und Kalantar (2017); Neumann et al. (2012) oder Nunes et al. (2016). Dabei unterscheiden sich die Forschungsfragen (z. B. kostenminimales Laden, maximales Ausnutzen der EE Erzeugung) und die an einer Fallstudie getesteten Instanzen. Jedoch haben all diese Arbeiten die Gemeinsamkeit, dass diese weder die stochastische Natur der E-Pkw, insbesondere der Fahrprofile, noch die volatile Erzeugung von EE berücksichtigen. Demnach ist die Bewertung von Unsicherheiten in der aktuellen Literatur zu E-Pkw Ladesteuerungsmechanismen unterrepräsentiert.

4.4 Stochastische Programmierung und Modellierung von Unsicherheiten

Dieser Abschnitt zeigt Arbeiten zu der Modellierung von Unsicherheiten und der stochastischen Optimierung auch mit anderen Anwendungsfällen außerhalb der Energiesystemanalyse auf. Unsicherheiten werden bisher in wenigen Arbeiten im Kontext von Elektromobilität abgehandelt (vgl. Gottwalt et al., 2016). Unter der Begrifflich-

keit der Unsicherheiten oder auch Stochastik werden je nach Autor verschiedene Konzepte verstanden. Hinzukommt, dass je nach Modell Unsicherheiten anders berücksichtigt und definiert werden. Dabei unterscheiden sich die Methoden für die Unsicherheitsmodellierung in Bezug auf die Genauigkeit und Komplexität (vgl. Weitzel und Glock, 2018). Einige Autoren nutzen beispielsweise Wahrscheinlichkeitsverteilungen, wie Poisson- oder Weibullverteilungen als Annahmen für die Modellierung der E-Pkw und schreiben von stochastischer Modellierung (z. B. Uhrig et al. (2015)). Wiederum andere decken die Unsicherheiten durch Szenarioanalyse (z. B. Zakariazadeh et al. (2014)) ab. In nur wenigen Veröffentlichungen wird stochastische Programmierung so wie in der vorliegenden Arbeit angewendet.

Die Ausführungen von Soroudi und Amraee (2013) geben einen guten Überblick über Entscheidungsprozesse unter Unsicherheit in Energiesystemen. Sie zeigen verschiedene Ansätze auf, die je nach Anwendungsfall genutzt werden können und diskutieren über die Vor- und Nachteile. Ebenfalls wird eine Klassifizierung unsicherer Parameter hinsichtlich technischer und ökonomischer Ziele vorgenommen. Zu den Ansätzen stochastischer Modellierung zählen z. B. robuste Optimierung, stochastische Dynamische Programmierung, MCS oder Chance Constraint.

Momber et al. (2015) haben eine Methode entwickelt, die den Gewinn des E-Pkw Aggregator unter Unsicherheit maximiert. Dafür wird ein zweistufig stochastisches lineares Optimierproblem entwickelt, welches das optimale E-Pkw Scheduling unter Unsicherheit bei der Flottenmobilität und Marktpreisen findet. Dabei wird nur eine Flotte berücksichtigt, es gibt keine Stromerzeugung aus EE, technische Restriktionen werden ebenfalls nicht integriert und das Modell besitzt keine Binärvariablen.

Für die Lösung von stochastischen Optimierungsproblemen wird die SAA Methode immer häufiger genutzt und schon in verschiedenen Bereichen angewendet (z. B. Emelogu et al. (2016); Long et al. (2012)). Häufig wird die MCS in Verbindung mit der SAA Methode verwendet. Zunehmend findet jedoch der Vergleich verschiedener Sampling Methoden, wie der zufälligen quasi MCS, LHS oder Antithetischen Variablen hinsichtlich der Leistungsfähigkeit statt (vgl. Bayraksan, 2018). LHS übertrifft die anderen Sampling Techniken in Bezug auf Varianz und Bias Reduktion für eine Vielzahl an formulierten Problemen und das Ganze mit minimaler Rechenzeit (vgl. Bayraksan, 2018; Freimer et al., 2012).

Eine andere Möglichkeit stochastische Optimierungsprobleme zu lösen, bietet die Nutzung von Szenarien. Um bei dieser Methode die Rechenzeiten zu verringern, sind die Szenario-Reduktionstechniken bei der Stochastischen Optimierung eingeführt

worden (z. B. Feng und Ryan (2013)). Jedoch haben Wu und Sioshansi (2017) bereits kritisiert, dass die Lösungsqualität reduziert sei und sich die Rechenzeiten nicht signifikant ändern, insbesondere wenn ein nicht-optimaler Startpunkt ausgewählt wurde. Deswegen haben bspw. Wu und Sioshansi (2017) die SAA Methode verwendet, um ihr Modell effizienter zu lösen.

Viele Forschungsarbeiten in der wissenschaftlichen Literatur nutzen unterschiedliche parametrische Wahrscheinlichkeitsverteilungen, um die E-Pkw Charakteristiken zu modellieren, einige Beispiele dazu finden sich im Abschnitt 3.3.2. In der Arbeit von Plötz et al. (2017) werden die Anpassungsgüten (Goodnes of Fit) für drei verschiedene Verteilungen miteinander verglichen. Dabei wird erkenntlich, dass die zugrundeliegenden Daten einen ausschlaggebenden Einfluss haben. Nur wenige nutzen nicht-parametrische Ansätze. Die Modellierung und Anwendung von KDE gibt es auch im E-Pkw Kontext. Paterakis und Gibescu (2016) beschreiben die Modellierung ihrer elektromobilen Flotten mit einer KDE. Iversen et al. (2014) wenden es für die Schätzung ihrer Flottendistanzen an. Ein anderes Beispiel ist von Li et al. (2016), welche die E-Pkw Verfügbarkeit von Umfragedaten mit einer KDE schätzen. KDE finden aber auch in vielen anderen Bereichen einen Einsatz z. B. Sheather (2004); Vermeesch (2012); El Heda und Louani (2018); Bäcklin et al. (2018) oder Chacón und Duong (2013).

4.5 Abgrenzung und Forschungslücke

Die letzten Abschnitte haben einen relevanten Auszug der Literatur in diesem Forschungsgebiet aufgezeigt und es wird die Forschungslücke ersichtlich, die mit der folgenden Abgrenzung noch einmal hervorgehoben wird. Die Tabelle 4.1 zeigt eine Gegenüberstellung verschiedener identifizierter Modelle, im Vergleich zum eigenen entwickelten Forschungsansatz. Es werden die Unterschiede der Modelldimensionen hinsichtlich der Systemgrenzen, behandelte Inhalte, der Modellierung sowie angewendeten Methode deutlich. In vielen vorgestellten Arbeiten kamen beispielsweise Betrachtungen bzgl. des Ladeverhaltens von E-Pkw und der Integration von EE vor, aber die Berücksichtigung von Unsicherheiten in diesem Kontext wurde bisher wenig erforscht. In der vorliegenden Arbeit werden durch Simulationen und einer zugrunde gelegten stochastischen Modellierung der elektromobilen Flotten eine Breite von Parametrisierungen einbezogen. Hinzu kommt die Stochastische Programmierung, die Unsicherheiten durch eingetretene Abweichungen von angenommenen und eingeplanten Informationen involviert. Somit werden auch Abweichungen von der perfekten und vollen Information integriert.

Im Vergleich zu den anderen Modellen und der bestehenden Literatur wird ersichtlich, dass der in dieser Arbeit entwickelte Ansatz ein neues E-Pkw Lademodell beschreibt, welches die besonderen Charakteristika von drei verschiedenen E-Pkw Flotten mit einer gemeinsamen Ladeinfrastruktur und technischen Restriktionen betrachtet. Zusätzlich werden bei der PV-Stromerzeugung mehrere Prognosemodelle untersucht und flexible Elektrizitätspreise abgebildet. Die Merkmale werden unter Unsicherheit betrachtet. Die E-Pkw werden optimal von einem E-Pkw Aggregator mit der zusätzlichen maximalen Ausnutzung des Stromes von PV koordiniert, so dass diese kostenminimal unter der Berücksichtigung von Unsicherheiten geladen werden. Die E-Pkw Charakteristika werden insbesondere durch eine nicht-parametrische Verteilung abgebildet, dadurch werden noch einmal besonders die Abhängigkeiten der Variablen und damit Eigenschaften der E-Pkw im Detail hervorgehoben. Damit ist das entwickelte Modell näher an der Realität und für einen Parkhausbetreiber potenziell einsetzbar, da sich dadurch insbesondere Erlöse abschätzen lassen. Des Weiteren wird die LHS basierte SAA Methode angewendet, um das zugrundeliegende zweistufige stochastische gemischt- ganzzahlige Problem akkurater und effizienter zu lösen. Diese Kombination der Effekte von Unsicherheiten der Energienachfrage von E-Pkw und der PV-Stromerzeugung stellt einen neuen Beitrag für die Erforschung des Verhaltens von elektromobilen Flotten im lokalen Energiesystem dar.

Tabelle 4.1: Übersicht relevanter Arbeiten im Kontext von Lademanagementsystemen für E-Pkw unter Unsicherheiten

Referenzen	Zielsetzung und Inhalt	Fokus	E-Pkw Flottengröße	Kombination E-Pkw Flotten	Simulationshorizont	Zeitliche Auflösung	Netzrestriktion	EE Integration	Preis	E-Pkw Flotten Modellierung	Stochastische Fahrprofile	Unsicherheit EE	Unsicherheit Energielieferung
Braam et al. (2016)	Bewertung von LVP. Dabei unterliegt ihr System mehreren Restriktionen aus der Umwelt, diese beinhalten u. a. die Ladeinfrastruktur oder das Verteilnetz; MILP	PH	13	-	12 h	15 min	+	+	+	-	-	-	-
Brandt et al. (2017)	Untersuchen die Möglichkeit ein Geschäftsmodell für elektromobile Flotten in einem Parkhaus zu erstellen. Kostenanalyse für Bereitstellung von Frequenzregulierung; Simulation	PH	> 100	-	1 d	15 min	-	-	+	-	-	-	-
Detzler et al. (2015)	Optimierung basiert auf einem evolutionären Algorithmus, um das Lastverhaltensverhalten einer Flotte zu untersuchen; Evolutionäre Algorithmen	PH	50	-	<1 d	15 min	+	+	+	+	-	-	-
Salah und Flath (2016)	'Deadline Differentiated Pricing' wird angewendet, um die Anreize für Lastverschiebung der Kunden zu erhöhen, dieses wird durch Rabatte für die Kunden umgesetzt; MILP	PH	100	-	1 d	15 min	+	+	+	+	-	-	-
Uhrig et al. (2014)	Ein zentrales Parkhaus-Energiemanagement und optimale Ladestrategien für Parkhausbetreiber, EVU, Fahrzeugnutzer werden vorgestellt; Optimierung und Simulation	PH	< 100	-	1 d, 4 h	15 min	+	-	-	+	-	-	-
Kaschub et al. (2016)	Untersuchung der Wirtschaftlichkeit von PV und Batteriespeichersystemen im HH mit E-Pkw und der Auswirkungen auf Elektrizitätsnachfrage; MIP	HH	225	-	1 Jahr	15 min	-	+	+	+	-	-	-
Gottwalt et al. (2016)	Bewertung von Haushaltsflexibilität für die EE Integration; Simulation und Optimierung	HH	160	-	12 Wo	15 min	-	+	+	+	-	-	-

Schuller et al. (2015)	Bewertung von LVP von E-Pkw für EE Integration; MILP	Dtl > 100	-	1 Wo	15 min	-	+	-	+	-	-	-
Tushar et al. (2014)	Reduktion des externen benötigten Stromes durch optimales Planen der Geräte und E-Pkw und Ausnutzen von EE; MILP	SMC 600	-	1 d	1 h	-	+	+	+	-	-	-
Li et al. (2012)	Energieeffiziente Lösung der Integration von E-Pkw in ein Smart Grid mit EE unter Unsicherheit von Preisen, EE, Energienachfrage; SP	SG k. A.	-	1 d	1 h	-	+	+	-	+	+	+
Saber und Venayagamoorthy (2012)	Ressourcen Scheduling unter Unsicherheit in einem Smart Grid mit EE und E-Pkw zur Emissions- und Kostenreduktion; PSO	SG k. A.	-	1 d	1 h	-	+	+	-	+	+	+
Eigenes Modell (2019)	Bewertung von Lastverschiebepotenzialen von E-Pkw für die Integration von PV unter Berücksichtigung von Unsicherheiten der PV und Energienachfrage	PH ~ 150	+	1 d	15 min	+	+	+	+	+	+	+

Abkürzungen: k. A. = keine Angabe; HH = Haushalt; PH = Parkhaus; SG = Smart Grid; SMG = Smart Microgrid
 PSO = Particle Swarm Optimierung; SP = Stochastische Programmierung

5 Fallstudie eines Parkhauses mit synergetischer Ladeinfrastruktur und PV-Anlage

In diesem Kapitel wird der konkrete Anwendungsfall mit der entsprechenden Umsetzung beschrieben. Zunächst stellt der Abschnitt 5.1 die spezifischen Rahmenbedingungen im Parkhaus vor. Die folgenden Abschnitte gehen im Detail auf die Modellierung der einzelnen Inputgrößen, die verschiedenen elektromobilen Flotten (Abschnitt 5.2), das Fahrzeug und die Batterie (Abschnitt 5.3), die PV-Anlage und CO₂-Emissionen (Abschnitt 5.4) sowie die angewendeten Ladestrategien (Abschnitt 5.5) ein. Die letzten beiden Abschnitte beschäftigen sich zum einen mit den untersuchten Modellvarianten (Abschnitt 5.6) und zum anderen mit der Modellumsetzung und der dazugehörigen technischen Modellbeschreibung (Abschnitt 5.7).

5.1 Spezifizierung der Rahmenbedingungen im Parkhaus

Dieser Fallstudie liegt ein Parkhaus in Stuttgart zu Grunde. Dabei kann auf Originaldaten von mehreren Nutzergruppen aus dem Jahr 2013 zurückgegriffen werden. Für die konkrete Umsetzung werden die ursprünglichen Daten angepasst und erweitert, um zukünftige E-Pkw darstellen zu können. Das aktuelle Parkhaus besitzt wenige Ladesäulen. Geplant sind aber Erweiterungen und insbesondere die schon angefangene Einführung einer synergetischen Ladeinfrastruktur abzuschließen. Dieses bedeutet, dass verschiedene Nutzergruppen auf eine gemeinsame Ladesäule zurückgreifen. Dabei können sich sowohl regelmäßige Dauerparkerkunden (z. B. mit einer RFID-Karte) anmelden als auch spontane Kurzzeitparker mit einem gezogenen Ticket oder ebenfalls anderen RFID-Karten von verschiedenen Anbietern. Somit handelt es sich hier um einen halböffentlichen Ladeort, wie im Kapitel 2.4.1 angeführt. Aufgrund der synergetischen Ladeinfrastruktur und der Berücksichtigung verschiedener Kundengruppen werden gleichzeitig die Ladeorte beim Arbeitgeber und öffentlicher Bereich abgedeckt.

In Abbildung 5.1 ist die Umsetzung der Fallstudie schematisch dargestellt. Es ist ein Parkhaus, in dem drei verschiedene elektromobile Flotten – Kurzzeitparker, Dauerparker und Unternehmensflotte (vgl. Abschnitt 5.2) – gleichzeitig parken und laden können. Durch die Diversifizierung mit drei E-Pkw Flotten wird das Parkhaus über den gesamten Tagesverlauf genutzt. Dies bewirkt eine Erweiterung des halböffentlichen Ladepunktes (vgl. Kapitel 2.4.1). Zugleich kann ein breiteres Spektrum an Ladevorgängen abgebildet werden. Entsprechend der drei E-Pkw Flotten spiegeln die Dauerparker (bzw. Pendler) das Laden am Arbeitsplatz (vgl. Abschnitt 2.4.1.3) wider, die Kurzzeitparker sind klassische Parker des halböffentlichen Bereiches und die Unternehmensflotte kann durch das Nachtladen ebenfalls mit gewerblichen Flotten und nicht öffentlich zugänglichen Parkplätzen verglichen werden.

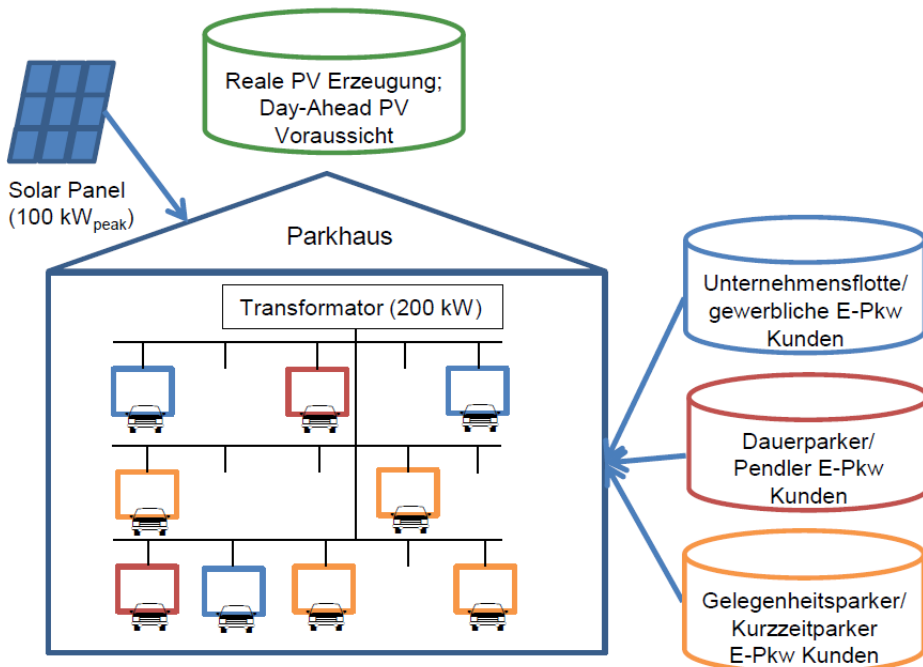


Abbildung 5.1: Schematische Darstellung der Fallstudie

Das Parkhaus besitzt eine maximale Gebäudeanschlussleistung, die durch einen Transformator bestimmt wird und einschränkend auf die individuellen Ladeleistungen wirken kann. Hinzukommen die natürlichen Begrenzungen der einzelnen Ladesäulen, als auch die technischen Restriktionen der Ladeleistung der E-Pkw. Das Parkhausdach

ist mit einer kleinen Photovoltaikanlage (vgl. Abschnitt 4.4) ausgestattet. Zur Abrundung der Fallstudie werden, neben den realen Parkhausdaten, diverse externe Datenquellen hinzugezogen, z. B. EPEX SPOT-Preise, PV-Stromerzeugung, Fahrzeugdaten. Die EPEX SPOT-Preise, wie auch die PV-Stromerzeugung wurde für das Jahr 2013 genutzt, damit diese zu den aus 2013 erhobenen Parkhausdaten passen.

5.2 Charakterisierung elektromobiler Flotten

In der Fallstudie nutzen drei verschiedene elektromobile Flotten eine gemeinsame Ladeinfrastruktur. Dieser Abschnitt zeigt im Detail die Modellierung der einzelnen Flotten und die unterschiedlichen hinterlegten Charakteristika auf. Insbesondere wird für alle drei Flotten zur Ermittlung der Verteilung eine nicht-parametrische Dichtefunktion, die KDE, genutzt. Zusätzlich werden die verwendeten Datensätze, sowohl die realen Daten als auch die Mobilitätsstudien detailliert erklärt und ausgewertet. Somit wird in diesem Unterpunkt die erste Forschungsfrage (I) zum Thema der relevanten Charakteristika bei der Modellierung von E-Pkw Flotten beantwortet.

5.2.1 Kurzzeit-/Gelegenheitsparker

Im Rahmen der Arbeit werden als Kurzzeitparker die E-Pkw betrachtet, die für wenige Stunden in einem Parkhaus stehen und laden. Typischerweise ist jenes mit Aktivitäten, wie Kinobesuch oder Shopping verbunden. Ausgehend von verschiedenen Studien kann sich die durchschnittliche Aufenthaltsdauer von ca. 3,5 Stunden (reale Parkhausdaten eines Werktages) (vgl. Seddig et al., 2014) oder nur 1 bis 2 Stunden erstrecken (vgl. BMVBS, 2012a). Beim letzten Datensatz wurde entsprechend des Parkortes ‚Parkhaus‘ bzw. ‚Freizeit‘ gefiltert.

Der Tagesverlauf für das Verkehrsaufkommen in dem untersuchten Parkhaus ist der Abbildung 5.2 für die Ankunftszeiten und daran gekoppelten Aufenthaltsdauern zu entnehmen. Aus der Summe von Aufenthaltszeiten in Verbindung mit der Ankunftszeit ergeben sich die Abfahrtszeiten, da die Datenzusammenhänge bekannt sind. Er-sichtlich wird, dass eine größere Anzahl der Kurzzeitparker zunehmend zu den Abendstunden den Weg ins Parkhaus finden. In der Abbildung sind zum einen die Verteilung der Ankunftszeiten durch Histogramme dargestellt, als auch die Verteilung der Aufenthaltsdauern mit Hilfe von Histogrammen verbildlicht. Der Nachteil der Darstellung mit Histogrammen ist, dass es eine nicht stetige Darstellung ist. KDE hingegen haben den Vorteil, dass diese die noch unbekannte stetige Verteilung schätzen.

Die entsprechenden 2D KDE sind im Anhang B zu finden. Die Abhängigkeiten und Häufigkeiten zwischen beiden Verteilungen sind durch die Hexaeder dargestellt. Der Korrelationskoeffizient r nach Pearson beträgt $-0,32$. Somit liegt eine negative schwache (lineare) Korrelation zwischen den beiden Variablen vor (vgl. Cramer und Kamps, 2008b).




Abbildung 5.2: Verteilung der Ankunftszeiten und Aufenthaltsdauern der Gelegenheitsparker im Beispielparkhaus an einem Werktag; Datenquelle: PBW (2013)

Die Ladeanfragen der Kurzzeitparker werden stochastisch modelliert. Als Ausgangslage werden die Ankunfts- und Abfahrtszeiten der Kurzzeitparker im Parkhaus erfasst. Auf Basis dieser Daten wird eine zweidimensionale Wahrscheinlichkeitsverteilung erstellt, die diese Verteilung bestmöglich abbildet. Dafür wird die Kerndichtefunktion (Kernel Density Funktion) als Wahrscheinlichkeitsverteilung gewählt (vgl. Abschnitt 3.3.2). Die dritte benötigte Variable w ist die zurückgelegte Distanz. Dafür wird der Datensatz von KiD 2010 genutzt (vgl. BMVBS, 2012a). Die Kurzzeitparker fahren

insbesondere kurze Strecken von bis zu 5 km (vgl. Abbildung 5.3). Der zurückgelegte durchschnittliche Fahrweg liegt bei den Kurzzeitparkern (mit einem angenommenen Maximum der Distanz von 120 km) bei lediglich 13 km. Aus den vorhandenen Daten wird eine eindimensionale KDE für die Variable w erstellt. Die beiden erzeugten Wahrscheinlichkeitsverteilungen der KDE werden genutzt, um die Variablen Abf , Ank , w für eine Ladeanfrage der Kurzzeitparker zu generieren, indem aus beiden Verteilungen jeweils die entsprechenden Werte gezogen werden. Die Anzahl der zufälligen Ziehungen aus der KDE ist abhängig von der Anzahl an Kunden. Gibt es beispielsweise 50 Kurzzeitparkerkunden für einen Tag, werden 50 Ladeanfragen mit den Variablen Abf , Ank , w aus der 1D und 2D KDE gezogen. Die Zuordnung zwischen der 2D KDE und 1D KDE erfolgt dabei zufällig, da keine Informationen über die Abhängigkeiten zwischen den beiden erzeugten KDE vorliegen, da unterschiedliche Datensätze genutzt werden.

Für die Erzeugung der 1D, 2D und auch 3D KDE werden mehrere Schritte vollzogen. Zum einen wird der relevante Parameter der KDE, die Bandbreite, neben dem Kernel bestimmt (siehe Abschnitt 3.3.2). Der Parameter der Bandbreite der jeweiligen ein- bzw. zweidimensionalen KDE wird mit einem Best Fit über die Cross-Validation (Kreuzvalidierung) mit einem Maximum-Likelihood (ML)-Schätzer ermittelt, um die optimale Bandbreite zu erhalten. Als Kernel wird der Gaussian angenommen. Bei der zweidimensionalen KDE wird eine multivariate Verteilung erstellt. Dabei werden bedingte Verteilungen der Zufallsvariablen erzeugt. Diese wird durch die Bestimmung der Randverteilungen der Zufallsvariablen gebildet, um somit das vorhandene Wissen über die Zufallsvariable für die neue Verteilung zu integrieren.

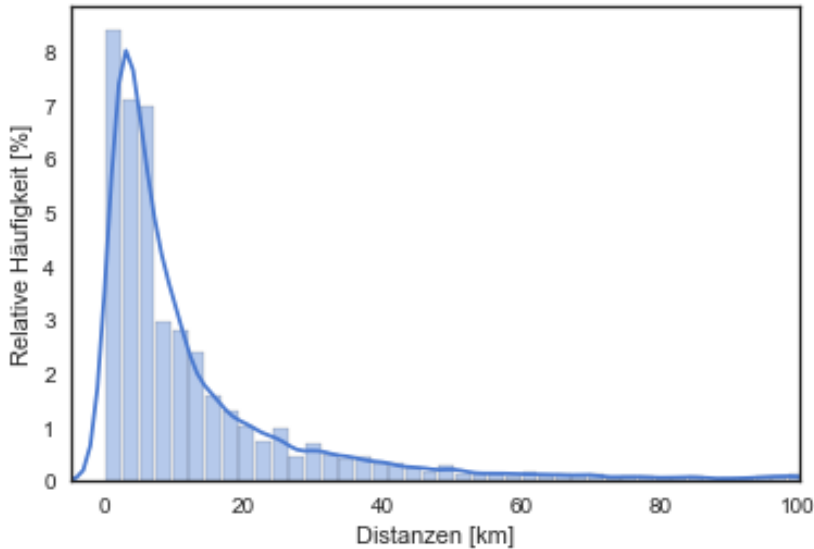


Abbildung 5.3: Verteilung der Distanzen der Gelegenheitsparker und zugehörige 1D KDE; Datenquelle: BMVBS (2012a)

5.2.2 Dauerparker/Pendler

Die zweite betrachtete Flotte in der Fallstudie sind die Dauerparker bzw. Pendler. Charakteristisch für diese Gruppe ist der Tagesverlauf mit dem Peak der Ankunft am Morgen und dem Peak am Abend für die Abfahrt, dargestellt in Abbildung 5.4. Die ausgewerteten Daten beruhen ebenfalls auf den Daten des Parkhauses in Stuttgart. In den Vormittagsstunden fahren die Kunden ein und stellen ihr Fahrzeug im Parkhaus ab. Üblicherweise verweilt das Auto dann für den Arbeitstag durchschnittlich 8 h (mit Peaks von bis zu 10 h) im Parkhaus bis der Kunde sein Auto wieder abholt und nach Hause fährt. Die Daten vom KiD 2010 zeigen ähnliche Aufenthaltsdauern auf. Bei diesem haben die Gruppe der Pendler im Durchschnitt 7,5 h Aufenthaltsdauer mit Spitzenwerten bis zu 9,5 h. Der Pearson-Korrelationskoeffizient zwischen den Variablen Ankunftszeit und Aufenthaltsdauer beträgt $r = -0,55$ und somit liegt eine negative mittelstarke (lineare) Korrelation vor.




Abbildung 5.4: Verteilung der Ankunftszeit und Aufenthaltszeiten der Dauerparker im Beispielparkhaus an einem Werktag; Datenquelle: PBW (2013)

Die für die Fallstudie ausgewählten Distanzen sind dem Datensatz KiD 2010 entnommen. Die Dauerparker legen ebenso wie die Kurzzeitparker bei ihren Fahrten insbesondere kurze Distanzen von bis zu 5 km (vgl. Abbildung 5.5) zurück. Werden jedoch die Durchschnittswerte miteinander verglichen, so liegt dieser bei den Dauerparkern mit 19 km um 6 km höher als bei den Kurzzeitparkern. Die Werte beruhen auf der Annahme, dass die maximale zurückgelegte Distanz 120 km ist (nähere Informationen zum Auswahlalgorithmus siehe Abschnitt 5.3.1). Die Dauerparker unterliegen der gleichen Modellierung wie die Kurzzeitparker, da die Datengrundlage eine ähnliche Struktur aufweist. Somit wird wieder zunächst eine zweidimensionale KDE aus Ankunftszeit im Parkhaus und Aufenthaltsdauer gebildet. Die Kombination aus beiden ergibt die Abfahrtszeit. Die Grafiken zur 2D KDE sind im Anhang B zu finden. Dazu kommen jeweils die Daten vom KiD als eindimensionale KDE, für den Parameter w , von den zurückgelegten Distanzen. Die beiden KDE werden wie bei den Kurzzeitparkern bestimmt. Aus diesen beiden Verteilungen werden dann entsprechend die drei

benötigten Variablen Abf , Ank , w gezogen, um damit die Ladeanfragenerstellung der Dauerparker durchzuführen.




Abbildung 5.5: Verteilung der Distanzen der Dauerparker und zugehörige 1D KDE;
Datenquelle: BMVBS (2012a)

5.2.3 Unternehmensflotte/gewerbliche Flotte

Als Unternehmensflotte sind in dieser Arbeit die gewerblichen Flotten charakterisiert. Es werden Dienstfahrten berücksichtigt, die innerhalb eines Tages stattfinden. Der typische Verlauf von Fahrtbeginn, Fahrtende als auch die Distanzen sind in der Abbildung 5.6 dargestellt. Die Grafiken in der Diagonale sind die entsprechenden Histogramme und Verteilungen der Variablen, wenn diese isoliert betrachtet werden. Die anderen Grafiken stellen die Abhängigkeiten zwischen den Variablen dar. Die Streudiagrammdarstellung verdeutlicht die aufgetretenen Realisierungen aus der Mobilitätsstudie KiD (2010) und die Konturlinien, die entsprechend approximierte 2D KDE zwischen zwei Variablen. Des Weiteren verdeutlichen die Pearson-Korrelationskoeffizienten zwischen den jeweiligen Variablen mit $r = 0,12$ (Ank , Abf), $r = -0,16$ (Abf , w) und $r = 0,16$ (Ank , w), dass zwischen diesen Variablen eine schwache Korrelation besteht. Werden die drei Variablen einzeln betrachtet, wird ersichtlich, dass in den Morgenstunden zwischen 7 Uhr und 9 Uhr die meisten Fahrten starten, noch einmal

zur Mittagszeit und dann in den frühen Nachmittagsstunden bis hin zu 18 Uhr die Fahrzeuge wieder zurückkehren. In der Fallstudie wird davon ausgegangen, dass die Flottenfahrzeuge die Nacht über in dem Parkhaus stehen. Somit wird das Fahrtende für die späteren Simulationen zur Ankunftszeit im Parkhaus transferiert und der Fahrtbeginn zur Ausfahrt aus dem Parkhaus. Im Gegensatz zu den anderen beiden Nutzergruppen liegen die zurückgelegten Distanzen bei den Fahrten der Unternehmensflotte höher, wie ebenfalls in Abbildung 5.6 zu sehen ist. Die Durchschnittswerte der gefahrenen Distanzen belaufen sich dabei auf rund 43 km (unter der ebenfalls getroffenen Annahme, dass die maximale zurückgelegte Distanz 120 km ist, vgl. Abschnitt 5.3.1). Bei diesen Strecken handelt es sich hauptsächlich um Dienstfahrten, die auch mit weiter entfernten Orten im Zusammenhang stehen (vgl. BMVBS, 2012a).

Die Charakterisierung der Unternehmensflotte beruht auf dem Datensatz vom KiD (2010), weswegen bei der Erstellung der Wahrscheinlichkeitsverteilung auf eine dreidimensionale KDE zurückgegriffen wird, wie in Abbildung 5.7 demonstriert ist. Damit können die vorhandenen Abhängigkeiten zwischen den einzelnen Variablen Abf , Ank , w besser abgebildet werden. Zur Erstellung der KDE wird so vorgegangen, wie bei den anderen beiden Flotten, d. h. Kreuzvalidierung mit ML-Schätzer für die optimale Parameterbestimmung der Bandbreite unter Annahme eines Gaussian Kerns als Parameter für alle drei Zufallsvariablen. Es wird entsprechend für alle drei Zufallsvariablen eine bedingte Verteilung erstellt, um das vorhandene Wissen in die multivariate Verteilung einfließen zu lassen. Für die Generierung einer Ladeanfrage wird einmal aus der dreidimensionalen KDE gezogen und eine zufällige Realisierung jeweils für die Variablen Abf , Ank , w ermittelt. Entsprechend der Anzahl an Flottenkunden wird dieser Vorgang wiederholt.




Abbildung 5.6: Verteilung und KDE der Abfahrts- und Ankunftszeiten sowie der Distanzen der Unternehmensflottenbuchungen an einem Werktag;
Datenquelle: BMVBS (2012a)

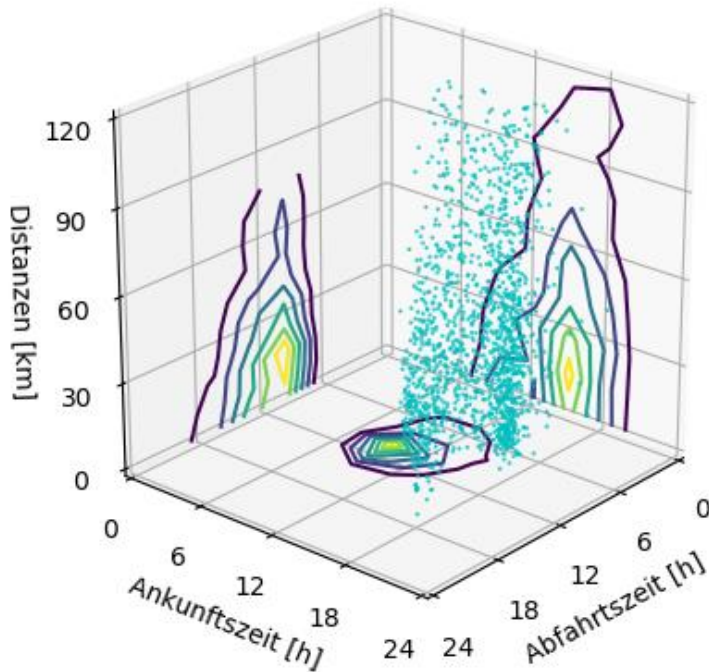


Abbildung 5.7: 3D-Verteilung der Abfahrts- und Ankunftszeiten sowie der Distanzen der Unternehmensflottenbuchungen an einem Werktag;
Datenquelle: BMVBS (2012a)

5.3 Modellierung der Elektrofahrzeuge

In diesem Abschnitt werden die technischen Aspekte und der Auswahlalgorithmus für die synthetischen Fahrprofile sowie die Unsicherheiten der Energienachfrage der E-Pkw vorgestellt.

