

Masterarbeit

Entwicklung eines Algorithmus zur ökonomischen Optimierung der Ladevorgänge von Elektroautos

Development of an algorithm for the economic optimisation
of charging processes of electric vehicles

Nico Pieper

Erste Gutachterin:	Prof. Dr.-Ing. Johanna Myrzik
Zweiter Gutachter:	Dr.-Ing. Holger Groke
Betreuer:	M. Sc. Tom Warendorf
Eingereicht am:	14.04.2021
IAT-Registrierungsnummer:	MT2004

Kurzfassung

In der vorliegenden Arbeit wird ein Algorithmus entwickelt, der die Ladevorgänge von batterieelektrischen Fahrzeugen hinsichtlich der Generierung ökonomischen Nutzens optimiert. Durch die Vorausplanung von Ladezeiten und -leistungen werden die Beschaffungskosten im Strombörsenhandel reduziert und der Eigenverbrauch privater Photovoltaik-Anlagen erhöht. Die Steuerung der Ladevorgänge ermöglicht zudem eine Teilnahme am Sekundärregelleistungsmarkt. Zur Erlangung reduzierter Netznutzungsentgelte werden darüber hinaus die Anforderungen des netzdienlichen Ladens gemäß § 14a Energiewirtschaftsgesetz beachtet. Der Algorithmus wird in ein Optimierungssystem eingebettet, das mithilfe von Simulationen untersucht wird.

Die Untersuchung der Ladevorgangsoptimierung erfolgt vor dem Hintergrund zunehmender Einspeisefluktuationen im Zuge der Energiewende und zeitweiser lokaler Überlastungen der Verteilnetze, die durch den wachsenden Strombedarf von Elektroautos drohen. Eine gezielte Steuerung der Ladevorgänge kann Einspeisefluktuationen bedarfsseitig ausgleichen und Netzüberlastungen vermeiden. Die Optimierung anhand ökonomischer Ziele bietet Chancen für neue Geschäftsmodelle und, bei finanzieller Beteiligung der Nutzer, für eine Attraktivitätssteigerung der Elektromobilität. Die vorliegende Arbeit bewertet das ökonomische Potenzial der vier kombinierten Quellen ökonomischen Nutzens. Es wird untersucht, ob die ökonomische Optimierung zur Integration von erneuerbaren Energien in das Stromnetz beiträgt und netzdienlich ist. Außerdem wird der Einfluss einer großen Elektroautoflotte auf die Preise am Sekundärregelleistungsmarkt ermittelt.

Das entwickelte Optimierungssystem und die durchgeführten Simulationen basieren auf den Regularien und Mechanismen der deutschen Stromwirtschaft, die zunächst beschrieben werden. Es wird ein Prognosemodell für den Day-Ahead-Börsenstrompreis auf der Grundlage von autoregressiven Modellen mit exogenen Eingabewerten (ARX) entwickelt. Für die Simulationen werden unter der Verwendung realer Fahrprofile Nutzer modelliert und der Regelleistungsmarkt wird virtuell abgebildet. Per linearer Programmierung werden auf der Basis von Prognosen vorausplanend in mehrstündigen Intervallen die optimalen Ladezeiten und -leistungen ermittelt. Eine Heuristik gleicht den Ladeplan in kurzen Zeitschritten an die realen Gegebenheiten an.

Die Genauigkeit des entwickelten Prognosemodells für den Börsenstrompreis ist mit derer anderer Modelle aus der Literatur vergleichbar. Die Auswertung der Simulationen ergibt, dass insbesondere Besitzer von Photovoltaik-Anlagen und Nutzer mit hohen Energiebedarfen ein großes ökonomisches Potenzial aufweisen. Es wird gezeigt, dass die Reduktion der Ladeenergiekosten gleichzeitig mit Glättungseffekten für die Netzlast und einem steigenden Grünstromanteil für das Laden einhergeht. Bei der Teilnahme von 100 000 Elektroautos am Sekundärregelleistungsmarkt wird ein merklicher Einfluss auf die ausgezahlten Marktpreise festgestellt.

Zur Schaffung von Leitmarktbedingungen wird politischen Entscheidungsträgern empfohlen, zeitvariable Netznutzungsentgelte einzuführen, die Präqualifikationsbedingungen des Regelleistungsmarktes anzupassen und die Verbreitung von intelligenten Messsystemen zu überschaubaren Kosten zu forcieren.

Abstract

In this thesis, an algorithm is developed to optimize the charging processes of battery electric vehicles with respect to the creation of economic benefits. By scheduling charging times and powers, advantages of fluctuations in the spot market exchange prices are taken and the self-consumption of photovoltaic power of private plants is increased. Further, negative secondary control reserve is provided. To take advantage of reduced grid usage fees, proper participation in a peak load avoidance program managed by German distribution system operators is ensured. The algorithm is embedded in an optimization system, which is investigated using simulations.

The investigation of charging process optimization was conducted in the context of increasing power generation fluctuations in the course of the Energiewende and intermittently local overloads of distribution networks, which are threatened by the growing power demand of electric vehicles. The scheduling of charging processes can compensate for power generation fluctuations and avoid grid overloads by adapting the demand side. Optimization based on economic objectives offers opportunities for new business models and for increased attractiveness of electromobility if revenues are shared with the users. This thesis evaluates the economic potential of the four combined sources of economic benefits. It is investigated whether economic optimization contributes to the integration of renewable energies into the power grid and whether it is beneficial to the grid. Also, the impact of a large fleet of electric cars on the secondary control reserve market prices is determined.

The developed optimization system and the conducted simulations are based on the regulations and mechanisms of the German electricity economy, which are described first. A day-ahead exchange electricity price forecast model is developed based on autoregressive models with exogenous inputs (ARX). In the simulations, users are modeled using real driving profiles and the control reserve market is modeled using real market data. A two-level optimization procedure is used. An algorithm based on linear programming determines the optimal charging times and powers in advance at intervals of several hours relying on forecasts. A heuristic adjusts the charging schedule to the real conditions in short time steps.

The performance of the developed exchange electricity price forecast model is comparable to the results from the literature. The evaluation of the simulations demonstrates that especially owners of photovoltaic plants and users with high energy demands have a high economic potential. It is shown that the reduction of charging energy costs is accompanied by smoothing effects for the grid load and an increase in the share of green electricity consumption. The participation of 100 000 electric cars in the secondary control reserve market leads to a noticeable reduction of the paid market prices.

To create lead market conditions, political decision-makers are recommended to introduce time variable grid usage fees, make adjustments to the pre-qualification conditions for the control reserve market and enable real-time pricing at reasonable costs.

Inhaltsverzeichnis

Kurzfassung	i
Abstract	ii
Inhaltsverzeichnis	iii
1. Einleitung	1
1.1. Motivation: Herausforderungen der Energie- und Verkehrswende	1
1.2. Forschungsgegenstand der Arbeit	2
1.3. Aufbau der Arbeit	3
2. Theoretischer Hintergrund	5
2.1. Regularien in der deutschen Stromwirtschaft	5
2.1.1. Grundlagen der stromwirtschaftlichen Bilanzierung	5
2.1.2. Stromhandel	8
2.1.3. Regelleistungsmarkt	10
2.1.4. Eigenverbrauch des Stromes privater Photovoltaikanlagen	13
2.1.5. Netzdienliches Laden	16
2.2. Ladevorgangssteuerung von Elektroautos	17
2.2.1. Ladesysteme in Elektroautos	17
2.2.2. Systemarchitekturen der Ladevorgangsoptimierung	19
2.2.3. Praxisbeispiel Jedlix	21
2.3. Regressionsmodelle für die Prognose von Zeitreihen	21
2.3.1. Lineare Regressionsmodelle	22
2.3.2. AR-Modell	23
2.3.3. ARX-Modell	24
2.3.4. Methode der kleinsten Quadrate	25
2.3.5. Metriken zur Ermittlung der Prognosequalität	26
2.4. Lineare Optimierung	26
2.4.1. Grundlagen der linearen Optimierung	26
2.4.2. Lösung eines linearen Optimierungsproblems durch den primalen Simplexalgorithmus	27
2.5. Überblick zum Forschungsstand der Ladevorgangsoptimierung	30
2.5.1. Zusammenfassung ausgewählter Studien	30
2.5.2. Dominierende Methoden, Systemarchitekturen und Optimierungsziele	32
3. Entwicklung eines Systems zur ökonomischen Ladevorgangsoptimierung	33
3.1. Modellierte Systemarchitektur	33
3.1.1. Interaktion mit dem Strommarkt	35
3.1.2. Interaktion mit dem Regelleistungsmarkt	35
3.1.3. Einbindung der privaten Photovoltaikanlagen	35
3.1.4. Einbindung in das netzdienliche Laden	36

3.2.	Optimierungskonzept	36
3.3.	Modellierung der Nutzer	38
3.3.1.	Nutzungsprofile	38
3.3.2.	Fahrzeug- und Ladedaten	39
3.3.3.	Generierung der Nutzungsprofile	40
3.3.4.	Vertragsdaten	41
3.3.5.	Photovoltaikanlagendaten und -prognosen	42
3.3.6.	Wissen des Aggregators über Nutzerdaten	43
3.4.	Modellierung der Spotmarktinteraktion und -preisprognose	44
3.4.1.	Rohdaten aus der Stromwirtschaft	44
3.4.2.	Analyse des Day-Ahead-Strompreises	44
3.4.3.	Spotmarktprognosemodell	46
3.5.	Modellierung der Regelleistungsmarktinteraktion und Preisstrategie	47
3.5.1.	Rohdaten des Regelleistungsmarkts	48
3.5.2.	Generierung der Regelarbeitspreise	49
3.5.3.	Analyse des Regelleistungs- und Regelarbeitspreises	49
3.5.4.	Preisstrategie	51
3.6.	Entwickelte Algorithmen zur ökonomischen Ladevorgangsoptimierung	53
3.6.1.	Vorausplanender Optimierungsalgorithmus	53
3.6.2.	Operativer Algorithmus	58
4.	Untersuchungen zum Optimierungssystem und Ergebnisse der Simulationen	61
4.1.	Auswertung der Spotmarkt- und PV-Prognose	61
4.1.1.	Spotmarktprognosemodell	61
4.1.2.	PV-Prognosedaten	62
4.2.	Parameter der durchgeführten Simulationen	62
4.3.	Auswertung der simulierten Nutzungsprofile	63
4.4.	Auswertung der simulierten Lastprofile	66
4.4.1.	Geplante Lastprofile	66
4.4.2.	Reale Lastprofile	68
4.5.	Auswertung der Regelleistungsmarktinteraktion	69
4.6.	Finanzielle Auswertung des Optimierungssystems	71
4.6.1.	Auswertung der Ladeenergiekosten	71
4.6.2.	Untersuchung möglicher Zusatzkosten durch den Bedarf an intelligenten Messsystemen	74
4.6.3.	Untersuchung des netzdienliches Ladens für PV-Anlagenbesitzer	75
4.6.4.	Untersuchung verkürzter Regelleistungszeitscheiben	75
5.	Abschließende Betrachtungen	77
5.1.	Zusammenfassung	77
5.2.	Diskussion	78
5.2.1.	Einordnung der Ergebnisse in den Forschungsstand	78
5.2.2.	Vergleich der Optimierungsergebnisse mit anderen Studien	79
5.2.3.	Limitationen und weiterer Forschungsbedarf	80
5.2.4.	Ausblick	81

5.3. Politische Handlungsempfehlungen	81
5.3.1. Maßnahmen zur Förderung des Eigenverbrauchs	81
5.3.2. Anpassungen der Regularien des Regelleistungsmarkts	82
5.3.3. Neugestaltung des § 14a EnWG	83
5.3.4. Verringerung der Messbetriebskosten	83
A. Anhang	85
A.1. Theoretischer Hintergrund	85
A.1.1. Autokorrelation eines AR(1)-Modells	85
A.1.2. Nicht-lineare autoregressive neuronale Netze mit externen Eingabewerten .	86
A.2. Entwicklung eines Algorithmus zur ökonomischen Ladevorgangsoptimierung	88
A.2.1. Photovoltaikanlagendaten	88
A.2.2. Verlauf des Day-Ahead-Preises im Wochendurchschnitt	88
A.2.3. Autokorrelationsfunktionen der Variablen des Regelleistungsmarktes	89
A.3. Auswertung	90
A.3.1. Lastprofile der Optimierungsschritte	90
A.3.2. Lastprofile nach Wochentag und Wochenende	91
A.3.3. Anteile der Strombezugsquellen im Jahresverlauf	92
A.3.4. Anteile der Strombezugsquellen an der Ladeleistung	92
A.3.5. Lastprofile bei Verkürzung der Regelleistungszeitscheiben	93
Abkürzungsverzeichnis	95
Symbolverzeichnis	97
Abbildungsverzeichnis	101
Tabellenverzeichnis	104
Literaturverzeichnis	106

1. Einleitung

1.1. Motivation: Herausforderungen der Energie- und Verkehrswende

Die Ziele der deutschen Politik sind ambitioniert. Das *Klimaschutzprogramm 2030 der Bundesregierung zur Umsetzung des Klimaschutzplans 2050* setzt das Ziel, innerhalb der nächsten 30 Jahre die Treibhausgasneutralität zu erreichen [1, S. 7]. Der größte Anteil der deutschen Emissionen entfällt auf den Sektor der Stromwirtschaft. Im Jahr 2018 lag er bei 41 % [2, S. 24] [3, S. 9]. Im Zuge der Energiewende scheidet, wie in Abbildung 1.1 visualisiert, zunehmend konventionelle Erzeuger aus der Stromwirtschaft aus. Sie werden vor allem durch Windkraft und Photovoltaik (PV) ersetzt. Ihr gemeinsamer Anteil am Bruttostromverbrauch lag im Jahr 2020 bei 32,8 % [4, S. 19] und soll bis 2030 auf rund 53 % steigen [1, S. 39]. Damit einhergehen verstärkte Fluktuationen der Erzeugungsleistung, die das Stromsystem vor Herausforderungen stellen.




Abbildung 1.1.: Entwicklung des historischen deutschen Strommix und die politische Zielsetzung des Klimaschutzprogramms im Jahr 2030 (2030KSP). Die historischen Daten stammen von [5], die Zielsetzung wurde in [1, S. 39] formuliert.

Der Verkehrssektor ist mit einem Anteil von 23 % im Jahr 2018 der zweitgrößte Treibhausgasemittent [3, S. 9]. Im Zuge der Verkehrswende weisen die Neuzulassungszahlen von Elektroautos aktuell ein hohes Wachstum auf. Abbildung 1.2 zeigt die Entwicklung der Neuzulassungszahlen für batterieelektrische Fahrzeuge (Engl. Battery Electric Vehicle, BEV) und plug-in-hybrid-elektrische Fahrzeuge (Engl. Plug-In-Hybrid Electric Vehicle, PHEV). Ende 2020 waren rund 317 000 BEV-Pkws und 289 000 PHEV-Pkws zugelassen [6], [7]. Bis zum Jahr 2030 strebt die deutsche Bundesregierung sieben bis zehn Mio. zugelassene BEVs und PHEVs an [1, S. 76]. Mit der steigenden Anzahl an Elektroautos wächst ihr Anteil an der Netzlast. Als Folge typischer Nutzungsmuster wird zu Stoßzeiten eine zeitweise Überlastung der Verteilnetze befürchtet [8], [9].

Smart Charging bezeichnet die zeitliche Planung der Ladeprofile von Elektroautos durch dessen Nutzer und Systemoperatoren zur Generierung technischer und ökonomischer Nutzen [10]. Es ist eine Form des Demand Side Managements (DSM). Durch eine gezielte Steuerung der Ladevorgänge kann der Einsatz von Smart Charging sowohl zum bedarfsseitigen Ausgleich der Einspeisefluktuationen als auch zur Vermeidung von Netzüberlastungen beitragen. Gleichzeitig können

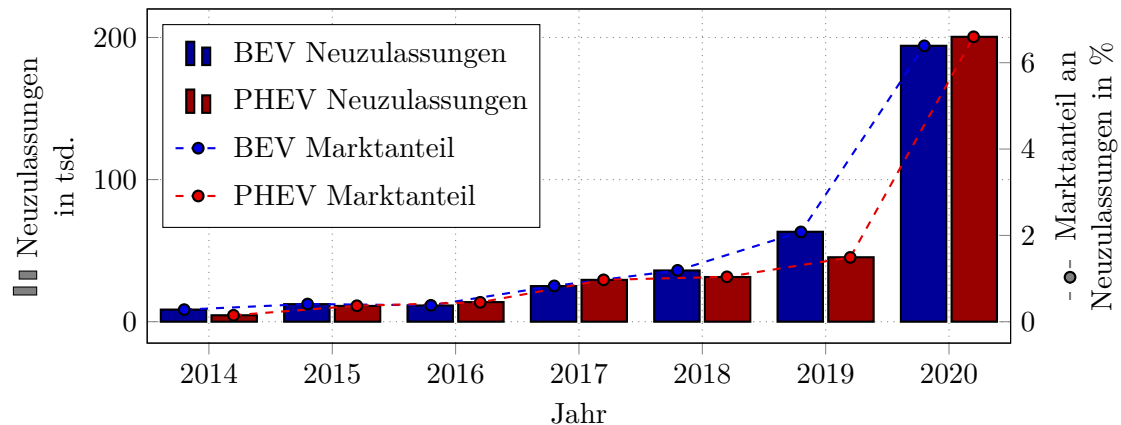


Abbildung 1.2.: Neuzulassungen und Marktanteile für BEV-Pkws und PHEV-Pkws in Deutschland seit 2014. Die Daten stammen von [7].

ökonomische Potenziale in der Stromwirtschaft geschöpft werden. Durch eine zeitliche Ausrichtung der Ladevorgänge an den Großhandelsmarktpreisen lassen sich die Ladeenergiekosten reduzieren. Werden Elektroautos bevorzugt dann geladen, wenn eine private PV-Anlage ansonsten Energie in das Stromnetz einspeisen würde, können die finanziellen Vorteile des Eigenverbrauchs gesteigert werden. Außerdem können Erlöse durch die Teilnahme am Regelleistungsmarkt erzielt und Ausgleichsenergiekosten durch gezieltes Bilanzkreismanagement reduziert werden.

Gelingt es inländischen Unternehmen, frühzeitig erfolgreiche Smart-Charging-Geschäftsmodelle und -Systeme zu entwickeln, können anschließende internationale Expansionen positive Effekte auf die heimische Wirtschaft haben. Profitieren die Nutzer finanziell von Smart-Charging-Services, kann dies die Attraktivität für die Elektromobilität erhöhen. Sollte die ökonomische Optimierung ebenfalls förderlich für die Integration erneuerbarer Energie (EE) in das Stromsystem und für die Netzstabilität sein, trüge sie zum Erreichen mehrerer politischer Zielsetzungen bei.

1.2. Forschungsgegenstand der Arbeit

In dieser Arbeit wird die ökonomische Optimierung der Ladevorgänge von BEVs untersucht. Dazu wird basierend auf linearer Programmierung ein Algorithmus entwickelt, der die Ladevorgänge von BEVs aggregiert steuert. Ökonomische Vorteile werden erreicht, indem die Ladevorgänge so gesteuert werden, dass die Fahrzeuge in Zeiten günstiger Börsenstrompreise geladen werden und der Eigenverbrauch privaten PV-Anlagen gesteigert wird. Zudem werden die Elektroautos zur Bereitstellung von negativer Sekundärregelleistung verwendet und in das netzdienliche Laden gemäß § 14a Energiewirtschaftsgesetz (EnWG) eingebunden.

Der entwickelte Algorithmus wird in Simulationen getestet. Dazu werden ein Aggregator und potenzielle Nutzer eines Smart-Charging-Services modelliert. Der Algorithmus wird von dem Aggregator zur Steuerung der Ladevorgänge der Nutzer verwendet. Jeder Nutzer besitzt ein individuelles Set an Eigenschaften, bestehend aus einem BEV und einem dazugehörigen Nutzungsprofil, einem privaten Ladepunkt, einem Stromvertrag sowie einem Ladetarif für die Nutzung öffentlicher Ladepunkte. Ein Teil der Nutzer besitzt eine private PV-Anlage, ein anderer Teil nimmt

am netzdienlichen Laden teil. Zur Bewertung des ökonomischen Potenzials und der Auswirkung auf die Nutzer wird das Ladeverhalten mit der Steuerung durch den entwickelten Algorithmus (Smart-Charging-Szenario) und ohne Steuerung (Basisszenario) simuliert.

Es lassen sich fünf Kernziele dieser Arbeit benennen.

1. Die Akquise und Generierung von Datensätzen, die die realitätsnahe Simulation der Partizipation am Strombörsenhandel und am Regelleistungsmarkt erlauben.
2. Die wirklichkeitsgetreue Modellierung von potenziellen Smart-Charging-Nutzern sowie die realitätsnahe Simulation ihres Ladeverhaltens im Basisszenario.
3. Die Entwicklung eines Prognosemodells für den Day-Ahead-Börsenstrompreis mit möglichst hoher Prädiktionsgenauigkeit.
4. Die Entwicklung eines Algorithmus, der die Ladevorgänge einer aggregierten Elektrofahrzeugflotte hinsichtlich eines möglichst hohen ökonomischen Nutzens optimiert.
5. Die Bewertung des ökonomischen Potenzials von Smart Charging sowie die Untersuchung der Auswirkungen auf die Nutzer, den geladenen Strommix, die Netzlast und den Regelleistungsmarkt.

1.3. Aufbau der Arbeit

Die Arbeit gliedert sich in fünf Kapitel. Kapitel 2 erklärt die theoretischen Grundlagen, auf denen das entwickelte Smart-Charging-System basiert. Dazu werden die relevanten Mechanismen und Regularien der Stromwirtschaft, insbesondere des Stromhandels, des Regelleistungsmarktes, des Eigenverbrauchs von PV-Strom und das netzdienliche Laden gemäß § 14a EnWG beschrieben. Es wird erklärt, wie Ladevorgänge gesteuert werden können. Das Kapitel beschreibt die Methoden, die zur Prognose des Börsenstrompreises und zur algorithmusbasierten Ladevorgangsoptimierung eingesetzt wurden. Es schließt mit einem aktuellen Überblick zum Forschungsstand.

In Kapitel 3 werden zunächst die grundlegende Systemarchitektur und das Optimierungskonzept erklärt. Anschließend wird die Modellierung der Systemnutzer erläutert. Es werden ein Prognosemodell für den Börsenstrompreis und eine Preisstrategie für den Regelleistungsmarkt vorgestellt. Schließlich erfolgt die Entwicklung des Smart-Charging-Algorithmus.

Kapitel 4 wertet das entwickelte Optimierungssystem aus. Zunächst wird die Prognosequalität des Prognosemodells analysiert. Anschließend werden die durchgeführten Simulationen vorgestellt. Die Eigenschaften der modellierten Nutzer werden mit den Angaben externer Quellen verglichen, die Lastprofile des Basis- und Smart-Charging-Systems werden analysiert und Auswirkungen des Systems auf das Stromsystem und den Regelleistungsmarkt untersucht. Schließlich werden die ökonomischen Potenziale des Smart-Charging-Systems beleuchtet.

Im abschließenden Kapitel 5 wird die Arbeit zusammengefasst. Sie wird in den aktuellen Forschungsstand eingeordnet und es werden Limitationen aufgezeigt. Schließlich werden Handlungsempfehlungen für politische Entscheidungsträger formuliert.

2. Theoretischer Hintergrund

Das im Rahmen dieser Arbeit entwickelte System basiert auf den Regularien und Mechanismen der deutschen Stromwirtschaft, die in Unterkapitel 2.1 zunächst beschrieben werden. Das folgende Unterkapitel 2.2 erklärt aus technischer Perspektive, wie Ladevorgänge von Elektroautos gesteuert werden können. Die Unterkapitel 2.3 und 2.4 führen in das Prognose- und das Optimierungsverfahren ein, die bei der Systementwicklung verwendet wurden. Schließlich wird in Unterkapitel 2.5 der aktuelle Forschungsstand betrachtet.

2.1. Regularien in der deutschen Stromwirtschaft

2.1.1. Grundlagen der stromwirtschaftlichen Bilanzierung

Da Strom nicht großtechnisch speicherbar ist [11, S. 309], muss im Stromsystem zu jedem Zeitpunkt eine Balance zwischen Einspeisung und Entnahme sichergestellt werden. Andernfalls weicht die Netzfrequenz des Dreiphasenwechselstromnetzes von ihrem Zielwert 50 Hz ab. Per DSM können sowohl kurzfristige Schwankungen der Netzfrequenz ausgeglichen werden. Zudem kann der Verbrauch mit Blick auf die aktuell verfügbare Einspeiseleistung und Netzauslastung angepasst werden. Die folgenden Abschnitte erklären die zugrunde liegende Regulatorik und zeigen, warum die bisherige stromwirtschaftliche Bilanzierung aus technischen Zwängen dem großflächigen Einsatz von DSM für kleine Verbraucher im Wege steht.

2.1.1.1. Bilanzkreise und Fahrpläne

Um die Frequenzabweichungen gering zu halten, müssen Strombedarf und -verfügbarkeit prognostiziert und angeglichen werden. Gemäß § 4 der Stromnetzzugangsverordnung (StromNZV) müssen die stromwirtschaftlichen Aktivitäten aller Stromnetznutzer in Bilanzkreisen (BK) abgebildet werden. BKs sind virtuelle Energiemengenkonten und umfassen einen, einige oder viele Netznutzer. Der Bilanzkreisverantwortliche (BKV) muss für die Teilnehmer seines BKs alle Stromeinspeisungen und -entnahmen sowie gehandelten physischen Stromkäufe und -verkäufe erfassen [12, S. 55].

Ein BK darf geografisch die Grenzen einer Regelzone nicht überschreiten. In Deutschland müssen BKVs bis zur Gate Closure Time (GCT) um 14:30 Uhr dem Übertragungsnetzbetreiber (ÜNB) ihrer Regelzone melden, wie viel Leistung an einer Einspeise- oder Entnahmestelle am nächsten Tag eingespeist oder entnommen werden wird. Zudem werden die Salden des Stromhandels mit anderen BKs übermittelt (§§ 2 und 5 StromNZV). Diese Fahrpläne müssen in viertelstündigen Zeitrastern und 1 kW-Auflösung ausgeführt werden [13, S. 88]. Damit dem Strombedarf zu jeder Zeit die gleiche Stromerzeugung gegenübersteht, muss jeder Fahrplan ausgeglichen sein. Das heißt, in Summe muss jeder Fahrplan vorsehen, stets genauso viel Strom einzuspeisen und einzukaufen, wie Strom entnommen oder verkauft wird (§ 5 StromNZV).

Weder die Stromerzeugung noch der Strombedarf können einen Tag im Voraus exakt prognostiziert werden. Die Prognosefahrpläne weisen folglich Differenzen zu den realen Leistungsumsätzen auf. Am Erbringungstag dürfen BKVs noch Änderungen an ihren Fahrpläne vornehmen. Eine Anpassung kann mit zeitlichem Vorlauf von mindestens einer Viertelstunde zu jeder Viertelstunde vorgenommen werden [14, S. 26]. Regelzoneninterne Änderungen am Fahrplan können auch noch im Nachgang bis 16:00 Uhr des nächsten Werktags vorgenommen werden (§ 5 StromNZV).

Die realen Differenzen zwischen Einspeisung und Verbrauch aller BKs summieren sich zum Regelzonensaldo. Um Netzfrequenzabweichungen gering zu halten, müssen die ÜNBs die Ungleichgewichte durch Regularbeit ausgleichen, die sie über den Markt für Regelleistung beschaffen (vgl. Abschnitt 2.1.3). Die entstandenen Kosten für Regularbeit werden auf die BKs umgelegt. BKVs müssen ihre verbliebenen Fahrplandifferenzen durch Ausgleichsenergie kompensieren. Überstiegen Stromeinspeisung und -zukauf die Stromentnahme und den -verkauf, war der BK überdeckt und der BKV muss in gleicher Höhe negative Ausgleichsenergie zum regelzonenübergreifenden einheitlichen Bilanzausgleichsenergiepreis (reBAP) beziehen. Im entgegengesetzten Fall wird für die Unterdeckung positive Ausgleichsenergie nötig [12, S. 55f.]. Weist der Saldo eines BKs ein anderes Vorzeichen auf als der Regelzonensaldo, so kann, dem Abrechnungsschema in Tabelle 2.1 entsprechend, ein BKV den Bezug von Ausgleichsenergie auch vergütet bekommen. Insgesamt entsteht über den Ausgleichsenergiemechanismus für die BKVs ein Anreiz durch präzise Prognosen, vorausschauenden Stromhandel und dem Regeln ihrer Erzeuger und Verbraucher ihre Fahrpläne ausgeglichen zu halten.

Tabelle 2.1.: Schema zur Abrechnung von Ausgleichsenergie über den reBAP. In Anlehnung an [15].

		Saldo Bilanzkreis	
		unterdeckt	überdeckt
reBap	positiv	BKV zahlt an ÜNB	ÜNB zahlt an BKV
	negativ	ÜNB zahlt an BKV	BKV zahlt an ÜNB

2.1.1.2. Bilanzierung von Standardlastprofilen

I. d. R. werden Letztverbraucher mit Jahresstromverbräuchen kleiner als 100 000 kWh noch nach einem Standardlastprofil (SLP) bilanziert. Es findet keine viertelstündige Zählerstandsgangmessung statt, sondern eine Erfassung der bezogenen Energie über einen längeren Zeitraum von zumeist einem Jahr. Der tägliche Verbrauch wird auf Basis einer Jahresverbrauchsprognose und dem typischen Verbrauchsverhalten des Letztverbrauchertyps prognostiziert. Für die Bilanzierung von SLPs stehen zwei Verfahren zur Auswahl. Der Verteilnetzbetreiber (VNB) gibt dem BKV vor, welches Verfahren zur Anwendung kommt.

Wird das synthetische Lastprofilverfahren angewendet, übermittelt der VNB allen BKVs seines Netzgebiets fixierte SLPs der Letztverbraucher. Der BKV kann den Strombedarf langfristig im Voraus beschaffen, ohne dass ihm ein Risiko für Ausgleichsenergie entsteht. Der VNB versucht

durch Prognosen Differenzen zwischen den synthetischen Profilen und den tatsächlichen Lastverläufen durch Handel am Großhandelsmarkt gering zu halten. Die verbleibenden Abweichungen werden im Differenzbilanzkreis des VNBs bilanziert. Differenzen, die sich einen Abrechnungszeitraum (zumeist ein Jahr) zwischen dem SLP und dem tatsächlichen Kundenverbrauch ergeben, werden zwischen VNB und BKV im Rahmen der Mehr-/ Minderungenabrechnung zu Marktpreisen ausgeglichen [16, S. 8].

Bei Anwendung des analytischen Lastprofilverfahrens prognostiziert der BKV tagesaktuelle Abweichungen vom SLP und versucht sie durch kurzfristigen Handel auszugleichen. Ein BKV kann in diesem Fall durch gute Prognosen seine Ausgleichsenergiekosten gering halten. Der VNB ermittelt viertelstundenscharf den aggregierten Lastgang aller SLP-Verbraucher aus der Differenz zwischen dem gemessenen Energieabnahmeverlauf aller Kunden und dem der Großverbraucher mit registrierender Leistungsmessung. Der aggregierte Lastgang kann messtechnisch nicht für jeden BKV einzeln ermittelt werden. Die Stromentnahmen aller SLP-Kunden müssen daher unter allen BKVs aufgeteilt werden [16, S. 9]. Daher kann, ebenso wie beim synthetischen Verfahren, auch mit dieser Methode ein BKV nur geringfügig von Lastgängen seiner Kunden, die mit zeitlich günstigen Strombeschaffungskosten am Großhandelsmarkt einhergehen würden, profitieren. Der reale Lastgang seiner SLP-Kunden ist schlicht unbekannt und kann dem BKV nicht zugeordnet werden.

2.1.1.3. Einführung intelligenter Messsysteme

Die SLP-Bilanzierung ändert sich mit der Einführung intelligenter Messsysteme (iMSys). Bei ihnen können BKVs den Stromverbrauch nach den erfassten viertelstündigen Zählerständen bilanzieren. Erst so wird die Nutzung von Flexibilitätspotenzialen für BKVs und Letztverbraucher auch finanziell lohnenswert. Mit der Markterklärung des Bundesamts für Sicherheit in der Informationstechnik am 31.01.2020 wurden die Messstellenbetreiber gemäß §§ 29 und 31 Messstellenbetriebsgesetz (MsbG) verpflichtet, innerhalb von acht Jahren Haushalte mit Jahresstromverbräuchen über 6000 kWh mit iMSys ausstatten. Bei Haushalten mit kleineren Verbräuchen entscheidet der Messstellenbetreiber, ob er eine günstigere moderne Messeinrichtung (mME) oder ein iMSys einbaut. Messstellen mit PV-Anlagen, deren installierte Leistung 7 kW überschreiten, sind bis 2025 mit iMSys auszustatten.

iMSys gehen mit höheren Betriebskosten als Ferraris-Zähler oder mME einher. In § 31 Abs. 3 MsbG werden Obergrenzen für die Betriebskosten von iMSys für Letztverbraucher definiert, die grundzuständige Messstellenbetreiber maximal erheben dürfen. Die Obergrenzen sind nach Jahresstromverbrauch gestaffelt. Bis zu einem Jahresstromverbrauch von 2000 kWh dürfen 23 €, bis 3000 kWh 30 €, bis 4000 kWh 40 €, bis 6000 kWh 60 € und bis 10 000 kWh 100 € pro Jahr berechnet werden. Für PV-Anlagen mit installierter Leistung kleiner 15 kW beträgt die Obergrenze ebenso 100 €. Für mME dürfen maximal 20 € pro Jahr abgerechnet werden. Anschlussnutzern, bei denen innerhalb eines Gebäudes mehrere Messstellen mit einem iMSys ausgestattet werden müssen (z. B. separater Zähler für Haushalt und PV-Anlage oder steuerbare Verbrauchseinrichtung), darf nach § 31 Abs. 5 MsbG nicht mehr als die höchste Preisobergrenze aller eingesetzten iMSys in Rechnung gestellt werden. Nicht-grundzuständige Messstellenbetreiber bleiben von den Obergrenzen unberührt.

2.1.2. Stromhandel

Der Großhandelsmarkt für Strom lässt sich in zwei Teilmärkte untergliedern: den Handel an Strombörsen und das OTC-Geschäft. An Strombörsen werden standardisierte Produkte zentralisiert und anonym über eine digitale Plattform gehandelt. Im OTC-Markt handeln die Marktteilnehmer hingegen direkt miteinander und beschließen ihre Geschäfte mit bilateralen Verträgen, die auf Rahmenverträgen basieren, aber je nach Wunsch der Vertragspartner ausgestaltet werden können. Abbildung 2.1 zeigt exemplarisch die Handelsaktivitäten, die ein Stromversorger zur Deckung seines Strombedarfs durch den Erwerb verschiedener Stromprodukte über die Großhandelsmärkte durchführen könnte.




Abbildung 2.1.: Bilanzkreismanagement durch die Nutzung verschiedener Stromprodukte. In Anlehnung an [17, S. 456].

Aus dem Beispiel wird deutlich, dass es für einen BKV nur schwerlich möglich ist, seinen BK perfekt ausgeglichen zu halten. In diesem Fall muss eine Vielzahl an Produkten mit unterschiedlichen Laufzeiten genutzt werden, um den schwankenden Strombedarf ohne größere Abweichungen abzudecken. Für die unweigerlich auftretenden Differenzen muss er Ausgleichsenergie beziehen.

2.1.2.1. Stromhandel an der EPEX Spot

Der Börsenstromhandel im deutsch/luxemburgischen Marktgebiet teilt sich auf die European Energy Exchange (EEX) und die European Power Exchange (EPEX Spot) auf. An der EEX werden Produkte des Terminmarktes gehandelt; der Kurzfristhandel läuft über die EPEX Spot.

Einmal pro Tag finden im Day-Ahead-Handel der EPEX Spot Auktionen für alle einstündigen Blöcke des nächsten Tages statt. Bis zur GCT um 12:00 Uhr können Marktteilnehmer Kauf- oder Verkaufsaufträge übermitteln. Ein Auftrag umfasst die zeitlichen Lieferblöcke, die Strommenge sowie bei einem Verkauf den Mindestpreis und bei einem Kauf den Höchstpreis. Die Börse ermittelt in der Folge für jede Stunde einen Einheitspreis als Ergebnis der Auktion. Wie in Abbildung 2.2 dargestellt, werden dazu alle Verkauf- und Kaufaufträge hinsichtlich ihres Mindest- und Höchstpreises sortiert und gegenüber dem kumulierten Handelsvolumen aufgetragen. Die sich ergebende Reihenfolge der stromverkaufenden Kraftwerke wird Merit-Order-Liste (MOL) genannt. Der Schnittpunkt der Angebots- mit der Nachfragekurve ergibt den Markträumungspreis (Engl.

Market Clearing Price, MCP). Alle Verkäufer, deren Mindestpreise unter, und alle Bieter, deren Höchstpreis über dem MCP liegen, sind in der Auktion erfolgreich. Ihre Aufträge werden zum MCP ausgeführt. Die gehandelte Strommenge wird Marktträumungsvolumen (Engl. Market Clearing Volumen, MCV) genannt. Veröffentlicht werden die Auktionsergebnisse um 12:40 Uhr [18, S. 91].




Abbildung 2.2.: Preisbildung im Day-Ahead-Handel der EPEX Spot. Dargestellt sind die aggregierten Angebots- und Nachfragekurven aller Day-Ahead-Aufträge zur Erfüllung in der ersten Stunde des 30.06.2020 an der EPEX Spot. Die Daten stammen von der Website der EEX [19].

Nach dem gleichen Prinzip wie im Day-Ahead-Handel können bis 15:00 Uhr Aufträge für die Intraday-Auktionen übermittelt werden. Bei diesen Auktionen werden nicht die 24 einstündigen Blöcke, sondern die 96 viertelstündigen Blöcke des Folgetages gehandelt. Die Ergebnisse liegen um 15:10 Uhr vor [20, S. 243]. Ab 15:00 Uhr öffnet der kontinuierliche Intraday-Handel mit Stunden- und ab 16:00 Uhr der mit Viertelstundenprodukten. Im kontinuierlichen Handel gilt das Pay-as-bid-Verfahren. Marktteilnehmer tragen ihre Aufträge in ein Orderbuch ein. Zwei Aufträge, bei denen bei gleichem Handelsvolumen und Zeitblock der gebotene Verkaufspreis größer oder gleich dem gebotenen Kaufpreis ist, werden automatisch in eine Transaktion umgewandelt [17, S. 440f.]. Ein Produkt kann im kontinuierlichen Intraday-Handel bis zu fünf Minuten vor seiner Erfüllung gehandelt werden. Im gesamten Spotmarkt der EPEX Spot beträgt die Mindesthandelsmenge 100 kWh.

2.1.2.2. Strompreis für Haushaltskunden

Die Kosten für die Strombeschaffung am Großhandelsmarkt entsprechen für Haushaltskunden nur einem Teil ihres Strompreises. Hinzukommen die externen Strompreisbestandteile, auf die zusammen mehr als drei Viertel des Gesamtpreises entfallen. Zu ihnen gehören die Netznutzungsentgelte (NNE) sowie Kosten für die Strommessung und den Messstellenbetrieb, die Umlage aus dem Erneuerbare-Energien-Gesetz (EEG), die Stromsteuer sowie weitere Abgaben wie Schadensersatzforderungen von Offshore-Windparkbetreibern, die Vergütung von abschaltbaren Lasten und Anlagen, die nach dem Kraft-Wärme-Kopplungs-Gesetz (KWKG) gefördert werden, und zur Kompensation von individuellen NNE nach § 19 Stromnetzentgeltverordnung (StromNEV). Auf alle Preisbestandteile wird zudem die Umsatzsteuer erhoben. In Abbildung 2.3 werden die Preisbestandteile des Haushaltskundenpreises für das Jahr 2020 abgebildet.

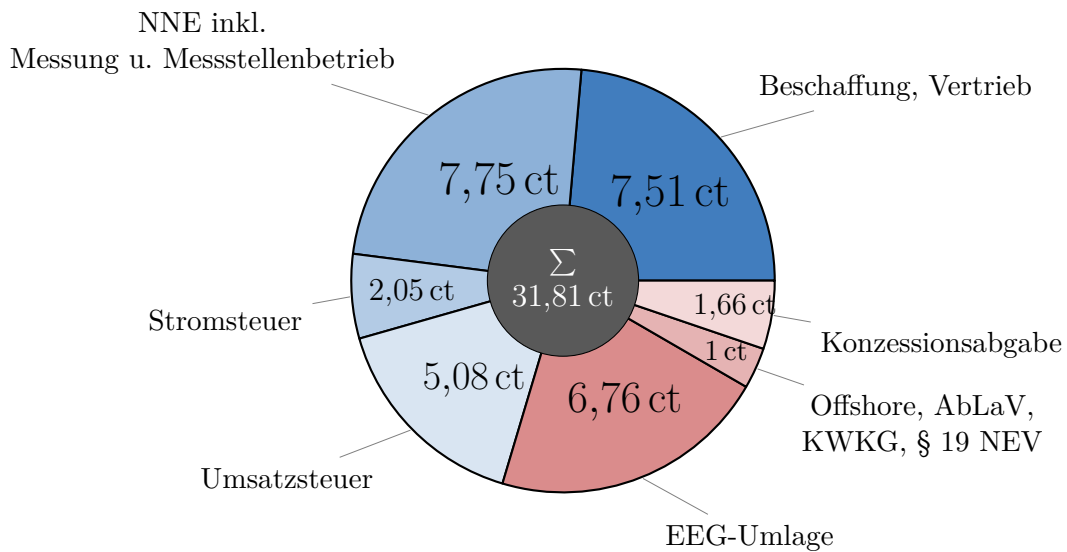


Abbildung 2.3.: Aufschlüsselung des durchschnittlichen Strompreises für eine Kilowattstunde für Haushaltskunden für das Jahr 2020. Betrachtet wurde ein Haushalt mit einem Stromverbrauch von 3500 kWh/a. Die Daten stammen von [21].

2.1.3. Regelleistungsmarkt

Weicht die Netzfrequenz um mehr als das Totband von ± 10 mHz von ihrem Zielwert 50 Hz ab, weisen die ÜNBs qualifizierte Anlagen an, durch Regelung ihres Arbeitspunktes die Differenzen auszugleichen [22]. Die dafür eingesetzte elektrische Leistung wird Regelleistung genannt. Die Regelarbeit oder auch Regelenergie bezeichnet die Energiemenge, die innerhalb eines Zeitraumes zum Schwankungsausgleich eingesetzt wird.

2.1.3.1. Regelleistungsarten

Regelleistung (und damit auch Regelarbeit) wird nach dem Vorzeichen der Leistungserbringung unterschieden. Übersteigt die Stromentnahme die -zufuhr, wird positive Regelleistung notwendig, um das Leistungsdefizit auszugleichen. Wird mehr Leistung in das Netz eingespeist als durch Übertragungsverluste und Verbraucher entnommen wird, benötigt es negative Regelleistung. Regelleistung kann von Erzeugern und Verbrauchern bereitgestellt werden. Positive Regelleistung wird erbracht, wenn ein Erzeuger seine Einspeiseleistung hoch regelt oder ein Verbraucher seine Verbrauchsleistung reduziert. Zur Erbringung negativer Regelleistung senken Erzeuger ihre Leistung oder steigern Lasten ihren Verbrauch. Zusätzlich werden Regelleistungsarten anhand des Einsatzzeitraumes klassifiziert. Abbildung 2.4 visualisiert die Einsatzreihenfolge und -dauer der verschiedenen Regelleistungsarten.

Momentanreserve Schnelle Frequenzänderungen werden durch die Trägheit rotierender Massen ausgeglichen. Da die Generatorzahl von Kraftwerken an die Netzfrequenz gekoppelt ist, führt eine Veränderung der Netzfrequenz zu einer Veränderung der Generatorzahl. Die Trägheit des Generators wirkt dieser Änderung entgegen [12, S. 46][17, S. 350]. Die Momentanreserve (MR) wird nicht auf dem Regelleistungsmarkt gehandelt, sie wird durch die Anlagen im Netz automatisch bereitgestellt.

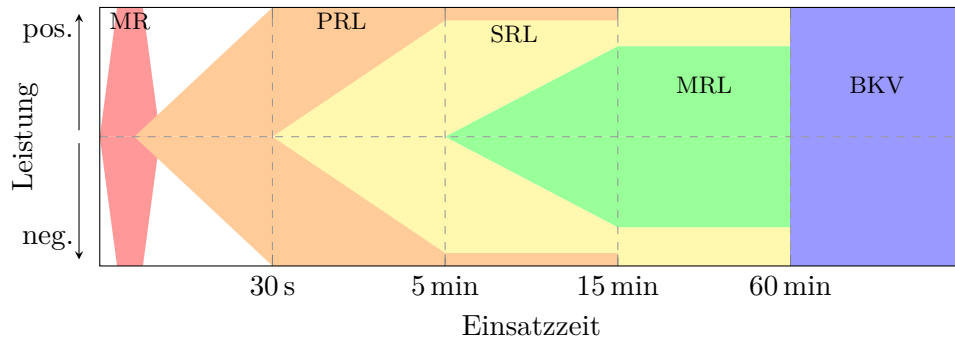


Abbildung 2.4.: Unterscheidung von Regelleistungsarten nach ihrem Einsatzzeitpunkt. In Anlehnung an [23] und [24, S. 201].

Primärregelreserve Technische Einheiten (TE), die Primärregelleistung (PRL) erbringen, messen eigenständig permanent die Netzfrequenz. Verlässt die Netzfrequenz das Totband, beginnen die TEs automatisch PRL bereitzustellen. Durch PRL werden vor allem kurzfristige Laständerungen ausgeglichen, sodass die Zielfrequenz gehalten wird. Eine TE muss seine gesamte Angebotsleistung innerhalb von 30 s und für mindestens 15 min bereitstellen können [24, S. 200][25, S. 8f.].

Sekundärregelreserve Sekundärregelleistung (SRL) wird zur Frequenzwiederherstellung und zur Einhaltung des geplanten Energieaustausches zwischen den Regelzonen eingesetzt. Die erbringenden Anlagen erhalten direkt von dem ÜNB ihrer Regelzone ein Sollsignal [17, S. 338][24, S. 201][25, S. 9f.]. Sie müssen nach spätestens 30 s beginnen, den Sollwert anzufahren und ihn innerhalb von 5 min erreicht haben [26, S. 3].

Minutenreserve Bei länger anhaltende Frequenzabweichungen kommt die Minutenreserve zum Einsatz. Der Abruf von Minutenregelleistung (MRL) erfolgt im Viertelstundentakt der Fahrpläne durch eine manuelle Aktivierung der Betreiber [25, S. 10] über maximal eine Stunde.

Stundenreserve Nach einer Stunde geht die Verantwortung für den Ausgleich der anhaltenden Störung auf den verursachenden BKV über. Dieser muss durch die Regelung eigener Erzeuger oder Lasten oder durch Aktivitäten auf dem Großhandelsmarkt die Differenzen ausgleichen [27, S. 32]. Ebenso wie die MR ist auch die Stundenreserve nicht Teil des Regelleistungsmarktes.

2.1.3.2. Auktionsverfahren der Sekundärregel- und Minutenreserve

Die Marktregularien des Regelleistungsmarktes werden regelmäßig geändert. Der folgende Abschnitt beschreibt die Regularien, die bis zum 30.06.2020 gültig waren und bei der Entwicklung des Algorithmus berücksichtigt wurden. Die anschließend vorgenommenen Änderungen am Marktdesign werden in die politischen Handlungsempfehlungen in Abschnitt 5.3.2 einbezogen.

Die deutschen ÜNBs schreiben öffentlich auf der Website www.regelleistung.net gemeinsam ihren Bedarf für Regelleistung aus. Tabelle 2.2 fasst die wichtigsten Regularien des Auktionsverfahrens zusammen.

Tabelle 2.2.: Wesentliche Merkmale der Auktionsverfahren der Regelleistungstypen die bis zum 30.06.2020 gültig waren. In Anlehnung an [25, S. 18].

	Primärregeleserve	Sekundärregelreserve	Minutenreserve
Ausschreibung	werktags D-2	täglich D-1	täglich D-1
GCT	15:00	8:00	10:00
Vergabefrist	16:00	9:00	11:00
Zeitscheiben	1 Block à 24 h	6 Blöcke à 4 h	6 Blöcke à 4 h
Vorzeichendifferenzierung	keine	positiv & negativ	positiv & negativ
Mindestgebot	1 MW	1 MW / 5 MW	1 MW / 5 MW
Gebotsinkrement	1 MW	1 MW	1 MW
Vergabe	Leistungspreis	1. Leistungspreis 2. Arbeitspreis	1. Leistungspreis 2. Arbeitspreis
Vergütung	Einheitspreis	Pay-as-bid	Pay-as-bid

Die Beschaffungsverfahren für die Sekundärregelreserve und Minutenreserve gleichen sich. Täglich wird für die sechs Angebotsblöcke des Folgetages eine bestimmte Menge an Regelleistung ausgeschrieben. Positive und negative Regelleistung sind in den SRL- und MRL-Auktionen getrennte Produkte, für die separate Auktionen stattfinden. Ein Gebot in einer SRL- oder MRL-Auktion umfasst neben dem Produkt (Regelleistungsart und die ausgewählte Zeitscheibe) die erbringbare Leistungshöhe sowie den geforderten Leistungs- und Arbeitspreis. Für Marktteilnehmer, die pro Produkt nur ein Angebot abgeben, liegt die Mindestgebotsmenge bei 1 MW, für andere Teilnehmer bei 5 MW. Es sind nur ganzzahlige Megawatt-Gebote zulässig [25, S. 18].

In der Auktion werden zur Ermittlung der erfolgreichen Bieter alle Angebote nach ihren Leistungspreisen sortiert. Ebenso wie an der EPEX Spot entsteht eine MOL. Alle Anbieter, deren Leistungspreis unterhalb des Grenzpreises liegt, der benötigt wird, um das ausgeschriebene Regelleistungsvolumen abzudecken, erhalten einen Zuschlag. Bieter mit Preisen über dem Grenzpreis werden nicht weiter berücksichtigt. Die erfolgreichen Teilnehmer bekommen per Pay-as-bid-Verfahren den von ihnen gebotenen Preis multipliziert mit ihrer Leistungshöhe fest vergütet. Sie müssen in der Folge für den gebotenen Zeitraum die angebotene Regelleistung vorhalten.

