

DEZENTRALES VS. ZENTRALES LADEMANAGEMENT VON ELEKTROAUTOS IM QUARTIER

**Paula Oberfeier*, Arne Surmann, Niklas Hain, Anna Rothenhäusler, Arne Groß,
Benedikt Köpfer und Matthias Kühnbach**

*Fraunhofer-Institut für Solare Energiesysteme ISE, Heidenhofstr. 2, 79110 Freiburg,
paula.oberfeier@ise.fraunhofer.de

Kurzfassung: Die Dekarbonisierung der Individualmobilität über Elektrofahrzeugen führt zu gleichzeitigen Ladevorgängen und daraus resultierenden Spitzenlasten in den Niederspannungsnetzen. Intelligentes Lademanagement bietet das Potential den Netzbezug zu reduzieren. Die Studie simuliert ein Mehrparteienhaus, das Netzbezug durch Lademanagement reduziert. Es werden zwei Lademanagement-Ansätze verglichen: ein zentrales und ein dezentrales, agentenbasiertes Betriebsführungskonzept. Wir bewerten die Fähigkeit beider Modelle, den Netzbezug eines Mehrparteienhaus mit 16 Wohneinheiten und Elektroautos zu minimieren. Das zentrale Lademanagement erreicht eine höhere systemübergreifende Eigenversorgung aus der PV-Anlage, während das dezentrale Lademanagement eine gleichmäßigere Verteilung der Vorteile für individuelle Parteien aufweist.

Keywords: Smart Charging, Centralized EVs Charging, Distributed EVs Charging, Optimization objectives

1 Einleitung

Die Integration von 15 Mio. Elektrofahrzeugen (EVs) bis 2030 sowie eine nahezu vollständige Elektrifizierung des PKW-Verkehrs in Deutschland wird eine enorme Belastung für die derzeitigen Stromnetze mit sich bringen [1]. Kritisch sind dabei insbesondere gleichzeitige Ladevorgänge und daraus resultierende Spitzenlasten [2]. Um eine Überlastung der Stromnetze zu vermeiden, ist ein möglicher Lösungsansatz die Steuerung von lokalen Flexibilitäten bspw. innerhalb eines Quartiers, Mehrparteienhauses oder einer Energy Community [3]. In den letzten Jahren wurde eine Vielzahl von Optimierungstechniken zur Steuerung von lokalen Flexibilitäten entwickelt [4, 5]. Es sind allerdings zusätzliche Forschungsarbeiten erforderlich, um die optimalen Lösungen für reale Anwendungsfälle zu finden [4].

Dieses Papier fokussiert sich auf den Anwendungsfall des Lademanagements von EVs im Mehrfamilienhaus bzw. Quartier. Es wird ein Mehrparteienhaus simuliert, dessen Ziel es ist, den Netzbezug des Mehrparteienhauses über ein optimiertes Lademanagement zu minimieren. In der Literatur lassen sich hierbei insbesondere zentrale und dezentrale Steuerungskonzepte identifizieren, um ein solches Ziel zu erreichen. Die vorliegende Studie vergleicht diese beiden Optimierungskonzepte: Einerseits eine zeitlich diskrete Simulation eines zentralen Optimierungsansatz und andererseits ein dezentrales, agentenbasiertes Modell, das zeitlich kontinuierlich agiert.

2 Lademanagement von Elektroautos

Ansätze zum Lademanagement von Elektroautos können in zentrale und dezentrale Ansätze unterteilt werden. Im zentralen Fall wird eine zentrale Einheit, auch als Aggregator bezeichnet, eingesetzt, die sämtliche Daten im Zusammenhang mit dem Laden der EVs sammelt und auf Basis dieser die Betriebsführung [6]. Diese zentralisierte Vorgehensweise hat insbesondere den Vorteil, dass voraussichtlich ein globales Optimum, d. h. die optimale Ladestrategie auf Systemlevel erreicht wird. Allerdings sind auch einige Nachteile und Herausforderungen mit diesem Ansatz verbunden. Die Kommunikationsinfrastruktur ist komplex und potenziell mit hohen Kosten verbunden, da eine große Menge an Daten verarbeitet werden muss. Zudem gibt es Bedenken hinsichtlich des Datenschutzes der Nutzer [6]. Das System ist stark von einer zentralen Einheit abhängig, bricht diese zusammen, scheitert das gesamte intelligente Lademanagement und alternative Regelungen sind notwendig, was die Kosten des Systems erhöhen kann [7].

Im Gegensatz dazu ermöglicht der dezentrale Ansatz für das individuelle EV einen größeren autonomen Handlungsspielraum [6]. Das System wird flexibler, es können einfacher neue dezentrale Steuerungseinheiten mit eigenen Steuerungsmechanismen hinzu- oder abgeschaltet werden, die Skalierbarkeit steigt [8]. Des Weiteren zeigt García Villalobos J. [9], dass sich bei guter Ausgestaltung des Systems die Resilienz gegenüber einzelnen Teilausfällen erhöht, bei denen die noch aktiven Systeme weiterarbeiten und auch bei einem Ausfall des übergeordneten Kommunikationssystems können die lokalen Inseln weiter agieren. Amjad *et al.* [8] zeigt zudem, dass im Vergleich zur zentralen Steuerung, die Schwierigkeiten bezüglich des Datenschutzes als minimal zu bewerten seien, da keine individuellen Daten geteilt werden müssen, die Entscheidung darüber was zwischen Agenten kommuniziert wird, liegt in der Hand der Nutzer:innen. Allerdings ist zu erwarten, dass auf Grund des potenziell geringeren Wissensstands der einzelnen Agenten im Gegensatz zu einem zentralen Aggregator, die optimale Ladestrategie auf Systemlevel nicht erreicht werden kann [8, 10].

