

# Selbst-organisiertes, trust-bewusstes Supply Demand Management in Smart Grids

Dissertation  
zur Erlangung des Doktorgrades Dr. rer. nat.  
an der Fakultät für Angewandte Informatik  
der Universität Augsburg

vorgelegt von

Florian Siefert

2017



Erstgutachter: Prof. Dr. Wolfgang Reif  
Zweitgutachter: Prof. Dr. Bernhard Bauer

Tag der mündlichen Prüfung: 31.05.2017

*Für meine Familie.*



## ZUSAMMENFASSUNG

---

Die Bestrebungen einer klimafreundlichen Energieversorgung stellen das elektrische Energieversorgungssystem vor große Herausforderungen. Um diese zu meistern, ist der aktive Einbezug der bisher weitgehend unbeteiligten Verbraucher in den Betrieb des elektrischen Energieversorgungssystems notwendig.

In dieser Arbeit wird ein Ansatz zum autonomen, selbst-organisierten Demand Side Management vorgestellt. Durch die Steuerung von kleineren Gruppen von Verbrauchern, sogenannten Autonomen Verbraucherorganisationen, wird eine skalierbare Koordination der Verbraucher erreicht. Autonome Verbraucherorganisationen sind selbst-organisierend, d. h. sie bilden ihre Struktur selbst aus und passen sie wenn notwendig veränderten Bedingungen an. Für den Umgang mit den im System inhärenten Unsicherheiten wird auf das soziale Konzept der Vertrauenswürdigkeit zurückgegriffen, um die Koordination der Verbraucher robust gegenüber Vorhersagefehler zu machen.

Des Weiteren werden die Autonomen Verbraucherorganisationen in der vorliegenden Arbeit mit dem existierenden Konzept der Autonomen Virtuellen Kraftwerke, selbst-organisierte Gruppen von Erzeugern, kombiniert. Dieses System aus Autonomen Verbraucherorganisationen und Autonomen Virtuellen Kraftwerken betreibt ein autonomes, selbst-organisiertes Supply Demand Management durch die robuste Koordination von Erzeugern und Verbrauchern unter Unsicherheiten.



## ABSTRACT

---

The aim to provide a climate-friendly energy supply poses a great challenge to electric power systems. To meet this challenge, actively including the currently mainly uninvolved consumers into the operation of electric power systems is a necessity.

In this thesis, an approach for an autonomous, self-organized Demand Side Management is proposed. By controlling smaller groups of consumers, so-called Autonomous Consumer Organizations, a scalable coordination of the consumers is achieved. Autonomous Consumer Organizations are self-organizing, meaning that they form their structure on their own and adapt it if changing conditions make it necessary. To handle the system's inherent uncertainties, the social concept of trust is used, thereby making the coordination of consumers robust against prediction errors.

Moreover, in this thesis, Autonomous Consumer Organizations are combined with the existing concept of Autonomous Virtual Power Plants, self-organized groups of power producers. This system of Autonomous Consumer Organizations and Autonomous Virtual Power Plants is able to do an autonomous, self-organized Supply Demand Management by robustly coordinating producers and consumers under uncertainties.



## DANKSAGUNG

---

An dieser Stelle möchte ich die Gelegenheit nutzen, um einigen Personen meinen Dank auszusprechen.

Zuallererst möchte ich mich bei meinem Doktorvater Prof. Dr. Wolfgang Reif bedanken – für seine große Unterstützung und die Möglichkeit, an einem spannenden Forschungsprojekt mitzuwirken und diese Dissertation zu verfassen.

Des Weiteren möchte ich allen Kollegen am Lehrstuhl danken, mit denen das Arbeiten am Lehrstuhl in einer sehr angenehmen Atmosphäre möglich war. Besonderer Dank gebührt dabei für die gute Zusammenarbeit meinen Kollegen der „SO-Truppe“: Hella Seebach, Florian Nafz, Jan-Philipp Steghöfer, Benedikt Eberhardinger, Alexander Schiendorfer, Oliver Kosak und speziell meinem langjährigen Bürokollegen Gerrit Anders.

Zu guter Letzt möchte ich noch ganz herzlich meiner Familie meinen Dank aussprechen: Meinen Eltern und meiner Schwester, die mich gefördert und gefordert haben und über all die Jahre stets für mich da waren; und Carina, deren grandiose Unterstützung, zugesprochener Mut und ihr Glaube an mich eine wichtige Stütze im Gelingen dieser Arbeit waren.

Florian Siefert



# INHALTSVERZEICHNIS

---

ABBILDUNGSVERZEICHNIS	xv
TABELLENVERZEICHNIS	xvii
ABKÜRZUNGSVERZEICHNIS	xix
SYMBOLVERZEICHNIS	xxi
I. SELBST-ORGANISATION UND TRUST IN SMART GRIDS: MOTIVATION UND ÜBERBLICK	1
1. EINLEITUNG	3
1.1. Motivation	3
1.2. Erzielte Ergebnisse	6
1.3. Überblick über die Arbeit	6
2. ELEKTRISCHE ENERGIEVERSORGUNGSSYSTEME	9
2.1. Grundlagen der elektrischen Energieversorgung	9
2.2. Wandel in der elektrischen Energieversorgung durch die Energiewende	13
2.3. Flexibilisierung des Verbrauchs als Maßnahme für eine erfolgreiche Energiewende	19
2.4. Transformation heutiger elektrischer Energieversorgungssysteme zu Smart Grids	23
2.5. Entstehende Herausforderungen beim autonomen Betrieb zukünftiger elektrischer Energieversorgungssysteme	23
	xi

II. SELBST-ORGANISIERTES, TRUST-BEWUSSTES DEMAND SIDE MANAGEMENT	25
3. SELBST-ORGANISATION UND TRUST IN AUTONOMEN VERBRAUCHERORGANISATIONEN	27
3.1. Selbst-Organisation für den skalierbaren Betrieb elektrischer Energieversorgungssysteme	28
3.2. Trust für den robusten Betrieb elektrischer Energieversorgungssysteme	29
3.3. Betrachtete steuerbare Verbrauchertypen und Steuerungsmodelle	33
3.4. Autonome Verbraucherorganisationen	42
4. SELBST-ORGANISIERTE AUSBILDUNG VON AUTONOMEN VERBRAUCHERORGANISATIONEN	49
4.1. Selbst-Organisation in Autonomen Verbraucherorganisationen	49
4.2. Das Partitionierungsproblem	53
4.3. Ausbildung von Autonomen Verbraucherorganisationen mit einem Partikelschwarmoptimierer	55
4.3.1. Einführung in Partikelschwarmoptimierung	57
4.3.2. Ein Partikelschwarmoptimierer zur Lösung des Partitionierungsproblems	59
4.4. Ausbildung von Autonomen Verbraucherorganisationen mit einem agenten-basierten Ansatz	68
4.4.1. Systemmodell	69
4.4.2. Grundsätzliches Vorgehen des Algorithmus	71
5. REGIO-ZENTRALE, ROBUSTE STEUERUNG VON VERBRAUCHERN	75
5.1. Verbrauchersteuerung als Optimierungsproblem	75
5.2. Umgang mit Unsicherheiten bei der Verbrauchersteuerung	80
5.2.1. Trust-basierte Szenarien	80
5.2.2. Robuste Steuerung von Verbrauchern mit trust-basierten Szenarien	82
5.3. Verwandte Arbeiten	86

III. SELBST-ORGANISIERTES, TRUST-BEWUSSTES SUPPLY DEMAND MANAGEMENT	89
6. AUTONOME VIRTUELLE KRAFTWERKE	91
6.1. Grundprinzip von Autonomen Virtuellen Kraftwerken	91
6.2. Verwandte Arbeiten	95
7. ZUSAMMENFÜHRUNG VON AUTONOMEN VERBRAUCHERORGANISATIONEN UND AUTONOMEN VIRTUELLEN KRAFTWERKEN	99
7.1. Robuste Einsatzplanung in Autonomen Virtuellen Kraftwerken	99
7.2. Integration von Autonomen Verbraucherorganisationen in Autonome Virtuelle Kraftwerke	101
7.2.1. Ablauf des kombinierten Steuerungsprozesses im System	103
7.2.2. Ablauf der Selbst-Organisation im System	104
7.3. Verwandte Arbeiten	109
IV. EVALUATION UND SCHLUSS	111
8. EVALUATION	113
8.1. Evaluationsziele	113
8.2. Evaluationsaufbau	114
8.3. Evaluationsmetriken und ausgewertete Daten	115
8.4. Demand Side Management: Evaluationsszenarien und -ergebnisse	117
8.4.1. Homogene Partitionen	120
8.4.2. Heterogene Partitionen	131
8.4.3. Größere Partitionen	135
8.4.4. Fazit zum Demand Side Management	139
8.5. Supply Demand Management: Evaluationsszenarien und -ergebnisse	140
8.5.1. Konservatives System	143
8.5.2. Zukünftiges System	147
8.5.3. Fazit zum Supply Demand Management	149
8.6. Zusammenfassung	150
	xiii

## *Inhaltsverzeichnis*

9. FAZIT UND AUSBLICK	153
9.1. Zusammenfassung der erreichten Ergebnisse	153
9.2. Offene Fragestellungen und Ausblick auf zukünftige Arbeiten	155
LITERATUR	159

## ABBILDUNGSVERZEICHNIS

---

2.1. Eine beispielhafte Lastkurve, unterteilt in Grund-, Mittel- und Spitzenlast	12
2.2. Beispielhafte Residuallast	13
2.3. Volatile Einspeisung von Windkraftanlagen	15
2.4. Auswirkungen der Elektromobilität auf die Last und Residuallast	19
2.5. Geglättete Residuallast durch Anpassung des Verbrauchs	21
3.1. Lebenszyklus von Trust-Werten	32
3.2. Last- und Temperaturkurve eines thermischen Verbrauchers	36
3.3. Lastkurve eines programmgetriebenen Verbrauchers	37
3.4. Lastkurve eines abschaltbaren Verbrauchers	38
3.5. Last- und Energiekurve eines elektrischen Speichers	39
3.6. Last- und Energiekurve eines Elektrofahrzeugs	41
3.7. Exemplarisches System Autonomer Verbraucherorganisationen	43
4.1. Exemplarische Reorganisation von Agentenorganisationen	53
4.2. Grundsätzliches Vorgehen eines Partikels in PSOPP	61
4.3. Exemplarischer Acquaintances Graph	70
4.4. Entfernen eines Agenten aus einer Partition	71
5.1. Exemplarisches Erstellen eines Trust-basierten Szenariobaums	83
6.1. Exemplarisches System Autonomer Virtueller Kraftwerke	94
6.2. Hinzufügen einer neuen Hierarchieebene	95
6.3. Reorganisation in der Hierarchie	96
7.1. Exemplarisches System Autonomer Virtueller Kraftwerke mit integrierten Autonomen Verbraucherorganisationen	103
7.2. Reorganisation von Autonomen Verbraucherorganisationen in einem Autonomen Virtuellen Kraftwerk	105
7.3. Reorganisation innerhalb einer Hierarchieebene	107



## TABELLENVERZEICHNIS

---

8.1.	Parametrisierung der Steuerungsmodelle für die Evaluierung	119
8.2.	Evaluationsergebnisse zu EF50	121
8.3.	Evaluationsergebnisse zu EF50-t mit unterschiedlichen Planungshorizonten	123
8.4.	Evaluationsergebnisse zu PV50	124
8.5.	Evaluationsergebnisse zu PV50-t mit unterschiedlichen Planungshorizonten	125
8.6.	Evaluationsergebnisse zu TV50	126
8.7.	Evaluationsergebnisse zu TV50-t mit unterschiedlichen Planungshorizonten	128
8.8.	Evaluationsergebnisse zu O15	132
8.9.	Evaluationsergebnisse zu O15-t mit unterschiedlichen Planungshorizonten	133
8.10.	Vergleich der Evaluationsergebnisse von O15-t mit O15H-t	134
8.11.	Evaluationsergebnisse zu O5	136
8.12.	Evaluationsergebnisse zu O5-t mit unterschiedlichen Planungshorizonten	137
8.13.	Parametrisierung der Steuerungsmodelle für die Evaluierung	144
8.14.	Parametrisierung der Steuerungsmodelle für die Evaluierung	145
8.15.	Evaluationsergebnisse zu SD-now	146
8.16.	Evaluationsergebnisse zu SD-fut	148