Um die Einsatzreihenfolge für die Erbringung von Regelarbeit zu bestimmen, wird eine MOL auf Basis des Regularbeitspreises aller Bieter gebildet, die über den Regelleistungspreis erfolgreich waren. Wird nun der Einsatz von Regelleistung in einer bestimmten Höhe nötig, werden zuerst die Anlagen der Bieter mit den niedrigsten Arbeitspreisen aktiviert. Diese Bieter erhalten zusätzlich zur Vergütung für die vorgehaltene Regelleistung auch die tatsächlich erbrachte Regelarbeit mit ihrem gebotenen Arbeitspreis vergütet.

2.1.3.3. Abrechnung von Regelarbeit und Nachholeffekte

Für erbrachte Regelarbeit wird ein Bilanzkreisausgleich in der Höhe der geleisteten Delta-Arbeit vorgenommen. Bei positiver Regelarbeit wird Energie in den BK hineingebucht, bei negativer Regelarbeit herausgebucht. Erbringern von Regelarbeit entstehen so keine zusätzlichen Kosten durch den Bezug von Ausgleichsenergie [28, S. 5].

Positive Regelarbeit per DSM wird erbracht, indem Verbraucher ihren Strombezug reduzieren. Dadurch verringert sich die abgesetzte Strommenge des Stromversorgers. Um diesen Ausfall zu kompensieren, muss der Erbringer der Regelarbeit die nicht bezogene Delta-Energie dem Stromversorger bezahlen. Die Zahlung umfasst lediglich die Energiekomponente, die externen Strompreisbestandteile (vgl. Abschnitt 2.1.2.2) werden exkludiert. Erbringer negativer Regelarbeit zahlen hingegen nur die externen Strombestandteile in Höhe der Delta-Energie [28].

Wird Regelleistung per DSM bereitgestellt, kommt es häufig zu Nachholeffekten. Eine Flotte aus BEVs, die durch die Unterbrechung ihrer Ladevorgänge den Strombezug reduziert und dadurch negative Regelleistung erbringt, wird das Laden zu einem späteren Zeitpunkt nachholen müssen. Bei einer großen Flotte kann dies zu merklichen Abweichungen von der Lastprognose des Fahrplans führen. Werden die Fahrzeuge nicht nach SLP bilanziert (vgl. Abschnitt 2.1.1.2), muss der BKV reagieren, die Nachholeffekte prognostizieren und durch Handel an den Spotmärkten Ungleichgewichte im BK vorbeugen, um Kosten für Ausgleichsenergie zu vermeiden.

2.1.3.4. Pooling und virtuelle Kraftwerke

Regelleistungsanbieter können mehrere TEs zu Pools zusammenschließen. Dadurch können auch TEs, die alleine die Präqualifikationsanforderungen nicht erfüllen oder die Mindestgebotshöhe nicht leisten können, am Regelleistungsmarkt teilnehmen. Außerdem verringert die Zusammenschaltung mehrerer Anlagen das Ausfallrisiko und bietet eine Möglichkeit zum gegenseitigen Ausgleich von Schwankungen. Die Poolzusammensetzung kann zwischen jeder Viertelstunde geändert werden. Eine regelzonenübergreifende Poolbildung ist bislang nicht erlaubt [29, S. 11ff.].

In virtuellen Kraftwerken (Engl. virtual power plant, VPP) werden mehrere Erzeuger und Verbraucher gemeinsam gemanagt. VPPs können als Verbund aus örtlich verteilten Erzeugern, Speichern und Lastmanagementeinheiten, die Energie und Systemdienstleistungen anbieten, beschrieben werden [30, S. 5]. Der VPP-Betreiber vernetzt dezentrale Anlagen mithilfe eines zentralen Leitsystems. Durch die gemeinsame Optimierung der Anlagenfahrweise und Vermarktung sowie geteilte Aufwände für Prognosemodelle und technische Infrastruktur entstehen Synergieeffekte.

2.1.4. Eigenverbrauch des Stromes privater Photovoltaikanlagen

Für die Betreiber von PV-Anlagen mit einigen Kilowatt installierter Leistung gibt es mehrere Gründe, ihren Anlagenbetrieb hinsichtlich einer möglichst hohen Eigenverbrauchsquote des erzeugten PV-Stromes zu optimieren. Ideelle Gründe sind eine größere Unabhängigkeit von externen Energielieferungen durch die Steigerung des Autarkiegrades, die Entlastung des öffentlichen Stromnetzes und die Erhöhung des eigenen Grünstromanteils. Für Betreiber jüngerer PV-Anlagen lohnen sich hohe Eigenverbrauchsquoten auch finanziell.

2.1.4.1. Entwicklung der EEG-Vergütung und des Strompreises

Das EEG bietet den Anlagenbetreibern mehrere Optionen, ihren Strom zu vermarkten. Für kleine Anlagen kommt in aller Regel die Einspeisevergütung nach § 21 EEG zur Anwendung. Diese garantiert dem Anlagenbetreiber für 20 Jahre einen konstanten Vergütungssatz für jede in das Stromnetz

eingespeiste Kilowattstunde. Für die Höhe der Vergütung besteht mittlerweile ein Degressionsmechanismus, der zu einer stetigen Abnahme der Vergütungshöhe führt. Welchen Vergütungssatz ein Anlagenbetreiber erhält, hängt von der installierten Anlagenleistung, vom Inbetriebnahmedatum und dem für dieses Datum gültigen Fördersatz ab.

Durch die kontinuierliche Absenkung der EEG-Förderung bei steigenden Strompreisen wächst die finanzielle Bedeutung des Eigenverbrauchs des PV-Stromes. Abbildung 2.5 zeigt die zeitliche Entwicklung der EEG-Einspeisevergütung und des Strompreises für private Haushalte.




Abbildung 2.5.: Feste Einspeisevergütung für PV-Anlagen auf Wohngebäuden mit Peakleistungen kleiner als 10 kW und durchschnittliche Bruttostrompreise für Haushalte mit einem Stromverbrauch von 3500 kWh/ im zeitlichen Verlauf seit 2001. Die EEG-Vergütungsdaten stammen von [31], die Strompreisdaten von [21].

Nachdem im Jahr 2012 die Vergütung einer in das Netz eingespeisten Kilowattstunde durch die EEG-Förderung den durchschnittlichen Strompreis deutlich unterschritt, konnte für die Betreiber von PV-Neuanlagen der Verbrauch einer selbsterzeugten Kilowattstunde Strom finanziell attraktiver sein als seine Netzeinspeisung. Die Höhe des finanziellen Vorteils eines gesteigerten Eigenverbrauchs hängt von mehreren Faktoren ab. Insbesondere dem Preis für den alternativen Strombezug über das Stromnetz, dem EEG-Fördersatz und der Entscheidung des Anlagenbetreibers für oder gegen die Kleinunternehmerregelung.

2.1.4.2. Ausmaß des finanziellen Vorteils des Eigenstromverbrauchs

Im Jahr 2020 betrug der durchschnittliche Strompreis für einen privaten Haushalt mit 3500 kWh/a Stromverbrauch 31,81 ct/kWh. Der EEG-Vergütungssatz für PV-Anlagen mit installierter Leistung kleiner als 10 kW lag im Juni 2020 bei 9,17 ct/kWh. Für eine Kilowattstunde Strom, die nicht über das Netz bezogen wurde, sondern von der eigenen PV-Anlage, verzichtet der Anlagenbetreiber auf die EEG-Vergütung, muss aber gleichzeitig auch nicht seinen Stromversorger für den Strombezug bezahlen. Sein Gewinn entspricht allerdings nicht genau der Differenz zwischen EEG-Vergütung und Durchschnittsstrompreis. Der genannte Durchschnittsstrompreis umfasst auch den verbrauchsunabhängigen Grundpreis der NNE. Dieser lag im Jahr 2020 in Deutschland zwischen 8 €/a und 105 €/a und im Mittel bei 52 €/a [32, S. 164]. Die variablen Kosten lagen folglich bei etwa 30,32 ct/kWh. In der Differenz würde ein Anlagenbetreiber durch den gesteigerten Eigenverbrauch 21,15 ct/kWh gewinnen. Weitere Faktoren sind allerdings zu berücksichtigen.

Gemäß §§ 61 und 61e EEG sind Betreiber von PV-Anlagen, die nach dem 01.08.2014 in Betrieb genommen wurden, zur Zahlung der EEG-Umlage i. H. v. 40 % für den Eigenverbrauch verpflichtet. Im Jahr 2020 lag die volle EEG-Umlage bei 6,76 ct/kWh, sodass für die genannten Anlagen 2,70 ct für jede selbst verbrauchte Kilowattstunde an die Netzbetreiber abgeführt werden müssen. Eigenversorger, deren Anlagen höchstens über 30 kW installierte Leistung verfügen, sind nach § 61j EEG von dieser Pflicht allerdings befreit.

Für die Bemessung der Marge ist zudem entscheidend, ob der selbst genutzte Strom umsatzsteuerpflichtig und wie hoch die Eigenverbrauchsquote ist. Speist ein Anlagenbetreiber weniger als 10 % des erzeugten Stromes in das Netz ein, ist er von der Umsatzsteuer befreit [33, S. 12]. Andernfalls muss sowohl für den an den Netzbetreiber verkauften Strom als auch für den selbst verbrauchten Strom Umsatzsteuer abgeführt werden. Da die EEG-Vergütung allerdings ein Nettobetrag ist, wird die Umsatzsteuer für den verkauften Strom vom VNB übernommen.

Anlagenbetreiber können die Umsatzsteuerpflicht auf den Eigenverbrauch umgehen, wenn sie von der Kleinunternehmerregelung, die ihnen § 19 des Umsatzsteuergesetzes einräumt, Gebrauch machen. Die Kleinunternehmerregelung kann geltend gemacht werden, wenn der Umsatz aus den unternehmerischen Aktivitäten des Betreibers, dies inkludiert auch die Bewirtschaftung einer kleinen PV-Anlage, 22 000 € im vergangenen Jahr nicht überstieg. Der Vorteil der Aussetzung der Umsatzsteuerpflicht hat einen Verzicht auf den Vorsteuerabzug zum Nachteil. Folglich kann die Umsatzsteuer, die bei der Anschaffung und Installation gezahlt wurde, nicht zurückgefordert werden. Ein Verzicht auf die Ausnahmeregelung ist für fünf Jahre bindend [34, S. 59ff.].

Bei einer Entscheidung gegen die Kleinunternehmerregelung und für die Umsatzsteuerpflicht auf den selbst genutzten Strom muss als Bemessungsgrundlage der Steuerhöhe der Einkaufspreis beim eigenen Stromversorger angelegt werden [34, S. 74.]. Bezahlt beispielsweise ein Anlagenbetreiber seinem Stromlieferanten (inkl. dem anteiligen fixen Grundpreis) 31,81 ct/kWh, werden bei einem Umsatzsteuersatz von 19 % auf seinen Eigenverbrauch

$$\begin{aligned} \text{Umsatzsteuer} &= \text{Nettostrompreis} \cdot \text{Umsatzsteuersatz} \\ \text{Umsatzsteuer} &= \frac{31,81 \text{ ct/kWh}}{1,19} \cdot 0,19 = 5,07 \text{ ct/kWh} \end{aligned} \tag{2.1}$$

an Umsatzsteuer fällig. Bei einem jährlichen Eigenverbrauch i. H. v. 1250 kWh belaufen sich die Kosten auf rund 63 €/a. Welche Entscheidung zur Wahrnehmung der Kleinunternehmerregelung finanziell am lohnendsten ist, ist stets fallabhängig. Nicht selten wird in den ersten fünf Anlagenjahren auf die Kleinunternehmerregelung verzichtet, um die Umsatzsteuer von den hohen Fixkosten zu Beginn absetzen zu können, und anschließend die Regelung wahrgenommen, um keine Umsatzsteuer auf den Eigenverbrauch zahlen zu müssen.

Für eine Anlage, deren installierte Leistung 30 kW nicht überschreitet, ergibt sich mit den obigen Annahmen bei Wahrnehmung der Kleinunternehmerregelung in Summe ein finanzieller Vorteil durch den gesteigerten Eigenverbrauch i. H. v. 21,15 ct/kWh. Bei Zahlung der Umsatzsteuer reduziert sich der Betrag auf 16,08 ct/kWh.

2.1.5. Netzdienliches Laden

Mit der aktuell exponentiellen Marktdiffusion von BEVs (vgl. Abbildung 1.2) steigen die Anteile der Elektromobilität am Stromverbrauch und der Netzlast. Werden die Fahrzeuge ungesteuert geladen, erwarten Studien zukünftig zeitweise Engpässe in den Verteilnetzen, insbesondere den Ortsnetzen. Eine Studie zu den Auswirkungen der Elektromobilität auf das deutsche Niederspannungsnetz in [8] schätzt, dass ab einem Anteil von 30 % Elektroautos am gesamten Pkw-Bestand mit vermehrten Stromausfällen zu rechnen ist. Die Studie prognostiziert einen Investitionsaufwand i. H. v. 11 Mrd. €, um bei einer Elektroauto-Quote von 50 % die Integration in die Ortsnetze sicherzustellen. Bei einer Quote von 100 % Elektroautos steigt der Aufwand auf 26 Mrd. €.

Auch in [9] werden die Auswirkungen der Elektromobilität auf das deutsche Verteilnetz untersucht. Umfasst die BEV-Flotte im Jahr 2030 sechs Mio. Fahrzeuge, gehen die Autoren von Investitionskosten i. H. v. 35 Mrd. € aus und 15 Mio. BEVs erforderten Ausbaumaßnahmen im Umfang von 36 Mrd. €.

2.1.5.1. Steuerbare Verbrauchseinrichtungen gemäß § 14a EnWG

Der § 14a EnWG bietet VNBs eine Möglichkeit zeitweisen lokalen Überlastungen der Verteilnetze entgegenzuwirken:

„Betreiber von Elektrizitätsverteilernetzen haben denjenigen Lieferanten und Letztverbrauchern im Bereich der Niederspannung, mit denen sie Netznutzungsverträge abgeschlossen haben, ein reduziertes Netzentgelt zu berechnen, wenn mit ihnen im Gegenzug die netzdienliche Steuerung von steuerbaren Verbrauchseinrichtungen, die über einen separaten Zählpunkt verfügen, vereinbart wird. Als steuerbare Verbrauchseinrichtung im Sinne von Satz 1 gelten auch Elektromobile [...]“.

Entscheidet sich der Betreiber einer Ladeeinrichtung (LE) seine Anlage als steuerbare Verbrauchseinrichtung anzumelden, ist der zuständige Messstellenbetreiber nach § 29 MsbG verpflichtet, den separaten Zählpunkt als iMSys auszuführen. Die Wahl der Steuertechnik und die Gestaltung der Anreize in Form verringerter NNE sind dem VNB überlassen.

Von den rund 1,5 Mio. steuerbaren Verbrauchseinrichtungen, die 2020 in Deutschland angemeldet waren, entfielen nur etwa 5700 bzw. 0,38 % auf LEs für Elektroautos. 66 % der angemeldeten Anlagen waren Nachtspeicherheizungen und 26 % Wärmepumpen [32, S. 192f.]. Die Nationale Plattform Elektromobilität (NPM) schätzte im Jahr 2019, dass für jedes Elektroauto etwa 1,1 private Ladepunkte errichtet werden. [35, S. 55]. Mit den etwa 600 000 Elektroautos, die Ende 2020 in Deutschland zugelassen waren [6], [7], ergeben sich etwa 660 000 private Ladepunkte, sodass der Anteil der privaten LEs, die als steuerbare Verbrauchseinrichtung angemeldet waren, knapp unter 1 % liegt.

Zur Steuerung der Verbrauchseinrichtungen setzen die VNBs bislang vor allem auf Rundsteuertechnik und Zeitschaltungen. Per Rundsteuertechnik können VNBs ein Signal an einen Funkrundsteuerempfänger an der LE senden, der daraufhin die Stromversorgung der LE reduziert

oder vollständig unterbricht. Die Steuerungspraxis weist zwischen den VNBs wesentliche Unterschiede auf. Während einige Netzbetreiber ein- bis mehrstündige permanente Zeitkorridore pro Tag definieren, in denen die Stromversorgung der LEs unterbrochen wird, verwenden andere VNBs die Unterbrechungsmöglichkeit nur bedarfsabhängig. Ebenso unterschiedlich wird gehandhabt, ob die Stromversorgung vollständig unterbrochen wird oder nur eine Leistungsreduktion stattfindet.

Differenzen zeigen sich auch bei der Gestaltung der finanziellen Anreize. Im Durchschnitt aller steuerbaren Verbrauchseinrichtungen reduzierten die VNBs im Jahr 2020 den Arbeitspreis der NNE um 57 % bzw. 3,69 ct/kWh [32, S. 192], wobei das Minimum bei 16 % und das Maximum bei 85 % lag. Einige Netzbetreiber zahlen für die Anmeldung einer steuerbaren Verbrauchseinrichtung einen einmaligen Bonus. Bei der finanziellen Betrachtung müssen den reduzierten NNE die Kosten für die Installation und den Betrieb des iMSys gegenübergestellt werden. Für den Einbau des Zählers trägt grundsätzlich der Messstellenbetreiber die Kosten. Ist ein Umbau des Zähler-schranks notwendig, sind die Kosten vom Letztverbraucher zu tragen. Für die Messbetriebskosten setzt § 31 MsbG eine Obergrenze von 100 €/a.

Tabelle 3.4 in Abschnitt 3.3.4 zeigt die Vertragsmodalitäten von drei deutschen VNBs, die für die Modellierung des netzdienlichen Ladens in dieser Arbeit abgebildet wurden.

2.1.5.2. Kombination steuerbare Verbrauchseinrichtung und PV-Anlage

Es ist technisch möglich an einer LE bilanziell den Strom der eigenen PV-Anlage zu beziehen, obwohl die LE aufgrund der Anmeldung als steuerbare Verbrauchseinrichtung an einem separaten Zählpunkt liegt. Dazu muss eine Kaskadenschaltung verwendet werden, wie sie Abbildung 2.6 zeigt. Der Strombezug der LE aus dem Verteilnetz wird durch die Differenzbildung der Bezugsmessungen beider Zähler ermittelt. Der separate Zählpunkt, den § 14a EnWG fordert, ergibt sich erst aus der Kombination beider Zähler. Kaskadenschaltungen werden bislang nur selten eingesetzt und gehören nicht immer zu den internen Messkonzepten der VNB und erfordern daher Abstimmungsbedarf. Die Wahl des Messkonzepts obliegt allerdings dem Anlagenbetreiber. Entspricht es den technischen Anschlussbedingungen und ist es konform zu den Anforderungen des EnWGs, ist es vom VNB umzusetzen [36, S. 14].

2.2. Ladevorgangssteuerung von Elektroautos

2.2.1. Ladesysteme in Elektroautos

Moderne BEVs lassen sich sowohl per Wechselstrom (Engl. alternating current, AC) als auch per Gleichstrom (Engl. direct current, DC) laden. Einige wenige Ausnahmen gibt es im Kleinwagensegment, beispielsweise den Smart Fortwo EQ und den e.GO Life, bei denen auf einen DC-Anschluss verzichtet wurde. Abbildung 2.7 zeigt in einem Schaltplan die wichtigsten elektrischen Komponenten eines Ladesystems, bestehend aus dem Stromnetz, der AC- und DC-LE und einem BEV. Für private und viele öffentliche LEs sind derzeit AC-Ladepunkte üblich, die eine Ladeleistung der Stufen 3,6 kW (16 A einphasig), 7,2 kW (16 A zweiphasig), 11 kW (16 A dreiphasig)

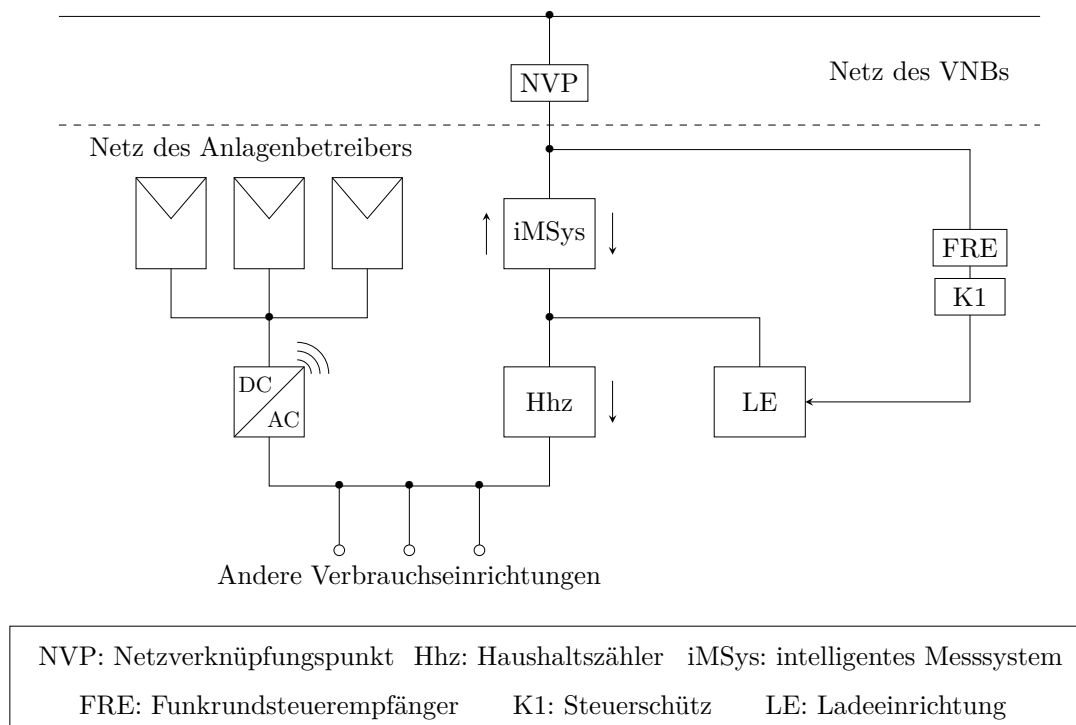


Abbildung 2.6.: Messkonzept für einen Haushalt mit PV-Anlage und LE als steuerbare Verbrauchseinrichtung mit einer Kaskadenschaltung. In Anlehnung an [36, S. 8] und [37, S. 12].

oder 22 kW (32 A dreiphasig) anbieten. Diese Normalladesäulen werden an das Niederspannungsnetz angeschlossen. LEs mit Leistungen größer als 22 kW definiert § 2 der Ladesäulenverordnung als Schnellladesäulen. Mit Ausnahme einiger 43 kW-AC-Ladepunkte stellen sie DC bereit. Zumeist ermöglichen sie Ladeleistungen bis zu 50 kW, seltener 100 kW, 150 kW, 250 kW oder sogar 350 kW. Bei Schnellladesäulen ist ein Anschluss an das Mittelspannungsnetz üblich [39, S. 22].

Die Hochvoltbatterie des BEVs wird mit DC geladen. Bei Verwendung einer AC-LE finden die Gleichrichtung und Spannungswandlung im Ladegerät (Engl. On-Board Charger, OBC) des Autos statt. Die Wallbox oder AC-Ladesäule verfügt über Sicherheitsschaltungen sowie ein Modul, das zur Kommunikation mit dem Fahrzeug und an öffentlichen Ladepunkten zur Abrechnung des Ladevorgangs dient. Ab dem mittelpreisigen Segment verfügen auch LEs für den privaten Gebrauch über eine Internetanbindung, die das Monitoring und die Steuerung von Ladevorgängen ermöglicht. Einige hochpreisige LEs sind MID (Measuring Instruments Directive, Richtlinie der EU) zertifiziert. Sie erfüllen die gleichen messtechnischen Anforderungen wie Haushaltsstromzähler. Beim Laden an einem DC-Ladepunkt übernimmt die LE das Gleichrichten des Stromes und die Anpassung der Ladespannung.

Das Spannungsniveau des Ladevorgangs wird vom Batteriemanagementsystem (BMS), dem Laderegler des Fahrzeugs (Engl. Charging Control Unit, CCU) und der LE vorgegeben. Beim üblichen Constant-Current-Constant-Voltage-Verfahren (CCCV) wird es im Laufe eines Ladevorgangs bis zu einem Grenzwert gesteigert, bei gleichzeitig konstanter Stromstärke, und anschließend konstant gehalten, während die Stromstärke absinkt. Die beiden Ladestränge werden über die Battery Junc-

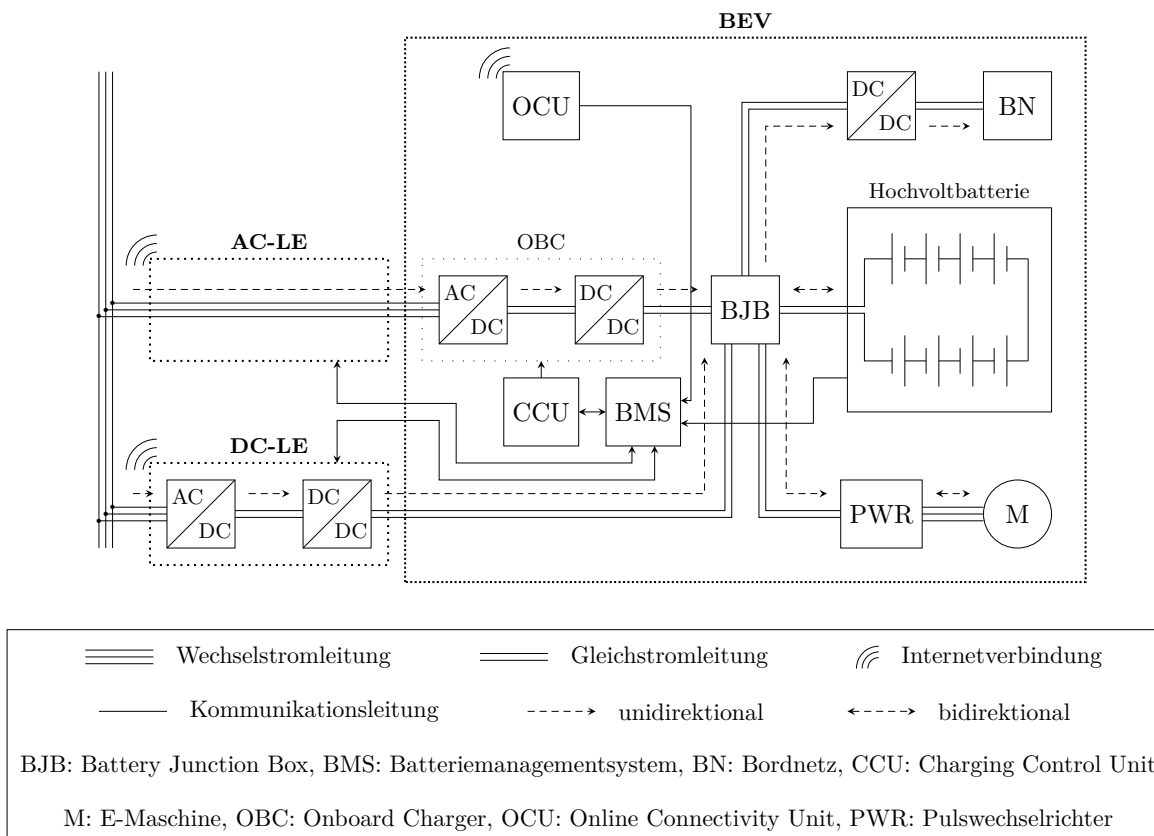


Abbildung 2.7.: Simplifizierter Schaltplan für ein leitendes Ladesystem. In Anlehnung an [38].

tion Box (BJB) mit der Hochvoltbatterie verbunden. Über sie werden auch das Bordnetz inkl. der Niedervoltbatterie und der Antriebsstrang mit Energie versorgt. Beim Rekuperieren wandelt der Pulswechselrichter (PWR) den von der E-Maschine während eines Bremsvorgangs erzeugten AC in DC um, der zum Wiederaufladen der Hochvoltbatterie genutzt wird.

Alle relevanten Elektroautos auf dem europäischen Markt verfügen über eine Internetanbindung. Über die Online Connectivity Unit (OCU) können die Nutzer nicht nur Navigations- und Unterhaltungsdaten beziehen, sondern auch Steuerungsbefehle an das Fahrzeug weitergeben. Die Möglichkeit, Ladevorgänge per App zu starten und zu unterbrechen, gehört zur Standardausstattung moderner BEVs.

2.2.2. Systemarchitekturen der Ladevorgangsoptimierung

Die gewählte Systemarchitektur definiert die beteiligten Akteure und Komponenten sowie ihre Handlungen und Verknüpfungen. Gemäß [10] lassen sich zentralisierte und dezentralisierte Smart-Charging-Systemarchitekturen voneinander unterscheiden.

2.2.2.1. Zentralisierte Architektur

Innerhalb einer zentralisierten Systemarchitektur werden die Ladevorgänge der beteiligten BEVs durch einen Aggregator gesteuert. Sein Ziel ist es, durch die gleichzeitige Optimierung einer Vielzahl an Ladevorgängen unterschiedlicher Fahrzeuge Synergieeffekte zu erzielen. In die Optimierung

fließen neben Daten der Fahrzeuge, je nach Optimierungsziel, häufig auch Daten aus der Stromwirtschaft ein, beispielsweise aktuelle Börsenstrom- und Regelleistungspreise, Einspeiseleistungen von Erzeugern, die Netzauslastung oder der prognostizierte BK-Saldo. Je nach Systemauslegung ermöglicht der Aggregator den Fahrzeugnutzern mehr oder weniger Einflussmöglichkeiten auf den Optimierungsprozess. Abschnitt 2.2.3 beschreibt ein Praxisbeispiel für die Ausgestaltung einer zentralisierten Systemarchitektur.

Voraussetzung für eine zentralisierte Architektur ist die technische Steuerungsmöglichkeit des Ladevorgangs durch den Aggregator. Ihm bieten sich dazu zwei Möglichkeiten: die Steuerung über das Fahrzeug oder über die LE.

Die Steuerung über das Fahrzeug erfordert die Kommunikation zwischen Fahrzeug und Aggregator. Genutzt wird die Internetanbindung über die OCU und dessen Verbindung zum BMS. Zum einen kommuniziert das Fahrzeug Statusinformationen wie den Batteriefüllstand (Engl. state of charge, SoC), den Fahrzeugstatus (Fahren, Parken, verbunden mit Ladepunkt) und die Ladeleistung. Zum anderen übermittelt der Aggregator, wenn das Fahrzeug mit einem Ladepunkt verbunden ist, einen Ladeleistungssollwert. Über das BMS wird der Sollwert an die CCU und die LE weitergegeben. Die Schnittstelle zur OCU wird vom Hersteller des Fahrzeugs (Engl. Original Equipment Manufacturer, OEM) kontrolliert. Ein Aggregator, der nicht gleichzeitig der OEM ist, benötigt zunächst die Gewährung des Schnittstellenzugangs durch den OEM.

Die Steuerung über die LE erfolgt vergleichbar. Der Aggregator kommuniziert mit der LE, erhält von dieser Informationen zum Verbindungsstatus und Ladevorgang und übermittelt die Befehle zur Ladevorgangssteuerung an sie. Ebenso wie der Fahrzeug-OEM die Schnittstelle zum Fahrzeug kontrolliert, steht der Zugang zur Kommunikation mit einer LE einem externen Aggregator nicht per se offen. Er ist auf eine Kooperation mit dem Hersteller oder Betreiber der LE angewiesen. Zusätzlich wird eine Nutzung der Schnittstelle durch noch bestehende technische Limitationen erschwert. Nicht alle LEs verfügen über eine Internetanbindung und jene, die eine Onlineanbindung aufweisen, unterstützen nur zum Teil das erforderliche Open Charging Point Protocol (OCPP). Ebenso unterstützen nicht alle LEs den Kommunikationsstandard ISO 15118, der benötigt wird, damit das Fahrzeug sein SoC an die LE weitergeben kann.

Um eine hohe Akzeptanz der Nutzer für die zentralisierte Steuerung der Ladevorgänge zu erreichen, müssen Aggregatoren die Mobilitätsbedürfnisse ihrer Nutzer gewährleisten [40]. Sie müssen sicherstellen, dass die Verschiebung der Ladezeitpunkte nicht zur Folge hat, dass Nutzer Fahrten nicht tätigen können, weil der SoC des Fahrzeuges nicht ausreichend ist. Dazu können Aggregatoren die Nutzer bei der Planung der Ladevorgänge einbeziehen. Zum einen können sie den zukünftigen Energiebedarf auf der Basis des historischen Bedarfs bestimmen, zum anderen den Nutzer um Informationen zum zukünftigen Nutzungsverhalten bitten [40], [41].

2.2.2.2. Dezentralisierte Architektur

Innerhalb von dezentralisierten Architekturen werden die Entscheidungen über die optimalen Ladezeiträume vor Ort getroffen. Die Steuerung kann manuell durch den Nutzer erfolgen, indem er das Fahrzeug zu bestimmten Zeitpunkten mit der LE verbindet oder den Ladevorgang

per Fahrzeug-App steuert, oder automatisch durch das Fahrzeug, die LE oder ein dezentrales Energie-Managementsystem vorgenommen werden. In allen Fällen können die Entscheidungen über günstige Ladezeiträume ebenso wie bei zentralisierten Architekturen auf Strompreis-, Erzeugungsleistungs- oder Netzzustandsdaten basieren, die entweder dem Nutzer zur Verfügung gestellt werden oder in einen Algorithmus einfließen, der vom Fahrzeug, der LE oder einem Energie-Managementsystem ausgeführt wird.

2.2.3. Praxisbeispiel Jedlix

Nachdem Smart Charging jahrelang nur Gegenstand von theoretischen Überlegungen und praktischen Forschungsprojekten war, haben seit ein paar Jahren die ersten Anbieter begonnen Smart-Charging-Dienste und -Produkte kommerziell anzubieten. Einer dieser Pioniere ist das niederländische Unternehmen Jedlix. Es wurde 2016 innerhalb des Energieversorgungsunternehmens Eneco gegründet und ist seit 2019 ein eigenständiges Unternehmen, an dem Renault Anteile hält. Über Renault hinaus bestehen aktuell Kooperationen mit Tesla, Jaguar, BMW und Hyundai. Zur Zeit bietet Jedlix seinen Service in Großbritannien, den Niederlanden, Belgien, Frankreich, Norwegen und der Schweiz an. Die Aufnahme eines Projekts zur Partizipation am deutschen Regelleistungsmarkt zusammen mit TransnetBW gaben beide Unternehmen im Januar 2021 bekannt [42].

Das Unternehmen richtet sich mit einer zentralisierten Systemarchitektur an private Elektroautofahrer und größere Flotten. Die kooperierenden OEMs gewähren Jedlix den Zugriff auf die Ladevorgangssteuerung ihrer BEVs, sodass Jedlix an die Fahrzeuge teilnehmender Nutzer Soll-ladewerte senden und von den Fahrzeugen Fahr- und Ladedaten erhält. Den Nutzern wird eine Beeinflussung der Optimierung ermöglicht. Über eine App können sie Jedlix im Voraus mitteilen, wann ihr Fahrzeug das nächste Mal am privaten Ladepunkt angeschlossen und wann im Anschluss die Verbindung getrennt wird. Um ein Mindestmaß an Fahrleistung garantiert zu bekommen, können die Nutzer einstellen, wie viel Energie direkt nach dem Anschluss des Fahrzeugs an eine LE geladen werden soll. Nach dem Erreichen des Mindest-SoCs entscheidet Jedlix' Algorithmus über die weiteren Ladezeiträume [43] [44].

Die Ladezeiträume werden hinsichtlich günstiger Spotmarktpreise und eines möglichst hohen Anteils an EE am geladenen Strommix optimiert. Das Unternehmen kooperiert mit mehreren Stromversorgern. Die Nutzer müssen daher keinen Stromvertrag mit Jedlix abschließen. Jedlix wird an den Ersparnissen, die bei den Stromlieferanten durch günstigere Strompreise und verbesserte Bedarfsprognosen anfallen, beteiligt. Außerdem erbringt Jedlix mit seiner gesteuerten Flotte SRL. Die Fahrzeuge werden innerhalb des VPPs von Next Kraftwerke mit Gewächshäusern, Windrädern, PV- und Biogasanlagen gepoolt [45]. Auch die Nutzer werden an den Erlösen beteiligt. Je mehr Ladeflexibilität sie anbieten, desto höher fällt der monatliche Betrag aus.

2.3. Regressionsmodelle für die Prognose von Zeitreihen

Um zeitlich im Voraus die Ladezeiträume einer Flotte von Elektroautos so zu bestimmen, dass sie hinsichtlich des Börsenstrom-, des Regelleistungspreises und der Erzeugungsleistung privater PV-Anlagen fallen, müssen diese Kenngrößen prognostiziert werden. Im Rahmen dieser Arbeit wird in Abschnitt 3.4.3 auf der Basis eines Regressionsmodells ein Prognosemodell entwickelt, das den EPEX Spot Day-Ahead-Strompreis für eine Zeitspanne von 48 h prognostiziert.

2.3.1. Lineare Regressionsmodelle

Ein Regressionsmodell wird definiert durch eine abhängige Variable y (auch Regressand genannt) und K erklärende Variablen $\mathbf{x} = [1, x_1, x_2, \dots, x_K]$ (auch Regressoren genannt), die in einen mathematischen Zusammenhang gesetzt werden. Für den Fall $K = 1$ liegt ein univariates Modell vor, bei $K > 1$ ist das Modell multivariat. Das Ziel eines Regressionsmodells ist die Erklärung oder Vorhersage der abhängigen Variable durch die Beobachtung der erklärenden Variablen [46, S. 1]. In einem linearen Regressionsmodell wird die Beziehung zwischen der abhängigen Variable und den erklärenden Variablen durch eine lineare Funktion modelliert

$$y = \beta_0 + x_1 \beta_1 + x_2 \beta_2 + \dots + x_K \beta_K + \epsilon = \mathbf{x} \boldsymbol{\beta} + \epsilon, \quad (2.2)$$

innerhalb der die β -Terme Regressionskoeffizienten genannt werden und der Fehlerterm ϵ alle nicht beobachtbaren, zufälligen Einflüsse abbildet. ϵ besitzt die Eigenschaften von weißem Rauschen und ist mittelwertfrei. \mathbf{x} ist ein Zeilenvektor der Länge $K + 1$ mit $x_0 = 1$, $\boldsymbol{\beta}$ ein Spaltenvektor mit ebenfalls $K + 1$ Elementen.

Eine Zeitreihe ist eine Sequenz $\mathbf{y} = [y_1, y_2, \dots, y_T]^\top$ einer Zufallsvariable, deren empirische Ausprägung T -Mal beobachtet wurde [46, S. 41]. Für das lineare Regressionsmodell einer Zeitreihe folgt aus Gleichung 2.2

$$\mathbf{y} = [\mathbf{x}_1 \boldsymbol{\beta} + \epsilon_1, \mathbf{x}_2 \boldsymbol{\beta} + \epsilon_2, \dots, \mathbf{x}_T \boldsymbol{\beta} + \epsilon_T] = \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\epsilon}, \quad (2.3)$$

mit den Dimensionen $\mathbf{y}^{T \times 1}$, $\mathbf{X}^{T \times (K+1)}$, $\boldsymbol{\beta}^{(K+1) \times 1}$ und $\boldsymbol{\epsilon}^{T \times 1}$.

Damit das gleiche Regressionsmodell erfolgreich die Zeitreihe \mathbf{y} aus den Zeitreihen \mathbf{X} vorhersagen kann, muss der Zusammenhang zwischen beiden Zeitreihen gleich bleiben. Sind beide Zeitreihen schwach stationär, ist dies der Fall. Ein stochastischer Prozess ist schwach stationär, wenn für jede Sequenz $\mathbf{y}_t = [y_1, y_2, \dots, y_t]^\top$ für den Mittelwert

$$\mu_y = E[\mathbf{y}_t], \quad \text{mit } |\mu_y| \leq \infty \quad \forall t \in T, \quad (2.4)$$

für die Varianz

$$\sigma_y^2 = E[(\mathbf{y}_t - \mu_y)(\mathbf{y}_t - \mu_y)], \quad \text{mit } \sigma_y^2 < \infty \quad \forall t \in T \quad (2.5)$$

und für die Autokovarianz

$$\gamma_{y,l} = E[(\mathbf{y}_t - \mu_y)(\mathbf{y}_{t-l} - \mu_y)] \quad \forall l, \quad \text{mit } \gamma_{y,l} < \infty \quad \forall t \in T \quad (2.6)$$

gilt, die ersten und zweiten Momente also zeitlich konstant sind [46, S. 43].

2.3.2. AR-Modell

Unterliegt die Zufallsvariable y einem autoregressiven (AR) Prozess der Ordnung p , kann er am Zeitpunkt t mithilfe der Modellparameter ϕ als Summe der Sequenz der p vergangenen Zustände von y_t beschrieben werden

$$y_t = \phi_0 + y_{t-1} \phi_1 + y_{t-2} \phi_2 + \dots + y_{t-p} \phi_p + \epsilon_t = \phi_0 + \sum_{j=1}^p y_{t-j} \phi_j + \epsilon_t. \quad (2.7)$$

In diesem Fall weist der Zustand y eine Korrelation zu seinen p vorherigen Zuständen auf. Das AR(p)-Modell entspricht strukturell dem linearen Regressionsmodell in Gleichung 2.2, nur dass in diesem Fall nicht exogene Variablen, sondern Vergangenheitswerte zur Beschreibung des Prozesses verwendet werden [47, S. 32f.].

Die autoregressive Eigenschaft einer Zufallsvariable lässt sich durch die Berechnung der Autokorrelation analysieren. Sie beschreibt die Korrelation der Zufallsvariablen mit einer zeitlich verschobenen Version von sich selbst. Je stärker diese Korrelation ist, desto besser lässt sich der künftige Zustand der Variable auf der Basis ihrer vergangenen Zustände prognostizieren. Die Autokorrelation entspricht der in Gleichung 2.6 definierten Autokovarianz normiert auf das Produkt der Standardabweichungen beider Versionen der Zufallsvariablen

$$\rho_{y,l} = \frac{E[(\mathbf{y}_t - \mu_y)(\mathbf{y}_{t-l} - \mu_y)]}{\sigma_{y_t} \sigma_{y_{t-l}}}, \quad \text{mit } 0 \leq l \leq 1 \text{ und } 0 \leq \rho_{y,l} \leq 1. \quad (2.8)$$

Die Verzögerungsvariable l beschreibt die Verschiebung zwischen den beiden Versionen von \mathbf{y}_t . Bei schwach stationären Prozessen ist gemäß Gleichung 2.6 die Standardabweichung zeitunabhängig, sodass sich Gleichung 2.8 zu

$$\rho_{y,l} = \frac{E[(\mathbf{y}_t - \mu_y)(\mathbf{y}_{t-l} - \mu_y)]}{\sigma_y^2} = \frac{\gamma_{y,l}}{\sigma_y^2} \quad (2.9)$$

vereinfacht. Da für keine Verschiebung $l = 0$ gemäß Gleichung 2.5 $\gamma_{y,0} = \sigma_y^2$ gilt, ist die Autokorrelation an dieser Stelle stets $\rho_{y,0} = 1$.

Für ein AR(1)-Modell einer schwach stationären Zufallsvariable y

$$y_t = \phi_0 + y_{t-1} \phi_1 + \epsilon_t \quad (2.10)$$

kann gezeigt werden, dass die Autokorrelation exponentiell mit dem Faktor ϕ_1 abfällt

$$\rho_{y,l} = \phi_1 \rho_{y,l-1}, \quad \forall l > 0. \quad (2.11)$$

Eine Herleitung dieses Zusammenhangs findet sich in Abschnitt A.1.1 im Anhang. Abbildung 2.8 verdeutlicht diesen Zusammenhang und zeigt beispielhaft die Autokorrelationsfunktionen zweier AR(1)-Modelle mit den Modellparametern $\phi_1 = 0,8$ und $\phi_1 = -0,8$.




Abbildung 2.8.: Autokorrelationsfunktionen zweier AR(1)-Modelle. In Anlehnung an [47, S. 35].

2.3.3. ARX-Modell

AR-Modelle sind Spezialfälle von autoregressiven Modellen mit exogenen Eingabewerten (Engl. autoregressive with exogenous input, ARX). In ARX-Modellen werden Korrelationen der Zufallsvariable y mit seinen eigenen vergangenen Zuständen und weiteren exogenen, erklärenden Variablen zusammen modelliert [48, S. 107]

$$y_t = y_{t-1} \phi_1 + y_{t-2} \phi_2 + \dots + y_{t-p_y} \phi_{p_y} + x_{t-1} \beta_1 + x_{t-2} \beta_2 + \dots + x_{t-p_x} \beta_{p_x} + \epsilon_t \quad (2.12)$$

$$\Leftrightarrow y_t = \sum_{j=1}^{p_y} y_{t-j} \phi_j + \sum_{j=1}^{p_x} x_{t-j} \beta_j + \epsilon_t. \quad (2.13)$$

Für den Fall eines multivariaten Modells, indem y durch mehrere exogene Variablen erklärt wird, wird Gleichung 2.13 zu

$$y_t = \sum_{j=1}^{p_y} y_{t-j} \phi_j + \sum_{k=1}^K \sum_{j=1}^{p_{x_k}} x_{k,t-j} \beta_{k,j} + \epsilon_t \quad (2.14)$$

erweitert. Mit

$$\mathbf{z}_{t-1} = \left[y_{t-1}, y_{t-2}, \dots, y_{t-p_y}, \quad x_{1,t-1}, x_{1,t-2}, \dots, x_{1,t-p_{x_1}}, \quad \dots, \quad x_{K,t-1}, x_{K,t-2}, \dots, x_{K,t-p_{x_K}} \right] \quad (2.15)$$

und

$$\boldsymbol{\theta} = \left[\phi_1, \phi_2, \dots, \phi_{p_y}, \quad \beta_{1,1}, \beta_{1,2}, \dots, \beta_{1,p_{x_1}}, \quad \dots, \quad \beta_{K,1}, \beta_{K,2}, \dots, \beta_{K,p_{x_K}} \right]^T \quad (2.16)$$

kann Gleichung 2.14 in der Form

$$y_t = \mathbf{z}_{t-1}^T \boldsymbol{\theta} + \epsilon_t \quad (2.17)$$

geschrieben werden. Für eine Sequenz \mathbf{y}_t folgt

$$\mathbf{y}_t = \mathbf{Z}_{t-1} \boldsymbol{\theta} + \boldsymbol{\epsilon}_t, \quad (2.18)$$

mit den Dimensionen $\mathbf{y}_t^{T \times 1}$, $\mathbf{Z}_{t-1}^{T \times (p_y + \sum_{k=1}^K p_{x_k})}$, $\boldsymbol{\theta}^{(p_y + \sum_{k=1}^K p_{x_k}) \times 1}$ und $\boldsymbol{\epsilon}_t^{T \times 1}$.

2.3.4. Methode der kleinsten Quadrate

Um die gezeigten Modelle zur Prädiktion einer abhängigen Variable zu verwenden, müssen die erklärenden Variablen des Modells beobachtet und die Modellparameter geschätzt werden. Die Methode der kleinsten Quadrate (Engl. least squares method, LS-Methode) ist ein wichtiges Verfahren zur Lösung überbestimmter linearer Gleichungssysteme [49, S. 115] und kann zur Approximation der Modellparameter verwendet werden.

Das Ziel der LS-Methode ist das Ermitteln einer möglichst guten Schätzung der Modellparameter $\hat{\boldsymbol{\theta}}$, sodass der mittlere quadratische Fehler zwischen dem geschätzten dem tatsächlichen Zustand der abhängigen Variable über alle Beobachtungen minimiert wird

$$\min_{\hat{\boldsymbol{\theta}}} E [\mathbf{y}_t - \hat{\mathbf{y}}_t]^2 = \min_{\hat{\boldsymbol{\theta}}} J, \quad (2.19)$$

wobei J Fehlerfunktion genannt wird. Für ein ARX-Modell nach Gleichung 2.18, deren abhängige Variable mit der Funktion

$$\hat{\mathbf{y}}_t = \mathbf{Z}_{t-1} \hat{\boldsymbol{\theta}}, \quad (2.20)$$

geschätzt wird, ergibt sich die Fehlerfunktion zu

$$J = E [\mathbf{y}_t - \mathbf{Z}_{t-1} \hat{\boldsymbol{\theta}}]^2 = E \left[(\mathbf{y}_t - \mathbf{Z}_{t-1} \hat{\boldsymbol{\theta}})^\top (\mathbf{y}_t - \mathbf{Z}_{t-1} \hat{\boldsymbol{\theta}}) \right] \quad (2.21)$$

$$\Leftrightarrow J = E \left[\mathbf{Z}_{t-1}^\top \hat{\boldsymbol{\theta}}^\top \mathbf{Z}_{t-1} \hat{\boldsymbol{\theta}} - 2 \mathbf{Z}_{t-1}^\top \hat{\boldsymbol{\theta}}^\top \mathbf{y}_t - \mathbf{y}_t^\top \mathbf{y}_t \right]. \quad (2.22)$$

Für die vorliegenden Beobachtungswerte im Zeitraum 1, 2, ..., T kann die mathematisch optimale Schätzung der Modellparameter durch Nullsetzen der partiellen Ableitung der Fehlerfunktion ermittelt werden

$$\frac{\partial J}{\partial \hat{\boldsymbol{\theta}}} = E \left[\mathbf{Z}_{t-1}^\top \hat{\boldsymbol{\theta}}^\top \mathbf{Z}_{t-1} \hat{\boldsymbol{\theta}} - 2 \mathbf{Z}_{t-1}^\top \hat{\boldsymbol{\theta}}^\top \mathbf{y}_t - \mathbf{y}_t^\top \mathbf{y}_t \right] \stackrel{!}{=} 0 \quad (2.23)$$

$$\Rightarrow \mathbf{Z}_{t-1}^\top \mathbf{Z}_{t-1} \hat{\boldsymbol{\theta}} = \mathbf{Z}_{t-1}^\top \mathbf{y}_t \quad (2.24)$$

$$\Leftrightarrow \hat{\boldsymbol{\theta}} = (\mathbf{Z}_{t-1}^\top \mathbf{Z}_{t-1})^{-1} \mathbf{Z}_{t-1}^\top \mathbf{y}_t. \quad (2.25)$$

Gleichung 2.24 wird auch Normalgleichung genannt [48, S. 87ff.] [49, S. 115f.]. Die Lösung der Normalgleichung $\hat{\boldsymbol{\theta}}$ wird zusammen mit den Beobachtungen der erklärenden Variablen zur Prognose der abhängigen Variable verwendet

$$\hat{\mathbf{y}}_{t+1} = \mathbf{z}_t^\top \hat{\boldsymbol{\theta}}. \quad (2.26)$$

bzw. zur Prognose einer Sequenz der abhängigen Variable

$$\hat{\mathbf{y}}_{t+1} = \mathbf{Z}_t \hat{\boldsymbol{\theta}}. \quad (2.27)$$

2.3.5. Metriken zur Ermittlung der Prognosequalität

Es werden verschiedene Metriken zur Ermittlung der Qualität von Prognoseverfahren verwendet. Drei der am häufigsten verwendeten Metriken sind der mittlere absolute Fehler (Engl. Mean Absolute Error, MAE), die Wurzel der mittleren Fehlerquadratsumme (Engl. Root Mean Square Error, RMSE) sowie der mittlere absolute Prozentfehler (Engl. Mean Absolute Percentage Error, MAPE) bzw. der modifizierte MAPE (mMAPE). Im Vergleich zum MAE

$$\text{MAE} = \frac{1}{T} \sum_{t=1}^T |y_t - \hat{y}_t|, \quad (2.28)$$

fallen beim RMSE

$$\text{RMSE} = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2} \quad (2.29)$$

einzelne große Abweichungen durch das Quadrieren stärker ins Gewicht. Beide Metriken eignen sich zum Vergleich zweier Prognoseverfahren für die gleiche zu prognostizierende Größe. Sie treffen allerdings keine Aussage über die relative Prognosequalität. Mit dem MAPE

$$\text{MAPE} = \frac{1}{T} \sum_{t=1}^T \frac{|y_t - \hat{y}_t|}{y_t} \cdot 100\%, \quad (2.30)$$

lassen sich Prognoseergebnisse von Größen mit unterschiedlichen Bezugsgrößen vergleichen. Im Gegensatz zum MAPE dividiert die modifizierte Variante

$$\text{mMAPE} = \frac{\sum_{t=1}^T |y_t - \hat{y}_t|}{\sum_{t=1}^T y_t} \cdot 100\% \quad (2.31)$$

stets durch den Mittelwert der Beobachtungen $1/T \sum_{t=1}^T y_t$ und nicht durch die Einzelwerte y_t . Dies erlaubt die Verwendung dieser Metrik bei Zeitreihen, die sehr kleine Werte annehmen oder gleich null sein können. Der mMAPE wird teilweise auch als normalisierter MAE (nMAE) oder relativer MAE (rMAE) bezeichnet.