5.3.1 Fahrtmodell

Für die synthetischen Fahrprofile werden nur Tagesfahrten herangezogen. Diese bilden jedoch nur einen Teil der Realität ab. Es gibt wenige Studien, die das Mobilitätsverhalten für einen längeren Zeitraum erfassen, wie bspw. MOP (vgl. BMVBS, 2011). Wird das deutsche Elektrifizierungspotenzial untersucht, dann haben 13 % der Autos während eines ganzen Jahres niemals 100 km pro Tag überschritten und könnten ohne Änderung des Nutzerverhaltens durch ein E-Pkw ersetzt werden (vgl. Weissert al.,

2014). Diese Annahmen sind recht restriktiv. Werden andere Studien herangezogen und wird der Fokus auf den Prozentsatz der Fahrten unter 100 km gelegt, dann ergeben sich andere Erkenntnisse. Somit kann zu ca. 95 % das Verkehrsverhalten der Fahrzeuge abgedeckt werden (vgl. BMVBS, 2012b). Darin wird der mögliche Spielraum für die Elektrifizierung der Fahrzeuge hin zu E-Pkw deutlich.

Zur konkreten Umwandlung der Daten aus verschiedenen Mobilitätsstudien wird ein Auswahlalgorithmus angewendet. Dafür wird auf dem Datensatz vom KiD 2010 aufgebaut. Für die Ermittlung der Distanzen wurde entsprechend nach der jeweiligen Nutzergruppe gefiltert. Für alle drei Flotten werden nur die Wochentage Montag bis Freitag untersucht, da insbesondere die dienstlichen Fahrten als auch die Pendler in diesem Zeitraum aktiv sind und ein darin liegender Wochentag der Betrachtungszeitraum des Modells ist. Die Kurzzeitparker werden nach dem Fahrtzweck (z. B. privater Einkauf oder Freizeit, Erholung) gefiltert, um die entsprechend relevanten Fahrten zu ermitteln. In der Arbeit stehen die Parkzeiten sowie die zurückgelegten Distanzen aus diesem Datensatz im Vordergrund, um darauf aufbauend die möglichen Ladefenster für die Fahrzeuge zu ermitteln. In Abhängigkeit der gewählten Batteriekapazität und des durchschnittlichen Energieverbrauchs k verändern sich die berücksichtigten maximalen Distanzen für den Auswahlalgorithmus. Für die Berechnung der benötigten Energienachfrage v der E-Pkw wird die folgende Formel genutzt:

$$v_i = w_i \cdot k \quad \forall i \quad (5.1)$$

Dabei ergibt sich der Ladebedarf aus der zurückgelegten Distanz w und dem hinterlegten durchschnittlichen Energieverbrauch k . Basierend auf den Daten eines heute üblichen E-Pkw (Nissan Leaf) wird eine Batteriekapazität von 24 kWh und ein durchschnittlicher Energieverbrauch von 0,2 kWh/km angenommen (vgl. ADAC Autotest, 2012). Dies gilt unter der Annahme, dass es sich um einen konstanten Energieverbrauch handelt, welcher unabhängig vom Fahrprofil ist. Vermutlich unterscheiden sich die durchschnittlichen Verbrauchswerte der E-Pkw im Sommer und im Winter. Im Winter werden die Verbrauchswerte der E-Pkw zusätzlich durch die technischen Applikationen des Autos (Heizung, erhöhter Lichtbedarf, etc.) erhöht sowie auch durch die geringere Effizienz. Im Sommer gibt es ebenfalls Verbrauchsquellen innerhalb des Autos, wie z. B. die Klimaanlage, die sich i. d. R. aber geringer auf den Verbrauch auswirken.

Für die Dauerparker wird der Fahrtzweck nach Fahrt zum Arbeitsplatz und Fahrt nach Hause gefiltert, damit die korrespondierenden Daten erfasst werden. Zuletzt werden

nur dienstliche/geschäftliche Fahrten mit Distanzen unter 120 km an Wochentagen für die Unternehmensflotte berücksichtigt. Die Maximaldistanz ergibt sich aus der Restriktion der Batteriekapazität, gekoppelt mit dem Energieverbrauch. Daraus resultiert die Reichweite von den E-Pkw. Die Vorgehensweise zur Erstellung der synthetischen Fahrprofile ist in der Abbildung 5.8 zu sehen.

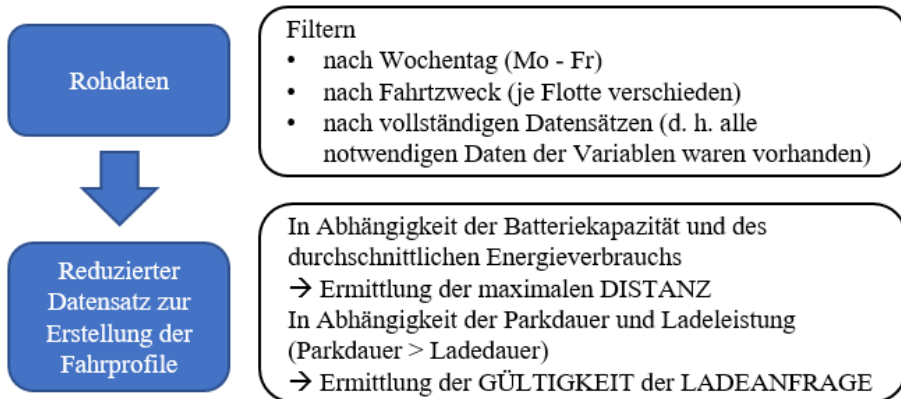


Abbildung 5.8: Auswahlalgorithmus zur Erstellung der synthetischen Fahrprofile

Die Boxplotdarstellung¹ der Abbildung 5.9 zeigt den durchschnittlichen Ladebedarf je Kunde aus einer Flotte von 50 Kunden. Dabei wurde der Parameter w für jeden Kunden zufällig aus der KDE der Distanzen gezogen und danach entsprechend der Ladebedarf ermittelt. Die Unternehmensflotte hat aufgrund der höchsten durchschnittlichen Distanzen der drei Flotten ebenfalls den höchsten durchschnittlichen Ladebedarf, da sich dieser proportional zu den Distanzen verhält.

¹ In den hier verwendeten Boxplots bildet der Strich den Median ab, die Box beinhaltet die mittleren 50 % der Daten, also sind damit das obere und untere Quartil repräsentiert. Die Antenne und damit die Länge der Whisker ist auf maximal das 1,5-Fache des Interquartilsabstands definiert.

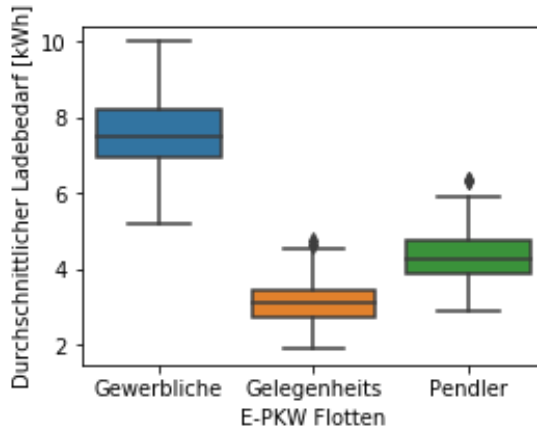


Abbildung 5.9: Boxplot der durchschnittlichen Energienachfrage je Kunde für die drei E-Pkw Flotten

Viele andere Untersuchungen (vgl. Zhang et al., 2014) nutzen für die Beschreibung ihres Fahrzeugmodells ebenfalls eine Parametrisierung der Fahrzeuge. Das detaillierte physikalische Verhalten des Fahrzeuges, beispielsweise die Schätzung des Batteriezustands, die Effekte der Geschwindigkeit oder des Fahrbahnumtergrundes auf den Batteriezustand, steht in dieser Arbeit nicht im Vordergrund. Veröffentlichungen, die sich im Detail damit beschäftigen sind z. B. Cuma und Koroglu (2015). Stattdessen wird der Fokus auf die Auswirkungen des Fahrzeugverhaltens auf das Energiesystem gelegt.

Eine weitere Annahme ist, dass sobald ein Auto eine Fahrt beendet hat, die gerade gefahrene Energiemenge wieder sofort aufgeladen wird. Die Fahrzeuge beginnen ihre Fahrt mit einem SOC von 100 %, so dass beim Ladeprozess nur die Energie der letzten Strecke berücksichtigt wird. Der Zeitpunkt des Aufladens hängt von der gewählten Ladestrategie (vgl. Abschnitt 5.5) ab, muss aber im Zeitfenster des Parkens stattfinden, ansonsten ist dies keine gültige Anfrage.

Die Batteriekapazität wird in dieser Arbeit nicht variiert und auf 24 kWh festgesetzt. Der Grund dafür liegt an der Tatsache, dass die Vergrößerung der Batteriekapazität keine große Auswirkung hat, weil die nachgefragten und hier betrachteten Energiemengen eher klein sind. Hinzu kommt die Annahme, dass die Nutzer regelmäßig angesteckt sind zum Laden (vgl. Pfriem und Gauterin, 2013). Eine Vergrößerung der Batterie würde diesen Zustand nicht signifikant ändern, da die durchschnittlichen Distanzen (siehe Abschnitt 5.2) zu 95 % unter 100 km liegen.

Ein weiterer Aspekt für die Batterie stellt das Ladeverhalten dar. Zur Vereinfachung wird angenommen, dass dieses mit einer maximal verfügbaren Ladeleistung für den gesamten Ladevorgang von statten geht. Detailliertere Informationen zur Modellierung des Ladeverhaltens von Batterien und entsprechende Ladekurven können z. B. in Kaschub (2017) gefunden werden.

5.3.2 Unsichere Energienachfrage

Die im vorherigen Abschnitt 5.3.1 definierten Energiewerte der Fahrzeuge sind im Referenzszenario mit einer Wahrscheinlichkeitsverteilung hinterlegt und werden, wenn eingetreten, als sichere Werte, die a priori bekannt sind, festgelegt. Zur besseren Abbildung der Realität, in der Abweichungen von geplanten Lademengen auftreten können, werden die Ladeanfragen mit Unsicherheit berücksichtigt. Zunächst wird, zur Erstellung einer neuen Ladeanfragekurve, über die Kurve der geplanten Ladeanfragen ein Rauschen gelegt, welches der Gaussian Normalverteilung entspricht. Für alle drei Flotten (Gelegenheitsparker, Dauerparker, Unternehmensflotte) ist eine Wahrscheinlichkeitsverteilung für die Energienachfrage der Ladeprozesse hinterlegt. Für jede Flotte wird zufällig ein Wert aus einer Gaußschen Normalverteilung gezogen und dieser als Rauschen genutzt. Die Parametrisierung der Normalverteilung liegt bei $N(1; 0,3)$ und wird für alle Flotten als gleich angenommen (vgl. Hafez und Bhattacharya, 2017). Die Unsicherheiten der Energienachfrage pro Flotte sind in Abbildung 5.10 dargestellt. Dabei sind positive wie negative Abweichungen möglich. Aber die absolute Nachfrage eines E-Pkw kann insgesamt nicht negativ werden, da dann V2G eintreten würde und das ist in dieser Arbeit ausgeschlossen. Ebenfalls ist die maximale Grenze durch die Batteriegröße des jeweiligen E-Pkw bestimmt. Die Boxplotdarstellung ergibt sich aus der Annahme, dass es 50 Kunden je Flotte sind. Die Unterschiede zwischen den Flotten resultieren aus der Annahme, dass das Rauschen mit dem entsprechenden Ladebedarf der jeweiligen Flotte multipliziert wird. Aufgrund des größten durchschnittlichen Ladebedarfs bei der gewerblichen E-Pkw Flotte hat diese auch die größten Unsicherheiten innerhalb des Ladebedarfs.

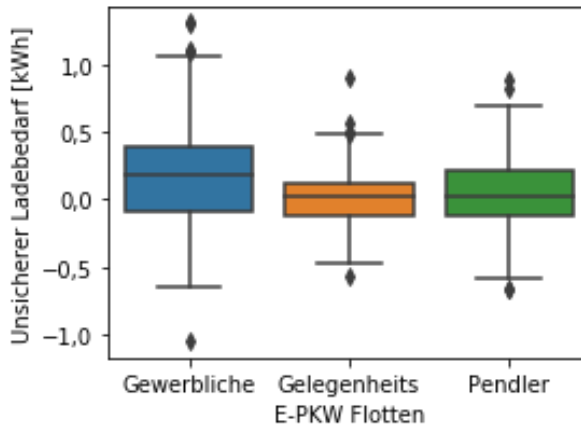


Abbildung 5.10: Boxplot der Unsicherheit der Energienachfrage je E-Pkw und pro Flotte

5.4 PV-Modell

Für eine flexible Gestaltung der restriktiven Anschlussgrenze des Parkhauses können weitere externe Stromquellen Berücksichtigung finden. Dabei wird der Strom des auf dem Dach produzierten Stromes der PV-Anlage als eine Komponente betrachtet. Dieser ist insbesondere interessant, um die potenziell möglichen positiven Auswirkungen des Ladens der E-Pkw mit erneuerbaren Energien auf das CO₂-Einsparpotenzial zu untersuchen. In diesem Abschnitt wird die Forschungsfrage (II) – in Bezug auf die Unsicherheiten bei Prognosen der PV-Stromerzeugung näher untersucht.

5.4.1 Intermittierender Charakter von PV




Abbildung 5.11: Boxplot der Globalstrahlung über den Tagesverlauf des gesamten Jahres 2013 für die Stadt Stuttgart; Datenquelle: Meteotest (2014)

In Abbildung 5.11 wird die Fluktuation der Globalstrahlung über den Tagesverlauf von einem Jahr deutlich. Die resultierende Einspeisung von PV ist von Tag zu Tag verschieden und hängt von der lokalen Sonneneinstrahlung ab. Ebenfalls ist die Energieerzeugung von PV zwischen den Jahren unterschiedlich. Es lässt sich der unvorhersehbare Charakter von PV und die daraus resultierende Unsicherheit erkennen. Die Unsicherheiten bei der Elektrizitätserzeugung aus PV beruhen hauptsächlich auf den Schwankungen der Globalstrahlung, welche je nach Bewölkung und Luftfeuchtigkeit verschieden ist.

Prognoseverfahren sind ein wichtiger Bestandteil zur Entscheidungsfindung. Eine Methode, die insbesondere Anwendung findet ist die Zeitreihenanalyse, welche eine Prognose durch quantitative Verfahren erstellt (vgl. Suhl und Mellouli, 2013). Die Abbildung 5.12 zeigt für das Jahr 2013 die realen vs. vorhergesagten PV-Stromerzeugungskurven der TransnetBW für die drei Sommermonate. Dabei ist die Leistung auf die PV-Anlage des Parkhauses skaliert, ausgehend von den TransnetBW Daten (vgl. TransnetBW, 2017). Die Kurven stellen die Medianwerte dar und der schattierte Bereich entsprechend das 25 % bzw. 75 % Quantil.

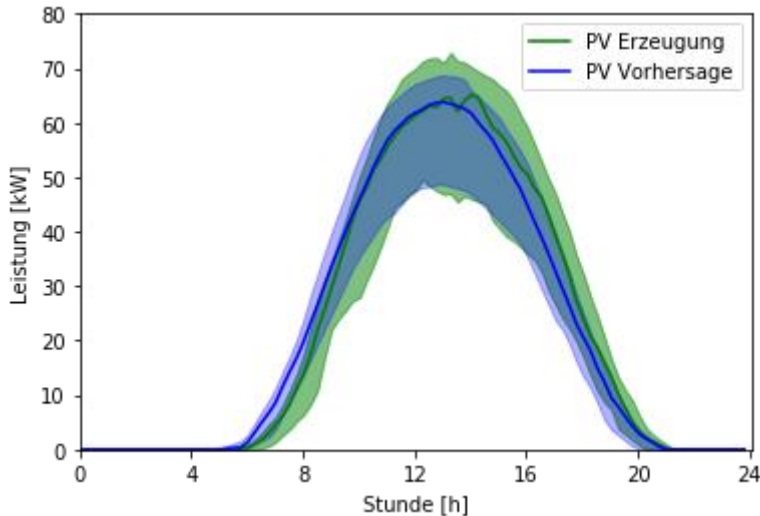



Abbildung 5.12: Darstellung der realen vs. der Day-Ahead vorhergesagten PV-Stromerzeugung von der TransnetBW in den Sommermonaten des Parkhauses des Jahres 2013; Datenquelle: TransnetBW (2017)

Die TransnetBW veröffentlicht seit Januar 2010 Prognosedaten für die PV-Stromerzeugung für den nächsten Tag und die tatsächlich eingetretene Erzeugung von PV (vgl. TransnetBW, 2017). Basierend auf diesen beiden Datensätzen wird die Prognosegüte durch eine multivariate Zeitreihenanalyse berechnet. Für die Gütebestimmung wird zunächst die Differenz der beiden Zeitreihen ermittelt. Die gebildete Differenzzeitreihe kann anhand verschiedener statistischer Kenngrößen bewertet werden, wie beispielsweise der mittlere Prognosefehler, die Standardabweichung oder der mittlere quadratische Prognosefehler (RMSE) (vgl. Winker und Funk, 2017). Der Prognosefehler für jeden Zeitpunkt zwischen den beiden Datenreihen der letzten sieben Jahre der TransnetBW ist in Abbildung 5.13 dargestellt. Erkennlich ist die größere Streuung zu den Mittagsstunden, da zu diesem Zeitpunkt auch eine erhöhte Erzeugung stattfindet. Aufgrund der fehlenden Sonneneinstrahlung ist in den Nachtstunden keine Erzeugung und demnach keine Streuung vorzufinden. Wird der RMSE für diese Zeitreihen berechnet, dann beträgt dieser 269,5 MW.



**Abbildung 5.13: Boxplotdarstellung des Prognosefehlers der PV-Stromerzeugung durch Zeitreihenanalyse von 2011 - 2017 im TransnetBW Einzugsgebiet;
Datenquelle: TransnetBW (2017)**

5.4.2 Unsichere PV-Stromerzeugung

Es ist nicht nur der Prognosefehler interessant, sondern das genaue zugrundeliegende Rauschen zwischen den beiden Zeitreihen der Realisierung und Prognose der PV-Stromerzeugung der TransnetBW, also die Wahrscheinlichkeitsverteilung über den Tagesverlauf der letzten Jahre der beiden Zeitreihen. Um die Streuung, die in der Abbildung 5.13 deutlich geworden ist, bestmöglich darzustellen, wird für die Berechnung der Wahrscheinlichkeitsdichtefunktion eine Mischverteilung, das Gaussian Mixture Model (GMM), des Fehlers angenommen. Dieses spiegelt die Summe von gewichteten einzelnen unimodalen Gaußverteilungen wider (vgl. Reynolds, 2008). Dafür notwendig ist die Schätzung der noch unbekannt Parameter der GMM-Wahrscheinlichkeitsdichteverteilung. Das Problem dabei ist, dass erst bestimmt werden muss, welche Gaussians es gibt und welche Datenpunkte dazu gehören. Durch die Anwendung des Expectation Maximization (EM) Algorithmus kann das Problem gelöst werden (vgl. Dempster et al., 1977). Durch Iteration des EM-Algorithmus werden die Parameter (Mittelwert bzw. Erwartungswert, Kovarianz Matrizen und Gewichtung aller Gaußverteilungen) erstellt. Das Vorgehen ist wie folgt definiert:

- Mit dem Expectation-Schritt wird das Modell gestartet. Die Kernidee ist einige Gaussians anzunehmen und die Daten zu den einzelnen Modellen zuzuordnen. Damit werden die Parameter geschätzt.
- Der Maximization-Schritt verändert das Modell so, dass es besser zu den Daten passt. Es wird die Maximum Likelihood Methode durchgeführt und somit die geschätzten Parameter angepasst.
- Die beiden Schritte werden wiederholt, damit sich die Parameter immer mehr ihren tatsächlichen Werten annähern.

Wenn sich die Parameter nicht mehr wesentlich ändern, endet der Algorithmus. Da eine Konvergenz der Folge des Algorithmus bewiesen wurde, endet dieser auf jeden Fall und das Ergebnis bildet ein lokales Optimum ab (vgl. McLachlan und Krishnan, 2008).




Abbildung 5.14: Boxplotdarstellung des Prognosefehlers der PV-Stromerzeugung mit Anwendung des GMM-basierten Ansatzes; Datenquelle: TransnetBW (2017)

Dargestellt ist der Verlauf des Prognosefehlers für die Anwendung des GMM-basierten Ansatzes zur Vorhersage der PV-Stromerzeugung und der realisierten PV-Stromerzeugung der TransnetBW in der Abbildung 5.14, skaliert auf die PV-Erzeugung der Größe des Parkhausdaches. Diese zeitabhängige Mischverteilung ist das Rauschen zwischen den beiden PV Zeitreihen der TransnetBW und wird im folgenden Abschnitt

5.4.3 verwendet. Der RMSE für diese beiden Zeitreihen beläuft sich auf 3,69 kW. Dieser RMSE ist um 0,35 kW besser als der Vergleich mit der vorhergesagten Datenreihe von der TransnetBW (siehe Abbildung 5.13).

Es gibt keine weiteren Informationen, wie die TransnetBW ihre Prognosen für den folgenden Tag ermitteln. Somit ist es bei dem genannten Vorgehen kritisch zu bewerten, dass die zugrundeliegenden Prognosealgorithmen von der TransnetBW nicht vorliegen. Sonst bestände die Möglichkeit eine noch spezifischere Bewertung der Prognosegüte vorzunehmen, da die entsprechenden Parameter der einzelnen Zeitreihen analysiert werden könnten.

5.4.3 PV-Prognose

In dem vorangestellten Abschnitt 5.4.1 wurde der fluktuierende Charakter der PV-Stromerzeugung beschrieben. Damit eine breite Spanne dieser Variabilität und Unsicherheit abgedeckt ist, werden drei verschiedene Charakteristika der PV-Stromerzeugung betrachtet:

- **Perfekte Voraussicht:** Als Benchmark Ansatz für die PV-Stromerzeugung wird von a priori bekannten PV Kurven ausgegangen. Die genutzte Datenquelle der TransnetBW basiert auf den realen Beobachtungen, welche die entsprechenden Informationen für die Region von Süddeutschland zur Verfügung stellt (vgl. TransnetBW, 2017). Für die deterministische Optimierung, die durch die Anwendung einer MCS mehrmals simuliert wird, wird zwischen drei Winter- und drei Sommermonaten unterschieden und ein Tag wird zufällig jedes Mal neu gezogen.
- **Day-Ahead-Voraussicht:** Der zweite Ansatz für die PV-Stromerzeugung sind die Vorhersagen für den nächsten Tag, ebenfalls von der Datenquelle der TransnetBW (vgl. TransnetBW, 2017). Diese geben einen Tag im Voraus eine PV-Stromerzeugungskurve für den nächsten Tag heraus. In dem hier entwickelten Modell wird zunächst mit der Day-Ahead Kurve der PV-Anlage der Strombedarf mit Hilfe des MILP für die Ladeanfragen entsprechend ermittelt. In einem zweiten Schritt, wenn die reale PV-Stromerzeugung eingetreten ist, werden die Unterschiede zu den Day-Ahead Kosten bewertet und kurzfristig reagiert.
- **GMM-basierte Voraussicht:** In dem dritten Ansatz werden die Unsicherheiten der PV-Stromerzeugung berücksichtigt. Dafür werden empirisch erstellte

Kurven mit einem Rauschen belegt, wodurch die Unsicherheit abgebildet wird. Dabei werden zunächst die Vorhersagen von TransnetBW und die dann realen eingetretenen PV-Stromerzeugungskurven der letzten sieben Jahre miteinander verglichen. Das Ergebnis der Zeitreihenanalyse der Daten ist eine approximierte Normalverteilung, welche als ein Rauschen auf die erwartete Day-Ahead-Voraussicht Kurve gelegt wird (vgl. Abschnitt 5.4.2). Damit werden die stochastischen Szenarien für die Unsicherheit abgebildet.

Abschließend können die Ergebnisse der Prognosen verglichen werden.

5.4.4 Größendimensionierung der PV-Anlage

Für das entwickelte Modell des Fallbeispiels gibt es die Annahme, dass eine PV-Anlage auf dem Dach des Parkhauses installiert ist. Dieses entspricht der Realität, jedoch ist jene nur klein dimensioniert. Für die Betrachtung der PV-Anlage wird hingegen die volle Ausnutzung des Parkhausdaches angenommen. Für die Region Stuttgart hat die Globalstrahlung im Jahr 2013 circa $1090 \text{ kWh/m}^2/\text{a}$ mit einem Durchschnittswert von $124,5 \text{ W/m}^2$ betragen (vgl. Meteotest, 2014). Somit könnte sich die erzeugte Energie der PV-Anlage des Parkhausdaches (1000 m^2) im Idealfall für das Jahr auf circa 100 MWh belaufen. Das maximal nutzbare Potenzial der PV-Anlage und damit die Leistung ist von der Fläche, dem Wirkungsgrad der Anlagen und der Sonneneinstrahlung abhängig (vgl. Kaschub et al., 2010). Spezifischere Annahmen bzgl. der Ausrichtung der Module, wie beispielsweise der Neigegrad (mit optimaler Ausrichtung in Azimut) werden nur bedingt berücksichtigt. Es wird von Verlusten des maximal nutzbaren Potenzials ausgegangen und maximal mit einer Leistung der PV-Anlage von 80 kW_p gerechnet.

5.4.5 CO₂-Einsparpotenzial

Für die Bestimmung der Emissionen, die durch E-Pkw erzeugt werden, sind verschiedene Verfahren möglich. In Abhängigkeit der Berechnungsmethode, z. B. jährlicher Elektrizitätsmix, Grenzelektrizitätsmix oder durchschnittlicher zeit-abhängiger Mix (vgl. Jochem et al., 2015) können unterschiedliche CO₂-Emissionen für die E-Pkw angesetzt werden. Hinzu kommt die Unterscheidung der Einheiten zwischen $\text{kg CO}_2/\text{kWh}$ oder $\text{g CO}_2/\text{km}$. Des Weiteren schwanken die durchschnittlichen Werte zwischen den einzelnen Ländern, da diese sich ebenfalls in ihrem Erzeugungsmix unterscheiden (vgl. Tabelle 5.1). Frankreich beispielsweise hat einen relativ geringen

durchschnittlichen Wert für die CO₂-Emissionen, was auf den hohen Anteil an nuklearer Energie bei der Elektrizitätserzeugung zurückzuführen ist. Brasilien wiederum hat ebenfalls einen geringen Wert für die durchschnittlichen CO₂-Emissionen, dieser beruht aber auf einem hohen Anteil der Elektrizitätserzeugung aus Wasserkraft.

Für die späteren Analysen bzgl. der CO₂-Einsparpotenziale von E-Pkw werden die durchschnittlichen CO₂-Emissionen für Deutschland genutzt, die sich auf 447 g CO₂/kWh bzw. 89 g CO₂/km belaufen (siehe Tabelle 4.1). Diese Werte liegen unterhalb des Durchschnitts der Welt.

Tabelle 5.1: Durchschnittliche CO₂-Emissionen des Energiemixes für ausgewählte Länder im Jahr 2016;
Datenquelle: IEA (2018a)

Land	Durchschnittliche CO ₂ -Emissionen in	
	g CO ₂ /kWh _{el}	g CO ₂ /km*
Australien	759	152
Brasilien	120	24
China	627	125
Dänemark	207	41
Deutschland	447	89
Frankreich	52	10
Indien	726	145
Japan	544	109
Kanada	149	30
Schweden	12	2
Südafrika	945	189
Thailand	477	95
Türkei	465	93
Vereinigtes Königreich	278	56
Vereinigte Staaten	433	87
EU-28	299	60
Welt	490	98

* Berechnet mit einem angenommenen E-Pkw Energieverbrauch von 0,2 kWh/km.

5.5 Ladestrategien

E-Pkw werden nach verschiedenen Konzepten geladen. Abhängig von der Zielfunktion und den dazugehörigen Nebenbedingungen können E-Pkw auch zur Lastverschiebung (vgl. Abschnitt 2.3.4.1) genutzt werden. Die entsprechenden Ladestrategien beeinflussen den Vorgang. Die theoretischen Grundlagen und die dazugehörige Anwendung für die hier vorhandene Fallstudie wurden bereits im Kapitel 3 vorgestellt. In diesem Anwendungsfall wird besonderes Interesse auf die Identifizierung der minimalen Ladekosten gelegt. Wie viel wirtschaftlicher kann ein Parkhausbetreiber durch die Steuerung der Stromflüsse und damit der Ladevorgänge werden? Die Infrastruktur wird als gegeben vorausgesetzt, da die fixen Kosten immer auf den Parkhausbetreiber zukommen würden. Die Investitionen werden in diesem Anwendungsfall schon als gegeben angenommen. Jedoch können durch ein intelligentes und optimales Lademanagementsystem die laufenden Betriebskosten reduziert werden. Es stellt sich die Frage, in welcher Größenordnung die Einsparungen liegen? Damit eine wirtschaftliche Bewertung der einzelnen Ladestrategien und der daraus erzeugten Ladekurven stattfinden kann, werden die damals noch in stündlichen Werten vorliegenden Preisdaten von Deutschland von dem Day-Ahead Strom-Spotmarkt aus dem Jahr 2013 genutzt. Die stündlichen Preise werden für das angewendete Modell in 15-minütige Schritte angepasst. Dieses passiert durch eine Interpolation der Daten.

5.5.1 Optimiertes Laden

Für die entsprechende Bewertung der zu untersuchenden Verfahren in den jeweiligen Szenarien, werden Preise genutzt, um die gesamten Ladekosten zu ermitteln. Es liegen die Einzelstunden des Day-Ahead-Marktes der EPEX SPOT-Börse vor. Mit dem Ziel die Auswirkungen von verschiedenen Preiskurven eines Tages zu identifizieren, werden Verteilungen von Sommer- und Winterpreiskurven eingesetzt, die in Abbildung 5.15 zu sehen sind. Dabei bilden diese die Medianwerte aller Tage der drei Monate der Sommer- bzw. Winterjahreszeiten ab und die entsprechenden 25 % und 75 % Quantil sind ebenfalls dargestellt. Es wurden nur die positiven EPEX SPOT-Preise ausgewählt, um konsistent mit der Annahme (t) zu sein (siehe Abschnitt 3.4.1). Im Allgemeinen ist ein ähnlicher Kurvenverlauf der Preise im Sommer wie im Winter erkennbar, lediglich sind die Preise im Sommer etwas geringer als im Winter. Hinzu kommen geringere Schwankungen des Sommerpreises.




Abbildung 5.15: Medianwerte EPEX SPOT Kurven (25 % bzw. 75 % Quantil schattierter Bereich) für Sommer- und Wintertage im Jahr 2013; Datenquelle: EEX (2013)

Die kostenminimale Optimierung hinsichtlich EPEX SPOT-Preisen wird verwendet, damit ein wirtschaftlicher Anreiz besteht, die Ladevorgänge zu den Zeitintervallen mit niedrigen Preisen zu verschieben. Die vorliegenden EPEX SPOT-Preise in €/MWh werden in ct/kWh umgerechnet und auf das 15-minütige Zeitintervall interpoliert. Es wird zufällig ein EPEX SPOT-Preis gezogen. An dem Tag des Day-Ahead EPEX SPOT-Preises ist die Stromerzeugung durch PV gekoppelt, damit die Abhängigkeiten von Preis und erneuerbaren Energien abgebildet werden. Dabei wurde z. B. in Paraschiv et al. (2014) oder Dillig et al. (2016) festgestellt, dass der Kurvenverlauf des Day-Ahead EPEX SPOT-Preises vom Erzeugungsmix abhängig ist und insbesondere von der Stromerzeugung durch erneuerbare Energien.

Durch die Annahme (s) wird der Strom aus erneuerbaren Energien maximal für die Ladevorgänge der E-Pkw genutzt. Somit laden die E-Pkw bevorzugt mit Strom von der lokalen PV-Anlage und erst als zweite Stromquelle wird sich des Netzes bedient.

In der Fallstudie kann im Idealfall der Parkhausbetreiber auf die genaue Verteilung der Ladeanfragen über den Tagesverlauf zurückgreifen. Auf der Grundlage von Reservierungen, genau hinterlegten Kundendaten und der Kenntnis über die zusätzliche Stromerzeugung von PV kann eine Realisierung erfolgen. In der Realität wird es aber

zu Abweichungen kommen. Das Fahrverhalten von den Kunden ist nicht immer identisch und von daher nicht genau vorhersehbar. Viel wahrscheinlicher ist die Betrachtung der Ausgangsdaten der Kunden, als auch der prognostizierten PV-Stromerzeugung unter Unsicherheit, um somit die Realität besser abbilden zu können.

5.5.2 Referenzfall: Unkontrolliertes Laden

Die Ladestrategie des unkontrollierten Ladens, FCFS, wird in dieser Arbeit als Referenzfall angesehen. Dieses heuristische Verfahren findet Anwendung, wenn keine Anreize gesetzt werden oder keine intelligenteren Steuerung verfügbar ist. Die Fahrzeuge kommen an einer Ladestation im Parkhaus an, werden angeschlossen und das Laden beginnt sofort und es wird ohne Unterbrechung mit einer maximal möglichen Ladelistung, unter der Berücksichtigung der globalen Anschlussleistung, geladen. In diesem Fall kann einerseits die Anzahl der Kunden nicht erhöht werden. Andererseits zeigt es dem Parkhausbetreiber auf, wie hoch die einzuplanenden Betriebskosten wären, wenn kein Lademanagement durchgeführt wird. Die entstehenden Lastkurven der einzelnen Kundengruppen werden mit den entsprechenden Day-Ahead Preisen des EPEX SPOT Strommarktes bewertet, unter Berücksichtigung der erzeugten PV-Leistung *PV*. Somit wären diese die Referenzfall Kosten, die der Parkhausbetreiber als Ladekosten für die E-Pkw einplanen müsste, da die Leistungsnachfrage der Kunden u. a. mit extern eingekauftem Strom abgedeckt werden muss. Diese Transaktion wird angenommen und findet über den EPEX SPOT Strommarkt statt.