## ABKÜRZUNGSVERZEICHNIS

---

AVKW	Autonomes Virtuelles Kraftwerk
AVO	Autonome Verbraucherorganisation
CSOP	Constraint Satisfaction Optimization Problem
DPSO	Diskrete Partikelschwarmoptimierung
EEG	Gesetz für den Ausbau erneuerbarer Energien (Erneuerbare-Energien-Gesetz)
ENTSO-E	European Network of Transmission System Operators for Electricity
GA	Genetischer Algorithmus
JPSO	Jumping Particle Swarm Optimization
KWK	Kraft-Wärme-Kopplung
MAS	Multiagentensystem
NPE	Nationale Plattform Elektromobilität
PP	Partitionierungsproblem
PSO	Partikelschwarmoptimierung
PSOPP	Particle Swarm Optimizer for the Partitioning Problem

## *Abkürzungsverzeichnis*

RIA	Restore Invariant Approach
SPADA	Set Partitioning Algorithm for Distributed Agents
SPP	Set Partitioning Problem
TBS	Trust-basierte Szenarien
TBST	Trust-basierter Szenariobaum (engl. Trust-Based Scenario Tree)
TEMAS	Trust-Enabling Multi-Agent System
v2G	Vehicle to Grid

## SYMBOLVERZEICHNIS

---

$a$	Ein Agent aus der Menge der Agenten $\mathcal{A}$ .
$\mathcal{A}$	Die Menge aller Agenten.
$B$	Die bisher global beste gefundene Lösung aller Partikel.
$B_{\mathcal{N}_i}$	Die bisher beste gefundene Lösung in der Nachbarschaft $\mathcal{N}_i$ des Partikels $\Pi_i$ .
$B_i$	Die bisher beste gefundene Lösung des Partikels $\Pi_i$ .
$\Delta P$	Die durchschnittlich in jedem Zeitpunkt aufgetretene absolute Abweichung der Leistung steuerbarer Kraftwerke von der Residuallast.
$\Delta t$	Die zeitliche Differenz zwischen zwei aufeinanderfolgenden Zeitpunkten aus $\mathcal{T}$ .
$\Delta t_{\text{hour}}$	Die zeitliche Differenz zwischen zwei aufeinanderfolgenden Zeitpunkten aus $\mathcal{T}$ in Stunden.
$\Delta T_{\text{off}}$	Die Veränderung der Temperatur eines thermischen Verbrauchers, wenn das Gerät nicht in Betrieb ist.
$\Delta T_{\text{on}}$	Die Veränderung der Temperatur eines thermisches Verbrauchers, wenn das Gerät in Betrieb ist.
$\Delta^2 R_{\mu}^{\omega}$	Die mittleren Änderungen $ \Delta R_t^{\omega} - \Delta R_{t-1}^{\omega} $ von einem Zeitschritt zum nächsten Zeitschritt $t$ , gemittelt über alle Zeitschritte und Simulationsläufe.

## Symbolverzeichnis

$\Delta R_{\mu}^{\omega}$	Die durchschnittlich pro Autonomer Verbraucherorganisation $\omega \in \Omega$ pro Zeitschritt $t$ aufgetretene absolute Differenz $\Delta R_t^{\omega} =  R_t^{\omega} - R_{t-1}^{\omega} $ der Residuallast zum vorherigen Zeitschritt, gemittelt über alle Autonomen Verbraucherorganisationen, Zeitschritte und Simulationsläufe.
$\Delta U_{\mu}^{\omega}$	Die durchschnittlich pro Autonomer Verbraucherorganisation $\omega \in \Omega$ pro Zeitschritt $t$ aufgetretene absolute Differenz $\Delta U_t^{\omega} =  U_t^{\omega} - U_{t-1}^{\omega} $ der ungesteuerten Leistung zum vorherigen Zeitschritt, gemittelt über alle Autonomen Verbraucherorganisationen, Zeitschritte und Simulationsläufe.
$E(t)$	Die in einem Speicher zum Zeitpunkt $t$ vorhandene Energie.
$E_{des}^{dep}$	Die Mindestbatteriekapazität eines Elektrofahrzeugs, die zur Abfahrt vorhanden sein soll.
$E_{des}^{min}$	Die Mindestbatteriekapazität eines Elektrofahrzeugs, die während des Ladevorgangs nicht unterschritten werden soll.
$E_{max}$	Die maximale Energiekapazität eines Speichers.
$E_{min}$	Die minimale Energiekapazität eines Speichers.
$e$	Der Wirkungsgrad eines Speichers.
$N$	Die Anzahl der in $\mathcal{W}$ enthaltenen Zeitschritte, also die Anzahl an Zeitschritten, für die Fahrpläne erstellt werden.
$n_{max}$	Die maximale Anzahl an Partitionen einer Partitionierung.

$n_{\min}$	Die minimale Anzahl an Partitionen einer Partitionierung.
$\mathcal{N}_i$	Die Nachbarschaft eines Partikels $\Pi_i$ .
$P(t)$	Die nachgefragte/erzeugte Leistung zum Zeitpunkt $t$ .
$P_{\max}$	Die maximal nachgefragte/erzeugte Leistung.
$P_{\min}$	Die minimal nachgefragte/erzeugte Leistung.
$P_{\text{off}}$	Die nachgefragte Leistung eines Verbrauchers, wenn er nicht im Betrieb ist.
$P_{\text{on}}$	Die nachgefragte Leistung eines Verbrauchers, wenn er im Betrieb ist.
$\Pi_i$	Ein Partikel.
$\mathcal{P}$	Eine Partitionierung.
$R_{\max}$	Die durchschnittlich in einem Simulationslauf maximal aufgetretene Residuallast.
$R_{\min}$	Die durchschnittlich in einem Simulationslauf minimal aufgetretene Residuallast.
$R_{\mu}$	Die durchschnittlich in jedem Zeitschritt aufgetretene Residuallast.
$R^{\omega}$	Die Residuallast einer Autonomen Verbraucherorganisation. Analog dazu definiert $R_{\uparrow}^{\omega}$ den Residuallastbaum auf Basis von TBS.
$R_{\updownarrow}$	Die durchschnittlich in einem Simulationslauf aufgetretene Spreizung der Residuallast, also die Differenz aus $R_{\max}$ und $R_{\min}$ .

## Symbolverzeichnis

$s_{\max}$	Die maximale Größe einer Partition.
$s_{\min}$	Die minimale Größe einer Partition.
$S^a$	Die steuerbare Nachfrage bzw. der Fahrplan eines Agenten. Analog dazu definiert $S_T^a$ den Fahrplanbaum auf Basis von TBST.
$S_\mu$	Die durchschnittlich in jedem Zeitpunkt aufgetretene Nachfrage steuerbarer Verbraucher.
$S^\omega$	Die gesamte steuerbare Nachfrage einer Autonomen Verbraucherorganisation. Analog dazu definiert $S_T^\omega$ den Fahrplanbaum auf Basis von TBST.
$\text{sim}(\mathcal{P}, \mathcal{Q})$	Die Ähnlichkeit zwischen zwei Partitionierungen.
$T(t)$	Die Temperatur eines thermischen Verbrauchers zum Zeitpunkt $t$ .
$t_{\text{arr}}$	Der Ankunftszeitpunkt eines Elektrofahrzeugs.
$t_{\text{dep}}$	Der Abfahrtszeitpunkt eines Elektrofahrzeugs.
$t_{\text{early}}$	Der früheste Zeitpunkt, zu dem ein programmgetriebener Verbraucher sein Programm beendet haben soll.
$t_{\text{late}}$	Der späteste Zeitpunkt, zu dem ein programmgetriebener Verbraucher sein Programm beendet haben soll.
$T_{\max}$	Die maximale Temperatur eines thermischen Verbrauchers.
$T_{\min}$	Die minimale Temperatur eines thermischen Verbrauchers.

$t_{\text{start}}$	Der Zeitpunkt, zu dem ein programmgetriebener Verbraucher sein Programm gestartet hat.
$\tau_{\text{dur}}$	Die Dauer des Programms eines programmgetriebenen Verbrauchers.
$\tau_{\text{init}}$	Die Dauer, die ein Elektrofahrzeug nach Ankunft geladen werden muss, um schnellstmöglich $E_{\text{des}}^{\text{min}}$ zu erreichen.
$\tau_{\text{off}}$	Die maximale Anzahl an Zeitpunkten, die sich ein abschaltbarer Verbraucher in dem Zeitraum $\mathcal{T}_{\text{sub}}$ abschalten lässt.
$\mathcal{T}^{\omega}$	Die durchschnittlich in jeder Autonomen Verbraucherorganisation aufgetretene Dauer für die Berechnung der Fahrpläne für die untergeordneten Verbraucher.
$\mathcal{T}^{\lambda}$	Die durchschnittlich in jedem Autonomen Virtuellen Kraftwerk aufgetretene Dauer für die Berechnung der Fahrpläne für die untergeordneten Kraftwerke.
$t$	Ein diskreter Zeitpunkt.
$\mathcal{T}$	Die Menge aller äquidistanten diskreten Zeitpunkte $t$ .
$\mathcal{T}_{\text{sub}}$	Die Menge der Zeitschritte, während denen ein abschaltbarer Verbraucher in Betrieb ist und sich maximal $\tau_{\text{off}}$ Zeitschritte abschalten lässt.
$U^{\omega}$	Die ungesteuerte Leistung einer Autonomen Verbraucherorganisation. Analog dazu definiert $U_{\Gamma}^{\omega}$ den zugehörigen TBST.
$v_i(t)$	Die Geschwindigkeit eines Partikels $\Pi_i$ in der Iteration $t$ .
$\mathcal{W}$	Die Menge der Zeitschritte, für die Fahrpläne erstellt werden.

## *Symbolverzeichnis*

$x_i(t)$  Die Position eines Partikels  $\Pi_i$  im Suchraum in der Iteration  $t$ .

## I.

# SELBST-ORGANISATION UND TRUST IN SMART GRIDS: MOTIVATION UND ÜBERBLICK

Der erste Teil dieser Arbeit startet mit einer Motivation und legt die Grundlagen für die weitere Arbeit.



# EINLEITUNG

---

## 1.1. MOTIVATION

Die größtenteils vom Menschen verursachte Zunahme an Treibhausgasen in der Erdatmosphäre verstärkt den natürlichen Treibhauseffekt und sorgt für eine ansteigende globale Erwärmung. So war das Jahr 2016 das wärmste Jahr seit Beginn der Aufzeichnung von Klimadaten, womit bereits das dritte Mal in Folge ein neuer Temperaturrekord aufgestellt wurde [80]. Die globale Erwärmung hat zahlreiche ernsthafte Konsequenzen für Mensch und Umwelt, darunter beispielsweise das Ansteigen des Meeresspiegels durch das Abschmelzen der Pole und vermehrte extreme Wettersituationen wie Dürren und Starkregen. Ein wesentlicher Faktor bei dem Ausstoß von Treibhausgasen ist die Verbrennung fossiler Brennstoffe für die Gewinnung von Strom, Wärme und den Betrieb von Verkehrsmitteln.

Um die globale Erwärmung abzuschwächen, wurde bereits 1997 im sogenannten *Kyoto-Protokoll* der Vereinten Nationen eine Reduktion des Ausstoßes der Treibhausgase gegenüber dem Wert von 1990 beschlossen. Ein großer Schritt in Sachen Klimaschutz wurde 2015 im Rahmen der Klimakonferenz in Paris gemacht. Im sogenannten *Übereinkommen von Paris* einigten sich die Mitgliedsstaaten der Vereinten Nationen völkerrechtlich bindend auf eine Begrenzung der globalen Erwärmung auf unter 2°C gegenüber vorindustriellen Temperaturwerten, angestrebt ist sogar eine Begrenzung auf unter 1,5°C [36].

Damit diese ambitionierten Ziele eingehalten werden können, muss jedoch die Reduktion der Emission von Treibhausgasen bald beginnen und in großen Schritten voranschreiten [91], anderenfalls ist eine globale Erwärmung von 4°C oder mehr möglich [34]. Spätestens in der zweiten Hälfte dieses Jahrhunderts dürfen netto keine Treibhausgase mehr emittiert werden [34]. Dies hat zur Folge, dass weltweit ein großer Wandel in den Sektoren Strom, Wärme und Verkehr stattfinden muss, damit diese ohne die Emission von Treibhausgasen auskommen.

Im Zuge des Übereinkommens von Paris hat die deutsche Bundesregie-



## 1. Einleitung

rung im November 2016 den sogenannten *Klimaschutzplan 2050* [34] vorgelegt, der in regelmäßigen Abständen aktualisiert und angepasst werden soll. In diesem ist derzeit zum Ziel gesetzt, bis 2050 die Emission von Treibhausgasen um 80–95 % gegenüber 1990 zu reduzieren. Demzufolge müssen auch die Energieversorgung durch Strom und Wärme und der Verkehrssektor bis 2050 nahezu dekarbonisiert sein.