2.4. Lineare Optimierung

Die lineare Optimierung ist eines der wichtigsten Verfahren aus dem Bereich des Operations Research. Sie wird vor allem in der Betriebswirtschaft, den Ingenieurwissenschaften, der Mathematik und der Informatik angewandt. Im Rahmen dieser Arbeit wird das Laden einer Elektroautoflotte als lineares Optimierungsproblem formuliert und per linearer Optimierung aus einer ökonomischen Betrachtungsweise optimiert.

2.4.1. Grundlagen der linearen Optimierung

Bei einem allgemeinen Optimierungsproblem wird eine Lösung \mathbf{x} innerhalb des Lösungsraumes S gesucht, sodass das Ergebnis einer Bewertungsfunktion $f(\mathbf{x})$ optimiert wird. Das Optimierungsziel

ist zumeist das Finden des Minimums oder Maximums von $f(\mathbf{x})$ [50, S. 1]. Ein lineares Optimierungsproblem

$$\min \{f(\mathbf{x}) : \mathbf{x} \in S\} \quad (2.32)$$

beschränkt sich auf lineare Zielfunktionen und lineare Nebenbedingungen, die den Lösungsraum definieren. Zudem sind die Entscheidungsvariablen $\mathbf{x} \in \mathbb{R}^{n \times 1}$ beliebig teilbar.

Ein lineares Programm (LP) ist eine lineare Optimierungsaufgabe, bei dem die Zielfunktion durch den Vektor $\mathbf{c} \in \mathbb{R}^{n \times 1}$ bestimmt wird

$$\min_{\mathbf{x}} f(\mathbf{x}) = \min_{\mathbf{x}} (c_1 x_1 + c_2 x_2 + \dots + c_n x_n) \quad (2.33)$$

und die Nebenbedingungen durch eine Matrix $\mathbf{A} \in \mathbb{R}^{m \times n}$ und einen Vektor $\mathbf{b} \in \mathbb{R}^{m \times 1}$ gegeben sind

$$\begin{aligned} a_{1,1} x_1 + a_{1,2} x_2 + \dots + a_{1,n} x_n &= b_1 \\ a_{2,1} x_1 + a_{2,2} x_2 + \dots + a_{2,n} x_n &= b_2 \\ \vdots & \\ a_{m,1} x_1 + a_{m,2} x_2 + \dots + a_{m,n} x_n &= b_m, \end{aligned} \quad (2.34)$$

wobei zusätzlich Nichtnegativitätsbedingungen für \mathbf{x} gelten können

$$x_j \geq 0, \quad \text{für einige oder alle } j \in \{1, \dots, n\}. \quad (2.35)$$

Eine kompaktere Schreibweise ist die Standardform des linearen Optimierungsproblems [51, S. 1ff.]

$$\begin{aligned} \min_{\mathbf{x}} \mathbf{c}^T \mathbf{x} \\ \text{unter } \mathbf{A} \mathbf{x} \leq \mathbf{b} \\ x_j \geq 0, \quad \text{für einige oder alle } j \in \{1, \dots, n\}. \end{aligned} \quad (2.36)$$

2.4.2. Lösung eines linearen Optimierungsproblems durch den primalen Simplexalgorithmus

Kleine lineare Optimierungsprobleme, jene mit genau zwei Entscheidungsvariablen x_1 und x_2 und jene mit genau zwei Nebenbedingungen, können in einem einfachen Verfahren graphisch gelöst werden. Für die Lösung umfangreicherer Probleme wird der Simplexalgorithmus als Standardverfahren eingesetzt. An dieser Stelle folgt eine kurze Beschreibung des Simplex-Verfahrens. Da der vollständige theoretische Hintergrund zu umfangreich ist, um ihn hier darstellen zu können, insbesondere bzgl. Spezialfällen, sei für detailliertere Ausführungen auf die einschlägige Fachliteratur, z. B. [50]–[52], verwiesen.

Zur Anwendung des Simplexalgorithmus muss das LP zunächst in die Normalform umgewandelt werden. In der Normalform unterliegen alle Entscheidungsvariablen Nichtnegativitätsbedingungen $\mathbf{x} \geq \mathbf{0}$ und alle anderen Nebenbedingungen liegen als Gleichheitsrestriktionen vor. Die Umwandlung aus der Standardform in die Normalform erfolgt durch die Einführung von Schlupfvariablen

$x_{n+1}, x_{n+2}, \dots, x_{n+m}$

$$\begin{array}{rcccccc}
 a_{1,1} x_1 + a_{1,2} x_2 + \dots + a_{1,n} x_n + a_{1,n+1} x_{n+1} & & & & & = b_1 \\
 a_{2,1} x_1 + a_{2,2} x_2 + \dots + a_{2,n} x_n + & a_{2,n+2} x_{n+2} & & & & = b_2 \\
 \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\
 a_{m,1} x_1 + a_{m,2} x_2 + \dots + a_{m,n} x_n + & & & & a_{m,n+m} x_{n+m} & = b_m,
 \end{array} \quad (2.37)$$

deren Nebenbedingungskoeffizienten $a_{1,n+1}, a_{2,n+2}, \dots, a_{m,n+m}$ gleich eins gesetzt werden und die durch das Nullsetzen der Koeffizienten $c_{n+1}, c_{n+2}, \dots, c_{n+m}$ für die Zielfunktion ergebnisneutral sind. Von Interesse für LPs sind Nebenbedingungsmatrizen, für die $\text{rang}(\mathbf{A}) = m < n$ gilt. Nur in diesem unterbestimmten Fall ist, die Abwesenheit von redundanten Nebenbedingungen vorausgesetzt, das Gleichungssystem nicht eindeutig bestimmt, sodass Freiheitsgrade zur Erfüllung der Nichtnegativitätsbedingungen verbleiben [52, S. 43].

Werden $n - m$ Entscheidungsvariablen gleich null gesetzt, so ist das Gleichungssystem 2.37 eindeutig bestimmbar. Zur Anwendung des Simplexalgorithmus werden die Entscheidungsvariablen \mathbf{x} , die nun auch die Schlupfvariablen umfassen, in $n - m$ Nichtbasisvariablen (NBV) \mathbf{x}_{NBV} , deren Werte beliebig und insbesondere gleich null gewählt werden können, und m Basisvariablen (BV) \mathbf{x}_{BV} , deren Werte aus der Lösung des Gleichungssystems folgen und die zusammen die sogenannte Basis bilden, aufgeteilt [51, S. 28f.]

$$\mathbf{x} = \begin{bmatrix} \mathbf{x}_{BV} \\ \mathbf{x}_{NBV} \end{bmatrix}, \quad \mathbf{c} = \begin{bmatrix} \mathbf{c}_{BV} \\ \mathbf{c}_{NBV} \end{bmatrix} \quad \text{und} \quad \mathbf{A} = [\mathbf{A}_{BV}, \mathbf{A}_{NBV}]. \quad (2.38)$$

Das Kernprinzip des Simplexalgorithmus ist es, pro Iteration aus dem Gleichungssystem 2.37 die BVs eindeutig zu bestimmen, anschließend eine NBV so anzupassen, dass sich aus der neuen Lösung für die BVs eine Verringerung der Zielfunktion ergibt. Schließlich wird die angepasste NBV in die Basis aufgenommen und eine BV aus der Basis entfernt [52, S. 54].

Zu Beginn einer Iteration werden alle $\mathbf{x}_{NBV} := \mathbf{0}$ gesetzt. Im ersten Schritt folgt aus $\mathbf{b} = \mathbf{A} \mathbf{x} = \mathbf{A}_{BV} \mathbf{x}_{BV} + \mathbf{A}_{NBV} \mathbf{x}_{NBV}$ durch Umstellen für die BVs

$$\mathbf{x}_{BV} = \mathbf{A}_{BV}^{-1} \mathbf{b} - \mathbf{A}_{BV}^{-1} \mathbf{A}_{NBV} \mathbf{x}_{NBV} \quad (2.39)$$

$$\Rightarrow \mathbf{x}_{BV} := \mathbf{A}_{BV}^{-1} \mathbf{b}, \quad \text{wegen} \quad \mathbf{x}_{NBV} = \mathbf{0} \quad (2.40)$$

die so genannte Basislösung. Eine Basislösung ist zulässig, falls alle BVs nichtnegativ sind [51, S. 29f.]. Ist dies bei der Startbasis nicht der Fall, kann mithilfe der Zwei-Phasen-Methode eine zulässige initiale Basislösung hergestellt werden (vgl. z. B. [51, S. 36ff.]). Wegen der Nichtnegativitätsbedingung für Entscheidungsvariablen ist für NBVs, ausgehend von der Initialisierung $\mathbf{x}_{NBV} = \mathbf{0}$, nur eine Erhöhung ihrer Werte möglich, um die Zielfunktion zu minimieren. Die Zielfunktion

$$\mathbf{c}^\top \mathbf{x} = \mathbf{c}_{BV}^\top \mathbf{x}_{BV} + \mathbf{c}_{NBV}^\top \mathbf{x}_{NBV} = \mathbf{c}_{BV}^\top \mathbf{A}_{BV}^{-1} \mathbf{b} - \mathbf{c}_{BV}^\top \mathbf{A}_{BV}^{-1} \mathbf{A}_{NBV} \mathbf{x}_{NBV} + \mathbf{c}_{NBV}^\top \mathbf{x}_{NBV} \quad (2.41)$$

$$\Leftrightarrow \mathbf{c}^\top \mathbf{x} = \mathbf{c}_{BV}^\top \mathbf{A}_{BV}^{-1} \mathbf{b} + \left(\mathbf{c}_{NBV} - (\mathbf{A}_{BV}^{-1} \mathbf{A}_{NBV})^\top \mathbf{c}_{BV} \right)^\top \mathbf{x}_{NBV} \quad (2.42)$$

kann folglich in einer Iteration durch die Veränderung einer NBV nicht weiter minimiert werden, wenn alle Elemente des Vektors der Optimalitätsindikatoren

$$\mathbf{z}_{NBV}^r = \mathbf{c}_{NBV} - (\mathbf{A}_{BV}^{-1} \mathbf{A}_{NBV})^\top \mathbf{c}_{BV} \geq \mathbf{0} \quad (2.43)$$

sind. Ist dieser Zustand erreicht, ist die erzeugte Basislösung optimal [51, S. 28f.]. Gleichung 2.43 stellt das Abbruchkriterium des Algorithmus dar.

Findet sich in \mathbf{z}_{NBV}^r ein Vektorelement $z_{j_0}^r < 0$, kann die Zielfunktion durch eine Erhöhung der zugehörigen NBV auf $x_{j_0} := t > 0$ minimiert werden. Durch die Anpassung $\mathbf{x}_{NBV} := t \mathbf{e}_{j_0}$, mit als j_0 -tem Einheitsspaltenvektor, ändern sich beim Lösen des Gleichungssystems 2.37 die Ergebnisse der BVs. Für die Aktualisierung der BVs folgt gemäß Gleichung 2.39

$$\mathbf{x}_{BV} := \mathbf{A}_{BV}^{-1} \mathbf{b} - t \Delta \mathbf{x}_B, \quad \text{mit } \Delta \mathbf{x}_{BV} = \mathbf{A}_{BV}^{-1} \mathbf{A}_{NBV} \mathbf{e}_{j_0}. \quad (2.44)$$

Bevor die Entscheidungsvariablen nach Gleichung 2.44 angepasst werden können, muss die optimale Schrittweite t_{opt} gefunden werden. Die Zielfunktion berechnet sich mit Gleichung 2.42 durch [51, S. 29.]

$$\mathbf{c}^\top \mathbf{x} = \mathbf{c}_{BV}^\top \mathbf{A}_{BV}^{-1} \mathbf{b} + t z_{j_0}^r. \quad (2.45)$$

Da $z_{j_0}^r < 0$ ist, fällt die Zielfunktion nach Gleichung 2.45 mit steigendem t . Sind alle Elemente von $\Delta \mathbf{x}_{BV} \leq \mathbf{0}$, ist das Optimierungsproblem unbeschränkt, da ein beliebig hohes t gewählt werden kann, ohne die Nichtnegativitätsbedingungen zu verletzen. Andernfalls ergibt sich die maximal zulässige Schrittweite aus den Gleichungen 2.40 und 2.44

$$\mathbf{x}_{BV} = \mathbf{x}_B - t \Delta \mathbf{x}_{BV} \stackrel{!}{\geq} \mathbf{0} \quad (2.46)$$

$$\Rightarrow t_{\text{opt}} := \min \left\{ \frac{x_i}{\Delta x_i} \right\}, \quad \forall i \in \mathbf{BV}, \Delta x_i \geq 0 \quad (2.47)$$

$$\Rightarrow t_{\text{opt}} := \frac{x_{i_0}}{\Delta x_{i_0}} \quad (2.48)$$

wobei \mathbf{BV} die Menge der Indizes der BVs umfasst und das Minimum beim Index i_0 vorliegt [51, S. 30.].

Mit der errechneten optimalen Schrittweite t_{opt} werden die BVs anhand von Gleichung 2.44 aktualisiert. Es folgt ein Basiswechsel, bei dem $x_{j_0} := t_{\text{opt}}$ in die Basis aufgenommen und $x_{i_0} := 0$ zur NBV wird. Mit der Berechnung der BVs anhand von Gleichung 2.40 wird eine neue Iteration des Algorithmus gestartet. Sobald das Abbruchkriterium aus Gleichung 2.43 erfüllt ist, wird der Algorithmus beendet und die optimalen Werte für die Entscheidungsvariablen sind gefunden.

In jedem Iterationsschritt des Algorithmus müssen $\mathcal{O}(mn)$ arithmetische Operationen ausgeführt werden. Der Rechenaufwand zur Ausführung eines Schrittes wächst durch Hinzufügen weiterer Entscheidungsvariablen und Nebenbedingungen polynomial. Die Anzahl der notwendigen Schritte zur Lösung des LPs variiert mit Anzahl der Entscheidungsvariablen und Nebenbedingungen, den Parametern der Zielfunktion und der Nebenbedingungen. Im ungünstigsten Fall müssen 2^n Schritte zur Lösung des LPs ausgeführt werden [53, S. 146ff.], sodass der Rechenaufwand exponen-

tiell mit der Anzahl der Entscheidungsvariablen wächst. Die mittlere Anzahl notwendiger Schritte kann mit

$$\frac{e\pi}{4} \left(\frac{\pi}{2} + \frac{1}{e} m n^2 (n+1)^2 \right) \quad (2.49)$$

abgeschätzt werden sodass der mittlere Rechenaufwand linear mit der Anzahl der Restriktionen und mit der vierten Potenz der Anzahl der Entscheidungsvariablen wächst.

2.5. Überblick zum Forschungsstand der Ladevorgangsoptimierung

Bessa und Matos haben mehrere nennenswerte Beiträge zum aktuellen Forschungsstand beigetragen. In [54]–[57] haben sie bedeutende Algorithmen auf der Basis lineare Optimierungsprobleme für die aggregierte Ladevorgangsteuerung von BEVs entwickelt. Die in dieser Arbeit modellierte Systemarchitektur und der gewählte Optimierungsansatz bauen insbesondere auf diesen Arbeiten auf. In der Folge werden vier der Studien von Bessa und Matos detaillierter vorgestellt. Im Anschluss werden mehrere Studien mit vergleichbarem Themenschwerpunkt und anderen Ansätzen zusammengefasst. Der Forschungsstand wird hinsichtlich der dominanten Optimierungsverfahren, Systemarchitekturen und Optimierungsziele ausgewertet.

2.5.1. Zusammenfassung ausgewählter Studien

Für das gleiche Optimierungsproblem, dessen Ziel es ist, die Strombeschaffungskosten von BEVs zu minimieren, vergleichen Bessa und Matos in [55] und [54] zwei unterschiedliche Ansätze der Informationsmodellierung der Fahrzeuge. Die beiden verschiedenen Vorausplanungsansätze prognostizieren am Vortag den Strombedarf der BEVs und erwerben die Strommenge am Day-Ahead-Spotmarkt. Der *global approach* genannte Ansatz findet die optimale Strommenge pro halbstündigem Zeitintervall über den prognostizierten aggregierten Strombedarf der Flotte, während der *divided approach* den optimalen Energiebezug für jedes Fahrzeug einzeln berechnet. Ein operativer Algorithmus gleicht am Erbringungstag kontinuierlich Prognoseabweichungen und tatsächlichen Bedarf aus. Alle Optimierungsprobleme werden per linearer Programmierung gelöst. Der *divided approach* erzielt geringere Abweichungen zwischen erworbener Strommenge und tatsächlichem Strombedarf als der *global approach*. Im Vergleich zu einem Basisszenario mit ungesteuertem Laden reduziert der *divided approach* die Gesamtkosten um 18 % (rund 17,6 €/a/Fzg.) und der *global approach* um 7 % (rund 6,95 €/a/Fzg.). Unter Vorliegen perfekten Wissens bzgl. des künftigen Strombedarfs, also der künstlichen Reduzierung des Prognosefehlers auf null, verbessern sich die Kostenreduktionen nur jeweils um weitere 2,4 %.

In [56] und [57] greifen Bessa und Matos ihren *divided approach* auf. Zusätzlich zur Optimierung der Strombeschaffung am Spotmarkt wird ein Regelleistungsangebot durch BEVs simuliert. In [56] erwirbt der Vorausplanungsalgorithmus in Abhängigkeit des prognostizierten Energiebedarfs und der Ladeverfügbarkeit einen Tag vor dem Erbringungstag nicht nur Strom am Spotmarkt, sondern partizipiert am iberischen Elektrizitätsmarkt (MIBEL) auch durch das Angebot von positiver und negativer SRL. Auf eine Prognose der Regelarbeitsabrufhöhe verzichten die Autoren. Das stochastische Abrufverhalten durch die ÜNBs unterliegt lediglich einer geringen Autokorrelation und kann folglich kaum aus vorherigen Zeitschritten der Zeitreihe prognostiziert

werden (wie in Abschnitt 2.3.2 erläutert). In der Folge unterliegt der Voraussplanungsalgorithmus der Annahme eines vollständigen Regelarbeitsabrufes in Höhe des Regelleistungsangebots. Der operative Algorithmus berücksichtigt die tatsächlichen Abrufe. Fehlprognosen der Ladeverfügbarkeit, die zu einer Untererfüllung des Regelarbeitsabrufes führen, modellieren die Autoren mit einer finanziellen Bestrafung. Im Vergleich zum *divided approach* in [56] ermitteln die Autoren durch das Angebot von SRL Kostenreduktionen, je nach Eigenschaften der betrachteten BEV-Flotte, zwischen 30 % und 40 % (rund 30 €/a/Fzg. bis 40 €/a/Fzg.). Perfektes Wissen über das Flottenverhalten steigern die Reduktion nur um 4 % bis 7 %, während perfekte Prognosen für alle Variablen zu weiteren Ersparnissen i. H. v. rund 70 % führen.

Für die Teilnahme am Minutenregelleistungsmarkt in [57] prognostizieren Bessa und Matos hingegen die Wahrscheinlichkeit für einen Regelarbeitsabruf für beide Vorzeichen auf Basis der vergangenen Abrufe. Je geringer die Eintrittswahrscheinlichkeit für einen Regelarbeitsabruf ist, desto kleiner wird das Regelleistungsangebot gewählt. Im Vergleich zu ihrem Basisszenario ermitteln die Autoren Kostenreduktionen im Bereich zwischen 21 % und 16 %.

Drei weitere Algorithmen auf Basis linearer Programmierung stammen von Sortomme und El-Sharkawi [58]. Ein Aggregator erzielt Gewinne aus dem Angebot von Regelleistung und einem Fixbetrag auf die geladene Energie, der von den Nutzern bezahlt wird. Ausgehend von dem maximalen Angebot von Regelleistung ergänzen die Autoren weitere Nebenbedingungen und Kostenterme zur Untersuchung der Reduzierung der Netzbelastung und der Strombeschaffungskosten.

Van der Kam und van Sark [59] verwenden lineare Programmierung zur Optimierung des Eigenverbrauchs von PV-Anlagen in einem Inselnetz. Sowohl Lade- als auch Entladevorgänge (Engl. Vehicle-to-Grid, V2G) von zwei BEVs werden so gesteuert, dass möglichst viel des Energiebedarfs der Fahrzeuge und aller weiteren Verbraucher des Inselnetzes durch eine lokale PV-Anlage gedeckt und der Netzbezug reduziert wird. Die Lösung per linearer Programmierung wird mit einem ungesteuerten Ladeverhalten verglichen sowie je einem gesteuerten Smart-Charging- und V2G-Algorithmus, die im Unterschied zur linearen Programmierung nicht vorausplanend auf Basis von Prognosen entscheiden, sondern ausschließlich auf der Grundlage des aktuellen Systemzustandes. Im ungesteuerten Szenario liegt die Eigenverbrauchsquote bei 49 %. Sie wird durch die Smart-Charging- und V2G-Live-Algorithmen auf 62 % und 79 % gesteigert. Per linearer Programmierung werden 87 % erreicht.

In [60] modellieren Sánchez-Martín et al. ein Zwei-Ebenen-Entscheidungsproblem und lösen es per gemischt-ganzzahliger stochastischer Programmierung. Optimiert werden der Stromhandel im Day-Ahead- und Intraday-Markt und Erlöse durch Regelleistung. Neben zeitlicher Ladeflexibilität wird für die simulierten BEVs und PHEVs eine V2G-Funktionalität angenommen. In der ersten Ebene werden Day-Ahead- und Regelleistungsangebote festgelegt. In der zweiten Ebene werden die Folgekosten durch die Fehler der ersten Entscheidung per Intraday-Handel unter der Berücksichtigung des stochastischen Parkverhaltens der Fahrzeuge minimiert.

Mehrere Arbeiten verwenden dynamische Programmierung. Roterling und Ilic schlagen in [61] innerhalb eines einstufigen Optimierungsprozesses zwei Algorithmen für die dezentrale Ladevorgangsteuerung durch die Laderegler von Elektroautos vor. Ersterer optimiert ausschließlich die Strombeschaffungskosten eines Fahrzeugs durch Verschiebung der Ladezeiträume, der zweite ma-

ximiert zusätzlich Erlöse durch das Angebot von Regelleistung durch Verwendung von V2G. Per dynamischer Programmierung werden die optimalen Ladeleistungen pro Fahrzeug vom letzten betrachteten Zeitschritt zeitlich rückwärts laufend bis zum ersten Zeitschritt ermittelt. Einen ähnlichen Ansatz unter Verwendung eines zentralisierten Aggregators zeigen Han und Sezaki in [62].

López et al. [63] verwenden dynamische Programmierung zur Ermittlung einer optimalen Lösung zur Reduktion der Spotmarktkosten für PHEV. Die optimalen Lösungen werden als Trainingsdaten für maschinelle Lernverfahren verwendet, sodass das stochastische Parkverhalten der Fahrzeuge und die Schwankungen des Strompreises von den Modellen implizit gelernt werden. Ökonomisch verglichen werden die Basisszenarien *immer Laden* und *Grenzwert-basiertes Laden* mit den Ergebnissen eines k-Nearest-Neighbor-Algorithmus, eines flachen sowie eines tiefen künstlichen neuronalen Netzes (KNN). Die ökonomisch besten Entscheidungen treffen das tiefe KNN, gefolgt von dem flachen KNN. k-Nearest-Neighbor erzielt weniger gute Ergebnisse und schneidet etwas besser als die beiden Basisszenarien ab.

2.5.2. Dominierende Methoden, Systemarchitekturen und Optimierungsziele

In der Literatur dominieren bislang lineare, stochastische und dynamische Programmierung die Ladevorgangsoptimierung. Als weitere Methoden werden unter anderen Fuzzy-Logik-Regler von Nour et al. [64] oder der genetische Algorithmus von Mehta et al. [65] jeweils zur Reduzierung der Spotmarktkosten vorgeschlagen.

Zumeist übernimmt ein zentraler Aggregator die Ladevorgangsplanung. Dezentrale Ansätze zeigen neben Rotering und Ilic auch Kamboj et al. [66], die einem Multiagentensystem die Synergieeffekte einer Koalition aus Elektroautos zur Teilnahme am Spot- und Regelleistungsmarkt per V2G aufzeigen, und Kisacikoglu et al. [67], die ein System zur Glättung der Netzlast vorschlagen, in dem jedes Fahrzeug ein eigenes lokales Optimum mit einem iterativen Algorithmus berechnet.

Die meisten Ansätze verwenden eine einstufige Optimierung, die entweder im Voraus planend oder in Echtzeit vorgenommen wird. Bessa und Matos sowie Sánchez-Martín et al. beschreiben einen zweistufigen Prozess, indem zur Einhaltung von Fristen am Day-Ahead- und Regelleistungsmarkt einen Tag im Voraus Ladevorgänge geplant und anschließend während des Erbringungstages Differenzen zwischen Planung und tatsächlichem Status ausgeglichen werden. Im Ansatz von Kisacikoglu et al. berechnet zunächst der Netzbetreiber einen präferierten Leistungswert für eine Elektroautoflotte, der an die Fahrzeuge kommuniziert und im zweiten Schritt von den Fahrzeugen erfüllt wird.

Am häufigsten zielt die Ladevorgangsoptimierung auf ökonomische Vorteile am Spot- oder Regelleistungsmarkt ab. Außerdem werden der Ausgleich von Netzschwankungen und die Erhöhung von PV-Eigenverbrauchsquoten betrachtet. Göhler et al. [68] nennen zusätzlich das Engpassmanagement, Bailey und Axsen [41] die Steigerung des Grünstromanteils als mögliche Ziele einer Optimierung.

3. Entwicklung eines Systems zur ökonomischen Ladevorgangsoptimierung

Dieses Kapitel beschreibt und erklärt das entwickelte Ladevorgangsoptimierungssystem, welches in Matlab implementiert wurde. Das modellierte System berücksichtigt die in Unterkapitel 2.1 erklärten Regularien der deutschen Stromwirtschaft und die aktuellen technischen Möglichkeiten der Ladevorgangssteuerung nach Unterkapitel 2.2. Das modellierte System wird in Unterkapitel 3.1 erklärt. Anschließend wird das Optimierungskonzept des Aggregators vorgestellt. Die Modellierung der Elektroautofahrer basiert hauptsächlich auf realen Datensätzen. Die dafür verwendeten Datensätze werden in Unterkapitel 3.3 beschrieben. Im Anschluss wird erklärt, wie mithilfe von ARX-Modellen und der LS-Methode (vgl. Unterkapitel 2.3) ein Prognosemodell für die Spotmarktpreise entwickelt wurde. Unterkapitel 3.5 erklärt, wie der Aggregator mit dem Regelleistungsmarkt interagiert und welche Preisstrategie er dabei verwendet. Abschließend werden die beiden Algorithmen erklärt, die der Aggregator zur Optimierung der Ladevorgänge verwendet.

Um das entwickelte Optimierungskonzept bewerten zu können, wird es mit einem Basisszenario verglichen. In diesem Basisszenario wurde das Verhalten der gleichen Nutzer, die im Smart-Charging-Szenario betrachtet wurden, simuliert, ohne dass die Ladevorgänge gesteuert werden. Die Ergebnisse der Simulationen werden im Anschluss in Kapitel 4 vorgestellt.

3.1. Modellierte Systemarchitektur

Im Rahmen dieser Arbeit wurde ein System entwickelt, das die Steuerung der Ladevorgänge von Elektroautos durch einen Aggregator mit dem Ziel der ökonomischen Optimierung modelliert. Das System besteht neben dem Aggregator aus den Nutzern des Services, die die Ladevorgangssteuerung ihres BEVs dem Aggregator überlassen. Es wird vom Preisverlauf an der Strombörse beeinflusst, interagiert mit dem Regelleistungsmarkt und bildet Vertragsmodalitäten mit Stromanbietern und VNBS ab.

Der Aggregator kann in diesem System ökonomische Vorteile erzielen, indem er die Ladevorgänge der BEVs an den Strompreis am Spotmarkt und die Erzeugungsleistungen der PV-Anlagen der Nutzer ausrichtet. Zudem kann er durch die Möglichkeit, die Ladeleistung der gesteuerten Flotte gezielt zu erhöhen, negative Regelleistung am Regelleistungsmarkt offerieren. Der Aggregator muss die netzdienlichen Ladezeiträume seiner Nutzer beachten, damit in dem System von reduzierten NNE gemäß § 14a EnWG profitiert werden kann. Es kann davon ausgegangen werden, dass in einem realen System (wie dem von Jedlix, vgl. Abschnitt 2.2.3) sowohl der Aggregator als auch die Nutzer von den ökonomischen Vorteilen finanziell profitieren.

Abbildung 3.1 bildet den Systemaufbau schematisch ab. Das hier betrachtete System basiert auf dem Konzept von Jedlix. Es erweitert das Konzept durch die Partizipation am netzdienlichen

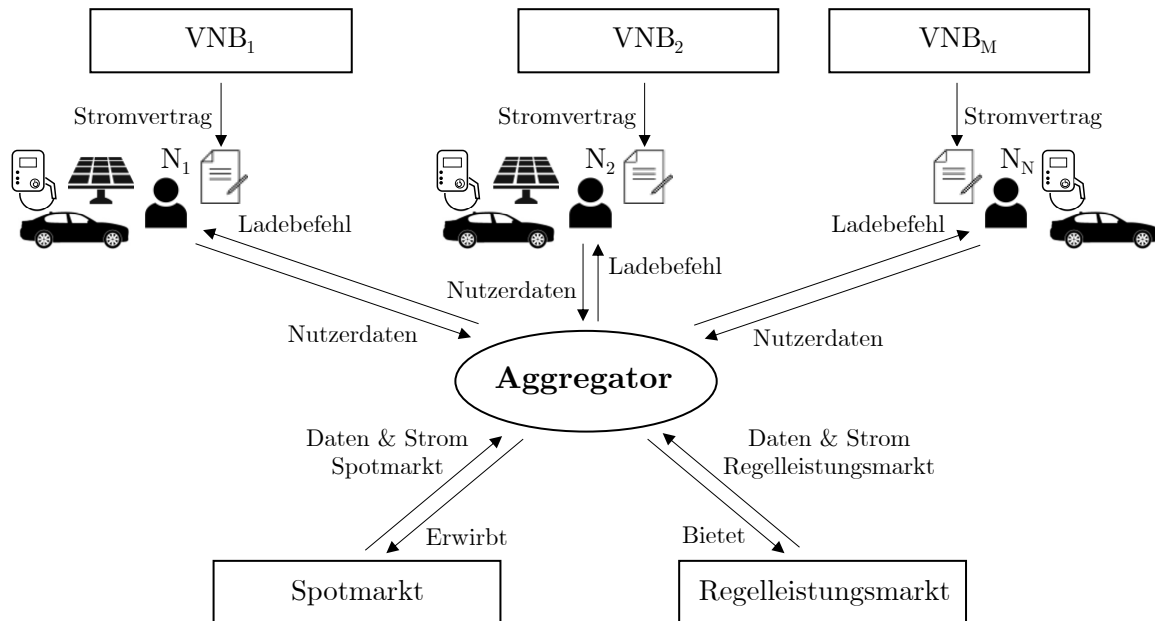


Abbildung 3.1.: Aufbau des modellierten Systems und Interaktionen zwischen den Systemelementen.

Laden und die Anpassung der Ladevorgänge an die Erzeugungsleistungen von PV-Anlagen. Jeder Nutzer verfügt über ein BEV, einen privaten Ladepunkt, der über ein iMSys abgerechnet wird, und einen Stromvertrag. Ein Teil besitzt eine private PV-Anlage. Die Stromvertragskonditionen werden von den VNBs und Stromanbietern der Nutzer definiert. In einem realen System kann entweder der Aggregator selber als Stromanbieter auftreten oder mit anderen Stromanbietern kooperieren (Konzept von Jedlix), um von den Kosteneinsparungen durch eine Ausrichtung der Ladevorgänge am Spotmarktpreis zu profitieren. Durch das Vorliegen eines iMSys kann die Ladeenergie BK-wirksam viertelstündig abgerechnet werden, sodass anders als in der Bilanzierung von SLPs, ein stromwirtschaftlicher Vorteile durch die Verschiebung Strombezügen entsteht (vgl. Abschnitt 2.1.1.2). Die Abschnitte 3.3.4 und 3.3.5 beschreiben die Modalitäten der Stromverträge und die Eigenschaften der privaten PV-Anlagen.

Der Aggregator steuert die Ladevorgänge über die Kommunikationsschnittstelle der OCUs der Fahrzeuge (siehe Abschnitt 2.2.2.1). Er ruft auf diesem Wege das aktuelle SoC ab, erfährt, ob das Fahrzeug gerade mit einer LE verbunden ist und übermittelt die Ladesteuerungsbefehle. Es wird davon ausgegangen, dass die Nutzer dem Aggregator Angaben zu den geplanten Fahrten und Ladeverfügbarkeiten für die nächsten 48 h zur Verfügung stellen. Um leere Batterien während längerer Fahrten zu verhindern, laden die Nutzer auch an öffentlichen Ladepunkten. Durch diese Stopps verschieben sich geplante Fahrten und Ladeverfügbarkeiten. Über diese Verschiebungen hat der Aggregator im Vorhinein keine Kenntnis. Er verfügt damit nicht über perfektes Wissen zum zukünftigen Zustand seiner Flotte. Zusätzlich zum zukünftigen Nutzungsverhalten erhält der Aggregator Informationen zum Stromvertrag, den Fahrzeug- und den LE-Eigenschaften. In einem realisierten System könnten die Nutzer diese Informationen per mobiler App, Web-App oder Human-Machine-Interface der Fahrzeuge übermitteln. Abschnitt 3.3.6 beschreibt das Wissen des Aggregators detailliert.

3.1.1. Interaktion mit dem Strommarkt

Der Aggregator bindet, ebenso wie im System von Jedlix, die Elektroautoflotte zusammen mit anderen Verbrauchern und Regelleistungserbringern in ein VPP ein (vgl. Abschnitt 2.1.3.4). Ein Teil des Ladestrombedarfs wird über die Partizipation an den Intraday-Auktionen gedeckt. Dazu meldet der Aggregator vor der GCT um 15:00 Uhr dem Betreiber des VPPs die benötigte Strommenge für jede Viertelstunde des Folgetages. Der VPP-Betreiber erwirbt die Strommenge zum MCP. Aufgrund der gemeinsamen Strombeschaffung wird angenommen, dass der Aggregator nicht an die Mindestgebotsmengen und -inkremente i. H. v. 100 kWh gebunden ist (vgl. Abschnitt 2.1.2.1). Es wird angenommen, dass Abweichungen von der beschafften Strommenge, die sich während des Tages ergeben, größtenteils innerhalb des VPPs oder durch kurzfristigen Intraday-Handel ausgeglichen werden können, sodass Kosten oder Einnahmen durch den Bezug oder Verkauf von Ausgleichsenergie vernachlässigt werden (vgl. Abschnitt 2.1.1.1).

3.1.2. Interaktion mit dem Regelleistungsmarkt

Der Aggregator beteiligt sich innerhalb des VPPs an Angeboten für negative SRL. Dazu meldet er dem VPP-Betreiber vor der GCT um 8:00 Uhr für jede vierstündige Zeitscheibe des Folgetages die Leistungshöhe, die er durch die Elektroautoflotte am Regelleistungsmarkt anbieten möchte. Die Festlegung des Angebotspreises wird in Abschnitt 3.5 erklärt. Die Zusammensetzung eines Pools darf alle 15 min geändert werden. Es ist daher denkbar, dass das Betriebskonzept des VPPs vorsieht, dass die Regelgruppen des VPPs nur für einen Teil einer Zeitscheibe für die SRL-Erbringung zur Verfügung stehen, sodass sich dennoch über alle Regelgruppen hinweg ein konstantes Angebot pro Zeitscheibe ergibt. Zunächst wird angenommen, dass der Aggregator verpflichtet ist, über eine volle vierstündige Zeitscheibe eine konstante Leistung vorzuhalten. In Unterkapitel 4.6.4 werden die Auswirkungen kürzerer Zeitscheiben auf die Entscheidungen des Aggregators untersucht. Für die am Regelleistungsmarkt erfolgreichen Angebote ist der Aggregator am Folgetag verpflichtet, negative SRL in der vermarkteten Höhe vorzuhalten und auf Anforderung der ÜNBs bereitzustellen. Er ist zwingend an die Einhaltung seiner gemeldeten Leistungshöhe gebunden.

3.1.3. Einbindung der privaten Photovoltaikanlagen

Gemäß der Umfrageergebnisse in [69, S. 10] besaßen im Jahr 2015 45 % aller Elektroautofahrer in Deutschland ebenfalls eine PV-Anlage. [70] bezifferte den Wert für 2016 auf 39 %. Die Anzahl neuer Elektroautos wird in den kommenden Jahren die Zuwächse an PV-Anlagen überschreiten, sodass davon ausgegangen werden kann, dass die Quote sinkt. Aufgrund der ökonomischen Vorteile eines gesteigerten Eigenverbrauchs (vgl. Abschnitt 2.1.4), ist Smart Charging für Besitzer einer PV-Anlage besonders lohnenswert, sodass erwartet werden kann, dass Besitzer einer PV-Anlage häufiger an Smart-Charging-Services interessiert sind. In dieser Arbeit wird daher angenommen, dass 50 % der Nutzer ihr BEV mit dem Strom einer privaten PV-Anlage laden können.

Für die Modellierung der PV-Anlagen werden die Daten realer Anlagen zugrunde gelegt (eine Beschreibung des Datensatzes erfolgt in Abschnitt 3.3.5). Die Höhe der Einspeisevergütung einer Anlage ist von ihrem Inbetriebnahmedatum abhängig und folgt den in Abbildung 2.5 gezeigten

realen Fördersätzen. Da bei zunehmender Eigenverbrauchsquote die Attraktivität der Kleinunternehmerregelung steigt, wird angenommen, dass alle Nutzer mit PV-Anlage diese Möglichkeit in Anspruch nehmen, sodass eine Zahlung der Umsatzsteuer entfällt. Alle betrachteten Anlagen weisen Peakleistungen kleiner als 15 kW auf und sind folglich nicht zur Zahlung der EEG-Umlage verpflichtet.

3.1.4. Einbindung in das netzdienliche Laden

Aktuell sind nur etwa 1 % aller LEs als steuerbare Verbrauchseinrichtung angemeldet (vgl. Abschnitt 2.1.5.1). Im Basisszenario wird daher davon ausgegangen, dass 1 % aller Nutzer am netzdienlichen Laden partizipieren. Um die Teilnahme am netzdienlichen Laden innerhalb von Smart-Charging-Systemen genauer untersuchen zu können, melden im Smart-Charging-Szenario 35 % der Nutzer ihre LE als steuerbare Verbrauchseinrichtung an, wobei keiner der Teilnehmenden eine PV-Anlage besitzt. Durch die Verwendung der Kaskadenschaltung nach Abbildung 2.6 ist für Nutzer mit PV-Anlagen das netzdienliche Laden mit Eigenstromverbrauch an der privaten LE zwar grundsätzlich möglich. Die Ergebnisse der Simulation zeigen jedoch, dass für fast alle Nutzer mit PV-Anlage die Wahrnehmung des § 14a EnWG unter ökonomischen Gesichtspunkten nicht lohnenswert ist, für die anderen Nutzer hingegen schon. Dieser Umstand wird auf Basis der Simulationsergebnisse in Abschnitt 4.6.3 untersucht.

3.2. Optimierungskonzept

Abbildung 3.2 zeigt den Prozess, mit dem die Ladevorgänge der Nutzer optimiert werden. Der Optimierungsansatz umfasst zwei Ebenen: eine für die vorausplanende Berechnung der optimalen Ladezeiträume und -leistungen und eine für das operative Management der aktuellen Ladevorgänge. Die Optimierung erfolgt auf der vorausplanenden Ebene und wird durch Algorithmus 1 vorgenommen. Er wird alle vier Stunden, jeweils kurz vor dem Beginn einer Regelleistungszeitscheibe, ausgeführt. Auf der operativen Ebene allokiert Algorithmus 2 die von den ÜNBs angeforderte Regelleistung auf die Fahrzeuge der Flotte. Erbringer von SRL müssen nach 30 s beginnen den vorgegebenen Sollwert anzufahren (vgl. Abschnitt 2.1.3.1). In einem realen System müsste Algorithmus 2 daher in Intervallen ausgeführt werden, deren Dauer unter 30 s liegt. Da die verbundnetzweiten Leistungsabrufe der ÜNBs, auf deren Basis in dieser Arbeit die angeforderte Regelleistung durch die ÜNBs an den Aggregator ermittelt wird, ohnehin nur in Viertelstundenauflösung veröffentlicht wird, wird in den Simulationen Algorithmus 2 alle 15 min ausgeführt.

Es gibt drei bilanzielle Quellen, über die ein Fahrzeug Strom erhalten kann und die die Kosten eines Ladevorgangs beeinflussen: Aus einem Stromprodukt, das der Betreiber des VPPs über den Intraday-Auktionenhandel an der EPEX Spot erworben hat, per negativer Regelarbeit oder, sofern vorhanden, von seiner PV-Anlage. Der Vorausalgorithmus berechnet um kurz vor 8:00 Uhr des Tages d auf Basis von Prognosen für den Spotmarkt-Strompreis und die PV-Erzeugungsleistungen, den Regelleistungs- und den Regelarbeitspreisen des vergangenen Tages, sowie den geplanten Ladeverfügbarkeiten und Fahrten der Nutzer für die nächsten 48 h die ökonomisch optimalen Ladezeiträume und -leistungen, aufgeteilt auf die drei Strombezugsmöglichkeiten.

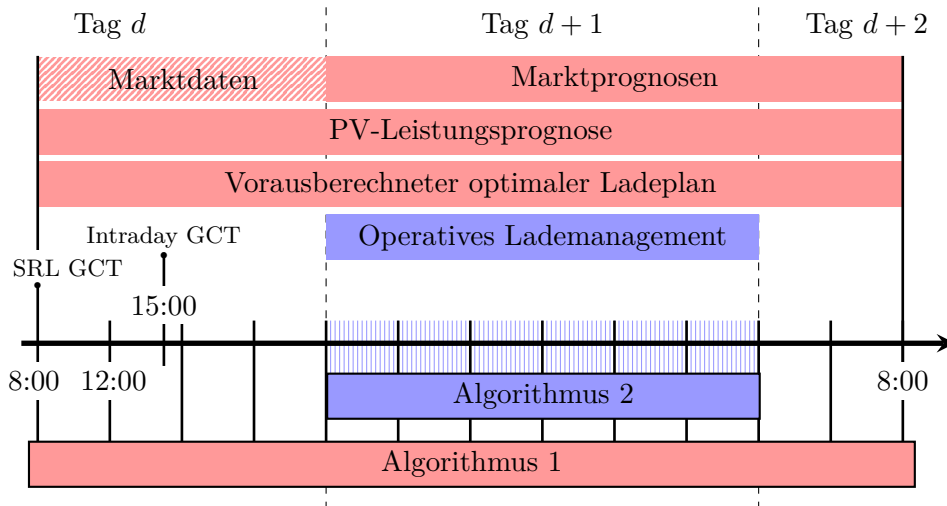


Abbildung 3.2.: Prozeduraler Ablauf der Ladevorgangsoptimierung. Prozessschritte der vorausplanenden Ebene sind in rot, der operativen in blau dargestellt.

Auf der Grundlage der Optimierung um 8:00 Uhr übermittelt der Aggregator dem VPP-Betreiber die Höhe der vermarktbareren SRL und einen Bepreisungsvorschlag für die anstehenden SRL-Auktionen. In die nächsten Optimierungen ab 12:00 Uhr fließen die Resultate der Auktionen ein. In ihnen sind die Ladeleistungen für den Strombezug über negative SRL für die Tage d und $d+1$ fixiert, anders als die geplanten Bezüge für den Tag $d+2$, die noch bis zur Optimierung um 8:00 Uhr von Tag $d+1$ angepasst werden können. Dabei wird, vergleichbar mit dem Vorgehen von Bessa und Matos [56] (vgl. Abschnitt 2.5.1), zunächst davon ausgegangen, dass die erfolgreich vermarktete Regelleistung vollständig in Form von Regelarbeit abgerufen wird. Auf Basis der Optimierung um kurz vor 12:00 Uhr übermittelt der Aggregator dem VPP-Betreiber die benötigten Strommengen in Viertelstundenaufösung zum Erwerb bei den Intraday-Auktionen. Die Optimierungen ab 12:00 Uhr betrachten ebenfalls den Zeitraum bis 8:00 Uhr des Tages $d+2$, sodass sich der Optimierungszeitraum mit jeder Optimierung um jeweils 4 h verkürzt. Erst um 8:00 Uhr des Tages $d+1$ wird der Zeitraum wieder auf die folgenden 48 h ausgedehnt. Zur Lösung der Optimierungsprobleme verwendet Algorithmus 1 lineare Programmierung. Abschnitt 3.6.1 beschreibt das zugehörige LP.

Bei der Planung des Regelleistungsangebots findet bereits eine Aufteilung der angebotenen Leistung auf die Flottenfahrzeuge statt. Die im Voraus von den Nutzern übermittelten Fahr- und Ladeverfügbarkeitspläne weisen Abweichungen von der Realität durch ungeplante Ladevorgänge an öffentlichen Ladepunkten auf. Dadurch kann es vorkommen, dass Fahrzeuge, die für einen bestimmten Zeitpunkt zur Erbringung von SRL eingeplant waren, sich noch auf einer Fahrt befinden und nicht zum Laden verfügbar sind. Um dennoch die Bereitstellung der angeforderten Regelleistung sicherstellen zu können, wird die finale Allokation der Regelleistungsabrufe auf die Flotte durch Algorithmus 2 anhand der realen Fahrzeugzustände vorgenommen. Eine detaillierte Ablaufbeschreibung für Algorithmus 2 nimmt Abschnitt 3.6.2 vor.

Zur Modellierung, Simulation und Optimierung des Systems werden verschiedene Datensätze aus unterschiedlichen Quellen verwendet. Abbildung 3.3 zeigt, wie die Datensätze für die Optimierung durch Algorithmus 1 miteinander verknüpft werden.