5.6 Modellvarianten

Damit realistische Annahmen für das Parkhaus getroffen werden, mussten noch verschiedene Parameter entsprechend eingestellt werden. Ein wesentlicher Aspekt dabei bildet die Flottengröße der einzelnen Flotten. Zum einen sind die Rahmendaten des Parkhauses gegeben, d. h. mehr als 600 Stellplätze stehen aktuell zur Verfügung. Dabei stellt sich aber die Frage, wie hoch wird die Durchdringung in Zukunft mit Elektromobilität sein und dementsprechend die Ausstattung des Parkhauses mit Ladesäulen an den Parkplätzen. Dazu kommt die Restriktion des vorhandenen Transformators mit derzeit 200 kW. Somit ist nur eine begrenzte Anzahl an Ladesäulen sinnvoll, da die Leistungsgrenze von 200 kW schnell erreicht wird beim gleichzeitigen Laden von mehreren E-Pkw. Durch die vorhandene Anschlussleistungsgrenze wird nicht noch zusätzlich eine Begrenzung der Ladesäulen eingeführt. Als Annahme wird eine 25 %-

ige Auslastung des Parkhauses mit E-Pkw angenommen, wodurch sich für die meisten Untersuchungen folgende Flottengrößen ergeben:

- Gelegenheitsparker: 50
- Dauerparker: 50
- Unternehmensflotte: 50

Um Sensitivitäten festzustellen, werden verschiedene Parameter variiert, dazu zählt u. a. die Kundenanzahl, entsprechend gibt es Berechnungen mit insgesamt 75 oder 225 Kunden. Für die Analyse der verschiedenen Anwendungsfälle werden unterschiedliche Methoden betrachtet. Der folgende Abschnitt 4.6.1 gibt einen Überblick bzgl. der untersuchten Ansätze und der Parametrisierung.

5.6.1 Überblick der Parametrisierung

Für die Beantwortung der verschiedenen Forschungsfragen werden mehrere Methoden angewendet, die in mehreren Modellen umgesetzt sind. Einen Überblick über die gewählten Ansätze und die dazugehörige grundlegende Parametrisierung, die in dieser Arbeit genutzt werden, bietet die Tabelle 5.2, wobei eine genauere Beschreibung der jeweiligen Modelle und der dazugehörige Ablauf in dem Abschnitt 5.7.2 erfolgt. Im Ergebniskapitel 5 werden zusätzlich Sensitivitätsanalysen bzgl. des Einflusses verschiedener Parameter, wie z. B. Sommer- oder Winterpreise, Änderung der Anschlussleistung oder der Ladeleistung sowie Kundenzahl stattfinden.

Tabelle 5.2: Übersicht der Parametrisierung der verschiedenen Ansätze

Ansatz	Parameter	Drei EV Flotten	PV real	PV Day-Ahead	PV GMM-ba- siert
Unkontrolliertes Laden		x	x		
Perfekte Voraussicht MILP: Benchmark – deterministische Optimierung		x	x		
Day-Ahead-Voraussicht MILP		x		x	
GMM-basierte Voraussicht SMILP		x			x

Die Anschlussleistung des Parkhauses ist zunächst als einziger Stromlieferant und damit obere Leistungsgrenze für die Summe aller Ladevorgänge der E-Pkw gegeben. Hinzukommen noch die lokalen Begrenzungen durch Ladesäulen. PV wird als alter-

native Stromquelle angesehen. Mit Hinzunahme der Unsicherheit bei der Energienachfrage ändert sich die nachgefragte Energiemenge aller Ladeanfragen im Durchschnitt nur marginal, es finden insbesondere einzelne Verschiebungen statt.

5.6.2 Bewertung der Methoden

In vorhergehenden Abschnitten (vgl. 3.5) wurde das SMILP vorgestellt, welches den Wert der minimalen Ladekosten unter verschiedenen Unsicherheiten ermittelt. Im späteren Verlauf wurde noch ein MILP mit einem PV-Vorhersagemodell (vgl. Abschnitt 5.4.3) angewendet und zum Vergleich gegenüber der stochastischen Optimierung herangezogen. Zur Beurteilung der einzelnen Ergebnisse der jeweilig untersuchten Methoden, werden nicht nur die EVPI (vgl. Abschnitt 3.5.4) berechnet. Es werden zusätzlich noch Abweichungskosten einbezogen, die angefallen wären, wenn man die Differenzenergiemenge zwischen Einplanung und tatsächlicher Realisierung hätte kaufen bzw. verkaufen müssen. Damit finden die zugrundeliegenden Unsicherheiten Berücksichtigung und die unterschiedlichen Methoden werden vergleichbarer.

5.7 Modellumsetzung

Nach der Modellierung der einzelnen Einflussfaktoren und der mathematischen Formulierung des Modells erfolgt in diesem Unterkapitel die Beschreibung der technischen Umsetzung und Implementierung. Zusätzlich wird der Aspekt der Modellstruktur, -komplexität und -ablauf aufgegriffen sowie vereinzelte spezifische Umsetzungen, z. B. die Erstellung einer eigenen Klasse für die KDE oder die Umsetzung als Latin Hypercube basierende SAA Methode, erläutert.

5.7.1 Grundlegende technische Modellbeschreibung

Das entwickelte Modell für den Anwendungsfall des Parkhauses wird sowohl in einer deterministischen als auch in einer stochastischen Optimierung umgesetzt. Zusätzlich wird eine Monte Carlo Simulation für alle Ansätze angewendet, um die zugrundeliegenden stochastischen Profile der PV-Erzeugung, Elektrizitätspreise, Abfahrts- und Ankunftszeiten sowie die vor dem betrachteten Ladeprozess zurückgelegten Fahrdistancen der E-Pkw abzubilden. Das gesamte Modell ist mit Python 3.6 implementiert. Dabei findet sowohl das Erstellen der Wahrscheinlichkeitsverteilungen für die Fahr-

zeugflotten sowie das Einlesen der weiteren Inputparameter und das damit verbundene Datenhandling, als auch die Implementierung der verschiedenen Modellvarianten statt. Das Modell besteht aus verschiedenen hinterlegten Klassen und entsprechend definierten Methoden und Funktionen.

Für die Optimierung wird zum einen auf den Solver Gurobi 7.5 zurückgegriffen und zum anderen auf einzelne Bibliotheken innerhalb von Python, die eine effiziente Gestaltung und Lösbarkeit des Modells ermöglichen. Der Gurobi Solver ist mit einem MIP Gap von 0,01 eingestellt. Des Weiteren wurden der Thread und der Seed auf jeweils 1 gesetzt. Ansonsten wurden die meisten Grundeinstellungen des Solvers übernommen. Die Berechnungen wurden mit einem Windows Betriebssystem und zum größten Teil auf einem Desktoprechner mit Intel i5-2500, 3,3 GHz, sowie 4 Threads durchgeführt. Der Arbeitsspeicher von 16 GB ist dabei schnell ausgelastet, obwohl nur ein Kern für das Multiprocessing vorgesehen wurde. Die Rechenzeiten können reduziert werden, wenn Rechner mit größerem Arbeitsspeicher verwendet werden. Dieses geschieht aufgrund der Ausnutzung von mehreren Kernen und damit der Möglichkeit des parallelen Rechnens.

Die Output Daten werden in einer dokumentenbasierten NoSQL Datenbank (MongoDB) gespeichert. Der Vorteil besteht u. a. darin, dass schon während des Schreibprozesses die Daten ausgelesen werden können. Zusätzlich gibt es aufgrund von schnelleren Lese- und Schreibzugriffen Geschwindigkeitsvorteile. Zum anderen war die dokumentenbasierte Struktur aber erforderlich, da die Daten nicht nur in Tabellenform, also in zweidimensionaler Form gespeichert werden können, sondern die Arrays in mehreren Dimensionen vorliegen. Dieses hat zur Folge, dass die Auswertung etwas komplexer ist und die Dokumente entsprechend ausgepackt werden müssen. Des Weiteren ist MongoDB open source und die am weitesten verbreitetste NoSQL Datenbank (vgl. MongoDB, 2018). Als grafische Oberfläche dient die ebenfalls frei verfügbare Robo 3T (ehemals Robomongo), welche es ermöglicht, die sogenannten Collections (diese Strukturen enthalten die Dokumente) zu sichten und zu bearbeiten.

Zur Visualisierung der in der NoSQL Datenbank (MongoDB) gespeicherten Output Daten werden ebenfalls hauptsächlich verschiedene Bibliotheken von Python (seaborn, matplotlib) verwendet. Ein Teil der genutzten Bibliotheken innerhalb von Python ist in der Tabelle 5.3 dargestellt. Die Grundstruktur des Modells basiert insbesondere auf NumPy, SciPy und Pandas, welche für ein besseres Datenhandling bzgl.

der Darstellung in Arrays, Matrixen, Listen, Tupeln oder Dictionaries, die Modellierung und Implementierung vereinfacht. Ebenfalls eine Spezialbibliothek ist chaospy, die insbesondere für die Konstruktion von abhängigen, multivariaten Zufallsvariablen zum Einsatz kommt. Bei der Erstellung der multivariaten PDF wird die Rosenblatt Transformation genutzt (vgl. Feinberg und Petter, 2015). Zur weiteren effizienten Umsetzung des Modells wurden z. B. Caches angewendet, um die Daten für die Erstellung der Wahrscheinlichkeitsfunktionen nicht jedes Mal neu einlesen und speichern zu müssen. Weiterhin wurde ein paralleles Rechnen und die Nutzung von mehreren Kernen ermöglicht, da durch die Durchführung von vielen Simulationen die Parallelisierung gut möglich ist und die Rechenzeiten verkürzt.

Tabelle 5.3: Auszug der benutzten Bibliotheken in Python

Name	Funktion
NumPy	Numerische Berechnungen
SciPy	Numerische Algorithmen
Pandas	Datenanalyse und -strukturierung
Seaborn	Visualisierung, Plots
Matplotlib	Visualisierung, Plots
Statsmodels	Datenanalyse und Statistik, Verteilungen
Random	Zufallszahlenerzeugung
Scikitlearn	Clustering, GMM und KDE
Gurobipy	Optimierungssolver Schnittstelle
Chaospy	LHS, Joint sampling
CVXPY	Optimierung
Itertools	Effiziente Iterationen
PyDOE	Quasirandom sampling
Tinydb	Zwischenspeicherung von Daten, Cache
Pymongo	Datenbank Schnittstelle
Joblib	Multiprocessing
Pickle	Serialisierung von Objekten
Jupyter Notebook	Browser-basiertes Tool, interaktiver Testbereich

Der Code und die ermittelten Ergebnisse werden mit mehreren Plausibilitätschecks überprüft und validiert. Darunter zählen z. B.:

- Überprüfung der Anzahl bedienter Ladeanfragen und dazugehörig die Einhaltung der gewünschten Mindesterfolgsquote,

- Ermittlung des gesamten Ladebedarfs und Überprüfung, ob identisch mit tatsächlicher eingeplanter Ladeenergie,
- Überprüfung jeder einzelnen Ladeanfrage bzgl. gewünschter Lademenge und erhaltener Lademenge,
- Test der Einhaltung von sowohl lokalem Ladelimit als auch globalem Ladelimit sowie
- Überprüfung der Einhaltung der gesetzten Limits des SOC.

Dadurch konnten mögliche Fehlerquellen eliminiert und die Konsistenz des Codes geprüft werden.

Tabelle 5.4: Überblick zu den Modellgrößen anhand der Anzahl der Variablen und durchschnittlichen Rechenzeiten für die unterschiedlichen Strategien und Kundenanzahl

Ansatz		Anzahl Kunden		
		75	150	225
Unkontrol- liertes Laden	Gleichungen/ Reihen	15.180	29.880	44.580
	Stetige Variablen	7.617	14.892	22.242
	Nicht-Null Elemente	36.930	73.380	109.830
	Binäre Variablen	75	150	225
	Lösungszeit, gesamt in Sekunden	0,02	0,05	0,07
MILP - Benchmark	Gleichungen/ Reihen	14.989	29.689	44.389
	Stetige Variablen	7.596	14.796	22.146
	Nicht-Null Elemente	36.792	73.392	109.992
	Binäre Variablen	150	300	450
	Lösungszeit, gesamt in Sekunden	1,45	5,55	6,37
MILP – Day- Ahead-Vo- raussicht	Gleichungen/ Reihen	14.989	29.689	44.389
	Stetige Variablen	7.596	14.796	22.146
	Nicht-Null Elemente	36.792	73.392	109.992
	Binäre Variablen	150	300	450
	Lösungszeit, gesamt in Sekunden	1,56	5,56	7,18
SMILP	Gleichungen/ Reihen	1.912.339	3.764.389	5.616.439
	Stetige Variablen	950.121	1.876.146	2.802.171
	Nicht-Null Elemente	4.674.117	9.276.042	13.877.967
	Binäre Variablen	9.450	18.900	28.350
	Lösungszeit, gesamt in Sekunden	338,44	1276,81	8656,83

Die Tabelle 5.4 stellt ein Beispiel für eine Parametrisierung mit einer Ladeleistung (z. B. 11 kW), einer Anschlussleistung (z. B. 200 kW), nur Sommerpreise sowie 125 SAA Szenarien dar. Es wird in jedem Modell mit 150 Tagen in den Sommermonaten simuliert² und dementsprechend vergrößert sich die Anzahl der Variablen, sowie die Rechenzeiten linear. Die Modellkomplexität vom SMILP erklärt sich aufgrund der Tatsache, dass im SMILP 125 SAA Szenarien enthalten sind, wodurch ein Vielfaches (Anzahl der SAA Szenarien) an Variablen benötigt wird. Das Verhältnis der Rechenzeiten ändert sich fast proportional zur Anzahl der gewählten Simulationsläufe. So beläuft sich die Rechenzeit beim SMILP Ansatz mit 150 Kunden für eine Instanz auf ca. 21 Minuten, werden die 150 Durchläufe betrachtet, sind es ca. 53 Stunden. Das sind die Rechenzeiten, wenn nur eine Parametrisierung betrachtet wird. Werden Listen von Parametern abgefragt (z. B. mehrere Anschlussleistungen), erhöht sich die Rechenzeit entsprechend. Die Anzahl der Variablen steigt ebenfalls mit einer zunehmenden Kundenanzahl, was für die verschiedenen untersuchten Methoden mit den drei Kundenkonstellationen von 75, 150 und 225 dargestellt wurde.

5.7.2 Modellstruktur und -umsetzung

Damit es einen Überblick gibt, wie die einzelnen zuvor vorgestellten Abschnitte miteinander interagieren, wird mit der Abbildung 5.16 eine kurze Übersicht eingeführt, um den Zusammenhang aller Komponenten, die für das Modell relevant sind zu verdeutlichen.

² Anzahl der Simulationen ermittelt sich aus Konvergenztests, siehe Anhang A.

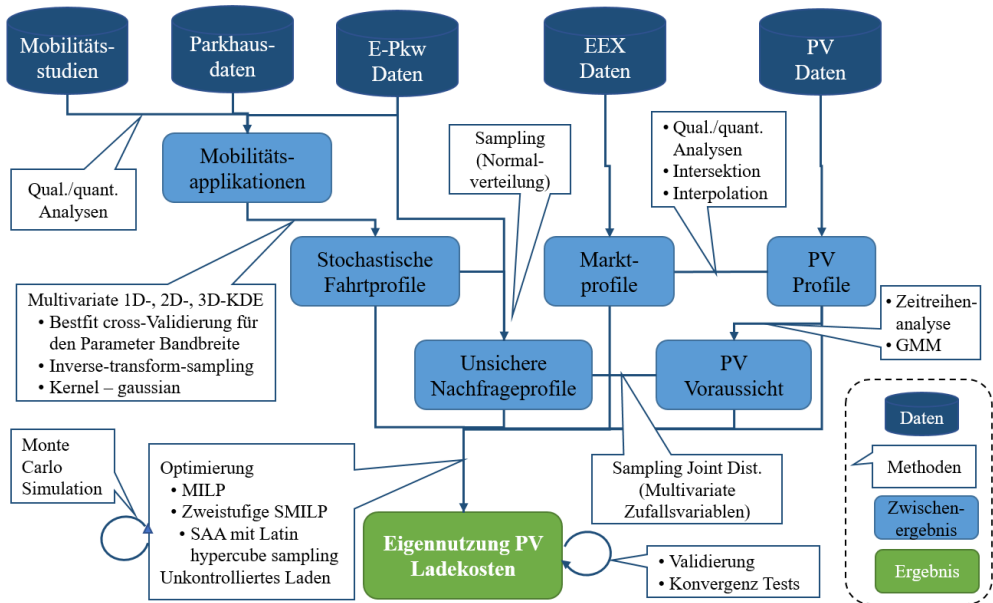


Abbildung 5.16: Zusammenhang der Modellkomponenten

Der grundlegende Ablauf des entwickelten Modells lässt sich wie folgt beschreiben. Zunächst werden sowohl die realen Parkhausdaten als auch die Daten aus den jeweiligen Studien in Ladeanfragen für die drei elektromobilen Flotten umgewandelt und mit einer Wahrscheinlichkeitsverteilung hinterlegt. Für die Erstellung der stochastischen Fahrprofile der einzelnen Kunden der E-Pkw Flotten werden dann die 1D, 2D oder 3D KDE genutzt. Die Ausgangsdaten werden entsprechend der gewählten Modellvarianten um weitere Inputdaten (EPEX SPOT-Preise, erzeugter PV-Strom) erweitert, damit die jeweiligen Forschungsfragen mit der stochastischen Optimierung auch unter Unsicherheit vereinzelter Parameter beantwortet werden können. Für die unsicheren Nachfrageprofile werden die zunächst eingeplanten Energienachfragen mit einem normalverteilten Rauschen belegt. Die PV-Kurvenvorhersage ergibt sich aus den unterschiedlichen Prognoseverfahren für PV. Es wird ein beliebiger Werktag simuliert. Dabei werden die Ladeanfragen für die drei E-Pkw Flotten zufällig erstellt und entsprechend aus den Wahrscheinlichkeitsverteilungen gezogen. Es wird ein EPEX SPOT-Preis zufällig gezogen (mit der zuvor festgelegten Unterscheidung zwischen Sommer und Winter). Daran gekoppelt sind die dazugehörigen erwarteten Erzeugungswerte von der PV-Anlage. Dieses Vorgehen wird entsprechend der gewählten Anzahl an Simulationsläufen mit einer MCS für alle Ansätze wiederholt. Es werden jeweils die Ladekosten der drei Ansätze (Unkontrolliertes Laden, MILP,

SMILP) unter der Berücksichtigung der drei PV-Vorhersagemodelle (Perfekte Voraussicht, Day-Ahead, GMM-basiert) berechnet. Abschließend finden noch Validierungs- sowie Konvergenztests statt.

Im Anschluss werden die Ergebnisse ausgewertet und visualisiert. Dafür wurde wieder eine Vielzahl an Skripten geschrieben, um die Daten in einer entsprechenden Form vorliegen zu haben, die gewährleistet, dass die jeweiligen Fragestellungen beantwortet werden können.

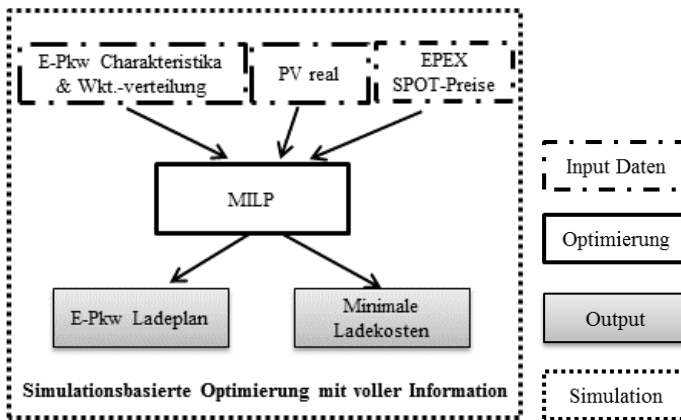


Abbildung 5.17: Überblick über den Ablauf der deterministischen Optimierung mit perfekter Information

Abbildung 5.17 veranschaulicht noch einmal die grundlegende Struktur des entwickelten Modells ohne Unsicherheiten, also den Benchmark der Optimierung mit perfekter Information, d. h. es werden die Realisierungen eines Tages genutzt. Die Eingangsdaten von E-Pkw, PV real und EPEX SPOT-Preise sind alle mit stochastischen Profilen hinterlegt. Dafür wird eine MCS durchgeführt. Dabei wird beim MILP der reale Ladebedarf entsprechend der gezogenen Anfragen eingeplant und der real erzeugte Strom aus PV findet Berücksichtigung. Zusätzlich wird eine EPEX SPOT-Preiskurve genutzt, um damit die Ladeanfragen kostenminimal einzubeziehen. Daraus ergibt sich der E-Pkw Ladeplan, also zu welchem Zeitpunkt die E-Pkw mit wie viel Energie geladen werden. Das Ergebnis des MILP sind die minimalen Ladekosten, welche gleichzeitig den Zielfunktionswert WS (vgl. Abschnitt 3.5.4.1) darstellen, welcher mit den anderen Modellvariationen verglichen wird.

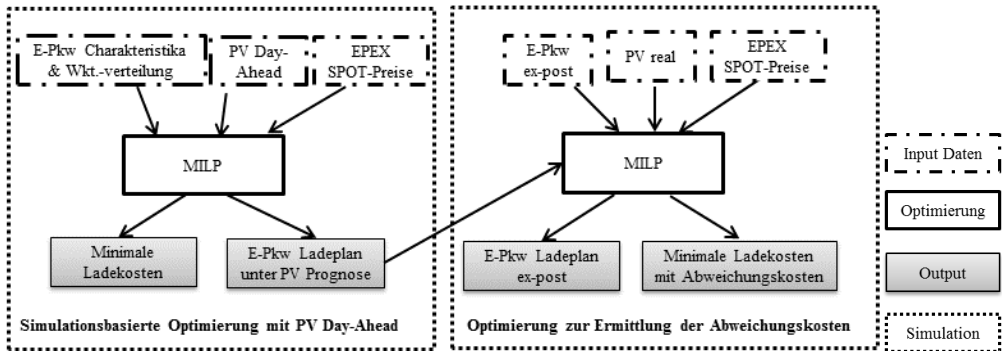


Abbildung 5.18: Überblick über die Optimierung für das Modell mit der Day-Ahead PV-Voraussicht

Für das Modell mit der Day-Ahead PV-Voraussicht werden die Abweichungskosten eingeführt, wie in dem rechten Teil der Abbildung 5.18 dargestellt. Zunächst wird, wie im linken Teil der Grafik abgebildet, der Tag mit den entsprechend vorliegenden Anfragen und der Day-Ahead PV-Prognose eingeplant, ohne dass schon Abweichungskosten berücksichtigt werden. In diesem Modell finden die Unsicherheiten noch keine Beachtung. Im zweiten Schritt werden die Abweichungskosten zwischen den tatsächlich eingetretenen Realisierungen und dem eingeplanten Tag wieder durch ein MILP ermittelt. Dadurch ergeben sich im Anschluss die minimalen Ladekosten inkl. Abweichungskosten.

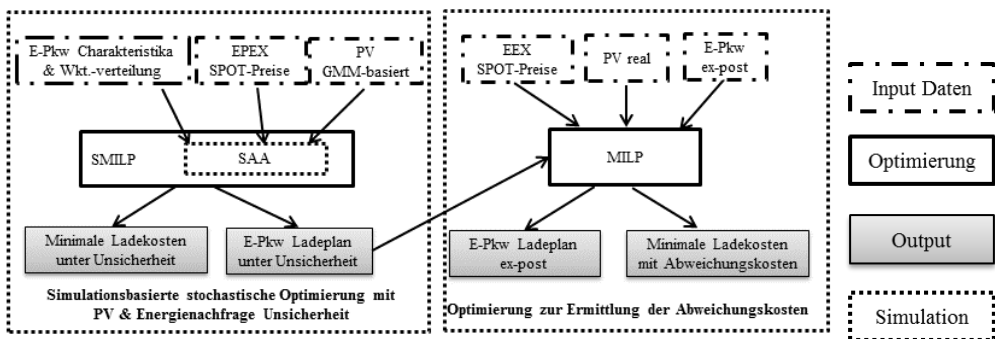


Abbildung 5.19: Überblick über die stochastische Optimierung unter Berücksichtigung der Unsicherheiten der Energienachfrage und der PV-Stromerzeugung

In dem linken Teil der Abbildung 5.19 ist der strukturelle Ablauf der zweistufigen stochastischen Optimierung dargestellt. Es werden zunächst die Ladeanfragen ent-

sprechend kostenminimal unter der Annahme eingeplant, dass Abweichungen am realisierten Tag eintreten können. Die Unsicherheiten und die damit zu berücksichtigenden Abweichungskosten sowohl für die Energienachfrage der Fahrzeuge als auch des erzeugten PV-Stromes werden mit der SAA Methode approximiert. Als Ergebnis steht ein E-Pkw Ladeplan mit dem entsprechend eingeplanten Strom unter Unsicherheit und die dafür benötigten minimalen Ladekosten. Am Durchführungstag treten die tatsächlichen Ladeanfragen (E-Pkw ex-post) und die PV Realisierung ein. Diese werden als Input genutzt, genauso wie der bereits eingeplante Strom, um nun die zusätzlichen minimalen Abweichungskosten mit einem MILP zu bestimmen, die zur Bedienung der tatsächlichen Ladeanfragen notwendig sind. Daraus ergeben sich dann die gesamten minimalen Ladekosten und dazugehörigen Abweichungskosten.

Es wird angenommen, dass am Tag der Realisierung die Abweichungskosten zum Einkaufen bzw. Verkaufen von Strom entsprechend der Parameter a und b und der Day-Ahead Preiskurve bewertet werden. Für den Parameter a wird eine Verdopplung und für den Parameter b eine Halbierung des Strompreises angenommen. Somit ist eine Vergleichbarkeit der beiden Methoden mit den PV-Varianten (PV Day-Ahead-Vorhersage, PV GMM-basierte Vorhersage) und die daraus ermittelten Ladekosten zuzüglich der Abweichungskosten gegeben. Dadurch können die entsprechenden Ladekurven zusätzlich beurteilt werden.

5.7.3 Latin Hypercube Sampling

In Abschnitt 3.5 wurde bereits die Modellierung des SMILP vorgestellt. Dazu zählt ebenfalls die Umsetzung der SAA Methode mit dem Latin Hypercube Sampling anstelle des Monte Carlo Samplings. Dieses beruht auf der Tatsache, dass die LHS Methode schneller konvergiert und dabei den geringeren Stichprobenfehler hat. Der Stichprobenfehler ist vom MCS proportional zu $1/N$ hingegen der für LHS proportional zu $1/\sqrt{N}$ (vgl. Kroese et al., 2011; Aisleitner et al., 2012). Mit anderen Worten, für die gleiche Genauigkeit der Ergebnisse werden mit LHS N und mit MCS N^2 Stichproben benötigt, somit ist LHS quadratisch schneller. In dieser Arbeit werden 125 SAA Szenarien durchgeführt, demnach liegt der Stichprobenfehler bei $1/125$, also 0,008. In der folgenden Tabelle 5.5 ist die Ergebnisgenauigkeit beider Methoden mit 125 SAA Szenarien und 150 durchgeführten Simulationen dargestellt für das Ergebnis des SMILP. Aufgrund der 150 Simulationen ist die Streuung bei beiden Methoden recht hoch, was sich in einer hohen Standardabweichung widerspiegelt. Dennoch lässt

sich erkennen, dass die LHS sowohl im Mittelwert (Mean), als auch bei der Standardabweichung geringere Werte aufzeigt und somit zur Varianzreduktion beiträgt. Diese erhöht die Ergebnisgenauigkeit, wenngleich die Unterschiede gering ausfallen.

Tabelle 5.5: Vergleich der Ergebnisse des SMILP Ansatzes unter Anwendung der LHS und MCS Methode

	Mean	Standardabweichung	25 %-Quantil	75 %-Quantil
LHS	10,1	6,2	5,5	13,1
MCS	10,2	6,4	5,6	13,2

5.7.4 Implementierung der Wahrscheinlichkeitsverteilung – Kerndichteschätzer

Damit die verschiedenen vorhandenen Daten der Fahrzeuge genutzt werden können, müssen diese in ein entsprechendes Format übertragen werden. Dafür sind eigene Klassen definiert und implementiert, um die Daten jeweils in das Format einer 1D, 2D oder 3D KDE zu bringen (vgl. Abschnitt 5.2). Ein weiterer Vorteil der eigenen Implementierung der KDE stellt das Einführen von Cache Möglichkeiten dar. Dadurch wird die Datenanpassung und anschließend die gebildete KDE in einem Zwischenspeicher abgelegt. Auf die einmal erstellten Verteilungen der KDE kann nun für jede Simulation zurückgegriffen werden, ohne dass diese jedes Mal neu ermittelt werden müssen. Die eigenen Klassen waren weiterhin notwendig, um z. B. mit einem Best Fit Algorithmus über die Kreuzvalidierung mit ML-Schätzer die optimale Parameterbestimmung der Bandbreite zu ermitteln. Ebenfalls war dafür die Erstellung von bedingten Verteilungen (mit Hilfe der Randverteilungen) für die Zufallsvariablen notwendig. Somit wird im Falle der 2D und 3D KDE eine multivariate Schätzung angewendet. Dadurch können strukturelle Merkmale in den Daten aufgedeckt werden, die ein parametrischer Ansatz möglicherweise nicht offenbart (vgl. Silverman, 1998).

6 Modellgestützte Analysen der Fallstudie

Dieses Kapitel beschreibt die Anwendung des erstellten Forschungsansatzes mit den dazugehörigen Modellen und die daraus gewonnenen Ergebnisse aus den untersuchten Methoden und Analysen für die Fallstudie.

Ein wesentlicher Aspekt sind dabei die LVP der verschiedenen elektromobilen Flotten und die Auswirkungen, die sich durch verschiedene Einflussgrößen ergeben. Im Abschnitt 6.1 wird sich mit dieser Thematik auseinander gesetzt. Die detaillierte Flottenbetrachtung erfolgt im Abschnitt 6.2. Die Bewertung der Unsicherheiten und damit einhergehend der methodische Vergleich inklusive der PV-Vorhersagemodelle wird im Abschnitt 6.3 abgehandelt. Der Abschnitt 6.4 widmet sich den Ergebnissen zur Integration der erneuerbaren Energien und damit verbundenen CO₂-Vermeidungspotenzialen. Hierbei wird mit Hilfe einer Simulation eine Sensitivitätsanalyse angewendet, welche die Abhängigkeiten der erzielten Ergebnisse, insbesondere des stochastischen Ansatzes, von ausgewählten unsicheren Eingangsparametern bewertet. Der Abschnitt 6.5 stellt einen kurzen Exkurs zum Thema möglicher Geschäftsmodelle für Parkhausbetreiber dar. Teilweise beruhen Inhalte in diesem Abschnitt auf eigenen Vorarbeiten aus der Veröffentlichung von Seddig et al. (2019a). Den Abschluss des Kapitels bildet Abschnitt 6.6 mit einer kritischen Würdigung und einer entsprechenden Einordnung der Ergebnisse in die bestehende Literatur.

6.1 Lastverschiebepotenzial elektromobiler Flotten

In diesem Abschnitt werden Untersuchungen von verschiedenen Einflussfaktoren auf das LVP von E-Pkw Flotten durchgeführt. Es werden die Auswirkungen von Ladeleistungen, Preissignalen, Anschlussleistungen, des Energieverbrauchs sowie der Größe des PV-Moduls auf das Ladeverhalten näher untersucht. Dabei werden die Ergebnisse des MILP mit perfekter Voraussicht und als Vergleichswerte die des Referenzfalls des unkontrollierten Ladens herangezogen. Bei beiden Methoden beträgt die Flottengröße jeweils 50 Kunden pro E-Pkw Flotte, also insgesamt 150 Kunden. Es wurden 150 Simulationen betrachtet, damit den hinterlegten Wahrscheinlichkeitsver-

teilungen Rechnung getragen wird. Sofern nicht anders angegeben, wurden die folgenden Werte für die Parameter für alle E-PKW Flotten angenommen: ein durchschnittlicher Energieverbrauch von 0,2 kWh/km, 200 kW Anschlussleistung, 22 kW Ladeleistung (welche zwischen 0 und 22 kW beliebig variierbar ist) sowie EPEX SPOT-Preise aus den Sommermonaten und ein PV-Modul, abgestimmt auf die Größe des Parkhausdaches.

6.1.1 Unkontrolliertes Laden

Als Ausgangssituation wird der Referenzfall des unkontrollierten Ladens der drei E-Pkw Flotten untersucht. Die dargestellten Lastkurven in Abbildung 6.1 entsprechen der Parametrisierung mit einer angenommenen maximalen Ladeleistung von 22 kW. Dabei spiegelt sich im Lastprofil der drei einzelnen Flotten das hinterlegte Fahr- bzw. Ladeverhalten wider. Die Mittelwerte der Lastkurven der jeweiligen Flotten sind durch die durchgezogene Linie dargestellt. Es wird aus Wahrscheinlichkeitsverteilungen, sowohl bei den drei Flotten, als auch beim EPEX SPOT-Preis und bei dem erzeugten PV-Strom gezogen. Um damit die durchgeführten 150 Simulationen abzubilden, gibt es ebenfalls einen schattierten Bereich, welcher das obere und untere Quartil repräsentiert. Diese Darstellungsart wird in den nächsten Abbildungen beibehalten. Die in Abschnitt 5.2 hinterlegten Charakteristika lassen sich erkennen. Pendler (Dauerparker) kommen in den frühen Morgenstunden am Parkhaus an, beginnen sofort den Ladevorgang und erreichen zu diesen Stunden ihre Ladespitzen. Die Kurzzeitparker (Gelegenheitsparker) suchen ein Parkhaus insbesondere in den Nachmittagsstunden auf und dementsprechend ist der Ladebedarf zu dieser Zeit am höchsten. Die Unternehmensflotte kommt über den ganzen Tag verteilt zurück zum Laden, deshalb erstreckt sich ein größeres Ladefenster mehr über den Tag verteilt, dennoch gibt es insbesondere am Nachmittag die Lastspitzen. Der Verlauf der Lastkurve der Unternehmensflotte resultiert aus der Annahme q) von 3.4.1, dass die eine Hälfte der Flotte nach der Ankunft und vor Mitternacht lädt, die andere Hälfte lädt vor der Abfahrt ab 0:00 Uhr. Das ist auf dem Zeitfenster der Betrachtung von 0 bis 24 Uhr zurückzuführen, da dennoch das Ladeverhalten über Nacht dargestellt werden soll. Die 200 kW Ladeleistung zu Beginn beruht auf der Begrenzung durch die Anschlussleistung und der Tatsache, dass alle angeschlossenen E-Pkw sofort mit Laden beginnen.