In diese Richtung hat Deutschland bereits vor Jahren wichtige Schritte eingeleitet, die zur sogenannten *Energiewende* führten. Mit dem *Gesetz für den Ausbau erneuerbarer Energien* (EEG)<sup>1</sup> wurde im Jahre 2000 ein Gesetz erlassen, das den Ausbau von Stromerzeugern aus erneuerbaren Energien massiv beschleunigt hat; insbesondere Erzeuger basierend auf Wind- und Sonnenkraft haben stark zugenommen. Im Jahr 2015 wurden bereits knapp 32 % der Stromnachfrage von Erzeugern aus erneuerbaren Energien, vor allem Windkraftanlagen und Photovoltaikanlagen, gedeckt und hatten damit als Gruppe den größten Anteil aller Stromerzeuger an der Deckung der Nachfrage [29]. Dieser Anteil soll in den kommenden Jahren noch weiter ansteigen und im Jahr 2025 40–45 %, im Jahr 2035 55–60 % und im Jahr 2050 mindestens 80 % betragen [29].

Durch die weitgehende Elektrifizierung des Verkehrs auf Basis von Strom aus erneuerbaren Energien soll auch der Verkehrssektor klimafreundlicher werden. Der Anteil an Fahrzeugen, die zumindest teilweise mit Strom betrieben werden können, ist zwar derzeit noch verhältnismäßig gering, legt aber laut Statistiken des Kraftfahrt-Bundesamtes bereits seit Jahren kontinuierlich zu [63] und wird in Zukunft voraussichtlich weiter kräftig ansteigen: So hat sich die Bundesregierung zum Ziel gesetzt, im Jahre 2020 eine Million und im Jahre 2030 sechs Millionen Elektrofahrzeuge in Deutschland in Betrieb zu haben [28].

Doch bereits die heutige Situation im elektrischen Energieversorgungssystem mit dem gestiegenen Anteil an unsicherer, volatiler Einspeisung elektrischer Energie aus Wind- und Sonnenkraft sorgt für zunehmende Schwierigkeiten, das elektrische Energieversorgungssystem stabil zu betreiben, also für ein Gleichgewicht zwischen erzeugter und nachgefragter Leistung zu jeder Zeit zu sorgen. Dieser Aufgabe kommen nämlich bisher weitgehend nur größere steuerbare Kraftwerke nach, die ihre Leistung der aktuellen Nachfrage und der aktuellen Einspeisung aus Wind- und

<sup>1</sup> [http://www.gesetze-im-internet.de/eeg\\_2014/index.html](http://www.gesetze-im-internet.de/eeg_2014/index.html), Stand 2017 (besucht am 23.03.2017)

Sonnenkraft anpassen müssen, dies allerdings aufgrund ihrer limitierten Steuerungsmöglichkeiten nicht beliebig machen können. Diese Situation verschärft sich in der Zukunft weiterhin, wenn der Anteil der eingespeisten Leistung aus erneuerbarer Energien weiter zunimmt und sich Elektrofahrzeuge in der Bevölkerung weiter verbreiten, die den Stromverbrauch in Deutschland um einen wesentlichen Faktor erhöhen werden und für große Lastspitzen am Abend sorgen werden.

Eine Möglichkeit, dieser Herausforderung Herr zu werden, ist der aktive Einbezug aller Systemteilnehmer in die Steuerung elektrischer Energieversorgungssysteme, die bisher dazu nicht beitragen, denen es aber prinzipiell möglich wäre. Das beinhaltet beispielsweise ein Großteil der Biomasseanlagen oder auch viele elektrische Verbraucher wie zum Beispiel Kühlschränke und -häuser, Waschmaschinen oder Elektrofahrzeuge, welche zudem als Energiespeicher wenn nötig auch Strom in das elektrische Energieversorgungssystem abgeben könnten. Notwendige Voraussetzung hierfür ist die Durchdringung des elektrischen Energieversorgungssystems mit IKT. Forschung und Politik sind sich einig, dass sich das elektrische Energieversorgungssystem in Zukunft zu einem Smart Grid entwickeln muss, um mit den zukünftigen Herausforderungen umgehen zu können [31, 17]. Das ebnet den Weg für intelligente Lösungen durch den Einsatz von IKT wie einen autonomen Betrieb des elektrischen Energieversorgungssystems.

Ein autonomer Betrieb des elektrischen Energieversorgungssystems, der alle steuerbaren Erzeuger und Verbraucher miteinbezieht, steht allerdings vor zwei zentralen Herausforderungen. Einerseits muss der autonome Betrieb elektrischer Energieversorgungssysteme aufgrund der riesigen Anzahl an zu koordinierenden Erzeuger und Verbraucher skalieren. Andererseits muss er mit den im System vorliegenden Unsicherheiten umgehen können, die durch die unsicheren Vorhersagen diverser Systemteilnehmer verursacht werden.

Aufbauend auf dem Konzept der *Autonomen Virtuellen Kraftwerke* [108, 5], ein Ansatz zur autonomen, skalierbaren Steuerung von Kraftwerken unter Unsicherheiten, und der dafür entwickelten Techniken werden in dieser Arbeit *Autonome Verbraucherorganisationen* als ein Ansatz zur autonomen, skalierbaren Steuerung von Verbrauchern unter Unsicherheiten vorgestellt.

## 1. Einleitung

### 1.2. ERZIELTE ERGEBNISSE

In dieser Arbeit wurden folgende Ergebnisse erzielt:

- Ein Ansatz zum autonomen Demand Side Management in Smart Grids durch sogenannte Autonome Verbraucherorganisationen, die eine skalierbare und robuste Einsatzplanung von steuerbaren Verbrauchern erlauben. Die Evaluierung konnte zeigen, dass eine Einsatzplanung von steuerbaren Verbrauchern im Kontext der Autonomen Verbraucherorganisationen zu deutlich besseren Lösungen führt, als eine ungesteuerte Nachfrage.
- Die Ausbildung von Autonomen Verbraucherorganisationen erfolgt selbst-organisiert durch Lösung des Partitionierungsproblems [12] mit dem Ziel einer homogenen Partitionierung [12]. Zwei Algorithmen [12, 5], die das Partitionierungsproblem lösen, werden in dieser Arbeit vorgestellt. Dass eine homogene Partitionierung für Autonome Verbraucherorganisationen bessere Resultate liefert als Partitionierungen, die nicht eine homogene Partitionierung bilden, wurde in dieser Arbeit gezeigt.
- Eine robuste Einsatzplanung von steuerbaren Verbrauchern auf Basis von Trust-basierten Szenarien [16], wodurch die Quantifizierung und Antizipation von Unsicherheiten ermöglicht wird. Dass die Berücksichtigung von Unsicherheiten mittels Trust-basierten Szenarien bessere Ergebnisse erzielt als eine Einsatzplanung auf Basis von Vorhersagen, konnte in einer Evaluierung demonstriert werden.
- Ein Ansatz zur Integration von Autonomen Verbraucherorganisationen in Autonome Virtuelle Kraftwerke, resultierend in einem autonomen Supply Demand Management. In der Evaluierung hat sich gezeigt, dass Autonome Virtuelle Kraftwerke zwar mit einer glatteren Residuallast konfrontiert werden, allerdings in den untersuchten Evaluationsszenarien keine weiteren Vorteile hatten.

### 1.3. ÜBERBLICK ÜBER DIE ARBEIT

Diese Arbeit besteht aus vier größeren Teilen: (1) Der erste Teil der Arbeit dient der Motivation und Hinführung an die Thematik. (2) Im zweiten

Teil der Arbeit wird der Ansatz der Autonomen Verbraucherorganisationen vorgestellt, die ein autonomes Demand Side Management durch den Einsatz von Selbst-Organisation und Trust [9] ermöglichen. (3) Daraufhin werden im dritten Teil der Arbeit die Autonomen Verbraucherorganisationen mit dem existierenden Konzept der Autonomen Virtuellen Kraftwerke – ein Ansatz zur autonomen Steuerung von Kraftwerken – zu einem autonomen Supply Demand Management kombiniert. (4) Im vierten und letzten Teil der Arbeit erfolgt eine ausführliche Evaluierung der vorgestellten Konzepte und die Arbeit wird abgeschlossen.

Im ersten Teil der Arbeit werden nach der in diesem Kapitel erfolgten Einleitung in Kapitel 2 zunächst die Grundlagen elektrischer Energieversorgungssysteme gelegt, die für das Verständnis und die Motivation dieser Arbeit notwendig sind. Außerdem stellt es vor, mit welchen Herausforderungen, die durch den Wandel in der Energieversorgung und im Verkehrssektor verursacht werden, zukünftige elektrische Energieversorgungssysteme konfrontiert werden, und motiviert die autonome Steuerung von sowohl Kraftwerken als auch Verbrauchern in einem Smart Grid als eine Möglichkeit mit diesen Herausforderungen umzugehen.

Im zweiten Teil der Arbeit stellt Kapitel 3 den der Arbeit zugrundeliegenden Ansatz zu einem autonomen Demand Side Management in sogenannten Autonomen Verbraucherorganisationen vor. Durch den Einsatz von Selbst-Organisation und von Trust werden elektrische Verbraucher skalierbar unter der Betrachtung von Unsicherheiten in den Betrieb elektrischer Energieversorgungssysteme miteinbezogen.

Im Anschluss wird in Kapitel 4 vorgestellt, wie sich Autonome Verbraucherorganisationen selbst-organisiert ausbilden. Dazu wird das zugrundeliegende Partitionierungsproblem [12] eingeführt. Zudem werden zwei Algorithmen vorgestellt, die das Partitionierungsproblem im Allgemeinen lösen können: PSOPP [12], eine bio-inspirierte Metaheuristik, und SPADA [5], ein agenten-basierter Ansatz.

Die Einsatzplanung in Autonomen Verbraucherorganisationen wird in Kapitel 5 präsentiert. Dazu wird im ersten Teil dieses Kapitels generell das Optimierungsproblem der Glättung der Residuallast eingeführt, das noch ohne die Betrachtung von Unsicherheiten auskommt. Im zweiten Teil des Kapitels wird dieses Optimierungsproblem dahingehend erweitert, dass es durch den Einsatz von Trust-basierten Szenarien [16] mit Unsicherheiten umgehen kann.

## 1. Einleitung

Im dritten Teil der Arbeit stellt Kapitel 6 zunächst das bereits existierende Konzept der Autonomen Virtuellen Kraftwerke genauer vor. In Kapitel 7 werden dann Autonome Verbraucherorganisationen in Autonome Virtuelle Kraftwerke integriert.

Der letzte Teil der Arbeit startet mit einer Evaluierung, die die Wirksamkeit der in dieser Arbeit vorgestellten Konzepte unterstreicht. Zu diesem Zweck erfolgt in Kapitel 8 die Evaluierung in unterschiedlichen Evaluationsszenarien und Systemkonfigurationen – zuerst nur für Autonome Verbraucherorganisation und danach für die Kombination aus Autonomen Verbraucherorganisationen und Autonomen Virtuellen Kraftwerken. Abschließend zieht Kapitel 9 ein Fazit über die erzielten Ergebnisse und gibt einen Ausblick auf mögliche zukünftige Arbeiten.

**ZUSAMMENFASSUNG** Dieses Kapitel gibt einen Überblick über die Grundlagen von elektrischen Energieversorgungssystemen und motiviert, warum aktuelle und zukünftige Änderungen in elektrischen Energieversorgungssystemen es notwendig machen, die bisher weitestgehend unangetasteten elektrischen Verbraucher zukünftig stärker in den Betrieb eines elektrischen Energieversorgungssystems einzu beziehen und diese Systeme in der Zukunft autonom zu betreiben. Im Falle eines autonomen Betriebs elektrischer Energieversorgungssysteme müssen allerdings zwei zentrale Herausforderungen gemeistert werden: Solch ein Betrieb muss einerseits trotz einer riesigen Anzahl an Systemteilnehmern skalieren und andererseits mit den in diesen Systemen inhärenten Unsicherheiten umgehen können.

**3**UNÄCHST liefert Abschnitt 2.1 diejenigen Grundlagen der elektrischen Energieversorgung, die für das Verständnis dieser Arbeit notwendig sind. Im Anschluss zeigt Abschnitt 2.2 die Probleme und Herausforderungen, die mit dem fortlaufenden Wandel in der elektrischen Energieversorgung einhergehen, verursacht durch die *Energiewende*. Abschnitt 2.3 motiviert die Flexibilisierung des elektrischen Verbrauchs als eine wichtige Maßnahme für eine erfolgreiche Energiewende. Dass sich das elektrische Energieversorgungssystem zu einem Smart Grid entwickeln muss, erläutert Abschnitt 2.4. Abschließend stellt Abschnitt 2.5 zwei Herausforderungen vor, die in einem zukünftigen, autonom betriebenen elektrischen Energieversorgungssystem auftreten und mit denen umgegangen werden muss.