3. Entwicklung eines Systems zur ökonomischen Ladevorgangsoptimierung

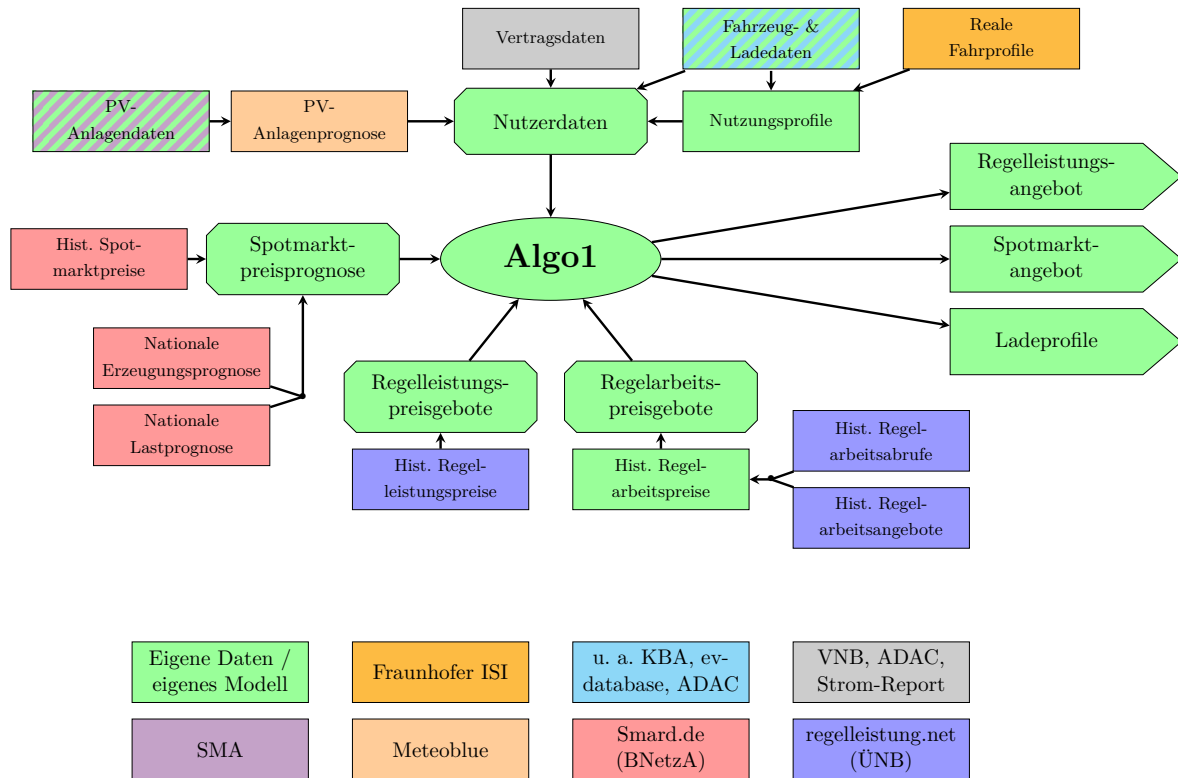


Abbildung 3.3.: Verknüpfungslogik der verwendeten Datensätze, die der Voraussplanungsalgorithmus nutzt, um die optimalen Ladezeiten und -leistungen für die nächsten 48 Stunden zu berechnen. Ein schraffiertes Farbmuster zeigt an, dass der Datensatz externe Daten inkludiert und durch eigene Annahmen ergänzt wurde (Fahrzeug- und Ladedaten) bzw. erst im Rahmen dieser Arbeit zu einem verwertbaren Datensatz wurde (PV-Anlagendaten).

3.3. Modellierung der Nutzer

Das entwickelte Optimierungssystem wurde in mehreren Simulationen anhand einer modellierten Flotte aus BEV-Fahrern getestet. Diese Arbeit greift den *divided approach* von Bessa und Matos auf, der gemäß der Auswertung in [54] im Vergleich zu einer aggregierten Abbildung bessere Ergebnisse erzielt. Jeder Nutzer wird in der verwendeten Datenstruktur einzeln abgebildet. Ein Nutzer muss nicht zwingend eine Person repräsentieren. Vielmehr korrespondiert ein Nutzer mit einem BEV, das auch von mehreren Personen genutzt werden kann. Jeder Nutzer besitzt ein Set aus unterschiedlichen Eigenschaften. Es umfasst ein Nutzungsprofil sowie Informationen zum Fahrzeug, privaten Ladepunkt, Stromvertrag, Ladevertrag für öffentliche Ladepunkte und zu einer eventuell vorhandenen PV-Anlage. Die folgenden Abschnitte beschreiben wie mithilfe verschiedener Rohdaten die Nutzer des Systems modelliert wurden.

3.3.1. Nutzungsprofile

Die Nutzungsprofile bestehen aus den getätigten Fahrten und Ladevorgängen der Fahrzeuge. Für die Fahrten wurde eine reale Datengrundlage verwendet. Die Ladevorgänge wurden synthetisch generiert.

3.3.1.1. Reale Fahrprofile

Die Fahrprofile basieren auf den Fahrtaufzeichnungen der REM-2030-Fahrprofile-Datenbank des Fraunhofer ISI [71]. In der Studie wurden 630 gewerblich gehaltene Fahrzeuge ab Juni 2011 über einen Zeitraum von im Mittel drei Wochen mit einem GPS- oder Mobilfunksender ausgestattet. Über den Standortverlauf wurden mithilfe von Google Maps Fahrtenbücher generiert. Diese umfassen den Start- und Endzeitpunkt einer Fahrt, die zurückgelegte Strecke sowie die Distanz zum Unternehmenssitz am Ende einer Fahrt. Außerdem wurden weitere Informationen, beispielsweise zur Fahrzeuggröße oder dem Wirtschaftszweig des Halterunternehmens erfasst. Es handelt sich entweder um rein betrieblich oder als Dienstwagen auch für private Fahrten genutzte Fahrzeuge.

Für diese Arbeit wurden die aufgezeichneten Daten in Kombination mit den im folgenden Abschnitt beschriebenen Fahrzeug- und Ladedaten in Nutzungsprofile von BEVs umgewandelt. Um möglichst gut das Fahrverhalten privater Nutzer abzubilden, wurden ausschließlich die Fahrprofile der Dienstwagenfahrer berücksichtigt, deren Fahrzeuge auch für private Fahrten genutzt wurden. Außerdem wurden Fahrprofile herausgefiltert, deren Erfassungszeiträume kleiner als 14 Tage sind. Für jedes Fahrzeug wurde anhand der aufgezeichneten Distanzen zwischen Parkort und Firmenstandort ein Hauptparkort definiert. Der Hauptparkort ist der Ort, an dem das Fahrzeug über den aufgezeichneten Zeitraum die meiste Zeit geparkt hat. Für die Modellierung wurde angenommen, dass an diesem Ort ein privater AC-Ladepunkt verfügbar ist. Autos, die weniger als 10/24 des aufgezeichneten Zeitraums an ihrem Hauptparkort parken, wurden nicht weiter betrachtet. Es verbleiben 88 individuelle Fahrprofile.

Um einen einjährigen Simulationszeitraum zu erhalten, wurden die wenige Wochen umfassenden Erfassungszeiträume auf die Zeit vom 01.09.2019 bis zum 31.08.2020 abgebildet. Dazu wurden Fahrprofile durch die Wiederholung der aufgezeichneten Fahrten zeitlich ausgedehnt. Die Wiederholungen sind zufällig, aber wochentagsgetreu. Sie wurden mit einem zusätzlichen Rauschen hinsichtlich der Abfahrts- und Ankunftszeit sowie der Streckendistanz versehen. In den Simulationen wurden mehrere tsd. verschiedene Nutzer betrachtet. Da weniger Nutzungsprofile als Nutzer zur Verfügung stehen, wurden Nutzungsprofile mehrfach verwendet. Nutzer mit dem gleichen Nutzungsprofil unterscheiden sich jedoch in einer Vielzahl ihrer anderen Eigenschaften.

3.3.2. Fahrzeug- und Ladedaten

Die generierten Fahrprofile wurden mit verschiedenen BEV-Fahrzeugdaten kombiniert, um realistische Fahr- und Ladedaten zu generieren. Tabelle 3.1 fasst die wichtigsten Fahrzeugparameter der Flotte zusammen. Jedem Fahrzeug aus der REM-2030-Fahrprofile-Datenbank wurde ein reales BEV-Modell der gleichen Größenklasse zugewiesen. Verwendet wurden die Fahrzeugdaten der acht BEVs mit den meisten Neuzulassungen in Deutschland im Jahr 2019. Dabei entspricht der Flottenanteil eines Fahrzeugmodells seinem Marktanteil unter den ausgewählten Modellen. Abweichend von der Darstellung in Tabelle 3.1 wurden auch Modellvarianten berücksichtigt (z. B. Audi e-tron 50 quattro und Audi e-tron 55 Sportback quattro). Jedes Fahrzeug besitzt vier Verbrauchswerte, unterschieden nach innerstädtischen Fahrten und Autobahnfahrten sowie kalten und warmen Temperaturen. Der angegebene kombinierte Verbrauch in der Darstellung von Tabelle 3.1 ist der arithmetische Mittelwert der vier Werte.

Tabelle 3.1.: Verwendete Fahrzeugdaten zur Generierung eines realistischen Flottenverhaltens. Der Flottenanteil der Fahrzeuge basiert auf den Marktanteilen der Fahrzeuge an den BEV-Neuzulassungen in Deutschland im Jahr 2019 [72]. Die Angaben zu den Nettobatteriegrößen, den Ladeleistungen und den Verbräuchen stammen von der EV Database [73]. Die Ladeeffizienz basiert auf Messungen des ADACs [74]. Zwei Werte pro Spalte repräsentieren Unterschiede pro Modellvariante.

Modell	Flotten- anteil in %	Fahrzeug- größe	Batterie- größe in kWh		Ladeleistung			Ladeeffizienz in %	Kombi. Verbrauch in kWh/100 km
					AC in kW	DC in kW			
Renault Zoe	19,1	klein	52		22	46		80,9	17,5
BMW i3	18,4	mittel	37,9		11	49		77,7	17,1
Tesla Model 3	18,2	mittel	47,5	72,5	11	170	250	81,0	16,8
VW e-Golf	13,9	mittel	32		7,2	40		91,6	17,8
Smart Fortwo EQ	10,7	klein	16,7		4,6	-		93,1	16,6
Audi e-tron	7,2	groß	64,7	86,5	11	125	155	88,7	23,9
Hyundai Kona	7,1	groß	39,2	64	11	50	77	86,6	16,5
Nissan Leaf	5,3	mittel	36,0	56	6,6	46	100	79,4	17,6

Die maximale Ladeleistung der privaten Ladepunkte der Nutzer variiert zwischen 2,3 kW und 22 kW, wobei die Ladeleistung der Wallbox die des Fahrzeugmodells nicht überschreitet und Fahrzeuge mit höheren AC-Ladeleistungen häufiger ebenso leistungsstarke Ladepunkte besitzen. Tabelle 3.2 zeigt die relativen Häufigkeiten der Ladeleistungen der privaten LEs der Nutzer.

Tabelle 3.2.: Verteilung der maximalen Ladeleistungen der privaten Ladepunkte. Angenommen wurden die üblichen Ladeleistungsstufen für das Laden an Schuko- und CEE-Steckdosen sowie an ein- bis dreiphasigen Wallboxen mit 16 A pro Phase und 32 A pro Phase bei 22 kW. Die Verteilung beruht auf eigenen Annahmen.

Ladeleistung	2,3 kW	3,7 kW	7,3 kW	11 kW	22 kW
Flottenanteil	24,0 %	21,1 %	17,2 %	34,0 %	3,8 %

3.3.3. Generierung der Nutzungsprofile

Aus den realen Fahrprofilen sowie den Fahrzeug- und Ladedaten wurden simulierte Nutzungsprofile generiert. Sie bestehen aus den Fahrten und Ladevorgängen der Fahrzeuge sowie dem SoC. Jedes Fahrzeug beginnt zum Start der Simulation am 01.09.2019 mit einem zufällig gewählten SoC. Aus den zurückgelegten Strecken der realen Fahrprofile werden mithilfe der angelegten Verbrauchswerte die Energieentnahmen aus den Fahrzeugbatterien berechnet. Außerdem werden die Energiezufuhren aus den Ladevorgängen erfasst. Ein Fahrzeug kann entweder an seinem privaten oder an einem öffentlichen Ladepunkt geladen werden.

Wird ein Fahrzeug an seinem Hauptparkort geparkt, trifft im Basisszenario der Nutzer eine Entscheidung, ob er das Fahrzeug mit dem Ladepunkt verbindet oder nicht. Die Entscheidung wird mit einer Grenzwertlogik modelliert. Je niedriger das SoC, je länger die Dauer bis zur nächsten Fahrt, je mehr Energiebedarf am nächsten Tag und je höher die individuelle Präferenz frühzeitig zu laden, desto eher wird der Grenzwert überschritten, ab dem der Nutzer sein Fahrzeug mit

dem Ladepunkt verbindet. Der Grenzwert und die statistische Verteilung der Ladepräferenz wurden so gewählt, dass das Ladeverhalten der Nutzer dem realen Ladeverhalten von BEV-Fahrern möglichst stark ähnelt. Ein Vergleich mit realen Lademustern wird in Abschnitt 4.3 vorgenommen.

Für das Basisszenario wird angenommen, dass mit dem Einstecken an der Wallbox der Ladevorgang beginnt und das Fahrzeug mit maximaler Ladeleistung aufgeladen wird, bis entweder die Batterie vollständig geladen ist oder die nächste Fahrt beginnt. Im Smart-Charging-Szenario schlägt der Aggregator vor, wann der Nutzer sein Fahrzeug mit der LE verbinden sollte. Es wird angenommen, dass die Nutzer diesen Vorschlag befolgen. Der Ladevorgang startet erst, wenn das Fahrzeug vom Aggregator einen Ladebefehl erhält. Bei der Berechnung der aufgenommenen Energie werden Ladeverluste gemäß Tabelle 3.1 berücksichtigt.

Unterschreitet das SoC während einer Fahrt einen nutzerindividuellen Grenzwert, entscheidet sich der Fahrer in beiden Szenarien zum Laden an einem öffentlichen Ladepunkt. Befindet sich der Fahrer auf einer längeren Fahrt, so wird angenommen, dass die Wahrscheinlichkeit höher ist, dass er eine Schnellladesäule z. B. an einer Autobahnraststätte in Anspruch nimmt. Auf kurzen Strecken werden hingegen eher öffentliche Normladestationen wahrgenommen, sodass auch typische Ladevorgänge an Supermärkten, am Straßenrand oder anderen öffentlichen Parkplätzen repräsentiert werden. Verfügt das Fahrzeug über genügend Energie, um die Strecke bis zum nächsten Halt am privaten Ladepunkt zurückzulegen, wird die Fahrt fortgesetzt. Tabelle 3.3 zeigt die Verteilung der Ladevorgänge an den öffentlichen Ladepunkten.

Tabelle 3.3.: Verteilung der Ladevorgänge an öffentlichen Ladepunkten nach Ladeleistung. Ladesäulen mit 11 kW und 22 kW werden als AC-Ladepunkte betrachtet, höhere Leistungen als DC-Ladepunkte. Die Verteilung beruht auf eigenen Annahmen.

Ladeleistung	AC		DC			
	11 kW	22 kW	50 kW	100 kW	150 kW	250 kW
Anteil an Ladevorgängen	6,9 %	25,4 %	35,5 %	15,7 %	10,1 %	6,5 %

3.3.4. Vertragsdaten

Jeder Nutzer besitzt einen eigenen Stromvertrag und einen Vertrag mit einem e-Mobility Service Provider für die Nutzung öffentlicher Ladepunkte. Der Stromvertrag legt den zu zahlenden Strompreis für das Laden am privaten Ladepunkt fest. Im Basisszenario bezahlen alle Nutzer einen statischen Preis, der im Mittel 31,81 ct/kWh beträgt und auf dem durchschnittlichen deutschen Strompreis für Privatkunden im Jahr 2020 basiert [21]. Im Smart-Charging-Szenario berechnet sich der Preis aus den statischen externen Strompreisbestandteilen (vgl. Abschnitt 2.1.2.2) und einem dynamischen Strombeschaffungsanteil, der sich aus den Preisen am Intraday-Markt berechnet. Im mengenungewichteten zeitlichen Mittel liegt auch hier der Strompreis bei 31,81 ct/kWh. Preisunterschiede ergeben sich lediglich dadurch, dass im gesteuerten Szenario bevorzugt zu Zeiten geladen wird, zu denen der dynamische Strombeschaffungsanteil gering ausfällt.

Für Nutzer, die am netzdienlichen Laden teilnehmen, regelt der Stromvertrag die zeitlichen Einschränkungen des Ladeverhaltens und die finanziellen Vorteile. Die verwendeten Daten stammen von drei VNBs: der Westnetz GmbH, der Netze BW GmbH und der E.DIS AG. Tabelle 3.4 fasst die verwendeten Vertragsmodalitäten zum netzdienlichen Laden zusammen.

Tabelle 3.4.: Verwendete Vertragsmodalitäten für Nutzer, deren private Ladepunkte als steuerbare Verbrauchseinrichtungen angemeldet sind. Die Daten basieren auf den veröffentlichten Angaben der VNBs [37], [75]–[78]. Die gezeigten NNE sind Nettowerte (exklusive Umsatzsteuer). Netze BW reduziert in dem angegebenen Zeitraum lediglich den Ladestrom auf 8 A pro Phase auf.

	Westnetz1	Westnetz2	Westnetz3	Netze BW	E.DIS
Arbeitspreis Standard in ct/kWh	5,26	5,26	5,26	8,53	7,51
NNE Arbeitspreis § 14a EnWG in ct/kWh	1,50	1,50	1,50	4,48	2,44
Grundpreis § 14a EnWG in €/a	gestaffelt	gestaffelt	gestaffelt	20,00	100,00
Einmaliger Bonus §14 EnWG in €	0,00	0,00	0,00	200,00	0,00
Gespernte Ladezeiträume	07:30 - 15:45	07:45 - 16:00	08:00 - 16:15	19:00 - 23:00	10:45 - 12:15
	16:30 - 19:30	16:45 - 19:45	17:00 - 20:00		17:15 - 18:45

Westnetz lässt seinen Kunden die Wahl zwischen drei Optionen mit jeweils zwei Zeiträumen, in denen der private Ladepunkt blockiert wird. Die anderen beiden betrachteten VNBs geben die Zeiträume fest vor. Während Kunden im E.DIS-Netz 5,07 ct/kWh gegenüber einem normalen Stromvertrag sparen können, sind es bei Netze BW lediglich 3,20 ct/kWh. Der § 31 Abs. 1 des MsbGs sieht 100 €/a als Obergrenze für den Messstellenbetrieb des zusätzlich notwendigen iMSys vor (vgl. Abschnitt 2.1.5.1). Westnetz orientiert sich bei den Betriebskosten für das iMSys an den gestaffelten Obergrenzen je nach Jahresstromverbrauch gemäß § 31 Abs. 3 MsbG (vgl. Abschnitt 2.1.1.3). E.DIS verwendet die Obergrenze von 100 €/a. Netze BW erhebt 20 €/a und zahlt seinen Kunden 200 € als einmaligen Bonus für die Anmeldung der LE als steuerbare Verbrauchseinrichtung. Ebenso verschieden fallen die gesperrten Ladezeiträume aus. Während Westnetz das Laden vom Vormittag bis in den Nachmittag sowie in den frühen Abendstunden vollständig blockiert, begrenzt Netze BW lediglich den Ladestrom pro Phase auf 8 A in den Abendstunden.

3.3.5. Photovoltaikanlagendaten und -prognosen

Die simulierten PV-Anlagen werden durch die Anlagenparameter und gemessenen Erzeugungsleistungen realer Anlagen repräsentiert. Die Grundlage bilden die frei zugänglichen Daten aus dem Sunny Portal der SMA Solar Technology AG [79]. PV-Anlagenbesitzer mit internetfähigen Wechselrichtern können über diese Plattform die Erzeugungsleistung ihrer Anlage verfolgen und die Anlagendaten öffentlich teilen. Zur Verwendung der Daten wurde in Python unter Verwendung der Selenium-Bibliothek ein Screen Scraper entwickelt, der automatisiert die Anlagenparameter und historischen Erzeugungsleistungen der Anlagen extrahiert. Die gesammelten Daten umfassen den Standort, den Azimut, die Elevation und die Peakleistung der Anlagen sowie die historische Erzeugungsleistung über einen mehrjährigen Zeitraum. Der generierte Datensatz umfasst Anlagen aus ganz Deutschland mit einer Peakleistung zwischen 3 kW und 15 kW.

In den Simulationen wurden 20 verschiedene Anlagen betrachtet. Für sie stehen historische Eintagesprognosen der Erzeugungsleistungen zur Verfügung, die auf Basis der Anlagenparameter durch

das „History Photovoltaic“ Modell der meteoblue AG [80] berechnet wurden. Da die Anzahl der verfügbaren individuellen PV-Anlagen die Anzahl der modellierten Nutzer übersteigt, werden auch die PV-Anlagen mehrmals von unterschiedlichen Nutzern verwendet. In das Prognosesystem hineingegeben wurden pro Anlage der geografische Standort, der Azimut, die Elevation und die Peakleistung. Die wichtigsten Daten aller verwendeten PV-Anlagen zeigt Tabelle A.1 im Anhang.

Das Prognosesystem basiert auf verschiedenen Wettermodellen und legt für die Vorhersage Wetter- und Sonneneinstrahlungsprognosen zugrunde. Die berechneten Werte liegen in einstündigen Zeitschritten über den vollständigen Simulationszeitraum vor. Da in den Simulationen viertelstündige Zeitschritte verwendet wurden, wurden die Prognosedaten interpoliert. Die besten Prognosequalitäten zeigten sich nicht mit verschiedenen Spline-Interpolationen, sondern mit einer simplen linearen Interpolation, wenngleich die Differenzen zwischen den Verfahren gering waren.

3.3.6. Wissen des Aggregators über Nutzerdaten

Die Nutzer geben dem Aggregator nur einen Teil ihrer Eigenschaften bekannt. Tabelle 3.5 fasst das Wissen des Aggregators über die Nutzerdaten zusammen. Tritt ein neuer Nutzer der gesteuerten Flotte bei, übermittelt er dem Aggregator einmalig sich nicht oder nur selten ändernde (statische) Informationen über sich. Er nennt sein Fahrzeugmodell, sodass dem Aggregator die Batteriegröße, AC-Ladeleistung und Ladeeffizienz bekannt sind. Ebenso gibt er das Modell seiner LE, die Zusammensetzung seiner Strompreisbestandteile, die Parameter seiner PV-Anlage, sofern er eine besitzt, und, falls er daran partizipiert, die Modalitäten des netzdienlichen Ladens an. Es wird angenommen, dass die Nutzer jeweils bis 8:00 Uhr eines Tages eine aktualisierte Planung über die nächsten 48 h für die zurückgelegten Strecken und die Zeiträume, in denen sie voraussichtlich an ihrem privaten Ladepunkt parken werden, dem Aggregator zur Verfügung stellen.

Tabelle 3.5.: Nutzerdaten, die der Aggregator verwendet und deren Zustand ihm entweder zu jeder Zeit (statisch), zum Beginn einer Prognose oder für den aktuellen 48 h-Zeitraum bekannt sind.

Statisch	Fahrzeugeigenschaften Privater Ladepunkt PV-Anlage Vertragsdaten	Batteriegröße, AC-Ladeleistung, Ladeeffizienz AC-Ladeleistung Azimut, Elevation, Standort, Peakleistung, EEG-Vergütung Strompreisbestandteile, gesperrte Ladezeiträume
Jederzeit	Nutzungsprofil PV-Anlage	SoC, Fahrzeugstatus Erzeugungsleistung
Optimierungszeitraum	Geplantes Nutzungsprofil PV-Anlage	Geplante Fahrten und Parkzeiten am privaten Ladepunkt Erzeugungsprognose

Per Schnittstelle zur OCU des Fahrzeugs hat der Aggregator zu jedem Zeitpunkt Kenntnis über das SoC und den Status des Fahrzeugs (Fahren, Parken, Laden). Die modellierten PV-Anlagen seien, ebenso wie ihre realen Entsprechungen, mit einem internetfähigen Wechselrichter ausgestattet, sodass der Aggregator über eine Schnittstelle die aktuelle Erzeugungsleistung auslesen kann.

3.4. Modellierung der Spotmarktinteraktion und -preisprognose

Der VPP-Betreiber beschafft den vom Aggregator angeforderten Strombedarf über die Intraday-Auktionen der EPEX Spot. Es wird eine Price-Taker-Annahme gesetzt. Die Flotte beeinflusst in der Simulation daher nicht die Marktpreise. Zur Generierung einer Spotmarktprognose werden zum einen historische Preisdaten verwendet, zum anderen gehen Prognosen zur Erzeugungsleistung und der Netzlast in Deutschland als weitere Prädiktoren ein. Die folgenden Abschnitte beschreiben die verwendeten Datensätze und das Prognoseverfahren.

3.4.1. Rohdaten aus der Stromwirtschaft

Es werden die historischen Preise der Day-Ahead-Auktionen der EPEX Spot in der Marktregion Deutschland/Luxemburg verwendet. Die Preisdaten können von der Informationsplattform der Bundesnetzagentur über den deutschen Strommarkt smard.de [81] für einen beliebigen Zeitraum abgerufen werden. Sie stimmen mit den tagesaktuellen Angaben auf der Internetseite der EPEX [82] überein. Die hier verwendete Abbildung der Intraday-Auktionspreise durch die Day-Ahead-Auktionspreise, die aus Gründen der Datenverfügbarkeit erfolgt, hat geringfügige Auswirkungen auf die Simulationsergebnisse. Die Differenz zwischen den Mittelwerten beider MCPs ist vernachlässigbar. Jedoch ist die Varianz der Intraday-Preise größer, sodass bei verlässlichen Prognosen durch Intraday-Preise größere Optimierungspotenziale durch Verschiebungen entstehen.

Die deutschen ÜNBs prognostizieren jeweils für den nächsten Tag die bundesweit aggregierte Erzeugungsleistung. Die Prognosen werden von den ÜNBs nur über einen Zeitraum von einem Tag veröffentlicht und lediglich die Daten von 50 Hertz sind zum Zeitpunkt der Festlegung des Regelleistungsangebots um kurz vor 8:00 Uhr regelmäßig abrufbar. Um rechtzeitig und über den vollen Zeitraum von 48 h die Ladevorgänge optimieren zu können, wird daher angenommen, die Daten stünden vollständig zum Optimierungszeitpunkt für die nächsten 48 h zur Verfügung. Vergleichbare Daten werden von kommerziellen Daten Providern rechtzeitig und über den benötigten Zeitraum von 48 h bereitgestellt.

3.4.2. Analyse des Day-Ahead-Strompreises

Der Entwicklung des Prognosemodells geht eine Datenanalyse der Spotmarktpreise voraus. Abbildung 3.4 (a) verdeutlicht, dass der Tagesverlauf des Day-Ahead-Preises einem uhrzeitabhängigen Muster folgt. Die beiden Hauptursachen für diese Uhrzeitabhängigkeit des MCPs sind die Uhrzeitabhängigkeiten des Lastgangs und der PV-Einspeisung, die Abbildung 3.4 (b) zeigt. Ein höherer Strombedarf und damit ein höheres Handelsvolumen führt dazu, dass sich die Angebots- und Nachfragekurve im Auktionshandel bei einem höheren Preis schneiden (vgl. Abbildung 2.2). Dadurch steigt der Preis in den Morgenstunden mit wachsender Netzlast und sinkt in den späten Abend- und Nachtstunden mit ihr wieder ab. Während der Mittagszeit führt ein hohes Angebot an PV-Strom zu sinkenden Preisen. Über den Simulationszeitraum lag der arithmetische Mittelwert des MCPs bei 29,28 €/MWh. Innerhalb eines Tages traten im Durchschnitt Preisdifferenzen von rund 20 €/MWh zwischen dem Höchst- und Tiefstwert auf. Die 90%-Intervallgrenzen in Abbildung 3.4 (a) zeigen die Grenzen, innerhalb der der Preis in 90 % aller Fälle lag.




Abbildung 3.4.: Verläufe des arithmetischen Mittelwerts und 90%-Intervalls des Day-Ahead-MCPs an der EPEX Spot und der deutschlandweiten Netzlast für den Simulationszeitraum. Die Daten stammen von [81].

Besonders gut verdeutlicht die Verlaufsregelmäßigkeit des MCPs seine Autokorrelationsfunktion, die Abbildung 3.5 darstellt. Neben den direkt folgenden und vorherigen Preisen gleichen sich insbesondere jene Preise, zwischen denen zeitlich etwa ein ganzzahliges Vielfaches eines Tages liegt, die also eine ähnliche Tageszeit haben. Dieses ausgeprägte autoregressive Verhalten über mehrere Tage wird sich im folgenden Prognosemodell ausgenutzt. Zudem deutet die Grafik eine Wochentagsabhängigkeit an. Der Trend der Autokorrelationsfunktion fällt zunächst mit steigendem zeitlichen Abstand und steigt nach einer Verschiebung von vier Tagen wieder an. Der Grund liegt in einem veränderten Preisverhalten für die Wochenendtage. An Samstagen und Sonntagen zeigt der Verlauf des MCPs ein etwas anderes Verhalten als an Werktagen. Im arithmetischen Mittel liegt er deutlich unter dem der Wochentage. Abbildung A.2 im Anhang zeigt den Preisverlauf im Wochentagsdurchschnitt.




Abbildung 3.5.: Autokorrelationsfunktion des Day-Ahead MCPs an der EPEX Spot für den Simulationszeitraum. Die Daten stammen von [81].

Die Preise an der Strombörse werden mittlerweile maßgeblich vom Angebot von PV- und Windenergie mitgeprägt. Die Grenzkosten, die variablen Kosten für die Erzeugung einer Energiemenge, liegen bei ihnen nahe null. Der Verkauf einer Megawattstunde lohnt sich für die Anlagenbetreiber immer, sofern die Preise positiv sind. Aus diesem Grunde beeinflusst das Angebot an Strom aus Windkraft ebenfalls den MCP, auch wenn die Windstromerzeugung kein ausgeprägtes Muster im durchschnittlichen Tagesverlauf aufweist. Im Gegensatz dazu müssen andere Erzeuger für die Generierung einer zusätzlichen Megawattstunde mehr Brennstoffkosten bezahlen. Sie besitzen höhere Grenzkosten, geben im Auktionshandel Angebote mit höheren Preisen ab, stehen in der Merit-Order weiter unten und bleiben bei niedrigen Preisen erfolglos mit ihrem Angebot. Dieses Marktverhalten wird Merit-Order-Effekt genannt.

Dieser Effekt spiegelt sich in den Korrelationen des MCPs mit den genannten Einflussgrößen wider. Tabelle 3.6 zeigt die linearen Korrelationen der deutschlandweiten geplanten Erzeugungsleistungen nach Kraftwerkstyp sowie der Lastprognose der ÜNBs mit dem MCP der Day-Ahead-Auktionen.

Tabelle 3.6.: Korrelationskoeffizienten für den Day-Ahead-MCP mit den Erzeugungs- und Lastprognosen der ÜNBs. Die Rohdaten stammen von [81].

Regressor		ρ_{DA}
	Gesamt	0,041
	Wind offshore	-0,319
Erzeugungsprognose	Wind onshore	-0,425
	Photovoltaik	-0,220
	Sonstige	0,716
Lastprognose		0,428

Hohe Erzeugungsprognosen für die fluktuierenden EE korrelieren mit niedrigen MCPs, hohe Erzeugungsprognosen für die anderen Erzeuger sowie eine große Stromnachfrage mit hohen MCPs. Der Betrag des Korrelationskoeffizienten für die PV-Prognose ist vergleichsweise niedrig, weil diese Variable in den Nachtstunden konstant null ist. Wird ausschließlich der Zeitraum zwischen 9:00 Uhr und 19:00 Uhr betrachtet, sinkt der Korrelationskoeffizient auf -0,480.

3.4.3. Spotmarktprognosemodell

Aufgrund der autoregressiven Eigenschaft sowie des Zusammenhangs mit exogenen Variablen ist die Verwendung eines ARX-Modells für die Prognose des Day-Ahead-MCPs gut geeignet. Eine wichtige Eigenschaft, die für die Verwendung eines ARX-Modells erfüllt sein muss, ist die schwache Stationarität des Regressanden (vgl. Abschnitt 2.3.1). Diese ist für den MCP offensichtlich nicht per se gegeben, da sich, wie Abbildung 3.4 zeigt, der Erwartungswert mit der Uhrzeit ändert. Mit der Einführung eines eigenen Prognosemodells für jede Stunde eines Tages wird der Einhaltung dieser Bedingung näher gekommen. Aufgrund der zusätzlichen Wochentagsabhängigkeit bräuchte es 168 Prognosemodelle, um diese Bedingung vollständig zu erfüllen. Da jedes Prognosemodell nur mit historischen Daten der jeweiligen Uhrzeit und des jeweiligen Wochentages trainiert werden könnte, würde sich die Größe des Trainingsdatensatzes stark reduzieren.

Die Spotmarktprognose wird um kurz vor 8:00 Uhr des Tages d erstellt. Die MCPs bis zum Ende des Tages d sind bekannt, sie stammen aus den Auktionen am Tag $d - 1$. Prognostiziert werden müssen die MCPs für den Zeitraum von 0:00 Uhr am Tag $d + 1$ bis 8:00 Uhr am Tag $d + 2$. Folglich werden 32 Prognosewerte ermittelt. Theoretisch könnte für die Prognose für $d + 1$ 0:00 Uhr das gleiche Modell verwendet werden wie für $d + 2$ 0:00 Uhr, da für beide Zeitpunkte (die Wochentagsabhängigkeit außen vor gelassen) ein ähnlicher Erwartungswert gilt. Die besten Ergebnisse wurden allerdings erzielt, wenn für jeden der 32 Prognoseschritte ein eigenes ARX-Modell trainiert und die Wochentagsabhängigkeit über einen gesonderten Parameter berücksichtigt wurde.

Die 32 verwendeten Prognosemodelle besitzen die Struktur

$$\hat{y}_{t+\tau} = \sum_{j=1}^{p_y-2} y_{t+1-j} \hat{\phi}_{\tau,j} + \mu_{y,\text{mod}(\tau,24)} \hat{\phi}_{\tau,p_y-1} + \mu_{y,w(t+\tau)} \hat{\phi}_{\tau,p_y} + \sum_{k=1}^K \hat{x}_{\tau,k} \hat{\beta}_{\tau,k}, \quad \text{mit } \tau \in \{1, \dots, 32\}, \quad (3.1)$$

wobei t der Zeit 23:00 Uhr am Tag d entspricht. $\hat{y}_{t+\tau}$ ist der prognostizierte MCP für den Zeitpunkt $t + \tau$. $\mu_{y,\text{mod}(\tau,24)}$ und $\mu_{y,w(t+\tau)}$ sind die Erwartungswerte des MCPs für die Uhrzeit τ und den Wochentag w des Zeitpunktes $t + \tau$. $\hat{\phi}_{\tau,j}$ entspricht den p_y geschätzten autoregressiven Modellparametern. $\hat{x}_{\tau,k}$ stellt die K von den ÜNBs prognostizierten exogenen Variablen und $\hat{\beta}_{\tau,k}$ die K Modellparameter der exogenen Variablen dar. Anders als im Ausgangsmodell in Gleichung 2.14 aus dem Theoriekapitel werden keine Vergangenheitswerte der exogenen Variablen miteinbezogen.

Zur Berechnung der Modellparameter $\hat{\Phi}$ und \hat{B} wurde die LS-Methode verwendet (vgl. Abschnitt 2.3.4). Die besten Ergebnisse wurden mit $p_y = 226$ erzielt, sodass die 224 jüngsten bekannten MCPs in die Prognose eingeflossen sind. Als exogene Variablen wurden die $K = 6$ Prognosen aus Tabelle 3.6 verwendet. Zum Vergleich wurde die Modellstruktur außerdem mithilfe von nicht-linearen autoregressiven neuronalen Netzen mit externen Eingabewerten (NARXNET) abgebildet (eine Erklärung dieses Modells bietet Abschnitt A.1.2 im Anhang), wobei hier mit $p_y = 72$ die besten Prognosewerte generiert wurden. Unterkapitel 4.1 zeigt die Auswertung der Qualität beider Prognosemethoden.

3.5. Modellierung der Regelleistungsmarktinteraktion und Preisstrategie

Der Strombezug durch negative Regelarbeit weist im Vergleich zum Stromhandel an der Strombörse große Unsicherheiten auf. Zunächst muss das Angebot des Aggregators im Regelleistungsmarkt erfolgreich sein. Ist dies der Fall, ist dem Aggregator noch immer unbekannt, wie viel negative Regelarbeit, die er zum Laden seiner Flotte nutzt, tatsächlich abgerufen werden wird. Zum einen, um diese Unsicherheit abbilden zu können und zum anderen, weil durch das Pay-as-bid-Verfahren die Preisstrategie des Bieters, anders als an der Strombörse, die Bepreisung der eigenen Produkte determiniert, wird für den Regelleistungsmarkt auf einen Preis-Taker-Ansatz verzichtet. Stattdessen werden die realen Marktmechanismen modelliert und der Aggregator als Price-Maker aufgefasst. Die folgenden Abschnitte beschreiben die dazu notwendigen Rohdaten, erklären die Umsetzung des Verfahrens zur Modellierung des Regelleistungsmarktes und erläutern die Strategie für die Festlegung des Regelleistungs- und Regelarbeitspreises.

3.5.1. Rohdaten des Regelleistungsmarkts

Die ÜNBs veröffentlichen auf ihrer Internetseite regelleistung.net [83] historische Daten des Regelleistungsmarkts. Zwei dieser Datensätze für SRL werden im Folgenden verwendet.

3.5.1.1. Anonyme Angebotsliste

Pro Zeitscheibe und getrennt nach negativer und positiver SRL veröffentlichen die ÜNBs alle Regelleistungsangebote, die über ihren Regelleistungspreis per MOL erfolgreich waren. Für jeden erfolgreichen Anbieter sind anonymisiert die abgegebenen Leistungs- und Arbeitspreise sowie die bezuschlagte Leistungshöhe einsehbar. Tabelle 3.7 gibt einen exemplarischen Eindruck zu dieser Datenquellen.

Tabelle 3.7.: Die ersten sechs und letzten beiden Einträge der anonymen Angebotsliste für den 01.03.2020 für negative SRL der ersten Zeitscheibe des Tages von 00:00 Uhr bis 04:00 Uhr für den deutschen Netzregelverbund. Die Rohdaten sind unter [83] abrufbar.

Datum	Typ	Produkt	Leistungspreis in €/MW	Arbeitspreis in €/MWh	bezuschlagte Leistung in MW
01.03.2020	SRL	NEG_00_04	0,00	350,00	5
01.03.2020	SRL	NEG_00_04	13,95	35,00	15
01.03.2020	SRL	NEG_00_04	14,80	1,00	5
01.03.2020	SRL	NEG_00_04	14,80	233,00	5
01.03.2020	SRL	NEG_00_04	14,80	117,00	5
01.03.2020	SRL	NEG_00_04	15,00	63,17	5
			⋮		
01.03.2020	SRL	NEG_00_04	84,57	122,86	5
01.03.2020	SRL	NEG_00_04	85,12	490,00	5

Dieser Datensatz genügt für eine vollständige Abbildung der Regelleistungsauktionen. Dem VPP-Betreiber, der für den Aggregator die Vermarktung der Regelleistung übernimmt, sind bei der Erstellung seines Angebots die Gebote seiner Konkurrenten unbekannt. Nachdem er seinen Leistungspreis festgelegt hat, wird mithilfe der anonymen Angebotsliste überprüft, ob sein Preis kleiner ist als der Grenzpreis. Ist dies der Fall, erhält der Aggregator sicher den gebotenen Leistungspreis multipliziert mit der bereitgestellten Leistungshöhe. Die verwendete Preisstrategie erläutert Abschnitt 3.5.4.

3.5.1.2. Abrufwerte

Die ÜNBs veröffentlichen mit einer zeitlichen Verzögerung von 15 min bis 30 min die aktuellen betrieblichen Abrufwerte für Regularbeit. Etwa zwei Monate später werden die Daten im Nachgang durch die Ergänzung der qualitätsgesicherten Werte präzisiert. Bei den Abrufwerten handelt es sich um die aggregierte Arbeit über den gesamten Netzregelverbund. Angegeben werden die summierten Energien in 15-minütiger Auflösung. Die Daten werden nach negativer und positiver Regularbeit unterteilt. Tabelle 3.8 zeigt beispielhaft die Struktur der Liste.

Tabelle 3.8.: Auszug aus der Liste der Abrufwerte für negative Sekundärregelarbeit am 01.03.2020 für den gesamten deutschen Netzregelverbund. Die Abrufwerte entsprechen der durchschnittlich benötigten Leistung innerhalb einer Viertelstunde. Die Rohdaten sind unter [83] abrufbar.

Datum	Zeit	betriebl. neg. in MW	betriebl. pos. in MW	qualitätsg. neg. in MW	qualitätsg. pos. in MW
01.03.2020	00:00 - 00:15	196,80	27,36	202,14	28,94
01.03.2020	00:15 - 00:30	126,98	1,85	130,78	2,63
01.03.2020	00:30 - 00:45	148,76	1,53	153,09	2,12
01.03.2020	00:45 - 01:00	88,92	3,00	92,11	3,88
			⋮		

3.5.2. Generierung der Regelarbeitspreise

Die tatsächlich ausgezahlten Regelarbeitspreise werden auf `regelleistung.net` nicht veröffentlicht. Sie können allerdings aus der anonymen Angebotsliste und den Abrufwerten unter Verwendung der Marktmechanismen mit guter Näherung ermittelt werden.

Die Ausgangsbasis ist die anonyme Angebotsliste. Für jedes vierstündige Produkt wird diese anhand der Arbeitspreise in ihre Merit-Order gebracht. Anschließend wird pro viertelstündigem Abrufwert aus der Reihenfolge der MOL ermittelt, welche Bieter der entsprechenden Zeitscheibe innerhalb der Viertelstunde tatsächlich ein Aktivierungssignal für die Bereitstellung von Regelarbeit erhalten haben. Dazu werden die bezuschlagten Leistungen der Anbieter solange addiert, bis der durchschnittliche viertelstündige Wert des Regelleistungsabrufs erreicht wurde. Zur Ermittlung der ausgezahlten Vergütung (bzw. Kosten bei einem gebotenen negativen Arbeitspreis) pro Bieter wird die Höhe der geleisteten Arbeit mit seinem gebotenen Arbeitspreis multipliziert. Ein vergleichbares Verfahren wurde in [84, S. 44ff.] verwendet.

3.5.3. Analyse des Regelleistungs- und Regelarbeitspreises

Um im Wettbewerb mit den anderen Bietern des Regelleistungsmarktes eine möglichst hohe Erfolgsquote im Auktionshandel zu ökonomisch günstigen Konditionen zu erhalten, muss das Preisverhalten der Wettbewerber abgeschätzt werden. Tabelle 3.7 lässt erkennen, dass sehr unterschiedliche Gebotsstrategien verfolgt werden. Einige Bieter versuchen mit günstigen Regelleistungspreisangeboten möglichst häufig den Grenzpreis zu unterschreiten. Sie verdienen Geld über die Regelmäßigkeit der Zuschläge oder den Abruf von Regelarbeit. Bei höherpreisigen Angeboten sinkt die Erfolgswahrscheinlichkeit. Durch den Pay-as-bid-Mechanismus steigt dafür die Vergütung pro Zuschlag. Der leistungsgewichtete arithmetische Mittelwert aller erfolgreichen Angebote für negative SRL lag im Simulationszeitraum bei 6,50 €/MWh. Abbildung 3.6 (a) zeigt den Preisverlauf im Tagesdurchschnitt. Der Verlauf weist ein systematisches uhrzeitabhängiges Muster auf. In der ersten und vierten Zeitscheibe eines Tages werden höhere Regelleistungspreise geboten als während des Rests des Tages.




Abbildung 3.6.: Tagesdurchschnittliche Verläufe der ausgezahlten Regelleistungs- und Regelarbeitspreise sowie der Regelleistungsabrufe. Die Preise sind leistungsgewichtete Mittelwerte. Die Rohdaten sind unter [83] abrufbar.

Hohe Regelarbeitspreisgebote zielen darauf ab, selten Regelarbeit erbringen zu müssen, dafür in diesen Fällen eine besonders hohe Vergütung zu erhalten. Diese Strategie eignet sich insbesondere für Anlagen mit hohen Grenzkosten für die Erbringung von Regelarbeit. Bei negativer Regelarbeit können Angebote mit niedrigen Preisen attraktiv sein, da der Bieter im Gegenzug Strom zum Regelarbeitspreis bilanziell gut geschrieben bekommt. Angebote mit negativen Regelarbeitspreisen sind bei negativer SRL keine Seltenheit. In diesem Fall zahlt der Regelarbeitserbringer für den Energiebezug. Solange die Kosten dafür geringer sind als die Summe aus Grenzkosten für die Regelarbeitserbringung und den alternativen Strombezug über den Großhandelsmarkt, sind auch negative Regelarbeitspreise wirtschaftlich.

Während des betrachteten Zeitraums wurden im Mittel 1,98 GW negative SRL pro Zeitscheibe von den ÜNBs ausgeschrieben. Durchschnittlich wurden aber nur 130,37 MW abgerufen. In der Folge bleiben die meisten Bieter, die über ihren Regelleistungspreis erfolgreich waren, ohne Regelleistungsabrufe. Sie sichern die Netzstabilität für den Fall einer Ausnahmesituation ab, profitieren von der Regelleistungsvergütung und erhalten in diesen Ausnahmesituationen hohe Regelarbeitspreise. Das leistungsgewichtete Mittel der Regelarbeitspreisangebote lag bei 908,99 €/MWh. Da zumeist nur Regelarbeit von Anbietern mit günstigen Preisen abgerufen wird, lag das Mittel der tatsächlich ausgezahlten Vergütungen hingegen bei -3,20 €/MWh.

Während die Regularbeitsgebotspreise einen vergleichbar systematischen Tagesverlauf nehmen wie die Regelleistungsgebotspreise, besitzen die tatsächlich ausgezahlten Regularbeitsvergütungen kein uhrzeitabhängiges Muster, wie Abbildung 3.6 (b) zeigt. Die Ursache ist in Abbildung 3.6 (c) zu sehen. Die tatsächliche Vergütung ist abhängig von der Höhe der Regelleistungsabrufe. Diese weisen kein nennenswertes Tagesverlaufsmuster auf.

Ein ausgeprägtes autoregressives Verhalten zeigen in der Folge lediglich die Regelleistungs- und Regularbeitsangebotspreise. Die tatsächlich gezahlten Regularbeitsvergütungen und die Regelleistungsabrufhöhe korrelieren über wenige Stunden hinaus kaum mit ihren Vergangenheitswerten. Abbildung A.3 im Anhang zeigt die entsprechenden Autokorrelationsfunktionen. Auch die Erzeugungsprognosen und Lastprognose eignen sich nicht als Prädiktoren für die tatsächlich gezahlten Regularbeitspreise und die Regelleistungsabrufe. Tabelle 3.9 zeigt betragsmäßig kleine Korrelationskoeffizienten zwischen den Variablen. Lediglich für die Regelleistungspreise ist ein nennenswerter linearer Zusammenhang mit der Höhe der prognostizierten Windeinspeisung zu erkennen.

Tabelle 3.9.: Korrelationskoeffizienten für den Regelleistungspreis, die tatsächlich gezahlten Regularbeitspreise und die Regelleistungsabrufe mit den Erzeugungs- und Lastprognosen der ÜNBs. Bei den Preisen wurden jeweils die leistungsgewichteten Mittelwerte verwendet. Die Prognosedaten stammen von [81] und die Rohdaten des Regelleistungsmarktes von [83].

Regressor		$\rho_{\text{SRL,Preis}}$	$\rho_{\text{SRA,Preis}}$	$\rho_{\text{SRL,Abruf}}$
	Gesamt	0,195	-0,037	0,112
	Wind offshore	0,306	0,078	0,126
Erzeugungsprognose	Wind onshore	0,470	0,087	0,113
	Photovoltaik	0,092	0,103	0,029
	Sonstige	-0,294	-0,242	0,007
Lastprognose		-0,154	-0,144	0,007

3.5.4. Preisstrategie

Die Grenzkosten für das Erbringen von negativer Regularbeit durch Smart Charging gehen gegen null. Es fallen weder höhere Batteriealterungskosten [85]–[87] noch nennenswerte variable Kosten für Kommunikations- und Regelungstechnik an. Der Aggregator und die Nutzer erhalten den Strom zum Preis der externen Strompreisbestandteile (vgl. Abschnitt 2.1.2.2) subtrahiert um die Regularbeitsvergütung, die allerdings bei negativem Angebotspreis auch einen Kostenpunkt darstellen kann. Hinzu kommt die Vergütung der vorgehaltenen Regelleistung. Da das Erbringen von negativer Sekundärregularbeit im Mittel 0,32 ct/kWh kostet (vgl. Abschnitt 3.5.3) und der Durchschnittspreis im Börsenstromhandel bei 2,93 ct/kWh (vgl. Abschnitt 3.4.2) liegt, ist es für den Aggregator ökonomisch in den meisten Fällen sinnvoll, eine Preisstrategie zu verfolgen, die zu einem möglichst hohen Bezug von Regularbeit führt.

Auch wenn die Elektroautoflotte über das VPP mit anderen Anlagen gepoolt wird, wird hier die Annahme gesetzt, dass die Preisstrategie vom Aggregator bestimmt und auf die Elektroautos

zugeschnitten wird. Eine Vorhersage der Regelleistungs- und Regelarbeitspreise auf der Basis eines ARX-Modells mithilfe der LS-Methode oder NARXNETs kann hier nicht vorgenommen werden. Der Hauptgrund ist, dass zu wenig Trainingsdaten vorliegen. Das in dieser Arbeit berücksichtigte Auktionsverfahren war zwischen dem 01.08.2019 und dem 02.11.2020 gültig. Zwischen dem Beginn der Simulation und dem Start des Auktionsverfahrens liegt nur ein Monat, mit dessen Daten ein solches Modell trainiert werden könnte. Selbst wenn das Prognosemodell mit Daten aus dem Simulationszeitraum trainiert wird, liegen die Prognosequalitäten deutlich unter denen für den Day-Ahead-MCP. Die Ursachen liegen in den schlechteren Korrelationen der exogenen Prädiktoren (vgl. Tabelle 3.9) und den zum Teil weniger ausgeprägten autoregressiven Eigenschaften (vgl. Abbildung A.3).

Stattdessen werden die Regelleistungs- und Regelarbeitspreisangebote auf der Basis der Marktpreise der vergangenen Auktion festgelegt. Der gebotene Regelleistungspreis entspricht dem leistungsgewichteten Mittel der I erfolgreichen Regelleistungspreisgebote der uhrzeitgleichen Zeitscheibe des Tages der Angebotsabgabe multipliziert mit dem Faktor $\alpha_P^{\text{SRL,Ang}}$

$$C_{t,\text{Agg},P}^{\text{SRL,Ang}} := \alpha_P^{\text{SRL,Ang}} \frac{\sum_{i=1}^I C_{t-6,i,P}^{\text{SRL,Ang}} P_{t-6,i}^{\text{SRL,Ang}}}{\sum_{i=1}^I P_{t-6,i}^{\text{SRL,Ang}}}. \quad (3.2)$$

$\alpha_P^{\text{SRL,Ang}}$ wurde experimentell bestimmt. Die besten Ergebnisse wurden mit $\alpha_P^{\text{SRL,Ang}} = 0,4$ erzielt, sodass der Aggregator, dem Ziel einer möglichst hohen Erfolgswahrscheinlichkeit folgend, permanent das mittlere Preisniveau des Vortages um 60 % unterbietet.