Abhängig davon, wie ein konkretes System aufgebaut ist, welche Anreize für ein koordiniertes Agentenverhalten extern gegeben werden und welche konkreten Informationen ausgetauscht werden, fallen einzelne Punkte stärker oder schwächer ins Gewicht, die generelle Tendenz der Vor- und Nachteile bleibt jedoch erhalten [8]. Weiterhin sind Hybridmodelle möglich, bei denen zentrale und dezentrale Komponenten gemeinsam agieren.

Neben den technischen und wirtschaftlichen Vor- und Nachteilen der beiden Ansätze ist auch ein Blick auf die Akzeptanz aus Sicht potenzieller Endkunden interessant bzw. wie wichtig die genannten Vor- und Nachteile aus Sicht dieser sind. Im Allgemeinen ist für dezentrale Ansätze eine höhere Akzeptanz zu erwarten, weil die Kontrolle für den Ladevorgang beim Endkunden verbleibt [6, 8]. Exemplarisch wurden in Delmonte *et al.* [11] ein nutzergesteuertes Modell (dezentral) mit einem anbiertergesteuerten Modell (zentral) verglichen. Das nutzergesteuerte Modell wurde gegenüber dem anbiertergesteuerten Modell bevorzugt, da die Teilnehmer:innen die persönliche Kontrolle und das Risiko, dass ein Fahrzeug zum gewünschten Zeitpunkt nicht vollständig aufgeladen ist, als geringer wahrnahmen. Die allgemeine Akzeptanz von intelligentem Lademanagement ist insbesondere von einer signifikanten Kostenreduktion abhängig [11]. Zudem steigt die Akzeptanz von intelligentem Lademanagement durch Kommunikation der Vorteile gegenüber den Endkunden. Ein wichtiger Treiber für die

Akzeptanz der Endkunden ist zudem die Steigerung der Integration von erneuerbaren Energien. Neben den wirtschaftlichen und ökologischen Treibern stellen sich zudem die Möglichkeit zur individuellen und flexiblen Nutzung, sowie der Möglichkeit zur Personalisierung durch Dateninput als signifikant für die Akzeptanz heraus [12].

3 Case Study

Für den Vergleich der beiden Betriebsführungskonzepte wird ein Mehrparteienhaus mit 16 Parteien simuliert. Wir nehmen an, dass jede Partei ein EV besitzt. Die Fahrzeugnutzungs- und Ladeprofile (ungesteuert) werden mit dem Simulationstool *synPRO* erstellt [13]. Zusätzlich wird mithilfe einer stochastischen Bottom-up-Simulation ebenfalls über *synPRO* je ein Lastprofile pro Wohnungsebene erstellt [14]. Das Mehrparteienhaus hat einen Jahresverbrauch von 63473,93 kWh, wovon 19259,68 kWh aus dem Laden der Elektroautos resultieren. Basierend auf Wetterdaten für ein Testreferenzjahr für den Standort Kaiserslautern werden PV-Profile für 4 Dach und eine Fassadenanlage mit einer Gesamtleistung von 55 kWp erstellt und für die nachfolgenden Simulationen aggregiert [15]. Die PV-Anlage wurde so dimensioniert, dass eine bilanzielle Autarkie ermöglicht wird. Der gesamte Simulationsaufbau ist in Tabelle 1 abgebildet.

Tabelle 1: Simulationsaufbau für ein Mehrparteienhaus mit 16 Parteien und 5 PV-Anlagenteilen

Partei	Typ	Anzahl Bewohnende	Jahresverbrauch Wohnung [kWh]	Jahresverbrauch EV [kWh]	Jahresverbrauch Gesamt [kWh]
1	Familie	4	4989.38	2431.92	7421.30
2	Familie	4	5026.74	1240.25	6266.99
3	Familie	4	3967.16	1612.97	5580.13
4	Familie	4	3635.40	1851.49	5486.89
5	Familie	4	3987.38	1071.58	5058.96
6	Vollzeit Arbeitende	2	2345.33	1843.76	4189.09
7	Vollzeit Arbeitende	2	2777.85	1624.52	4402.37
8	Teilzeit Arbeitende	2	2632.81	1489.61	4122.42
9	Rentner	2	2091.33	1371.89	3463.22
10	Rentner	2	2618.84	296.27	2915.11
11	Alleinerziehende	2	2411.26	1070.76	3482.02
12	Studierende	1	1838.82	633.81	2472.63
13	Studierende	1	932.59	1064.62	1997.21
14	Studierende	1	1388.99	229.35	1618.34
15	Studierende	1	1274.19	831.42	2105.61
16	Studierende	2	2296.17	595.47	2891.64
Mehrparteienhaus			44214.25	19259.68	63473.93
PV Kombianlage					63473.93

Die Abbildung 1 stellt den Verlauf des Verbrauchs aller Wohnungen, der PV-Erzeugung und der ungesteuerten Ladeprofile über zwei exemplarische Tage dar. Die aufgetragenen Flächen stellen die aufsummierten Ladevorgänge der einzelnen EVs dar.