Abbildung 6.1: Unkontrollierte Lastkurve der drei E-Pkw Flotten mit 22 kW Ladeleistung (Linie – Mittelwert; schattierter Bereich – 25 %- und 75 %-Quantil)

6.1.2 Auswirkungen von Ladeleistungen

Bei der Betrachtung der verschiedenen Ladeleistungen werden die Anfragen angepasst, da sich die Ladezeiten entsprechend ändern. Damit wird weiterhin die Nebenbedingung – Parkdauer ist länger als die Ladedauer – erfüllt. Erkennlich wird in den nächsten beiden Grafiken (Abbildung 6.2, Abbildung 6.3), dass die Lastkurven geringere kumulierte Peaks bei den niedrigeren Ladeleistungen von z. B. 3,7 oder 11 kW haben. Bei letzterem ist es weniger stark ausgeprägt. Der Vergleich der drei Ladeleistungen zeigt, wie zeitlich unterschiedlich die Ladevorgänge sind. So ist beispielsweise die Unternehmensflotte schon gegen 1 Uhr am morgen bei 22 kW und nicht erst gegen 5 Uhr wie bei 3,7 kW mit dem Ladevorgang fertig. Bei den Dauerparkern ist die Fertigstellung des Ladevorgangs schon gegen 11 Uhr beendet (22 kW), bei 3,7 kW dagegen zieht es sich bis 14 Uhr bzw. 15 Uhr hin. Auffällig ist zudem, dass die Anschlussleistung bei 3,7 kW nicht ausgenutzt wird und nur in den frühen Morgenstunden einen maximalen Peak von ca. 100 kW aufzeigt.




Abbildung 6.2: Unkontrollierte Lastkurven für die drei E-Pkw Flotten mit jeweils 3,7 kW Ladeleistung




Abbildung 6.3: Unkontrollierte Lastkurven für die drei E-Pkw Flotten mit jeweils 11 kW Ladeleistung

Die Ladeleistungen haben insbesondere bei der Optimierung nach Preis Auswirkungen auf die Ladekosten. Bei FCFS können die Kosten nicht beeinflusst werden, da die E-Pkw sofort laden, unabhängig wie hoch der Preis gerade ist. Bei der optimierten Lastkurve hingegen werden die E-Pkw zu den niedrigeren Preisen geladen. Der Vorteil einer höheren Ladeleistung liegt darin, dass unter Berücksichtigung der Nebenbedingungen die niedrigeren Preise besser genutzt werden können, weil eine höhere Leistung zu diesem Zeitpunkt abgerufen werden kann. Der Vorteil ist aber nur marginal. Die Abbildung 6.4 stellt die durchschnittlichen Stromkosten der drei Flotten unter Berücksichtigung der drei verschiedenen Ladeleistungen mit Hilfe eines Violinplots dar.

Der Violinplot ist eine Kombination aus Boxplot und Dichtepplot. Somit wird zusätzlich, im Vergleich zum Boxplot, die Kerndichtevertelung der Datenpunkte dargestellt. Vier Informationen können aus dem Violinplot abgelesen werden. Das sind der Median, repräsentiert durch den Punkt in der Mitte, das obere und untere Quartil, durch die breitere vertikale Linie dargestellt, welches 50 % der Daten repräsentiert. Die Dicke des Umrisses stellt zum einen die Häufigkeit der Datenpunkte dar und zum anderen beinhaltet der Violinplot die Datenpunkte zwischen dem 2,5 %- und 97,5 %-Quantil. Es werden also 95 % der auftretenden Daten abgebildet (vgl. Hintze und Nelson, 1998).

In der Abbildung 6.4 zeigt der Median an, dass die durchschnittlichen Ladekosten mit zunehmender maximalen Ladeleistung eine sinkende Tendenz haben. Dieser Trend ist über die drei elektrmobilen Flotten hinweg erkennbar. Die Form und damit die Verteilung der einzelnen Datenpunkte der jeweiligen Kundengruppen ist je Flotte ähnlich, unterscheidet sich aber zwischen den drei Flotten. So gibt es bei den Dauerparkern eine größere Spannbreite der durchschnittlichen Kosten und bei der Unternehmensflotte die geringste. Des Weiteren können die Kunden der Unternehmensflotte im Durchschnitt die günstigsten Strompreise nutzen, die Gelegenheitsparker die teuersten. Die Erkenntnisse lassen sich gut anhand des Parkverhaltens der jeweiligen Nutzergruppe erklären. Die Gelegenheitsparker haben die kürzesten Aufenthaltsdauern und damit die geringste Flexibilität bzgl. der Lastverschiebung. Zudem müssen diese zu Zeiten laden, wo die Strompreise tendenziell höher sind. Die Unternehmensflotte kann wiederum auf günstige Strompreise in der Nacht zurückgreifen. Dauerparker können sich den PV-Strom zu Nutze machen und dadurch ihre Ladekosten reduzieren. Je nach Verfügbarkeit des erzeugten PV-Stromes schwanken auch die Ladekosten der Dauerparker.

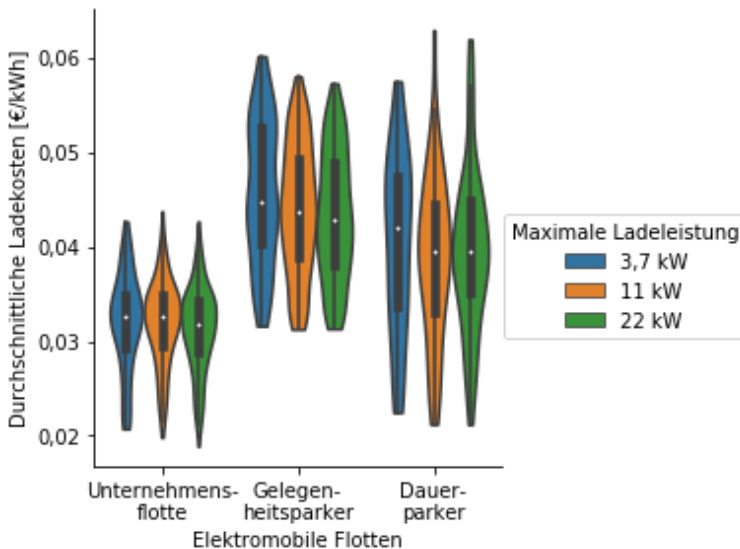


Abbildung 6.4: Optimierung: Violinplot der durchschnittlichen Ladekosten der verschiedenen Flotten und lokalen Ladeleistungen (3,7; 11; 22 kW)

6.1.3 Einfluss von Preissignalen

Verschiedene Preissignale haben bei der Optimierung einen erheblichen Einfluss auf die Ladekosten und den Ladezeitpunkt der einzelnen E-Pkw. In diesem Abschnitt wurde exemplarisch zwischen den durchschnittlich gebildeten Winter- und Sommerpreisen der EPEX SPOT unterschieden. Die folgenden beiden Grafiken (Abbildung 6.5 und Abbildung 6.6) stellen den Kurvenverlauf der drei elektromobilen Flotten für den optimierten Fall hinsichtlich maximaler Ausnutzung des erzeugten PV-Stromes und minimaler Ladekosten dar. Dabei lässt sich bei beiden Jahreszeiten erkennen, dass nicht nur die Strompreise einen unterschiedlichen Verlauf haben, sondern auch die PV Kurve des erzeugten Stromes in den Wintermonaten viel flacher verläuft. Die EPEX SPOT-Strompreise im Winter unterliegen stärkeren Schwankungen als die im Sommer. Soweit es die jeweiligen Aufenthaltsdauern der elektromobilen Flotten zulassen, werden sie zu den niedrigeren EPEX SPOT-Preisen geladen. Somit ergeben sich insbesondere dann Ladepicks der E-Pkw, wenn die EPEX SPOT-Preise niedrig sind oder ausreichend erzeugter PV-Strom vorhanden ist. In den Wintermonaten werden die Aufenthaltsdauern der Kunden viel mehr genutzt, um noch von niedrigen EPEX SPOT-Preisen zu profitieren. Von daher unterscheiden sich die Lastkurvenverläufe der einzelnen Gruppen im Winter und im Sommer.




Abbildung 6.5: Optimierte Lastkurven der Flotten basierend auf dem durchschnittlichen Sommer EPEX SPOT-Preis




Abbildung 6.6: Optimierte Lastkurven der Flotten basierend auf dem durchschnittlichen Winter EPEX SPOT-Preis

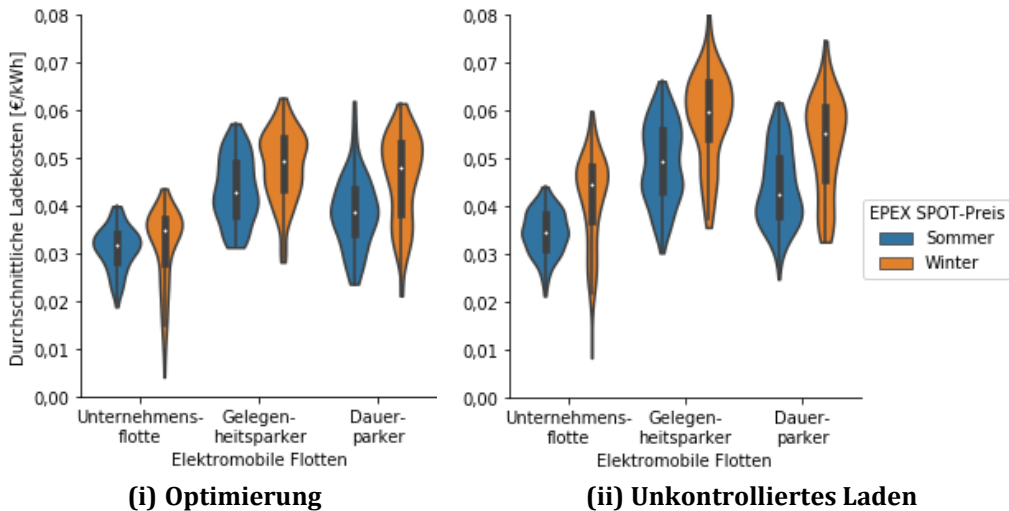


Abbildung 6.7: Violinplot der durchschnittlichen Stromkosten je Flotte für Sommer vs. Winter EPEX SPOT-Preise, links (i) Optimierung, rechts (ii) Unkontrolliertes Laden

Die Abbildung 6.7 verdeutlicht noch einmal die gewonnenen Erkenntnisse aus den vorausgehenden Darstellungen. Die durchschnittlichen Ladekosten sind im Winter bei jeder elektromobilen Flotte höher als im Sommer. Die Streuung im Winter ist größer bei jeder Flotte. Insbesondere bei der Unternehmensflotte gibt es minimale Ladekosten von knapp 0,01 ct/kWh. Die geringen Werte gehen mit den Strompreisen im Winter einher, denn die Strompreise können in den Nachtstunden sehr niedrig sein. Werden die Ergebnisse der (i) Optimierung mit den Werten des (ii) Unkontrollierten Ladens verglichen, wird deutlich, dass die Kosten beim Referenzfall für jede Flottengruppe höher sind. Der Trend, dass die Unternehmensflotte die niedrigsten und die Gelegenheitsparker die höchsten durchschnittlichen Kosten haben, spiegelt sich auch in dieser Abbildung wider. Die Erläuterung dazu ist analog zu Abschnitt 6.1.2 und beruht auf den hinterlegten Flottencharakteristika.

Anstelle von Sommer- und Winterpreisen können ebenfalls andere Preissignale genutzt werden. Eine Lastverschiebung der Flotten kann durch die Optimierung hinsichtlich verschiedener Zielgrößen durchgeführt werden.

6.1.4 Einfluss von Anschlussleistungen

Dieser Abschnitt untersucht den Einfluss der globalen Anschlussleistung, welche durch den Transformator bestimmt wird, näher. Sowohl im Falle der Optimierung

(Abbildung 6.8) als auch bei dem unkontrollierten Laden (Abbildung 6.9) haben die drei gewählten Anschlussleistungen (150, 200 und 250 kW) keinen signifikanten Einfluss auf die gesamten Ladekosten der elektrmobilen Flotten. Bei 150 Kunden erreichen die Lastkurven in beiden Fällen fast nie die globale Anschlussleistung von 200 kW. Dadurch ist es bei dieser Konstellation an Parametern nicht verwunderlich, dass die Änderung der Anschlussleistung keine Auswirkungen auf die gesamten Ladekosten hat. Beispielsweise können Zeiten von Niedrigpreisen weiterhin von allen drei Flotten zum Laden genutzt werden. Demnach sind die Violinplots ähnlich. Der Median der gesamten Ladekosten aller Flotten ist im Falle der Optimierung geringer als beim unkontrollierten Laden. Signifikant sind die Unterschiede bei der Unternehmensflotte und den Dauerparkern. Werden die Lastpeaks aus der Abbildung 6.5 näher betrachtet, so ist ersichtlich, dass diese im Mittel erst bei 50 kW ihre Peaks erreichen. Daher würden Änderungen der Anschlussleistung insbesondere in den niedrigeren Größenordnungen von 50 kW Auswirkungen haben.




Abbildung 6.8: Optimierung: Violinplot zum Vergleich der Ladekosten für alle Flotten zusammen je Anschlussleistung (150, 200, 250 kW)

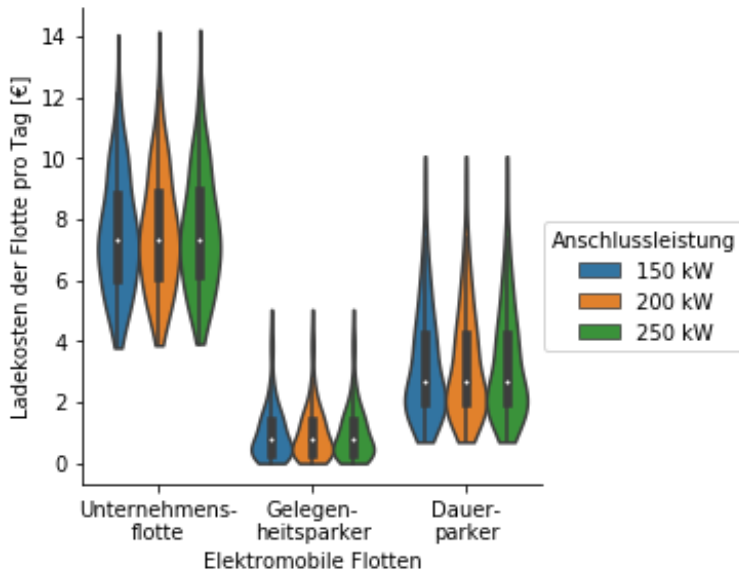


Abbildung 6.9: Unkontrolliertes Laden: Violinplot der Ladeposten für alle Flotten zusammen je Anschlussleistung (150, 200, 250 kW)

Die Kosten der Anschlussleistung sind insbesondere für den Parkhausbetreiber interessant. Die Jahresrechnung des in diesem Fallbeispiel genutzten Parkhauses beruht auf dem maximalen genutzten Wert der Anschlussleistung. Ein Beispiel dazu, wird einmal im Jahr an einem Tag 190 kW Leistung abgerufen und die restlichen Tage im Jahre nicht mehr als 150 kW, so muss dennoch 190 kW bezahlt werden. Somit ist es aus der Sicht eines Parkhausbetreibers wirtschaftlich sinnvoll, die Anschlussleistung recht konstant zu nutzen und keine einmaligen Lastpeaks im Jahr zu haben.

6.1.5 Auswirkungen der PV-Stromerzeugung

Die Erzeugung des Stromes aus PV hat in diesem Fallbeispiel einen großen Einfluss, da die Kosten zum Laden für die elektromobilen Flotten mit 0 €/kWh angesetzt werden. In dem Fallbeispiel des Parkhauses sind 150 Kunden angenommen worden. Für die beiden nachfolgenden Abbildungen ist die vorherrschende PV-Stromerzeugung als Skalierung ‚mittel‘ bezeichnet worden. Die Abbildung 6.10 verdeutlicht den Einfluss der Größe der PV-Module im Falle der Optimierung. Die gesamten Ladeposten aller Flotten halbieren (verdoppeln) sich, wenn ein großes (kleines) PV-Modul be-

trachtet wird. Die höchsten absoluten Kosteneinsparpotenziale hat die Unternehmensflotte, aufgrund des größten absoluten Energiebedarfs zum Laden der E-Pkw. Als Einschränkung ist die fehlende Betrachtung der Investitionen zu nennen.

Im Vergleich zum Referenzfall des unkontrollierten Ladens in der Abbildung 6.11 fällt auf, dass die Reduktion der Ladekosten nicht so stark ausgeprägt ist. Insbesondere die Dauerparker können ihre Ladekosten reduzieren. Weitere Ausführungen zum Thema PV-Integration und CO₂-Emissionen werden in Abschnitt 6.4 abgehandelt.




Abbildung 6.10: Optimierung: Violinplot der Ladekosten je Flotte basierend auf drei unterschiedlich großen PV-Modulen




Abbildung 6.11: Unkontrolliertes Laden: Violinplot der gesamten Ladekosten je Flotte basierend auf drei unterschiedlich großen PV-Modulen

6.2 Flottenbetrachtung

In diesem letzten Abschnitt zur Auswertung der Fallstudie werden die drei E-Pkw Flotten im Detail untersucht. Dabei werden ebenfalls die Unterschiede aufgezeigt, wenn es insgesamt 75 vs. 150 vs. 225 Kunden sind und von jeder Flotte gleich viele Fahrzeuge vertreten sind. Dabei liegt ein Schwerpunkt auf den entstehenden Stromkosten und der andere Fokus liegt auf dem Strombezug. Die Parametrisierung der Simulationen bleibt bis auf die wechselnde Anzahl der Kunden wieder gleich wie schon in den vorangestellten Abschnitten. Dabei werden methodisch erneut der Referenzfall des unkontrollierten Ladens und der Benchmark der Optimierung gegenübergestellt.

Neben der am Anfang definierten Forschungsfrage (III) zum LVP von verschiedenen E-Pkw Flotten in Bezug auf die Ladekosten und den Vergleich des unkontrollierten Ladens mit einer wirtschaftlich optimierten Ladestrategie, werden noch die folgenden spezifischeren Fragen untersucht:

- III.a Welche Faktoren haben einen Einfluss auf das LVP der E-Pkw Flotten?
- III.b Wie gut können die individuellen E-Pkw Flotten zum Lastmanagement genutzt werden?

6.2.1 Netznutzung

Die Abbildung 6.12 zeigt für die je 50 Flottenkunden das Verhältnis der Aufteilung der Energienachfrage nach der Stromquelle. Die Unternehmensflotte hat zum einen den größten Bedarf und deckt diesen fast gleichwertig durch Strom vom Netz, als auch von der PV-Anlage ab. Bei den anderen beiden Flotten ist der Energiebedarf geringer und wird größtenteils durch den erzeugten PV-Strom abgedeckt. Die Dauerparker nutzen den PV-Strom am meisten. Rund 200 kWh können nicht von dem erzeugten PV-Strom zum Laden abgedeckt werden und müssen von den drei Flotten insgesamt vom Netz bezogen werden.




Abbildung 6.12: Optimierung: Violinplot der Ausnutzung des erzeugten PV-Stromes sowie der Anteile vom Netz zum Laden für die einzelnen Flotten mit insgesamt 150 Kunden

Die Abbildung 6.13 stellt analog zur vorherigen Grafik das Verhältnis der genutzten Stromquellen dar. Dieses aber einmal für insgesamt (i) 75 Kunden und (ii) 225 Kunden der drei Flotten. Nicht untypisch ist, dass aufgrund der Skalierung der Kunden die Energienachfrage sich entsprechend verringert, wenn es nur 75 Kunden und sich erhöht, wenn es 225 Kunden sind. Die Verteilung zwischen den beiden Stromquellen PV und Netz verändert sich innerhalb der einzelnen Flotten und Kundenanzahl. Entsprechend ändern sich die Mediane, Quartile und Form des Violinplots. Die Ausnutzung des erzeugten PV-Stromes ist bei 150 Kunden fast bei 100 % (vgl. Abbildung

6.18). Daher ist es nicht überraschend, dass das genutzte Verhältnis des Stromes bei 75 Kunden höher liegt und mit steigender Kundenzahl abnimmt. Somit wird bei 225 Kunden viel Strom vom Netz nachgefragt, insbesondere bei der Unternehmensflotte, welche den größten Ladebedarf von allen drei Flotten hat. Interessant ist festzustellen, dass bei 225 Kunden die Unternehmensflotte ähnlich viel PV-Strom nachfragt, wie die Gelegenheitsparker. Stände mehr PV-Strom zur Verfügung, dann würde die Unternehmensflotte wieder mehr Strom von PV beziehen. Die unterschiedliche Verteilung der Auslastung beider Stromquellen durch die drei Flotten beruht auf der Annahme, dass es keine Priorität zwischen den drei Flotten gibt.




Abbildung 6.13: Optimierung: Violinplot der Ausnutzung des erzeugten PV-Stromes sowie der Anteile vom Netz zum Laden für die einzelnen Flotten mit insgesamt (i) 75 Kunden, links und (ii) 225 Kunden, rechts

Durch die Violinplotdarstellung von Abbildung 6.14 wird deutlich, dass beim unkontrollierten Laden die Ausnutzung des PV-Stromes bei allen drei Flotten geringer ist als bei der Optimierung. Demnach ist der Anteil der Energienachfrage vom Netz, besonders bei der Gruppe der Dauerparker, höher. Das Ergebnis lässt sich mit der Zielfunktion der Optimierung begründen, da diese den extern benötigten Strom vom Netz

zu minimalen Kosten einplant und versucht den erzeugten PV-Strom maximal auszunutzen. Die Flotte der Dauerparker bleibt weiterhin die Gruppe mit dem größten Ausnutzungspotenzial des erzeugten PV-Stromes.

Bezugnehmend auf die Forschungsfrage (III.b) kann festgestellt werden, dass die Verschiebung hinsichtlich der Erzeugung des PV-Stromes insbesondere durch die Dauerparker bei 150 Kunden möglich ist. Der Anteil der Ausnutzung von PV erhöht sich von 63 % auf 94 % innerhalb dieser Flotte. Die Gelegenheitsparker sind sowohl bei der Optimierung als auch beim Referenzfall des unkontrollierten Ladens bei ca. 80 % Auslastung des PV-Stromes. Die Unternehmensflotte kann 5 % zulegen und 43 % des erzeugten PV-Stromes im Falle der Optimierung ausnutzen.

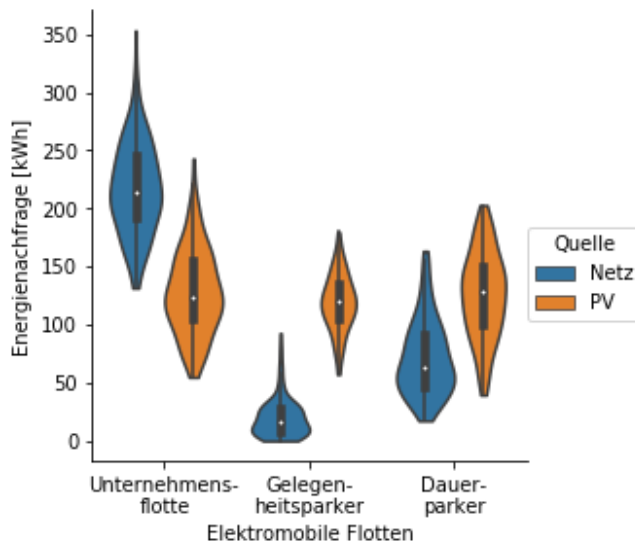


Abbildung 6.14: Unkontrolliertes Laden: Violinplot der Energienachfrage des erzeugten PV-Stromes sowie der Anteile vom Netz zum Laden für die einzelnen Flotten mit insgesamt 150 Kunden

6.2.2 Stromkosten

Die Höhe der Stromkosten wird zum einen anhand der Energienachfrage der Kunden bestimmt, aber ist auch von der Wahl der Stromquelle abhängig. Die Abbildung 6.15 stellt die durchschnittlichen Ladekosten je Flotte und genutzter Stromquelle für insgesamt 150 Kunden der drei Flottengruppen dar. Die Unternehmensflotte hat die durchschnittlich geringsten Ladekosten vom Netz. Das resultiert aus der Möglichkeit

nachts zu laden. In dieser Zeitspanne sind die EPEX SPOT-Preise am niedrigsten. Werden die gesamten durchschnittlichen Ladekosten von beiden Stromquellen kombiniert (unter Berücksichtigung, dass der Strom von PV mit 0 €/kWh angesetzt ist, vgl. Annahme (s) aus Abschnitt 3.4.1) hat die Unternehmensflotte die höchsten durchschnittlichen Ladekosten. Bedingt wird dies auch dadurch, dass nachts kein PV-Strom zur Verfügung steht, was zur Kostenminimierung beitragen würde. Diese Tatsache spiegelt sich ebenfalls in den höchsten gesamten Ladekosten wider. Die Dauerparker hingegen haben die niedrigsten kombinierten durchschnittlichen Ladekosten. Das lässt sich schon vom vorherigen Abschnitt der Netzauslastung ableiten, da der Anteil der PV Ausnutzung sehr hoch ist im Vergleich zur Stromquelle des Netzes.




Abbildung 6.15: Optimierung: Boxplot der durchschnittlichen Stromkosten mit Unterscheidung der Stromquelle je Flotte mit insgesamt 150 Kunden

Die Tabelle 6.1 zeigt die Entwicklung der durchschnittlichen Ladekosten je Flotte und genutzter Stromquelle für jeweils 25, 50 oder 75 Kunden je Flottengruppe und der Unterscheidung zwischen Optimierung und Referenzfall. Die Tendenz der elektromobilen Flotten ist dabei ähnlich. Dauerparker haben die geringsten durchschnittlichen Ladekosten und die Unternehmensflotte die höchsten, wenn die kombinierte Stromquelle von PV und Netz betrachtet wird. Im Falle der Kostenbetrachtung des Netzes hat die Unternehmensflotte die geringsten und die Dauerparker die größten Ladekosten. Die Tendenz ist über alle Flottengrößen hinweg ähnlich, die Ausprägung aber unterschiedlich. Ein Unterschied zwischen Optimierung und unkontrolliertem Laden

ist, dass mit Zunahme der Kundenanzahl je Flotte die durchschnittlichen Stromkosten von PV und Netz bei der Optimierung leicht steigen. Hingegen sind beim unkontrollierten Laden die Auswirkungen kaum merklich. Die durchschnittlichen Ladekosten nehmen bei der Optimierung bei der Kombination der Stromquellen zu. Dies lässt sich daraus ableiten, dass jetzt nicht mehr alle Kunden zu den niedrigen Preisen laden können und demnach auch höhere Preise genutzt werden. Ebenfalls kann die begrenzte Menge an erzeugtem PV-Strom ein weiterer Grund dafür sein.

Tabelle 6.1: Übersicht der durchschnittlichen Stromkosten des unkontrollierten Ladens sowie Optimierung je Flotte mit insgesamt 75, 150 und 225 Kunden mit Unterscheidung der Stromquelle, (a) Netz (oben) sowie (b) PV + Netz (unten)

(a) Stromquelle Netz in ct/kWh

Anz. Kunden	Flotte	Unternehmensflotte			Gelegenheitsparker			Dauerparker		
		Unteres Quartil	Median	Oberes Quartil	Unteres Quartil	Median	Oberes Quartil	Unteres Quartil	Median	Oberes Quartil
MILP	75	2,8	3,1	3,4	3,7	4,2	5,0	3,4	4,1	4,9
	150	2,8	3,2	3,4	3,8	4,2	4,9	3,4	3,8	4,3
	225	2,7	3,0	3,2	3,7	4,1	4,9	2,8	3,3	4,1
Unkontr. Laden	75	3,1	3,4	3,9	4,4	5,0	5,6	3,9	4,4	5,0
	150	3,1	3,5	3,8	4,3	5,0	5,5	3,8	4,2	5,0
	225	3,0	3,3	3,6	4,1	4,5	5,5	3,5	4,0	4,7

(b) Stromquelle PV + Netz in ct/kWh

Anz. Kunden	Flotte	Unternehmensflotte			Gelegenheitsparker			Dauerparker		
		Unteres Quartil	Median	Oberes Quartil	Unteres Quartil	Median	Oberes Quartil	Unteres Quartil	Median	Oberes Quartil
MILP	75	0,7	1,1	1,7	0,2	0,5	1,1	0	0	0,03
	150	1,0	1,4	2,4	0,3	0,7	1,2	0	0,01	0,3
	225	1,8	2,1	2,8	0,4	0,7	1,2	0,04	0,2	0,7
Unkontr. Laden	75	1,8	2,1	2,6	0,3	0,8	1,4	1,2	1,7	2,4
	150	1,8	2,2	2,5	0,2	0,6	1,0	1,0	1,3	2,3
	225	1,7	2,0	2,3	0,2	0,4	0,8	0,8	1,2	2,1

Ausgehend von den durchschnittlichen Ladekosten aus Tabelle 6.1 (b) lassen sich die gesamten Ladekosten ableiten. Diese sind in der Abbildung 6.16 und Abbildung 6.17 einmal für die Optimierung und einmal für den Referenzfall des unkontrollierten Ladens dargestellt. Die Ladekosten verändern sich zwischen den unterschiedlichen Kundenzahlen recht stetig. Der Einfluss der Stromerzeugung aus PV ist offensichtlich, wie aus vorherigen Analysen vermutet werden konnte. Die höchsten Ladekosten weist die Unternehmensflotte bei beiden Methoden auf, wenn beide Stromquellen gemeinsam betrachtet werden. Diese Flotte hat auch die größte Streuung der Ladekosten. Während die Dauerparker die niedrigsten Ladekosten bei der Optimierung haben, hat diese Flottengruppe beim unkontrollierten Laden höhere Ladekosten als die Gelegenheitsparker. Wie bereits schon mehrfach in der Arbeit erwähnt, fundiert diese Tatsache auf den angenommenen Flottencharakteristiken und den gewählten Preisen.




Abbildung 6.16: Optimierung: Boxplot der gesamten Ladekosten der einzelnen Flotten mit jeweils insgesamt 75, 150 und 225 Kunden




Abbildung 6.17: Unkontrolliertes Laden: Boxplot der gesamten Ladekosten der einzelnen Flotten mit jeweils insgesamt 75, 150 und 225 Kunden

6.3 Einfluss von Unsicherheiten auf die Ergebnisse

Dieser Abschnitt dient vorrangig der Analyse des Einflusses der Unsicherheiten auf die Auswertungen. Die Modellierung der Unsicherheiten ist in vorangestellten Kapiteln erfolgt (vgl. Abschnitte 3.5, 5.3 und 5.4). Darauf aufbauend werden in diesem Abschnitt alle untersuchten Ansätze (Unkontrolliertes Laden, MILP, SMILP) und PV-Vorhersagemodelle einander gegenübergestellt. Dieses geschieht unter Berücksichtigung des Vergleichs der gesamten Ladekosten sowie der Eigennutzung des erzeugten PV-Stromes zum Laden. Abschließend wird der stochastische Ansatz noch getrennt bewertet (Abschnitt 6.3.3). Die Grundannahmen bzgl. der Parametrisierung stimmen mit dem Abschnitt 5.1 überein. Zusätzlich werden noch 125 SAA-Szenarien pro gerechneten Simulationslauf berücksichtigt.

Die Forschungsfrage (V) zielt auf die Auswirkungen der verschiedenen methodischen Ansätze ab, um die E-Pkw Flotten kostenminimal zu laden. Spezifischer werden im Verlauf dieses Unterpunktes noch die folgenden beiden Fragen aufgegriffen:

V.a Welche Effekte haben Unsicherheiten auf die Ladekosten?

V.b Welche Auswirkung haben verschiedene PV-Prognosemodelle auf die Auslastung der PV-Anlage durch die E-Pkw Flotten?

6.3.1 PV-Integrationspotenzial unter Unsicherheit

In dieser Arbeit stehen verschiedene zu vergleichende Ansätze (Unkontrolliertes Laden, MILP, SMILP) im Vordergrund sowie drei unterschiedliche Ansätze für PV-Voraussicht. Die Lastkurven der einzelnen Flotten haben im Falle der Optimierung (Day-Ahead-Voraussicht MILP und GMM-basierte Voraussicht SMILP) einen sehr ähnlichen Tagesverlauf wie der Benchmark mit der perfekten Voraussicht MILP. Dieses beruht auf der Tatsache, dass alle drei PV-Vorhersagemodelle hinsichtlich minimaler Ladekosten optimiert werden und eine maximale Ausnutzung des erzeugten PV-Stromes erreicht wird.




Abbildung 6.18: Boxplot der Ausnutzung des erzeugten Stromes von PV basierend auf den unterschiedlichen Methoden und PV-Voraussicht Ansätzen

Die Abbildung 6.18 stellt den Ausnutzungsgrad des erzeugten PV-Stromes zum Laden der Flotten unter der jeweiligen Methode dar. In dem Boxplotdiagramm gleichen sich die drei Mediane und die Quartile der Optimierungsverfahren. Insbesondere die Day-Ahead-Voraussicht und die GMM-basierte Voraussicht unterscheiden sich nur marginal. Das unkontrollierte Laden kann nur zu gut drei Viertel den zur Verfügung

stehenden PV-Strom nutzen. Somit benötigen die E-Pkw Flotten beim unkontrollierten Laden durchschnittlich über 100 kWh mehr vom Netz zum Laden als bei den Optimierungsverfahren. Die Forschungsfrage (V.b) hat als Ergebnis, dass zwischen den drei PV-Vorhersagemodellen nur geringe Unterschiede bestehen. Die Auswirkungen der Unsicherheiten sind nur marginal auf die Eigennutzung der PV-Anlage. Der Unterschied der Ergebnisse zwischen Optimierung und unkontrolliertem Laden ist signifikant.