### 2.1. GRUNDLAGEN DER ELEKTRISCHEN ENERGIEVERSORGUNG

Oberstes Ziel im elektrischen Energieversorgungssystem ist es, dass die von elektrischen Energieerzeugern in das System eingespeiste Leistung zu jedem Zeitpunkt der von elektrischen Verbrauchern nachgefragten Leis-

## 2. Elektrische Energieversorgungssysteme

tung – der sogenannten *Last* – entspricht. Ob dieses Ziel eingehalten wird, lässt sich direkt an der aktuellen Netzfrequenz des Wechselstroms im elektrischen Energieversorgungsnetz ablesen. Sind die eingespeiste Leistung und die nachgefragte Leistung im Gleichgewicht, so entspricht die Netzfrequenz ihrem Nennwert. Das in der Verantwortung der *European Network of Transmission System Operators for Electricity* (ENTSO-E) liegende kontinental-europäische Verbundnetz hat z. B. eine Nennfrequenz von 50 Hz [40].

Treten Abweichungen zwischen eingespeister und nachgefragter Leistung auf, weicht die Netzfrequenz ebenfalls von dem Nennwert ab. Ist z. B. die Nachfrage elektrischer Energie höher als die Einspeisung elektrischer Energie, sinkt die Netzfrequenz unter 50 Hz. Umgekehrt, wenn mehr elektrische Leistung in das Stromnetz eingespeist wird als gerade nachgefragt wird, steigt die Netzfrequenz über 50 Hz. Zu große Abweichungen der Netzfrequenz von ihrem Nennwert können allerdings zu Schäden an Kraftwerken und elektrischen Verbrauchern führen. Bei zu großen Frequenzabweichungen werden deshalb schrittweise Erzeuger bzw. Verbraucher vom Netz genommen, mit dem Ziel, das Netz wieder zu stabilisieren und einen Zusammenbruch (Blackout) zu vermeiden [41].

Um die Frequenzabweichungen gar nicht erst zu groß werden zu lassen, wird im elektrischen Energieversorgungssystem die sog. *Regelleistung* eingesetzt, die reaktiv innerhalb von wenigen Sekunden bereits bei kleinen Frequenzabweichungen ab 10 mHz aktiviert wird und das Ziel hat, die Frequenz zunächst zu stabilisieren und später zu ihrem Nennwert zurückzubringen [40]. Da der Abruf von Regelleistung für den Verursacher allerdings kostspielig ist, wird versucht, so wenig Abweichungen wie möglich auftreten zu lassen und jederzeit für ein Gleichgewicht von erzeugter und nachgefragter Leistung zu sorgen.

Zur Erfüllung des Ziels des Gleichgewichts von nachgefragter und eingespeister Leistung wird in der Regel die Last kaum angepasst. Stattdessen läuft das elektrische Energieversorgungssystem nachfrage-getrieben, d. h. die elektrischen Energieerzeuger speisen anhand der Last in das System ein. Der Einsatz von Energiespeichern zur Erfüllung des Ziels ist nur begrenzt möglich, denn das elektrische Energieversorgungssystem weist bis heute sehr wenige Speichermöglichkeiten auf. Das liegt einerseits daran, dass Speicher bisher relativ teuer und/oder ineffizient sind; andererseits sind manche Speichermöglichkeiten aus geographischen Gründen nur begrenzt installierbar. Zu dieser Sorte gehören beispielsweise Pumpspeicherkraftwerke, bei

## 2.1. Grundlagen der elektrischen Energieversorgung

denen Wasser in einen geographisch höher gelegenen See gepumpt und bei Bedarf wieder abgelassen wird. Deren Bau ist zudem mit ökologischen und landschaftlichen Nachteilen verbunden. Pumpspeicherkraftwerke machen in Deutschland derzeit rund 6 % der installierten steuerbaren Leistung aus [33]. Folglich muss die momentane Nachfrage hauptsächlich unmittelbar von elektrischen Energieerzeugern gedeckt werden.

Steuerbare Kraftwerke können allerdings nicht beliebig Leistung in das System einspeisen, sondern unterliegen technischen Einschränkungen. So hat jedes Kraftwerk eine *Minimalleistung* sowie eine *Maximalleistung* (oft auch mit *Nennleistung* bezeichnet), mit der es betrieben werden kann. Zudem sind steuerbare Kraftwerke nicht beliebig von einem Zeitpunkt zum nächsten regelbar, sondern weisen ein träges Verhalten auf. Diese Trägheit zeichnet sich durch die *Anfahrzeit*<sup>2</sup> und die *Änderungsgeschwindigkeit* der eingespeisten Leistung aus. So bewegt sich die Änderungsgeschwindigkeit von Kohle- oder Kernkraftwerken z. B. typischerweise zwischen ca. 3–10 % der Nennleistung pro Minute. Die entsprechenden Anfahrzeiten bewegen sich im Bereich von wenigen Stunden. Kraftwerke, die in ihrem Verhalten eher träge sind, dafür aber Leistung mit sehr günstigen Betriebskosten erbringen können, werden in der Regel über den Tag oder einen größeren Zeitraum konstant ausgelastet und in ihrer Leistung wenig angepasst. Eine konstante, hohe Auslastung ist ökonomisch und technisch gesehen für solche Kraftwerke am effizientesten. Sie werden daher zumeist zur Deckung der durchgängig über den ganzen Tag auftretenden Last – der *Grundlast* – oder zur Deckung von über einen längeren Zeitraum auftretenden Last – der *Mittellast* – eingesetzt. Für Lastspitzen – eine erhöhte Nachfrage über einen kurzen Zeitraum – werden hingegen Kraftwerke eingesetzt, die sehr schnell anfahren können und eine hohe Änderungsgeschwindigkeit aufweisen, wie z. B. Gasturbinenkraftwerke, deren Änderungsgeschwindigkeiten bis zu 20 % der Nennleistung pro Minute betragen können. Solche *Spitzenlastkraftwerke* besitzen meist jedoch relativ hohe Betriebskosten und eine geringere Effizienz und werden daher bevorzugt für die Deckung von Lastspitzen oder die Erbringung von Regelleistung eingesetzt. Eine beispielhafte Lastkurve mit einer Unterteilung in Grund-, Mittel- und Spitzenlast zeigt Abbildung 2.1.

Die Trägheit steuerbarer Kraftwerke sowie ökonomische Kriterien erfor-

<sup>2</sup> Die Anfahrzeit bezeichnet die Dauer bis ein steuerbares Kraftwerk – ausgehend vom Stillstand – betriebsbereit ist.

## 2. Elektrische Energieversorgungssysteme

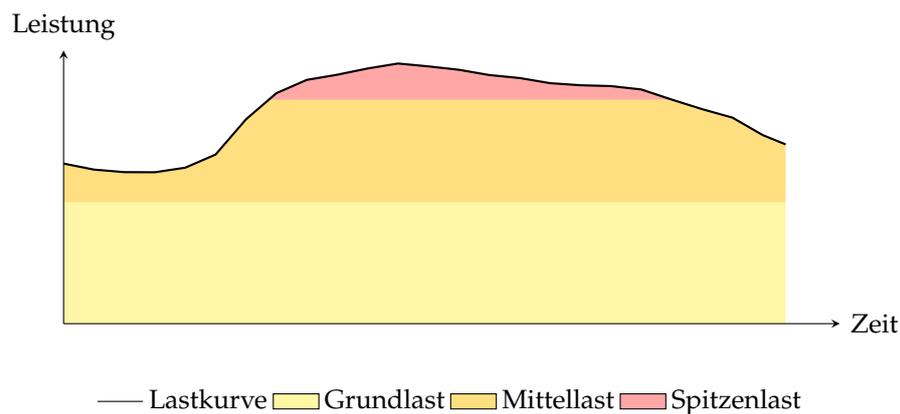


Abbildung 2.1.: Eine beispielhafte Lastkurve über einen Zeitraum von einem Tag, unterteilt in Grund-, Mittel- und Spitzenlast. Lastspitzen treten vor allem mittags und abends auf, die durch verhältnismäßig teure Spitzenlastkraftwerke gedeckt werden müssen.

dern deshalb statt einem reaktiven einen proaktiven Betrieb von steuerbaren Kraftwerken zur Deckung der Last: Damit die Last überhaupt gedeckt werden kann, Kraftwerke effizient und kostengünstig betrieben werden können und für die Deckung der Last die günstigst möglichen Kraftwerke eingesetzt werden, muss auf Basis von Vorhersagen der Last die eingespeiste Leistung von steuerbaren Kraftwerken entsprechend im Voraus geplant werden. Dies geschieht im Rahmen der *Kraftwerkseinsatzplanung*; Ergebnis der Einsatzplanung ist ein *Fahrplan* für jedes steuerbare Kraftwerk. Ein Fahrplan gibt an, wie viel Leistung ein steuerbares Kraftwerk zu welchem Zeitpunkt einzuspeisen hat, gewöhnlich in einer Auflösung von 15 Minuten.

Doch nicht nur steuerbare Erzeuger tragen zu der Menge an eingespeister Leistung und damit zur Deckung der Last bei, sondern auch *dargebotsabhängige* Erzeuger, also nicht steuerbare Erzeuger, die abhängig von ihren Umwelteinflüssen Leistung in das elektrische Energieversorgungssystem einspeisen. Zu dieser Gruppe von Erzeugern gehören z. B. Windkraftanlagen und Photovoltaikanlagen, die abhängig vom Wetter Leistung erzeugen. Für die steuerbaren Kraftwerke bedeutet dies, dass der Anteil an eingespeister Leistung, der von dargebotsabhängigen Erzeugern eingebracht wird, folglich nicht mehr für die Deckung der Last erbracht werden muss. Die Differenz aus Last und der eingespeisten Leistung dargebotsabhängiger Kraftwerke wird *Residuallast* genannt (von lat. *residuum*, Rest). Abbildung 2.2 visualisiert diesen Zusammenhang. Folglich werden für die

## 2.2. Wandel in der elektrischen Energieversorgung durch die Energiewende

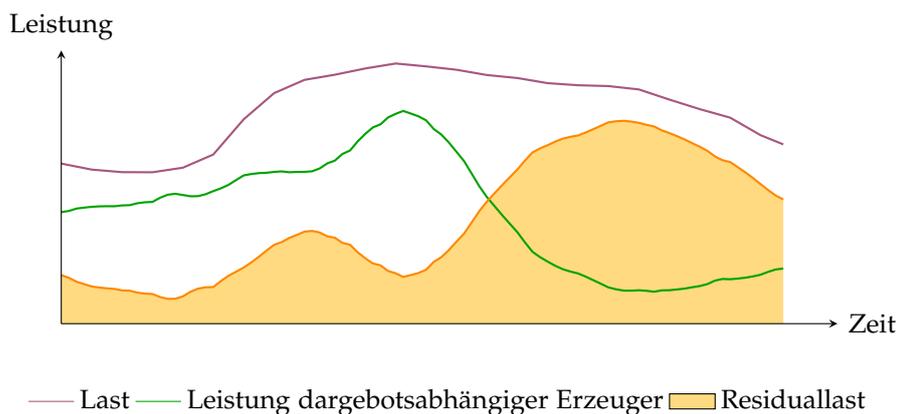


Abbildung 2.2.: Eine beispielhafte Lastkurve und Kurve eingespeister Leistung von dargebotsabhängigen Erzeugern wie z. B. Windkraftanlagen und Photovoltaikanlagen und die daraus resultierende Residuallast. Die durch steuerbare Kraftwerke zu deckende Residuallast (orangefarbene Fläche) entsteht aus der Differenz der Last und der Leistung dargebotsabhängiger Erzeuger und kann unter Umständen auch negativ werden, wenn die dargebotsabhängige Leistung die Nachfrage übertrifft.

Kraftwerkseinsatzplanung nicht nur Vorhersagen der Last benötigt, sondern auch Vorhersagen der dargebotsabhängigen Leistung, um daraus resultierend eine Vorhersage der Residuallast zu erstellen, auf deren Basis Kraftwerksfahrpläne erstellt werden.

### 2.2. WANDEL IN DER ELEKTRISCHEN ENERGIEVERSORGUNG DURCH DIE ENERGIEWENDE

Die in Deutschland<sup>3</sup> vor allem aus Gründen des Klima- und Umweltschutzes gesellschaftlich und politisch gewollte Abkehr von der Kernenergie und fossilen, endlichen Rohstoffen hin zu regenerativen, erneuerbaren Energien – oft als *Energiewende* bezeichnet –, führt zu drastischen Umwälzungen im elektrischen Energieversorgungssystem.