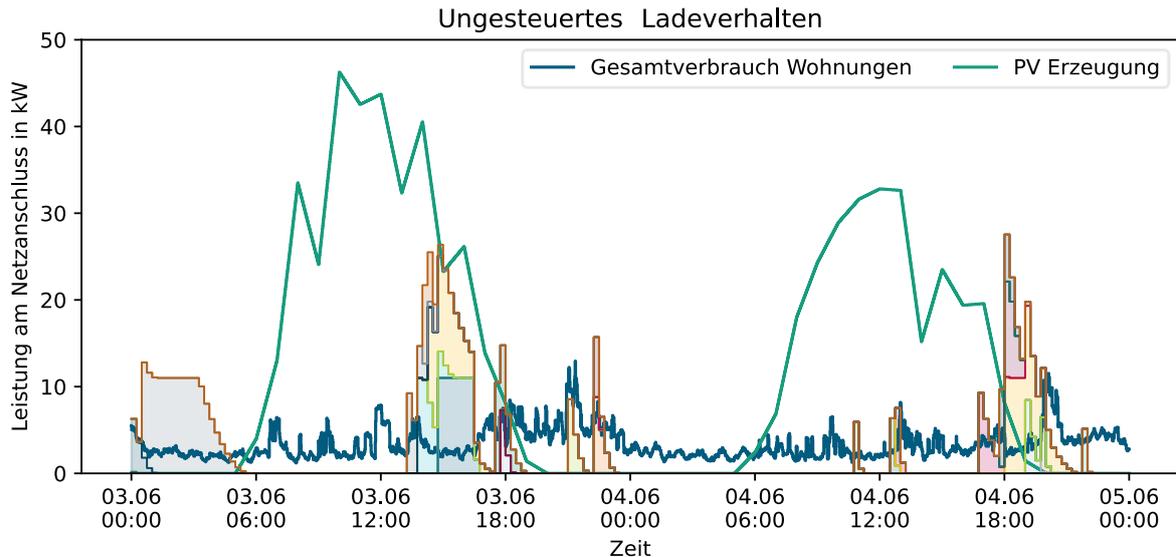


Abbildung 1: Ungesteuerte Ladeprofile über zwei exemplarische Tage für das betrachtete Mehrparteienhaus

4 Methodik

Im vorliegenden Papier betrachten wir ein zentrales Optimierungsmodell sowie Agentensystem, d.h. eine zentrale Gebäudesimulation mit dezentral eingebetteten, optimierenden Agenten.

Die betrachteten Optimierungsmodelle minimieren die Stromkosten des Mehrparteienhauses, indem die Flexibilität der EVs für ein optimiertes Lademanagement ausgenutzt wird. Die Minimierung des Netzbezugs ergibt sich implizit, da der hauseigene PV-Strom als kostengünstiger angenommen wird als der Strombezug aus dem öffentlichen Netz.

In beiden Optimierungsmodellen sind zudem 3 verschiedene Operationsmodi berücksichtigt. Jedes EV besitzt einen minimalen Batterieladezustand (SOC) und einen Ziel-SOC. Wird ein EV zum Laden angeschlossen, so lädt es bis zum Erreichen des minimalen SOC mit maximaler Leistung. Anschließend lädt das EV kostenminimierend, bis der Ziel-SOC erreicht wird. Delmonte *et al.* [11] kommen im Rahmen einer Befragung zu dem Ergebnis, dass EV-Nutzer:innen im Durchschnitt eine minimale Reichweite 70 km als hinreichend empfinden. Berücksichtigt man die in diesem Papier verwendete minimale Batteriegröße von 51 kWh resultiert daraus ein minimaler SOC von 0,3. Der Ziel-SOC wird auf 0,8 gesetzt, um die Batterie möglichst schonend zu laden.

4.1 Modellierung des Elektrofahrzeugs

Das elektrische Modell eines EV wird nach der folgenden Gleichung bestimmt und stellt die Nebenbedingungen sowohl für das agentenbasierte als auch das zentrale Lademanagement dar:

$$soc_{i,t+1} = soc_{i,t} + \frac{\Delta t \cdot P_{i,t} \cdot \eta}{E_i^{tot}} \quad \forall i, t \quad (1)$$

Dabei ist $soc_{i,t}$ der Batterie-Ladezustand (SOC) von EV i zum Zeitpunkt t während eines Parkvorgangs. $soc_{i,0}$ stellt den SOC des EVs bei Ankunft dar. $P_{i,t}$ ist die aktuelle Ladeleistung, η der Ladewirkungsgrad und E_i^{tot} die maximale Kapazität der Fahrzeugbatterie von EV i .

$$E_{i,t+1}^{dem} = E_{i,t}^{dem} - P_{i,t} \cdot \Delta t \quad \forall i, t \quad (2)$$

$E_{i,t}^{dem}$ stellt die Energiemenge dar, die noch benötigt wird, um den nächsten SOC-Meilenstein (minimaler, Ziel- oder 100 %-SOC) zu erreichen. Das mathematische EV-Modell unterliegt der Nebenbedingung für die Leistungsgrenzen der Ladeeinrichtung und der Batteriekapazität wie in Formel (3) beschrieben.

$$p^{min} \leq |P_{i,t}| \leq p^{max} \quad \forall i, t \quad (3)$$

4.2 Agentenbasiertes Lademanagement

Die Optimierung erfolgt im agentenbasiertem Lastmanagement dezentral und basiert auf dem in Surmann *et al.* [3] veröffentlichtem Modell. Agentenbasiertes Lastmanagement bedeutet in diesem Anwendungsfall, dass für jedes EV, das als Agenten fungiert, ein individuelles Optimierungsproblem mit dem Ziel, die individuellen Stromkosten zu minimieren, gelöst wird. Die Zielfunktion für ein EV i ist in Formel (4) gegeben.

$$\min_{s_{i,t}, P_{i,t}} \sum_{t \in T} (p^{PV} \cdot E_t^{PV} + p^{Grid} \cdot E_t^{Grid}) \quad (4)$$

E_t^q beschreibt die Energie aus Quelle $q \in Q = \{PV, Grid\}$ zum Zeitpunkt t innerhalb des Parkvorgangs T . Die Preiskoeffizienten für die Energie aus einer bestimmten Quelle q werden mit p^q bezeichnet.