6.3.2 Bewertung der Unsicherheiten

In der Arbeit werden Nachfrage- und PV-Unsicherheiten, neben den stochastischen Profilen der E-Pkw, betrachtet. Als Ausgangsbasis werden zunächst in Abbildung 6.19 die reinen Ladekosten der einzelnen Ansätze für alle 150 Kunden beziffert. Das MILP mit perfekter Voraussicht stellt die Benchmark Kosten dar, wenn alle Unsicherheiten eingetreten sind. Das Day-Ahead MILP berücksichtigt noch die Stromerzeugung der PV-Day-Ahead-Voraussage und keine Unsicherheiten der Energienachfrage. Bei dem GMM-basierten SMILP sind die Kosten der ersten Stufe des stochastischen Problems der here-and-now Entscheidung dargestellt. Als letztes ist noch der Referenzfall des unkontrollierten Ladens abgebildet. Dieser beinhaltet die höchsten Kosten, welches nicht verwunderlich ist, da diese Ladestrategie keiner Optimierung unterlag. Die Größe der Differenz zwischen dem unkontrollierten Laden und dem Benchmark der Optimierung beruht insbesondere auf den zusätzlichen ca. 100 kWh, die die unkontrollierte Ladestrategie vom Netz beziehen muss. Die anderen drei Ansätze unterscheiden sich nur marginal und liegen alle bei einem Mittelwert von ca. 8 € für die Ladekosten. Der Median, dargestellt durch die durchgezogene Linie im Boxplot, ist bei dem MILP mit perfekter PV-Voraussicht am niedrigsten.




Abbildung 6.19: Boxplot der gesamten Flottenladekosten für die verschiedenen methodischen Ansätze ohne Unsicherheiten

Im Abschnitt 5.6.2 wurde bereits das Konzept der Abweichungskosten eingeführt. Dadurch werden die verschiedenen zugrunde gelegten Ansätze vergleichbar gemacht, um zu ermitteln, wie viel Strom nach der Bekanntgabe der Unsicherheiten noch notwendig gewesen wäre. In der Abbildung 6.20 sind die beiden unterschiedlichen PV-Vorhersagen (Day-Ahead vs. GMM-basierte) aufgezeigt. Es wird ersichtlich, dass die Auswirkungen der unsicheren Energienachfrage sowie unsicheren PV-Stromerzeugung einen signifikanten Einfluss haben, denn beide Ansätze liegen im Mittel bei etwas über 2 € an Abweichungskosten. Entsprechend des expliziten Vergleichs sind die in dieser Arbeit formulierten Abweichungskosten beim GMM-basierten Ansatz im Mittelwert ca. 20 ct geringer als bei dem Day-Ahead MILP und verdeutlichen somit einen signifikanten Unterschied von ca. 10 % bei den Abweichungskosten von 2 €. Diese Abweichungskosten sind von den Parameter a und b (vgl. Abschnitt 3.5.4.2) abhängig und können entsprechend andere Werte annehmen. Die Auswertungen der Fallstudie belegen den Einfluss der PV-Vorhersage Methoden, der aber gering ist, insbesondere wenn die Ladekosten aus Abbildung 6.19 mit den Abweichungskosten kombiniert werden. Die daraus entstehenden Kosten sind in Abbildung 6.21 für alle Ansätze abgebildet. Dann verringert sich der Unterschied zwischen den beiden PV-Prognose Modellen auf nur noch ca. 10 ct und scheint demnach vernachlässigbar, insbesondere in Anbetracht der durchschnittlichen Flottenladekosten der beiden Ansätze, die in Höhe von ca. 10 € liegen. Die Abweichung ist demnach nicht signifikant.

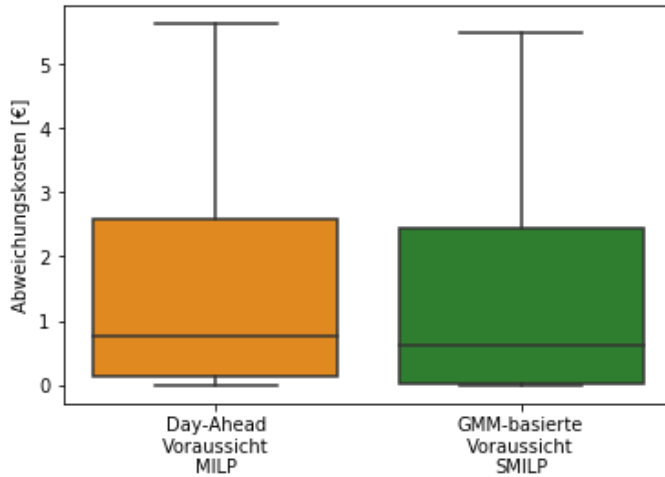


Abbildung 6.20: Boxplot der Abweichungskosten der Ansätze Day-Ahead vs. GMM-basierte PV-Voraussicht

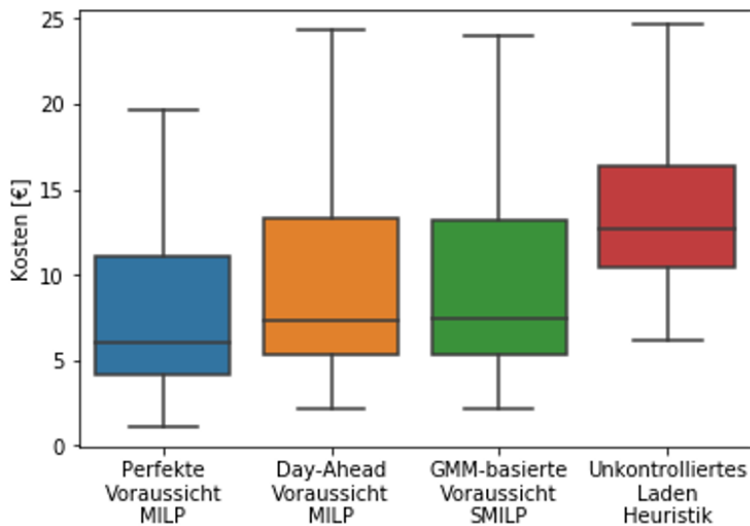


Abbildung 6.21: Boxplot basierend auf den gesamten Flottenladekosten inklusive der Abweichungskosten für die verschiedenen methodischen Ansätze

Die Unsicherheiten, belegt mit den definierten Abweichungskosten, zeigen erhebliche Auswirkungen auf die Ladekosten und erhöhen diese je nach Methodik im Durchschnitt zwischen 25 % und 30 %. Damit konnte die Forschungsfrage (V.a) zu den Effekten beantwortet werden. Aus der Abbildung 6.21 können die Zielerreichungsgrade,

normiert auf die Benchmark Kosten des MILP, berechnet werden. Im Mittel liegt der Zielerreichungsgrad zwischen 1,23 für das SMILP, 1,24 für die Day-Ahead Voraussicht MILP und 1,70 für das unkontrollierte Laden.

6.3.3 Modellbewertung des stochastischen Ansatzes

In diesem Abschnitt soll explizit die Modellierung als zweistufiges stochastisches MILP bewertet werden. Die Abweichungskosten aus den vorherigen Ausführungen waren ein Ansatz, um im Nachhinein die Unsicherheiten verschiedener Methoden miteinander zu vergleichen und damit einen Zielerreichungsgrad zu ermitteln. Die folgende Tabelle 6.2 stellt die Ergebnisse der in Abschnitt 3.5.4.1 eingeführten Gütemaße vor. Die Methodik des Benchmark MILP mit dem wait-and-see (WS) Ansatz wird dem Rekurs-Problem (RP) des stochastischen Ansatzes SMILP gegenübergestellt. Der resultierende EVPI von 2,10 € ist im Verhältnis zu den minimalen Ladekosten von 8,03 € recht hoch und weist darauf hin, dass in dieser Fallstudie die Unsicherheiten von Energienachfrage der E-Pkw Flotten und Vorhersage der PV-Stromerzeugung einen hohen Stellenwert einnehmen.

Tabelle 6.2: Güte des stochastischen Ansatzes

	RP	WS	EVPI
€	10,13	8,03	2,10

6.4 Integration von PV und CO₂-Emissionen

In dem Abschnitt werden die PV-Integrations- sowie die CO₂-Vermeidungspotenziale aufgezeigt. Diese Analysen dienen zur Beantwortung der Forschungsfrage (IV). Zusätzlich werden noch die folgenden drei Fragen formuliert:

- IV.a. Wie hoch ist die Eigennutzung der PV-Stromerzeugung zum Laden der E-Pkw Flotten?
- IV.b. Welche E-Pkw Flotte hat das höchste Potenzial zum Laden mit lokal erzeugtem PV-Strom?
- IV.c. Wie hoch ist das CO₂-Reduktionspotenzial?

6.4.1 Eigennutzung der PV-Stromerzeugung

Das PV-Integrationspotenzial wurde in den letzten drei Abschnitten schon näher untersucht. Es wurde der methodische Vergleich mit Unsicherheiten (vgl. Abschnitt 6.3.1) und die Auslastung zwischen den einzelnen Flotten (vgl. Abschnitt 6.2.1) betrachtet. Die Skalierung der PV-Module wurde im Abschnitt 6.1.5 ebenfalls schon näher analysiert. Es konnte gezeigt werden, dass die E-Pkw Flotte der Dauerparker das größte Potenzial zum Laden mit lokal erzeugtem PV-Strom hat. Die Forschungsfrage (IV.b) ist damit beantwortet. Die Analyse zur Frage (IV.a) ist abhängig von der Dimensionierung der Flotten und der PV-Stromerzeugung. Bei 150 Kunden konnte schon über 95 % des erzeugten PV-Stromes zum Laden genutzt werden (vgl. Abschnitt 6.3.1). 225 Kunden lasten die PV-Anlage komplett aus (vgl. Abbildung 6.12 (ii)).

Die Abbildung 6.22 zeigt, wie sich die Ladekurven der drei Flotten verhalten, wenn die PV-Anlage vergrößert wird. Durch die Optimierung hinsichtlich der PV-Erzeugung verschieben sich die Lastkurven, sofern möglich in den Zeitraum der PV-Stromerzeugung. Insbesondere die Unternehmensflotte kann noch in den frühen Morgenstunden laden. Doch aufgrund der Flottencharakteristiken muss auch in Zeiten ohne vorhandenen PV-Strom geladen werden.




Abbildung 6.22: Optimierte Lastkurven bzgl. Strom-Preis und PV-Einspeisung für die drei E-Pkw Flotten mit 22 kW Ladeleistung und großem PV-Modul

6.4.2 CO₂-Einsparpotenzial

Das CO₂-Einsparpotenzial ist in dieser Fallstudie gekoppelt an die Nutzung des erzeugten PV-Stromes und steht daher mit den Ergebnissen der vorangestellten Abschnitte in Verbindung. Die nachfolgende Tabelle 6.3 stellt die Durchschnittswerte der eingesparten CO₂-Emissionen der durchgeführten Analysen mit der Unterscheidung zwischen Sommer- und Winter-EPEX SPOT-Preisen für die drei elektromobilen Flotten dar. Es werden insgesamt 150 Flottenkunden betrachtet. Der Wert für die durchschnittlichen CO₂-Emissionen für den Energiemix aus dem Netzbezug wird mit 447 g CO₂/kWh_{el} angesetzt (vgl. Abschnitt 5.4.5). Dabei stellen die Zahlen einen einzelnen Durchschnittstag von 150 simulierten Tagen dar. Für ein Jahrespotenzial wären die Werte entsprechend höher und würden sich auf ca. 43 t CO₂ im Falle der Optimierung belaufen.

Tabelle 6.3: Überblick der eingesparten CO₂-Emissionen je Flotte und Tag mit Unterscheidung zwischen Optimierung und unkontrolliertem Laden bewertet mit Sommer- und Winter-EPEX SPOT-Preisen

g CO ₂ / Flotte/ Tag	Optimierung			Unkontrolliertes Laden		
	Unternehmensflotte	Gelegenheitsparker	Dauerparker	Unternehmensflotte	Gelegenheitsparker	Dauerparker
Sommer EPEX SPOT-Preis	65.709	53.640	82.248	58.557	50.958	55.875
Winter EPEX SPOT-Preis	4.917	10.728	22.797	8.493	9.834	6.705

6.5 Geschäftsmodelle eines Parkhausbetreibers

In dem Abschnitt werden die gewonnenen Erkenntnisse hinsichtlich einer Anwendung im Geschäftsumfeld analysiert. Das Konzept wird für die nachfrageseitige Flexibilisierung für einen Parkhausbetreiber entwickelt. Im Vordergrund steht zunächst die Identifizierung eines geeigneten Geschäftsmodells. Welche Faktoren sollten Berücksichtigung finden und wie sieht das konkrete Design mit den entsprechenden Komponenten aus? Daran anknüpfend ist abzuklären, welche Konzepte für wen angeboten werden können? Dabei ist eine Untergliederung aus Betreibersicht und Kundensicht (Abschnitt 6.5.1 bzw. 6.5.2) vorzunehmen. Es sollte der Offset zwischen Kosten-Nutzen für beide Seiten Berücksichtigung finden. Die vorhandene Flexibilität

bzgl. Lastverschiebung der E-Pkw soll sich in den möglichen Produkten widerspiegeln, um entsprechende Anreize für die Kunden zu setzen. Genau der Aspekt eines möglichen Tarifdesigns sowie die entscheidenden Faktoren, die E-Pkw Kunden (E-Pkw Besitzer) beeinflussen, um ihre Ladeflexibilität einem Aggregator anzubieten, sind Inhalt der Forschungsfrage (VI) und werden hier diskutiert.¹

6.5.1 Konzept für Parkhausbetreiber

In den vorherigen Abschnitten (vgl. 6.1, 6.4) konnte aufgezeigt werden, dass Lastverschiebung mit jeder der drei E-Pkw Flotten möglich ist. Des Weiteren sind die verschiedenen Alternativen hinsichtlich unterschiedlicher Zielformulierungen ersichtlich geworden.

Zur systematischen Darstellung der möglichen Designoptionen wird der methodische Ansatz der Morphologischen Box verwendet (vgl. Zwicky und Wilson, 1967). Dafür werden die im Abschnitt 2.5.1 definierten Elemente eines Geschäftsmodells auf einen Parkhausbetreiber angewendet. Hierbei sind einige Bausteine mehr oder weniger relevant für das Konzept eines Parkhausbetreibers, insbesondere da in diesem Abschnitt lediglich auf den Aspekt der nachfrageseitigen Modellentwicklung eingegangen und die Angebotsseite mit dem dazugehörigen Energiemarkt außen vor gelassen wird. Die identifizierten Charakteristika sind in der Tabelle 6.4 dargestellt.

Das ‚Wertangebot‘, welches den Kunden angeboten wird, ist in diesem Kontext die Dienstleistung des ‚Parkservice‘, zusätzlich kann der ‚Ladeservice‘ ergänzt werden. Die Charakteristik des ‚System Service‘ unterscheidet drei verschiedene Design Möglichkeiten. Es wird kein Service angeboten, somit stellt sich die spätere Preisbildung auch weniger komplex dar. Als nächste Möglichkeit ist die ‚Einfache Lastverschiebung‘ zu sehen, welche die Flexibilität der Kunden nutzt. Die dritte Variante stellt die ‚Rückspeisung‘ dar, die durch die Batterienutzung der E-Pkw die größte Flexibilität der Nachfrageseite erreichen kann. Die ‚Kundenbeziehung‘ gliedert sich in ‚Einmalig‘ oder ‚Wiederkehrend‘ auf. Es ist somit relevant, ob ein Kunde täglich das Parkhaus aufsucht und zu welchen Zeiten oder dieses spontan nutzt. Der Parkhausbetreiber sollte die verschiedenen Kundentypen identifizieren und entsprechend deren Bedürfnissen Produkte entwickeln. Durch den Parkhausbetreiber sind auf alle Fälle der Service des Ladens und die dazugehörigen Komponenten sicher zu stellen. Im Kontext

¹ Die Arbeiten dieses Unterkapitels beruhen auf Ausarbeitungen aus der Veröffentlichung von Seddig et al. (2019a).

des Lademanagements ist ebenfalls ein entsprechendes Scheduling der E-Pkw relevant. Das ist notwendig, um sowohl die Ladebedürfnisse der Kunden zu erfüllen, als auch bei einer Teilnahme des Parkhauses am Energiemarkt die versprochenen Leistungen einzuhalten. Der Bezug der ‚Stromquelle‘ kann entweder aus dem ‚Öffentlichen Netz‘, der ‚Lokalen Erzeugung‘ oder ‚EE‘ sein. Letzteres bietet die Möglichkeit, dass der Parkhausbetreiber Strom aus EE bezieht. Für das Element ‚Netzanschluss‘ sind die vier Varianten ‚Mode 2‘, ‚Mode 3 11 kW‘, ‚Mode 3 22 kW‘ oder ‚Mode 4‘ wesentlich. Zum ‚Zugang‘ zählen die vier Design Möglichkeiten ‚Parkticket‘, ‚Barzahlung‘, ‚RFID-Karte‘ sowie ‚Externer Dienstleister‘.

**Tabelle 6.4: Überblick der Komponenten des Geschäftsmodellkonzepts für einen Parkhausbetreiber für die nachfrageseitige Flexibilisierung;
Quelle: nach Seddig et al. (2019a)**

Charakteristiken	Design Möglichkeiten			
Wertangebot	Parkservice		Ladeservice	
System Service	Kein Ladeservice	Einfache Lastverschiebung		Rückspeisung
Kundenbeziehung	Einmalig		Wiederkehrend	
Stromquelle	Öffentliches Netz	Lokale Erzeugung		EE
Netzanschluss	Mode 2	Mode 3 11 kW	Mode 3 22 kW	Mode 4
Zugang	Parkticket	Barzahlung	RFID-Karte	Externer Dienstleister
Märkte	Primärregelreserve		Sekundärregelreserve	
Preisbildung E-Pkw Laden	Keine Gebühr	Festpreis	Bezahlung pro Nutzung	Variabler Preis

Die unteren beiden Charakteristika der Morphologischen Box repräsentieren die finanziellen Aspekte. Jene sind zum einen beeinflusst durch die oberen Charakteristika und zum anderen spiegeln sie die Erlöse des zugrundeliegenden Geschäftsmodells wider. Bei der Charakteristika ‚Märkte‘ ist die Teilnahme am Energiemarkt, insbesondere die Regelenergie mit den drei Ausprägungen ‚Primärregelreserve‘, ‚Sekundärregelreserve‘ und ‚Minutenreserve‘ zu nennen. Der letzte Punkt der ‚Preisbildung E-Pkw Laden‘ spezifiziert konkrete Preiskonzepte für das Laden der E-Pkw. Dabei

kann zwischen ‚Keine Gebühr‘, ‚Festpreis‘ (bspw. pro Monat, Tag oder Ladevorgang), ‚Bezahlung pro Nutzung‘ oder ‚Variabler Preis‘ unterschieden werden. Diese Preiskonzepte werden im folgenden Abschnitt 6.5.2 näher erklärt.

6.5.2 Tarifkonzepte für Parkhauskunden mit Elektrofahrzeug

Aus den Ergebnissen der Fallstudie wird erkenntlich, dass die vorhandenen Flotten verschiedene Charakteristika aufweisen. Dieses geht einher mit unterschiedlicher Flexibilität, die ein Parkhausbetreiber ausschöpfen kann. Um die Ressourcen bestmöglich zu nutzen, sollten entsprechende Tarifkonzepte für die jeweiligen Parkhauskunden entwickelt werden.

Daraus abgeleitet könnte zunächst zwischen verschiedenen Kundentypen unterschieden werden. Einerseits die einmaligen Kunden oder Kunden mit geringer Verweildauer, welche zum einen geringer planbar sind und zum anderen mit kurzen Aufenthaltsdauern weniger Flexibilität anbieten. Dem gegenüber stehen die wiederkehrenden Kunden, welche eine bessere Vorhersehbarkeit für den Parkhausbetreiber darstellen, genauso wie die Kunden mit langer Verweildauer, die dadurch höhere Flexibilität aufweisen. Somit können entsprechend der Eigenschaften der Kunden und dem dazugehörigen Ladeverhalten verschiedene Service Level angeboten werden, welche mit entsprechenden Tarifkonzepten einhergehen (siehe Abbildung 6.23). Dabei besteht die Möglichkeit, dem Kunden mit zunehmender Flexibilität und der Bereitschaft zur Teilnahme am Lademanagement eine größere Bandbreite an Tarifen mit verschiedenen Bestandteilen anzubieten. Zusätzlich können dabei Nutzerpräferenzen berücksichtigt werden.

Ein ‚Statischer Tarif‘ impliziert feste Raten, welche beispielsweise an einem Tagesatz, einer Monatspauschale oder pro Nutzung festgelegt werden. Der ‚Variable Tarife‘ versetzt den Parkhausbetreiber in die Lage, die Preise über den Verlauf eines Tages anzupassen. Es besteht weiterhin die Möglichkeit dieses in Abhängigkeit von der Jahreszeit zu gestalten. Ein lineares Preiskonzept bzgl. der nachgefragten Energiemenge könnte ebenfalls ein Produkt in solch einem Tarif sein. Es macht zusätzlich Sinn spezielle Premiumpreise für die Bedürfnisse der Kunden mit hoher Priorität und hoher Nachfrage gleichfalls in das Tarifkonzept zu integrieren. Durch Lademanagement ist ein spezifischeres Laden möglich, was Vorteile für Parkhausbetreiber als auch für Kunden mit sich bringt. Dadurch kann in den ‚Variablen Tarifen‘ bspw. Echtzeitpreisung stattfinden und damit das Ziel der Ladekostenminimierung verfolgt

werden. Diese Konzepte sind alles mögliche Versionen des ‚Basis Produkts‘ für die Kunden.




Abbildung 6.23: Mögliches Produktdesign für Parkhauskunden unter Berücksichtigung der Kundenflexibilität und der Tarifkomplexität; Quelle: nach Seddig et al. (2019a)

Bei der letzten Variante, der ‚Designte Tarif‘, ist ein Lademanagement zur Erreichung von flexiblen Zielen unabdingbar. Somit würde das ‚Spezial Produkt‘ noch mehr Auswahlmöglichkeiten anbieten, z. B. dass Kunden eine Spanne an gewünschter Energie zum Ende des Ladevorgangs angeben oder zur Reduktion der Nachfragespitze beitragen möchten. Das ‚Nachhaltigkeits Produkt‘ sollte über alle Tarife hinweg angeboten werden. Es stellt eine Chance dar, die Ressourcen besser zu nutzen und bspw. Strom aus EE zu nehmen. Damit könnte eine Sensibilisierung der Kunden bzgl. des Ladeverhaltens stattfinden und gleichzeitig eine höhere Sensitivität für die angebotenen Preiskonzepte erreicht werden.

Zusammenfassend muss erwähnt werden, dass alle möglichen Produkte die Kunden zufriedenstellen sollten insbesondere unter dem Aspekt der Zuverlässigkeit des angebotenen Ladeservice. Weiterhin ist die Frage zu klären, inwieweit die Kunden bereit wären, sich an solche neuen Konzepte anzupassen. Ein Nachteil für die vorgestellten möglichen Produkte könnten die zusätzlichen Informationen sein, die vom Kunden zur Verfügung gestellt werden müssten sowie der größere Zeitaufwand bei der Auswahl des geeigneten Produkts. Weiterhin wäre fraglich, ob so eine große Vielfalt an Produkten überhaupt für die Zukunft notwendig ist, da mit immer größeren Batterien der E-Pkw als auch schwankenden Strompreisen zu rechnen ist. In Zukunft könnte

der Aspekt des V2G relevant werden. Die E-Pkw können dem Parkhausbetreiber dann eine noch größere Flexibilität anbieten, da diese dann ins Netz zurückspeisen können.

6.5.3 Übertragung der Tarifkonzepte auf die Fallstudie

In den vorangestellten Analysen der Abschnitte 6.1 - 6.2 konnte gezeigt werden, dass eine Gruppierung der Kunden sinnvoll erscheint. Jede der Flotten hat eine spezifische Charakterisierung. Wird der Blick nun auf mögliche Tarife für die drei untersuchten Flotten gelegt, dann wird deutlich, dass insbesondere die Dauerparker und die gewerbliche Flotte zum Lademanagement geeignet sind. Demnach kommen für diese beiden Gruppen sowohl das ‚Spezial Produkt‘ als auch das ‚Basis Produkt‘ in Frage. Das ‚Nachhaltigkeits Produkt‘ macht im Kontext des Ladens mit lokal erzeugtem Strom insbesondere bei den Dauerparkern Sinn. Beide Gruppen sind ebenfalls von einer regelmäßigen Wiederkehr in das Parkhaus gekennzeichnet.

Die Gelegenheitsparker zeichnen sich dadurch aus, dass sie i. d. R. nur einmalig oder in unregelmäßigen Abständen ein Parkhaus aufsuchen. Durch die kurze Aufenthaltsdauer ist ein Lademanagement weniger sinnvoll. Daher scheinen für diese Kundengruppe insbesondere die ‚Basis Produkte‘ mit ‚Statischen Tarifen‘ oder ‚Variablen Tarifen‘ zweckmäßig.

Es kann ein Vergleich zu anderen Parkhäusern gezogen werden. Dort existieren aktuell i. d. R. verschiedene Tarife. Zum einen gibt es für einen Monat eine e-parken Pauschale und bei den Tagessätzen einen Höchstsatz (vgl. PBW, 2019). Alternativ wird bei den Tagestarifen auch nach Stunden abgerechnet, die Preise sind bspw. von der Ladeleistung der Ladesäule abhängig. Ebenfalls haben Nutzer mit unterschiedlichen Ladekarten die Möglichkeit die Ladesäulen zu nutzen, was wiederum Auswirkungen auf den Ladetarif haben kann. Lademanagement wird dabei aktuell noch nicht betrieben. Inwieweit die jeweiligen Tarife Anklang finden, ist nicht bekannt.

6.5.4 Einsatz von Parkhaus mit Solardach

Die aufgezeigten Varianten in den vorangestellten Unterkapiteln verdeutlichen die Möglichkeit, E-Pkw mit Strom von EE zu laden. Parkhäuser, sowohl öffentliche als halböffentliche, sind weit verbreitet. Bereiche wie Shopping-Center, Flughafen, Universität, Restaurants oder Arbeitsplätze werden aktuell schon mit Solardächern ausgestattet. Dabei kann noch ein zusätzlicher Nutzen erzeugt werden, wenn die Einrichtungen, je nach Rentabilität und Abwägung bestimmter Faktoren (vgl. Tabelle 6.5),

die Dächer mit PV-Modulen ausstatten. Dadurch können die positiven Effekte von E-Pkw noch besser ausgeschöpft werden, da die Ladeprozesse mit ‚grünem‘ Strom erfolgen.

**Tabelle 6.5: Möglichkeiten und Herausforderungen von Parkhäusern mit Solardächern;
Quelle: nach Nunes et al. (2016)**

Möglichkeiten	Herausforderungen
Laden der E-Pkw mit lokal erzeugtem PV-Strom	Koordinierung zwischen PV-Stromerzeugung und E-Pkw Ladung
Förderung der Marktdurchdringung von Elektrofahrzeugen	Aufrüstung von Hard- und Software für Lademanagement
Parkhausdachfläche ist keine Konkurrenz zur Landnutzung für eine PV-Anlage	Design von optimalen Ladestrategien
Schutz der Fahrzeuge vor Sonneneinstrahlung oder anderen äußeren Einflüssen	Umsatzbewertung
Parkhäuser können als E-Pkw Aggregatoren wirken	Umsetzung & Handel auf Energiemärkten

6.6 Kritische Würdigung

Im Folgenden werden insbesondere getroffene Annahmen, die Modellierung und Methodik sowie Eingangsdaten des entwickelten Modells kritisch betrachtet. Abschließend finden Überlegungen zur Übertragbarkeit auf andere Bereiche und Regionen statt.

6.6.1 Kritische Betrachtung des entwickelten Modells

6.6.1.1 Diskussion von Modellierung und Methodik

Es gibt eine Vielzahl an Methoden, die je nach der Fragestellung in Betracht gezogen werden können. Bei der Modellierung und Methodenauswahl sollten insbesondere die Aspekte der Zielformulierung und der Fokus der Analyse berücksichtigt werden.

Ein erster zu betrachtender Gesichtspunkt bei der vorliegenden Arbeit ist die Unterscheidung zwischen lokaler vs. globaler Optimierung. Viele Untersuchungen nehmen eine perfekte Voraussicht der Informationen an. Fraglich ist der Mehrwert einer noch genaueren Darstellung, da die zu berücksichtigenden Unsicherheiten noch mehr Streuung in die zu erwartenden Ergebnisse hineinbringen.

Die Rechenzeiten sind in dieser Arbeit bei der stochastischen Optimierung noch recht hoch im Vergleich zur deterministischen Optimierung (ca. 225-fache Zeit). Falls die Berechnungen wirklich zeitkritisch werden, dann wäre auch ein Einsatz von High Performance Computing möglich oder als erster Schritt leistungsstärkere Rechner. Paralleles Rechnen auf mehreren Kernen ist in dem Modell schon vorgesehen und wird teilweise genutzt. Generell sollte zwischen einem detaillierten und dadurch komplexeren Modell mit einer wahrscheinlich genaueren Lösung oder der Gewährleistung der Lösbarkeit und damit möglicherweise verbundenen Modellvereinfachungen abgewägt werden. Ebenfalls wurde in dieser Arbeit weder der worst-case noch der best-case betrachtet, sondern der Erwartungswert. Demnach könnte die robuste Optimierung für risikoaverse Entscheider von Interesse sein.

Die genaue Formulierung der Zielfunktion und der Restriktionen des entwickelten Modells lässt sich variieren. Insbesondere bei der Parametrisierung können andere Werte vorgenommen werden. Die weiche Nebenbedingung der Ablehnung von angefragten E-Pkw ist realitätsnah. Ist ein Parkhaus voll, würde sich ein potenzieller Kunde nach einer alternativen Variante umschaun. Des Weiteren wird davon ausgegangen, dass ausreichend Ladesäulen vorhanden sind und damit bspw. kein Warteschlangensystem einzuführen ist. In der Praxis würde in Abhängigkeit der Warteschlange ein anderes Parkhaus angefahren werden, wenn das ursprünglich anvisierte vollständig belegt ist.

Der Aspekt der Vereinfachung der PV-Stromerzeugung ist ebenfalls relevant. Denn nicht nur die Größe der PV-Module hat Auswirkungen auf die erzeugte Leistung, sondern z. B. auch die Ausrichtung, Wirkungsleistung sowie der Verschattungsgrad der PV-Module. Diese Elemente und ein eigenes Prognosemodell könnten zur Ergebnisverbesserung beitragen. Insbesondere der letzte Punkt des eigenen Prognosemodells könnte signifikante Auswirkungen haben. Die Unterschiede zwischen der Day-Ahead-Vorhersage und der selbstentwickelten GMM-Vorhersage waren nur gering. Eine Verbesserung dieses Ergebnisses würde erreicht, wenn z. B. auf das zugrundeliegende Prognosemodell von TransnetBW zugegriffen werden könnte und die Algorithmen für die Prognose anwendbar wären. Zusätzlich wäre es sinnvoll lokale Gegebenheiten und somit das Aggregationslevel der Daten zu berücksichtigen.

Kritisch bei der Optimierung nach Preisen ist zu sehen, dass dadurch wiederum Lastspitzen entstehen, wenn es viele Aggregatoren mit flexiblen Lasten gibt, die preisbasierte Anreize nutzen. Es müsste also das miteinander gekoppelte Ladeverhalten durch

andere Mechanismen gesteuert werden, um die Niederspannungsnetze besser zu entlasten (vgl. Ensslen et al., 2018). Somit ist der Preis nur ein mögliches Steuerungsinstrument. Insbesondere spieltheoretische Ansätze können genutzt werden, um die Lastverschiebeaktivitäten und deren Effekte zu bewerten.

Zur Bewertung der verschiedenen integrierten Unsicherheiten in dem Fallbeispiel, sowohl in der Stromerzeugung durch PV als auch in der Energienachfrage der E-Pkw, werden Abweichungskosten eingeführt. Dies geschieht, damit die unterschiedlichen Szenarien im Nachgang vergleichbar sind. Dabei wird davon ausgegangen, dass der Strom sowohl eingekauft als auch verkauft werden kann. Die genaue Bewertung der Abweichungskosten könnte ebenfalls anders gestaltet sein. Zusätzlich ist es fraglich, inwieweit ein Parkhausbetreiber den Strom auch wiederverkaufen wird und welche Kosten da angesetzt werden sollten, da die Energiemengen im zweistelligen kWh Bereich liegen.

Wird der Flottenbetreiber als aggregierende Instanz betrachtet, um die Fahrzeuge individuell ansteuern zu können, müssen auch alle teilnehmenden E-Pkw Besitzer damit einverstanden sein. Manche Kunden werden es durchaus als Einschränkung empfinden und ihr Auto nicht für die Lastverschiebung zur Verfügung stellen. Somit müsste ebenfalls das Kundenverhalten expliziter untersucht werden, sowie entsprechende Geschäftsmodelle dafür entwickelt werden (vgl. Will und Schuller, 2016).

Des Weiteren könnte die Annahme, dass immer auf 100 % des Batteriestandes geladen wird, hinterfragt werden. Mit entsprechenden hinterlegten Geschäftsmodellen kann es ebenfalls Sinn machen den Kunden Anreize zu geben, nur bestimmte Energiemengen nachzufragen, was zu einer Verbrauchersteuerung führen würde.

Ebenfalls besteht die Möglichkeit ein Batterielade- sowie Alterungsmodell zu hinterlegen, um damit die E-Pkw noch spezifischer zu modellieren (vgl. Kaschub, 2017). Der durchschnittliche Energieverbrauchswert könnte genauer umgesetzt werden. All diese Änderungen würden das Modell aber noch komplexer und umfangreicher machen. Daher ist fraglich, in wie weit es einerseits die Ergebnisse verbessert und andererseits die Rechenzeiten erhöht.