Für die Festsetzung des Regelarbeitspreises wird ein ähnliches Vorgehen gewählt. Grundsätzlich sind verschiedene Größen als Ausgangsbasis, wie der in Abbildung 3.6 (b) gezeigte Mittelwert der tatsächlichen Vergütungen, der kleinste Grenzpreis einer Zeitscheibe oder der kleinste Angebotspreis denkbar. Die ökonomisch besten Ergebnisse wurden erzielt, wenn der kleinste Angebotspreis der uhrzeitgleichen Zeitscheibe des Angebotstages zugrunde gelegt wurde

$$C_{t,\text{Agg},W}^{\text{SRL,Ang}} := \min \left\{ C_{t-6,i,W}^{\text{SRL,Ang}} \right\} - \alpha_W^{\text{SRL,Ang}} \left| \min \left\{ C_{t-6,i,W}^{\text{SRL,Ang}} \right\} \right|, \quad \text{mit } i \in \{1, \dots, I\}. \quad (3.3)$$

Da die Arbeitspreise auch negative Werte annehmen können, muss hier im Vergleich zu Gleichung 3.2 mit dem Betrag gerechnet werden. Es wurde experimentell $\alpha_W^{\text{SRL,Ang}} = 0,15$ festgelegt, sodass der Aggregator den kleinsten Angebotspreis des Vortages um 15 % unterbietet.

3.6. Entwickelte Algorithmen zur ökonomischen Ladevorgangsoptimierung

Dem Optimierungskonzept in Unterkapitel 3.2 folgend, wird die Ladevorgangsoptimierung in eine vorausplanende Ebene und eine operative Ebene strukturiert.

3.6.1. Vorausplanender Optimierungsalgorithmus

Algorithmus 1 optimiert alle vier Stunden den Ladevorgangsplan bis um 8:00 Uhr des Tages $d + 2$ durch die Lösung eines linearen Optimierungsproblems per Simplexalgorithmus (vgl. Abschnitt 2.4.2). Um große Simulationen mit fünf- und sechststelligen Nutzerzahlen berechnen zu können, wird allerdings nicht ein einziges Optimierungsproblem für alle Nutzer, sondern mehrere strukturell identische Optimierungsprobleme gelöst, innerhalb derer Nutzergruppen betrachtet werden. Abschnitt 3.6.1.2 erläutert das genauere Vorgehen der Aufteilung der Nutzer in Teilgruppen. Zur besseren Verständlichkeit kann für die folgenden Betrachtungen zunächst angenommen werden, dass ein Optimierungsproblem für alle Nutzer gelöst wird.

Das Ziel von Algorithmus 1 ist es, die Ladevorgänge so zu planen, dass die Kosten für das Laden in der Summe aller Fahrzeuge minimal wird. Dazu legt er für jeden Zeitschritt t des Optimierungszeitraums $t \in \{1, \dots, T\}$ für alle Nutzer $n \in \{1, \dots, N\}$ die geplanten optimalen Ladeleistungen $\hat{P}_{t,q,n}^{\text{Lad}}$ für jede der drei bilanziellen Strombezugsquellen $q \in \{1, 2, 3\}$ des privaten Ladepunkts fest. Die Dauer eines Zeitschritts betrage $\Delta t = 15$ min, sodass $\hat{E}_{t,q,n}^{\text{Lad}} = \hat{P}_{t,q,n}^{\text{Lad}} \Delta t$ der Energie entspricht, die während des Zeitschritts t geladen werden soll. Die Länge des Optimierungszeitraums variiert mit der Uhrzeit der Ausführung des Algorithmus (vgl. Abschnitt 3.2). Bei der Optimierung um 8:00 Uhr beträgt sie $T = 48 \text{ h} / \Delta t = 192$. In der Primärsimulation wurden $N = 20\,000$ Nutzer betrachtet (siehe Parameter der Simulation in Unterkapitel 4.2). Das Dachsymbol „ $\hat{}$ “ verdeutlicht, dass es sich um planerische Werte handelt.

Der Strombezug über das Stromnetz vom Stromversorger wird durch $q = 1$ repräsentiert. Die Kosten setzen sich zusammen aus den fixen externen Strompreisbestandteilen sowie dem aktuellen Spotmarktpreis. Ist $q = 2$, entspricht die Bezugsquelle des Stromes der eigenen PV-Anlage zu den Kosten der EEG-Einpeisevergütung, die sich an dem Inbetriebnahmedatum der jeweiligen PV-Anlage orientiert. Da angenommen wurde, dass alle Nutzer die Kleinunternehmerregelung in Anspruch nehmen (vgl. Abschnitt 2.1.4.2), wird keine Umsatzsteuer auf den PV-Strombezug einberechnet. Mit $q = 3$ wird der Strombezug durch die Erbringung negativer Sekundärregelarbeit abgebildet. Die Kosten umfassen die externen Strompreisbestandteile reduziert um die anteilige Vergütung des Regelleistungs- und des Regelarbeitspreises, der allerdings auch negativ ausfallen kann. Für jeden Nutzer sind damit zu jedem Zeitpunkt für jede Bezugsquelle die Stromkosten $\hat{C}_{t,q,n}$ definiert. Da sich die Stromvertragskonditionen der Nutzer bzgl. der externen Preisbestandteile voneinander unterscheiden und auch die EEG-Prämie nicht für jeden Nutzer identisch ist, sind die Kosten nutzerindividuell.

3.6.1.1. Aufstellung des Optimierungsproblems

Im Folgenden wird das lineare Optimierungsproblem als LP formuliert. Minimiert wird das Produkt aus der Entscheidungsvariable $\hat{\mathbf{P}}^{\text{Lad}}$ und den Kosten $\hat{\mathbf{C}}$ durch die Zielfunktion

$$\min_{\hat{\mathbf{P}}^{\text{Lad}}} \hat{\mathbf{P}}^{\text{Lad}} \top \hat{\mathbf{C}} \Delta t = \min_{\hat{\mathbf{P}}_{t,q,n}^{\text{Lad}}} \sum_{t=1}^T \sum_{q=1}^3 \sum_{n=1}^N \hat{P}_{t,q,n}^{\text{Lad}} \hat{C}_{t,q,n} \Delta t. \quad (3.4)$$

Die Kosten für den Bezug von PV-Strom $C_{t,2,n}$ sind zeitinvariant. Um das Aufschieben von Ladevorgängen zu verhindern, wird im LP das Laden mit PV-Strom zu Beginn der Optimierungsperiode durch geringfügig geringere und zum Ende durch etwas höhere Kosten repräsentiert

$$\hat{C}_{t,2,n} := \hat{C}_{t,2,n} + r \left(t - \frac{T+1}{2} \right) \cdot 1 \text{ ct/kWh}, \quad \text{mit } 0 > r \ll 1 \text{ und } \forall t, n. \quad (3.4)$$

Die Minimierung unterliegt sieben Nebenbedingungen und der Nichtnegativitätsbedingung

$$\hat{P}_{t,q,n}^{\text{Lad}} \geq 0, \quad \forall t, q, n, \quad (3.5)$$

die sicherstellt, dass beim Laden keine Energie aus der Batterie zurückgespeist wird. V2G wird folglich nicht betrachtet.

Nebenbedingung 1

$$\hat{P}_{t,2,n}^{\text{Lad}} \leq \hat{P}_{t,n}^{\text{PV}}, \quad \forall t, n \quad (3.6)$$

stellt sicher, dass der Leistungsbezug aus der Quelle $q = 2$ nicht die prognostizierte Leistung der eigenen PV-Anlage überschreitet. Bei Nutzern ohne PV-Anlage ist $\hat{P}_{t,n}^{\text{PV}} = 0 \forall t$.

Nebenbedingung 2 gewährleistet, dass die geplante Ladeleistung in der Summe der drei Bezugsquellen nicht die technisch maximal verfügbare Ladeleistung überschreitet

$$\sum_{q=1}^3 \hat{P}_{t,q,n}^{\text{Lad}} \leq \hat{P}_{t,n}^{\text{Lad,max}}, \quad \forall t, n. \quad (3.7)$$

$\hat{P}_{t,n}^{\text{Lad,max}}$ definiert sich aus dem Minimum der maximalen Ladeleistung des Fahrzeuges und der LE, reduziert um die Verlustleistung beim Laden. Wenn ein Fahrzeug nicht am privaten Ladepunkt parkt oder das Laden durch den VNB im Rahmen des netzdienlichen Ladens blockiert wird, gilt $\hat{P}_{t,n}^{\text{Lad,max}} = 0$. Für Nutzer, deren VNB Netze BW ist, wird in diesen Zeiträumen die maximale Ladeleistung um 50% reduziert.

Die Hilfsvariable

$$\hat{E}_{t,n}^{\text{Bat,init}} := E_{0,n}^{\text{Bat}} - \sum_{t^*=1}^t \hat{E}_{t^*,n}^{\text{Ver}}, \quad \forall t, n \quad (3.8)$$

schreibt den Energieinhalt der Batterie zum Optimierungszeitpunkt $\hat{E}_{0,n}^{\text{Bat}}$ um die von den Nutzern gemeldeten und geplanten Fahrverbräuche $\hat{E}_{t,n}^{\text{Ver}}$ über den Optimierungszeitraum fort. $\hat{E}_{t,n}^{\text{Bat,init}}$ ermittelt für jeden Zeitpunkt t den Ladefüllstand der Batterie, wenn keine Ladevorgänge getätigt

werden würden. Nebenbedingung 3

$$\sum_{t^*=1}^t \sum_{q=1}^3 \hat{P}_{t^*,q,n}^{\text{Lad}} \leq \frac{E_n^{\text{Bat,max}} - \hat{E}_{t,n}^{\text{Bat,init}}}{\Delta t}, \quad \forall t, n \quad (3.9)$$

verhindert, dass der Ladefüllstand die maximale Kapazität $E_n^{\text{Bat,max}}$ überschreitet.

Mit den bisherigen Nebenbedingungen würde die Zielfunktion minimal werden, wenn $\hat{\mathbf{P}}^{\text{Lad}} = \mathbf{0}$ gesetzt werden würde, also gar keine Ladevorgänge an privaten Ladepunkten stattfänden. In diesem Fall müssten die Nutzer stets auf die teureren öffentlichen Ladepunkte ausweichen, sodass sich die Gesamtkosten erhöhten und gleichzeitig die Mobilitätsbedürfnisse der Nutzer stark eingeschränkt werden würden. Um dies zu verhindern, wird angestrebt, während einer Optimierungsperiode die Batterie voll oder zumindest so voll wie möglich zu laden. Dazu wird ermittelt, wie viel Energie während einer Optimierungsperiode geladen werden kann, ohne dass es zu einem Überlauf der Batterie kommt. $\hat{E}_{t,n}^{\text{Bat,max,mög}}$ ist der maximale Batteriefüllstand zum Zeitpunkt t , wenn von $t = 1$ ausgehend, in jedem Zeitschritt die technisch maximal ladbare Energie geladen wird, ohne dabei die Batteriekapazität zu überschreiten

$$\begin{aligned} \hat{E}_{1,n}^{\text{Bat,max,mög}} &:= \min \left\{ E_n^{\text{Bat,max}}, \hat{E}_{1,n}^{\text{Bat,init}} + \hat{E}_{1,n}^{\text{Lad,max}} \right\} \\ \hat{E}_{t,n}^{\text{Bat,max,mög}} &:= \min \left\{ E_n^{\text{Bat,max}}, \hat{E}_{t-1,n}^{\text{Bat,max,mög}} - \hat{E}_{t,n}^{\text{Ver}} + \hat{E}_{t,n}^{\text{Lad,max}} \right\}, \quad \text{mit } t \in \{2, \dots, T\}. \end{aligned} \quad (3.10)$$

Die maximal ladbare Energiemenge während der Optimierungsperiode entspricht dann der Differenz zwischen dem maximal möglichen Batteriefüllstand und dem fortgeschriebenen Batteriefüllstand am Ende der Optimierungsperiode

$$\hat{E}_n^{\text{Lad,max,mög}} := \hat{E}_{T,n}^{\text{Bat,max,mög}} - \hat{E}_{T,n}^{\text{Bat,init}}, \quad \forall n. \quad (3.11)$$

Damit kann durch Nebenbedingung 4

$$\sum_{t=1}^T \sum_{q=1}^3 \hat{P}_{t,q,n}^{\text{Lad}} = \frac{\hat{E}_n^{\text{Lad,max,mög}}}{\Delta t}, \quad \forall n \quad (3.12)$$

sichergestellt werden, dass über den Optimierungszeitraum das Laden der maximal möglichen Energiemenge vorausgeplant wird.

Der Aggregator strebt an, nicht nur über den gesamten Optimierungszeitraum genügend Energie zu laden, sondern auch zu jedem Zeitpunkt ein gewisses Level des Batteriefüllstands zu gewährleisten. So wird ebenfalls der Anteil der Ladevorgänge an öffentlichen Ladepunkten reduziert und die Mobilität der Nutzer weiter verbessert. Dafür muss bis zu jedem Zeitpunkt so viel Energie geladen worden sein, dass der Batteriefüllstand nicht unter einen Schwellwert $E_n^{\text{Bat,min}}$ fällt, den der Aggregator nutzerindividuell auf der Basis der Batteriekapazität festlegt. Je höher $E_n^{\text{Bat,min}}$ gewählt wird, desto seltener müssen Nutzer wegen geringer SoC teure öffentlichen Ladestationen in Anspruch nehmen. Im Gegenzug reduziert sich die Flexibilität beim Verschieben von Ladevorgängen. Die besten ökonomischen Ergebnisse wurden erzielt, wenn $E_n^{\text{Bat,min}}$ durchschnittlich 39,6% der Batteriekapazität entsprach. Die mindestens zu ladenden Energiemenge darf die technisch

maximal ladbare Energiemenge nicht überschreiten. Die bis zu einem Zeitpunkt t mindestens zu ladende Energie $\hat{E}_{t,n}^{\text{Lad},\min}$ ist das Minimum aus der Energie die fehlt, um den nutzerindividuellen Schwellwert zu erreichen und der bis zum Zeitpunkt t technisch maximal ladbaren Energie

$$\hat{E}_{t,n}^{\text{Lad},\min} := \min \left\{ E_n^{\text{Bat},\min} - \hat{E}_{t,n}^{\text{Bat},\text{init}}, \hat{E}_{t,n}^{\text{Bat},\text{max},\text{mög}} - \hat{E}_{t,n}^{\text{Bat},\text{init}} \right\}, \quad \forall t, n. \quad (3.13)$$

Mit Nebenbedingung 5 wird bis zu jedem Zeitpunkt die mindestens zu ladende Energie eingehalten

$$\sum_{t^*=1}^t \sum_{q=1}^3 \hat{P}_{t^*,q,n}^{\text{Lad}} \geq \frac{\hat{E}_{t,n}^{\text{Lad},\min}}{\Delta t}, \quad \forall t, n. \quad (3.14)$$

Die letzten beiden Nebenbedingungen widmen sich den Anforderungen des Regelleistungsmarktes. Die Optimierungsperiode wird in $K_{\text{Zts}} = \frac{T}{T_{\text{Cons}}}$ Zeitscheiben der Dauer T_{Cons} aufgeteilt. Während einer Zeitscheibe wird der geplante Strombezug aus Regelarbeit in der Summe der Flotte konstant gehalten. Dazu muss die summierte Ladeleistung aus $q = 3$ aller Nutzer während aller Zeitschritte einer Zeitscheibe gleich sein. Dies wird durch Nebenbedingung 6

$$\sum_{n=1}^N \hat{P}_{t,3,n}^{\text{Lad}} - \sum_{n=1}^N \hat{P}_{t+1,3,n}^{\text{Lad}} = 0, \quad \text{mit } t \in \{1, \dots, T\} \setminus \{k T_{\text{Cons}}\} \text{ und } k \in \{1, \dots, K_{\text{Zts}}\} \quad (3.15)$$

gewährleistet. Lediglich an den Übergängen zweier Zeitscheiben $\{k T_{\text{Cons}}\}$ darf es zu Änderungen bei der geplanten Ladeleistung kommen. Nebenbedingung 7

$$\sum_{n=1}^N \hat{P}_{t,3,n}^{\text{Lad}} = P_{t,\text{Agg}}^{\text{SRL,Ang}}, \quad \text{mit } t \in \{j T_{\text{Cons}}\} \text{ und } j \in \{1, \dots, K_{\text{Zts,SRL}}\}, \quad (3.16)$$

fixiert die geplante Ladeleistung aus $q = 3$ auf die Höhe der erfolgreich vermarkteten Regelleistung $P_{t,\text{Agg}}^{\text{SRL,Ang}}$, die null beträgt, sollte sich ein Angebot über den Regelleistungspreis nicht durchsetzen, für alle Zeitschritte bis zum letzten Zeitschritt des Tages $d + 1$. Dabei gibt

$$K_{\text{Zts,SRL}} = \frac{24 \text{ h} - t_{\text{h,SRL,Auk}} + \text{mod}(t_{\text{h,SRL,Auk}} - t_{\text{h}}, 24 \text{ h})}{T_{\text{Cons}}} \quad (3.17)$$

die Anzahl der Zeitscheiben in der Optimierungsperiode an, für die der geplante Strombezug aus $q = 3$ durch die Resultate bereits stattgefundener SRL-Auktionen vorgegeben ist. Sie ist abhängig von der Uhrzeit in Stunden t_{h} , zu der eine Optimierung ausgeführt wird und dem Zeitpunkt, an dem die Regelleistungsmarktauktionen stattfinden $t_{\text{h,SRL,Auk}} = 8 \text{ h}$. Es genügt lediglich dem ersten Zeitschritt einer Zeitscheibe einen festen Wert zuzuweisen. Wegen Nebenbedingung 6 in Gleichung 3.15 werden alle anderen Zeitschritte der Zeitscheibe ebenfalls auf $P_{t,\text{Agg}}^{\text{SRL,Ang}}$ fixiert.

3.6.1.2. Aufspaltung des linearen Programms

Für jeden Nutzer liegt pro Zeitschritt und Strombezugsquelle eine Entscheidungsvariable vor. Die Anzahl der Entscheidungsvariablen beläuft sich folglich auf $3TN$. Die sieben Nebenbedingungen umfassen jeweils mehrere Gleichungen bzw. Ungleichungen strukturell identischer Art, deren Mengen Tabelle 3.10 auflistet.

Tabelle 3.10.: Anzahl der Gleichungen bzw. Ungleichungen pro Nebenbedingung.

3.6	$T N$
3.7	$T N$
3.9	$T N$
3.12	N
3.14	$T N$
3.15	$T - K_{Zts}$
3.16	$K_{Zts,SRL}$
Summe	$4 T N + N + T - K_{Zts} + K_{Zts,SRL}$

Bei einer Optimierungsperiode von zwei Tagen und einer Zeitschrittlänge von $\Delta t = 15$ min beträgt $T = 2 \cdot 24 \text{ h} \cdot 4 \text{ h}^{-1} = 192$ Zeitschritte. In den Simulationen, die Kapitel 4 behandelt, umfassen die Flotten $N = 20\,000$ und $N = 100\,000$ Nutzer. In der Folge besäßen die LPs bei der Optimierung um 8:00 Uhr 15,4 Mio. bzw. 76,9 Mio. Nebenbedingungsgleichungen und -ungleichungen. Die Anzahl der Entscheidungsvariablen läge bei 11,5 Mio. bzw. 57,6 Mio. Die Nebenbedingungsmatrix umfasste 177,1 Bio. bzw. 4,4 Brd. Parameter. Durch den polynomialen Anstieg des Rechenaufwandes mit der Anzahl der Nebenbedingungen und insbesondere der Entscheidungsvariablen (vgl. Abschnitt 2.4.2) ließe sich dieses LP auch mit leistungsstarker Hardware nicht in sinnvoller Zeit lösen. Dazu würde die Nebenbedingungsmatrix, auch wenn sie als dünnbesetzte Matrix weniger Speicherplatz als übliche Matrizen benötigt, den Arbeitsspeicher gängiger Rechensysteme um ein Vielfaches übersteigen.

Zur Umgehung dieser Problematik wird das LP in viele kleinere LPs aufgesplittet. Dazu wird die Flotte in feste Teilgruppen unterteilt, für die jeweils ein eigenes LP aufgestellt und gelöst wird. Die Nebenbedingungen 1 bis 5 umfassen keine nutzerübergreifenden Restriktionen. Jede Gleichung bzw. Ungleichung inkludiert nur Entscheidungsvariablen eines Nutzers. Ohne die Nebenbedingungen 6 und 7 ließe sich für jeden Nutzer ein einzelnes LP aufstellen und lösen. Wird, wie in Abschnitt 3.1.2 angekündigt, $T_{\text{Cons}} = 4$ h gesetzt, müsste bei der Verwendung eines LPs pro Nutzer ein Fahrzeug über diesen Zeitraum eine konstante Ladeleistung aufweisen können, um am Regelleistungsmarkt teilzunehmen. Dies würde aufgrund des Mobilitätsverhaltens der Nutzer und den gängigen Batteriegrößen der Fahrzeuge zu einer geringen vermarktbaren Regelleistung führen. Je mehr Nutzer ein LP umfasst, desto mehr Freiheitsgrade ergeben sich bei der Planung der Regelleistungsmarkteinsätze.

Durch die Aufspaltung der Flotte in mehrere Teilgruppen wird kein globales Optimum mehr gefunden. Bei der Auswahl der Teilgruppengröße N_G muss ein Kompromiss gefunden werden zwischen Reduzierung der Rechenzeit und des Speicherbedarfs auf der einen Seite und der Abweichung vom ökonomischen Optimum auf der anderen Seite. Nach Tests, bei denen die Ergebnisse größerer Teilgruppengröße mit denen kleinerer verglichen wurden, wurde für die Simulationen in Kapitel 4 $N_G = 50$ gewählt. Damit reduziert sich das LP für die Optimierung um 8:00 Uhr auf 38 640 Nebenbedingungsgleichungen bzw. -ungleichungen und die Nebenbedingungsmatrix enthält 1,1 Mrd. Parameter. In den Simulationen wurde die Aufteilung der Nutzer in Gruppen zu Beginn zufällig festgelegt und anschließend nicht mehr verändert. Tests, bei denen die Nutzergruppen für

jede Zeitscheibe neu festgelegt wurden, erzielten keine besseren Ergebnisse. Die Aufteilung erfolgte dabei anhand einer Rangfolge der Ladeverfügbarkeit. Nutzer, die während einer Zeitscheibe nicht zum Laden zur Verfügung standen, wurden den gleichen Gruppen zugewiesen. Ebenso bildeten Nutzer mit hohen Ladeverfügbarkeiten gemeinsame Nutzergruppen.

Die Aufteilung in Teilgruppen ermöglicht darüber hinaus den Einsatz von Parallelrechenmethoden (Engl. parallel computing). Da Matlabs Implementierung des Simplexalgorithmus kein Multithreading unterstützt, kann ein LP nur von jeweils einem CPU-Thread gelöst werden. Die Aufteilung des einen großen LPs in mehrere kleine LPs ermöglicht mithilfe der Parallel Computing Toolbox die parallele Bearbeitung mehrerer LPs und trägt, insbesondere bei Rechnern mit vielen Prozessor-Threads, zur Verringerung der benötigten Rechenzeit bei.

3.6.2. Operativer Algorithmus

Auf der operativen Ebene wird den Fahrzeugen in regelmäßigen Abständen der anzunehmende Ladeleistungssollwert mitgeteilt. Algorithmus 2 löst kein LP, sondern passt die geplanten Ladeleistungen der letzten Optimierung durch Algorithmus 1 an die reale Situation an. Anpassungen sind wegen ungeplanten öffentlichen Ladevorgängen, Abweichungen zwischen der prognostizierten und realen PV-Erzeugungsleistung und eines kleineren Regelarbeitsabrufs als eingeplant notwendig.

Registriert der Aggregator, dass ein Nutzer das Laden an einem öffentlichen Ladepunkt beginnt, verschiebt er nach Abschluss des Ladevorgangs die nächsten geplanten Ladungen an der privaten LE

$$\hat{P}_{t+\Delta t_n^{\text{Lad,öff}},q,n}^{\text{Lad}} := \hat{P}_{t,q,n}^{\text{Lad}}, \quad \text{mit } t \in \left\{ t_n^{\text{Lad,öff,Beg}}, \dots, t_n^{\text{Lad,öff,End}} \right\}, \quad \forall q, n \quad (3.18)$$

um die Dauer des Ladevorgangs $\Delta t_n^{\text{Lad,öff}} = t_n^{\text{Lad,öff,End}} - t_n^{\text{Lad,öff,Beg}}$. Als Ausgangsbasis für die übermittelten Sollladeleistungen zum Zeitpunkt t

$$P_{t,q,n}^{\text{Lad}} := \min \left\{ \hat{P}_{t,q,n}^{\text{Lad}}, \frac{E_n^{\text{Bat,max}} - E_{t,n}^{\text{Bat}}}{\Delta t} \right\} \quad \forall q, n \quad (3.19)$$

dienen die geplanten optimalen Ladeleistungen. Dabei muss verhindert werden, dass durch ungeplantes öffentliches Laden ein geplanter privater Ladevorgang zum rechnerischen Überlauf des Batteriefüllstands führen könnte.

In die Berechnungen von Algorithmus 1 fließen die prognostizierten Erzeugungsleistungen der PV-Anlagen ein. Der operative Algorithmus begrenzt das Laden per PV-Strom auf die tatsächlich vorliegenden Erzeugungsleistungen der PV-Anlagen

$$P_{t,2,n}^{\text{Lad}} := \min \left\{ P_{t,2,n}^{\text{Lad}}, P_{t,n}^{\text{PV}} \right\}, \quad \forall n. \quad (3.20)$$

Weist der ÜNB den Aggregator an Regularbeit zu erbringen, allokiert Algorithmus 2 die zu erbringende Leistung auf die Fahrzeuge. Durch die ungeplanten Ladevorgänge an öffentlichen Ladepunkten kann es sein, dass Fahrzeuge, die zur Erbringung von Regularbeit vorgesehen waren,

nicht zur Verfügung stehen oder aufgrund ungeplant hoher Batteriefüllstände weniger Regelarbeit erbringen können als vorausgeplant. In diesem Fall wird versucht, die Differenz durch andere Fahrzeuge zu kompensieren, für die keine oder eine geringere Erbringung von Regelarbeit vorgesehen war, eine Erhöhung technisch aber möglich ist. Die Kompensation erfolgt teilgruppenübergreifend.

Bei der Allokation der zu erbringenden Regelarbeit wird eine Einsatzreihenfolge der Fahrzeuge festgelegt. Vergleichbar mit der Aufstellung einer MOL werden die Fahrzeuge aufsteigend anhand der Differenz

$$E_{t,n}^{\text{Bat}} - E_n^{\text{Bat},\text{min}} \quad (3.21)$$

geordnet. Von oben in der Liste beginnend, werden so viele Fahrzeuge zur Erbringung ausgewählt, wie zur Erfüllung des Sollwertes des ÜNBs $P_t^{\text{SRL,Soll}}$ notwendig ist. Bei der Zusammenstellung der Liste sind vier Fälle zu unterscheiden. Unterschreitet oder gleicht die angeforderte Leistung die Leistung, die zur Erbringung eingeplant war und leistbar ist, ohne dass Batterien ihre maximale Kapazität überschreiten

$$\text{Fall 1:} \quad P_t^{\text{SRL,Soll}} \leq \sum_{n=1}^N P_{t,3,n}^{\text{Lad}}, \quad (3.22)$$

setzt sich die MOL nur aus den Fahrzeugen zusammen, die ohnehin für die Erbringung von Regelarbeit vorgesehen waren. Andernfalls wird geprüft, ob der Sollwert durch eine Leistungserhöhung der Fahrzeuge, die ohnehin für die Regelarbeitsleistung vorgesehen waren, erfüllt werden kann

$$\text{Fall 2:} \quad \sum_{n^* \in N^*} P_{t,n^*}^{\text{Lad,max,mög}} \geq P_t^{\text{SRL,Soll}} > \sum_{n=1}^N P_{t,3,n}^{\text{Lad}}, \quad \text{mit } N^* := \{n^* : P_{t,3,n^*}^{\text{Lad}} > 0\}, \quad (3.23)$$

$$\text{mit } P_{t,n}^{\text{Lad,max,mög}} := \min \left\{ P_{t,n}^{\text{Lad,max}}, \frac{E_n^{\text{Bat,max}} - E_{t,n}^{\text{Bat}}}{\Delta t} \right\} \quad \forall n, \quad (3.24)$$

wobei $P_{t,n}^{\text{Lad,max}}$ analog zu $\hat{P}_{t,n}^{\text{Lad,max}}$ die technisch maximale Ladeleistung ist, aktualisiert mit dem Fahrzeugstatus zum Zeitpunkt t . Die über $\sum_{n=1}^N P_{t,3,n}^{\text{Lad,max,mög}}$ hinausgehende benötigte Leistung wird per MOL, die nach Gleichung 3.21 sortiert wird, allokiert. Im dritten Fall, dann wenn

$$\text{Fall 3:} \quad \sum_{n=1}^N P_{t,n}^{\text{Lad,max,mög}} \geq P_t^{\text{SRL,Soll}} > \sum_{n^* \in N^*} P_{t,n^*}^{\text{Lad,max,mög}}, \quad (3.25)$$

werden auch alle anderen Fahrzeuge in die MOL aufgenommen, die zur Deckung des Leistungsbedarfs über $\sum_{n^* \in N^*} P_{t,n^*}^{\text{Lad,max,mög}}$ hinaus verwendet wird. Beim Eintritt des vierten Falls

$$\text{Fall 4:} \quad P_t^{\text{SRL,Soll}} > \sum_{n=1}^N P_{t,n}^{\text{Lad,max,mög}}, \quad (3.26)$$

müssen die anderen TEs des Regelleistungspools des VPPs die verbleibende Differenz kompensieren.

4. Untersuchungen zum Optimierungssystem und Ergebnisse der Simulationen

Zunächst wertet dieses Kapitel die Qualität des entwickelten Spotmarktprognosemodells und der PV-Erzeugungleistungsprognose aus. Anschließend werden die Simulationsergebnisse untersucht. Unterkapitel 4.2 stellt die Parameter der durchgeführten Simulationen vor. Es folgt ein Vergleich zwischen dem Verhalten der modellierten Flotte im Basisszenario, im Smart-Charging-Szenario und dem Verhalten realer Elektroautos. In der Folge werden die Lastprofile der Simulationen ausgewertet. Unterkapitel 4.5 untersucht die Regelleistungsmarktaktivitäten des Aggregators. Abschließend wird das ökonomische Potenzial des entwickelten Optimierungssystems analysiert.

4.1. Auswertung der Spotmarkt- und PV-Prognose

Im Folgenden werden die Ergebnisse der Prognosemodelle ausgewertet. Ein Vergleich der erzielten Genauigkeit des Spotmarktprognosemodells mit vergleichbaren Ansätzen aus der Literatur und der PV-Prognose mit den Angaben des Datenlieferanten findet sich in Abschnitt 5.2.2.1.

4.1.1. Spotmarktprognosemodell

Das Spotmarktprognosemodell basiert auf dem ARX-Modell in Gleichung 3.1. Zur Berechnung der Parameter per LS-Methode und zur Ermittlung der NARXNET-Parameter wurde der reale MCP sowie die beschriebenen Prädiktoren im Zeitraum vom 01.01.2018 bis zum 31.08.2019 als Trainingsdatensatz verwendet. Für beide Modelle wurden Prognosedaten über den Simulationszeitraum generiert. Zur Ermittlung der Prognosequalität wurden die Prognosedaten mit dem realen MCP während des Simulationszeitraums verglichen. Abbildung 4.1 zeigt die tagesdurchschnittlichen Prognosewerte beider Prognoseverfahren im Vergleich mit dem realen MCP.

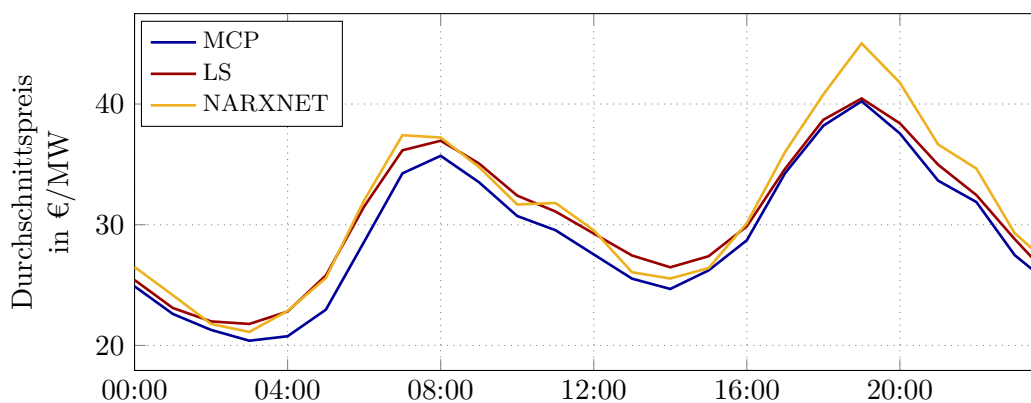


Abbildung 4.1.: Durchschnittlich prognostizierter MCP und tatsächlicher MCP des Day-Ahead-Marktes.

Die Grafik verdeutlicht, dass beide Prognosemodelle grundsätzlich den systematischen Preisverlauf abbilden. Im Mittel wurde per LS-Methode ein MCP von 30,54 €/MWh und von den NARXNETs 31,20 €/MWh prognostiziert. Im Vergleich zu den 29,28 €/MWh des realen MCPs ergibt sich für bei Methoden ein kleiner positiver Bias, der auf die deutlich höheren Preise während des Trainingszeitraums, der Mittelwert lag bei 41,77 €/MWh, zurückgeführt werden kann.

Insgesamt übertrifft die Prognosequalität der LS-Methode die der NARXNETs. Tabelle 4.1 zeigt die Werte der in Abschnitt 2.3.5 vorgestellten Metriken zur Bewertung von Prognoseverfahren. Im Durchschnitt wich die Prognose per LS-Methode um 5,25 €/MWh bzw. 17,8 % von den realen Preisen ab. Beide Verfahren generieren deutlich bessere Prognosewerte als der naive $d - 1$ Referenzansatz, bei dem der uhrzeitgleiche Wert des Vortages als Prognose dient.

Tabelle 4.1.: Fehlermaße der Prognoseverfahren für die Day-Ahead-MCP-Prognose.

Prognoseverfahren	MAE in €/MWh	RMSE in €/MWh	mMAPE in %
LS-Methode	5,25	7,49	17,8
NARXNETs	5,90	7,95	20,0
Naiv $d - 1$	9,11	13,93	31,2

4.1.2. PV-Prognosedaten

Insgesamt zeigen die Prognosedaten einen kleinen positiven Bias. Über den Simulationszeitraum wurde bei 15 von 20 Anlagen die reale Erzeugungsleistung im Mittel überschätzt. Die über den gesamten Zeitraum in der Summe aller Anlagen prognostizierte erzeugte elektrische Energie überstieg die gemessene um 4,93 %.

PV-Anlagen besitzen mit ihrem Erwartungswert eine individuelle Bezugsgröße. Eine Angabe der Prognosequalität mit absoluten Metriken wie dem MAE oder RMSE ist daher wenig sinnvoll. Eine Vergleichbarkeit ist bei Verwendung des mMAPE gegeben. Dieser schwankte für die 20 PV-Anlagen zwischen 37 % und 57 %. Im Mittel aller Anlagen lag er bei 45 %.

4.2. Parameter der durchgeführten Simulationen

Für die Simulationen standen ein Rechnersystem mit 64 GB RAM und dem AMD Ryzen Threadripper 2970WX mit 24 Kernen und 48 Threads als CPU zur Verfügung. Die Durchführung der Simulationen folgte zwei Zwecken. Zum einen wurden Modellierungsparameter so abgestimmt, dass das Fahrverhalten der modellierten Elektrofahrzeugflotte möglichst realitätsnah wird und dass die Kosten im Smart-Charging-Szenario minimal werden. Zum anderen wurde mithilfe der Simulationen das System ausgewertet, um das Optimierungssystem bewerten zu können.

Für die Festlegung der Modellierungsparameter wurden viele kleine Simulationen mit dreistelligen bis vierstelligen Nutzerzahlen durchgeführt. Durch Parametervariationen wurde das System

so abgestimmt, dass typische Indikatoren des Fahrverhaltens praktischen Messungen aus externen Quellen nahekommen. Das nächste Unterkapitel vergleicht die Indikatoren des modellierten Systems mit realen Daten und Angaben aus externen Quellen. Die durch Simulationen festgelegten Modellierungsparameter umfassen beispielsweise die nutzerindividuellen SoC-Schwellwerte, ab denen Nutzer während einer Fahrt öffentliche Ladepunkte in Anspruch nehmen und im Basisszenario ihr Fahrzeug mit ihrer privaten LE verbinden. Bei der Selektion der realen Fahrprofile (vgl. Abschnitt 3.3.1.1) wurden wegen des Abgleichs nur Dienstwagenfahrer ausgewählt. Für das Optimierungssystem wurden durch Parametervariationen der Leistungspreisfaktor $\alpha_P^{\text{SRL,Ang}}$, der Arbeitspreisfaktor $\alpha_W^{\text{SRL,Ang}}$ und die nutzerindividuelle Mindestenergie für Batterien $E_n^{\text{Bat,min}}$ so bestimmt, dass die Kosten minimal wurden. Außerdem wurde auf diese Weise entschieden, dass im Smart-Charging-Szenario kein PV-Anlagen-Besitzer am netzdienlichen Laden teilnimmt.

Das System wird mit den Ergebnissen der Primärsimulation ausgewertet. In ihr wurden das Basisszenario und das Smart-Charging-Szenario über den gesamten Simulationszeitraum mit 20 000 Nutzern simuliert. Wie in Abschnitt Unterkapitel 3.1 beschrieben, besitzen in beiden Szenarien 50 % der Nutzer eine PV-Anlage, im Basisszenario melden 1 % und im Smart-Charging-Szenario 35 % ihre private LE als steuerbare Verbrauchseinrichtung an. Beide Eigenschaften weisen keine Abhängigkeiten von anderen Nutzereigenschaften auf.

Auf dem genannten Rechnersystem nahm die Simulation des Smart-Charging-Szenarios 88,5 h und die des Basisszenarios 3,8 h Rechenzeit in Anspruch. Die Nutzerdaten beider Szenarien umfassen in Matlab jeweils 34,2 GB RAM. Im Smart-Charging-Szenario erreicht das Rechnersystem aufgrund der großen Nebenbedingungsmatrix fast sein RAM-Limit. Dazu trägt auch bei, dass durch das parallele Berechnen der LPs die Nebenbedingungsmatrix für jede Parallelisierungseinheit (Worker) einzeln abgespeichert werden muss. Um die RAM-Grenzen nicht zu überschreiten, wurden lediglich zwölf Worker eingesetzt, statt der durch die CPU möglichen 48.

Die Sekundärsimulation dient dazu, eine Aussage über den Einfluss großer Smart-Charging-Systeme auf den Regelleistungsmarkt treffen zu können (vgl. Unterkapitel 4.5). In ihr wurde die Nutzerzahl auf 100 000 erhöht. Zur Senkung der Rechenlaufzeit und des Speicherbedarfs wurde im Gegenzug nur ein Zeitraum von 24 Tagen, vom 01.09.2019 bis zum 24.09.2019, betrachtet.

4.3. Auswertung der simulierten Nutzungsprofile

Die Nutzungsprofile der Primärsimulation wurden anhand verschiedener Indikatoren ausgewertet. Die Modellierung verfolgte das Ziel, eine möglichst hohe Übereinstimmung des Basisszenarios mit der externen Referenz zu erreichen. Um die Realitätsnähe der Modellierung bewerten zu können, werden diese Indikatoren im Folgenden mit realen Messungen externer Quellen verglichen. Insbesondere wurde auf Messergebnisse des niederländischen Wissens- und Innovationscenters für intelligente Ladeinfrastruktur ElaadNL zurückgegriffen, das das Ladeverhalten niederländischer BEV-Fahrer im Zeitraum von 2018 bis 2020 ausgewertet hat [88].

In Tabelle 4.2 werden vier skalare Indikatoren zum Nutzungsverhalten verglichen. Im Basisszenario laden die modellierten Nutzer ihr Fahrzeug pro Woche ebenso häufig wie in [43] gemessen.

Tabelle 4.2.: Indikatorvergleich mit externen Quellen. Für die Angabe des Fahrverbrauch der externen Quelle wurden die gemessenen Verbräuche im ADAC Ecotest der modellierten Fahrzeuge ihrem Anteil an der Nutzerschaft entsprechend (vgl. Tabelle 3.1) in einem Mittelwertwert zusammengefasst.

Indikator	Smart-Charging	Basisszenario	Externe Quelle
Laden pro Woche	7,2	4,3	4 bis 5 [43, S. 6]
Anteil Laden privat	92,9 %	89,1 %	85 % [35, S. 83]
Verbrauch/100 km	19,5 kWh	19,5 kWh	19,6 kWh [89]
Fahrleistung pro Jahr	15 125 km	15 112 km	14 610 km [90, S. 9]

Der Anteil der Ladevorgänge an privaten Ladepunkten übertrifft mit 89,1 % leicht die Schätzung der NPM. Das ist durchaus sinnvoll. Es ist anzunehmen, dass insbesondere BEV-Fahrer, die häufig an privaten Ladepunkten laden, an Smart-Charging-Services interessiert sind. Die Anzahl der Ladevorgänge an privaten Ladepunkten steigt von 3,86 pro Woche im Basisszenario auf 6,67 im Smart-Charging-Szenario, während die Häufigkeit des Ladens an öffentlichen Ladestationen nur von 0,491 auf 0,498 steigt. Die Nutzer verbinden auf Anraten des Aggregators ihr Fahrzeug häufiger mit ihrem privaten Ladepunkt, um ihre Ladeflexibilität zu erhöhen. Sie müssen durch das Smart Charging wegen der Berücksichtigung einer mindestens zu ladenden Energiemenge durch Nebenbedingung 5 in Gleichung 3.14 aber kaum häufiger öffentliche Ladestationen beanspruchen.

Der simulierte Verbrauch der Flotte auf Basis der realen Fahrprofile und der Verbrauchswerte von [73] kommt den gemessenen Verbräuchen des ADACs sehr nahe. Die Fahrleistung übersteigt leicht die Umfrageergebnisse unter PkW-Fahrern aus dem *DAT Report 2020*. Da Elektroautos besonders für Vielfahrer wirtschaftlich sind [91], kann durchaus angenommen werden, dass ihre Fahrleistung die der durchschnittlichen Pkws übersteigt. Aus gleichem Grunde liegt die Fahrleistung von Diesel-Pkws mit 19 700 km/a über der ihrer Pendanten mit Benzinmotor mit 12 050 km/a.

Abbildung 4.2 zeigt gute Übereinstimmungen bei den durchschnittlichen Ankunftszeiten an einem Ladepunkt zwischen den Simulationen und den Daten von ElaadNL.

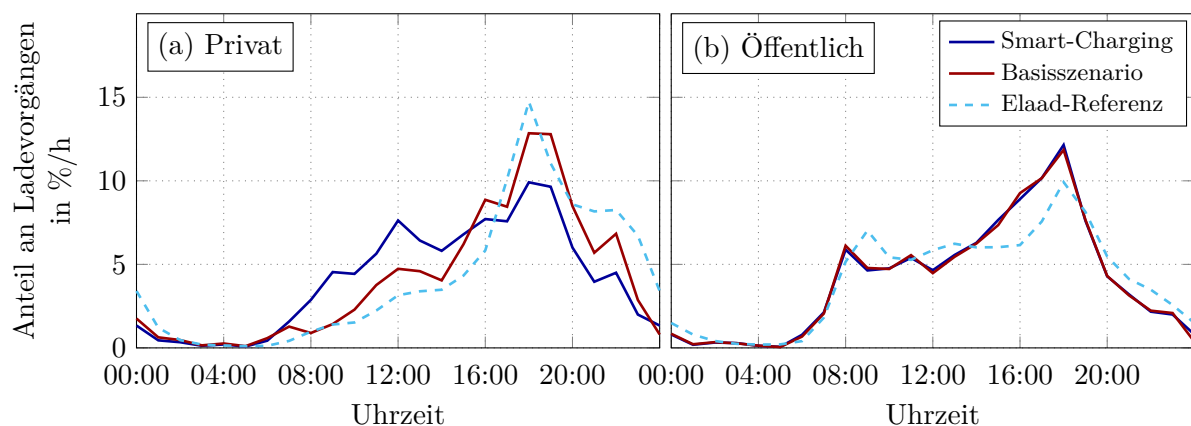


Abbildung 4.2.: Durchschnittliche Startzeit, zu dem ein Nutzer sein BEV mit einem (a) privaten oder (b) öffentlichen Ladepunkt verbindet.

In den Graphen in Abbildung 4.2 (a) zeigt sich das typische Verhalten privater BEV-Fahrer, die ihr Fahrzeug tagsüber, häufig zum Pendeln zum Arbeitsplatz, verwenden und es abends zum Laden mit ihrer privaten LE verbinden. Im Smart-Charging-Szenario wies der Aggregator seine Nutzer bevorzugt zur Mittagszeit an, Fahrzeuge mit der Wallbox zu verbinden. So wurden Flexibilitäten genutzt, um bevorzugt PV-Strom zu laden. Da die Batterien häufig nachts am privaten Punkt geladen und tagsüber durch Fahrten entladen wurden, wurden öffentliche Ladepunkte ebenfalls bevorzugt in den späten Nachmittagsstunden angefahren.

Gemessen an den Batteriegrößen werden bei einer Mehrzahl der Ladevorgänge an privaten LEs nur geringe Energiemengen geladen, die in etwa dem Fahrverbrauch des Tages entsprechen. In den simulierten Szenarien wurden häufiger kurze Ladevorgänge an privaten Ladepunkten vorgenommen, als von ElaadNL gemessen, wie Abbildung 4.3 verdeutlicht.

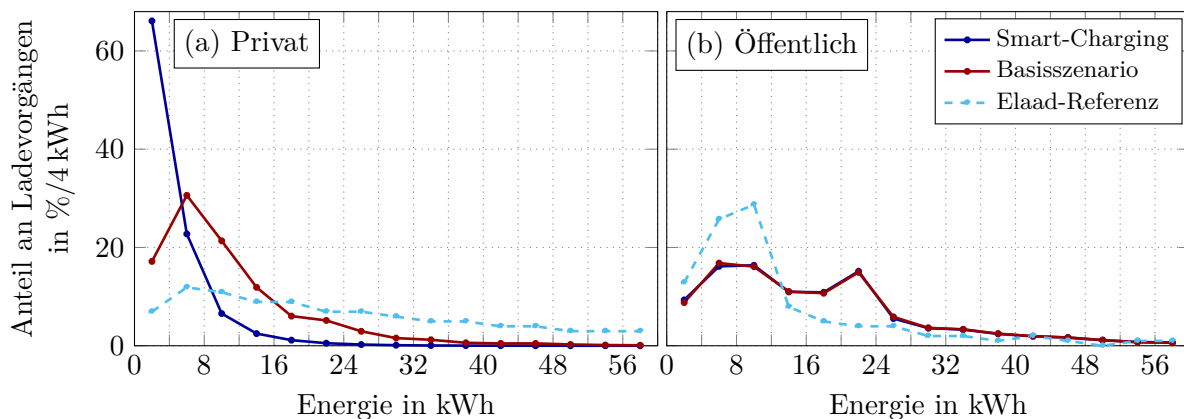


Abbildung 4.3.: Verteilung der Energie pro Ladevorgang an (a) privaten und (b) öffentlichen Ladepunkten. Ein Datenpunkt umfasst ein 4 kWh-Intervall.

Die von ElaadNL gemessene höhere Häufigkeit größerer geladener Energiemengen resultiert entweder aus höheren Fahrverbräuchen oder geringeren Ladehäufigkeiten. ElaadNL macht zu diesen Größen allerdings keine Angaben. Die hohe Anzahl geringfügiger Lademengen im Smart-Charging-Szenario ist wegen der zugenommenen Anzahl an Ladevorgängen plausibel. Es wird häufiger geladen, dafür sind die Zeitpunkte aus ökonomischer Perspektive günstiger.

Abbildung 4.4 deutet an, dass es für das Laden an privaten LEs zwei bevorzugte Zeitmotive beim Laden gibt. Elektroautos werden tagsüber kurz für zwei bis sechs Stunden mit dem Ladepunkt verbunden oder über die Nacht für zehn bis 16 Stunden. Im Smart-Charging-Szenario steigt der Anteil der kurzen Verbindungszeiten. Die Ursache liegt vor allem in der Eigenverbrauchsoptimierung von PV-Anlagen. Pro Kilowattstunde werden durch sie im Vergleich der drei Bezugsquellen die höchsten ökonomischen Vorteile erzielt. Entsprechend werden durch den Algorithmus tagsüber die Zeitfenster mit PV-Erzeugung so stark wie möglich zum Laden in Anspruch genommen. Da die Verbindungszeiten tagsüber durch das Fahrverhalten kürzer sind, steigt der Anteil kurzer Verbindungszeiten. In den Simulationen wurde angenommen, dass Nutzer nach dem Laden an öffentlichen LEs ihre Fahrt sofort fortsetzen, sobald sie genügend Energie geladen haben. Die modellierten Nutzer ließen in der Folge ihre Fahrzeuge deutlich kürzer mit öffentlichen Ladepunkten verbunden als von ElaadNL gemessen. Diese Abweichung dürfte nicht zu einer Verzerrung beim ökonomischen Vergleich zwischen Smart-Charging- und Basisszenario führen.