Das betrachtete agentenbasierte Lademanagement kann unterschiedliche Benutzereingaben für den minimalen und Ziel-SOC annehmen. Innerhalb dieses Papiers werden allerdings, wie zuvor erwähnt, einheitliche Werte für den minimalen und Ziel-SOC angenommen, um eine Vergleichbarkeit der Modelle herzustellen. Neben dem minimalen und Ziel-SOC wird vom Nutzer der Abfahrtszeitpunkt eingegeben. Der jeweilige Agent erfährt außerdem den Zustand des EV und der Ladeeinrichtung, die Informationen über den aktuellen SOC und den aktuellen Leistungsfluss enthält. Zu Beginn eines Ladevorgangs werden die maximale Batteriekapazität und die maximale Lade- und Entladeleistung vom Fahrzeug an den Agenten übermittelt. Untereinander teilen die Agenten lediglich ihre Leistungsbezüge für die Zeitschritte innerhalb eines vorher definierten rollierenden Planungshorizonts (in der Simulation 15-minütlich über 24h).

4.3 Zentrales Lademanagement

Das zentrale Lademanagement erfolgt über die Minimierung der Kosten über alle EV I , siehe Formel (5). Es basiert auf dem in Braam *et al.* [16] veröffentlichtem Modell.

$$\min_{s_{i,t}, P_{i,t}} \sum_{t \in T} \sum_{i \in I} (p^{PV} \cdot (E_{t,i}^{PV} + E_{t,hh}^{PV}) + p^{Grid} \cdot (E_{t,i}^{Grid} + E_{t,hh}^{Grid})) \quad (5)$$

$E_{t,i}^q$ beschreibt die Ladeenergie aus Quelle $q \in Q = \{PV, Grid\}$ von EV i zum Zeitpunkt t innerhalb des Parkvorgangs T . $E_{t,hh}^q$ steht für die summierte Haushaltslast aus Quelle q zum Zeitpunkt t .

In jedem Zeitschritt kommuniziert der Zustand des EV und der Ladeeinrichtung an den Aggregator kommuniziert. Darunter fällt die Informationen über den aktuellen SOC und den aktuellen Leistungsfluss. Zu Beginn werden die maximale Batteriekapazität und die maximale Lade- und Entladeleistung sowie der Abfahrtszeitpunkt an den Aggregator übermittelt, sobald ein EV an der Ladestation ankommt. Das Optimierungsmodell optimiert alle 15 Minuten für einen vorher definierten rollierenden Planungshorizont (in der Simulation 15-minütlich über 12h). Für eine einzelne Optimierung wird jeweils ein Mittelwert über ein 15 Minuten Intervall für die erzeugte PV und Haushaltslast angewendet und auf diese Weise die eigentliche minütliche Auflösung der Inputdaten reduziert, um die Optimierungszeit zu reduzieren.

4.4 Prognosen Haushaltslastprofile

Um einen möglichst umfangreichen Einblick in die beiden Optimierungsmodelle zu erhalten, wird für die Simulation - neben einer perfekten Vorhersage der Haushaltslast - eine Vorhersage über den K-Nächste-Nachbarn-Algorithmus (KNN) verwendet. In Groß *et al.* [17] wurden verschiedene Algorithmen zur kurzfristigen Prognose von elektrischen Lasten verglichen. Dabei stellte sich KNN als vielversprechend für Haushaltslastprofile heraus. Für die Erstellung der Prognose der Haushaltslastprofile wird ein KNN mit 60 Nachbarn und euklidischer Distanz verwendet. Die Features zum Erlernen der Charakteristiken des Lastprofils werden über ein Fourier Feature Encoding generiert. Die Prognose erzielt als Güte einen durchschnittlichen Wert von 1,38 für die normierte Wurzel der mittleren quadratischen Abweichung. Ein Ausschnitt der Prognose eines Beispielhaushaltes ist in Abbildung 2 abgebildet.

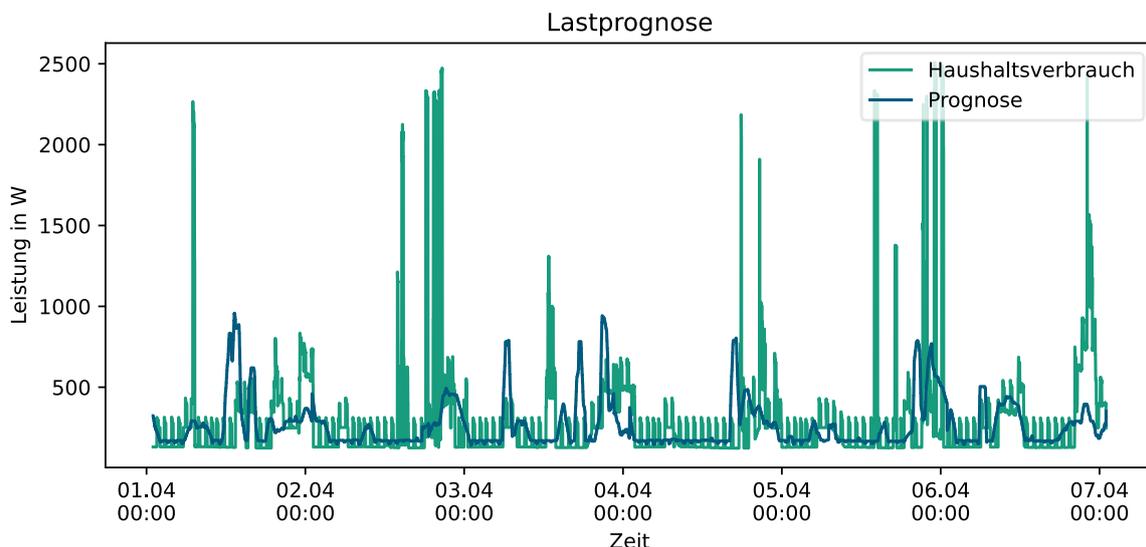


Abbildung 2: Auswertung der Prognose von PV und Last

5 Ergebnisse

Der Vergleich des zentralen mit dem dezentralen Ansatz erfolgt anhand des Netzbezugs des Mehrparteienhauses. Zudem wird analysiert, ob einzelne Parteien mehr oder weniger von einem bestimmten Lademanagement profitieren.