So stieg die installierte Leistung der Stromerzeugungsanlagen aus erneuerbaren Energien von ca. 4,2 GW im Jahre 1990 auf ca. 97,1 GW im Jahre 2015 [29] und ist damit schon in etwa auf dem Niveau der installierten

<sup>3</sup> Im Folgenden wird mit der Entwicklung in Deutschland argumentiert und Zahlen aus Deutschland präsentiert; der hier skizzierte Wandel in der elektrischen Energieversorgung ist aber kein auf Deutschland beschränktes Phänomen, sondern betrifft weite Teile der Welt.

## 2. Elektrische Energieversorgungssysteme

Leistung von konventionellen, steuerbaren Kraftwerken, die nicht auf erneuerbaren Energieträgern basieren<sup>4</sup>. Im gleichen Zeitraum stieg der Anteil derartiger Anlagen am Bruttostromverbrauch von 3,4 % auf 31,6 % [29]. Beschleunigt wurde diese Entwicklung vor allem durch das *Gesetz für den Ausbau erneuerbarer Energien* (EEG)<sup>5</sup>, das als Anreiz für die Einspeisung von Leistung aus erneuerbaren Energien in das elektrische Energieversorgungssystem attraktive Vergütungssätze festlegt. Das EEG legt auch in seiner aktuellen Fassung<sup>6</sup> die Ziele für die kommenden Jahre fest und bestimmt somit den weiteren Trend bzgl. dem Ausbau erneuerbarer Energien: Der Anteil des aus erneuerbaren Energien erzeugten Stroms am Bruttostromverbrauch soll bis zum Jahr 2025 auf 40–45 % steigen, bis zum Jahr 2035 auf 55–60 % zulegen und im Jahr 2050 mindestens 80 % betragen. Dieser bisherige und weiter anhaltende massive Zuwachs an Stromerzeugungsanlagen aus erneuerbaren Energien stellt das elektrische Energieversorgungssystem allerdings vor enorme Herausforderungen.

### *Zunehmende Volatilität und Vorhersagefehler durch dargebotsabhängige Erzeuger*

Mit 19,8 % Anteil am Bruttostromverbrauch im Jahr 2015 und damit rund 63,0 % der erzeugten Strommenge aus erneuerbaren Energien [29] stammt ein erheblicher Anteil der Stromerzeugung aus Windkraft- und Photovoltaikanlagen. Diese speisen gemäß den Wind- oder Lichtbedingungen in das elektrische Energieversorgungssystem ein; dementsprechend *volatil und fluktuierend* ist die Einspeisung dargebotsabhängiger Erzeuger (s. Abbildung 2.3) und kann sich innerhalb kurzer Zeit stark verändern. So kann sich beispielsweise die Windeinspeisung Schätzungen von Klobasa et al. zufolge innerhalb einer Stunde um bis zu 25 % der installierten Leistung ändern [60] – also im zweistelligen GW-Bereich.

4 Gemäß der Kraftwerkliste der Bundesnetzagentur [33] betrug die installierte Leistung von Kraftwerken, die nicht auf erneuerbaren Energieträgern basieren, Ende 2015 ca. 106,2 GW.

5 Das EEG war früher bekannt unter dem Namen *Gesetz für den Vorrang Erneuerbarer Energien*. Als Vorgänger des EEG gilt das *Stromeinspeisungsgesetz* von 1990.

6 [http://www.gesetze-im-internet.de/eeg\\_2014/index.html](http://www.gesetze-im-internet.de/eeg_2014/index.html), Stand 2017 (besucht am 23.03.2017)

7 Daten zur Verfügung gestellt von der TenneT TSO GmbH unter <https://www.tennetso.de/site/de/Transparenz/veroeffentlichungen/netzkennzahlen/tatsaechliche-und-prognostizierte-windenergieeinspeisung> (besucht am 01.11.2016).

## 2.2. Wandel in der elektrischen Energieversorgung durch die Energiewende

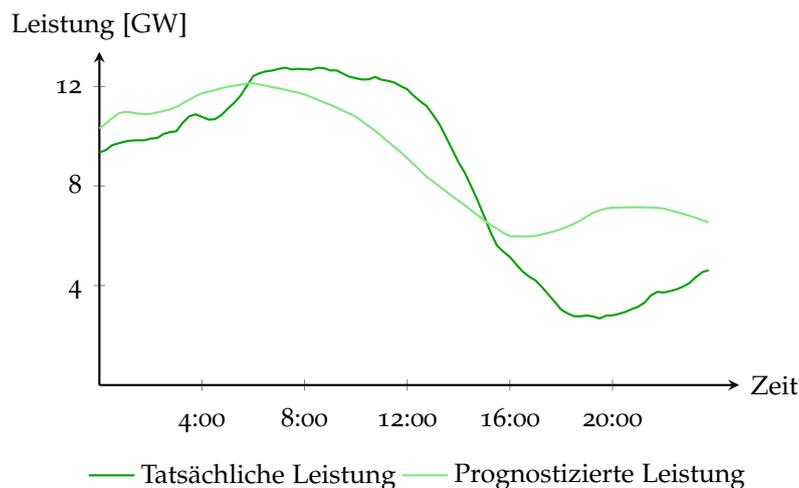


Abbildung 2.3.: Die volatile Einspeisung aller Windkraftanlagen in der deutschen Regelzone der TenneT TSO GmbH für den 8. Januar 2016 und die zugehörige, am Vortag abgegebene prognostizierte Einspeisung.<sup>7</sup> Während die eingespeiste Leistung am späten Vormittag noch über 12 GW betrug, fiel sie ab dem Mittag bis in den frühen Abend auf unter 3 GW ab. Die Prognose wich von der tatsächlichen Leistung teilweise deutlich ab.

In Zeiten niedriger Einspeisung dargebotsabhängiger Erzeuger müssen somit die konventionellen, steuerbaren Kraftwerke die Last weitestgehend selbst befriedigen, wohingegen in Zeiten hoher Einspeisung dargebotsabhängiger Erzeuger die Last zu großen Teilen von Windkraft- und Photovoltaikanlagen gedeckt werden kann und konventionelle, steuerbare Kraftwerke heruntergefahren werden müssen. Wechselt diese Situation aufgrund der Volatilität häufig, ist die Deckung der Residuallast hinsichtlich der Trägheit steuerbarer Kraftwerke ein schwieriges Unterfangen und führt somit zu Abweichungen zwischen erzeugter und nachgefragter Leistung.

Obwohl sich Windkraftanlagen und auch neuere Photovoltaikanlagen prinzipiell aus der Ferne verhältnismäßig schnell ab- und anschalten lassen und damit Ungleichgewichte zwischen erzeugter und nachgefragter Leistung vermieden oder reduziert werden können, wird das in der Praxis nur äußerst selten durchgeführt. Das liegt daran, dass im EEG die vorrangige Einspeisung von Erzeugern aus erneuerbaren Energien festgelegt ist und eine Abnahmepflicht besteht. Zudem muss für Leistung aus erneuerbaren Energien, die nicht in das Stromnetz eingespeist werden kann, weil z. B. das Netz überlastet ist, eine Entschädigung gezahlt werden. Im Jahr 2015

## 2. Elektrische Energieversorgungssysteme

mussten beispielsweise rund 4722 GWh an Energie abgeregelt werden, was sich auf Entschädigungsansprüche von rund 478 Mio. € belief und damit bereits fast das Dreifache der Ansprüche aus dem Jahr 2014 betrug [32].

Doch nicht nur die volatile Einspeisung stellt eine Herausforderung bei der Integration dargebotsabhängiger Erzeuger in das elektrische Energieversorgungssystem dar. Die Vorhersage der voraussichtlich eingespeisten dargebotsabhängigen Leistung, die die Basis für die Kraftwerkseinsatzplanung ist (siehe Abschnitt 2.1), ist zudem mit hohen *Unsicherheiten* verbunden (siehe Abbildung 2.3 auf Seite 15). Vorhersagefehler führen dazu, dass die tatsächliche Residuallast von der vorhergesagten Residuallast abweicht – welche die Basis für die Kraftwerkseinsatzplanung war – und daher das Gleichgewicht zwischen erzeugter und nachgefragter Leistung nicht mehr durch die Kraftwerksfahrpläne gehalten werden kann.

Vermeehrt auftretende Abweichungen zwischen erzeugter und nachgefragter Leistung, sowohl verursacht durch die zunehmende Volatilität als auch durch Vorhersagefehler, führen dazu, dass immer häufiger teure Regelleistung zur Kompensation solcher Abweichungen bezogen werden muss und unter Umständen eine nachträgliche Anpassung der Kraftwerksfahrpläne durchgeführt werden muss. Folglich wird es aktuell zunehmend schwieriger und teurer das Gleichgewicht zwischen erzeugter und nachgefragter Leistung zu halten.

### *Zunehmende Anzahl potentiell steuerbarer Erzeuger*

Doch nicht nur die Anzahl an dargebotsabhängigen Erzeugern aus erneuerbaren Energien nimmt stark zu; auch die Anzahl an potentiell steuerbaren Erzeugern aus erneuerbaren Energien, allen voran Erzeuger basierend auf Biomasse oder Biogas, hat in den letzten Jahren extrem zugelegt [29]. Derzeit werden solche Erzeuger selten von außen gesteuert, obwohl es für den stabilen Betrieb des elektrischen Energieversorgungssystems von großen Vorteil wäre. Stattdessen speisen die Anlagenbetreiber derzeit aufgrund der bestehenden EEG-Vergütung und -Abnahmepflicht überwiegend selbstständig nach eigenen, ökonomischen Interessen in das Stromnetz ein. Um sämtliches Potenzial an steuerbarer Leistung für die Deckung der fluktuierenden Residuallast zu verwenden, sollen Biomasse-Anlagen sowie Anlagen der

## 2.2. Wandel in der elektrischen Energieversorgung durch die Energiewende

KWK<sup>8</sup> zukünftig flexibler betrieben werden [31] und sind daher potentielle Teilnehmer an der Kraftwerkseinsatzplanung.

### *Veränderungen im Verbrauch elektrischer Energie*

Neben dem Wandel in der elektrischen Energieversorgung selbst macht die Energiewende auch nicht vor der Wärmeerzeugung und dem Verkehr halt (auch oft als *Wärmewende* und *Verkehrswende* bezeichnet), die einen erheblichen Anteil am Endenergieverbrauch in Deutschland haben. Die bereits begonnenen und anstehenden Umwälzungen in diesen Bereichen haben allerdings auch direkte Auswirkungen auf das elektrische Energieversorgungssystem bzw. den Verbrauch an elektrischer Energie.

So wird zum einen die *Wärmeerzeugung* zunehmend elektrifiziert, z. B. durch leistungsstarke Power-to-Heat-Anlagen wie große Tauchsieder – die beispielsweise dann eingesetzt werden, wenn zu viel Strom im Stromnetz vorhanden ist –, oder durch den Einsatz von Wärmepumpen. Wärmepumpen gelten als effiziente Alternative zu Heizsystemen basierend auf fossilen Energieträgern; deren Bestand und installierte Leistung hat sich in den letzten Jahren stetig vergrößert [29]. Andererseits werden Strom- und Wärmeerzeugung auch verstärkt miteinander kombiniert, wie z. B. bei der durch die von der Politik geförderten *Kraft-Wärme-Kopplung* (KWK). Beides führt dazu, dass der Stromverbrauch ansteigt und zusätzliche Lastspitzen entstehen.

Dem Bereich Verkehr stehen ebenfalls grundlegende Veränderungen bevor. Mit dem Ziel eines klimafreundlichen Verkehrs werden momentan in verschiedenen Richtungen Anstrengungen unternommen; ein vielversprechender Ansatz zur Erreichung dieses Ziels ist die *Elektromobilität*, d. h. die Elektrifizierung des Verkehrs durch Brennstoffzellentechnik oder batteriebetriebene Fahrzeuge. Elektrofahrzeuge haben den Vorteil gegenüber verbrennungsmotorbetriebenen Fahrzeugen, dass sie lokal emissionsfrei sind. Batteriebetriebene Fahrzeuge, deren Emissionen primär bei der Erzeugung von Strom entsteht, sind zudem selbst bei dem derzeitigen Strommix in Deutschland und unter Betrachtung von Faktoren wie Fahrzeugproduktion, Wartung und Entsorgung umweltfreundlicher als Fahrzeuge mit Verbrennungsmotoren [27]. Offensichtlich vergrößert sich dieser Vorteil

<sup>8</sup> Bei KWK-Anlagen wird die bei der Erzeugung von Strom entstehende Abwärme zusätzlich verwendet.