Damit das Laden über Nacht dargestellt werden konnte, obwohl nur 24 Stunden betrachtet werden, wurde die Lademenge der Unternehmensflotte aufgeteilt. Mit Hilfe einer mehrtägigen Simulation und Optimierung könnte dem Effekt entgegengewirkt werden. Da aber mit einem längeren Zeithorizont gleichfalls die Prognose von PV immer ungenauer wird, ist auch hier fraglich, ob das einen großen Mehrwert darstellt.

Zu dem betrifft das Laden über Nacht lediglich die Unternehmensflotte, die anderen beiden Flotten sind nur tagsüber im Parkhaus anzutreffen.

In dieser Arbeit wurde eine nicht-parametrische Wahrscheinlichkeitsverteilung genutzt, um insbesondere die Abhängigkeiten von mehreren Dimensionen der Inputdaten darzustellen. Je nach Datenlage können durchaus andere Wahrscheinlichkeitsverteilungen genutzt werden. Mit diesen lässt sich ein bestimmtes Verhalten darstellen und je nach Fragestellung kann das ausreichend sein.

6.6.1.2 Diskussion von Eingangsdaten

Damit der jeweilige Anwendungsfall adäquat abgebildet ist, muss eine dazugehörige Datengrundlage geschaffen werden. Mit anderen Inputdaten, seien es Wetterdaten, andere Energiequellen (z. B. Wind), Preise oder Ladeverhalten der einzelnen Flotten, ist davon auszugehen, dass andere Ergebnisse erzielt und andere Forschungsfragen beantwortet werden können. Durch die Anwendung einer Simulation wird aber schon eine größere Spannbreite an Daten abgedeckt, die mögliche Variationen aufzeigen können.

Des Weiteren ist die Skalierung der PV-Stromerzeugung anzuführen. Die Werte beruhen auf den aggregierten Daten des kompletten Einzugsgebiets der TransnetBW. Somit wirkt sich diese Mittelung über eine größere räumliche Ausdehnung positiv auf den Prognosefehler aus. Demnach wären lokale PV-Stromerzeugungen, insbesondere die Betrachtung von Einzelanlagen, von noch größeren Schwankungen geprägt, die hier nicht berücksichtigt werden. In Zukunft könnten Parkhausverbunde in einer Region berücksichtigt werden, bei denen sich solche Schwankungen dann ausgleichen könnten.

Die hier betrachteten Daten der Kurzzeit- sowie Dauerparker des Parkhauses sind nur auf zwei Beispieltage zurückzuführen. Ebenfalls sind die zugrundeliegenden Werte des Energiebedarfs nur an Wegdistanzen gekoppelt, die auf Grundlage von Verbrennerfahrzeugen erhoben wurden. Ein großer Datensatz an Realwerten von E-Pkw könnte noch tiefere Einblicke in das mögliche Ladeverhalten von E-Pkw geben.

Durch die Wahl unterschiedlicher Parametergrößen lassen sich beliebig viele Modellvariationen abbilden. Diese Arbeit zeigt nur einen Ausschnitt davon. Die Ergebnisse sind zudem von der Parameterwahl abhängig. Eine Änderung der gewählten Zusammensetzung der drei E-Pkw Flottengrößen ist z. B. eine große Stellgröße. Beispielsweise kann das Parkhaus eine andere Auslastung erfahren, sobald die Anzahl einer Flotte priorisiert wird.

Überdies wurden drei gleichverteilte Flotten untersucht, die sich gemeinsam eine Ladeinfrastruktur teilen. Die Ergebnisse beziehen sich also auf drei Flotten, hätte man z. B. nur zwei Flotten, könnten LVP anders aussehen. Der Vorteil mit den drei untersuchten Flotten ist, dass der ganze Tag abgedeckt werden kann. Dennoch ist damit das Potenzial zur Lastverschiebung als auch zur Einsparung an CO₂-Emissionen von verschiedenen Nutzergruppen – private Haushalte, Pendler sowie gewerbliche Flotten, insbesondere Dienstfahrten – ersichtlich geworden.

6.6.1.3 Diskussion des Geschäftsmodells

Die genaue Ausgestaltung der Preiskonzepte sowie die numerische Dimensionierung der Konzepte müssten noch ausgearbeitet werden. Mit einer entsprechenden Validierung könnten die relevanten Konzepte identifiziert werden. Um die Wirtschaftlichkeit zu bestimmen, müsste ein detailliertes Modell zugrunde gelegt werden, welches verschiedene Aspekte berücksichtigt. Dazu zählen Daten des Energiemarktes sowie des Netzes, die Elektromobilitätsdaten der E-Pkw und das dazugehörige Scheduling, mögliche Flexibilität und Präferenz der Kunden, als auch die Berücksichtigung der Unsicherheiten der zugrunde gelegten Daten.

Ein weiterer zu beachtender Faktor ist, dass bei dem Konzept, den Parkhausbetreiber als Zwischenhändler zu nutzen, aktuell noch keine Möglichkeit in Deutschland besteht direkt an Strommärkten teilzunehmen. Die entsprechenden Energien können nicht mit absoluter Sicherheit geliefert werden, da das Ein- und Ausfahrverhalten der E-Pkw stochastischen Prozessen unterliegen. Außerdem müsste die Wirtschaftlichkeit dieser Geschäftsmodelle noch geprüft werden (vgl. Brandt et al., 2017). Im Oktober 2018 konnte zum ersten Mal ein E-Pkw über einen Aggregator am Markt für Primärregelenergie teilnehmen. Ein Nissan LEAF, mit V2G ausgestattet, konnte den Präqualifizierungsprozess erfolgreich durchlaufen (vgl. The Mobility House, 2019). Somit ist eine erstmalige Testphase gestartet, dennoch sind noch weitere Ausgestaltungen am Markt notwendig, um solche Konzepte großflächig umzusetzen.

6.6.2 Übertragbarkeit auf andere Bereiche und Regionen

In der vorliegenden Arbeit wurde das Ladeverhalten mehrerer Kundengruppen mit E-Pkw analysiert, die sich eine gemeinsame Ladeinfrastruktur in einem Parkhaus teilen. Aufgrund der Charakterisierungen der einzelnen Flotten ist es möglich die Ergebnisse auch auf andere Anwendungsbeispiele zu übertragen. So kann das Ladeverhalten der

Dauerparker ebenfalls für einen Park & Ride Parkplatz genutzt werden. Parkplatzformen wie Park & Ride können ebenfalls zu Park & Charge & Ride Plätzen umgebaut werden. Eine Studie aus Chicago hat den Vorteil, der mit den CO₂-Einsparungen verbunden ist, bereits ermittelt (vgl. Ai et al., 2018).

Die gewerbliche Flotte könnte den Fuhrpark von Unternehmen darstellen (vgl. Ketelaer et al., 2014). Eine besondere Form der Betriebsfahrzeuge wären hierbei die Brief- und Paketzulieferdienste. Es sind recht gut planbare Flotten, da regelmäßig ähnliche Strecken zurückgelegt werden und dies zu bestimmten Zeiten. Des Weiteren kommen Tiefgaragen von Wohnhäusern infrage. Das Ladeverhalten der Unternehmensflotte spiegelt das mögliche Nutzerverhalten wider.

Abschließend ist festzuhalten, dass das Modell modular aufgebaut wurde und anhand von Variation der Eingangsdaten sowie der Parameter weitergehende Untersuchungen mit anderen Fragestellungen ermöglicht. Die vielseitige Einsetzbarkeit des Modells wird dadurch gewährleistet.

7 Schlussbetrachtung und Ausblick

Zum Abschluss dieser Arbeit werden die wesentlichen Inhalte, Rahmenbedingungen und gewonnenen Ergebnisse zusammengefasst (Abschnitt 7.1). Es folgt das Fazit mit dazugehörigen Erkenntnissen und der Schlussbetrachtung im Unterkapitel 7.2. Die Arbeit endet mit einem Ausblick und weiterführenden Forschungsmöglichkeiten im Abschnitt 7.3.

7.1 Zusammenfassung

Mit der Unterzeichnung des Pariser Klimaabkommens hat auch Deutschland sich verpflichtet, die anthropogenen Treibhausgasemissionen zu senken. Die CO₂-Zielerreichungsmaßnahmen sind breit gefächert. Dazu zählen neben den Effizienzsteigerungen in der Industrie insbesondere der Zubau von Wind- und Photovoltaikanlagen sowie ein höherer Anteil an E-Pkw und alternativer Kraftstoffe im Transportsektor. Mit der zunehmenden Verbreitung der E-Pkw geht ein steigender Bedarf an Lademöglichkeiten einher. Der Ausbau der Ladesäuleninfrastruktur ist ein aktuelles Thema.

Jedoch bewirkt eine steigende Zahl von E-Pkw eine zusätzlich zu bewältigende Energienachfrage im Energiesystem und höhere Lastspitzen, insbesondere im Niederspannungsnetz. Es steigt die Notwendigkeit, neben der verstärkten Dezentralisierung der Erzeugung, durch das erhöhte Elektrizitätsangebot aus erneuerbaren Energiequellen die Elektrizitätsnachfrage stärker zu steuern und in den Markt zu integrieren. Ein Demand Side Management des Ladeprozesses von E-Pkw bietet sich hierbei als eine geeignete Maßnahme an. Das Lastverschiebepotenzial kann genutzt werden, um die fluktuierende Einspeisung durch erneuerbare Energien auszugleichen und so deren Integration in das Stromnetz zu erleichtern. Als Ergebnis wird eine Stabilisierung des Netzes erwartet.

Die Zielsetzung der vorliegenden Arbeit ist es, ein Modell zu entwickeln, das zur Identifizierung von Lastverschiebepotenzialen von elektromobilen Flotten unter Berücksichtigung der Integration von PV-Stromerzeugung unter Unsicherheit genutzt werden kann. Darüber hinaus erfolgt im Rahmen der Arbeit ein kurzer Exkurs zu einem möglichen Geschäftsmodell, wie ein E-Pkw Aggregator in Form eines Parkhausbetreibers agieren kann. Die Ausführungen basieren auf einer Fallstudie in einem

Parkhaus mit PV-Anlage auf dem Dach sowie drei elektromobilen Kundenflotten, die sich eine gemeinsame Ladeinfrastruktur teilen.

Für die Beantwortung der identifizierten Fragestellungen der Arbeit wurden unterschiedliche Ansätze unter der Anwendung der Methoden Simulation, Optimierung und stochastische Optimierung entwickelt, um den Ladevorgang von drei verschiedenen Elektrofahrzeugflotten (Pendler-, Gelegenheitsparker- und Unternehmensflotte) an einer gemeinsam genutzten Ladeinfrastruktur unter Unsicherheit zu planen. Das Modell der deterministischen Optimierung wurde als gemischt-ganzzahliges lineares Problem formuliert, so dass auf Basis von perfekter Information der Benchmark der minimalen Ladekosten abgebildet werden kann. Die stochastische Optimierung wurde als ein zweistufiges gemischt-ganzzahliges lineares Programm aufgestellt: dadurch kann ein mögliches Abweichen von sowohl einer bereits geplanten Energiemenge als auch einer unsicheren PV-Stromerzeugungsprognose berücksichtigt werden. Das als Referenzfall bezeichnete unkontrollierte Laden wurde in einer Simulation umgesetzt. Dadurch konnten die ohne Ladesteuerung anfallenden Ladekosten ermittelt werden. Zusätzlich wird eine Monte Carlo Simulation für alle Ansätze angewendet, damit die zugrundeliegenden stochastischen Profile der PV-Stromerzeugung, Elektrizitätspreise, Abfahrts- und Ankunftszeiten sowie Fahrdistanzen der E-Pkw abgebildet werden können. Die Ganzzahligkeit der mathematischen Formulierung war erforderlich, um den technischen Restriktionen der Anschlussleistung des Transformators im Parkhaus Rechnung zu tragen. Damit ist berücksichtigt, dass nicht alle Kundenwünsche zum Laden in dem Parkhaus bedient werden können. In den entwickelten Modellen werden neben den Zielfunktionen ebenfalls relevante Restriktionen abgebildet. Diese umfassen u. a. das Einhalten der Energiebilanzen der nachgefragten Energiemengen oder die Begrenzungen durch sowohl lokale als auch globale Anschlussleistungen. Abschließend wurden verschiedene Parameter (z. B. Anzahl Kunden je Flotte, lokale sowie globale Anschlussleistung, PV-Stromerzeugung) variiert und in mehreren Analysen deren Auswirkungen untersucht.

Die im Abschnitt 1.2 gestellten Hauptforschungsfragen (I-VI) lassen sich nunmehr zusammenfassend wie folgt beantworten:

- I. Was sind die relevanten Charakteristika bei der Modellierung von E-Pkw Flotten?

Es konnte dargelegt werden, dass eine differenzierte Modellierung von elektromobilen Flotten die zugrundeliegenden Daten genauer abbildet. Für die Schätzung der Wahrscheinlichkeitsverteilung der abhängigen und stetigen Zufallsvariablen wurde

ein multivariater Kerndichteschätzer verwendet, der zur Gruppe der nicht-parametrischen Verfahren zählt. Durch die Nutzung einer KDE konnten alle vorhandenen Informationen verwendet und somit die Wahrscheinlichkeitsverteilungen sehr realitätsgetreu abgebildet werden. Insbesondere der Aspekt der Darstellung der Abhängigkeiten von mehreren Dimensionen der Inputdaten ist ein Vorteil der KDE gegenüber anderen Wahrscheinlichkeitsverteilungen. Somit zeigte die Modellierung mit Hilfe einer nicht-parametrischen Wahrscheinlichkeitsverteilung die schwachen Korrelationen der Daten von beispielsweise der Abfahrts- und Ankunftszeit auf. Damit alle Eigenschaften der jeweiligen Flotten berücksichtigt werden, ist eine individuelle Charakterisierung der E-Pkw Flotten relevant.

II. Wie können Unsicherheiten bei der Prognose der Stromerzeugung durch PV im stochastischen Modell berücksichtigt werden?

Zur Beantwortung der Forschungsfrage (II) fanden drei verschiedene PV-Vorhersagemodelle Anwendung und dadurch konnten die Unsicherheiten der PV-Stromerzeugung berücksichtigt werden. Der Vergleich erfolgte mittels der perfekten Information über die reale PV-Stromerzeugung. Diese Werte nutzend wurde die Prognosegüte der kommerziellen Day-Ahead-Vorhersage bewertet. Mit einem neu entwickelten Ansatz, basierend auf der GMM-Methodik und der Day-Ahead-Vorhersage, konnte die Prognosegüte verbessert werden.

III. Wie hoch ist das Lastverschiebepotenzial von verschiedenen E-Pkw Flotten, wenn unkontrolliertes Laden mit einer wirtschaftlich optimierten Ladestrategie verglichen wird?

Es kann festgestellt werden, dass das LVP der einzelnen Flotten je nach Zielgröße unterschiedlich ausfällt. In Bezug auf die maximale Eigennutzung der PV-Stromerzeugung haben sich die Dauerparker als geeignetste Flotte erwiesen. Wird das zugrunde gelegte Preissignal betrachtet, dann hat die Unternehmensflotte die durchschnittlich geringsten Ladekosten im Vergleich zu den anderen beiden Flotten im Falle der Optimierung. Dieser Tatbestand beruht auf der Charakterisierung und damit den Lastflexibilitäten der Flotten. Die Unternehmensflotte weist eine hohe Ladeflexibilität in den Nachtstunden auf. Die Dauerparker haben hingegen tagsüber das größte LVP. Zusätzlich üben Faktoren wie die zu optimierenden Preissignale, das Verhältnis zwischen Größe der PV-Anlage und des Netzanschlusses, die Ladeleistung sowie die Kundenanzahl einen entscheidenden Einfluss auf die Ergebnisse und damit verbunden auf das LVP aus.

- IV. Wie viel Prozent der lokalen Stromerzeugung durch PV kann zum Laden der E-Pkw Flotten genutzt werden, wenn eine maximierende PV-Auslastung und eine unkontrollierte Ladestrategie verglichen werden?

Die ersten beiden Forschungsfragen dienen zur Spezifizierung der Inputdaten für das Modell. Mit der Eigennutzung des erzeugten PV-Stromes zum Laden beschäftigt sich die Forschungsfrage (IV). Es wird ermittelt, dass jede Flotte mit gesteuertem Laden mehr PV nutzen kann als im Falle des unkontrollierten Ladens. Insbesondere die Flotte der Dauerparker kann den PV-Stromanteil von 63 % auf 94 % ausweiten. In Abhängigkeit von der Kundenanzahl und Größe der PV-Anlage erhöht sich der gesamte genutzte PV-Strom von ca. 80 % beim unkontrollierten Laden auf knapp 100 % bei der Optimierung. Daraus lässt sich ein CO₂-Reduktionspotenzial von ca. 43 t CO₂ pro Jahr im Falle der Optimierung ableiten. Dabei werden 150 Kunden pro Tag angenommen. Der methodische Vergleich zwischen den beiden Ansätzen MILP und SMILP mit den dazugehörigen Day-Ahead und GMM-basierten Vorhersagen bei der Auslastung der PV-Anlage führt zu ähnlichen Ergebnissen.

- V. Wie hoch sind die Unterschiede, wenn verschiedene methodische Ansätze (deterministische Optimierung vs. stochastische Optimierung) miteinander verglichen werden, um die E-Pkw Flotten kostenminimal zu laden?

Die Forschungsfrage (V) hat als Kern den methodischen Vergleich. Es wurde die Güte des stochastischen Ansatzes mit Gütemaßen bewertet. Zusätzliche Analysen bezifferten neben den Ladekosten und Abweichungskosten die Zielerreichungsgrade der einzelnen Ansätze bzgl. der Benchmark Optimierung und damit die Auswirkungen der Unsicherheiten. Die Unsicherheiten haben erheblichen Einfluss auf die Ladekosten und je nach Methodik erhöhen sich diese zwischen 23 % und 70 %. Somit bewirken die Unsicherheiten im Mittel signifikante Effekte in der untersuchten Fallstudie. Jedoch ist der Unterschied zwischen den PV-Vorhersagemodellen (GMM-basiert und Day-Ahead-Vorhersage), marginal.

- VI. Welche Faktoren beeinflussen E-Pkw Kunden (E-Pkw Besitzer), damit sie ihre Ladeflexibilität einem Aggregator anbieten und was sollten Tarife entsprechend berücksichtigen?

Die Forschungsfrage (VI) beschäftigt sich mit möglichen Geschäftsmodellen. Dargelegt wird, wie ein mögliches Tarifdesign für die E-Pkw Kunden im Parkhaus gestaltet

sein kann, um ihre Ladeflexibilität einem Aggregator, hier in Form des Parkhausbetreibers, anzubieten. Dabei finden verschiedene Faktoren Berücksichtigung, bspw. die Option, mit Strom aus EE zu laden oder denkbare Nutzerpräferenzen der Kunden.

Die Beantwortung der Forschungsfragen und die daraus gewonnenen Ergebnisse zeigen die vielseitige Anwendbarkeit des in der vorliegenden Arbeit entwickelten Modells. Erstmals wurden neben den stochastischen Profilen verschiedener Parameter zusätzlich weitere Unsicherheiten berücksichtigt, die mit einer zweistufigen stochastischen gemischt-ganzzahligen Optimierung adressiert wurden. Die konkrete Modellierung der unterschiedlichen Flotten mit einer nicht-parametrischen Verteilung ist dabei hervorzuheben. Des Weiteren wurden mehrere PV-Prognosemodelle umgesetzt. Durch den methodischen Vergleich der verschiedenen gewählten Ansätze mit dem deterministischen Optimum können die Ergebnisse der Methoden diesem gegenübergestellt werden. Ebenfalls wurde erstmalig eine synergetisch genutzte Ladeinfrastruktur von verschiedenen elektromobilen Flotten geteilt und darauf basierend ein gesteuertes Laden der E-Pkw durchgeführt. Mit Hilfe des in der vorliegenden Arbeit entwickelten Modells konnten die LVP bewertet werden.

7.2 Erkenntnisse

Mit Hilfe des entwickelten Modells wurde eine umfangreiche Fallstudie durchgeführt. Auf Basis der verschiedenen Analysen aus Kapitel 5 und 6 resultieren mehrere wesentliche Aussagen aus der vorgestellten Fallstudie.

Zusammenfassend ergeben sich folgende Erkenntnisse:

Werden die drei Flotten (Pendler-, Gelegenheitsparker- und Unternehmensflotte) abschließend miteinander verglichen, fallen mehrere Aspekte ins Auge. Die Distanzen sind relativ homogen zwischen den einzelnen Flotten verteilt. Jedoch haben die Unternehmensflotten eindeutig die größten zurückgelegten Tageswegstrecken. Hingegen gibt es bei den Aufenthaltszeiten und der generellen Belegung über den gesamten Tagesverlauf deutliche Unterschiede. Es zeigt sich, dass die KDE eine geeignete Methode ist, um E-Pkw Flotten auf basierenden Realdaten bestmöglich darzustellen. Eine nicht-parametrische Verteilung, wie die KDE, kann strukturelle Merkmale in den Daten aufdecken, die ein parametrischer Ansatz möglicherweise nicht offenbart. Bezugnehmend auf die vorliegende Fallstudie konnte gezeigt werden, dass die Daten wie Ankunfts- und Abfahrtszeiten sowie zurückgelegte Distanzen schwache Korrelationen aufweisen. Somit konnten die Datenabhängigkeiten

abgebildet werden. Zusätzlich ist eine Unterscheidung zwischen den einzelnen Flotten sinnvoll, was zu einer individuellen Charakterisierung der E-Pkw Flotten beiträgt.

Bei den PV-Prognosen ist ersichtlich, dass die kommerziellen Vorhersagen leichte Abweichungen im Vergleich zu den real eingetretenen PV-Stromerzeugungswerten haben. Daher wurde eine weitere Methode angewendet. Mit der entwickelten GMM-basierenden Vorhersage kann die PV-Prognosegenauigkeit verbessert werden. Somit konnten zusätzliche Effekte von der Unsicherheit bei der Prognose der PV-Stromerzeugung durch einen neu entwickelten Ansatz berücksichtigt werden. Jedoch sind die Auswirkungen der expliziten Berücksichtigung von Unsicherheiten der PV-Prognose gering, welches auch mit der betrachteten aggregierten Datenlage zusammenhängen kann.

Des Weiteren kann festgestellt werden, dass mit der synergetischen Ladeinfrastruktur ein typischer Tagesverlauf mit de facto verschiedenen Ladesituationen abgebildet werden kann, bspw. sowohl Parken im öffentlichen als auch im halböffentlichen Raum. Diesem Aspekt kommt besondere Bedeutung zu, da erstmalig drei verschiedene E-Pkw Flotten gleichzeitig in die Untersuchung einbezogen worden sind.

Das Lastverschiebepotenzial ist für alle drei untersuchten elektromobilen Flotten (Pendler-, Gelegenheitsparker- und Unternehmensflotte) vorhanden und variiert je nach Zielgröße (z. B. Preis vs. Eigennutzung PV-Stromerzeugung). Das Lastverschiebepotenzial ist von der Charakterisierung der Flotte abhängig. Gelegenheitsparker haben nur kurze Aufenthaltszeiten und demnach wenig Ladeflexibilitäten. Die Dauerparker haben hauptsächlich tagsüber und die Unternehmensflotte nachts ihr Lastverschiebepotenzial. Lastmanagement kann eine hohe Relevanz für Parkhausbetreiber besitzen, insbesondere wenn es mit der Integration des erzeugten Stromes aus erneuerbaren Energiequellen gekoppelt ist. Damit wird nicht nur der Transformator entlastet, sondern auch das Netz. Im Hinblick auf die Zielstellung der Bundesregierung, bis 2050 einen Bruttostromverbrauch aus 80 % EE aufzuweisen, wird der Aspekt des Lastmanagements, um die fluktuierenden Lasten der EE auszugleichen, immer wichtiger. Sobald entsprechende Marktmechanismen (z. B. Teilnahme am Regenergiemarkt) etabliert sind, ergäbe sich in Zukunft auch die Variante, dass Parkhäuser als Aggregatoren auftreten und somit die Flexibilität des Ladevorgangs der E-Pkw nutzen. Entsprechend zu entwickelnde Tarifkonzepte können die Bereitschaft der E-Pkw Nutzer steigern, um am Lastmanagement teilzunehmen.

Weitergehende Überlegungen bzgl. der Installation von PV-Anlagen sollten getroffen werden. Wenn die E-Pkw mit regional und regenerativ erzeugtem Strom geladen werden, können die CO₂-Einsparpotenziale nochmal signifikant gesteigert werden. Diese Reduktionen beruhen auf der Tatsache, dass ansonsten der durchschnittliche CO₂-Emissionswert für den Energiemix aus dem Netzbezug angesetzt wird. Somit stellen die E-Pkw ein Potenzial dar, die CO₂-Bilanz des Transportsektors weiter zu verbessern. Der Aspekt wird in Zukunft eine weitere große Rolle spielen, wenn die EU-Grenzwerte für alle neu zugelassenen Pkw unter die geplanten 95 g CO₂/km nach dem Jahr 2022 gesenkt werden.

Von besonderem Interesse sind die Vergleiche der Ergebnisse der drei unterschiedlichen Methoden sowie PV-Vorhersagemodelle. Diese berücksichtigen komplexe Zusammenhänge von Wirtschaftlichkeit, stochastischen Profilen, Unsicherheiten und technischen Restriktionen (z. B. lokale und globale Anschlussleistung). Die Optimierung bildet die Ergebnisse minimaler Ladekosten sowie maximaler Ausnutzung des erzeugten PV-Stromes mit einem dazugehörigen optimalen Ladeplan für die drei verschiedenen elektromobilen Flotten ab. Die Relevanz Unsicherheiten zu betrachten, wurde aufgrund der verschiedenen Zielerreichungsgrade der Methoden verdeutlicht.

Bestimmte Teilergebnisse sind auch auf andere Bereiche übertragbar. So lässt sich das Ladeverhalten von Dauerparkern gut mit Laden am Arbeitsplatz oder an Park & Ride Parkplätzen vergleichen. Ebenfalls können Tiefgaragen von Wohnhäusern sowie Parkplätze von Betriebsfahrzeugflotten durch die Anpassung der Charakterisierung der Flotten mit der entwickelten Methode untersucht werden.

7.3 Ausblick und weiterführende Forschungsmöglichkeiten

Basierend auf der vorliegenden Arbeit ergeben sich fortführende, interessante Fragestellungen sowie Potenziale, die darauf abzielen, das Modell weiterzuentwickeln. Insbesondere durch den modularen Aufbau des Modells können weitere Anwendungsmöglichkeiten untersucht werden.

Im Hinblick auf die Methodik und die Modellierung könnte für die PV-Stromerzeugung ein eigenes Prognoseverfahren u. a. zur verstärkten Verwertung der Wettervorhersage entwickelt werden, um damit bessere Ergebnisse zu erzielen. Gleichmaßen

bietet sich die Integration einer rollierenden Planung an, damit weitere Elemente berücksichtigt werden und sich die Ergebnisgüte erhöht. Die Betrachtung von mehreren Tagen sowie die Untersuchung unterschiedlicher Flottenkombinationen sind weitere Optionen.

Mit Blick auf die technische Seite des Parkhauses wird erkennbar, dass mehrere Faktoren relevant sind. Es ist die komplette Auslegung und Dimensionierung der Infrastruktur zur Elektrifizierung des Parkhauses (Anzahl an Ladepunkten, mit welchen Leistungen ausgestattet sowie Größe des Transformators) zu analysieren. Dabei sollte auch eine möglichst hohe Auslastung des Parkhauses angestrebt werden. Falls es weniger Ladesäulen als Fahrzeuge gibt, ist es sinnvoll über eine Fahrzeugzuordnung nachzudenken. Die Betrachtung von Schnellladesäulen ist ein weiterer Aspekt für Untersuchungen, um festzustellen, ob es eine lohnenswerte Investition ist und inwieweit diese einen Mehrwert sowohl für Kunden als auch den Parkhausbetreiber liefert.

Des Weiteren besteht die Möglichkeit, eine externe Batterie, d. h. einen Speicher zur Entlastung des Transformators, einzuplanen. Zur Beurteilung der Wirtschaftlichkeit dieser Investition könnte eine Kosten-Nutzen-Analyse durchgeführt werden. Diese sollte u. a. eine potenzielle Vergrößerung des Transformators, die eingesparten Ladekosten durch die externe Batterie und deren Anschaffungs- sowie Instandhaltungskosten berücksichtigen. Die Batterie würde dann zu Niedrigpreisen des an der Börse gehandelten Stromes laden und zu Hochpreisen die E-Pkw beladen. Die Dimensionierung der Batterie ist daran anknüpfend ein weiterer zu beachtender Faktor. Ebenfalls ergibt es Sinn, eine detaillierte Eigenbedarfsoptimierung des Parkhauses durchzuführen.

Eine Netzflussanalyse ist ein weiterer Schritt, um zu untersuchen, inwieweit die Lasten vom Parkhaus zur Netzregulierung beitragen können. Bei der Netzauslegung ist nicht nur der Transformator von Bedeutung, sondern auch die verlegten Kabel, denn die Phasenbegrenzung könnte ebenfalls schnell auf der Verteilnetzebene erreicht sein (vgl. Jochem et al., 2018). Die übergeordneten Netzebenen bilden einen weiteren Forschungsschwerpunkt, um die Auswirkungen der E-Pkw auf das Energiesystem zu ermitteln, insbesondere, wenn die Systemgrenzen über das Parkhaus hinausgehen.

Einhergehend mit den technischen Veränderungen sind auch die Aspekte der Digitalisierung von Bedeutung. Denn für die ganzheitliche, technische Umsetzung von Lademanagementsystemen ist ein entsprechendes vernetztes und kommunizierendes Steuerungselement notwendig (vgl. Clausen, 2018). Dazu zählen Aspekte, wie die Ausgestaltung der Nutzerschnittstelle, die Berücksichtigung der Randbedingungen

der Fahrzeuge, eine Ausarbeitung der Schnittstelle zum Verteilnetzbetreiber sowie die Beachtung kritischer Netzzustände.

Die Digitalisierung setzt u. a. mit dem Internet of things neue Trends. Wie können Abrechnungssysteme umgesetzt werden? Wird es eine webbasierte Abrechnung geben? Die Umsetzung über Apps wird in den Vordergrund rücken. Wie finde ich ein passendes Parkhaus? Wie sehen sowohl Geschäftsmodelle für den Kunden als auch für den Parkhausbetreiber als Aggregator aus? Die Betrachtung der zukünftigen Ausgestaltung von Energiemärkten (z. B. Regelenergiemarkt) spielt gleichfalls eine wichtige Rolle. Wie gestaltet sich der Handel an der Börse und somit die Umsetzung von Angebots- und Nachfrageseite? All dies sind spannende Fragen, die noch mehrere Akteure beschäftigen werden. Dabei werden insbesondere die Protokollspezifikationen für die Umsetzung der Digitalisierung ein wichtiges Thema sein.

Eine Rückspeisung der Energie von E-Pkw in das Elektrizitätsnetz ist in der Arbeit nicht berücksichtigt worden. Dennoch bietet die Vehicle-to-Grid Technologie ein breites, neues Spektrum an Forschungsmöglichkeiten. Dabei ist eine Option, bspw. das Speicherpotenzial aller E-Pkw zu untersuchen, da diese dann als mobile Speicher fungieren könnten. Eine dahingehende Frage ist, wie viele Batteriespeicher zur Anwendung kommen? In diesem Kontext sind wiederum Untersuchungen zu Auswirkungen auf das Netz von Interesse. Weitere Anwendungsmöglichkeiten der mobilen Speicher beziehen sich auf die Systemdienstleistungen, z. B. Spannungs- oder Frequenzhaltung. Dabei sollte die Gewährleistung der Systemsicherheit aus Sicht des Stromnetzes einerseits sowie des Mobilitätsbedürfnisses andererseits nicht vernachlässigt werden. Einsatzmöglichkeiten von V2G könnten schon im lokalen Bereich bspw. auf Haushaltsebene stattfinden. E-Pkw Nutzer hätten die Möglichkeit, eine Eigenbedarfsoptimierung in Bezug auf eine PV-Anlage im Haus durchzuführen. Ebenfalls ist denkbar, dass bei Stromausfällen oder Netzengpässen mit Hilfe der E-Pkw eine Versorgung des Haushaltes weiter gewährleistet ist.

Ein weiteres wichtiges Themenfeld ist die Nutzerakzeptanz. Die Verbraucher sollten so viel wie nötig und dennoch so wenig wie möglich eingebunden werden. Der Nutzer möchte auf ein funktionierendes System zurückgreifen, das im Idealfall einen hohen Komfortlevel besitzt (vgl. Ensslen et al., 2014). Welche Tarife dabei für den Kunden relevant sein könnten und welche Zahlungsbereitschaften bei verschiedenen Nutzergruppen dafür vorhanden sind, wäre durch dahingehende Fallstudien oder Befragungen zu ermitteln (vgl. Ensslen et al., 2018). Somit kann abschließend gesagt werden,

dass Elektromobilität, für Anbieter und Nutzer gleichermaßen, wirtschaftlich und alltagstauglich sein soll.

Anhang A

In diesem Abschnitt wird überprüft, inwieweit die Simulationsgröße der einzelnen Modellvarianten angemessen ist (vgl. Averill M. Law, 2015). Dabei werden das perfekte Voraussicht MILP, das Day-Ahead-Voraussicht MILP sowie das SMILP näher analysiert. Je mehr Flottenkunden vorhanden sind, desto größer ist die Anzahl an Simulationen, die durchgeführt werden müssen. Die Abbildungen A.1 – A.4 verdeutlichen die Zusammenhänge für jeweils 75 und 150 Kunden.

Zur Ermittlung der Simulationsgröße kann das Gesetz der großen Zahl und der zentrale Grenzwertsatz herangezogen werden. Wird der Grenzwertsatz betrachtet, dann konvergiert für ein ausreichend großes n die absolute Häufigkeit gegen eine Normalverteilung. Für das Gesetz der großen Zahl nähert sich die relative Häufigkeit mit steigender Anzahl an Wiederholungen dem wahren Wert an (vgl. Fahrmeir et al., 2010).




Abbildung A.1: Konvergenztest (zentraler Grenzwertsatz) zur Ermittlung der Simulationsgröße mit 150 Simulationen und 125 SAA Szenarien und insgesamt 75 Kunden

In Abbildung A.1 wird untersucht, ob die ermittelten Kosten sich einer Normalverteilung annähern. Dieses wird für die drei Verfahren MILP mit perfekter Voraussicht, MILP mit Day-Ahead-Voraussicht und SMILP durchgeführt. Eine Tendenz zur Normalverteilung ist erkennbar, obwohl leicht linksschief.