5.1 Ungesteuertes Lademanagement

Als Referenz zur Einordnung der Ergebnisse der beiden Optimierungsmodellen wird ein ungesteuertes Lademanagement betrachtet. In diesem Fall lädt ein EV nach Ankunft mit maximaler Ladeleistung bis die Batterie vollständig geladen ist oder bis das Auto wieder abfährt, sollte dies vorher geschehen.

Im Fall des ungesteuerten Lademanagement wird ein Eigenverbrauch von 29,88 % erzielt. Berücksichtigt sind hierbei die PV-Anlage und die Wohnungs- und Ladeverbräuche. Das resultiert in eine jährliche Netzbezugsmenge von 44707,91 kWh. Die nachgefragte Ladeleistung der EVs kann zu 20 % aus der PV-Erzeugung gedeckt werden.

Für die einzelnen Parteien im Mehrfamilienhaus ist der Eigenversorgungsgrad der Ladevorgänge sehr verschieden. In Abbildung 3 ist für jede Partei aufgetragen, wie hoch der Anteil an durch PV und durch Netzbezug der Gesamtladeenergie ist. Der minimale individuelle Eigenversorgungsgrad liegt bei 9 % und der maximale Wert bei 32 %. Dies zeigt, dass im ungesteuerten Lademanagement das Gewinnpotenzial für die einzelnen Parteien unterschiedlich hoch ausfällt.

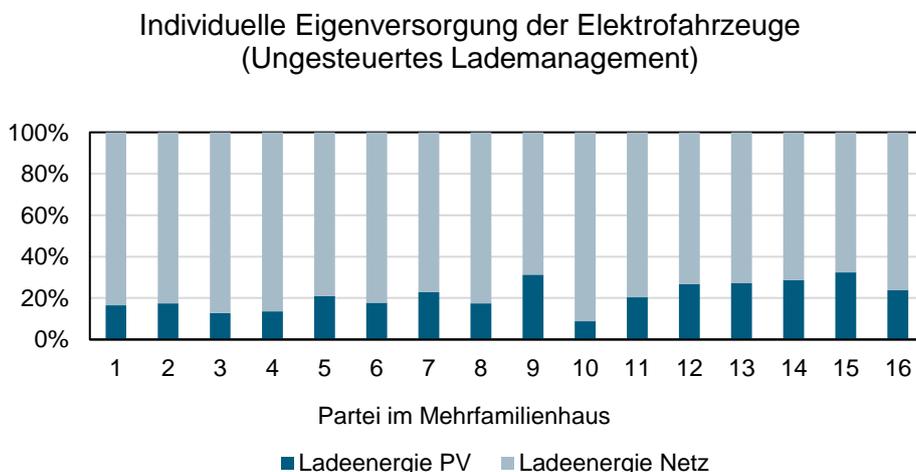


Abbildung 3: Eigenversorgung der Elektrofahrzeuge der individuellen Parteien

5.2 Zentrales Lademanagement

Das zentrale Lademanagement reduziert der jährliche Netzbezug um 9,27% auf 40564,34 kWh. Dies entspricht einem eingespartem Netzbezug von 4143,57 kWh entspricht einer ähnlichen Größenordnung wie der Jahresverbrauch eines Haushalts mit 4 Personen. Die EVs können den Bedarf zu 41 % aus der PV-Anlage decken und verdoppeln somit den Eigenversorgungsgrad aller Ladevorgänge im Vergleich zum ungesteuertem Lademanagement.

Die Abbildung 4 zeigt einen Ausschnitt des zentralen Lademanagements im Vergleich zum ungesteuerten Ladeverhalten. Aufgetragen ist die aufsummierte Ladeleistung der EVs, die innerhalb des Ausschnitts laden, sowie die verfügbare PV-Erzeugung nach Abzug der Haushaltslast. Die Balken unterhalb der x-Achse zeigt die Parkzeit der einzelnen EVs an. Es sind drei Abschnitte in orange zur Erläuterung der Funktionalität der Optimierungsmodelle hervorgehoben. Im ersten Abschnitt zeigt sich, dass im ungesteuerten Lademanagement EVs direkt nach Ankunft die nachgefragte Energie abrufen, bis die maximale Batteriekapazität erreicht ist. Das zentrale Lademanagement verschiebt diesen Ladevorgang in die Morgenstunden, um die verfügbare PV-Erzeugung zu nutzen und auf diese Weise den Netzbezug zu reduzieren. So lädt bspw. EV 5 nicht mehr direkt nach Ankunft um 16:30Uhr, sondern morgens zwischen 8:00 und 10:00 Uhr.