## 2. Elektrische Energieversorgungssysteme

weiter bei einem höheren Anteil an „sauberen“ Strom aus erneuerbaren Energien. Die Bundesregierung hat daher für das Jahr 2020 ein Ziel von 1 Mio. Elektrofahrzeugen in Deutschland ausgegeben<sup>9</sup>, für das Jahr 2030 ein Ziel von 6 Mio. Elektrofahrzeugen [28]. Um diese Ziele zu erreichen, wurde 2015 nach Vorbild des EEG das sog. *Gesetz zur Bevorrechtigung der Verwendung elektrisch betriebener Fahrzeuge*<sup>10</sup> erlassen, kurz *Elektromobilitätsgesetz* (EmoG), und zudem einen sogenannten Umweltbonus auf den Kauf von elektrischen Fahrzeugen beschlossen. Die Elektromobilität sorgt allerdings auch für zusätzliche Herausforderungen für das elektrische Energieversorgungssystem in Form eines deutlich höheren Verbrauchs. Bei einem derzeit knapp über 2900 kWh liegenden durchschnittlichen Jahresverbrauch an elektrischer Energie pro Haushalt im Jahr 2015 [19] – also ca. 8 kWh pro Tag – würde das tägliche Laden eines batteriebetriebenen Elektroautos, dessen Batteriekapazität heutzutage bereits bei den meisten Fahrzeugen über 20 kWh liegt, eine Vervielfachung des Verbrauchs bedeuten. Insbesondere wenn die arbeitende Bevölkerung abends nach Hause kommt und die batteriebetriebenen Elektrofahrzeuge aufgeladen werden müssen, wird dies zu extremeren Lastspitzen führen (s. Abbildung 2.4) und die Stromnetze sehr belasten – besonders in Niederspannungsnetzen, wo sich die meisten Haushalte befinden. Andererseits bergen batteriebetriebene Elektrofahrzeuge auch ein nicht zu unterschätzendes Speicherpotential und könnten in bestimmten Situationen Strom in das Stromnetz einspeisen (auch bekannt unter dem Begriff *Vehicle to Grid* (v2G)) und somit die fluktuierende Einspeisung dargebotsabhängiger Erzeuger abfedern. Denn laut der Mobilitätsstudie „Kraftfahrzeugverkehr in Deutschland 2010“ [121] nehmen Kraftfahrzeuge im Mittel an Werktagen fast 97 % der Zeit nicht am Straßenverkehr teil; an Wochenenden oder Feiertagen sogar etwas mehr als 98 %. Batteriebetriebene Elektrofahrzeuge könnten somit einen großen Teil der Zeit am Netz angeschlossen sein und bei Bedarf Leistung aufnehmen oder abgeben – eine entsprechende Ladeinfrastruktur z. B. an Arbeitsstätten vorausgesetzt.

Zudem verbreiten sich zunehmend dezentrale Speicher, die in Haushalten vorzugsweise zur Unterstützung der Photovoltaikanlagen eingesetzt werden und so den Eigenbedarf und die Autarkie des Besitzers erhöhen. Auch diese können damit einen wesentlichen Teil zum stabilen Betrieb des Stromnetzes

<sup>9</sup> Die Zahl der insgesamt in Deutschland im Jahr 2010 zugelassenen Kraftfahrzeuge betrug ca. 50,2 Mio., davon in etwa 41,7 Mio. Pkw [121].

<sup>10</sup> <https://www.gesetze-im-internet.de/emog/> (besucht am 23.03.2017)

### 2.3. Flexibilisierung des Verbrauchs für eine erfolgreiche Energiewende

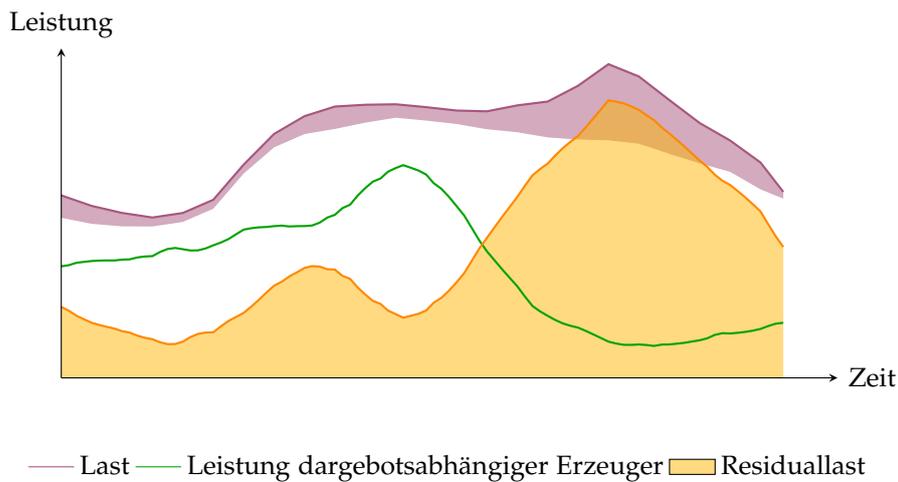


Abbildung 2.4.: Exemplarischer Verlauf der Last (violette Kurve) durch die zusätzliche von Elektrofahrzeugen verursachte Nachfrage (violette Fläche). Wird die Nachfrage von Elektrofahrzeugen nicht flexibilisiert, sorgt das gleichzeitige Laden vor allem am Abend für noch größere Lastspitzen und kann somit zudem zu noch stärkeren Steigungen in der Residuallast (orangefarbene Fläche) führen, wenn die dargebotsabhängige Leistung (grüne Kurve) nicht gleichzeitig ebenfalls ansteigt.

beitragen.

### 2.3. FLEXIBILISIERUNG DES VERBRAUCHS ALS MASSNAHME FÜR EINE ERFOLGREICHE ENERGIEWENDE

Durch die zunehmende fluktuierende, volatile Einspeisung dargebotsabhängiger Erzeuger sowie den Veränderungen im Verbrauch durch neue Verbrauchertypen, die für zunehmende Lastspitzen sorgen, wird die zu deckende Residuallast immer fluktuierender mit immer größer werdenden Schwankungen. Das hat zum einen zur Folge, dass die Deckung der Residuallast immer teurer wird und zum anderen, dass es immer schwieriger wird, das Gleichgewicht zwischen erzeugter und nachgefragter Leistung zu halten. Studien (s. z. B. [43]) kommen außerdem zu dem Schluss, dass sich der Trend der fluktuierenden Residuallast mit der weiteren Verbreitung von dargebotsabhängigen Erzeugern weiter fortsetzen wird und erwarten, dass sich die Residuallast zukünftig sogar zeitweise ins Negative bewegen kann, d. h. der Verbrauch würde schon alleine durch die dargebotsabhängige Er-

## 2. Elektrische Energieversorgungssysteme

zeugung gedeckt bzw. sogar übertroffen werden und steuerbare Kraftwerke würden zu diesen Zeitpunkten gar nicht erst benötigt werden.

Um die Energiewende dennoch erfolgreich zu meistern, werden in der Politik und der Forschung derzeit verschiedene Maßnahmen vorgeschlagen und diskutiert (siehe z. B. [31, 17]), darunter u. a. der Ausbau der Netze und der Bau von großen Stromtrassen, die Entwicklung von Speichertechnologien, sowie die Kopplung des elektrischen Energieversorgungssystems mit dem Gas- oder Wärmenetz (sog. *Power-to-Gas* und *Power-to-Heat*), die ein großes Speicherpotential bieten und z. B. bei einem Überangebot an elektrischer Leistung diese in Gas oder Wärme umwandeln können. Ein weiterer wichtiger und häufig genannter Baustein in der Meisterung der Energiewende ist die sog. *Flexibilisierung des Verbrauchs* [31, 17], also die Anpassung des Verbrauchs an die zur Verfügung stehende elektrische Leistung. Erfolgt heutzutage der Betrieb des elektrischen Energieversorgungssystems weitestgehend nachfrage-getrieben, sollen in Zukunft elektrische Verbraucher verstärkt ihre Nachfrage an das verfügbare Angebot an elektrischer Leistung anpassen. Dadurch kann das System robuster und effizienter betrieben werden, aber auch einiges an Kosten und Investitionen gespart werden, weil weniger teure Regelernergie zur Verfügung gestellt werden muss oder weniger in den Ausbau von Spitzenlastkraftwerken investiert werden muss. Die Deutsche Energie-Agentur GmbH (dena) geht in ihrer Studie z. B. für das Jahr 2020 davon aus, dass Anpassungen des Verbrauchs zu einer Deckung positiver bzw. negativer Regelleistung<sup>11</sup> von ca. 60 % bzw. 2 % führen, der Bedarf an Spitzenlast um ca. 800 MW reduziert wird und dadurch die volkswirtschaftlichen Kosten der Stromerzeugung in dem Zeitraum bis 2020 sich um 481 Mio. € reduzieren [37].

Obwohl der bisherige Betrieb des elektrischen Energieversorgungssystems weitestgehend nachfrage-getrieben verläuft, gibt es dennoch schon seit einigen Jahrzehnten Ansätze, die den Verbrauch an die Erzeugung anpassen (siehe z. B. [99]). Früher war dabei das Ziel, Lastspitzen zu reduzieren und die Grundlast über Nacht durch einen höheren Verbrauch z. B. mit Nachtspeicheröfen zu erhöhen, damit die steuerbaren Kraftwerke effizienter betrieben werden konnten und weniger oft teure Spitzenlastkraftwerke eingesetzt werden mussten. Ermöglicht durch die *Verordnung zu abschaltbaren*

<sup>11</sup> Positive Regelleistung wird erbracht, wenn die Nachfrage das Angebot erzeugter Leistung übertrifft; negative Regelleistung im umgekehrten Fall.

### 2.3. Flexibilisierung des Verbrauchs für eine erfolgreiche Energiewende

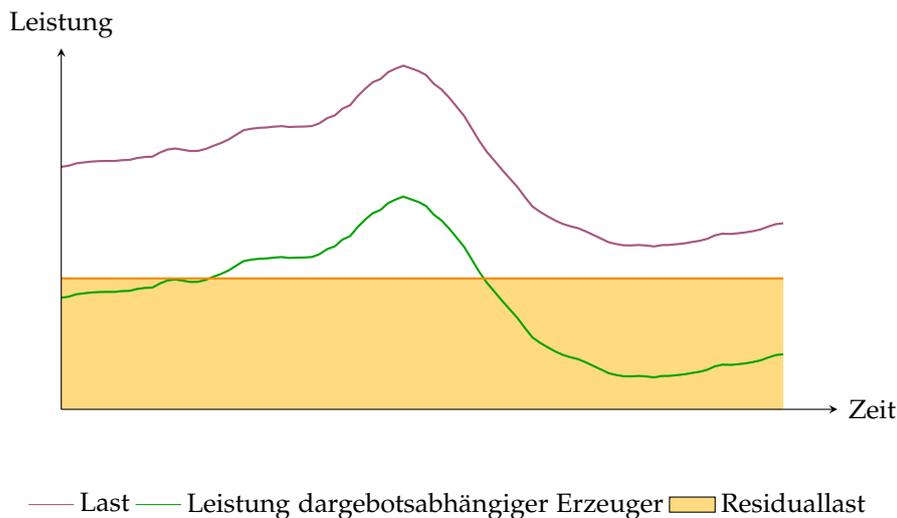


Abbildung 2.5.: Ziel der Flexibilisierung des Verbrauchs ist die Anpassung des Verbrauchs (violette Kurve) an die Charakteristik der dargebotsabhängigen Leistung (grüne Kurve), damit die Residuallast (orangefarbene Fläche) möglichst geglättet wird und die steuerbaren Kraftwerke diese leichter, effizienter und günstiger decken können. Im Idealfall kann die Nachfrage der dargebotsabhängigen Leistung so angepasst werden, dass wie hier in diesem Beispiel daraus eine vollständig geglättete Residuallast resultiert.

Lasten<sup>12</sup> gibt es heute in Deutschland für die Übertragungsnetzbetreiber die Möglichkeit, teilnehmende Großverbraucher gegen Vergütung für kurze Zeit abzuschalten oder deren Nachfrage zu reduzieren, um die Versorgungssicherheit zu erhöhen. In der heutigen und insbesondere der zukünftigen Situation mit dem hohen Angebot an fluktuierender dargebotsabhängiger Leistung muss sich die Last aber zunehmend an der Einspeisung dargebotsabhängiger Erzeuger orientieren, d. h. der Verbrauch findet idealerweise vornehmlich dann statt, wenn ein hohes Angebot an dargebotsabhängiger Leistung vorhanden ist. Wird der Verbrauch dementsprechend angepasst und verschoben hat das zur Folge, dass die Residuallast im Idealfall geglättet wird (s. Abbildung 2.5), wodurch wiederum die steuerbaren Kraftwerke effizient betrieben werden können und seltener auf teure Spitzenlastkraftwerke zurückgegriffen werden muss. Ziel der Flexibilisierung des Verbrauchs ist also die *Glättung der Residuallast*.