Abbildung A.2: Konvergenztest (Gesetz der großen Zahl) zur Ermittlung der Simulationsgröße mit 150 Simulationen und 125 SAA Szenarien und insgesamt 75 Kunden

Als weiterer Konvergenztest findet die Überprüfung nach dem Gesetz großer Zahlen statt. In Abbildung A.2 ist zu erkennen, dass sich nach einer ausreichend großen Anzahl an Simulationsläufen die berechneten Kosten einer Zahl annähern. Ab circa 100 Simulationen hat sich der Zielfunktionswert eingestellt.

Die Abbildungen A.3 und A.4 sind die analogen Konvergenztests zu den Abbildungen A.1 und A.2, jedoch mit 150 Kunden. Dabei wurden 300 Simulationen durchgeführt. Bei der Analyse mit dem Gesetz der großen Zahlen ähneln sich die Kurvenverläufe, ab ca. 100 Simulationen hat sich der Zielwert eingepegelt. Eine Normalverteilung ist beim zentralen Grenzwertsatz zu erkennen, aber diese ist wieder linksschief.




Abbildung A.3: Konvergenztest (zentraler Grenzwertsatz) zur Ermittlung der Simulationsgröße mit 300 Simulationen und 125 SAA Szenarien und insgesamt 150 Kunden




Abbildung A.4: Konvergenztest (Gesetz der großen Zahl) zur Ermittlung der Simulationsgröße mit 300 Simulationen und 125 SAA Szenarien und insgesamt 150 Kunden

Anhang B

In diesem Anhangsteil wird die Charakterisierung der elektromobilen Flotten nochmal aufgegriffen und die zugrunde gelegten KDE erneut graphisch dargestellt. Analog zu den Histogrammen von Abbildung 5.2 sind die KDE abgebildet, welche die Verstetigungen der Verteilung der Histogramme darstellen. Somit sind sowohl die 1D KDE von Ankunftszeit und Aufenthaltsdauer, als auch die 2D KDE in der Mitte der Abbildung B.1 erkennbar.




Abbildung B.1: 2D KDE von der Ankunftszeit und der Aufenthaltsdauer der Gelegenheitsparker, sowie die jeweilige 1D KDE; Datenquelle: PBW (2013)

Die KDE der Pendlerflotte sind analog zur vorherigen Abbildung B.1 in der Abbildung B.2 aufgeführt. Wie bereits in Abschnitt 5.2 erläutert, unterscheiden sich die beiden Flotten in den KDE sowohl bei der Verteilung der Ankunftszeit als auch der Aufenthaltsdauern.




Abbildung B.2: 2D KDE von der Ankunftszeit und der Aufenthaltsdauer der Pendler, sowie die jeweilige 1D KDE; Datenquelle: PBW (2013)

Literaturverzeichnis

- ADAC. (2019). Wallbox: Elektroauto-Ladestation für zu Hause - Die wichtigsten Tipps. Retrieved July 17, 2019, from <https://www.adac.de/rund-ums-fahrzeug/elektromobilitaet/laden/elektroauto-laden-wallbox-faq/>
- ADAC Autotest. (2012). Nissan Leaf. Retrieved January 24, 2014, from https://www.adac.de/_ext/itr/tests/Autotest/AT4719_Nissan_Leaf/Nissan_Leaf.pdf
- AG Energiebilanzen e.V. (2018). Bruttostromerzeugung in Deutschland ab 1990 nach Energieträgern. Retrieved December 15, 2018, from <https://www.ag-energiebilanzen.de/>
- Aghaei, J., Nezhad, A. E., Rabiee, A., & Rahimi, E. (2016). Contribution of Plug-in Hybrid Electric Vehicles in power system uncertainty management. *Renewable and Sustainable Energy Reviews*, 59(99), 450–458. <https://doi.org/10.1016/j.rser.2015.12.207>
- Aghajani, S., & Kalantar, M. (2017). A cooperative game theoretic analysis of electric vehicles parking lot in smart grid. *Energy*, 137, 129–139. <https://doi.org/10.1016/j.energy.2017.07.006>
- Agora Energiewende. (2018). *Die Energiewende im Stromsektor: Stand der Dinge 2017. Rückblick auf die wesentlichen Entwicklungen sowie Ausblick auf 2018*. <https://doi.org/125/01-A-2018/DE>
- Ai, N., Zheng, J., & Chen, X. (2018). Electric vehicle park-charge-ride programs: A planning framework and case study in Chicago. *Transportation Research Part D: Transport and Environment*, 59(February), 433–450. <https://doi.org/10.1016/j.trd.2018.01.021>
- Aisleitner, C., Hofer, M., & Tichy, R. (2012). A central limit theorem for Latin hypercube sampling with dependence and application to exotic basket option pricing. *International Journal of Theoretical and Applied Finance*, 15(07), 1250046. <https://doi.org/10.1142/S021902491250046X>
- Bäcklin, C. L., Andersson, C., & Gustafsson, M. G. (2018). Self-tuning density estimation based on Bayesian averaging of adaptive kernel density estimations yields state-of-the-art performance. *Pattern Recognition*, 78, 133–143. <https://doi.org/10.1016/j.patcog.2018.01.008>
- Bayraksan, G. (2018). An improved averaged two-replication procedure with Latin hypercube sampling. *Operations Research Letters*, 46(2), 173–178. <https://doi.org/10.1016/j.orl.2017.12.005>
- BCG. (2018). *The Electric Car Tipping Point - The Future of Powertrains for Owned and Shared Mobility*. Retrieved from http://image-src.bcg.com/Images/BCG-The-Electric-Car-Tipping-Point-Jan-2018_tcm108-180862.pdf

- BDEW. (2018). Was bedeutet die Digitalisierung für die Energiewirtschaft? Retrieved June 23, 2018, from <https://www.bdew.de/energie/digitalisierung/was-bedeutet-der-trend-der-digitalisierung-fuer-die-energiewirtschaft/>
- Bicer, Y., & Dincer, I. (2016). Comparative life cycle assessment of hydrogen , methanol and electric vehicles from well to wheel. *International Journal of Hydrogen Energy*, 42(6), 3767–3777. <https://doi.org/10.1016/j.ijhydene.2016.07.252>
- Birge, J. R., & Louveaux, F. (2011). *Introduction to Stochastic Programming. Introduction to Stochastic Programming*. New York, NY: Springer New York. <https://doi.org/10.1007/978-1-4614-0237-4>
- BMU. (2013). Emissionshandel - Was ist das? Retrieved August 8, 2018, from <https://www.bmu.de/themen/klima-energie/emissionshandel/emissionshandel-was-ist-das/>
- BMU. (2018). Bundeskabinett beschließt einheitliche Regeln für Umgang mit Fahrverboten. Retrieved November 15, 2018, from <https://www.bmu.de/pressemitteilung/bundeskabinett-beschliesst-einheitliche-regeln-fuer-umgang-mit-fahrverboten/>
- BMU. (2019a). Maßnahmenpaket der Bundesregierung. Retrieved April 12, 2019, from <https://www.bmu.de/themen/luft-laerm-verkehr/verkehr/elektromobilitaet/bmu-foerderprogramm/massnahmenpaket-der-bundesregierung/>
- BMU. (2019b). Wie klimafreundlich sind Elektroautos ? Retrieved April 10, 2019, from https://www.bmu.de/fileadmin/Daten_BMU/Download_PDF/Verkehr/emob_klima_bilanz_2017_bf.pdf
- BMVBS. (2010). *Mobilität in Deutschland (MiD) 2008 - Ergebnisbreicht, durchgeführt vom Institut für angewandte Sozialwissenschaft GmbH (infas), Institut für Verkehrsforschung des Deutschen Zentrums für Luftund Raumfahrt e.V. (DLR)*. Retrieved from http://www.mobilitaet-in-deutschland.de/pdf/MiD2008_Abschlussbericht_I.pdf
- BMVBS. (2011). *Deutsches Mobilitätspanel (MOP) - wissenschaftliche Begleitung und erste Auswertungen, Bericht 2010*. <https://doi.org/10.5445/IR/1000032792>
- BMVBS. (2012a). *Mobilitätsstudie „ Kraftfahrzeugverkehr in Deutschland 2010 “ (KiD 2010) – Schlussbericht*. Braunschweig. Retrieved from <http://daten.clearingstelle-verkehr.de/240/9/KiD2010-Schlussbericht.pdf>
- BMVBS. (2012b). *Mobilitätsstudie „Kraftfahrzeugverkehr in Deutschland 2010“ - Ergebnisse im Überblick*. Braunschweig. Retrieved from https://www.bmvi.de/SharedDocs/DE/Anlage/G/kid-2010.pdf?__blob=publicationFile
- BMVi. (2018a). Die Zukunft fährt elektrisch. Retrieved April 18, 2018, from <http://www.bmvi.de/DE/Themen/Mobilitaet/Elektromobilitaet/Elektromobilitaet-kompakt/elektromobilitaet-kompakt.html>
- BMVi. (2018b). Mobilität in Deutschland (MiD) 2017. Retrieved December 18, 2018,

- from <https://www.bmwi.de/SharedDocs/DE/Artikel/G/mobilitaet-in-deutschland.html>
- BMW. (2018). Der neue BMW i3 und der neue BMW i3s. Retrieved June 12, 2018, from <https://www.bmw.de/de/neufahrzeuge/bmw-i/i3/2017/auf-einen-blick.html>
- BMWi. (2017). *Die Energiewende: unsere Erfolgsgeschichte*. Berlin. Retrieved from http://www.bmwi.de/Redaktion/DE/Publikationen/Energie/energiewende-beileger.pdf;jsessionid=82AE7B0B69337EE4A46536D6636D444B?__blob=publicationFile&v=29
- BMWi. (2018a). Der Strompreis. Retrieved July 1, 2018, from <https://www.bmwi.de/Redaktion/DE/Textsammlungen/Energie/strompreise.html>
- BMWi. (2018b). Unsere Energiewende: sicher, sauber, bezahlbar. Retrieved April 16, 2018, from <https://www.bmwi.de/Redaktion/DE/Dossier/energiewende.html>
- BNE. (2018). Chronik der Energiemarktöffnung – 1998 bis 2012. Retrieved April 18, 2018, from <http://www.bne-online.de/de/content/die-oeffnung-der-energiemaerkte-eine-chronik>
- BNetzA. (2018). Versorgungssicherheit. Retrieved April 19, 2018, from https://www.bundesnetzagentur.de/DE/Sachgebiete/ElektrizitaetundGas/Unternehmen_Institutionen/Versorgungssicherheit/versorgungssicherheit-node.html
- Bocken, N. M. P., Short, S. W., Rana, P., & Evans, S. (2014). A literature and practice review to develop sustainable business model archetypes. *Journal of Cleaner Production*, *65*, 42–56. <https://doi.org/10.1016/j.jclepro.2013.11.039>
- Bohnsack, R., Pinkse, J., & Kolk, A. (2014). Business models for sustainable technologies: Exploring business model evolution in the case of electric vehicles. *Research Policy*, *43*(2), 284–300. <https://doi.org/10.1016/j.respol.2013.10.014>
- Boons, F., & Lüdeke-Freund, F. (2013). Business models for sustainable innovation: State-of-the-art and steps towards a research agenda. *Journal of Cleaner Production*, *45*, 9–19. <https://doi.org/10.1016/j.jclepro.2012.07.007>
- Bozic, D., & Pantos, M. (2015). Impact of electric-drive vehicles on power system reliability. *Energy*, *83*, 511–520. <https://doi.org/10.1016/j.energy.2015.02.055>
- Braam, F., Groß, A., Mierau, M., Kohrs, R., & Wittwer, C. (2016). Coordinated charge management for battery electric vehicles. *Computer Science - Research and Development*. <https://doi.org/10.1007/s00450-016-0307-6>
- Brandt, T., Wagner, S., & Neumann, D. (2017). Evaluating a business model for vehicle-grid integration: Evidence from Germany. *Transportation Research Part D: Transport and Environment*, *50*, 488–504. <https://doi.org/10.1016/j.trd.2016.11.017>
- Bundensnetzagentur. (2016). Monitoringbericht 2016. Retrieved June 2, 2017, from https://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/Sachgebiete/Energie/Unternehmen_Institutionen/DatenaustauschUndMonitoring/Monitoring/Monitoringbericht2016.pdf?__blob=publicationFile&v=2

- Bundesnetzagentur; Bundeskartellamt. (2017). *Monitoringbericht 2017*. Bonn. Retrieved from https://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/Allgemeines/Bundesnetzagentur/Publikationen/Berichte/2017/Monitoringbericht_2017.pdf?__blob=publicationFile&v=3
- Bundesnetzagentur. (2019). *Regelenergie*. Retrieved March 6, 2019, from <https://www.bundesnetzagentur.de/DE/Sachgebiete/El>
- Bundesregierung. (2009). *Nationaler Entwicklungsplan Elektromobilität der Bundesregierung*. Retrieved from http://www.bmwi.de/Dateien/BMWi/PDF/nationaler-entwicklungsplan-elektromobilitaet-der-bundesregierung,property=pdf,bereich=bmwi,sprache=de,rwb=true.pdf%5Cnhttp://www.bmbf.de/pubRD/nationaler_entwicklungsplan_elektromobilitaet.pdf
- Bundesregierung. (2010). *Energiekonzept: für eine umweltschonende, zuverlässige und bezahlbare Energieversorgung*. Retrieved from <https://archiv.bundesregierung.de/resource/blob/656922/779770/794fd0c40425acd7f46afacbe62600f6/energiekonzept-final-data.pdf?download=1>
- Bundesregierung. (2018). *Energiewende im Überblick*. Retrieved from <https://www.bundesregierung.de/Content/DE/StatischeSeiten/Breg/Energiekonzept/0-Buehne/buehnenartikel-links-energiewende-im-ueberblick.html;jsessionid=E4E24B12E0B8FD5DE18AF987B7AFE44F.s5t2>
- BuW (Begleit- und Wirkungsforschung Schaufenster Elektromobilität). (2016). *Studie: Second-Life-Konzepte für Lithium-Ionen-Batterien aus Elektrofahrzeugen - Analyse von Nachnutzungsanwendungen, ökonomischen und ökologischen Potenzialen*. Retrieved from <https://www.ffe.de/download/article/620/StudieSecondLifeKonzepte.pdf>
- Chacón, J. E., & Duong, T. (2013). Data-driven density derivative estimation, with applications to nonparametric clustering and bump hunting. *Electronic Journal of Statistics*, 7(1), 499–532. <https://doi.org/10.1214/13-EJS781>
- Cherubini, S., Iasevoli, G., & Michelini, L. (2015). Product-service systems in the electric car industry: Critical success factors in marketing. *Journal of Cleaner Production*, 97, 40–49. <https://doi.org/10.1016/j.jclepro.2014.02.042>
- Clausen, J. (2018). *Roadmap Elektromobilität Deutschland. Ziele, Chancen, Risiken, notwendige Maßnahmen und politische Initiativen*. Retrieved from <https://evolution2green.de/sites/evolution2green.de/files/documents/borderstep31-1-18roadmap-e-mobilitaet.pdf%0Awww.borderstep.de/publikation/clausen-j-2018-roadmap-elektromobilitaet-in-deutschland-berlin-borderstep-institut/>
- Cramer, E., & Kamps, U. (2008a). *Grundlagen der Wahrscheinlichkeitsrechnung und Statistik*. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-540-77761-8>
- Cramer, E., & Kamps, U. (2008b). *Grundlagen der Wahrscheinlichkeitsrechnung und*

- Statistik - Ein Skript für Studierende der Informatik, der Ingenieur- und Wirtschaftswissenschaften.* <https://doi.org/10.1007/978-3-540-77761-8>
- Cuma, M. U., & Koroglu, T. (2015). A comprehensive review on estimation strategies used in hybrid and battery electric vehicles. *Renewable and Sustainable Energy Reviews*, 42, 517–531. <https://doi.org/10.1016/j.rser.2014.10.047>
- Dallinger, D., Gerda, S., & Wietschel, M. (2013). Integration of intermittent renewable power supply using grid-connected vehicles – A 2030 case study for California and Germany. *Applied Energy*, 104, 666–682. <https://doi.org/10.1016/j.apenergy.2012.10.065>
- Dallinger, D., Kohrs, R., Mierau, M., Marwitz, S., & Wesche, J. (2015). *Plug-in electric vehicles automated charging control.*
- Dantzig, G. G. B. (1955). Linear Programming under Uncertainty. *Management Science*. Retrieved from <http://www.springerlink.com/index/PQ4575968157751L.pdf%0Ahttp://mansci.journal.informs.org/content/1/3-4/197.short>
- Dempster, A. P., Laird, N. M., & Rubin, D. B. (1977). Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society Series B Methodological*, 39(1), 1–38. <https://doi.org/http://dx.doi.org/10.2307/2984875>
- dena. (2019). *Blockchain in der integrierten Energiewende.* Berlin. Retrieved from https://www.dena.de/fileadmin/dena/Publikationen/PDFs/2019/dena-Studie_Blockchain_Integrierte_Energiewende_DE4.pdf
- Denholm, P., & Hand, M. (2011). Grid flexibility and storage required to achieve very high penetration of variable renewable electricity. *Energy Policy*, 39(3), 1817–1830. <https://doi.org/10.1016/j.enpol.2011.01.019>
- Detzler, S., Eichhorn, C., & Karnouskos, S. (2015). Charging optimization of enterprise electric vehicles for participation in demand response. *Proceedings - 2015 International Symposium on Smart Electric Distribution Systems and Technologies, EDST 2015*, 284–289. <https://doi.org/10.1109/SEDST.2015.7315222>
- Detzler, S. K. (2017). *Lademanagement für Elektrofahrzeuge.* KIT Scientific Publishing, Karlsruhe. <https://doi.org/http://dx.doi.org/10.5445/KSP/1000057827>
- Dillig, M., Jung, M., & Karl, J. (2016). The impact of renewables on electricity prices in Germany – An estimation based on historic spot prices in the years 2011 – 2013. *Renewable and Sustainable Energy Reviews*, 57, 7–15. <https://doi.org/10.1016/j.rser.2015.12.003>
- DPDHL. (2018). Elektromobilität. Retrieved June 20, 2018, from <https://www.dpdhl.com/de/presse/specials/electro-mobility.html>
- Druitt, J., & Früh, W.-G. (2012). Simulation of demand management and grid balancing with electric vehicles. *Journal of Power Sources*, 216, 104–116. <https://doi.org/10.1016/j.jpowsour.2012.05.033>
- Dupacová, J., Consigli, G., & Wallace, S. W. (2000). Scenarios for Multistage Stochastic

- Programs. *Annals of Operations Research*, 100(1), 25–53.
<https://doi.org/10.1023/A:1019206915174>
- e-mobil BW. (2015). *STRUKTURSTUDIE BWe MOBIL 2015 - Elektromobilität in Baden-Württemberg*. Retrieved from http://www.e-mobilbw.de/files/e-mobil/content/DE/Publikationen/PDF/14524_Strukturstudie_RZ_WebPDF.pdf
- EEX. (2015). *Energy_Spot_History_2013*. Retrieved January 12, 2015, from <https://www.eex.com/de/marktdaten/marktdaten-download>
- EEX. (2018). EU Emission Allowances. Retrieved August 9, 2018, from <https://www.eex.com/en/market-data/environmental-markets/spot-market/european-emission-allowances#!/2018/08/09>
- Ehsani, M., Falahi, M., & Lotfifard, S. (2012). Vehicle to Grid Services: Potential and Applications. *Energies*, 5(12), 4076–4090. <https://doi.org/10.3390/en5104076>
- El Heda, K., & Louani, D. (2018). Optimal bandwidth selection in kernel density estimation for continuous time dependent processes. *Statistics & Probability Letters*. <https://doi.org/10.1016/j.spl.2018.02.001>
- Emelogu, A., Chowdhury, S., Marufuzzaman, M., Bian, L., & Eksioglu, B. (2016). An enhanced sample average approximation method for stochastic optimization. *International Journal of Production Economics*, 182, 230–252. <https://doi.org/10.1016/j.ijpe.2016.08.032>
- Ensslen, A., Gnann, T., Jochem, P., Plötz, P., Dütschke, E., & Fichtner, W. (2018). Can product service systems support electric vehicle adoption? *Transportation Research Part A: Policy and Practice*, 2008(xxxx), 1–17. <https://doi.org/10.1016/j.tra.2018.04.028>
- Ensslen, A., Ringler, P., Dörr, L., Jochem, P., Zimmermann, F., & Fichtner, W. (2018). Energy Research & Social Science Incentivizing smart charging : Modeling charging tariffs for electric vehicles in German and French electricity markets. *Energy Research & Social Science*, 42(June 2017), 112–126. <https://doi.org/10.1016/j.erss.2018.02.013>
- Ensslen, A., Ringler, P., Jochem, P., Keles, D., & Fichtner, W. (2014). About business model specifications of a smart charging manager to integrate electric vehicles into the German electricity market. In *14th IAEE European Conference*.
- Ensslen, A., Schücking, M., Jochem, P., Steffens, H., Fichtner, W., Wollersheim, O., & Stella, K. (2017). Empirical carbon dioxide emissions of electric vehicles in a French-German commuter fleet test. *Journal of Cleaner Production*, 142, 263–278. <https://doi.org/10.1016/j.jclepro.2016.06.087>
- EPEX. (2019). Integrierte Intraday-Märkte: Optimale Flexibilität. Retrieved April 10, 2019, from https://www.epexspot.com/de/erneuerbare_energien/integrierte_intraday_märkte
- Faddel, S., Al-awami, A. T., & Abido, M. A. (2017). Fuzzy Optimization for the Operation of Electric Vehicle Parking Lots. *Electric Power Systems Research*, 145, 166–174.

- <https://doi.org/10.1016/j.eprs.2017.01.008>
- Fahrmeir, L., Künstler, R., Pigeot, I., & Tutz, G. (2010). *Statistik*. Springer Verlag. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-01939-5>
- FAZ. (2017). Mobilität. Zahl der Pendler erreicht Rekord. Retrieved June 18, 2018, from <http://www.faz.net/aktuell/wirtschaft/neue-mobilitaet/mobilitaet-zahl-der-pendler-erreicht-rekord-14953778.html>
- Feinberg, J., & Petter, H. (2015). Chaospy : An open source tool for designing methods of uncertainty quantification. *Journal of Computational Science*, *11*, 46–57.
- Feng, Y., & Ryan, S. M. (2013). Scenario construction and reduction applied to stochastic power generation expansion planning. *Computers and Operations Research*, *40*(1), 9–23. <https://doi.org/10.1016/j.cor.2012.05.005>
- Figueiredo, R., Nunes, P., & Brito, M. C. (2017). The feasibility of solar parking lots for electric vehicles. *Energy*, *140*, 1182–1197. <https://doi.org/10.1016/j.energy.2017.09.024>
- Flath, C. M., Ilg, J. P., Gottwalt, S., Schmeck, H., & Weinhardt, C. (2013). Improving Electric Vehicle Charging Coordination Through Area Pricing. *Transportation Science*, *48*(4), 619–634. <https://doi.org/10.1287/trsc.2013.0467>
- Fraunhofer ISE. (2014). *Aktuelle Fakten zur Photovoltaik in Deutschland* (Vol. 49). Retrieved from <https://www.ise.fraunhofer.de/de/veroeffentlichungen/veroeffentlichungen-pdf-dateien/studien-und-konzeptpapiere/aktuelle-fakten-zur-photovoltaik-in-deutschland.pdf>
- Fraunhofer ISE. (2018). *Stromgestehungskosten Erneuerbare Energien*. Retrieved from https://www.ise.fraunhofer.de/content/dam/ise/de/documents/publications/studies/DE2018_ISE_Studie_Stromgestehungskosten_Erneuerbare_Energien.pdf
- Freimer, M. B., Linderoth, J. T., & Thomas, D. J. (2012). The impact of sampling methods on bias and variance in stochastic linear programs. *Computational Optimization and Applications*, *51*(1), 51–75. <https://doi.org/10.1007/s10589-010-9322-x>
- García-Villalobos, J., Zamora, I., San Martín, J. I., Asensio, F. J., & Aperribay, V. (2014). Plug-in electric vehicles in electric distribution networks: A review of smart charging approaches. *Renewable and Sustainable Energy Reviews*, *38*, 717–731. <https://doi.org/10.1016/j.rser.2014.07.040>
- Gellings, C. W., & Smith, W. M. (1989). Integrating demand-side management into utility planning. *Proceedings of the IEEE*, *77*(6), 908–918. <https://doi.org/10.1109/5.29331>
- Gentle, J. E., Härdle, W. K., & Mori, Y. (2011). *Handbook of Computational Statistics*. (H. H.-S. Lu, B. Schölkopf, & H. Zhao, Eds.), *Methods*. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-16345-6>
- Gottwalt, S., Garttner, J., Schmeck, H., & Weinhardt, C. (2016). Modeling and Valuation of Residential Demand Flexibility for Renewable Energy Integration. *IEEE Transactions on Smart Grid*, 1–10. <https://doi.org/10.1109/TSG.2016.2529424>

- Gottwalt, S., Schuller, A., Flath, C., Schmeck, H., & Weinhardt, C. (2013). Assessing load flexibility in smart grids: Electric vehicles for renewable energy integration. *2013 IEEE Power & Energy Society General Meeting*, 1–5. <https://doi.org/10.1109/PESMG.2013.6672854>
- Gunningham, N. (2013). Managing the energy trilemma: The case of Indonesia. *Energy Policy*, *54*, 184–193. <https://doi.org/10.1016/j.enpol.2012.11.018>
- Guo, F., Yang, J., & Lu, J. (2018). The battery charging station location problem: Impact of users' range anxiety and distance convenience. *Transportation Research Part E: Logistics and Transportation Review*, *114*(April), 1–18. <https://doi.org/10.1016/j.tre.2018.03.014>
- Hafez, O., & Bhattacharya, K. (2017). Optimal design of electric vehicle charging stations considering various energy resources. *Renewable Energy*, *107*, 576–589. <https://doi.org/10.1016/j.renene.2017.01.066>
- Hardman, S., Jenn, A., Tal, G., Aksen, J., Beard, G., Daina, N., ... Witkamp, B. (2018). A review of consumer preferences of and interactions with electric vehicle charging infrastructure. *Transportation Research Part D: Transport and Environment*, *62*, 508–523. <https://doi.org/10.1016/j.trd.2018.04.002>
- Hargroves, K. J., & Smith, M. H. (2005). *The Natural Advantage of Nations. Governance An International Journal Of Policy And Administration*. London: Earthscan. <https://doi.org/10.4324/9781849773133>
- Hauff, J., Heider, C., Arms, H., & Gerber, J. (2011). Gesellschaftliche Akzeptanz als Säule der energiepolitischen Zielsetzung. *Energiewirtschaftliche Tagesfragen*, 85–87.
- Heffron, R. J., McCauley, D., & Sovacool, B. K. (2015). Resolving society's energy trilemma through the Energy Justice Metric. *Energy Policy*, *87*, 168–176. <https://doi.org/10.1016/j.enpol.2015.08.033>
- Herbst, A., Toro, F., Reitze, F., & Jochem, E. (2012). Introduction to energy systems modelling. *Swiss Journal of Economics and Statistics*, *148*(2), 111–135. <https://doi.org/10.1126/science.1111772>
- Hintze, J. L., & Nelson, R. D. (1998). Violin Plots: A Box Plot-Density Trace Synergism. *The American Statistician*, *52*(2), 181–184. <https://doi.org/10.1080/00031305.1998.10480559>
- Hofmann, P. (2014). *Hybridfahrzeuge: Ein alternatives Antriebssystem für die Zukunft*. (Intergovernmental Panel on Climate Change, Ed.) (Vol. 53). Vienna: Springer Vienna. <https://doi.org/10.1007/978-3-7091-1780-4>
- Homem-De-Mello, T., De Matos, V. L., & Finardi, E. C. (2011). Sampling strategies and stopping criteria for stochastic dual dynamic programming: A case study in long-term hydrothermal scheduling. *Energy Systems*, *2*(1), 1–31. <https://doi.org/10.1007/s12667-011-0024-y>
- Honarmand, M., Zakariazadeh, A., & Jadid, S. (2014). Integrated scheduling of renewable generation and electric vehicles parking lot in a smart microgrid. *Energy Conversion*

- and Management*, 86, 745–755. <https://doi.org/10.1016/j.enconman.2014.06.044>
- Honarmand, M., Zakariazadeh, A., & Jadid, S. (2015). Self-scheduling of electric vehicles in an intelligent parking lot using stochastic optimization. *Journal of the Franklin Institute*, 352(2), 449–467. <https://doi.org/10.1016/j.jfranklin.2014.01.019>
- Hou, C., Xu, L., Wang, H., Ouyang, M., & Peng, H. (2015). Energy management of plug-in hybrid electric vehicles with unknown trip length. *Journal of the Franklin Institute*, 352(2), 500–518. <https://doi.org/10.1016/j.jfranklin.2014.07.009>
- Hu, J., Morais, H., Sousa, T., & Lind, M. (2016). Electric vehicle fleet management in smart grids: A review of services, optimization and control aspects. *Renewable and Sustainable Energy Reviews*, 56, 1207–1226. <https://doi.org/10.1016/j.rser.2015.12.014>
- Hubject. (2018). Lernen Sie Hubject kennen. Retrieved June 12, 2018, from <https://www.hubject.com/ueber-uns/>
- IEA. (2018a). *CO₂ emissions from fuel combustion 2018*. https://doi.org/10.1787/co2_fuel-2018-en
- IEA. (2018b). *Global EV Outlook 2018: Towards cross-modal electrification*. Retrieved from <https://webstore.iea.org/download/direct/1045?filename=globalevoutlook2018.pdf>
- Intercharge. (2018). Das Zeichen für einfache Elektromobilität. Retrieved December 18, 2018, from <http://www.intercharge.eu/>
- ISO. (2013). ISO 15118-1:2013. Retrieved May 23, 2018, from <https://www.iso.org/standard/55365.html>
- Iversen, E. B., Morales, J. M., & Madsen, H. (2014). Optimal charging of an electric vehicle using a Markov decision process. *Applied Energy*, 123, 1–12. <https://doi.org/10.1016/j.apenergy.2014.02.003>
- Ji, W., & Chee, K. C. (2011). Prediction of hourly solar radiation using a novel hybrid model of ARMA and TDNN. *Solar Energy*, 85(5), 808–817. <https://doi.org/10.1016/j.solener.2011.01.013>
- Jochem, P. (2016). *Electric Mobility & Energy Systems: A techno-economic impact analysis of electric vehicles on the energy system*. KIT, Karlsruhe.
- Jochem, P., Babrowski, S., & Fichtner, W. (2015). Assessing CO₂ emissions of electric vehicles in Germany in 2030. *Transportation Research Part A: Policy and Practice*, 78, 68–83. <https://doi.org/10.1016/j.tra.2015.05.007>
- Jochem, P., Gómez Vilchez, J. J., Ensslen, A., Schäuble, J., & Fichtner, W. (2017). Methods for forecasting the market penetration of electric drivetrains in the passenger car market. *Transport Reviews*, 1647(May), 1–27. <https://doi.org/10.1080/01441647.2017.1326538>
- Jochem, P., Kaschub, T., & Fichtner, W. (2014). How to Integrate Electric Vehicles in the Future Energy System? In C. Hanke, M. Hülsmann, & D. Fornahl (Eds.),

- Evolutionary Paths Towards the Mobility Patterns of the Future* (pp. 243–263). <https://doi.org/10.1007/978-3-642-37558-3>
- Jochem, P., März, A., & Wang, Z. (2018). How Might the German Distribution Grid Cope With 100% Market Share of PEV? In *Proceedings of the 31th International Electric Vehicle Symposium & Exhibition*.
- Juul, F., Negrete-pincetic, M., Macdonald, J., & Callaway, D. (2015). Real-time Scheduling of Electric Vehicles for Ancillary Services. *IEEE Power & Energy Society General Meeting*, 1–6. <https://doi.org/10.1109/PESGM.2015.7286093>
- Kall, P., & Mayer, J. (2011). *Stochastic Linear Programming* (2nd ed., Vol. 156). Boston, MA: Springer US. <https://doi.org/10.1007/978-1-4419-7729-8>
- Kaschub, T. (2017). *Batteriespeicher in Haushalten unter Berücksichtigung von Photovoltaik, Elektrofahrzeugen und Nachfrigesteuerung*. KIT Scientific Publishing. <https://doi.org/http://dx.doi.org/10.5445/KSP/1000071259>
- Kaschub, T., Jochem, P., & Fichtner, W. (2016). Solar energy storage in German households: profitability, load changes and flexibility, 98, 520–532. <https://doi.org/10.1016/j.enpol.2016.09.017>
- Kaschub, T., Mültin, M., Schmeck, H., Fichtner, W., & Kessler, A. (2010). Intelligentes Laden von batterieelektrischen Fahrzeugen im Kontext eines Stadtviertels. In *VDE Kongress*. Leipzig.
- KBA. (2018a). Homepages des KBA - Bestand Kraftfahrzeuge. Retrieved April 26, 2018, from https://www.kba.de/DE/Statistik/Fahrzeuge/Bestand/Umwelt/umwelt_node.html
- KBA. (2018b). Jahresbilanz der Neuzulassungen 2017. Retrieved April 26, 2018, from https://www.kba.de/DE/Statistik/Fahrzeuge/Neuzulassungen/n_jahresbilanz.html
- Kempton, W., & Tomić, J. (2005). Vehicle-to-grid power implementation: From stabilizing the grid to supporting large-scale renewable energy. *Journal of Power Sources*, 144(1), 280–294. <https://doi.org/10.1016/j.jpowsour.2004.12.022>
- Ketelaer, T., Kaschub, T., Jochem, P., & Fichtner, W. (2014). The Potential of Carbon Dioxide Emission Reductions in German Commercial Transport by Electric Vehicles. *International Journal of Environmental Science and Technology*.
- Ketterer, B., Karl, U., Möst, D., & Ulrich, S. (2009). *Lithium-Ionen Batterien: Stand der Technik und Anwendungspotenzial in Hybrid-, Plug-In Hybrid- und Elektrofahrzeugen*. <https://doi.org/10.5445/IR/270081162>
- Khoo, Y. B., Wang, C. H., Paevere, P., & Higgins, A. (2014). Statistical modeling of Electric Vehicle electricity consumption in the Victorian EV Trial, Australia. *Transportation Research Part D: Transport and Environment*, 32, 263–277. <https://doi.org/10.1016/j.trd.2014.08.017>
- KIA. (2018). Der Kia Soul EV. Retrieved June 12, 2018, from <https://www.kia.com/de/modelle/soul-ev/entdecken/#/>