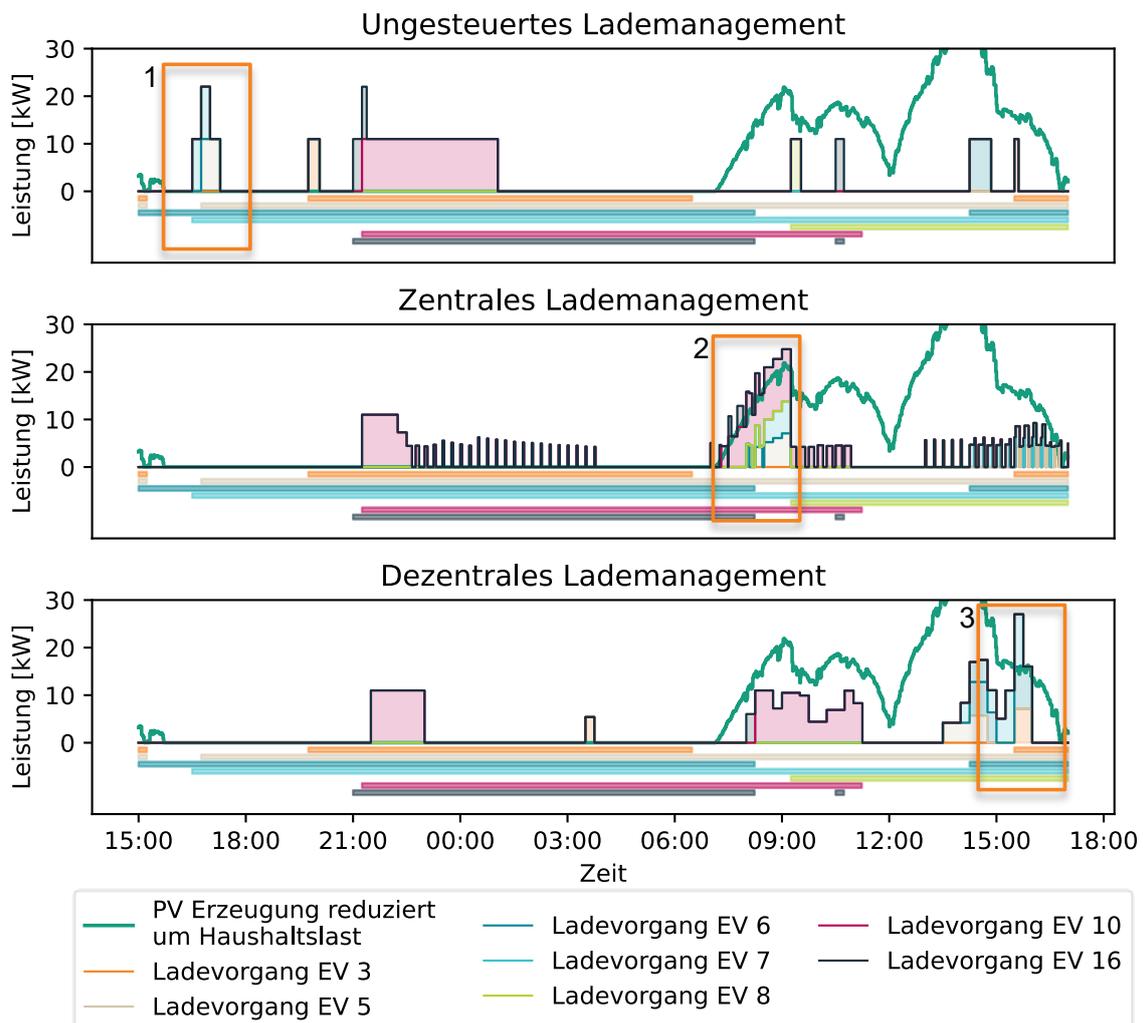


Abbildung 4: Vergleich ungesteuertes und zentrales Lademanagement für einen Beispieltag

In der zweiten Hervorhebung sind Spitzen in dem optimierten Lademanagement zu erkennen. Diese entstehen durch ein nachgelagertes Postprocessing, welches das Einhalten einer Mindestladeleistung von 4,2 kW erzwingt. Der zentrale Optimierungsansatz ist als Nicht-lineares Optimierungsmodell implementiert und verlangt zur optimalen Lösung einen konvexen Wertebereich der Variablen. Das agentenbasierte Lademanagement hingegen ist über ein Gemischt-ganzzahliges lineares Optimierungsmodell und gewährleistet über die Integration

von Binärvariablen, die aussagen, ob entweder geladen wird oder nicht, die Einhaltung der Mindestladeleistung.

Neben der Reduktion des Netzbezugs des Mehrparteienhauses werden die Auswirkungen des zentralen Lademanagements auf die einzelnen Parteien analysiert. In Abbildung 5 sind die individuellen Eigenversorgungsgrade der Ladevorgänge im ungesteuerten und zentralen Lademanagement miteinander verglichen. Der individuelle Eigenversorgungsgrad steigt für alle Parteien im Vergleich zum ungesteuerten Fall, allerdings profitieren einige Parteien deutlich stärker als andere. So liegt der maximale Eigenversorgungsgrad bei 61 % und der minimale bei 25 %. Zudem erhöht sich im Vergleich zum ungesteuertem Lademanagement die Standardabweichung der Eigenversorgungsgrade. Diese Unterschiede in dem Profitpotential durch das zentrale Lademanagement könnten durch eine nachgelagerte bilanzielle Aufteilung des Gesamtprofits ausgeglichen werden.

Des Weiteren wurden die Auswirkungen einer Prognose der Haushaltlast analysiert. Das zentrale Lademanagement mit KNN-Prognose für den Haushaltlast erreicht einen jährlichen Netzbezug von 40700,07 kWh. Die EVs können den Bedarf zu 40,4 % aus der PV-Anlage decken. Die verwendete Lastprognose in Verbindung mit dem zentralen Lademanagement ist somit geeignet, um ein ähnliches hohes Einsparungspotential zu erreichen wie bei einer perfekten Vorhersage.

5.3 Agentenbasiertes Lademanagement

Das agentenbasierte Lademanagement reduziert der jährliche Netzbezug auf um 7,5% 41353,74 kWh. Der eingesparte Netzbezug im Vergleich zum ungesteuertem Lademanagement von 3354,17 kWh ist in einer ähnlichen Größenordnung wie der Jahresverbrauch einer durchschnittlichen Wohnung im Mehrfamilienhaus und wird aufgrund dessen als signifikant interpretiert. Die EVs können den Bedarf zu 36,5 % aus der PV-Anlage decken. Das agentenbasierte Lademanagement weist somit einen höheren jährlichen Netzbedarf von 789,4 kWh auf im Vergleich zum zentralen Lademanagement, das entspricht 1,77% des Netzbezugs im ungesteuerten Lademanagement. In Abbildung 4 ist in Abschnitt 3 ein Beispiel hervorgehoben, welches zu dem vergleichsweise höheren Netzbezug führt. Gegen 16 Uhr verbindet sich EV 3 mit der Ladestation und lädt für 15 Minuten mit minimaler Ladeleistung, obwohl bereits EV 5 und 6 die noch verfügbare PV-Erzeugung ausnutzen würden. Es hat zu diesem Zeitpunkt noch keine Abstimmung über den Austausch der Pläne und die anschließende Optimierung erfolgt. Im darauffolgenden 15-Minuten-Intervall sind die Pläne der drei Fahrzeuge abgestimmt und es wird lediglich für die verfügbare PV-Erzeugung über die Ladevorgänge verwendet.