Doch nicht jeder Verbraucher ist für eine Anpassung des Bedarfs geeignet.

<sup>12</sup> [https://www.gesetze-im-internet.de/ablav\\_2016/](https://www.gesetze-im-internet.de/ablav_2016/) (besucht am 23.03.2017)

## 2. Elektrische Energieversorgungssysteme

Brooks et al. schätzen, dass ca. 33 % aller Lasten sich ohne signifikanten Komfortverlust für den Benutzer zumindest teilweise verschieben lassen können [25]. Dass es auch in Deutschland genug theoretisches Potenzial zur Verschiebung von Last gibt, hat z. B. Klobasa aufgezeigt [59]. So schätzt er das insgesamt verfügbare Potenzial in den drei Sektoren Industrie, Gewerbe-Handel-Dienstleistungen und Haushalte auf ca. 9–26 GW ein, abhängig von saisonalen Schwankungen wie der Temperatur. Außerdem erwartet Klobasa, dass dieses Potenzial in Zukunft weiter ansteigt. Verglichen mit der insgesamt in Deutschland auftretenden Last, deren Minimum im Jahr 2015 in einer Nacht an Weihnachten etwa 36 GW betrug und deren Maximum im Jahr 2015 an einem kalten Werktag ca. 83 GW betrug [1], ist das Potenzial zur Verschiebung von Last also in ausreichender Höhe vorhanden. Berücksichtigt man zusätzlich noch die in Zukunft zahlreich vorhandenen batteriebetriebenen Fahrzeuge, so erhöht sich dieses Potenzial noch weiter und eröffnet zudem darüber hinaus die Möglichkeit, Leistung wenn nötig in das System abzugeben und später wieder aufzunehmen (v2G). Die *Nationale Plattform Elektromobilität* (NPE) geht beispielsweise in einer vorsichtigen Schätzung für die anvisierten 6 Mio. Elektrofahrzeuge im Jahr 2030 von einem verfügbaren Speichervolumen von ca. 15 GWh und einer Leistungsaufnahme von 9 GW aus, was sich bereits auf vergleichbarem Niveau mit dem Speichervolumen und der installierten Leistung von Pumpspeicherkraftwerken bewegt (40 GWh bzw. 7 GW) [77].

Für die Beeinflussung des elektrischen Verbrauchs existieren verschiedene Konzepte und Begriffe, die allerdings teilweise auch nicht einheitlich oder synonym verwendet werden. In den häufigsten Fällen wird in der Literatur – z. B. in der Studie von acatech [17] und auch im Folgenden in dieser Arbeit – unter dem Begriff *Demand Response* die Beeinflussung des Verbrauchs durch Preissignale verstanden, wohingegen die Begriffe *Lastmanagement* bzw. *Demand Side Management* etwas allgemeiner sind und zusätzlich Techniken der direkten Beeinflussung des Verbrauchs durch Steuerungssignale beschreiben. Techniken zur koordinierten Beeinflussung des Verbrauchs und der Erzeugung für das Sicherstellen des Gleichgewichts zwischen erzeugter und nachgefragter Leistung bezeichnet man häufig als *Supply-Demand-Matching* oder *Supply Demand Management* (s. z. B. [61]). Einen umfassenden Überblick über Demand Response bietet beispielsweise Siano [103].

## 2.4. TRANSFORMATION HEUTIGER ELEKTRISCHER ENERGIEVERSORGUNGSSYSTEME ZU SMART GRIDS

Ein mit der Energiewende verbundener, parallel laufender Prozess und eine wichtige Voraussetzung für das Gelingen der Energiewende ist die Entwicklung des heutigen elektrischen Energieversorgungssystems hin zu einem intelligenten, mit IKT durchdrungenen elektrischen Energieversorgungssystem – einem sog. *Smart Grid*. Das United States Department of Energy beschreibt ein solches System beispielsweise als vollständig automatisiert, mit der Möglichkeit der Überwachung und Steuerung der Infrastruktur und Teilnehmer sowie des Informationsaustauschs zwischen diesen [113]. Die Transformation zu einem Smart Grid ermöglicht somit, dass alle Teilnehmer vernetzt sind und miteinander kommunizieren können. Ein Smart Grid ist deshalb eine wichtige Voraussetzung für die Koordination aller Teilnehmer und die Flexibilisierung des Verbrauchs.

Den langen Weg der Transformation des heutigen elektrischen Energieversorgungssystems hin zu einem Smart Grid und die bis dahin zu meisternden Herausforderungen beschreibt u. a. die Studie von acatech aus dem Jahre 2012 [17]. Einen weiteren Überblick über die Herausforderungen bei der Transformation zu Smart Grids, mehr aus der Sicht der Künstlichen Intelligenz und der Multiagentensysteme, liefern Ramchurn et al. [88]. Die Umsetzung eines Smart Grids ist ein großes, interdisziplinäres Forschungsfeld, bei dem neben den technischen Herausforderungen viele weitere verschiedene Aspekte eine wesentliche Rolle für das Gelingen spielen, z. B. das Schaffen von Anreizen und Regularien, die Berücksichtigung von Sicherheitsaspekten wie Datenschutz, das Sorgen für Akzeptanz bei den Endkunden, etc. Diese sind für die Transformation zu einem Smart Grid, das Gelingen der Energiewende aber auch für den in dieser Arbeit vorgestellten Ansatz zwingend notwendig, jedoch nicht im Fokus dieser Arbeit und werden im Folgenden nicht weiter betrachtet.

## 2.5. ENTSTEHENDE HERAUSFORDERUNGEN BEIM AUTONOMEN BETRIEB ZUKÜNFTIGER ELEKTRISCHER ENERGIEVERSORGUNGSSYSTEME

Wie in den vorherigen Abschnitten aufgezeigt, stellt die Energiewende das elektrische Energieversorgungssystem vor eine große Herausforderung. Ei-

## 2. Elektrische Energieversorgungssysteme

ne notwendige Maßnahme zur erfolgreichen Bewältigung der Energiewende und eines stabilen, zuverlässigen Betriebs des elektrischen Energieversorgungssystems ist der Einbezug in die Einsatzplanung und daraus folgend die Koordination aller potentiell steuerbaren Erzeuger und Verbraucher. Allerdings wird die große Anzahl an verschiedenen Teilnehmern erfordern, dass der Betrieb des elektrischen Energieversorgungssystems *autonom* erfolgt (siehe z. B. [88]). Damit einher gehen allerdings zwei zentrale Herausforderungen:

*Skalierbarkeit:* Die Einsatzplanung skaliert nicht mit der Anzahl der Teilnehmer, da es sich hierbei um ein komplexes, gemischt ganzzahliges Optimierungsproblem handelt, das NP-schwer ist.

*Unsicherheit:* Die Deckung der Residuallast ist mit Unsicherheiten verbunden, da sie in hohem Maße von der prognostizierten Leistung von Systemteilnehmern abhängt, deren Prognosen z. B. auf Wetterbedingungen oder dem Benutzerverhalten von elektrischen Verbrauchern basieren.

Anders hat in seiner Dissertation [5] bereits allgemeine Techniken und Algorithmen zur Bewältigung dieser Herausforderungen in offenen, technischen Systemen behandelt und diese insbesondere auf Erzeuger in einem elektrischen Energieversorgungssystem angewandt. In der vorliegenden Arbeit sollen diese Techniken und Algorithmen nun Anwendung auf Seiten der elektrischen Verbraucher finden und in den existierenden Ansatz auf Seiten der Erzeuger integriert werden.

## II.

# SELBST-ORGANISIERTES, TRUST-BEWUSSTES DEMAND SIDE MANAGEMENT

In diesem Teil der Arbeit wird betrachtet, wie *Autonome Verbraucherorganisationen* ein autonomes Demand Side Management unter Unsicherheiten in Smart Grids durch den Einsatz von Selbst-Organisation und dem sozialen Konzept der Vertrauenswürdigkeit ermöglichen.



## SELBST-ORGANISATION UND TRUST IN AUTONOMEN VERBRAUCHERORGANISATIONEN

---

# 3

**ZUSAMMENFASSUNG** In diesem Kapitel werden *Autonome Verbraucherorganisationen* als ein Ansatz zur autonomen Steuerung elektrischer Verbraucher in zukünftigen elektrischen Energieversorgungssystemen vorgestellt. Autonome Verbraucherorganisationen sind selbst-organisierend und nutzen außerdem das soziale Konzept der Vertrauenswürdigkeit, um einen skalierbaren Betrieb unter Berücksichtigung von Unsicherheiten zu ermöglichen.

**N**ACHDEM im vorhergehendem Kapitel aufgezeigt wurde, dass zukünftige elektrische Energieversorgungssysteme von ganz anderer Natur sind als es heutige sind und diese vor den zwei zentralen Herausforderungen der Skalierbarkeit und der Unsicherheit stehen, soll dieses Kapitel einen Überblick über den in dieser Arbeit verfolgten Ansatz zur Bewältigung dieser Herausforderungen geben. Abschnitt 3.1 stellt dazu vor, wie mittels *Selbst-Organisation* der autonome Betrieb elektrischer Energieversorgungssysteme skalierbar wird. Daraufhin beschreibt Abschnitt 3.2 den Umgang mit Unsicherheiten unter Einsatz des sozialen Konzepts der *Vertrauenswürdigkeit* [9]. In Abschnitt 3.3 werden die in dieser Arbeit betrachteten steuerbaren Verbraucher und ihre Steuerungsmodelle eingeführt. Abschnitt 3.4 präsentiert abschließend den Ansatz der *Autonomen Verbraucherorganisationen*, die diese zwei Techniken zur autonomen Koordination elektrischer Verbraucher einsetzen.

Im Folgenden bezeichnet das Wort *Verbraucher* die physikalische Einheit mit der Nachfrage an elektrischer Leistung, wohingegen der menschliche Endkunde, der den Verbraucher verwendet, als *Nutzer* oder *Benutzer* bezeichnet wird.

### 3. Selbst-Organisation und Trust in Autonomen Verbraucherorganisationen

#### 3.1. SELBST-ORGANISATION FÜR DEN SKALIERBAREN BETRIEB ELEKTRISCHER ENERGIEVERSORGUNGSSYSTEME

Aufgrund der vorliegenden Komplexität der Einsatzplanung ist eine zentrale Lösung dieses Optimierungsproblems für eine große Anzahl an Teilnehmern nicht in ausreichender Geschwindigkeit durchführbar, ohne dass die Lösungsqualität im starken Maße darunter leidet. Eine Möglichkeit dieser Komplexität Herr zu werden und Skalierbarkeit zu erreichen ist daher *Problemdekomposition*, d. h. das Zerlegen des gesamten Problems in kleinere Subprobleme. Diese Subprobleme sind jeweils für sich leichter und daher schneller zu bewältigen<sup>13</sup> und lösen in der Summe das gesamte Problem, allerdings möglicherweise auf Kosten einer global optimalen Lösung. Problemdekomposition wird in autonomen Systemen oft durch Ausbildung von *Organisationsstrukturen* umgesetzt, die z. B. durch Overlay-Netze repräsentiert werden (siehe z. B. [14]). Entsprechende Organisationsstrukturen können beispielsweise *Koalitionen* (siehe z. B. [101]), *Teams* (siehe z. B. [50]) oder *Hierarchien* (siehe z. B. [14]) sein; einen umfassenden Überblick über verschiedene Organisationsformen geben Horling und Lesser [50]. Die konkrete Wahl der Organisationsstruktur hängt dabei stark von der Situation ab, in der sie eingesetzt werden sollen. In vielen Fällen sollen Organisationsstrukturen nicht vorgegeben oder statisch sein, sondern sich selbst zur Laufzeit ausbilden und ggf. wieder auflösen oder sich an geänderte Bedingungen anpassen. Gemäß Di Marzo Serugendo et al. [38] ist ein solches System, das während der Laufzeit seine Organisation ohne explizite Befehle von außen anpassen kann, ein *selbst-organisierendes System*.

Einen umfangreichen Ansatz zur selbst-organisierten Problemdekomposition mit Anwendung in autonomen, elektrischen Energieversorgungssystemen wird von Anders et al. [14] und Anders in seiner Dissertation [5] vorgestellt. Dort werden Erzeuger selbst-organisiert in sog. *Autonome Virtuelle Kraftwerke (AVKW)* [108] gruppiert und innerhalb dieser autonom eine Einsatzplanung durchgeführt. Dieses Prinzip wird auch in dieser Arbeit verfolgt: Für die skalierbare, autonome Steuerung von elektrischen Verbrauchern sollen sich diese selbst-organisiert in sog. *Autonome Verbraucherorganisationen (AVO)* gruppieren (siehe Abschnitt 3.4).