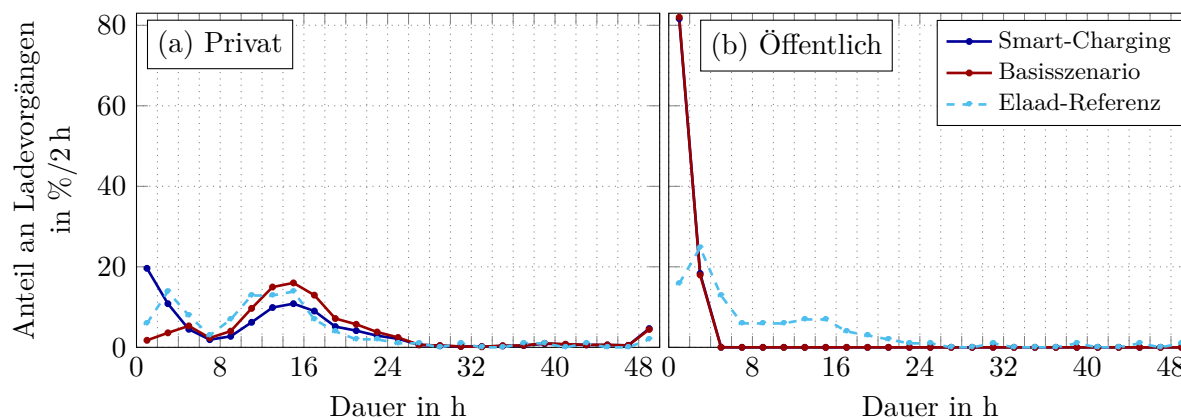


Abbildung 4.4.: Dauer der Verbindungszeit mit einem (a) privaten und (b) öffentlichen Ladepunkt. Ein Datenpunkt umfasst ein 2h-Intervall.

4.4. Auswertung der simulierten Lastprofile

4.4.1. Geplante Lastprofile

Ein entscheidender Faktor der Ladevorgangsoptimierung ist eine möglichst hohe Ladeflexibilität und damit möglichst hohe Ladeverfügbarkeit. Abbildung 4.5 (a) zeigt für die Primärsimulation in Abhängigkeit von der Uhrzeit den Anteil der Fahrzeuge, die an ihrem privaten Ladepunkt parken und deren Ladepunkt nicht gerade im Zuge des netzdienlichen Ladens durch den VNB blockiert wird, die also grundsätzlich zum Laden verfügbar sind.

In der Ladeverfügbarkeitskurve ist das typische Verhalten von Berufspendlern wiederzuerkennen. Während über die Nacht die meisten Fahrzeuge an ihrer Wallbox parken, nimmt die Ladeverfügbarkeit kurz vor den gängigen Zeiten des Arbeitsbeginns zwischen 7 Uhr und 9 Uhr ab. Die Abnahme am Vormittag wird durch die Teilnahme am netzdienlichen Laden verstärkt. Westnetz beginnt ab 7:30 Uhr, E.DIS ab 10:45 Uhr die LEs zu blockieren (vgl. Tabelle 3.4). Mit dem vorübergehenden Aufheben der Blockade ab 15:45 Uhr bei Westnetz steigt die Ladeverfügbarkeit zunächst sprunghaft und mit dem Zurückkehren von den Arbeitsplätzen auch systematisch wieder an. An Wochenenden fällt die Ladeverfügbarkeit tagsüber erwartungsgemäß weniger stark ab als an Wochentagen. Unter der Woche fällt sie kurz vor Mittag auf 20%, an Wochenenden unterschreitet sie zu dieser Zeit nicht die 40%-Marke, wie Abbildung A.5 im Anhang zeigt.

Im Smart-Charging-Szenario ist das Lastprofil der Flotte in erster Linie eine Funktion aus der Ladeverfügbarkeit, den Preisen des Spot- und Regelleistungsmarktes sowie der PV-Erzeugungsleistung. Abbildung 4.5 (b) zeigt die Lastprofile nach Bezugsquelle, die sich ergäben, wenn die Planung der Optimierung um 8:00 Uhr ohne Abweichungen umgesetzt werden würde. In diesen Planungen sind noch nicht die Ergebnisse der Regelleistungsmarktauktionen berücksichtigt. In der Folge würden 61,1% des Strombezuges an privaten Ladepunkten aus der Erbringung negativer Regelarbeit stammen, 21,9% von den PV-Anlagen und 17,1% vom Spotmarkt.

Als Folge von Nebenbedingung 6 in Gleichung 3.15 des Optimierungsproblems ist in der Kurve der Regelarbeit das Konstanthalten der Ladeleistung für die vierstündigen Zeitscheiben klar




Abbildung 4.5.: Ladeverfügbarkeit der Flotte und geplantes Lastprofil der Optimierung um 8:00 Uhr. Beim gezeigten Lastprofil wurden nur die Planungen für den Tag $d + 1$ betrachtet. Die Kurve „Summe“ gleicht den summierten Ladeleistungen der drei Bezugsquellen. Ihr Farbverlauf entspricht dem Anteil der Bezugsquellen an der summierten Ladeleistung im Tagesverlauf.

ersichtlich. Wegen der hohen Ladeverfügbarkeit in der ersten Zeitscheibe des Tages und der niedrigen Spotmarktpreise, ergeben sich für diesen Zeitraum die höchsten Ladeleistungen aus den Bezugsquellen $q = 1$ und $q = 3$. Der Bezug von PV-Strom folgt zeitlichen der Intensität der Sonneneinstrahlung.

Abbildung A.4 zeigt im Anhang die Lastprofile aller Optimierungsschritte. Insgesamt gibt es keine nennenswerten systematischen Unterschiede zwischen den Lastprofilen der verschiedenen Uhrzeiten. Mit der Bekanntgabe der Ergebnisse der Regelleistungsauktionen sinkt in den Optimierungen um 12:00 Uhr der geplante Bezug von Regelarbeit geringfügig. Der Anteil der Regelarbeit an der gesamten Ladeleistung nimmt in den Optimierungen um 12:00 Uhr auf 57,4% ab. Dies geschieht aufgrund von Geboten, die per Regelleistungspreis nicht erfolgreich waren. Durch die Niedrigpreisstrategie waren 89,1% der Regelleistungsgebote erfolgreich. Tabelle A.2 listet im Anhang die Anteile der Bezugsquellen an der gesamten Ladeleistung nach den Optimierungsschritten des Algorithmus 1 auf.

In den Optimierungen um 4:00 Uhr deuten sich bereits die in Abschnitt 2.1.3.3 erläuterten Nachholeffekte an. Der Aggregator geht in den vorausplanenden Optimierungen davon aus, dass seine erfolgreich vermarktete Regelleistung vollständig in Form von Regelarbeit abgerufen wird. In der Primärsimulation werden allerdings nur 80,4% der eingeplanten Regelarbeit tatsächlich abgerufen. Als Konsequenz muss der Aggregator kurzfristig am Intraday-Markt Stromprodukte beschaffen, um die fehlende Energiemenge auszugleichen.

4.4.2. Reale Lastprofile

In Abbildung 4.6 (a) wird das Lastprofil des Basisszenarios mit dem Lastprofil der Jedlix-Nutzer verglichen, die die Smart-Charging-Funktion deaktiviert hatten [43, S. 8]. Im Vergleich mit den niederländischen Jedlix-Fahrern, ist das simulierte Lastprofil um rund vier Stunden zeitlich nach vorne versetzt. Das simulierte Lastprofil ist direkt von den Ankunftszeiten am privaten Ladepunkt abhängig (vgl. Abbildung 4.2). Es zeigt tagsüber durch eine geringe Ladeverfügbarkeit eine kleine Ladeleistung, die ab dem Nachmittag mit der Rückkehr der Berufspendler ansteigt. Sein Maximum erreicht es in den frühen Abendstunden um 19 Uhr. In der Nacht fällt mit zunehmend vollgeladenen Batterien die Ladeleistung ab. Im Mittel wurde der Energiebedarf an privaten Ladepunkten zu 82,6 % durch Strom vom Spotmarkt und zu 17,4 % aus den PV-Anlagen bedient.




Abbildung 4.6.: Lastprofile der Primärsimulation für das Basis- und Smart-Charging-Szenario. Zum Vergleich werden die gemessenen Lastprofile von Jedlix gezeigt. Sie stammen von [43] und wurden so skaliert, dass die geladene Energiemenge dem jeweiligen summierten Lastprofil der Simulation gleicht.

Das reale Lastprofil des Smart-Charging-Szenarios ist das Ergebnis der operativen Optimierung. An privaten Ladepunkten wurde der Energiebedarf zu 24,5 % aus Spotmarktprodukten, zu 23,4 % aus PV-Strom und 52,1 % durch Regalarbeit gedeckt. Im Vergleich zu den 8:00 Uhr und 12:00 Uhr Optimierungen hat sich aus den besagten Gründen der Regalarbeitsanteil weiter verringert und der Spotmarktanteil erhöht. Abbildung A.6 zeigt den Anteil der drei Strombezugsquellen im Jahresverlauf. In den Sommermonaten verdoppelt sich der PV-Anteil verglichen mit dem Winter.

Der Bezug von Regalenergie muss während einer Zeitscheibe wegen schwankender Abrufhöhen nicht konstant sein. Die vier Stunden umfassenden Stufen der Regalarbeitskurve sind daher nur noch schemenhaft zu erkennen. Im Vergleich zum Basisszenario wurde ein wesentlicher Anteil der

Ladeleistung von den Abendstunden in die Nachtstunden verschoben. Im Bezug auf das Lastprofil des Netzverbundes (vgl. Abbildung 3.4) wirkt die ökonomische Optimierung in Richtung einer Glättung des Strombedarfs. Der Korrelationskoeffizient für die Last der gesteuerten Flotte und die Netzlast beträgt über das simulierte Jahr $-0,155$, während er für die ungesteuerte Flotte bei $0,198$ liegt.

Wird nur der Strombezug vom Spotmarkt ($q = 1$) betrachtet, sinkt die Korrelation der Ladeleistung mit den Spotmarktpreisen von $0,22$ im Basis- auf $-0,11$ im Smart-Charging-Szenario. Die ökonomische Optimierung führt allerdings nicht nur zu geringeren Preisen, sondern unterstützt auch die Integration der EE in das Stromsystem. Im Basisszenario korreliert der Strombezug vom Spotmarkt mit $-0,21$ mit dem Anteil der EE am deutschen Strommix. Durch das Smart Charging steigt der Wert auf $0,05$, wird zusätzlich der Bezug von Regularbeit berücksichtigt, liegt die Korrelation noch bei $-0,04$. PV-Anlagenbesitzer konnten ihren Eigenverbrauch um durchschnittlich 308 kWh/a steigern. Im Smart-Charging-Szenario wurden die Fahrzeuge folglich mit einem höheren Anteil an Grünstrom geladen.

Das reale Lastprofil weist deutliche Ähnlichkeiten mit dem Smart-Charging-Lastprofil von Jedlix auf. Im Gegensatz zum Jedlix-System wurde zusätzlich hinsichtlich der PV-Erzeugungsleistung optimiert, sodass das Optimierungssystem dieser Arbeit zu einer höheren Ladeleistung tagsüber führt. Der Datensatz von Jedlix stammt aus dem Jahr 2018. Zu dieser Zeit war das Unternehmen vor allem in den Niederlanden aktiv. Das Lastprofil dürfte stark oder ausschließlich von Ladevorgängen in den Niederlanden geprägt sein. Der frühere Anstieg der Ladeleistung in den Abendstunden und das spätere Abfallen in den Morgenstunden ist mit hoher Wahrscheinlichkeit auf das niederländische Regelleistungsmarktdesign zurückzuführen. Im niederländischen Markt dauert eine Zeitscheibe lediglich 15 min . Jedlix kann damit flexibler die Ladeleistung für die Erbringung von Regularbeit allokkieren.

4.5. Auswertung der Regelleistungsmarktinteraktion

In diesem Unterkapitel werden zu den Ergebnissen der Primärsimulation auch die Ergebnisse der Sekundärsimulation herangezogen. Bei der Interpretation der Ergebnisse muss der verkürzte Simulationszeitraum der Sekundärsimulation berücksichtigt werden.

Mit einer höheren Anzahl an Nutzern kann am Regelleistungsmarkt mehr Leistung angeboten werden. Abbildung 4.7 zeigt das Lastprofil der Sekundärsimulation. Im Durchschnitt umfasste ein SRL-Angebot in der Sekundärsimulation $21,6 \text{ MW}$ und lag damit um einen Faktor $5,7$ höher als in der Primärsimulation im gleichen Zeitraum. Damit stieg die angebotene Leistung stärker als die Flottengröße. $3,4\%$ der SRL-Angebote waren kleiner als 1 MW . In der Primärsimulation lag der Anteil bei $27,1\%$. Ohne VPP hätte die Flotte in diesem Fall nicht am Regelleistungsmarkt teilnehmen können. Die Leistungsverteilung auf die Zeitscheiben ist zeitlich stark asymmetrisch. In der Sekundärsimulation wurden für die erste Zeitscheibe eines Tages im Mittel $49,2 \text{ MW}$ angeboten, für die dritte nur $2,7 \text{ MW}$. Verantwortlich dafür sind der Verlauf der Ladeverfügbarkeit (vgl. Abbildung 4.5 (a)) und zu einem geringeren Anteil auch die Preisverläufe für Regelleistung und Regularbeit (vgl. Abbildung 3.6).




Abbildung 4.7.: Reales Lastprofil der Sekundärsimulation. Es wurden 100 000 Nutzer im Zeitraum vom 01.09.2019 bis zum 24.09.2019 simuliert.

In der Primärsimulation gab der Aggregator für 93,1 % der Zeitscheiben Angebote ab, von denen 89,1 % Erfolg hatten. In 77,2 % aller Viertelstundenintervalle, für die der Aggregator aufgrund eines erfolgreichen Angebots Regelleistung vorgehalten hat, wurde er zur Erbringung von Regelarbeit angewiesen. Damit hat die gewählte Niedrigpreisstrategie zu einer hohen Erfolgsquote in den Regelleistungsauktionen geführt. Für den Zeitraum der Sekundärsimulation ergaben sich keine Unterschiede hinsichtlich des Erfolges am Regelleistungsmarkt. Zu keinem Zeitpunkt konnte der Aggregator das Sollsignal der ÜNBs nicht erfüllen. Das Eintreten von Fall 4 des Algorithmus 2 (vgl. Abschnitt 3.6.2) war in anderen Simulationen erst bei deutlich kleineren Flottengrößen im dreistelligen Bereich zu beobachten.

Differenzen ergaben sich beim Anteil der abgerufenen Regelarbeit bezogen auf die vorgehaltene Leistung. Über den Zeitraum der Sekundärsimulation wurden in der Primärsimulation 85,4 % der vorgehaltenen Leistung durch die ÜNBs abgerufen. Zumindest für die Primärsimulation ist die im Optimierungsproblem gesetzte Annahme, dass die vorgehaltene Regelleistung vollständig in Form von Regelarbeit abgerufen wird, daher durchaus valide. Bei der fünf Mal größeren Flotte in der Sekundärsimulation lag der Anteil lediglich bei 64,9 %. Mit zunehmender Flottengröße kannibalisieren sich die Fahrzeuge hinsichtlich des Bezugs von Regelarbeit gegenseitig. Die Regelleistungs-, insbesondere aber die Regelarbeitsmarktvolumina sind nicht groß genug, um das Angebot sehr großer Flotten konstant und zuverlässig durch eine entsprechende Nachfrage zu decken. Mit den geringeren Abrufen sinkt der Anteil der Regelarbeit am Strombezugsmix. Lag der Anteil der privat geladenen Energie über den Sekundärsimulationszeitraum in der Primärsimulation noch bei 62,4 %, sank er in der Sekundärsimulation auf 54,0 % zugunsten des Spotmarktes.

Tabelle 4.3.: Vergleich der durchschnittlichen Preise für negative Sekundärregelleistung und -arbeit. Die Durchschnitte stellen die tatsächlich gezahlten Vergütungen (Leistung) bzw. Kosten (Arbeit) dar, nicht die Gebotspreise.

Simulation	Primär		Sekundär	
	Aggregator	Markt	Aggregator	Markt
Regelleistungspreis [€/MW]	2,53	6,31	0,49	0,94
Regelarbeitspreis [€/MWh]	-10,69	-3,20	-14,65	-6,97

Tabelle 4.3 zeigt, dass der Aggregator durch seine Niedrigpreisstrategie die Marktpreise für Regelleistung und Regelarbeit deutlich unterbot. Die Unterbietung ist das Ergebnis der ökonomischen Optimierung der Parameter $\alpha_P^{\text{SRL,Ang}}$ und $\alpha_W^{\text{SRL,Ang}}$.

Durch die Abbildung der Regelleistungsmarktmechanismen auf Basis der realen Marktdaten lässt sich der Einfluss des Aggregators auf die Marktpreise bestimmen. Dazu werden die Regelleistungsauktionen und die Regelarbeitsallokation einmal mit den Geboten des Aggregators und einmal ohne sie simuliert. In der Sekundärsimulation führten die Aktivitäten des Aggregators zu einem Rückgang der ausgezahlten Vergütungen für die Vorhaltung negativer SRL um 4,3%. Die entsprechenden Regelarbeitsvergütungen fielen um 8,0%. Über ein Jahr hinweg würden sich die Ersparnisse der ÜNBs auf 1,7 Mio. € belaufen. Die Rückgänge in der Primärsimulation im Zeitraum der Sekundärsimulation lagen bei 0,8% (Leistung) und 1,6% (Arbeit). Noch größer war der Einfluss auf die Preise während der ersten Zeitscheibe des Tages. In der Sekundärsimulation fielen hier die ausgezahlten Leistungspreise um 6,5% und die ausgezahlten Arbeitspreise um 11,5%. An dieser Stelle zeigt sich, warum ein Preis-Taker-Ansatz für den Regelleistungsmarkt bei großen Flotten keine valide Annahme mehr ist. Bereits bei 100 000 partizipierenden BEVs werden die Marktpreise merklich beeinflusst.

4.6. Finanzielle Auswertung des Optimierungssystems

4.6.1. Auswertung der Ladeenergiekosten

Tabelle 4.4 vergleicht die geladene Energiemenge und deren Kosten nach Bezugsquelle und Szenario. Im Smart-Charging-Szenario betragen die durchschnittlichen Energiekosten 27,25 ct/kWh. Im Basisszenario fielen sie mit 31,49 ct/kWh mehr als 4 ct/kWh höher aus. Damit konnten die Ladeenergiekosten pro Nutzer von 925,74 €/a auf 802,54 €/a reduziert werden. In den Ladeenergiekosten sind allerdings noch nicht Zusatzkosten berücksichtigt, die durch den nötigen Einbau von iMSys anfallen können. Diese werden in Abschnitt 4.6.2 untersucht. In beiden Szenarien entfiel rund ein Viertel der Ladekosten auf öffentliche Ladevorgänge.

Tabelle 4.4.: Geladene Energie und Ladekosten aufgeschlüsselt nach Bezugsquelle für das Smart-Charging- und das Basisszenario.

Szenario	Basis		Smart Charging	
	Geladene Energie in kWh/Tag/Fzg.	Energiekosten in ct/kWh	Geladene Energie in kWh/Tag/Fzg.	Energiekosten in ct/kWh
Spotmarkt	5,51	32,21	1,63	28,92
PV	1,16	15,30	1,57	14,69
Regelarbeit	-	-	3,47	26,22
Öffentliche LE	1,39	42,15	1,40	42,20
	Σ 8,06	\varnothing 31,49	Σ 8,07	\varnothing 27,25

Tabelle 4.5 schlüsselt die Daten von Tabelle 4.4 nach Nutzertyp auf. In keinem der beiden Szenarien führte die Teilnahme am netzdienlichen Laden zu einem höheren Bedarf an Ladevorgängen an

öffentlichen LEs. In beiden Szenarien sanken die durchschnittlichen Ladekosten durch die Anmeldung der privaten LE als steuerbare Verbrauchseinrichtung um rund 3,8 ct/kWh. Bezogen alleine auf den Strombezug vom Spotmarkt oder durch Regelarbeit führten die verringerten NNE zu geringeren Kosten i. H. v. rund 4,6 ct/kWh.

Tabelle 4.5.: Geladene Energie und Ladekosten nach Nutzertyp aufgeschlüsselt nach Bezugsquelle für das Smart-Charging- und das Basisszenario. Die geladene Energie wird pro Tag und Fahrzeug angegeben. Die Spalte „Normal“ umfasst alle Nutzer ohne PV-Anlage und ohne Teilnahme am netzdienlichen Laden. Die Spalten „PV-Anlage“ und „§ 14a EnWG“ beziehen sich entsprechend auf Nutzer, die eine PV-Anlage betreiben bzw. am netzdienlichen Laden partizipieren.

Smart-Charging-Szenario						
Nutzer	Normal		PV-Anlage		§ 14a EnWG	
	Energie in kWh	Kosten in ct/kWh	Energie in kWh	Kosten in ct/kWh	Energie in kWh	Kosten in ct/kWh
Spotmarkt	2,10	30,99	1,18	31,06	2,07	26,32
PV	-	-	3,14	14,69	-	-
Regelarbeit	4,61	28,37	2,42	28,28	4,47	23,70
Öffentl. LE	1,41	42,22	1,39	42,33	1,42	42,03
	Σ 8,11	\varnothing 31,45	Σ 8,13	\varnothing 25,82	Σ 7,96	\varnothing 27,65

Basisszenario						
Nutzer	Normal		PV-Anlage		§ 14a EnWG	
	Energie in kWh	Kosten in ct/kWh	Energie in kWh	Kosten in ct/kWh	Energie in kWh	Kosten in ct/kWh
Spotmarkt	6,71	32,24	4,34	32,31	6,42	27,71
PV	-	-	2,30	15,30	-	-
Öffentl. LE	1,41	42,23	1,36	42,07	1,30	41,96
	Σ 8,12	\varnothing 33,97	Σ 8,00	\varnothing 29,09	Σ 7,72	\varnothing 30,11

Im Basisszenario konnten die PV-Anlagenbesitzer 28,8 % der Ladeenergie aus ihrer Anlage bedienen, im Smart-Charging-Szenario stieg der Anteil auf 38,6 %. Werden öffentliche Ladevorgänge außen vorgelassen, betragen die Anteile 34,7 % im Basis- und 46,5 % im Smart-Charging-Szenario. Im Szenariovergleich zeigt sich, dass bei Nutzern mit PV-Anlage das meiste Optimierungspotenzial vorliegt. Ihre durchschnittlichen Ladekosten konnten um 3,27 ct/kWh bzw. rund 97 €/a reduziert werden. Teilnehmer des netzdienlichen Ladens zahlten im Smart-Charging-Szenario 2,46 ct/kWh (73 €/a) weniger und bei allen anderen Nutzern lag die Reduzierung bei 2,52 ct/kWh (74 €/a). Dass die Ladekostenreduktionen pro Nutzertyp deutlich unter der Ladekostenreduktion vom Basisszenario zum Smart-Charging-Szenario liegt, resultiert aus dem deutlich höheren Anteil an Nutzern, die im Smart-Charging-Szenario am netzdienlichen Laden partizipieren. Pro Jahr reduzierte die Teilnahme am netzdienlichen Laden die Ladeenergiekosten um rund 110 €.

Neben den oben definierten Nutzertypen hat insbesondere das Fahrprofil der Nutzer Einfluss auf die Höhe der Ladekostenreduktion durch Smart-Charging. Abbildung 4.8 zeigt die Ladekos-

tenersparnisse, die durch Smart Charging im Vergleich zum Basisszenario erzielt wurden in Abhängigkeit der insgesamt geladenen Energiemenge eines Fahrzeugs. Dazu wurden die Fahrzeuge in 1 MWh/a breite Intervalle geclustert. Die Ladekostendifferenz ist der Mittelwert aller Fahrzeuge eines Intervalls. Die Kurve mit den punktförmigen Markierungen zeigt die totalen Ersparnisse pro Jahr und bezieht sich auf die linke Achse. Die Kurve mit den rautenförmigen Markierungen gibt die Ersparnisse pro geladener Energiemenge an. Sie bezieht sich auf die rechte Achse. Die Farben der Kurven zeigen die Anzahl der unterschiedlichen Fahrprofile an, die von einem Intervall abgedeckt werden. Die Intervalle > 7 MWh/a repräsentieren jeweils weniger als acht der 88 individuellen Fahrprofile und sind aufgrund der geringen Stichprobengröße weniger aussagekräftig.

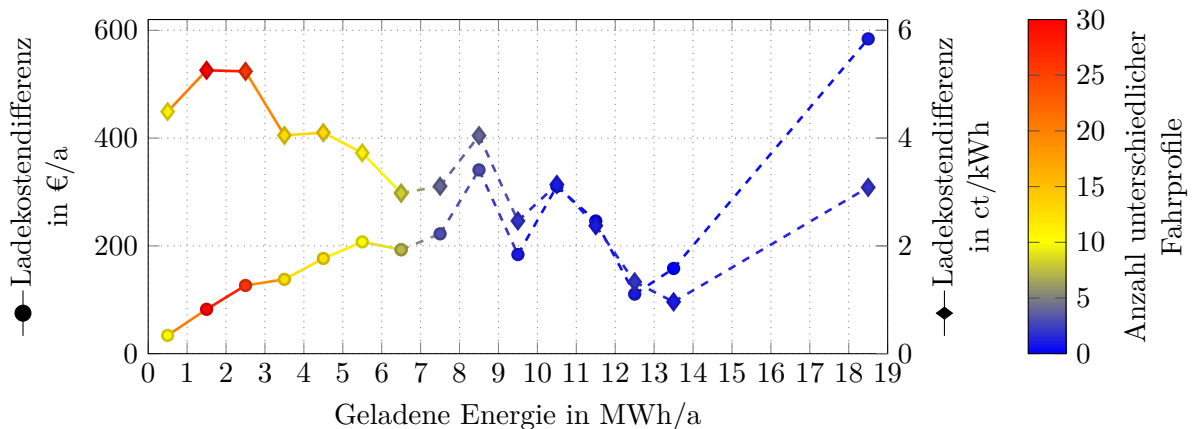


Abbildung 4.8.: Reduktion der Ladekosten pro Jahr und Fahrzeug vom Basisszenario zum Smart-Charging-Szenario in Abhängigkeit der geladenen Energiemenge.

In der Abbildung ist erkennbar, dass bis 7 MWh/a geladene Energie die Ersparnisse mit der Energiemenge deutlich steigen. Nutzer, deren Energiebedarf kleiner ist als 1 MWh/a, sparen durch das Smart-Charging-System im Durchschnitt lediglich rund 34 €/a an Ladekosten. Bei Energiebedarfen zwischen 5 MWh/a und 6 MWh/a steigt der Vorteil auf 207 €/a. Bei den höheren Intervallen ab 7 MWh/a ist die Stichprobengröße zu gering und der Trend zu unklar, als dass sich sichere Aussagen bzgl. des weiteren Verlaufes treffen ließen. Ein Ladebedarf von 7 MWh/a entsprechen mit den 19,5 kWh/100km Fahrverbrauch (vgl. Tabelle 4.2) rund 36 000 km/a. Die vorherigen Intervalle decken daher die allermeisten realen Nutzungsfälle ab. Das letzte dargestellte Intervall zeigt allerdings, dass bei Nutzern mit günstigen Fahrprofilen und hohen Energiebedarfen Ersparnisse i. H. v. 600 €/a möglich sind. Das Intervall wird von zwei Fahrprofilen, die für insgesamt 54 Nutzer mit ansonsten unterschiedlichen Eigenschaften verwendet wurden, repräsentiert.

Während bei höheren Energieumsätzen der absolute Kostenvorteil steigt, nimmt das Einsparpotenzial pro Energiemenge tendenziell ab, wie die zweite Kurve der Abbildung 4.8 zeigt. Das hat drei Ursachen. Erstens nehmen bei höheren Energiebedarfen die Ladezeiten zu. Längere Ladezeiten führen zu einer geringeren Konzentration auf Zeitpunkte, in denen der Strombezug vom Spotmarkt oder durch Regularbeit besonders günstig ist. Zweitens sinkt die Eigenverbrauchsquote von PV-Anlagenbesitzern. Drittens weisen Fahrzeuge mit höheren Energiebedarfen höhere Fahrleistungen und damit geringere Standzeiten auf. Dadurch sinkt ihr Flexibilitätspotenzial.

4.6.2. Untersuchung möglicher Zusatzkosten durch den Bedarf an intelligenten Messsystemen

Beschaffungskosten für Stromprodukte vom Spotmarkt können durch DSM erst reduziert werden, wenn der Verbrauch nicht mehr nach einem SLP, sondern per Zählerstandgangsmessung viertelstundengenau abgerechnet wird (vgl. Abschnitt 2.1.1.3). Mangels der bisherigen Berücksichtigung von BEVs in den Präqualifikationsbedingungen für den Regelleistungsmarkt ist es zum jetzigen Zeitpunkt unklar, ob die ÜNBs die Abrechnung der erbrachten Regelarbeit über die nicht-eichrechtskonformen Messungen per Fahrzeug-BMS oder LE zulassen oder auch auf ein iMSys bestehen. Nutzer, die keinen Jahresstromverbrauch über 6000 kWh aufweisen, nicht über eine PV-Anlage mit installierter Leistung größer 7 kW verfügen und bei denen sich der grundzuständige Messstellenbetreiber nicht für den optionalen Einbau eines iMSys entscheidet, können einen anderen Messstellenbetreiber als den grundzuständigen mit dem Einbau eines iMSys beauftragen (freie Wahl des Messstellenbetreibers). Verglichen mit einer mME oder einem Ferraris-Zähler entstehen für den Nutzer in diesem Fall zusätzliche Messbetriebskosten, die nicht von den Obergrenzen gemäß § 31 MsbG gedeckelt werden.

Für die Partizipation am netzdienlichen Laden ist ein weiteres iMSys als separater Zählpunkt notwendig (vgl. Abschnitt 2.1.1.3). Nutzer, bei denen der grundzuständige Messstellenbetreiber den Einbau eines iMSys verordnet haben, müssen beim Einbau eines zweiten iMSys für das netzdienliche Laden insgesamt nur die höchste fallbezogene Preisobergrenze bezahlen. Für einen Nutzer mit einem Jahresstromverbrauch über 6000 kWh oder einer PV-Anlage mit installierter Leistung über 7 kW entstünden daher insgesamt keine Zusatzkosten, weder durch die Teilnahme am netzdienlichen Laden, noch durch den Austausch einer mME durch ein iMSys zur Zählerstandgangsmessung. Für einen Nutzer, der für den Einbau eines iMSys den Messstellenbetreiber wechseln muss, können im schlechtesten Fall sowohl zusätzliche Messstellenbetriebskosten für zwei iMSys anfallen, die sich auf mehr als 200 €/a summieren können. Müssen für den Einbau eines zweiten Zählers Änderungen am Zählerschrank vorgenommen werden, können Umrüstkosten anfallen, die je nach Fall durchaus im vierstelligen Euro-Bereich liegen können. Sind Umrüstungsarbeiten notwendig, ist eine Amortisation angesichts der rund 110 €/a, um die sich die Ladeenergiekosten durch verringerte NNE im Durchschnitt reduzieren, nur über einen äußerst langfristigen Zeitraum möglich.

Damit kann festgehalten werden, dass sich Smart Charging insbesondere für PV-Anlagenbesitzer lohnt, die auch ohne iMSys vom gesteigerten Eigenverbrauch profitieren. Außerdem besteht hoher ökonomischer Nutzen für jene Nutzer, bei denen der grundzuständige Messstellenbetreiber bereits ein iMSys eingebaut hat. Für nicht wenige BEV-Fahrer wird dieser Fall in den kommenden Jahren eintreffen. Der durchschnittliche Stromverbrauch eines Haushalts lag in Deutschland im Jahr 2018 bei 3113 kWh/a [92]. Wird der Strombedarf für das private Laden des BEVs hinzugeaddiert, überschreiten 28 % der simulierten Nutzer die Grenze von 6000 kWh/a. Bei 63,7 % aller PV-Anlagen in Deutschland liegt die Peakleistung über 7 kW [93]. Für alle anderen Nutzer ist die Rentabilität von Smart Charging von ihren Eigenschaften abhängig. Fallen statt den 20 €/a an Messstellenbetriebskosten für die mME 100 €/a für das iMSys an, nur um am Smart-Charging-System teilnehmen zu können, müssen die Nutzereigenschaften ein Flexibilitätspotenzial im Wert von deutlich mehr als 80 €/a hergeben.

4.6.3. Untersuchung des netzdienlichen Ladens für PV-Anlagenbesitzer

Auch wenn der Eigenverbrauch durch die Verwendung einer Kaskadenschaltung weiterhin möglich ist (vgl. 2.1.5.2), zahlt sich die Teilnahme am netzdienlichen Laden bislang nur für einen Teil der PV-Anlagenbesitzer aus. Dieser Umstand wurde in zwei Simulationen mit 1000 Nutzern untersucht. In der ersten Simulation nahmen die PV-Anlagenbesitzer am netzdienlichen Laden teil, in der zweiten Simulation mit den ansonsten eigenschaftsgleichen Nutzern nicht.

Durch das netzdienliche Laden sanken zwar die Kosten für den Strombezug vom Spotmarkt und per Regelarbeit in Höhe der Angaben aus Tabelle 4.4. Gleichzeitig sank der bezogene PV-Strom um 53,7%. In der Summe waren die Ladeenergiekosten in beiden Szenarien fast identisch. Für 52% der PV-Anlagenbesitzer sanken die Ladeenergiekosten durch das netzdienliche Laden, für die andere Hälfte nahmen sie zu. Erwartungsgemäß profitieren vom netzdienlichen Laden insbesondere jene PV-Anlagenbesitzer, die einen hohen Energiebedarf aufweisen. Der Energiebedarf korreliert mit 0,443 mit der Kostenreduktion durch das netzdienliche Laden. Keine Korrelation ergab sich mit der Erzeugungsleistung der Anlage.

Wird berücksichtigt, dass für Anlagenbetreiber, deren installierte Leistung kleiner als 7 kW ist, Zusatzkosten für den Einbau eines iMSys anfallen können, müssen die PV-Anlagenbesitzer durch das netzdienliche Laden rund 15 €/a mehr bezahlen als ohne. Auch in diesem Fall entscheiden die Nutzeigenschaften über die Profitabilität. Mit Berücksichtigung zusätzlicher iMSys-Kosten ist die Teilnahme am netzdienlichen Laden für die Mehrheit der PV-Anlagenbesitzer nicht ökonomisch sinnvoll. Der erhöhte Anteil bezogener Regelarbeit steigert zudem die Kannibalisierungseffekte innerhalb der Flotte. Die PV-Anlagenbesitzer bezogen durch das netzdienliche Laden mehr Regelarbeit, für alle anderen Nutzer blieb dadurch weniger Regelarbeit übrig, sodass sie mehr des teureren Spotmarktstroms beziehen mussten.

4.6.4. Untersuchung verkürzter Regelleistungszeitscheiben

In einer Simulation mit 1000 Nutzern wurden die Folgen der Aufhebung der vierstündigen Zeitscheibenkonstanz auf $T_{\text{Cons}} = \{1 \text{ h}, 15 \text{ min}\}$ untersucht. In beiden Fällen stieg der Bezug von Regelarbeit gegenüber $T_{\text{Cons}} = 4 \text{ h}$ nicht merklich an. Die Ladeenergiekosten blieben weitestgehend unverändert. Im Gegensatz zur Smart-Charging-Referenz von Jedlix (vgl. Abbildung 4.6 (b)) dehnte sich der Zeitraum hoher Ladeleistungen in den Nachtstunden nicht aus. Vielmehr konzentriert sich ein größerer Anteil der angebotenen Regelleistung auf die ersten vier Stunden des Tages. Ursache hierfür sind die höheren Regelleistungsvergütungen und etwas geringeren Regelarbeitskosten während dieses Zeitraums (vgl. Abbildung 3.6). Durch die höhere Konzentration sank der Anteil der abgerufenen Regelarbeit bezogen auf die vorgehaltene Regelleistung durch Kannibalisierungseffekte, sodass sich diese Kostenvorteile nicht auszahlten. Abbildung A.7 im Anhang zeigt die drei Lastprofile für $T_{\text{Cons}} = \{4 \text{ h}, 1 \text{ h}, 15 \text{ min}\}$ im Vergleich.

5. Abschließende Betrachtungen

5.1. Zusammenfassung

In dieser Arbeit wurde ein Algorithmus entwickelt, der durch die Planung der Ladevorgänge einer aggregierten BEV-Flotte ihre Ladeenergiekosten minimiert. Der Algorithmus wurde in ein Optimierungssystem eingebettet und mittels Simulationen untersucht.

Zunächst wurden in Kapitel 2 die stromwirtschaftlichen und technischen Grundlagen betrachtet, damit das Optimierungssystem die realen Regularien, Mechanismen und technischen Möglichkeiten abbildet, um aussagekräftige Ergebnisse bzgl. des ökonomischen Potenzials und der Auswirkungen des Systems zu erhalten. Dabei wurden insbesondere Hürden für den Praxiseinsatz durch die geringe Verbreitung von iMSys deutlich. Anschließend wurden Regressionsmodelle und die lineare Optimierung behandelt, um darauf aufbauend im folgenden Kapitel ein Prognosemodell für die Preise des Day-Ahead-Marktes und den Algorithmus zur Ladevorgangsoptimierung zu entwickeln. Ein Literaturüberblick zeigte, dass die lineare Programmierung eine der häufigsten Methoden zur Entwicklung von Smart-Charging-Algorithmen ist. Außerdem wurde deutlich, dass in anderen Studien die kombinierte Optimierung aus PV-Eigenverbrauch und Strommärkten bisher noch nicht untersucht wurde.

Anschließend wurden in Kapitel 3 das Optimierungssystem und der Algorithmus entwickelt. Ein Aggregator steuert unter der Verwendung eines zweistufigen Optimierungskonzepts die Ladevorgänge seiner Systemnutzer. Basierend auf mehreren externen Datensätzen wurde jeder Nutzer mit einem individuellen Set an Eigenschaften, bestehend aus einem BEV und einem passenden Nutzungsprofil, einem privaten Ladepunkt, einem Stromvertrag sowie einem Tarif für die Nutzung der öffentlichen Ladeinfrastruktur, modelliert. Das ARX-Spotmarktprognosemodell verwendet Prognosen über die Last und Erzeugungsleistung im Netzverbund als exogene Variablen. Unter Nutzung der realen Marktdaten wurde der deutsche SRL-Markt modelliert. Der Aggregator partizipiert in ihm mit einer Niedrigpreisstrategie. Der erste Algorithmus berechnet auf Basis linearer Programmierung im Voraus die optimalen Ladezeitpunkte und -leistungen einer Flotte aus BEVs. Der Optimierung zugrunde liegen die Minimierung der Strombeschaffungskosten über den Spotmarkt, die Maximierung des PV-Eigenverbrauchs und dem Angebot von negativer SRL. Zudem berücksichtigt der Aggregator die Teilnahme am netzdienlichen Laden gemäß § 14a EnWG eines Teils seiner Nutzer. Der zweite Algorithmus passt den auf Prognosen basierenden Ladeplan des ersten Algorithmus in Echtzeit an die realen Gegebenheiten an.

In Kapitel 4 wurden das Prognosemodell und das Optimierungssystem ausgewertet. Das ARX-Prognosemodell weist einen MAE von 5,25 €/MWh und einen mMAPE von 17,8% auf. Anschließend wurden die simulierten Nutzungsprofile mit realen Datenquellen verglichen. Das simulierte Nutzerverhalten zeigt im Basisszenario weitestgehende Ähnlichkeiten zu den Angaben externer Quellen auf. Die ermittelten Lastprofile zeigen, dass die ökonomische Ladevorgangsoptimierung zu einer Glättung der Netzlast, einer Steigerung des PV-Eigenverbrauchs und einem Anstieg

des geladenen Grünstroms beiträgt. Die ökonomische Optimierung kann durch die vorliegenden marktwirtschaftlichen Anreize damit sowohl einen Beitrag zur Integration der EE in das Stromnetz als auch zur Stabilisierung des Stromsystems beitragen. Die Teilnahme des Aggregators am SRL-Markt mit 100 000 BEVs führte zu einem merklichen Preisrückgang und Kannibalisierungseffekten innerhalb der Flotte. Das größte ökonomische Potenzial bietet das entwickelte Smart-Charging-System für Nutzer mit einer PV-Anlage. Gegenüber dem Basisszenario sparten sie rund 97 €/a. In der Spitze wurden für Nutzer mit besonders hohen Energiebedarfen und günstigem Mobilitätsverhalten Kostenreduktionen bis zu 600 €/a ermittelt. Für Nutzer, bei denen der grundzuständige Messstellenbetreiber kein iMSys verbaut, können hohe Zusatzkosten fällig werden, die eine Teilnahme am Smart-Charging-System unrentabel machen können.

5.2. Diskussion

5.2.1. Einordnung der Ergebnisse in den Forschungsstand

Das hier vorgestellte System greift den in [55] vorgeschlagenen zweistufigen Optimierungsprozess auf. Mit der linearen Programmierung verwendet es eine der dominanten Optimierungstechniken im Bereich der Smart-Charging-Algorithmen. Mit dem Einsatz von ARX-Modellen zur Prognose des Day-Ahead-MCPs wurde ebenso auf eine etablierte Methodik zurückgegriffen.

Vergleichbare Algorithmen in der Literatur fokussieren sich auf die Schöpfung von ökonomischen Potenzialen in den Strommärkten, dem Ausgleich von Netzschwankungen oder der Eigenverbrauchsoptimierung von PV-Anlagen. Der in dieser Arbeit vorgeschlagene Algorithmus kombiniert die ökonomischen Potenziale bei der Strombeschaffung am Spotmarkt, dem Angebot von Regelleistung und der Eigenverbrauchsoptimierung von PV-Anlagen. Zudem wird erstmals die Wahrnehmung des § 14a EnWG innerhalb eines Smart-Charging-Systems betrachtet.

Während andere Studien für die Teilnahme am Regelleistungsmarkt einen Preis-Nehmer-Ansatz wählen, konnten durch die Modellierung des SRL-Marktes auf Basis der realen Marktdaten bei Verwendung eines Price-Maker-Ansatzes die Auswirkungen der Integration von BEVs in den Regelleistungsmarkt untersucht werden. Die beobachteten Kannibalisierungseffekte, die sich bei größeren Flottengrößen einstellen, zeigen, dass die Regelleistungsmarkterlöse nur realistisch geschätzt werden können, wenn die limitierte Marktgröße und die unsteten Regelarbeitsabrufe beachtet werden.

Die Simulationen anderer Studien verzichten zumeist auf die Abbildung öffentlicher Ladevorgänge, obwohl geschätzt wird, dass mit ansteigender Tendenz immerhin 15 % aller Ladevorgänge auf sie entfallen. Für das hier vorgestellte System konnte gezeigt werden, dass bei guter Planbarkeit zukünftiger Fahrten und Parkzeiten ein Smart-Charging-Algorithmus so entwickelt werden kann, dass der Bedarf für das Laden an öffentliche LEs nicht wesentlich zunimmt. Die Verhinderung zusätzlicher öffentlicher Ladevorgänge ist auch ein Ergebnis der Parameteroptimierung, die anhand der gesamten Ladekosten vorgenommen wurde. Eine ausschließliche Betrachtung der Kosten für das private Laden, für das der Aggregator letztlich verantwortlich ist, hätte zu einer Auslagerung der Ladevorgänge an öffentliche Ladestationen und in einem realen System zu einem Kostenanstieg für die Nutzer geführt.

5.2.2. Vergleich der Optimierungsergebnisse mit anderen Studien

Die Höhe des in dieser Arbeit ermittelten ökonomischen Potenzials von Smart Charging liegt im Schätzungsbereich anderer Werke. In den Arbeiten von Bessa und Matos [54] [56] wurde für die Optimierung der Spotmarktbeschaffungskosten und die Bereitstellung von SRL ein ökonomisches Potenzial pro Nutzer im Bereich von 45 €/a bis 60 €/a für den iberischen Elektrizitätsmarkt ermittelt (vgl. Abschnitt 2.5.1). Jargstorf und Wickert [94] haben für die Erbringung negativer SRL im deutschen Markt ein Erlöspotenzial von etwa 60 €/a ermittelt.

In der Arbeit von van der Kam und van Sark [59] reduzierten zwei BEVs mit einem durchschnittlichen Energiebedarf von 10 MWh/a die ins Netz eingespeiste Energie aus einer PV-Anlage mit 31 kW-Peakleistung durch Smart Charging um 3,3 MWh/a. Folglich wurden pro BEV durch Smart Charging etwa 4,52 kWh/d mehr PV-Energie geladen. Im hier vorgestellten System lag die Steigerung bei etwa 0,84 kWh/d. Die Fahrzeuge in [59] weisen einen um etwa 3,4-mal höheren Energiebedarf auf. Werden die Ergebnisse vereinfacht um diesen Faktor skaliert, lassen sich die rund 35 % geringere Eigenverbrauchssteigerung dieser Arbeit durch das zusätzliche Optimierungspotenzial der anderen beiden Strombezugsquellen erklären.

5.2.2.1. Vergleich der Prognosequalitäten mit anderen Studien

Zur weiteren Einordnung der Prognosequalität werden in Tabelle 5.1 die Ergebnisse mit ähnlichen Ansätzen aus der Literatur verglichen.

Tabelle 5.1.: Prognosequalitäten in der Literatur für die Prognose des Day-Ahead-MCPs an der EPEX Spot für das deutsche Marktgebiet.

Studie	Testzeitraum	exogene Variablen	Modell / Verfahren	MAE	RMSE
				in €/MWh	in €/MWh
[95]	2012 -	-	AR(p)	5,98	9,66
	2014	EXXA-MCP	Δ -AR(p)	3,90	7,09
[96]	01/2013 -	Netzlastprognose, Gaspreise, Erzeugungskapazität	ARIMA	-	11,84
	09/2013		KNN	-	6,58
[97]	01/2014 -	Temperatur, Windgeschwindigkeit	ARMA	6,02	8,38
	04/2014		ARMAX	5,72	7,89
			Random Forest	5,68	7,93

Bei der Beurteilung muss berücksichtigt werden, dass die Prognosequalitäten mit dem gewählten Trainings- und Testzeitraum schwanken können und dass unterschiedliche exogene Prädiktoren verwendet werden. Im Vergleich zu gezeigten Prognoseverfahren aus der Literatur weisen die hier vorgestellten Methoden vergleichbare Prognosequalitäten auf. Das Δ -AR(p)-Modell in [95] verwendet den tagesgleichen MCP der österreichischen Strombörse EXXA, die ihren MCP bereits um 10:20 Uhr bekannt gibt, als exogene Inputvariable. Bis zum Herbst 2019 gehörte Österreich noch zur gleichen Stromgebotszone wie Deutschland und Luxemburg. Trotz der Auftrennung der Stromgebotszonen könnte der EXXA-MCP sich immer noch als guter Prädiktor für den deutschen

MCP eignen. Die Eingliederung dieser Variable ist bei dem hier vorliegenden Optimierungskonzept aber nur teilweise replizierbar, da die GCT für die Regelleistungsauktionen bereits um 8:00 Uhr ist. Lediglich für die folgenden Optimierungen könnte diese Variable in eine neue Spotmarktprognose eingehen.

Für die vorliegenden PV-Anlagen erzeugte das „History Photovoltaic“ Modell nicht die Prognosequalitäten, die der Datenlieferant für tagesaktuelle Day-Ahead-Prognosen in einstündigen Intervallen erreicht. Gemäß [98] liegt der Prognosefehler für Anlagen in Zentraleuropa zwischen 15 % und 30 %.

5.2.3. Limitationen und weiterer Forschungsbedarf

Mit dem Einzug von iMSys, die aus stromwirtschaftlicher Perspektive für die Optimierung der Beschaffungskosten im Spotmarkt notwendig sind, entsteht ein Ausgleichsenergieisiko für den zuständigen BKV (vgl. die Abschnitte 2.1.1.2 und 2.1.1.3). In dieser Arbeit wurde angenommen, dass Fahrplanabweichungen innerhalb des VPPs oder durch kurzfristiges Handel im kontinuierlichen Intraday-Markt ausgeglichen werden. In diesem System nicht berücksichtigt wurden Ladevorgänge, die Nutzer abweichend von den Vorgaben des Aggregators vornehmen. Im Vergleich zu den vom Aggregator vorgegebenen Ladevorgängen können diese nicht genau prognostiziert werden und stellen ein Risiko für Ausgleichsenergie dar. Im Jedlix-System werden etwa ein Viertel aller Ladevorgänge nicht vom Aggregator gesteuert [43, S. 3]. Für das Anfallen von Ausgleichsenergiekosten in Smart-Charging-Systemen gibt es Forschungsbedarf.

Mit der Übermittlung künftiger Fahrpläne und Parkzeiten für die nächsten 48 h steht dem hier betrachteten Aggregator eine breite Informationsbasis zur Verfügung. Auch wenn die Pläne Abweichungen durch ungeplante öffentliche Ladevorgänge aufweisen, unterliegen reale Aggregatoren von Privatkunden größeren Unsicherheiten. Eine vergleichbar gute Planbarkeit ist im Management größerer Flotten denkbar, z. B. im städtischen Lieferverkehr, wo Streckenlängen, Fahrverbräuche und Parkzeiten mit guter Genauigkeit prognostiziert werden können. Für die Betrachtung der Aggregation privater BEV-Fahrer bedarf es besserer Prognosen für Ladeverfügbarkeit und Energiebedarfe. Zudem wurden nur VNBs betrachtet, die LEs statisch zu festen Uhrzeiten fernsteuern. In künftigen Systemen sollten ebenso die dynamische Steuerung integriert und ihre Auswirkungen in den Prognosen und Ladeplanungen mit abgedeckt werden.

Zur Ermittlung des vollen Smart-Charging-Potenzials sollten künftige Smart-Charging-Algorithmen die Partizipation an weiteren Erlösmöglichkeiten beherrschen. Verglichen mit dem hier vorgestellten System ist zunächst die Erbringung positiver SRL ins Auge zu fassen. Weitere Erlösoptionen sind die Bereitstellung von PRL oder die Minimierung von Ausgleichsenergiekosten in einem BK. Zudem bedarf es weiterentwickelter Preisstrategien für die Teilnahme eines Aggregators am Regelleistungsmarkt. Die hier verwendete einfache Preisstrategie wurde zwar in sich ökonomisch optimiert, die Methode ist allerdings simpel. Es ist zu erwarten, dass eine verbesserte Preisstrategie die Erlöse für Regelleistung und die Kosten für Regelarbeit merklich senken können.