In Abbildung 5 werden zudem die individuellen Eigenversorgungsgrade der Ladevorgänge im ungesteuertem, agentenbasiertem und zentralem Lademanagement miteinander verglichen. Die individuellen Eigenversorgungsgrade beim agentenbasiertem Lademanagement befinden sich in einem Wertebereich von 28 % bis 53 %. Der individuelle Eigenversorgungsgrad steigt für alle Parteien im Vergleich zum ungesteuerten Fall. Im Gegensatz zum zentralen Lademanagement erhöht das agentenbasierte Lademanagement allerdings nicht die Standardabweichung der individuellen Eigenversorgungsgrade im Vergleich zum ungesteuertem Lademanagement. Somit haben die Parteien beim agentenbasiertem Lademanagement einen ähnlichen Anreiz teilzunehmen.

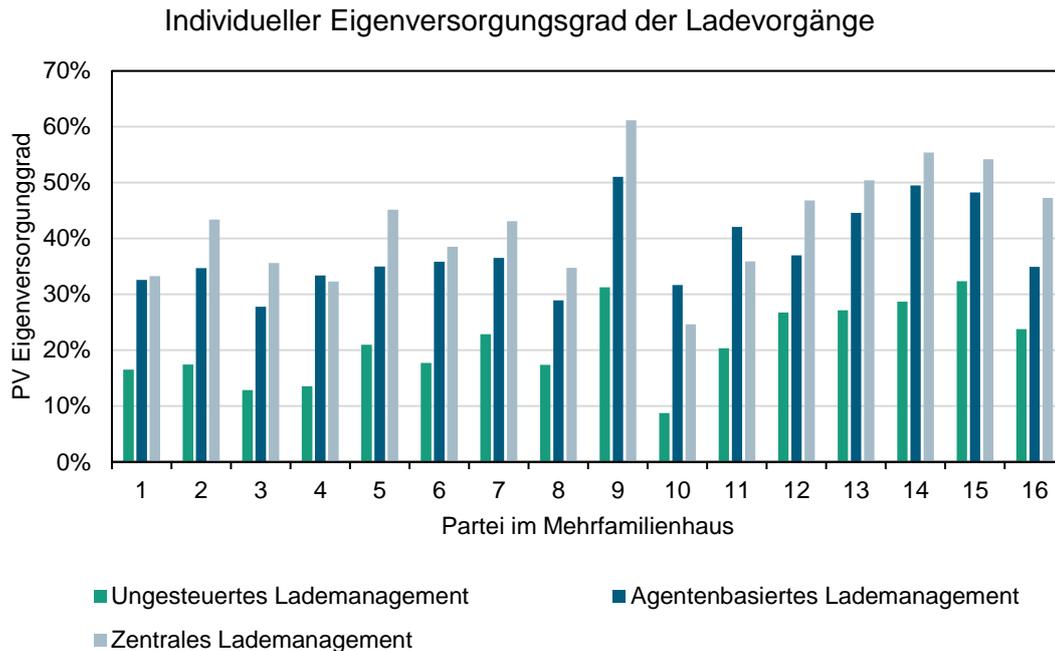


Abbildung 5: Vergleich des individuellen Eigenversorgungsgrades der Ladevorgänge zwischen ungesteuertem und agentenbasiertem Lademanagement

Die Integration einer Prognose für die Haushaltslastprofile in das agentenbasierte Lademanagement führt zu einem minimal höheren Netzbezug von 41343,28 kWh im Vergleich zur perfekten Vorhersage. Die verwendete Lastprognose kann somit nahezu das gesamte Potential des agentenbasierten Lademanagements mit perfekter Vorhersage erreichen.

6 Schlussfolgerung

Die vorliegende Untersuchung hat zentrale und dezentrale Ansätze zum Lademanagement von Elektroautos betrachtet. Für den Vergleich der beiden Betriebsführungskonzepte dient die Simulation eines Mehrparteienhaus mit 16 Parteien, welche jeweils über ein Elektrofahrzeug verfügen. Die zentrale Forschungsfrage der Analyse war zu quantifizieren, wie groß der Unterschied zwischen dem zentralen und dezentralen Ansatz in Bezug auf die Reduktion des Netzbezugs ist. Es wurde gezeigt, dass das zentrale Lademanagement den Netzbezug des Mehrparteienhauses im Vergleich zum agentenbasierten Lademanagement um weitere 1,77% reduziert. Das zentrale Lademanagement kann den PV-Eigenverbrauch von 30 % auf 36 % erhöhen. Das agentenbasierte Lademanagement erreicht hingegen einen PV-Eigenverbrauch von 34,5 %. Zudem können beide Betriebsführungskonzepte für ein optimiertes Lademanagement auch unter Anwendung einer Prognose der Haushaltslast auf Basis des K-Nächste-Nachbarn-Algorithmus ein ähnlich hohes Einsparungspotential erschließen wie unter der Anwendung einer perfekten Vorhersage.