- Kim, S., Pasupathy, R., & Henderson, S. G. (2011). A Guide to Sample-Average Approximation. *Handbook of Simulation Optimization*, 1–26. <https://doi.org/10.1057/palgrave.jors.2602370>
- King, A. J., & Wallace, S. W. (2012). *Modeling with Stochastic Programming*. Springer New York. <https://doi.org/10.1007/0-387-33477-7>
- Kley, F., Lerch, C., & Dallinger, D. (2011). New business models for electric cars—A holistic approach. *Energy Policy*, 39(6), 3392–3403. <https://doi.org/10.1016/j.enpol.2011.03.036>
- Kleywegt, A. J., Shapiro, A., & Homem-de-Mello, T. (2002). The Sample Average Approximation Method for Stochastic Discrete Optimization. *SIAM Journal on Optimization*, 12(2), 479–502. <https://doi.org/10.1137/S1052623499363220>
- Köllner, C. (2017, June 6). Reichweite von Elektroautos steigt weiter. Retrieved from <https://www.springerprofessional.de/elektrofahrzeuge/batterie/reichweite-von-elektroautos-steigt-weiter/12323466>
- Konstantin, P. (2017). *Praxisbuch Energiewirtschaft*. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-662-49823-1>
- Krewitt, W., & Schlomann, B. (2006). *Externe Kosten der Stromerzeugung aus erneuerbaren Energien im Vergleich zur Stromerzeugung aus fossilen Energieträgern Stuttgart*. <https://doi.org/10.1065/uwsf2007.06.193>
- Krickel, F. (2015). Digitalisierung in der Energiewirtschaft. In W. Hecker, C. Lau, & A. Müller (Eds.), *Zukunftsorientierte Unternehmenssteuerung in der Energiewirtschaft* (pp. 1836–1839). Wiesbaden: Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-07816-4>
- Kroese, D. P., Taimre, T., & Botev, Z. I. (2011). *Handbook of Monte Carlo Methods. Handbook of Monte Carlo Methods*. Hoboken, NJ, USA: John Wiley & Sons, Inc. <https://doi.org/10.1002/9781118014967>
- Law, A. M. (2015). *Simulation modeling and analysis* (5th ed.). New York: McGraw-Hill Education.
- Li, Y., Davis, C., Lukszo, Z., & Weijnen, M. (2016). Electric vehicle charging in China's power system: Energy, economic and environmental trade-offs and policy implications. *Applied Energy*, 173(2016), 535–554. <https://doi.org/10.1016/j.apenergy.2016.04.040>
- Li, Y., Kaewpuang, R., Wang, P., Niyato, D., & Han, Z. (2012). An energy efficient solution: Integrating Plug-In Hybrid Electric Vehicle in smart grid with renewable energy. *2012 IEEE Conference on Computer Communications Workshops*, 73–78. <https://doi.org/10.1109/INFCOMW.2012.6193522>
- Liu, L., Kong, F., Liu, X., Peng, Y., & Wang, Q. (2015). A review on electric vehicles interacting with renewable energy in smart grid. *Renewable and Sustainable Energy Reviews*, 51, 648–661. <https://doi.org/10.1016/j.rser.2015.06.036>
- Long, Y., Lee, L. H., & Chew, E. P. (2012). The sample average approximation method

- for empty container repositioning with uncertainties. *European Journal of Operational Research*, 222(1), 65–75. <https://doi.org/10.1016/j.ejor.2012.04.018>
- Luenberger, D. G., & Ye, Y. (2016). *Linear and Nonlinear Programming*. Springer (Vol. 228). Cham: Springer International Publishing. <https://doi.org/10.1007/978-3-319-18842-3>
- Madina, C., Zamora, I., & Zabala, E. (2016). Methodology for assessing electric vehicle charging infrastructure business models. *Energy Policy*, 89, 284–293. <https://doi.org/10.1016/j.enpol.2015.12.007>
- Magdowski, A., & Kaltschmitt, M. (2017). Prognose der Day-Ahead Wind- und Photovoltaikstromerzeugung – Einflussgrößen und Zuverlässigkeit, 57–71. <https://doi.org/10.1007/s12398-016-0190-7>
- Marinelli, M., Zecchino, A., & Andersen, P. B. (2017). Supporting involvement of electric vehicles in distribution grids : Lowering the barriers for a proactive integration, 134, 458–468. <https://doi.org/10.1016/j.energy.2017.06.075>
- Martí, K. (2008). *Stochastic Optimization Methods*. Springer. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-540-79458-5>
- McKay, M. D., Beckman, R. J., & Conover, W. J. (1979). Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code. *Technometrics*, 21(2), 239–245. <https://doi.org/10.1080/00401706.1979.10489755>
- McLachlan, G. J., & Krishnan, T. (2008). *The EM Algorithm and Extensions*, 2E. Hoboken, NJ, USA: John Wiley & Sons, Inc. <https://doi.org/10.1002/9780470191613>
- Meteotest. (2014). Wir sind Meteotest. Retrieved March 1, 2014, from <http://www.meteotest.ch/>
- Model3.info. (2018). Tesla Model 3 - Technische Daten. Retrieved June 12, 2018, from <https://www.model3.info/de/tesla-model-3-technische-daten>
- Mohammadi, S., Soleymani, S., & Mozafari, B. (2014). Scenario-based stochastic operation management of MicroGrid including Wind, Photovoltaic, Micro-Turbine, Fuel Cell and Energy Storage Devices. *International Journal of Electrical Power and Energy Systems*, 54, 525–535. <https://doi.org/10.1016/j.ijepes.2013.08.004>
- Momber, I., Member, S., Siddiqui, A., Gómez, T., Román, S., & Member, S. (2015). Risk Averse Scheduling by a PEV Aggregator Under Uncertainty. *IEEE Transactions on Power Systems*, 30(2), 882–891.
- MongoDB. (2018). The MongoDB 4.0 Manual. Retrieved August 6, 2018, from <https://docs.mongodb.com/manual/>
- Mouli, G. R. C., Kaptein, J., Bauer, P., & Zeman, M. (2016). Implementation of dynamic charging and V2G using Chademo and CCS/Combo DC charging standard. *2016 IEEE Transportation Electrification Conference and Expo, ITEC 2016*. <https://doi.org/10.1109/ITEC.2016.7520271>

- Mültin, M. (2014). *Das Elektrofahrzeug als flexibler Verbraucher und Energiespeicher im Smart Home*. Karlsruhe Institut für Technologie. <https://doi.org/10.5445/IR/1000042102>
- Mwasilu, F., Justo, J. J., Kim, E. K., Do, T. D., & Jung, J. W. (2014). Electric vehicles and smart grid interaction: A review on vehicle to grid and renewable energy sources integration. *Renewable and Sustainable Energy Reviews*, 34, 501–516. <https://doi.org/10.1016/j.rser.2014.03.031>
- Nair, S., & Paulose, H. (2014). Emergence of green business models: The case of algae biofuel for aviation. *Energy Policy*, 65, 175–184. <https://doi.org/10.1016/j.enpol.2013.10.034>
- Nationale Plattform Elektromobilität. (2014). *Fortschrittsbericht 2014 - Bilanz der Marktvorbereitung*. Berlin. Retrieved from https://www.bmbf.de/files/NPE_Fortschrittsbericht_2014_barrierefrei.pdf
- Neumann, H.-M., Schär, D., & Baumgartner, F. (2012). The potential of photovoltaic carports to cover the energy demand of road passenger transport. *Progress in Photovoltaics: Research and Applications*, 20(6), 639–649. <https://doi.org/10.1002/pip.1199>
- Nickel, S., Stein, O., & Waldmann, K.-H. (2014). *Operations Research* (2nd ed.). Berlin; Heidelberg: Springer Gabler.
- Nissan. (2018). Der neue Nissan LEAF, Broschüre und Preisliste. Retrieved June 12, 2018, from <https://www.nissan.de/content/dam/Nissan/de/brochures/pkw/leaf-2018-broschuere-preisliste.pdf>
- NPE. (2015). *Ladeinfrastruktur für Elektrofahrzeuge in Deutschland - Statusbericht und Handlungsempfehlungen 2015. Gemeinsame Geschäftsstelle Elektromobilität der Bundesregierung (GGEMO)*. Retrieved from http://nationale-plattform-elektromobilitaet.de/fileadmin/user_upload/Redaktion/NPE_AG3_Statusbericht_LI_S_2015_barr_bf.pdf
- NPE. (2016). *Wegweiser Elektromobilität*. Berlin. Retrieved from http://nationale-plattform-elektromobilitaet.de/fileadmin/user_upload/Redaktion/Wegweiser_Elektromobilitaet_2016_web_bf.pdf
- NPE. (2017). *Die Deutsche Normungs-Roadmap Elektromobilität 2020*. Berlin. Retrieved from http://nationale-plattform-elektromobilitaet.de/fileadmin/user_upload/Redaktion/Publikationen/NormungsRoadmap_Elektromobilitaet_2020_bf.pdf
- Nunes, P., Figueiredo, R., & Brito, M. C. (2016). The use of parking lots to solar-charge electric vehicles. *Renewable and Sustainable Energy Reviews*, 66, 679–693. <https://doi.org/10.1016/j.rser.2016.08.015>
- Omar, N. (2018). *Future and Emerging Technologies Workshop on Future Battery Technologies for Energy Storage*. Retrieved from <https://ec.europa.eu/digital-single-market/en/news/fet-workshop-future-battery-technologies-energy-storage>

- Open Charge Alliance. (2018). Protocols OCPP 2.0. Retrieved June 22, 2018, from <https://www.openchargealliance.org/protocols/ocpp/ocpp-20/>
- Osterwalder, A. (2004). The Business Model Ontology - A Proposition in a Design Science Approach. *Business, Doctor*, 1–169. <https://doi.org/10.1111/j.1467-9310.2010.00605.x>
- Osterwalder, A., Pigneur, Y., & Tucci, C. L. (2005). Clarifying Business Models : Origins , Present , and Future of the Concept. *Communications of the Association for Information Systems*, 15(May), 1–125. <https://doi.org/10.1.1.83.7452>
- Paetz, A. G., Kaschub, T., Jochem, P., & Fichtner, W. (2013). Load-shifting potentials in households including electric mobility - A comparison of user behaviour with modelling results. *International Conference on the European Energy Market, EEM*. <https://doi.org/10.1109/EEM.2013.6607324>
- Papageorgiou, M., Leibold, M., & Buss, M. (2012). *Optimierung*. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-540-34013-3>
- Paraschiv, F., Erni, D., & Pietsch, R. (2014). The impact of renewable energies on EEX day-ahead electricity prices. *Energy Policy*, 73, 196–210. <https://doi.org/10.1016/j.enpol.2014.05.004>
- Paschotta, R. (2018). CO2-Vermeidungskosten im RP-Energie-Lexikon. Retrieved August 8, 2018, from https://www.energie-lexikon.info/co2_vermeidungskosten.html
- Paterakis, N. G., Erdinç, O., & Catalão, J. P. S. (2017). An overview of Demand Response: Key-elements and international experience. *Renewable and Sustainable Energy Reviews*, 69(July 2016), 871–891. <https://doi.org/10.1016/j.rser.2016.11.167>
- Paterakis, N. G., & Gibescu, M. (2016). A methodology to generate power profiles of electric vehicle parking lots under different operational strategies. *Applied Energy*, 173, 111–123. <https://doi.org/10.1016/j.apenergy.2016.04.024>
- PBW. (2013). Parkraumgesellschaft Baden-Württemberg mbH. Retrieved December 12, 2013, from <https://www.pbw.de/>
- PBW. (2019). Parkgarage Schlossplatz in Karlsruhe: e-parken. Retrieved March 10, 2019, from https://www.pbw.de/?cmd=e-parken&id_city=7&id_object=104
- Perez-Diaz, A., Gerding, E., & McGroarty, F. (2018). Coordination and payment mechanisms for electric vehicle aggregators. *Applied Energy*, 212(July 2017), 185–195. <https://doi.org/10.1016/j.apenergy.2017.12.036>
- Pflug, G. C., & Pichler, A. (2014). *Multistage Stochastic Optimization*. Cham: Springer International Publishing. <https://doi.org/10.1007/978-3-319-08843-3>
- Pfriem, M., & Gauterin, F. (2013). Less range as a possible solution for the market success of electric vehicles in commercial fleets. In *2013 World Electric Vehicle Symposium and Exhibition (EVS27)* (pp. 1–8). IEEE. <https://doi.org/10.1109/EVS.2013.6914727>
- Pittel, K. (2012). Das energiepolitische Zieldreieck und die Energiewende. *Ifo Schnelldienst*, (2011), 22–26.

- Plötz, P., Jakobsson, N., & Sprei, F. (2017). On the distribution of individual daily driving distances. *Transportation Research Part B*, 101, 213–227. <https://doi.org/10.1016/j.trb.2017.04.008>
- PTJ. (2019). Elektrofahrzeuge und Infrastruktur eine Initiative des Bundesministeriums für Verkehr und digitale Infrastruktur (BMVI). Retrieved April 12, 2019, from <https://www.ptj.de/projektfoerderung/elektromobilitaet-bmvi/invest>
- PwC. (2016). *Blockchain – Chance für Energieverbraucher?* Retrieved from <https://www.pwc.de/de/energiewirtschaft/blockchain-chance-fuer-energieverbraucher.pdf>
- Radgen, P. (2018). Von der Schwierigkeit, nicht nur im Kopf umzuparken – Ein Selbstversuch zur Elektromobilität. In O. Kühne & F. Weber (Eds.), *Bausteine der Energiewende*. Wiesbaden: Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-19509-0>
- Rahbari, O., Vafaeipour, M., Omar, N., Rosen, M. A., Hegazy, O., Timmermans, J.-M., ... Bossche, P. Van Den. (2017). An optimal versatile control approach for plug-in electric vehicles to integrate renewable energy sources and smart grids. *Energy*. <https://doi.org/10.1016/j.energy.2017.06.007>
- Rahman, I., Vasant, P. M., Singh, B. S. M., Abdullah-Al-Wadud, M., & Adnan, N. (2016). Review of recent trends in optimization techniques for plug-in hybrid, and electric vehicle charging infrastructures. *Renewable and Sustainable Energy Reviews*, 58, 1039–1047. <https://doi.org/10.1016/j.rser.2015.12.353>
- Renault. (2017). Der neue Renault Zoe. Retrieved June 12, 2018, from https://www.cdn.renault.com/content/dam/Renault/AT/downloadcenter/zoe/PL_ZOE.pdf
- Reuters. (2018). EU agrees deal to cut greenhouse emissions from cars. Retrieved December 20, 2018, from <https://www.reuters.com/article/us-eu-autos-emissions-idUSKBN1OG278>
- Reynolds, D. a. (2008). Gaussian Mixture Models. *Encyclopedia of Biometric Recognition*, 31(2), 1047–1064. <https://doi.org/10.1088/0967-3334/31/7/013>
- Richardson, D. B. (2013). Electric vehicles and the electric grid: A review of modeling approaches, Impacts, and renewable energy integration. *Renewable and Sustainable Energy Reviews*, 19, 247–254. <https://doi.org/10.1016/j.rser.2012.11.042>
- Saber, A. Y., & Venayagamoorthy, G. K. (2012). Resource scheduling under uncertainty in a smart grid with renewables and plug-in vehicles. *IEEE Systems Journal*, 6(1), 103–109. <https://doi.org/10.1109/JSYST.2011.2163012>
- Sachs, B., Ungerer, L., Jochem, P., Ensslen, A., Fichtner, W., & Globisch, J. (2016). *Betreibermodell Elektro-Flotten in Stuttgart - Get e-Ready: FuE-Programm "Schaufenster Elektromobilität" der Bundesregierung: gemeinsamer Abschlussbericht : Laufzeit des Vorhabens vom: 01.01.2013 bis: 30.06.2016*. Bosch Software Innovations GmbH. <https://doi.org/https://doi.org/10.2314/GBV:873380274>

- Salah, F., & Flath, C. M. (2016). Deadline differentiated pricing in practice: marketing EV charging in car parks. *Computer Science - Research and Development*, 31(1–2), 33–40. <https://doi.org/10.1007/s00450-014-0293-5>
- Salah, F., Flath, C. M., Schuller, A., Will, C., & Weinhardt, C. (2016). Morphological analysis of energy services: Paving the way to quality differentiation in the power sector. *Energy Policy*. <https://doi.org/10.1016/j.enpol.2017.03.024>
- Schade, K. (2012). Stochastische Optimierung. In *Stochastische Optimierung*. https://doi.org/10.1007/978-3-8348-8345-2_4
- Schäuble, J., Balaban, S., Krasselt, P., Jochem, P., Özkan, M., Schellhas-Mende, F., ... Raabe, O. (2016). *Vergleichsstudie von Systemansätzen für das Schnellladen von Elektrofahrzeugen*. Retrieved from <http://digbib.ubka.uni-karlsruhe.de/volltexte/1000053148>
- Schellong, W. (2016). *Analyse und Optimierung von Energieverbundsystemen*. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-662-49463-9>
- Schmidt, O., Hawkes, A., Gambhir, A., & Staffell, I. (2017). The future cost of electrical energy storage based on experience rates. *Nature Energy*, 6(July), 17110. <https://doi.org/10.1038/nenergy.2017.110>
- Schuller, A., Flath, C. M., & Gottwalt, S. (2015). Quantifying load flexibility of electric vehicles for renewable energy integration. *Applied Energy*, 151, 335–344. <https://doi.org/10.1016/j.apenergy.2015.04.004>
- Schuller, A., & Hoeffler, J. (2014). Assessing the impact of EV mobility patterns on renewable energy oriented charging strategies. *Energy Procedia*, 46, 32–39. <https://doi.org/10.1016/j.egypro.2014.01.155>
- Schwab, A. J. (2017). *Elektroenergiesysteme*. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-662-55316-9>
- Seddig, K., Jochem, P., & Fichtner, W. (2014). Fleets of electric vehicles as adjustable loads - Facilitating the integration of electricity generation by renewable energy sources. In *Proceedings of the 37th IAEE International Conference*. New York: Proceedings of the 37th IAEE International Conference.
- Seddig, K., Jochem, P., & Fichtner, W. (2017a). A Framework for Electric Mobility Services for a Car Park. In *Proceedings of the Third Karlsruhe Service Summit Research Workshop*. Karlsruhe.
- Seddig, K., Jochem, P., & Fichtner, W. (2017b). Integrating renewable energy sources by electric vehicle fleets under uncertainty. *Energy*, 141, 2145–2153. <https://doi.org/10.1016/j.energy.2017.11.140>
- Seddig, K., Jochem, P., & Fichtner, W. (2019a). A Framework for Electric Mobility Services for a Car Park BT - Proceedings of the KSS Research Workshop: A Selection of Talks and Presentations on Designing the Digital Transformation. Ed.: S. Morana (pp. 21–26). Karlsruhe, Deutschland: KIT, Karlsruhe. <https://doi.org/10.5445/IR/1000104514>

- Seddig, K., Jochem, P., & Fichtner, W. (2019b). Two-stage stochastic optimization for cost-minimal charging of electric vehicles at public charging stations with photovoltaics. *Applied Energy*, 242, 769–781. <https://doi.org/10.1016/j.apenergy.2019.03.036>
- Shaaban, M. F., & El-Saadany, E. F. (2014). Accommodating high penetrations of pevs and renewable dg considering uncertainties in distribution systems. *IEEE Transactions on Power Systems*, 29(1), 259–270. <https://doi.org/10.1109/TPWRS.2013.2278847>
- Shapiro, A. (2006). On complexity of multistage stochastic programs. *Operations Research Letters*, 34(1), 1–8. <https://doi.org/10.1016/j.orl.2005.02.003>
- Shapiro, A. (2008). *Stochastic programming approach to optimization under uncertainty. Mathematical Programming* (Vol. 112). <https://doi.org/10.1007/s10107-006-0090-4>
- Shapiro, A., Dentcheva, D., & Ruszczyński, A. (2009). *Lectures on Stochastic Programming. Technology*. Philadelphia: Society for Industrial and Applied Mathematics. <https://doi.org/10.1137/1.9780898718751>
- Sheather, S. J. (2004). Density Estimation. *Statistical Science*, 19(4), 588–597. <https://doi.org/10.1214/088342304000000297>
- Silverman, B. W. (1998). *Density Estimation for Statistics and Data Analysis*. London; New York: Chapman & Hall. Retrieved from <http://www.jstor.org/stable/10.2307/2347507?origin=crossref>
- Smart. (2018). Smart EQ fortwo und forfour. Retrieved June 12, 2018, from <https://www.smart.com/de/de/index/smart-eq-fortwo-453.html>
- Soares, J., Fotouhi Ghazvini, M. A., Vale, Z., & de Moura Oliveira, P. B. (2016). A multi-objective model for the day-ahead energy resource scheduling of a smart grid with high penetration of sensitive loads. *Applied Energy*, 162, 1074–1088. <https://doi.org/10.1016/j.apenergy.2015.10.181>
- Soroudi, A., & Amraee, T. (2013). Decision making under uncertainty in energy systems: State of the art. *Renewable and Sustainable Energy Reviews*, 28, 376–384. <https://doi.org/10.1016/j.rser.2013.08.039>
- Spiegel Online. (2018). Hersteller von Elektroautos: Mal wieder nicht geliefert. Retrieved April 10, 2019, from <https://www.spiegel.de/auto/aktuell/elektroautos-so-lange-muessen-kaeuffer-auf-ihr-e-auto-warten-a-1194420.html>
- Statista. (2018a). *Dossier: Elektromobilität*. Retrieved from <https://de.statista.com/statistik/studie/id/6547/dokument/elektromobilitaet/>
- Statista. (2018b). Pkw-Bestand in Deutschland nach Haltergruppen (Stand: 1. Januar 2018). Retrieved June 18, 2018, from <https://de.statista.com/statistik/daten/studie/154574/umfrage/anteil-gewerblicher-pkw-in-deutschland-nach-ausgewaehlten-haltergruppen/>
- Stein, M. (1987). Large Sample Properties of Simulations Using Latin Hypercube Sampling. *Technometrics*, 29(2), 143–151. <https://doi.org/10.2307/1269769>

- Struckmeier, J. (2017). Was ist mathematische Modellierung? Retrieved November 24, 2017, from <http://www.math.uni-hamburg.de/home/struckmeier/modsim10/Kap1.pdf>
- Stryja, C., Fromm, H., Ried, S., Jochem, P., & Fichtner, W. (2015). On the Necessity and Nature of E-Mobility Services – Towards a Service Description Framework, (May). <https://doi.org/10.1007/978-3-319-14980-6>
- Suhl, L., & Mellouli, T. (2013). *Optimierungssysteme*. Springer Gabler. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-38937-5>
- Sundström, O., & Binding, C. (2012). Flexible charging optimization for electric vehicles considering distribution grid constraints. *IEEE Transactions on Smart Grid*, 3(1), 26–37. <https://doi.org/10.1109/TSG.2011.2168431>
- Swider, D. J. (2006). *Handel an Regelenergie- und Spotmärkten. Methoden zur Entscheidungsunterstützung für Netz- und Kraftwerksbetreiber*. Wiesbaden: Gabler. <https://doi.org/10.1007/978-3-8350-9303-4>
- Tang, W., Bi, S., Jun, Y., Zhang, A., & Member, S. (2013). Online Speeding Optimal Charging Algorithm for Electric Vehicles without Future Information, 175–180.
- The Mobility House. (2018). Mit unserer Technologie verändern wir die Welt. Retrieved December 18, 2018, from https://www.mobilityhouse.com/de_de/
- The Mobility House. (2019). Vehicle-to-Grid. Retrieved April 10, 2019, from https://www.mobilityhouse.com/de_de/vehicle-to-grid
- Tober, W. (2016). *Praxisbericht Elektromobilität und Verbrennungsmotor*. (H.-P. Lenz, Ed.). Wiesbaden: Springer Fachmedien Wiesbaden. <https://doi.org/10.1007/978-3-658-13602-4>
- TransnetBW. (2017). Kennzahlen. Retrieved November 9, 2017, from <https://www.transnetbw.de/de/transparenz/marktdaten/kennzahlen>
- Tsiropoulos I, Tarvydas D, & Lebedeva N. (2018). *Li-ion batteries for mobility and stationary storage applications Scenarios for costs and market growth*. <https://doi.org/10.2760/87175>
- Tulpule, P. J., Marano, V., Yurkovich, S., & Rizzoni, G. (2013). Economic and environmental impacts of a PV powered workplace parking garage charging station. *Applied Energy*, 108, 323–332. <https://doi.org/10.1016/j.apenergy.2013.02.068>
- Tushar, K. H. M., Assi, C., Member, S., & Maier, M. (2014). Smart Microgrids : Optimal Joint Scheduling for Electric Vehicles and Home Appliances. *IEEE Transactions on Smart Grid*, 5(1), 239–250. <https://doi.org/10.1109/TSG.2013.2290894>
- UBA. (2018a). Anteil erneuerbarer Energien am Bruttostromverbrauch und am Bruttoendenergieverbrauch. Retrieved April 19, 2018, from <https://www.umweltbundesamt.de/indikator-erneuerbare-energien#textpart-1>
- UBA. (2018b). Klimabilanz 2017: Emissionen gehen leicht zurück. Retrieved from <https://www.umweltbundesamt.de/presse/pressemitteilungen/klimabilanz-2017->

emissionen-gehen-leicht-zurueck

- UBA, & AGEE. (2018). *Erneuerbare Energien in Deutschland. Daten zur Entwicklung im Jahr 2017*. UBA. Retrieved from https://www.umweltbundesamt.de/sites/default/files/medien/376/publikationen/180315_uba_hg_einzahlen_2018_bf.pdf
- Uhrig, M., Leibfried, T., Schmidt, R., & Kuhn, J. (2014). Intelligentes Lademanagement für Elektrofahrzeuge in Parkhäusern – Auswirkungen und Potentiale im urbanen Umfeld. In *VDE-Kongress 2014 - Smart Cities – Intelligente Lösungen für das Leben in der Zukunft*. Frankfurt am Main: VDE VERLAG GMBH.
- Uhrig, M., Weiß, L., Suriyah, M., & Leibfried, T. (2015). E-Mobility in car parks – Guidelines for charging infrastructure expansion planning and operation based on stochastic simulations. In *28th International Electric Vehicle Symposium and Exhibition (EVS28)*. Seoul.
- Umweltbundesamt. (2013). Was ist ein „Smart-Grid“? Retrieved June 19, 2018, from <https://www.umweltbundesamt.de/service/uba-fragen/was-ist-ein-smart-grid>
- Umweltbundesamt. (2017). *Ansätze zur Bewertung und Darstellung der nationalen Emissionsentwicklung unter Berücksichtigung des EU-ETS* (Vol. 8/2017). Retrieved from https://www.umweltbundesamt.de/sites/default/files/medien/1410/publikationen/2017-03-01_climate-change_08-2017_ets-zieldarstellung.pdf
- Umweltbundesamt. (2018). Höhere Geschwindigkeit führt zu höherer Umweltbelastung. Retrieved August 9, 2018, from <http://www.umweltbundesamt.at/umweltsituation/verkehr/fahrzeugtechnik/pkw/tempo/>
- VDA. (2017). *Mehr Klimaschutz durch eine bessere und umfassendere CO₂-Regulierung*. Berlin. Retrieved from <https://www.vda.de/de/services/Publikationen/mehr-klimaschutz-durch-eine-bessere-und-umfassendere-co2-regulierung.html>
- VDA. (2018). Abgasemissionen. WLTP – weltweit harmonisierter Zyklus für leichte Fahrzeuge. Retrieved June 12, 2018, from <https://www.vda.de/de/themen/umwelt-und-klima/abgasemissionen/wltp-weltweit-harmonisierter-zyklus-fuer-leichte-fahrzeuge.html>
- VDE. (2017). Elektromobilität: VDE|DKE machen den Weg frei für Ladesäulen. Retrieved May 23, 2018, from <https://www.vde.com/de/presse/pressemitteilungen/vde-dke-machen-den-weg-frei-fuer-ladesaeulen>
- Vermeesch, P. (2012). On the visualisation of detrital age distributions. *Chemical Geology*, 312–313, 190–194. <https://doi.org/10.1016/j.chemgeo.2012.04.021>
- Verweij, B., Ahmed, S., Kleywegt, A. J., Nemhauser, G., & Shapiro, A. (2003). The sample average approximation method applied to stochastic routing problems: A computational study. *Computational Optimization and Applications*, 24(2–3), 289–333. <https://doi.org/10.1023/A:1021814225969>

- Volkswagen. (2018). Die e-Evolution des Autos geht weiter. Der e-Golf. Retrieved March 12, 2018, from https://www.volkswagen.de/content/dam/vw-ngw/vw_pkw/importers/de/dialogcenter/brochures/golf-bq/golf-e_preisliste.pdf/_jcr_content/renditions/original.media_file.download_attachment.file/golf-e_preisliste.pdf
- Waldmann, K.-H., & Helm, W. E. (2016). *Simulation stochastischer Systeme*. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-662-49758-6>
- Waldmann, K.-H., & Stocker, U. M. (2013). *Stochastische Modelle: eine anwendungsorientierte Einführung* (2nd ed.). Berlin ; Heidelberg: Springer Berlin Heidelberg.
- Wand, M. P., & Jones, M. C. (1995). *Kernel Smoothing*. London: Chapman & Hall. Retrieved from <http://www.jstor.org/stable/1268906?origin=crossref>
- Wang, Z., Jochem, P., & Fichtner, W. (2018). Optimal Charging Management of Electric Vehicle Fleets under Uncertainty. In *41st IAEE International Conference Proceedings*. Groningen.
- Wei, L., & Guan, Y. (2014). Market Impact and Risk Attitude Optimal Control of Plug-In Hybrid Electric Vehicles with Market Impact and Risk Attitude. *Transportation Science*, 48(4).
- Weiller, C., & Neely, a. (2014). Using electric vehicles for energy services: Industry perspectives. *Energy*, 77, 194–200. <https://doi.org/10.1016/j.energy.2014.06.066>
- Weiss, C., Chlond, B., Heilig, M., & Vortisch, P. (2014). Capturing the usage of the german car fleet for a one year period to evaluate the suitability of battery electric vehicles – a model based approach. *Transportation Research Procedia*, 1(1), 133–141. <https://doi.org/10.1016/j.trpro.2014.07.014>
- Weitzel, T., & Glock, C. H. (2018). Energy management for stationary electric energy storage systems: A systematic literature review. *European Journal of Operational Research*, 264(2), 582–606. <https://doi.org/10.1016/j.ejor.2017.06.052>
- Werners, B. (2013). *Grundlagen des Operations Research*. Springer Gabler. Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-40102-2>
- Will, C., & Schuller, A. (2016). Understanding user acceptance factors of electric vehicle smart charging. *Transportation Research Part C*, 71, 198–214. <https://doi.org/10.1016/j.trc.2016.07.006>
- Winker, P., & Funk, C. (2017). *Empirische Wirtschaftsforschung und Ökonometrie* (4th ed.). Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-662-52768-9>
- Wiwo. (2017). Berufspendler. 68 Prozent fahren mit dem Auto zur Arbeit. Retrieved June 18, 2018, from <https://www.wiwo.de/erfolg/beruf/berufspendler-68-prozent-fahren-mit-dem-auto-zur-arbeit/20258178.html>
- WiWo. (2018). 2022 statt 2020: Regierung verschiebt E-Auto-Ziel – doch das neue ist ähnlich optimistisch. Retrieved November 25, 2018, from

- <https://www.wiwo.de/politik/deutschland/2022-statt-2020-regierung-verschiebt-e-auto-ziel-doch-das-neue-ist-aehnlich-optimistisch/23094638.html>
- World Energy Council. (2017). *World Energy Trilemma Index*. Retrieved from <https://www.worldenergy.org/wp-content/uploads/2017/11/Energy-Trilemma-Index-2017-Report.pdf>
- Wu, F., & Sioshansi, R. (2017). A two-stage stochastic optimization model for scheduling electric vehicle charging loads to relieve distribution-system constraints. *Transportation Research Part B: Methodological*, 102, 55–82. <https://doi.org/10.1016/j.trb.2017.05.002>
- Yang, Z., Li, K., & Foley, A. (2015). Computational scheduling methods for integrating plug-in electric vehicles with power systems: A review. *Renewable and Sustainable Energy Reviews*, 51, 396–416. <https://doi.org/10.1016/j.rser.2015.06.007>
- Zhang, L., Jabbari, F., Brown, T., & Samuelsen, S. (2014). Coordinating plug-in electric vehicle charging with electric grid: Valley filling and target load following. *Journal of Power Sources*, 267, 584–597. <https://doi.org/10.1016/j.jpowsour.2014.04.078>
- Zhu, L., Yu, F. R., Ning, B., & Tang, T. (2012). Optimal Charging Control for Electric Vehicles in Smart Microgrids with Renewable Energy Sources. In *IEEE 75th Vehicular Technology Conference (VTC Spring)*. Yokohama, Japan. <https://doi.org/10.1109/VETECS.2012.6240169>
- Zhu, L., Yu, F. R., Ning, B., & Tang, T. (2011). Stochastic Charging Management for Plug-in Electric Vehicles in Smart Microgrids Fueled by Renewable Energy Sources. In *IEEE Online Conference on Green Communications*. New York, NY, USA. <https://doi.org/10.1109/GreenCom.2011.6082526>
- Zimmermann, H.-J. (2008). operations research. In *SpringerReference* (p. XIV, 481 S. TS-WorldCat T4-Methoden und Mode). Berlin/Heidelberg: Springer-Verlag. https://doi.org/10.1007/SpringerReference_20294
- ZSW (Zentrum für Sonnenenergie und Wasserstoff-Forschung). (2018). Elektromobilität. Retrieved April 26, 2018, from <https://www.zsw-bw.de/mediathek/datenservice.html#c6840>
- Zwicky, F., & Wilson, A. G. (1967). *New Methods of Thought and Procedure: Contributions to the Symposium on Methodologies*. (F. Zwicky & A. G. Wilson, Eds.). Berlin, Heidelberg: Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-87617-2>