5.2.4. Ausblick

Stromwirtschaftliche und technische Trends werden das ökonomische Potenzial der Ladevorgangsoptimierung wesentlich beeinflussen. Durch den zunehmenden Anteil der EE am Strommix werden die Fluktuationen der Erzeugungsleistung und mit ihnen die kurzfristigen Schwankungen der Spotmarktpreise zunehmen. Gleichzeitig sind auch systematische Änderungen am Preisverlauf zu erwarten. Die Zunahme der PV-Einspeisung dürfte zu einer Verstärkung des Preisabfalls um die Mittagszeit führen, während relativ dazu außerhalb der PV-Einspeisezeiten ein Preisanstieg wahrscheinlich ist. Je größer die kurzfristigen Preisdifferenzen sind, desto höher wird das Potenzial der Verschiebung von Lasten und damit für Smart Charging.

Aufgrund der zunehmenden Einspeisefluktuationen werden moderat höhere Bedarfe für SRL und deutlich höhere Bedarfe für MRL prognostiziert [99, S. 5ff.]. Bisher weist die Erbringung von MRL durch BEVs aufgrund der seltenen Regelarbeitsabrufe nur geringes ökonomisches Potenzial auf. Gleichzeitig scheidet durch die Abschaltung konventioneller Kraftwerke viel präqualifizierte Leistung aus dem Regelleistungsmarkt aus. Dem sich hier ergebenden Marktpotenzial steht allerdings wachsende Konkurrenz durch die Integration neuer Technologien in den Regelleistungsmarkt gegenüber. Zum einen wächst der Anteil der stationären Batteriespeicher an der präqualifizierten Leistung kontinuierlich, zum anderen werden zunehmend EE-Anlagen für die Erbringung von Regelleistung erprobt. Werden, dem Wachstum der Neuzulassungszahlen folgend, künftig eine Großzahl von BEVs in den Regelleistungsmarkt integriert, werden Kannibalisierungseffekte das ökonomische Potenzial pro BEV verringern.

5.3. Politische Handlungsempfehlungen

In einem Leitmarkt setzen sich Innovationen aufgrund günstiger Standortbedingungen zuerst durch. Unternehmen lernen in Leitmärkten und expandieren mit ihren erfolgreichen Geschäftsmodellen und Produkten anschließend in nachziehende Märkte mit positiven Auswirkungen auf die heimische Wertschöpfung [100, S. 8]. Um von Leitmarkteffekten zu profitieren, sollten politische Verantwortungsträger frühzeitig die Rahmenbedingungen für eine beschleunigte Marktdiffusion von Smart Charging schaffen. Die folgenden Empfehlungen zielen auf die Schaffung zu präferierender Standortbedingungen ab. Gute Standortbedingungen liegen insbesondere dann vor, wenn ein hohes ökonomisches Potenzial vorhanden ist, es keine regulatorischen Hürden für die Schöpfung des Potenzials gibt und die Anzahl potenzieller Nutzer groß ist. Es ist zu berücksichtigen, dass die Leitmarkteffekte stets gegen staatliche Mehrausgaben und andere Nebeneffekte, die z. B. volkswirtschaftlicher, ökologischer oder sozialer Natur sein können, abgewägt werden müssen.

5.3.1. Maßnahmen zur Förderung des Eigenverbrauchs

Strompreissenkungen, wie die immer wieder geforderte Abschaffung der EEG-Umlage für Verbraucher, würden zu einer Verringerung der ökonomischen Attraktivität der Eigenverbrauchsoptimierung führen und im Bezug auf Smart Charging der Schaffung von Leitmarktbedingungen entgegenstehen. Die Aufhebung der EEG-Abgabepflicht für Anlagen, deren installierte Leistung kleiner

als 30 kW ist, mit der EEG-Novelle 2021 ist hingegen zu begrüßen. Der Degradationsmechanismus der EEG-Einspeisevergütung steigert das ökonomische Potenzial grundsätzlich. Entscheidender als ein weiteres Absenken der Einspeisevergütung ist aber, dass der Zubau von privaten PV-Anlagen weiterhin attraktiv ist und voranschreitet. Je mehr BEV-Besitzer eine private PV-Anlage haben, desto mehr potenzielle Kunden für Smart-Charging-Anbieter gibt es und umso besser sind die Leitmarktbedingungen. Ein möglicher Ansatzpunkt, die sowohl die Attraktivität für den Kauf einer PV-Anlage als auch für Smart-Charging-Systeme erhöht, ist eine umsatzsteuerliche Vergünstigung des Eigenverbrauchs für Betreiber kleiner Anlagen abseits der Kleinunternehmerregelung.

5.3.2. Anpassungen der Regularien des Regelleistungsmarkts

Bisher setzen die Präqualifikationsbedingungen für den Regelleistungsmarkt zu hohe Hürden für die Integration von BEVs. Wird einer präqualifizierten Regelgruppe eine TE hinzugefügt, bedarf es bislang der ausdrücklichen Zustimmung des ÜNBs oder einem erneuten Präqualifikationsverfahren. Für ein Smart-Charging-System ist dies eine unpraktikable Lösung, da ein BEV einer TE entspricht. Hinzu kommt, dass Regelgruppen bisher nur aus TEs einer Regelzone gebildet werden dürfen. Ein Aggregator benötigt für Deutschland daher vier präqualifizierte Regelgruppen. Da sich die Fahrzeuge ganz natürlich über die Grenzen der deutschen Regelzonen bewegen, ergeben sich hier Schwierigkeiten bei der Zuordnung zu den Regelgruppen. Eine Anpassung der Präqualifikationsbedingungen auf die Eigenschaften von sich bewegenden TEs ist zur Schöpfung des Erlöspotenzials, das der Regelleistungsmarkt bietet, unabdingbar.

Die zum 03.11.2020 erfolgte und in dieser Arbeit noch nicht betrachtete Einführung des Regelarbeitsmarktes ist aus Leitmarktperspektiven zu begrüßen. Seitdem werden Regelleistung und -arbeit in getrennten Märkten gehandelt. Anbieter, die am Vortag über die MOL des Regelleistungsmarkts nicht erfolgreich waren, können noch bis zu einer Stunde vor dem Beginn einer Zeitscheibe auf ein Kontingent an free bids für die Erbringung von Regelarbeit bieten. Erfolgreiche Bieter der Regelleistungsmarktauktion erhalten ihren gebotenen Leistungspreis und nehmen mit ihrem Regelarbeitspreis automatisch am Regelarbeitsmarkt teil. Das kurzfristige Partizipieren am Regelarbeitsmarkt senkt die Eintrittshürde für Anbieter, deren geplante Leistungsverfügbarkeit stochastischen Schwankungen unterliegt und damit auch für Smart-Charging-Systeme. Aggregatoren müssen nicht mehr über einen Zeitraum von einem Tag schätzen, wie hoch ihre Leistungsverfügbarkeit sein wird, sondern können dies kurzfristiger und damit genauer bestimmen.

Dass kürzere Zeitscheiben zu höheren Smart-Charging-Erlösen führen, konnte in dieser Arbeit nicht bewiesen werden (vgl. Abschnitt 4.6.4). Es ist dennoch nicht auszuschließen. Mit einer Pönalisierung hoher Leistungskumulationen auf wenige kurze Regelleistungszeitscheiben, z. B. per quadratischer Programmierung, ließen sich die vermehrt aufgetretenen Kannibalisierungseffekte reduzieren. Es ist davon auszugehen, dass dies zu einer ökonomischen Verbesserung im Vergleich zum jetzigen Marktdesign führt. Angesichts der erzielten Ergebnisse erscheint es allerdings wenig wahrscheinlich, dass es sich um wesentliche Zusatz Erlöse handelt. Die Regulierungsbehörde und die ÜNBs sollten den Fokus auf die Anpassung der Präqualifikationsbedingungen legen.

5.3.3. Neugestaltung des § 14a EnWG

Eine Neugestaltung des § 14a EnWG ist seit einiger Zeit im Fokus einer regen fachpolitischen Debatte. Ein im Dezember 2020 veröffentlichter Referentenentwurf für ein neues Steuerbare-Verbrauchseinrichtungen-Gesetz des Bundesministeriums für Wirtschaft und Energie wurde im Januar 2021 nach Missbilligung des Bundeswirtschaftsministers zurückgezogen. Der Entwurf sah vor, steuerbare Verbrauchseinrichtungen, deren Leistung 3,7 kW übersteigt, künftig standardmäßig einer Spitzenlastglättung zu unterziehen. Die Betreiber der Einrichtungen hätten beim VNB eine bedingte, also unterbrechenbare Leistung, für die sie verringerte NNE gezahlt hätten und eine unbedingte, ununterbrechenbare Leistung, mit deutlich höheren NNE bestellt. Die VNBs hätten im Gegenzug pro Tag 2 h die bedingte Leistung reduzieren gedurft. Ein separater Zählpunkt hätte nur noch für Verbraucher mit einem Jahresstromverbrauch über 10 MWh eingerichtet werden müssen [101].

Es konnte gezeigt werden, dass nach ökonomischen Aspekten ausgerichtetes Smart Charging das Lastprofil einer aggregierten BEV-Flotte so verschiebt, dass die Last der Flotte sich gegenläufig zur Netzlast verhält, während eine ungesteuerte Flotte die Spitzenlast in den Abendstunden verstärkt (vgl. Abschnitt 4.4.2). Die bisher geringe Nutzung des § 14a EnWG zeigt, dass eine Reduzierung der Ladeenergiekosten im bisherigen Rahmen die temporäre Blockierung der LE sowie zusätzliche Messstellenbetriebskosten für das iMSys aus Nutzersicht nicht aufwiegen. Eine standardmäßig vorgesehene Blockierung der Lademöglichkeit bzw. eine Anhebung der Ladeenergiekosten bei Inanspruchnahme unbedingter Leistung könnte die Bereitschaft für den Umstieg auf die Elektromobilität reduzieren und die Marktverbreitung entsprechend verlangsamen.

Um das ökonomische Potenzial von Smart Charging zu stärken und gleichzeitig die schnelle Marktdiffusion von Elektroautos, die das erklärte Ziel der Bundesregierung ist, nicht zu dämpfen, sollten zur weiteren Steigerung der Netzdienlichkeit Preissignale verwendet werden. In den nächsten zehn Jahren ist noch nicht mit einer Überlastung der Verteilnetze zu rechnen [8], [9]. Es bleibt genügend Zeit, um durch zeitvariable NNE das Laden dann attraktiv zu machen, wenn die Netzauslastung gering ist. Die Leistungsreduzierung durch die VNBs sollte Ausnahmesituationen vorbehalten bleiben.

5.3.4. Verringerung der Messbetriebskosten

Maßnahmen, die zu einer Reduzierung der Kostenbelastung für den Letztverbraucher durch den Einbau eines iMSys führen, sind aus der Leitmarktperspektive stark zu befürworten. Vor dem Hintergrund der hohen Messbetriebskosten ist eine Aufhebung der Pflicht zur Einrichtung eines zweiten, separaten Zählpunktes in der Form eines iMSys bei der Wahrnehmung des § 14a EnWG ein Schritt in Richtung besserer Leitmarktbedingungen. Für die korrekte Abrechnung zeitvariabler NNE und um weitere Nutzer nicht mehr nach SLP, sondern Zählerstandgangsmessung abrechnen zu können, ist ein umfangreicher und schneller Rollout der iMSys unerlässlich. Zudem ist zu prüfen, inwieweit die Messeinrichtungen in den Fahrzeug-BMS und in den LEs, die zwar nicht bzw. nur sehr selten den Anforderungen des Eichrechts entsprechen, aber dennoch eine gute Genauigkeit besitzen, für eine viertelstundengenaue Abrechnung herangezogen werden können.

A. Anhang

A.1. Theoretischer Hintergrund

A.1.1. Autokorrelation eines AR(1)-Modells

Für ein AR(1)-Modell einer schwach stationären Zufallsvariablen y

$$y_t = \phi_0 + y_{t-1} \phi_1 + \epsilon_t \quad (\text{A.1})$$

kann die Autokorrelation leicht bestimmt werden. Zunächst wird der Erwartungswert von Gleichung A.1 betrachtet und die Gleichung umgestellt

$$\phi_0 = \phi_1 E[y_{t-1}] - E[y_t] + E[\epsilon_t] = \mu_y (1 - \phi_1), \quad (\text{A.2})$$

wobei aufgrund der schwachen Stationarität $E[y_{t-1}] = E[y_t] = \mu_y$ und der Charakteristik weißen Rauschens $E[\epsilon_t] = 0$ berücksichtigt wurden. Nach dem Einsetzen von Gleichung A.2 in Gleichung A.1, dem Umstellen der Gleichung, der beidseitigen Multiplikation mit $y_{t-l} - \mu_y$ und der Bildung des Erwartungswertes

$$y_t = \mu_y (1 - \phi_1) + y_{t-1} \phi_1 + \epsilon_t \quad (\text{A.3})$$

$$\Leftrightarrow y_t - \mu_y = \phi_1 (y_{t-1} - \mu_y) + \epsilon_t \quad (\text{A.4})$$

$$\Leftrightarrow E[(y_t - \mu_y)(y_{t-l} - \mu_y)] = E[\phi_1 (y_{t-1} - \mu_y)(y_{t-l} - \mu_y)] + E[\epsilon_t (y_{t-l} - \mu_y)] \quad (\text{A.5})$$

kann wegen $E[y_{t-l} - \mu_y] = 0$ mithilfe von Gleichung 2.6 die Autokovarianz

$$\gamma_{y,l} = \phi_1 \gamma_{y,l-1}, \quad \forall l > 0 \quad (\text{A.6})$$

und wegen der zeitlichen Konstanz der Varianz σ_y^2 durch Nutzung von Gleichung 2.9 die Autokorrelation

$$\rho_{y,l} = \phi_1 \rho_{y,l-1}, \quad \forall l > 0 \quad (\text{A.7})$$

bestimmt werden [47, S. 33ff.].

A.1.2. Nicht-lineare autoregressive neuronale Netze mit externen Eingabewerten

Auch neuronale Netze eignen sich als Prognosemodelle. Ein nicht-lineares autoregressives neuronales Netz mit externen Eingabewerten (Engl. nonlinear autoregressive neural network with external input, NARXNET) kann sowohl lineare als auch nicht lineare ARX-Modelle abbilden. Abbildung A.1 zeigt die gewöhnliche Struktur eines NARXNETs. Der grundsätzliche Aufbau ähnelt dem eines vorwärtsbetriebenen künstlichen neuronalen Netzes.

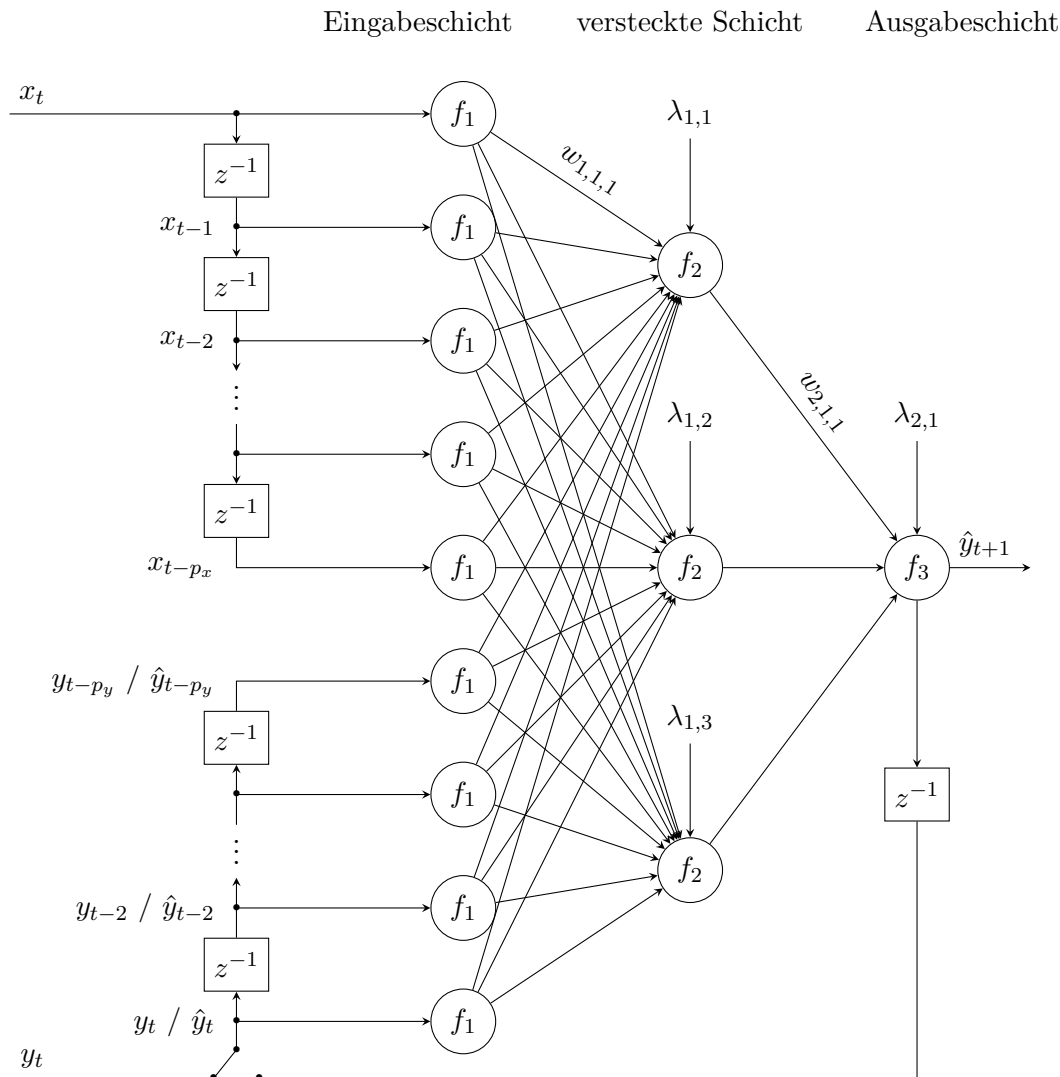


Abbildung A.1.: Struktur eines NARXNETs mit einer exogenen Variablen. In Anlehnung an [102, S. 535].

Der Übersichtlichkeit wegen wird in dem gezeigten Modell lediglich eine exogene Variable x_t als Eingabe verwendet. Modelle mit K exogenen Variablen sind ebenso möglich. Wie bei einem ARX-Modell üblich, wird zudem die abhängige Variable y_t selbst als Eingabe für das Modell verwendet. NARXNETs können mit offener oder geschlossener Rückkopplungsschleife trainiert und betrieben werden. Ist die Rückkopplungsschleife geöffnet, so wie in Abbildung A.1 dargestellt, gehen die beobachteten Zustände y_t in das Modell ein. Bei geschlossener Schleife werden die Ausgabewerte des Netzes \hat{y}_{t+1} zeitverzögert als rekursive Eingabe \hat{y}_t verwendet.

Die weitere Funktionsweise folgt der gewöhnlicher vorwärtsbetriebener künstlicher neuronalen Netze. Die Eingabewerte werden in der Eingabeschicht mit der Funktion f_1 verarbeitet. Jedes Neuron der Eingabeschicht ist über ein Gewicht w mit jedem Neuron der versteckten Schicht verbunden. Die Ergebnisse des ersten Verarbeitungsschrittes werden mit den Gewichten \mathbf{w}_1 multipliziert und die Produkte pro Neuron der versteckten Schicht zusammen mit dem jeweiligen Bias λ aufsummiert. Diese Prozedur wird zwischen der versteckten Schicht und der Ausgabeschicht mit den Übertragungsfunktionen f_2 und f_3 wiederholt. Das Ergebnis von f_3 entspricht dem Modellausgang. Bei einer einstufigen Prognose ist dies der vorhergesagte Zustand von y zum Zeitpunkt $t+1$.

Erlernt wird die Prognosefähigkeit des Netzes durch die Anpassung der Gewichte und Bias von einer zufälligen Initialkonfiguration aus. Im Rahmen eines überwachten Lernvorgangs wird dazu eine Sequenz der Netzausgabe $\hat{\mathbf{y}}_{t+1}$, die bei der Eingabe beobachteter Zustände von \mathbf{X}_t und \mathbf{Y}_t in die Eingabeschicht am Netzausgang entsteht, mit den tatsächlichen Zuständen \mathbf{y}_{t+1} verglichen. Die üblichen Backpropagation-Trainingsalgorithmen passen die Gewichte und Bias so an, dass per Methode der kleinsten Quadrate der mittlere quadratische Fehler minimiert wird

$$\min_{\mathbf{w}, \lambda} E [\mathbf{y}_{t+1} - \hat{\mathbf{y}}_{t+1}]^2. \quad (\text{A.8})$$

Detaillierte Beschreibungen des Netzaufbaues und der Trainingsverfahren würden den Umfang dieser Arbeit hier überschreiten. Eine erschöpfende Einführung in künstliche neuronale Netze bietet [103]. Für eine Beschreibung des Trainingsverfahrens auf der Basis von Backpropagation sei auf [104] verwiesen.

A.2. Entwicklung eines Algorithmus zur ökonomischen Ladevorgangsoptimierung

A.2.1. Photovoltaikanlagendaten

Tabelle A.1.: Daten der verwendeten PV-Anlagen, die aus dem Sunny Portal der SMA Solar Technology AG [79] per Screen Scraper extrahiert wurden. Die letzte Spalte gibt die prognostizierte Erzeugung.

Anlage	Inbetriebnahme	EEG-Fördersatz in ct/kWh	Elevation in °S	Azimut in °	Peakleistung in kW	Erzeugung kWh/a	Progn. Erzeugung in kWh/a
1	29.05.2017	12,30	-20	40	8,99	10 337	8 061
2	04.10.2013	14,27	-70	40	8,80	6 369	7 233
3	25.08.2011	28,74	-30	45	6,67	7 177	5 819
4	11.05.2012	19,31	20	35	8,58	9 616	7 998
5	30.04.2015	12,47	-15	10	7,25	7 385	6 334
6	10.05.2017	12,27	0	35	8,23	9 641	7 673
7	20.04.2017	12,30	80	35	8,40	7 178	7 002
8	28.11.2012	17,90	-10	38	5,98	5 864	5 388
9	16.04.2015	12,47	0	25	5,04	4 009	4 298
10	08.05.2017	12,27	-60	30	5,46	5 680	4 699
11	08.10.2013	14,27	15	30	6,63	6 651	5 913
12	23.08.2017	12,20	0	18	12,40	15 733	11 137
13	20.06.2011	28,74	26	40	11,04	13 658	9 881
14	29.08.2015	12,34	45	42	9,90	11 368	8 755
15	31.10.2014	12,65	0	30	5,10	5 782	4 785
16	26.07.2013	15,07	-85	59	5,83	5 176	4 379
17	27.11.2013	14,07	0	14	9,90	9 707	8 468
18	04.08.2013	14,80	-45	48	10,46	10 773	8 707
19	15.05.2017	12,27	7	20	7,20	6 598	6 560
20	27.07.2013	15,07	59	38	6,88	5 618	5 711

A.2.2. Verlauf des Day-Ahead-Preises im Wochendurchschnitt

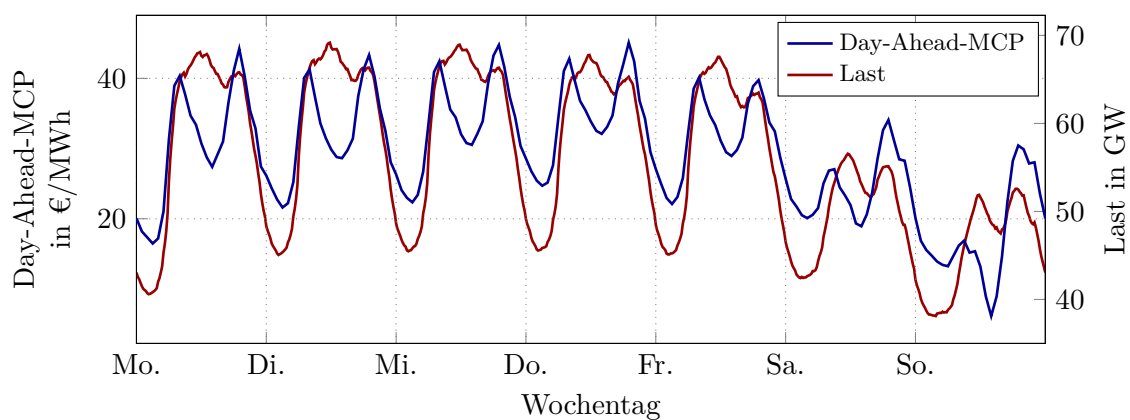


Abbildung A.2.: Verläufe des arithmetischen Mittelwerts des Day-Ahead MCPs der EPEX Spot und der Netzlast im Wochendurchschnitt für den Simulationszeitraum. Die Daten stammen von [81].

A.2.3. Autokorrelationsfunktionen der Variablen des Regelleistungsmarktes

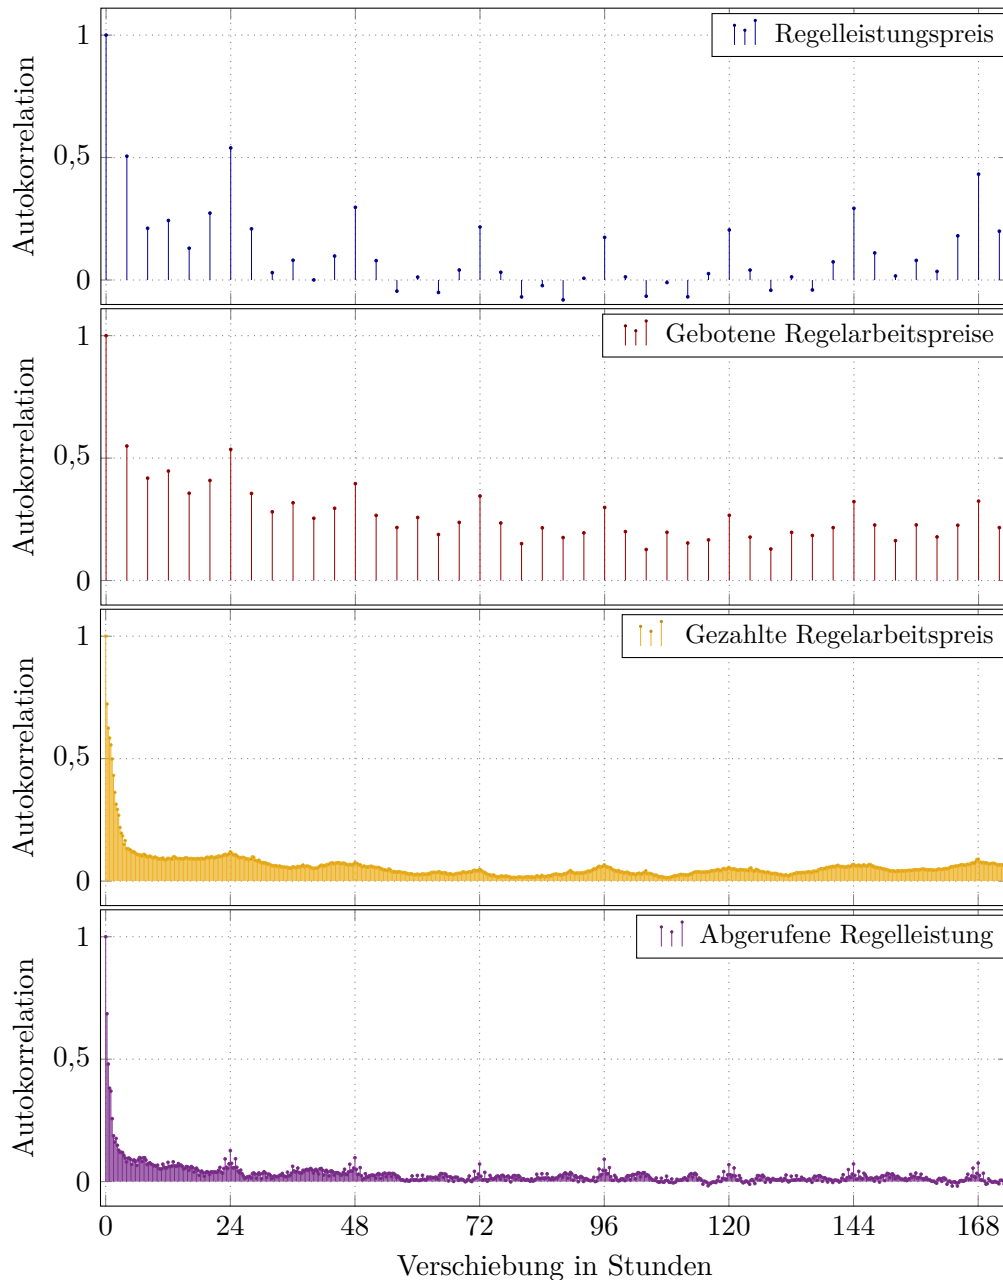


Abbildung A.3.: Autokorrelationsfunktionen für den Regelleistungspreis, den Regelarbeitspreis und die Regelleistungsabrufe im Simulationszeitraum. Betrachtet wurde negative SRL. Die Metriken basieren jeweils auf dem leistungsgewichteten arithmetischen Mittelwert ihrer Ausgangsgröße. Es wurden nur die Preisgebote aller Bieter betrachtet, die unter dem Grenzpreis für Regelleistung lagen. Die gezahlten Regelarbeitspreise betrachten nur die Preise für tatsächlich erbrachte Regelarbeit. Folgerichtig sind die Gebotspreise in den vierstündigen Zeitscheiben aufgelöst und die tatsächlich ausgezahlten Preise in den viertelstündigen Intervall, in denen auch die Höhe der abgerufenen Regelleistung veröffentlicht wird. Die Rohdaten sind unter [83] abrufbar.

A.3. Auswertung

A.3.1. Lastprofile der Optimierungsschritte

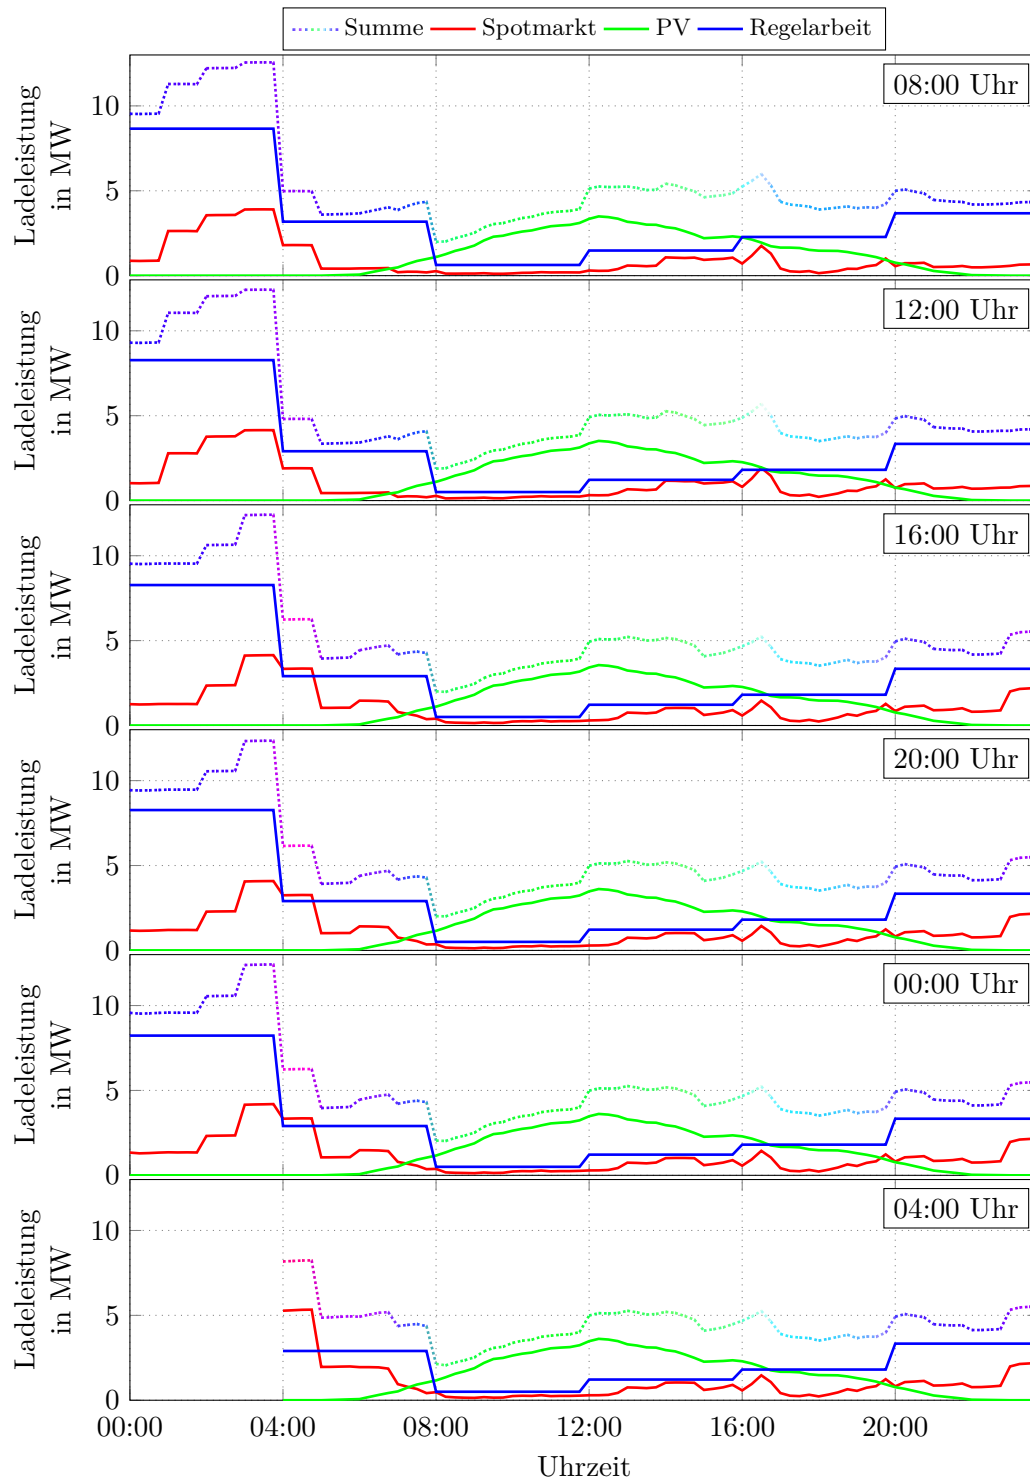


Abbildung A.4.: Durchschnittliche Lastprofile als Ergebnis der vorausplanenden Optimierungen in der Primärsimulation. Gezeigt werden jeweils die planerischen Ladeleistungen für den Tag $d + 1$.

A.3.2. Lastprofile nach Wochentag und Wochenende

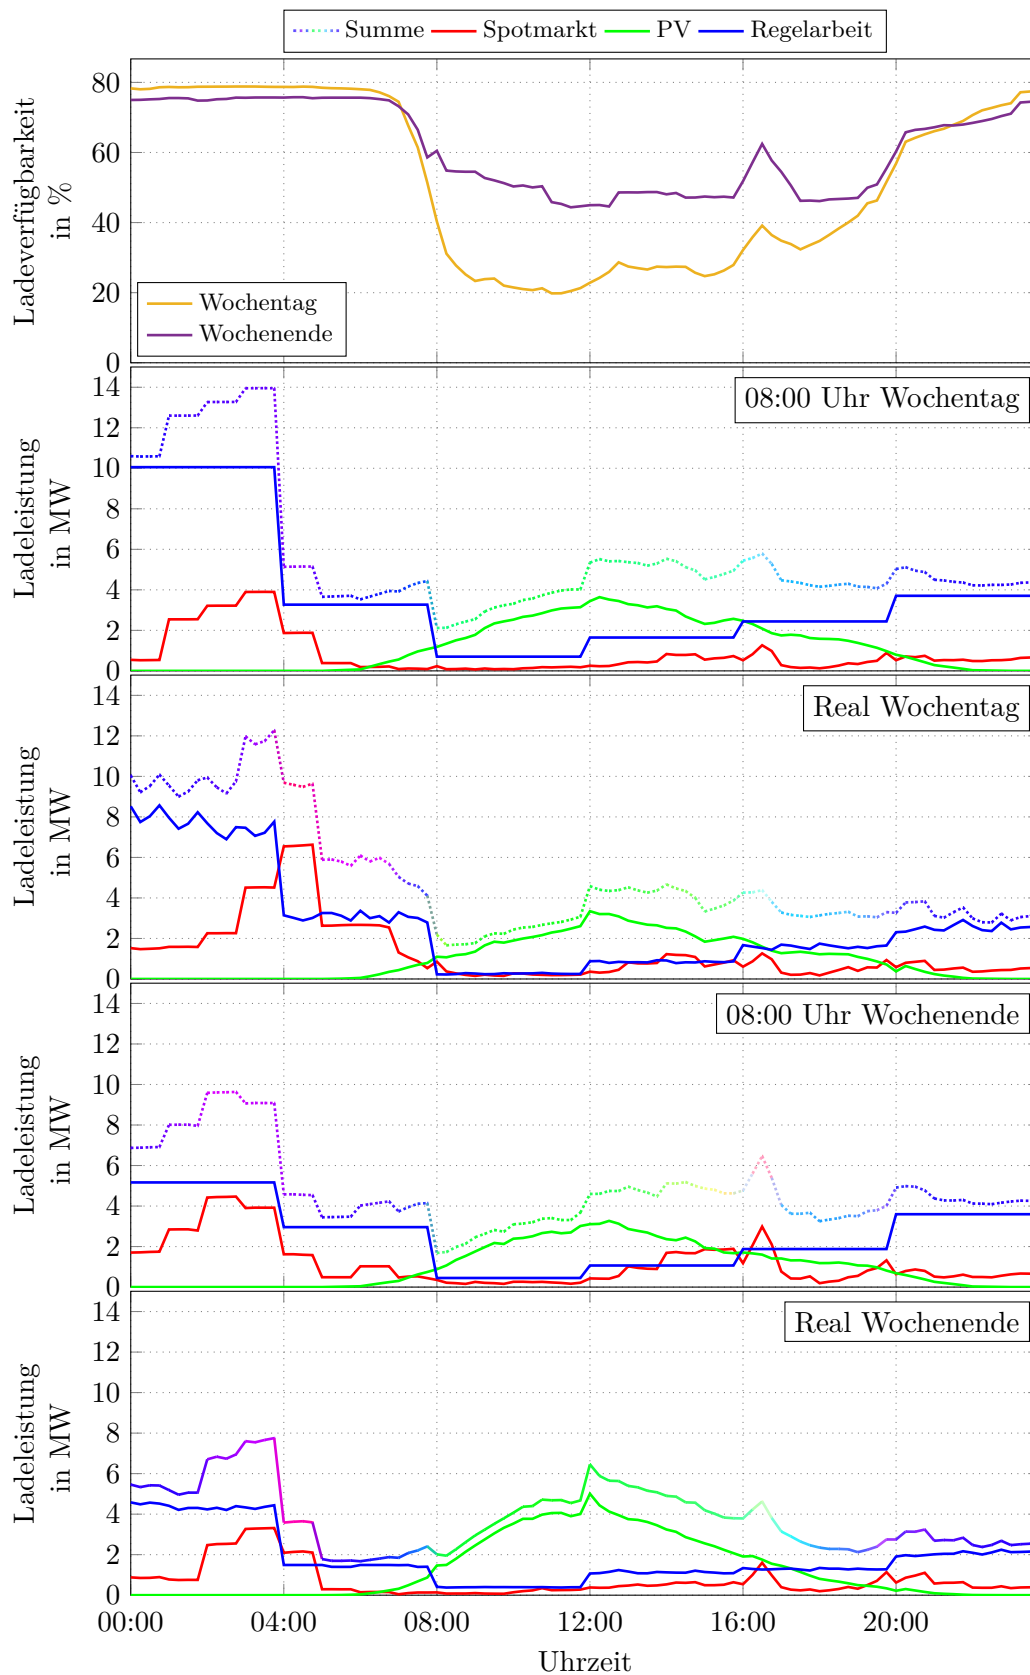


Abbildung A.5.: Ladeverfügbarkeit und durchschnittliche Lastprofile aufgeteilt nach Wochentag und Wochenende in der Primärsimulation.

A.3.3. Anteile der Strombezugsquellen im Jahresverlauf

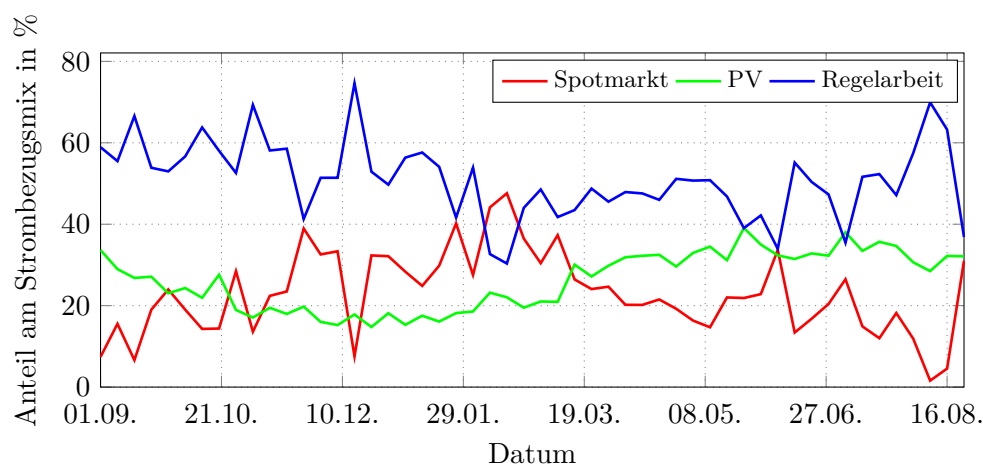


Abbildung A.6.: Anteile der drei Strombezugsquellen im Verlauf der Primärsimulation.

A.3.4. Anteile der Strombezugsquellen an der Ladeleistung

Tabelle A.2.: Anteile der Bezugsquellen an der gesamten Ladeleistung nach Optimierungsschritt in %. Die Zeilen „Real“ bezieht sich auf die tatsächliche genutzte Ladeleistung. Im Smart-Charging-Szenario entspricht dies dem Ergebnis des operativen Algorithmus. Bei der Interpretation der Angaben für 4:00 Uhr muss berücksichtigt werden, dass die erste vierstündige Zeitscheibe des Tages nicht mehr erfasst wird. Aufgrund des hohen Regelarbeitsbezug während dieser Zeit sinkt der Anteil dieser Bezugsquelle.

Lastprofil	Spotmarkt	PV	Regelarbeit	
Smart Charging	08:00	17,1	21,9	61,1
	12:00	19,8	22,8	57,4
	16:00	21,0	22,6	56,4
	20:00	20,4	23,1	56,5
	00:00	20,8	23,1	56,1
	04:00	23,6	32,9	43,5
	Real	24,5	23,4	52,1
Basisszenario	Real	82,6	17,4	0,00


A.3.5. Lastprofile bei Verkürzung der Regelleistungszeitscheiben

Abbildung A.7.: Durchschnittliche Lastprofile für verkürzte Regelleistungszeitscheiben. In den Simulationen wurden 1000 Nutzer betrachtet.