Bei beiden Betriebsführungskonzepten profitieren alle Parteien von einem intelligenten Lademanagement. Allerdings zeigt sich, dass die individuellen Parteien unterschiedlich stark von den beiden Betriebsführungskonzepten profitieren. Beim zentralen Lademanagement profitieren einzelne Parteien stärker als andere. Beim agentenbasierten Lademanagement sind die Unterschiede der Vorteile für die einzelnen Parteien in einer ähnlichen Größenordnung wie im ungesteuertem Referenzfall. Es erfolgt demnach eine gleichmäßigere

Profitaufteilung beim agentenbasierten Lademanagement im Vergleich zum zentralen Lademanagement.

Die gezeigten Erkenntnisse sind relevant, um zu bewerten welche Betriebsführungskonzepte für lokale Flexibilitäten für welchen Anwendungsfall besonders gut geeignet sind. Der erfolgte Vergleich der beiden Betriebsführungskonzepte ist nicht abschließend, da verschiedene Aspekte wie technische Herausforderungen bei der Umsetzung und die Akzeptanz der Endkunden ebenfalls eine Rolle spielen. Eine umfassende techno-ökonomische Analyse des Betriebsführungskonzepte, unter Berücksichtigung aller relevanten Faktoren, ist daher erforderlich, um eine fundierte Entscheidung für die Implementierung eines Lademanagementsystems zu treffen.

Förderung

Die Arbeiten für dieses Papier wurden im Zuge des Projekts „EnQuaFlex – Energiewendedenlicher Quartiersbetrieb durch gemeinschaftliche Flexibilitätskoordination“ durchgeführt und vom Bundesministerium für Wirtschaft und Klimaschutz unter dem Förderkennzeichen 03EN3085C gefördert.

7 Literatur

- [1] BMWK, Hg., "Rahmenbedingungen und Anreize für Elektrofahrzeuge und Ladeinfrastruktur," 2023. Zugriff am: 17. November 2023. [Online]. Verfügbar unter: <https://www.bmwk.de/Redaktion/DE/Artikel/Industrie/rahmenbedingungen-und-anreize-fuer-elektrofahrzeuge.html>
- [2] H. Vennegeerts, J. Tran, F. Rudolph und P. Pfeifer, "Metastudie Forschungsüberblick Netzintegration Elektromobilität," 2018.
- [3] A. Surmann, R. Walia und R. Kohrs, "Agent-based bidirectional charging algorithms for battery electric vehicles in renewable energy communities," 2020.
- [4] M. S. Bakare, A. Abdulkarim, M. Zeeshan und A. N. Shuaibu, "A comprehensive overview on demand side energy management towards smart grids: challenges, solutions, and future direction," *Energy Inform*, Jg. 6, Nr. 1, 2023, doi: 10.1186/s42162-023-00262-7.
- [5] G. S. Thirunavukkarasu, M. Seyedmahmoudian, E. Jamei, B. Horan, S. Mekhilef und A. Stojcevski, "Role of optimization techniques in microgrid energy management systems—A review," *Energy Strategy Reviews*, Jg. 43, S. 100899, 2022, doi: 10.1016/j.esr.2022.100899.
- [6] R. Fachrizal, M. Shepero, D. van der Meer, J. Munkhammar und J. Widén, "Smart charging of electric vehicles considering photovoltaic power production and electricity consumption: A review," *eTransportation*, Jg. 4, S. 100056, 2020, doi: 10.1016/j.etrans.2020.100056.
- [7] 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, doi: 10.1016/j.rser.2014.07.040.
- [8] M. Amjad, A. Ahmad, M. H. Rehmani und T. Umer, "A review of EVs charging: From the perspective of energy optimization, optimization approaches, and charging techniques," *Transportation Research Part D: Transport and Environment*, Jg. 62, S. 386–417, 2018, doi: 10.1016/j.trd.2018.03.006.
- [9] García Villalobos J., "Optimized charging control method for plug-in electric vehicles in LV distribution networks," 2016. doi: 10/21608. [Online]. Verfügbar unter: <http://hdl.handle.net/10810/21608>
- [10] P. Richardson, D. Flynn und A. Keane, "Local Versus Centralized Charging Strategies for Electric Vehicles in Low Voltage Distribution Systems," *IEEE Trans. Smart Grid*, Jg. 3, Nr. 2, S. 1020–1028, 2012, doi: 10.1109/TSG.2012.2185523.
- [11] 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. 101318, 2020, doi: 10.1016/j.erss.2019.101318.
- [12] C. Will und A. Schuller, "Understanding user acceptance factors of electric vehicle smart charging," *Transportation Research Part C: Emerging Technologies*, Jg. 71, S. 198–214, 2016, doi: 10.1016/j.trc.2016.07.006.
- [13] D. Fischer, A. Harbrecht, A. Surmann und R. McKenna, "Electric vehicles' impacts on residential electric local profiles – A stochastic modelling approach considering socio-

- economic, behavioural and spatial factors," *Applied Energy*, Jg. 233-234, S. 644–658, 2019, doi: 10.1016/j.apenergy.2018.10.010.
- [14] D. Fischer, T. Wolf, J. Scherer und B. Wille-Hausmann, "A stochastic bottom-up model for space heating and domestic hot water load profiles for German households," *Energy and Buildings*, Jg. 124, S. 120–128, 2016, doi: 10.1016/j.enbuild.2016.04.069.
- [15] Deutscher Wetterdienst, "Ortsgenaue Testreferenzjahre von Deutschland für mittlere, extreme und zukünftige Witterungsverhältnisse," 2017.
- [16] F. Braam, A. Groß, M. Mierau, R. Kohrs und C. Wittwer, "Coordinated charge management for battery electric vehicles," *Comput Sci Res Dev*, Jg. 32, 1-2, S. 183–193, 2017, doi: 10.1007/s00450-016-0307-6.
- [17] A. Groß, A. Lenders, F. Schwenker, D. A. Braun und D. Fischer, "Comparison of short-term electrical load forecasting methods for different building types," *Energy Inform*, Jg. 4, S3, 2021, doi: 10.1186/s42162-021-00172-6.