Abkürzungsverzeichnis

AC	Alternating Current
AR	Autoregressive
ARIMA	Autoregressive Integrated Moving Average
ARMA	Autoregressive Moving Average
ARMAX	Autoregressive Moving Average Model with Exogenous Input
ARX	Autoregressive with Exogenous Input
BEV	Battery Electric Vehicle
BJB	Battery Junction Box
BK	Bilanzkreis
BKV	Bilanzkreisverantwortlicher
BMS	Batteriemanagementsystem
BV	Basisvariable
CCCV	Constant-Current-Constant-Voltage-Verfahren
CCU	Charging Control Unit
DC	Direct Current
DSM	Demand Side Management
EE	Erneuerbare Energien
EEG	Erneuerbare-Energien-Gesetz
EEX	European Energy Exchange
EnWG	Energiewirtschaftsgesetz
EPEX Spot	European Power Exchange
GCT	Gate Closure Time
iMSys	Intelligentes Messsystem
KNN	Künstliches neuronales Netz
KWKG	Kraft-Wärme-Kopplungsgesetz
LE	Ladeeinrichtung
LP	Lineares Programm
LS	Least Squares
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MCP	Market Clearing Price
MCV	Market Clearing Volume
MID	Measuring Instruments Directive
mMAPE	Modified Mean Absolute Percentage Error
mME	Moderne Messeinrichtung
MOL	Merit-Order-Liste
MR	Momentanreserve
MRL	Minutenregelleistung
MsbG	Messstellenbetriebsgesetz
NARXNET	Nonlinear Autoregressive Neural Network with External Input

NNE	Netznutzungsentgelte
NPM	Nationale Plattform Zukunft der Mobilität
NBV	Nichtbasisvariable
OBC	On-Board Charger
OCU	Online Connectivity Unit
OEM	Original Equipment Manufacturer
OPCC	Open Charging Point Protocol
OTC	Over-the-Counter
PHEV	Plug-in-Hybrid Electric Vehicle
PRL	Primärregelleistung
PWR	Pulswechselrichter
PV	Photovoltaik
reBAP	Regelzonenübergreifender einheitlicher Bilanzausgleichsenergiepreis
RMSE	Root Mean Square Error
SLP	Standardlastprofil
SRL	Sekundärregelleistung
SoC	State of Charge
StromNEV	Stromnetzentgeltverordnung
StromNZV	Stromnetzzugangsverordnung
TE	Technische Einheit
ÜNB	Übertragungsnetzbetreiber
V2G	Vehicle-to-Grid
VNB	Verteilnetzbetreiber
VPP	Virtual Power Plant

Symbolverzeichnis

Allgemeine Notation

\mathbf{a}^\top	Transponierung des Vektors \mathbf{a}
\hat{a}	Schätzung, Prognose oder vorausgeplanter Wert der Variable a
$E[]$	Erwartungswert
$\mathcal{O}(\)$	Landau-Notation

Regressionsmodelle für die Prognose von Zeitreihen

β	Regressionskoeffizient eines exogenen Regressors
ϵ	Fehlerterm, weißes Rauschen
f	Übertragungsfunktion der Schicht eines NARXNETs
$\gamma_{y,l}$	Autokovarianz der Variablen y an der Verschiebung l
J	Fehlerfunktion
K	Anzahl der Regressoren
λ	Bias der Schicht eines NARXNETs
μ_y	Mittelwert der Variablen y
p_{x_k}	Anzahl der Regressionskoeffizienten der Sequenz der exogenen Variablen \mathbf{x}_k
p_y	Anzahl der autoregressiven Regressionskoeffizienten der Variablen y
ϕ	Regressionskoeffizient einer autoregressiven Variable
$\rho_{y,l}$	Autokorrelation der Variablen y an der Verschiebung l
σ_y^2	Varianz der Variablen y
T	Anzahl der Beobachtungen einer Sequenz
t	Zeitpunkt
θ	Modellparameter eines ARX-Modells
w	Gewicht zwischen den Schichten eines NARXNETs
x	Regressor
y	Regressand
z	Vektor aller Regressoren eines ARX-Modells

Lineare Optimierung

a, b	Koeffizienten der Nebenbedingungen
c	Koeffizienten der Kostenfunktion
e	Eulersche Zahl
m	Anzahl der Nebenbedingungen
n	Anzahl der Entscheidungsvariablen
π	Kreiszahl
S	Lösungsraum der Entscheidungsvariablen
t_{opt}	Optimale Schrittweite zur Anpassung einer NBV
x	Entscheidungsvariable
x_{BV}	Entscheidungsvariable, die zur Basis gehört
x_{NBV}	Entscheidungsvariable, die nicht zur Basis gehört
z^r	Optimalitätsindikator

Spotmarktprognosemodell

$\hat{\beta}$	Berechneter Regressionskoeffizient eines exogenen Regressors
d	Tag, an dem die Prognose erstellt wird
K	Anzahl der exogenen Prädiktoren aus der Stromwirtschaft
$\mu_{y, \text{mod}(\tau, 24)}$	Erwartungswert des MCPs für die Uhrzeit τ in Stunden
$\mu_{y, w(t+\tau)}$	Erwartungswert des MCPs für den Wochentag w des Zeitpunktes $t + \tau$
p_y	Anzahl der autoregressiven Regressionskoeffizienten des MCPs
$\hat{\phi}$	Berechneter Regressionskoeffizient einer autoregressiven Variable
t	Zeitschritt um 23:00 Uhr des Tages d
\hat{x}	Exogener Prädiktor für den MCP aus der Stromwirtschaft
y	MCP des Day-Ahead-Marktes

Preisstrategie Regelleistungsmarkt

$\alpha_P^{\text{SRL,Ang}}$	Faktor, um den der mittlere SRL-Leistungspreisgebot der letzten Auktion unterboten wird	
$\alpha_W^{\text{SRL,Ang}}$	Faktor, um den das kleinste SRL-Arbeitspreisgebot der letzten Auktion, das per Leistungspreis erfolgreich war, unterboten wird	
$C_{t,\text{Agg},P}^{\text{SRL,Ang}}$	Leistungspreis des SRL-Angebots des Aggregators für die Zeitscheibe t	€/MW
$C_{t,\text{Agg},W}^{\text{SRL,Ang}}$	Arbeitspreis des SRL-Angebots des Aggregators für die Zeitscheibe t	€/MWh
$C_{t,i,P}^{\text{SRL,Ang}}$	Leistungspreis des SRL-Angebots des Wettbewerbers i für die Zeitscheibe t des vergangenen Tages	€/MW
$C_{t,i,W}^{\text{SRL,Ang}}$	Arbeitspreis des SRL-Angebots des Wettbewerbers i für die Zeitscheibe t des vergangenen Tages	€/MWh
$P_{t-6,i}^{\text{SRL,Ang}}$	Leistungshöhe des SRL-Angebots des Wettbewerbers i für die Zeitscheibe t des vergangenen Tages	MW

Optimierungsalgorithmen

$C_{t,q,n}$	Kosten des Strombezugs zum Zeitpunkt t aus Quelle q von Nutzer n	ct/kWh
d	Tag der Optimierung	
$E_{t,n}^{\text{Bat}}$	Energie in der Batterie des Nutzers n zum Zeitpunkt t	kWh
$E^{\text{Bat,init}}$	Energie in der Batterie des Nutzers n zum Zeitpunkt t mit eingerechneten Fahrverbräuchen	kWh
$E_n^{\text{Bat,max}}$	Batteriekapazität des Nutzers n	kWh
$E_{t,n}^{\text{Bat,max,mög}}$	Maximal mögliche Energie in der Batterie des Nutzers n zum Zeitpunkt t	kWh
$E_n^{\text{Bat,min}}$	Vom Aggregator definierte individuelle Mindestenergie der Batterie des Nutzers n	kWh
$E_n^{\text{Lad,max,mög}}$	Maximal mögliche Energie, die Nutzer n während einer Optimierungsperiode laden kann	kWh
$E_{t,n}^{\text{Lad,min}}$	Energie, die mindestens bis zum Zeitpunkt t geladen werden muss	kWh
$E_{t,n}^{\text{Ver}}$	Entnommene Energie aus der Batterie des Nutzers n zum Zeitpunkt t durch Fahren	kWh

K_{Zts}	Anzahl der Zeitscheiben während einer Optimierungsperiode, über die der Aggregator die SRL-Vorhaltung konstant halten muss	
$K_{Zts,SRL}$	Anzahl der Zeitscheiben während einer Optimierungsperiode, für die der geplante Strombezug aus $q = 3$ durch die Resultate bereits stattgefundener SRL-Auktionen vorgegeben ist	
N	Anzahl der Nutzer des Smart-Charging-Systems	
N_G	Anzahl der pro Nutzergruppe	
n	Ein Nutzer des Systems	
$P_{t,q,n}^{Lad}$	Definierte Ladeleistung für den Zeitpunkt t aus der Quelle q für Nutzer n	kW
$P_{t,n}^{Lad,max}$	Technisch maximale Ladeleistung zum Zeitpunkt t für Nutzer n	kW
$P_{t,n}^{PV}$	Für das Laden zur Verfügung stehende Leistung der PV-Anlage des Nutzer n zum Zeitpunkt t	kW
$P_{t,Agg}^{SRL,Ang}$	Vorzuhaltende SRL des Aggregators zum Zeitpunkt t als Ergebnis der SRL-Auktion	MW
q	Bilanzielle Strombezugsquelle	
T	Anzahl der Zeitschritte im Optimierungszeitraum	
T_{Cons}	Zeitliche Dauer, über die der Aggregator die SRL-Vorhaltung konstant halten muss	h
t	Zeitschritt im Optimierungszeitraum	
Δt	Zeitliche Dauer eines Zeitschritts	h
t_h	Uhrzeit eines Zeitschritts im Optimierungszeitraum in Stunden	h
$t_{h,SRL,Auk}$	Uhrzeit des Zeitschritts, in dem die SRL-Auktionen stattfinden, in Stunden	h
$t_n^{Lad,öff,Beg}$	Beginn eines Ladevorgangs von Nutzer n an einem öffentlichen Ladepunkt	
$t_n^{Lad,öff,End}$	Ende eines Ladevorgangs von Nutzer n an einem öffentlichen Ladepunkt	
$\Delta t_n^{Lad,öff}$	Dauer eines eines Ladevorgangs von Nutzer n an einem öffentlichen Ladepunkt	

Abbildungsverzeichnis

1.1.	Entwicklung des historischen deutschen Strommix und die politische Zielsetzung des Klimaschutzprogramms im Jahr 2030 (2030KSP). Die historischen Daten stammen von [5], die Zielsetzung wurde in [1, S. 39] formuliert.	1
1.2.	Neuzulassungen und Marktanteile für BEV-Pkws und PHEV-Pkws in Deutschland seit 2014. Die Daten stammen von [7].	2
2.1.	Bilanzkreismanagement durch die Nutzung verschiedener Stromprodukte. In Anlehnung an [17, S. 456].	8
2.2.	Preisbildung im Day-Ahead-Handel der EPEX Spot. Dargestellt sind die aggregierten Angebots- und Nachfragekurven aller Day-Ahead-Aufträge zur Erfüllung in der ersten Stunde des 30.06.2020 an der EPEX Spot. Die Daten stammen von der Website der EEX [19].	9
2.3.	Aufschlüsselung des durchschnittlichen Strompreises für eine Kilowattstunde für Haushaltskunden für das Jahr 2020. Betrachtet wurde ein Haushalt mit einem Stromverbrauch von 3500 kWh/a. Die Daten stammen von [21].	10
2.4.	Unterscheidung von Regelleistungsarten nach ihrem Einsatzzeitpunkt. In Anlehnung an [23] und [24, S. 201].	11
2.5.	Feste Einspeisevergütung für PV-Anlagen auf Wohngebäuden mit Peakleistungen kleiner als 10 kW und durchschnittliche Bruttostrompreise für Haushalte mit einem Stromverbrauch von 3500 kWh/ im zeitlichen Verlauf seit 2001. Die EEG-Vergütungsdaten stammen von [31], die Strompreisedaten von [21].	14
2.6.	Messkonzept für einen Haushalt mit PV-Anlage und LE als steuerbare Verbrauchseinrichtung mit einer Kaskadenschaltung. In Anlehnung an [36, S. 8] und [37, S. 12].	18
2.7.	Simplifizierter Schaltplan für ein leitfähiges Ladesystem. In Anlehnung an [38].	19
2.8.	Autokorrelationsfunktionen zweier AR(1)-Modelle. In Anlehnung an [47, S. 35]. . .	24
3.1.	Aufbau des modellierten Systems und Interaktionen zwischen den Systemelementen.	34
3.2.	Prozeduraler Ablauf der Ladevorgangsoptimierung. Prozessschritte der vorausplanenden Ebene sind in rot, der operativen in blau dargestellt.	37
3.3.	Verknüpfungslogik der verwendeten Datensätze, die der Vorausplanungsalgorithmus nutzt, um die optimalen Ladezeiten und -leistungen für die nächsten 48 Stunden zu berechnen. Ein schraffiertes Farbmuster zeigt an, dass der Datensatz externe Daten inkludiert und durch eigene Annahmen ergänzt wurde (Fahrzeug- und Ladedaten) bzw. erst im Rahmen dieser Arbeit zu einem verwertbaren Datensatz wurde (PV-Anlagendaten).	38
3.4.	Verläufe des arithmetischen Mittelwerts und 90 %-Intervalls des Day-Ahead-MCPs an der EPEX Spot und der deutschlandweiten Netzlast für den Simulationszeitraum. Die Daten stammen von [81].	45
3.5.	Autokorrelationsfunktion des Day-Ahead MCPs an der EPEX Spot für den Simulationszeitraum. Die Daten stammen von [81].	45

3.6. Tagesdurchschnittliche Verläufe der ausgezahlten Regelleistungs- und Regularbeitspreise sowie der Regelleistungsabrufe. Die Preise sind leistungsgewichtete Mittelwerte. Die Rohdaten sind unter [83] abrufbar.	50
4.1. Durchschnittlich prognostizierter MCP und tatsächlicher MCP des Day-Ahead-Marktes.	61
4.2. Durchschnittliche Startzeit, zu dem ein Nutzer sein BEV mit einem (a) privaten oder (b) öffentlichen Ladepunkt verbindet.	64
4.3. Verteilung der Energie pro Ladevorgang an (a) privaten und (b) öffentlichen Ladepunkten. Ein Datenpunkt umfasst ein 4 kWh-Intervall.	65
4.4. Dauer der Verbindungszeit mit einem (a) privaten und (b) öffentlichen Ladepunkt. Ein Datenpunkt umfasst ein 2 h-Intervall.	66
4.5. Ladeverfügbarkeit der Flotte und geplantes Lastprofil der Optimierung um 8:00 Uhr. Beim gezeigten Lastprofil wurden nur die Planungen für den Tag $d + 1$ betrachtet. Die Kurve „Summe“ gleicht den summierten Ladeleistungen der drei Bezugsquellen. Ihr Farbverlauf entspricht dem Anteil der Bezugsquellen an der summierten Ladeleistung im Tagesverlauf.	67
4.6. Lastprofile der Primärsimulation für das Basis- und Smart-Charging-Szenario. Zum Vergleich werden die gemessenen Lastprofile von Jedlix gezeigt. Sie stammen von [43] und wurden so skaliert, dass die geladene Energiemenge dem jeweiligen summierten Lastprofil der Simulation gleicht.	68
4.7. Reales Lastprofil der Sekundärsimulation. Es wurden 100 000 Nutzer im Zeitraum vom 01.09.2019 bis zum 24.09.2019 simuliert.	70
4.8. Reduktion der Ladekosten pro Jahr und Fahrzeug vom Basisszenario zum Smart-Charging-Szenario in Abhängigkeit der geladenen Energiemenge.	73
A.1. Struktur eines NARXNETs mit einer exogenen Variablen. In Anlehnung an [102, S. 535].	86
A.2. Verläufe des arithmetischen Mittelwerts des Day-Ahead MCPs der EPEX Spot und der Netzlast im Wochendurchschnitt für den Simulationszeitraum. Die Daten stammen von [81].	88
A.3. Autokorrelationsfunktionen für den Regelleistungspreis, den Regularbeitspreis und die Regelleistungsabrufe im Simulationszeitraum. Betrachtet wurde negative SRL. Die Metriken basieren jeweils auf dem leistungsgewichteten arithmetischen Mittelwert ihrer Ausgangsgröße. Es wurden nur die Preisgebote aller Bieter betrachtet, die unter dem Grenzpreis für Regelleistung lagen. Die gezahlten Regularbeitspreise betrachten nur die Preise für tatsächlich erbrachte Regularbeit. Folgerichtig sind die Gebotspreise in den vierstündigen Zeitscheiben aufgelöst und die tatsächlich ausgezahlten Preise in den viertelstündigen Intervall, in denen auch die Höhe der abgerufenen Regelleistung veröffentlicht wird. Die Rohdaten sind unter [83] abrufbar.	89
A.4. Durchschnittliche Lastprofile als Ergebnis der vorausplanenden Optimierungen in der Primärsimulation. Gezeigt werden jeweils die planerischen Ladeleistungen für den Tag $d + 1$	90
A.5. Ladeverfügbarkeit und durchschnittliche Lastprofile aufgeteilt nach Wochentag und Wochenende in der Primärsimulation.	91
A.6. Anteile der drei Strombezugsquellen im Verlauf der Primärsimulation.	92

A.7. Durchschnittliche Lastprofile für verkürzte Regelleistungszeitscheiben. In den Simulationen wurden 1000 Nutzer betrachtet. 93

Tabellenverzeichnis

2.1. Schema zur Abrechnung von Ausgleichsenergie über den reBAP. In Anlehnung an [15].	6
2.2. Wesentliche Merkmale der Auktionsverfahren der Regelleistungstypen die bis zum 30.06.2020 gültig waren. In Anlehnung an [25, S. 18].	12
3.1. Verwendete Fahrzeugdaten zur Generierung eines realistischen Flottenverhaltens. Der Flottenanteil der Fahrzeuge basiert auf den Marktanteilen der Fahrzeuge an den BEV-Neuzulassungen in Deutschland im Jahr 2019 [72]. Die Angaben zu den Nettobatteriegrößen, den Ladeleistungen und den Verbräuchen stammen von der EV Database [73]. Die Ladeeffizienz basiert auf Messungen des ADACs [74]. Zwei Werte pro Spalte repräsentieren Unterschiede pro Modellvariante.	40
3.2. Verteilung der maximalen Ladeleistungen der privaten Ladepunkte. Angenommen wurden die üblichen Ladeleistungsstufen für das Laden an Schuko- und CEE-Steckdosen sowie an ein- bis dreiphasigen Wallboxen mit 16 A pro Phase und 32 A pro Phase bei 22 kW. Die Verteilung beruht auf eigenen Annahmen.	40
3.3. Verteilung der Ladevorgänge an öffentlichen Ladepunkten nach Ladeleistung. Ladesäulen mit 11 kW und 22 kW werden als AC-Ladepunkte betrachtet, höhere Leistungen als DC-Ladepunkte. Die Verteilung beruht auf eigenen Annahmen.	41
3.4. Verwendete Vertragsmodalitäten für Nutzer, deren private Ladepunkte als steuerbare Verbrauchseinrichtungen angemeldet sind. Die Daten basieren auf den veröffentlichten Angaben der VNBs [37], [75]–[78]. Die gezeigten NNE sind Nettowerte (exklusive Umsatzsteuer). Netze BW reduziert in dem angegebenen Zeitraum lediglich den Ladestrom auf 8 A pro Phase auf.	42
3.5. Nutzerdaten, die der Aggregator verwendet und deren Zustand ihm entweder zu jeder Zeit (statisch), zum Beginn einer Prognose oder für den aktuellen 48 h-Zeitraum bekannt sind.	43
3.6. Korrelationskoeffizienten für den Day-Ahead-MCP mit den Erzeugungs- und Lastprognosen der ÜNBs. Die Rohdaten stammen von [81].	46
3.7. Die ersten sechs und letzten beiden Einträge der anonymen Angebotsliste für den 01.03.2020 für negative SRL der ersten Zeitscheibe des Tages von 00:00 Uhr bis 04:00 Uhr für den deutschen Netzregelverbund. Die Rohdaten sind unter [83] abrufbar.	48
3.8. Auszug aus der Liste der Abrufwerte für negative Sekundärregelarbeit am 01.03.2020 für den gesamten deutschen Netzregelverbund. Die Abrufwerte entsprechen der durchschnittlich benötigten Leistung innerhalb einer Viertelstunde. Die Rohdaten sind unter [83] abrufbar.	49
3.9. Korrelationskoeffizienten für den Regelleistungspreis, die tatsächlich gezahlten Regelarbeitspreise und die Regelleistungsabrufe mit den Erzeugungs- und Lastprognosen der ÜNBs. Bei den Preisen wurden jeweils die leistungsgewichteten Mittelwerte verwendet. Die Prognosedaten stammen von [81] und die Rohdaten des Regelleistungsmarktes von [83].	51
3.10. Anzahl der Gleichungen bzw. Ungleichungen pro Nebenbedingung.	57

4.1. Fehlermaße der Prognoseverfahren für die Day-Ahead-MCP-Prognose.	62
4.2. Indikatorvergleich mit externen Quellen. Für die Angabe des Fahrverbrauch der externen Quelle wurden die gemessenen Verbräuche im ADAC Ecotest der modellierten Fahrzeuge ihrem Anteil an der Nutzerschaft entsprechend (vgl. Tabelle 3.1) in einem Mittelwertwert zusammengefasst.	64
4.3. Vergleich der durchschnittlichen Preise für negative Sekundärregelleistung und -arbeit. Die Durchschnitte stellen die tatsächlich gezahlten Vergütungen (Leistung) bzw. Kosten (Arbeit) dar, nicht die Gebotspreise.	70
4.4. Geladene Energie und Ladekosten aufgeschlüsselt nach Bezugsquelle für das Smart-Charging- und das Basisszenario.	71
4.5. Geladene Energie und Ladekosten nach Nutzertyp aufgeschlüsselt nach Bezugsquelle für das Smart-Charging- und das Basisszenario. Die geladene Energie wird pro Tag und Fahrzeug angegeben. Die Spalte „Normal“ umfasst alle Nutzer ohne PV-Anlage und ohne Teilnahme am netzdienlichen Laden. Die Spalten „PV-Anlage“ und „§ 14a EnWG“ beziehen sich entsprechend auf Nutzer, die eine PV-Anlage betreiben bzw. am netzdienlichen Laden partizipieren.	72
5.1. Prognosequalitäten in der Literatur für die Prognose des Day-Ahead-MCPs an der EPEX Spot für das deutsche Marktgebiet.	79
A.1. Daten der verwendeten PV-Anlagen, die aus dem Sunny Portal der SMA Solar Technology AG [79] per Screen Scraper extrahiert wurden. Die letzte Spalte gibt die prognostizierte Erzeugung.	88
A.2. Anteile der Bezugsquellen an der gesamten Ladeleistung nach Optimierungsschritt in %. Die Zeilen „Real“ bezieht sich auf die tatsächliche genutzte Ladeleistung. Im Smart-Charging-Szenario entspricht dies dem Ergebnis des operativen Algorithmus. Bei der Interpretation der Angaben für 4:00 Uhr muss berücksichtigt werden, dass die erste vierstündige Zeitscheibe des Tages nicht mehr erfasst wird. Aufgrund des hohen Regularbeitsbezug während dieser Zeit sinkt der Anteil dieser Bezugsquelle.	92

Literaturverzeichnis

- [1] Deutsche Bundesregierung, *Klimaschutzprogramm 2030 der Bundesregierung zur Umsetzung des Klimaschutzplans 2050*, Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit, 2019. Adresse: <https://www.bundesregierung.de/resource/blob/975226/1679914/e01d6bd855f09bf05cf7498e06d0a3ff/2019-10-09-klima-massnahmen-data.pdf?download=1> (besucht am 30.03.2021).
- [2] P. Icha und G. Kuhs, *Entwicklung der spezifischen Kohlendioxid-Emissionen des deutschen Strommix in den Jahren 1990 - 2019*, Umweltbundesamt, 2020. Adresse: https://www.umweltbundesamt.de/sites/default/files/medien/1410/publikationen/2020-04-01_climate-change_13-2020_strommix_2020_fin.pdf (besucht am 30.03.2021).
- [3] D. Drosihn, *Übersicht zur Entwicklung der energiebedingten Emissionen und Brennstoffeinsätze in Deutschland 1990 - 2018*, Umweltbundesamt, 2020. Adresse: https://www.umweltbundesamt.de/sites/default/files/medien/1410/publikationen/2020-04-01_climate-change_14-2020_energiebedingte-emissionen-brennstoffe.docx_.pdf (besucht am 30.03.2021).
- [4] Umweltbundesamt, *Erneuerbare Energien in Deutschland - Daten zur Entwicklung im Jahr 2020*, 2021. Adresse: https://www.umweltbundesamt.de/sites/default/files/medien/5750/publikationen/2021_hgp_erneuerbareenergien_deutsch_bf.pdf (besucht am 30.03.2021).
- [5] Bundesverband der Energie-und Wasserwirtschaft e. V. (2021). „Stromerzeugung in Deutschland 1991-2020,“ Adresse: https://www.bdew.de/media/documents/20210322_D_Stromerzeugung1991-2020.pdf (besucht am 01.04.2021).
- [6] Kraftfahrtbundesamt. (2020). „Bestand an Kraftfahrzeugen und Kraftfahrzeuganhängern nach Bundesländern, Fahrzeugklassen und ausgewählten Merkmalen, 1. Oktober 2020,“ Adresse: https://www.kba.de/SharedDocs/Publikationen/DE/Statistik/Fahrzeuge/FZ/2020/fz27_202010_xlsx.xlsx?__blob=publicationFile&v=4 (besucht am 02.11.2020).
- [7] Kraftfahrtbundesamt. (2014-2020). „Neuzulassungen von Kraftfahrzeugen und Kraftfahrzeuganhängern - Monatsergebnisse,“ Adresse: https://www.kba.de/DE/Statistik/Produktkatalog/produkte/Fahrzeuge/fz8/fz8_gentab.html?nn=1146130 (besucht am 28.01.2021).
- [8] G. Friedl, F. Walcher, J. Stäglich, F. Thomas und D. Manteuffel, *Blackout E-Mobilität setzt Netzbetreiber unter Druck*, TU München und Oliver Wyman, 2018. Adresse: https://www.oliverwyman.de/content/dam/oliver-wyman/v2-de/publications/2018/Jan/2018_OliverWyman_E-MobilityBlackout.pdf (besucht am 06.01.2021).
- [9] Agora Verkehrswende, Agora Energiewende und Regulatory Assistance Project, *Verteilnetzausbau für die Energiewende - Elektromobilität im Fokus*, 2019. Adresse: https://www.agora-energiewende.de/fileadmin2/Projekte/2018/Netzausbau_Elektromobilitaet/Agora-Verkehrswende_Agora-Energiewende_EV-Grid_WEB.pdf (besucht am 06.01.2021).

-
- [10] J. García-Villalobos, I. Zamora, J. I. San Martín, F. J. Asensio und V. Aperribay, „Plug-in electric vehicles in electric distribution networks: A review of smart charging approaches,“ *Renewable and Sustainable Energy Reviews*, Jg. 38, S. 717–731, 2014, ISSN: 1364-0321. DOI: 10.1016/j.rser.2014.07.040.
- [11] A. Löschel, D. T. G. Rübelke, W. Ströbele, W. Pfaffenberger und M. Heuterkes, *Energiewirtschaft, Einführung in Theorie und Politik*, 4., vollständig überarbeitete Auflage, Ser. De Gruyter Studium. Berlin: De Gruyter Oldenbourg, 2020, 421 S., ISBN: 3110556324. DOI: 10.1515/9783110556339.
- [12] M. Zapf, *Stromspeicher und Power-to-Gas im deutschen Energiesystem*. Wiesbaden: Springer Fachmedien Wiesbaden, 2017, ISBN: 978-3-658-15072-3. DOI: 10.1007/978-3-658-15073-0.
- [13] Bundesnetzagentur, *Fahrplananmeldung in Deutschland*, 2021. Adresse: https://www.bundesnetzagentur.de/DE/Beschlusskammern/1_GZ/BK6-GZ/2018/BK6-18-061/Mitteilungen/BK6-18-061_Mit_04.pdf?__blob=publicationFile&v=1 (besucht am 09.04.2021).
- [14] Bundesnetzagentur, *Lesefassung Standardbilanzkreisvertrag V2.1 gültig ab 01.08.2020*, 2019. Adresse: https://www.bundesnetzagentur.de/DE/Beschlusskammern/1_GZ/BK6-GZ/2018/BK6-18-061/BK6-18-061_Standardbilanzkreisvertrag_01_08_2020.pdf?__blob=publicationFile&v=4 (besucht am 01.01.2021).
- [15] 50Hertz, Amprion, TenneT und TransnetBW, *Modell zur Berechnung des regelzonenübergreifenden einheitlichen Bilanzausgleichsenergiepreises (reBAP) unter Beachtung des Beschlusses BK6-12-024 der Bundesnetzagentur vom 25.10.2012*, 2016. Adresse: https://www.regelleistung.net/ext/download/REBAP_BNETZA_BK6-12-024 (besucht am 04.01.2021).
- [16] Bundesverband der Energie- und Wasserwirtschaft e. V. und Verband kommunaler Unternehmen e. V., *Stellungnahme zu den BNetzA-Leitplanken zur SLP-Bilanzierung bei intelligenten Messsystemen*, 2018. Adresse: https://www.bdew.de/media/documents/Stn_20180629_SLP_bei_IMS_ohne_AP.pdf (besucht am 26.03.2021).
- [17] P. Konstantin, *Praxisbuch Energiewirtschaft*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2017, ISBN: 978-3-662-49822-4. DOI: 10.1007/978-3-662-49823-1.
- [18] J. Baumhögger und C. Perret, „Großhandelsmärkte für Strom und Gas,“ in *Industrielle Energiestrategie, Praxishandbuch für Entscheider des produzierenden Gewerbes*, F. J. Matzen und R. Tesch, Hrsg., Wiesbaden: Springer Gabler, 2017, S. 75–97, ISBN: 978-3-658-07606-1. DOI: 10.1007/978-3-658-07606-1.
- [19] European Energy Exchange. (2020). „DE Day-Ahead Auction Aggregated Curves EOD 30.06.2020,“ Adresse: <https://webshop.eex-group.com/data-type/de-day-ahead-auction-aggregated-curves-eod> (besucht am 04.01.2021).
- [20] H.-W. Schiffer, *Energiemarkt Deutschland, Daten und Fakten zu konventionellen und erneuerbaren Energien*. Wiesbaden: Springer Vieweg, 2019, 564 S., ISBN: 9783658230241. DOI: 10.1007/978-3-658-23024-1.
-

- [21] Bundesverband der Energie- und Wasserwirtschaft e. V. (2021). „BDEW-Strompreisanalyse Januar 2021, Haushalte und Industrie,“ Adresse: https://www.bdew.de/media/documents/BDEW-Strompreisanalyse_no_halbjaehrlich_Ba_online_28012021.pdf (besucht am 08.01.2021).
- [22] Next Kraftwerke. (2020). „Was ist der Strommarkt?“ Adresse: <https://www.next-kraftwerke.de/wissen/strommarkt> (besucht am 30.12.2020).
- [23] Next Kraftwerke. (2020). „Was ist Regelenergie?“ Adresse: <https://www.next-kraftwerke.de/wissen/regelenergie> (besucht am 05.01.2021).
- [24] Bundesnetzagentur und Bundeskartellamt, *Monitoringbericht 2019*, 2020. Adresse: https://www.bundesnetzagentur.de/SharedDocs/Mediathek/Berichte/2019/Monitoringbericht_Energie2019.pdf?__blob=publicationFile&v=6 (besucht am 28.12.2020).
- [25] Consentec, *Beschreibung von Konzepten des Systemausgleichs und der Regelreservemärkte in Deutschland*, 2020. Adresse: https://www.regelleistung.net/ext/download/MARKTBESCHREIBUNG_CONS (besucht am 05.01.2021).
- [26] 50Hertz, Amprion, TenneT und TransnetBW. (2018). „Marktinformation - Anpassung der Abrechnungsbedingungen für Sekundärregelarbeit,“ Adresse: https://www.regelleistung.net/ext/download/Konsultation_SRL_Abrechnung (besucht am 09.02.2021).
- [27] F. T. Rolli, *Marktstrukturanalyse der Stromwirtschaft, Der Regelleistungsmarkt und seine Bedeutung für die ordnungspolitische Gestaltung hinsichtlich Entflechtung, Wettbewerb und Regulierung*, 1. Auflage 2011, Ser. Wettbewerb und Regulierung von Märkten und Unternehmen. Baden-Baden: Nomos Verlag, 2011, Bd. 17, ISBN: 9783845232836. DOI: 10.5771/9783845232836.
- [28] Bundesnetzagentur, *Beschluss BK6-17-046*, 2017. Adresse: https://www.bne-online.de/fileadmin/bne/Dokumente/Englisch/Policy_Papers/BNetza_BK6_17_046_Beschluss_vom_14_09_2017.pdf (besucht am 06.01.2021).
- [29] 50Hertz, Amprion, TenneT und TransnetBW. (2020). „Präqualifikationsverfahren für Regelreserveanbieter (FCR, aFRR, mFRR) in Deutschland,“ Adresse: https://www.regelleistung.net/ext/download/PQ_Bedingungen_FCR_aFRR_mFRR (besucht am 06.01.2021).
- [30] B. Buchholz, V. Bühner, H. Frey, W. Glaunsinger, M. Kleimaier, P. Magnus, H. Roman, J. Schmiesing, J. Stein, Z. Styczynski und H. Baden, *Smart Distribution 2020 Virtuelle Kraftwerke in Verteilungsnetzen - Technische, regulatorische und kommerzielle Rahmenbedingungen*, Verband der Elektrotechnik Elektronik Informationstechnik e. V., 2008. Adresse: <https://shop.vde.com/de/vde-studie-smart-distribution-2020-virtuelle-kraftwerke-in-verteilungsnetzen-4> (besucht am 06.01.2021).
- [31] 50Hertz, Amprion, TenneT und TransnetBW. (2021). „EEG-Vergütungskategorientabelle 2021,“ Adresse: https://www.netztransparenz.de/portals/1/EEG-Verguetungskategorien_EEG_2021_20201231.xls (besucht am 01.04.2021).
- [32] Bundesnetzagentur und Bundeskartellamt, *Monitoringbericht 2020*, 2021. Adresse: https://www.bundesnetzagentur.de/SharedDocs/Mediathek/Berichte/2020/Monitoringbericht_Energie2020.pdf;jsessionid=25FEAF711652B5907A3AD9069F4DA30E?__blob=publicationFile&v=5 (besucht am 05.02.2021).

-
- [33] Bundesministerium der Finanzen, *Umsatzsteuerrechtliche Behandlung von Photovoltaik- und KWK-Anlagen; Abschaffung des Eigenverbrauchsbonus nach § 33 Abs. 2 EEG durch die EEG-Novelle zur Photovoltaik 2012; BFH-Urteil vom 12. Dezember 2012, XI R 3/10*, 2014. Adresse: https://www.bundesfinanzministerium.de/Content/DE/Downloads/BMF_Schreiben/Steuerarten/Umsatzsteuer/Umsatzsteuer-Anwendungserlass/2014-09-19-USt-Photovoltaik-KWK-Anlagen.pdf?__blob=publicationFile&v=2 (besucht am 11.01.2021).
- [34] J. K. Wittlinger, Hrsg., *Photovoltaikanlagen Im Steuerrecht, Steuerliche Grundlagen zur Nutzung der Sonnenenergie*, 3rd ed., Wiesbaden: Springer Gabler. in Springer Fachmedien Wiesbaden GmbH, 2020, 204 S., ISBN: 978-3-658-28442-8.
- [35] Nationale Plattform Elektromobilität, *Fortschrittsbericht 2019*, Bundesministerium für Verkehr und digitale Infrastruktur, 2019. Adresse: https://www.plattform-zukunft-mobilitaet.de/wp-content/uploads/2019/12/NPM_Fortschrittsbericht_2019.pdf (besucht am 06.03.2021).
- [36] Verband der Bayerischen Energie- und Wasserwirtschaft e. V. (2019). „VBEW-Messkonzepte - Handout zur Auswahl der Messkonzepte,“ Adresse: https://www.e-netzeallgaeu.de/media/VBEW-Messkonzepte_Handout.pdf (besucht am 13.01.2021).
- [37] Netze BW. (2020). „Technische Mindestanforderungen zur netzdienlichen Steuerung von elektrischen Anlagen im Verteilnetz Strom,“ Adresse: https://assets.ctfassets.net/xytfb1vrn7of/6TIIfm0d9BAatS1WvTSY3zis/4dd36bd0311ac927d19c00b5c5490bda/2020_03_NetzeBW_TMA_Netzdienliche_Steuerung.pdf (besucht am 03.11.2020).
- [38] B. Lawson. (2018). „Electric Vehicle Charging Infrastructure,“ Adresse: <https://www.mpoweruk.com/infrastructure.htm> (besucht am 12.01.2021).
- [39] Verband der Elektrotechnik, Elektronik und Informationstechnik | Forum Netztechnik/-Netzbetrieb, *Netzintegration Elektromobilität, Leitfaden für eine flächendeckende Verbreitung von E-Fahrzeugen*, 2019. Adresse: <https://www.vde.com/resource/blob/1896384/8dc2a98adff3baa259dbe98ec2800bd4/fnn-hinweis--netzintegration-e-mobilitaet-data.pdf> (besucht am 06.01.2021).
- [40] E. Delmonte, N. Kinnear, B. Jenkins und S. Skippon, „What do consumers think of smart charging? Perceptions among actual and potential plug-in electric vehicle adopters in the United Kingdom,“ *Energy Research & Social Science*, Jg. 60, S. 433–440, 2020, ISSN: 2214-6296. DOI: 10.1016/j.erss.2019.101318.
- [41] J. Bailey und J. Axsen, „Anticipating PEV buyers’ acceptance of utility controlled charging,“ *Transportation Research Part A: Policy and Practice*, Jg. 82, S. 29–46, 2015, ISSN: 09658564. DOI: 10.1016/j.tra.2015.09.004.
- [42] TransnetBW. (2021). „TransnetBW und Jedlix kooperieren: Gebündelte Kompetenz für Mobilitäts- und Energiewende,“ Adresse: <https://www.transnetbw.de/de/presse/presseinformationen/presseinformation/transnetbw-und-jedlix-kooperieren-gebundelte-kompetenz-fuer-mobilitaets-und-energiewende> (besucht am 08.03.2021).

- [43] N. Refa und N. Hubbers, *Impact of Smart Charging on EVs Charging Behaviour Assessed from Real Charging Events*, ElaadNL und Jedlix, 2019. Adresse: https://www.researchgate.net/profile/Nazir_Refa/publication/333262496_Impact_of_Smart_Charging_on_EVs_Charging_Behaviour_Assessed_from_Real_Charging_Events/links/5ce4ff7b458515712eba7809/Impact-of-Smart-Charging-on-EVs-Charging-Behaviour-Assessed-from-Real-Charging-Events.pdf (besucht am 06.10.2021).
- [44] Jedlix. (2020). „Jedlix Website,“ Adresse: <https://jedlix.com/en/>.
- [45] Next Kraftwerke. (2018). „Next Kraftwerke and Jedlix launch initiative to use electric car batteries for grid stability,“ Adresse: <https://www.next-kraftwerke.be/en/next-kraftwerke-and-jedlix-launch-initiative-to-use-electric-car-batteries-for-grid-stability/> (besucht am 13.01.2021).
- [46] M. Guidolin und M. Pedio, *Essentials of time series for financial applications*, eng. London, United Kingdom: Academic Press an imprint of Elsevier, 2018, ISBN: 0128134100. DOI: 10.1016/C2016-0-04275-4.
- [47] R. S. Tsay, *Analysis of financial time series*, eng, Third edition, Ser. Wiley series in probability and statistics. Hoboken, N.J: Wiley, 2010, 677 S., ISBN: 1282707833. DOI: 10.1002/9780470644560.
- [48] S. Bittanti, *Model identification and data analysis*. Hoboken, NJ, USA: Wiley, 2019, pages cm, ISBN: 9781119546368. Adresse: <https://www.wiley.com/en-us/Model+Identification+and+Data+Analysis-p-9781119546313> (besucht am 01.04.2021).
- [49] D. Schröder und M. Buss, *Intelligente Verfahren - Identifikation und Regelung Nichtlinearer Systeme*, 2nd ed. Berlin, Heidelberg: Vieweg, 2017, 932 S., ISBN: 9783662553275. DOI: 10.1007/978-3-662-55327-5.
- [50] W. Hochstättler, *Lineare Optimierung*. Berlin: Springer Spektrum, 2017, 305 S., ISBN: 3662544245. DOI: 10.1007/978-3-662-54425-9.
- [51] T. Unger und S. Dempe, *Lineare Optimierung, Modell, Lösung, Anwendung*, 1. Aufl. Wiesbaden: Vieweg+Teubner Verlag / GWV Fachverlage GmbH Wiesbaden, 2010, ISBN: 9783834896599. DOI: 10.1007/978-3-8348-9659-9.
- [52] A. Koop und H. Moock, *Lineare Optimierung - eine anwendungsorientierte Einführung in Operations Research*, 2. Auflage. Berlin, Heidelberg: Springer Spektrum, 2018, 297 S., ISBN: 9783662561416. DOI: 10.1007/978-3-662-56141-6.
- [53] K. H. Borgwardt, „Komplexität des Simplexverfahrens,“ in *Optimierung Operations Research Spieltheorie*, K. H. Borgwardt, Hrsg., Basel: Birkhäuser Basel, 2001, S. 143–160, ISBN: 978-3-7643-6519-6. DOI: 10.1007/978-3-0348-8252-1_9.
- [54] R. J. Bessa und M. A. Matos, „Global against divided optimization for the participation of an EV aggregator in the day-ahead electricity market. Part II: Numerical analysis,“ *Electric Power Systems Research*, Jg. 95, S. 319–329, 2013, ISSN: 0378-7796. DOI: 10.1016/j.epsr.2012.08.013.
- [55] R. J. Bessa und M. A. Matos, „Global against divided optimization for the participation of an EV aggregator in the day-ahead electricity market. Part I: Theory,“ *Electric Power Systems Research*, Jg. 95, S. 309–318, 2013, ISSN: 0378-7796. DOI: 10.1016/j.epsr.2012.08.007.

-
- [56] R. J. Bessa und M. A. Matos, „Optimization models for an EV aggregator selling secondary reserve in the electricity market,“ *Electric Power Systems Research*, Jg. 106, S. 36–50, 2013, ISSN: 0378-7796. DOI: 10.1016/j.epsr.2013.08.006.
- [57] R. J. Bessa und M. A. Matos, „Optimization Models for EV Aggregator Participation in a Manual Reserve Market,“ *IEEE Transactions on Power Systems*, Jg. 28, Nr. 3, S. 3085–3095, 2013, ISSN: 0885-8950. DOI: 10.1109/TPWRS.2012.2233222.
- [58] E. Sortomme und M. A. El-Sharkawi, „Optimal Charging Strategies for Unidirectional Vehicle-to-Grid,“ *IEEE Transactions on Smart Grid*, Jg. 2, Nr. 1, S. 131–138, 2011, ISSN: 1949-3061. DOI: 10.1109/TSG.2010.2090910.
- [59] M. van der Kam und W. van Sark, „Smart charging of electric vehicles with photovoltaic power and vehicle-to-grid technology in a microgrid; a case study,“ *Applied Energy*, Jg. 152, S. 20–30, 2015, ISSN: 0306-2619. DOI: 10.1016/j.apenergy.2015.04.092.
- [60] P. Sánchez-Martín, S. Lumbreras und A. Alberdi-Alén, „Stochastic Programming Applied to EV Charging Points for Energy and Reserve Service Markets,“ *IEEE Transactions on Power Systems*, Jg. 31, Nr. 1, S. 198–205, 2016. DOI: 10.1109/TPWRS.2015.2405755.
- [61] N. Rotering und M. Ilic, „Optimal Charge Control of Plug-In Hybrid Electric Vehicles in Deregulated Electricity Markets,“ *IEEE Transactions on Power Systems*, Jg. 26, Nr. 3, S. 1021–1029, 2011. DOI: 10.1109/TPWRS.2010.2086083.
- [62] S. Han und K. Sezaki, „Development of an Optimal Vehicle-to-Grid Aggregator for Frequency Regulation,“ *IEEE Transactions on Smart Grid*, Jg. 1, Nr. 1, S. 65–72, 2010. DOI: 10.1109/TSG.2010.2045163, .
- [63] K. L. López, C. Gagné und M. Gardner, „Demand-Side Management Using Deep Learning for Smart Charging of Electric Vehicles,“ *IEEE Transactions on Smart Grid*, Jg. 10, Nr. 3, S. 2683–2691, 2019. DOI: 10.1109/TSG.2018.280824700.
- [64] M. Nour, S. M. Said, A. Ali und C. Farkas, „Smart Charging of Electric Vehicles According to Electricity Price,“ in *2019 International Conference on Innovative Trends in Computer Engineering*, Piscataway, New Jersey: Institute of Electrical and Electronics Engineers, 2019, S. 432–437, ISBN: 978-1-5386-5261-9. DOI: 10.1109/ITCE.2019.8646425.
- [65] R. Mehta, D. Srinivasan, A. M. Khambadkone, J. Yang und A. Trivedi, „Smart Charging Strategies for Optimal Integration of Plug-In Electric Vehicles Within Existing Distribution System Infrastructure,“ *IEEE Transactions on Smart Grid*, Jg. 9, Nr. 1, S. 299–312, 2018, ISSN: 1949-3061. DOI: 10.1109/TSG.2016.2550559.
- [66] S. Kamboj, W. Kempton und K. Decker, „Deploying power grid-integrated electric vehicles as a multi-agent system,“ 01, Bd. 1, 2011, S. 13–20. Adresse: http://ifaamas.org/Proceedings/aamas2011/papers/BP1_G38.pdf (besucht am 01.04.2021).
- [67] M. C. Kisacikoglu, F. Erden und N. Erdogan, „Distributed Control of PEV Charging Based on Energy Demand Forecast,“ *IEEE Transactions on Industrial Informatics*, Jg. 14, Nr. 1, S. 332–341, 2018, ISSN: 1551-3203. DOI: 10.1109/TII.2017.2705075.
- [68] G. Göhler, C. Schmaus und A.-L. Klingler, *Netzbelastungen und Netzdienstleistungen durch Elektrofahrzeuge*, Institut für Arbeitswissenschaft und Technologiemanagement, Universität Stuttgart, 2019. DOI: 10.18419/opus-10607.
-

- [69] I. Frenzel, J. Jarass, S. Trommer und B. Lenz, *Erstnutzer von Elektrofahrzeugen in Deutschland*, Deutsches Zentrum für Luft- und Raumfahrt e.V., 2015. Adresse: https://elib.dlr.de/96491/1/Ergebnisbericht_E-Nutzer_2015.pdf (besucht am 03.11.2020).
- [70] The New Motion BV. (2016). „Wer Fährt Elektroautos - Und Warum?“ Adresse: https://newmotion.com/de_DE/wer-faehrt-elektroautos-und-warum/ (besucht am 03.11.2020).
- [71] T. Gnann und P. Plötz. (2019). „REM 2030 Fahrprofile,“ Fraunhofer ISI, Adresse: <https://www.rem2030.de/rem2030-de/REM-2030-Fahrprofile.php> (besucht am 29.10.2020).
- [72] Kraftfahrtbundesamt. (2020). „Neuzulassungen von Personenkraftwagen nach Marken und Modellreihen im Dezember 2019,“ Adresse: https://www.kba.de/SharedDocs/Publikationen/DE/Statistik/Fahrzeuge/FZ/2019_monatlich/FZ10/fz10_2019_12_xlsx.xlsx?__blob=publicationFile&v=5 (besucht am 02.11.2020).
- [73] EV Database. (2020). „Spezifikationsseiten der Fahrzeuge,“ Adresse: <https://ev-database.org/> (besucht am 02.11.2020).
- [74] ADAC. (2020). „Stromverbrauch Elektroautos & Reichweiten im Vergleich,“ Adresse: <https://www.adac.de/rund-ums-fahrzeug/tests/elektromobilitaet/stromverbrauch-elektroautos-adac-test/> (besucht am 02.11.2020).
- [75] Westnetz GmbH. (2020). „Preisblätter Westnetz Strom 2020 ab 01.07.2020,“ Adresse: <https://iam.westnetz.de/-/media/westnetz/documents/ueber-westnetz/unter-netz/netzentgelte-strom/preisblaetter/Preisbltter-WESTNETZ-Strom-2020-07-01.pdf?la=de-DE&hash=85BB31594796F7774265C2391084AEA7BA9E9900> (besucht am 03.11.2020).
- [76] Westnetz GmbH. (2020). „eMobility/neues Preissystem,“ Adresse: <https://iam.westnetz.de/faq/emobility-neues-preissystem> (besucht am 03.11.2020).
- [77] Netze BW. (2020). „Flyer Ladesäulenbonus,“ Adresse: https://assets.ctfassets.net/xytfb1vrn7of/1awcjPLRbQkCwwawqAY0o8/6e018a68ebca027f366134ce7a6b3d53/IV_NetzeBW_Flyer_Lades_uhlenbonus_20200709.pdf (besucht am 03.11.2020).
- [78] E.DIS Netz GmbH. (2019). „Endgültige Netzentgelte 2020 Stand 13. Dezember 2019 Preisblätter Netzentgelte Strom der E.DIS Netz GmbH,“ Adresse: https://www.e-dis-netz.de/content/dam/revu-global/e-dis-netz/dokumente/Preisblaetter_Netzentgelte_Strom_20200101.pdf (besucht am 03.11.2020).
- [79] SMA Solar Technology AG. (2020). „Sunny Portal - Freigegebene Anlagen,“ Adresse: <https://www.sunnyportal.com/Templates/PublicPagesPlantList.aspx> (besucht am 03.11.2020).
- [80] meteoblue AG. (2020). „History Photovoltaic,“ Adresse: <https://docs.meteoblue.com/en/apis/weather-data/packages-api> (besucht am 03.11.2020).
- [81] Bundesnetzagentur | SMARD.de. (2020). „Daten für die Stromerzeugung, den Stromverbrauch, den Strommarkt und Systemdienstleistungen,“ Adresse: <https://www.smard.de/home/downloadcenter/download-marktdaten> (besucht am 03.11.2020).
- [82] EPEX SPOT. (2020). „Market Data,“ Adresse: https://www.epexspot.com/en/market-data?market_area=DE-LU&modality=Auction&sub_modality=DayAhead&product=60&data_mode=table&period= (besucht am 10.11.2020).

-
- [83] 50Hertz, Amprion, TenneT und TransnetBW. (2020). „Internetplattform zur Vergabe von Regelleistung,“ Adresse: <https://www.regelleistung.net/ext/> (besucht am 10.11.2020).
- [84] A. Gruber, S. von Roon und S. Fattler, *Wissenschaftliche Projektbegleitung des Projektes DSM Bayern*, Deutsche Energie-Agentur GmbH, 2016. Adresse: https://www.ffegmbh.de/images/stories/Berichte/456_dsm-in-bayern/160809_Wissenschaftliche_Projektbegleitung_DSM-Bayern_final.pdf (besucht am 01.04.2021).
- [85] M. Jafari, A. Gauchia, S. Zhao, K. Zhang und L. Gauchia, „Electric Vehicle Battery Cycle Aging Evaluation in Real-World Daily Driving and Vehicle-to-Grid Services,“ *IEEE Transactions on Transportation Electrification*, Jg. 4, Nr. 1, S. 122–134, 2018, ISSN: 2372-2088. DOI: 10.1109/TTE.2017.2764320.
- [86] A. Ahmadian, M. Sedghi, B. Mohammadi-ivatloo, A. Elkamel, M. Aliakbar Golkar und M. Fowler, „Cost-Benefit Analysis of V2G Implementation in Distribution Networks Considering PEVs Battery Degradation,“ *IEEE Transactions on Sustainable Energy*, Jg. 9, Nr. 2, S. 961–970, 2018. DOI: 10.1109/TSTE.2017.2768437.
- [87] D. Wang, J. Coignard, T. Zeng, C. Zhang und S. Saxena, „Quantifying electric vehicle battery degradation from driving vs. vehicle-to-grid services,“ *Journal of Power Sources*, Jg. 332, S. 193–203, 2016, ISSN: 0378-7753. DOI: 10.1016/j.jpowsour.2016.09.116.
- [88] ElaadNL. (2020). „Open Datasets for Electric Mobility Research | Update April 2020,“ Adresse: https://platform.elaad.io/analyses/ElaadNL_opendata.php (besucht am 25.09.2020).
- [89] ADAC. (2020). „ADAC EcoTest - Fünf Sterne für die Umwelt,“ Adresse: <https://www.adac.de/infotestrat/tests/eco-test/default.aspx?redirectId=quer.ecotest> (besucht am 06.03.2021).
- [90] U. Heller, *DAT Report 2020*, Deutsche Automobil Treuhand, 2020.
- [91] L. Franckx, *Total cost of ownership of electric cars compared to diesel and gasoline cars in Belgium*, Federal Planning Bureau Belgium, 2020. Adresse: https://www.researchgate.net/profile/Laurent_Franckx2/publication/338622760 (besucht am 08.04.2021).
- [92] Statistisches Bundesamt. (2020). „Stromverbrauch der privaten Haushalte nach Haushaltsgrößenklassen,“ Adresse: <https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Umwelt/UGR/private-haushalte/Tabellen/stromverbrauch-haushalte.html#fussnote-1-133562> (besucht am 10.03.2021).
- [93] Bundesnetzagentur. (2021). „Marktstammdatenregister,“ Adresse: <https://www.marktstammdatenregister.de/MaStR/Einheit/Einheiten/ErweiterteOeffentlicheEinheitenuebersicht> (besucht am 11.01.2021).
- [94] J. Jargstorf und M. Wickert, „Offer of secondary reserve with a pool of electric vehicles on the German market,“ *Energy Policy*, Jg. 62, S. 185–195, 2013, ISSN: 03014215. DOI: 10.1016/j.enpol.2013.06.088.
- [95] F. Ziel, R. Steinert und S. Husmann, „Forecasting day ahead electricity spot prices: The impact of the EXAA to other European electricity markets,“ *Energy Economics*, Jg. 51, S. 430–444, 2015, ISSN: 0140-9883. DOI: 10.1016/j.eneco.2015.08.005.

- [96] D. Keles, J. Scelle, F. Paraschiv und W. Fichtner, „Extended forecast methods for day-ahead electricity spot prices applying artificial neural networks,“ *Applied Energy*, Jg. 162, S. 218–230, 2016, ISSN: 0306-2619. DOI: 10.1016/j.apenergy.2015.09.087.
- [97] N. Ludwig, S. Feuerriegel und D. Neumann, „Putting Big Data analytics to work: Feature selection for forecasting electricity prices using the LASSO and random forests,“ *Journal of Decision Systems*, Jg. 24, Nr. 1, S. 19–36, 2015, ISSN: 1246-0125. DOI: 10.1080/12460125.2015.994290.
- [98] meteoblue AG, „Solar Controlled Quality,“ 2017. Adresse: https://docs.meteoblue.com/assets/meteo/quality-verification/verification/meteoblue_Solar_Controlled_Quality_EN.pdf (besucht am 02.03.2021).
- [99] S. Spieker, J. Kopiske und G. Tsatsaronis, *Flexibilität aus Wind- und Photovoltaikanlagen im Regelenergiemarkt 2035*, Institut für Energietechnik, Technische Universität Berlin, 2016. Adresse: https://www.energietechnik.tu-berlin.de/fileadmin/fg106/Dateien/Mitarbeiter/Spieker_Kopiske_EnInnov2016_Flexibilitaet_aus_Wind-_und_Photovoltaikanlagen_im_Regelenergiemarkt_2035__Langfassung_.pdf (besucht am 01.04.2021).
- [100] A. Thielmann, C. Fan, N. Friedrichsen, T. Gnann, T. Hettesheimer, T. Hummen, F. Marscheider-Weidemann, T. Reiß, A. Sauer und M. Wietsche, *Energiespeicher für die Elektromobilität - Deutschland auf dem Weg zum Leitmarkt und Leitanbieter?* Fraunhofer-Institut für System- und Innovationsforschung ISI, 2014. Adresse: https://www.isi.fraunhofer.de/content/dam/isi/dokumente/cct/2014/EMOTOR_Leitmarkt-und-Leitanbieter_Fraunhofer-ISI.pdf (besucht am 01.04.2021).
- [101] Bundesverband der Energie- und Wasserwirtschaft e. V., *Stellungnahme Referentenentwurf Steuerbare-Verbrauchseinrichtungen-Gesetz (SteuVerG)*, 2021. Adresse: https://www.bdew.de/media/documents/20210115_Stn_SteuVerG.pdf (besucht am 29.03.2021).
- [102] J. M. P. Menezes und G. A. Barreto, „On recurrent neural networks for auto-similar traffic prediction: A performance evaluation,“ in *2006 International Telecommunications Symposium*, 2006, S. 534–539. DOI: 10.1109/ITS.2006.4433332.
- [103] Wolfgang Ertel, „Neuronale Netze, Grundkurs Künstliche Intelligenz,“ in *Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung*, Wiesbaden: Springer Fachmedien Wiesbaden, 2016, S. 265–311, ISBN: 978-3-658-13549-2. DOI: 10.1007/978-3-658-13549-2_9.
- [104] D. E. Rumelhart und J. L. McClelland, „Learning Internal Representations by Error Propagation,“ in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations*, 1987, S. 318–362. Adresse: <https://ieeexplore.ieee.org/document/6302929> (besucht am 01.04.2021).