Ein selbst-organisierendes System wird üblicherweise als *Multiagentensys-*

<sup>13</sup> Zudem können die Subprobleme – entsprechende Hardware-Kapazitäten vorausgesetzt – parallel gelöst werden.

### 3.2. Trust für den robusten Betrieb elektrischer Energieversorgungssysteme

tem (MAS) umgesetzt, in dem jeder Teilnehmer ein autonomer, intelligenter Software-Agent [120] ist, der sowohl reaktiv handeln als auch proaktiv seine Ziele verfolgen und mit anderen Agenten in Verbindung treten kann. Auch in dieser Arbeit wird davon ausgegangen, dass jeder physikalische Systemteilnehmer durch einen entsprechenden Agenten repräsentiert ist, der Wissen über und Zugriff auf die repräsentierte physikalische Einheit hat und mit der Außenwelt kommunizieren kann.

### 3.2. TRUST FÜR DEN ROBUSTEN BETRIEB ELEKTRISCHER ENERGIEVERSORGUNGSSYSTEME

Unsicherheiten in elektrischen Energieversorgungssystemen haben vielerlei Ursachen. So basiert die Einsatzplanung auf Last- und Leistungsprognosen, die mit Fehlern behaftet sind. Lastprognosen basieren bei Verbrauchern mit einem Energiebedarf von weniger als 100.000 kWh pro Jahr beispielsweise auf Standardlastprofilen<sup>14</sup>, die zwar eine gute Abschätzung der Nachfrage ermöglichen, aber naturgemäß die tatsächliche Nachfrage nicht fehlerfrei vorhersagen können. Die Prognosen dargebotsabhängiger Erzeuger hängen von der Umwelt in Form von Wettervorhersagen ab. Obwohl erwartet wird, dass diese zukünftig bis zu 45 % besser werden [37], werden sie dennoch auch in der Zukunft fehlerhaft und unsicher sein. Bei steuerbaren Verbrauchern, aber auch auf Seiten einiger potentiell steuerbarer Erzeuger, stehen außerdem eigene Interessen im Vordergrund, die nicht zwingend dem Systemziel entsprechen oder womit elektrische Energieversorgungsunternehmen gerechnet haben. Zudem können Kraftwerke und Verbraucher unerwartet ausfallen bzw. vom Netz gehen. Für den robusten, d. h. den zuverlässigen, stabilen Betrieb des elektrischen Energieversorgungssystems, ist es essentiell, dass solche Unsicherheiten antizipiert werden und mit ihnen in einem geeigneten Maße umgegangen wird.

Ein von Anders et al. verfolgter Ansatz, um mit Unsicherheiten in selbstorganisierenden Systemen umzugehen und die Robustheit und Effizienz solcher Systeme zu erhöhen, ist die Verwendung des sozialen Konzepts der Vertrauenswürdigkeit zur Quantifizierung von Unsicherheiten [9] – nachfolgend mit *Trust* bezeichnet. Dieses Konzept wurde bereits erfolgreich von

<sup>14</sup> Ein Standardlastprofil gibt die durchschnittlich erwartete Last eines Tages für eine Abnahmestelle in 15-Minuten-Schritten an. Es existieren Standardlastprofile für verschiedene Typen von Abnahmestellen, z. B. einen Haushalt, verschiedene Gewerbearten und Landwirtschaftsbetriebe.

### 3. Selbst-Organisation und Trust in Autonomen Verbraucherorganisationen

Anders et al. [14] und Anders in seiner Dissertation [5] in der Anwendung der Autonomen Virtuellen Kraftwerke zum robusten Betrieb autonomer, elektrischer Energieversorgungssysteme eingesetzt; ein Ziel dieser Arbeit besteht darin, diese Technik auf Autonome Verbraucherorganisationen (siehe Abschnitt 3.4) zu übertragen.

#### TRUST ZUR QUANTIFIZIERUNG VON UNSICHERHEITEN IN SELBST-ORGANISIERENDEN SYSTEMEN

Im Folgenden werden die wichtigsten und die für diese Arbeit relevanten Eigenschaften von Trust in selbst-organisierenden Systemen aus [9] zusammengefasst; für mehr Details ist der Blick in die entsprechende Publikation [9] empfohlen, aber auch z. B. Steghöfer et al. [110] oder Ramchurn et al. [85] geben ausführliche Einblicke über die Eigenschaften und die Verwendung von Trust in selbst-organisierenden Systemen bzw. Multiagentensystemen (MAS).

In MAS liegt der Fokus von *Trust* oft auf der Glaubwürdigkeit eines Agenten und bezeichnet den Grad, zu welchem ein Agent seine Verpflichtungen und an ihn gestellte Erwartungen erfüllt; Trust kann in technischen Systemen jedoch auch viele andere Facetten haben [110], wie beispielsweise die funktionale Korrektheit eines Systems. Das Vertrauen in Andere entwickelt sich über die Zeit mittels in *Interaktionen* gemachten *Erfahrungen* [110]. Trust spielt insbesondere bei der Auswahl von Interaktionspartnern eine Rolle; so ist die Auswahl eines vertrauenswürdigen Interaktionspartners von Vorteil, um den Nutzen einzelner Interaktionen zu maximieren und Unsicherheiten zu minimieren [85]. Allgemein lässt sich Trust in Entscheidungsprozessen nutzen, um die Glaubwürdigkeit unsicherer Informationsquellen zu quantifizieren und daraus ein erwartetes Verhalten abzuleiten [6].

Vertrauen ist eine *subjektive* Eigenschaft. Da jeder Beteiligte seine eigenen Erfahrungen mit einem Interaktionspartner sammelt, spiegelt das Vertrauen auch diese eigenen Erfahrungen wider; Andere wiederum können ganz andere Erfahrungen mit dem selben Interaktionspartner gesammelt haben und dementsprechend eine ganz andere Meinung über selbigen haben oder andere Maßstäbe an die Interaktionen anlegen. Demzufolge ist Vertrauen im Allgemeinen auch *nicht transitiv*. Eine weitere wichtige Eigenschaft von Vertrauen ist die Abhängigkeit vom *Kontext* der Interaktion: Vertraut man beispielsweise dem Arzt bei einer Behandlung einer Krankheit, ist das Vertrauen in diesen Arzt jedoch in einem anderen Kontext wie z. B. der

### 3.2. Trust für den robusten Betrieb elektrischer Energieversorgungssysteme

Reparatur eines Autos möglicherweise nicht vorhanden.

Grundlage, um in technischen Systemen das Vertrauen in jemand Anderen auf Basis von vergangenen Interaktionen abzuschätzen, ist eine *Trust-Metrik*, welche das Vertrauen in jemand Anderen oft durch einen numerischen *Trust-Wert* ausdrückt (siehe z. B. [72]), meistens normalisiert auf Werte zwischen 0 und 1 oder -1 und 1. Ein Trust-Wert am oberen Ende des Intervalls bedeutet dabei, dass der Agent sich bisher besonders vertrauenswürdig und positiv verhielt und dies auch für sein zukünftiges Verhalten erwartet wird, wohingegen ein Trust-Wert am unteren Ende des Intervalls das Gegenteil bedeutet. Über das Verhalten von Agenten mit einem Trust-Wert in der Mitte des Intervalls lässt sich meistens jedoch keine Schlüsse ziehen. Statt einem einfachen Trust-Wert können allerdings auch komplexere Konstrukte zum Einsatz kommen, wie z. B. *Trust-basierte Szenarien* (TBS) [16]. Diese erlauben es, Verhalten über einen zeitlichen Verlauf zu berücksichtigen und somit Abhängigkeiten zwischen aufeinanderfolgenden Verhalten abzubilden. Eine ausführlichere Beschreibung von TBS erfolgt später in Kapitel 5.

Der sog. *Lebenszyklus* von Trust-Werten (siehe Abbildung 3.1) beschreibt eine allgemeine Sichtweise auf das Entstehen und Nutzen selbiger. Zwei oder mehrere *Interaktionspartner* einigen sich auf einen *Kontrakt* [86].<sup>15</sup> Der Kontrakt hält sowohl die *Interaktion*, welche möglicherweise aus mehreren verschiedenen Schritten besteht, als auch das *vereinbarte Ergebnis* der Interaktion fest. Ist die Interaktion abgeschlossen, vergleichen die Beteiligten das *tatsächliche Ergebnis* der Interaktion mit dem vereinbarten Ergebnis und speichern dies in einer *Erfahrung* ab [53]. Auf Basis dieser Erfahrung – und möglicherweise bereits gesammelten Erfahrungen aus vergangenen Interaktionen mit dem Interaktionspartner – lässt sich mittels einer Trust-Metrik ein *Trust-Wert* ableiten. Der Trust-Wert entwickelt sich somit über die Zeit via in Interaktionen gesammelten Erfahrungen und kann selbst wiederum für die Auswahl von Interaktionspartnern herangezogen werden.

Zur Einschätzung, ob der Trust-Wert das tatsächlich beobachtbare Verhalten eines Agenten widerspiegelt, können beispielsweise Ansätze wie die *Confidence* [57] herangezogen werden. Dabei spielen z. B. Faktoren wie die Anzahl der Erfahrungen, das Alter der Erfahrungen und Unterschiede in den Erfahrungen eine Rolle. Wurden z. B. jüngst einige Erfahrungen mit einem Agenten gesammelt, die alle positiv waren, so ist das aufgrund der

<sup>15</sup> Der Kontrakt kann auch potentiell implizit sein.

### 3. Selbst-Organisation und Trust in Autonomen Verbraucherorganisationen

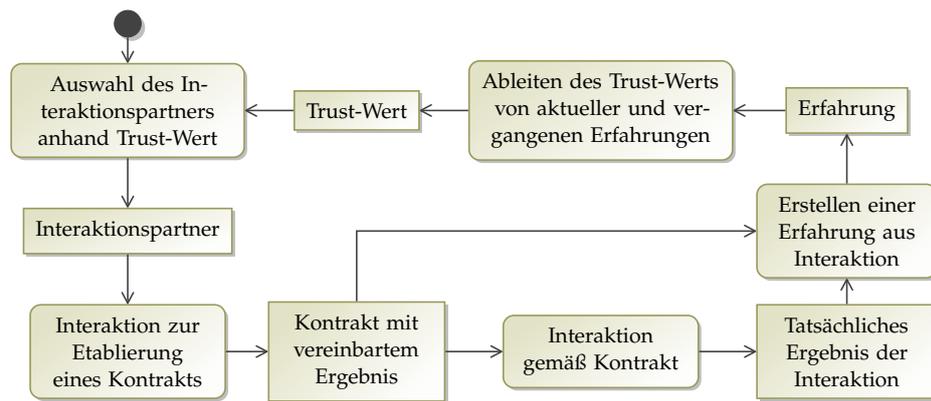


Abbildung 3.1.: Der Lebenszyklus von Trust-Werten, die sich aus in Interaktionen gesammelten Erfahrungen entwickeln, dargestellt als UML-Aktivitätsdiagramm (nach [9]).

Anzahl, des Alters und der Gleichheit der Erfahrungen ein Indikator dafür, dass der Trust-Wert das tatsächliche Verhalten des Agenten widerspiegelt und ein ähnliches Verhalten für zukünftige Interaktionen erwartet werden kann.

Zu Agenten, mit denen noch nicht persönlich interagiert wurde, kann noch kein Trust-Wert basierend auf eigenen Erfahrungen bestehen. Für den Umgang mit unbekanntem Agenten gibt es die Möglichkeit, einen sog. *Initial Trust* zu verwenden; oft ist jedoch nicht ganz klar, wie genau dieser gewählt werden soll [73]. Eine andere Möglichkeit ist die Verwendung eines *Reputationsystems*, das die Erfahrungen von Agenten kombiniert und Empfehlungen generiert (siehe z. B. [75]). Agenten, mit denen noch nicht oder selten interagiert wurde, können so aufgrund ihrer Reputation besser eingeschätzt werden. Zur Entscheidung, welche Information – Trust-Wert, Reputationswert oder eine Kombination aus beiden – für eine mögliche Interaktion herangezogen werden soll, stützen sich Ansätze aus der Literatur [58, 93] beispielsweise auf die Confidence oder ähnliche Metriken.

Im Beispiel der elektrischen Energieversorgungssysteme setzt sich die Vertrauenswürdigkeit aus den bisherigen Vorhersagefehlern zusammen. Die Interaktionen entsprechen den vorhergesagten Leistungen, woraufhin nach Eintritt der tatsächlichen Leistung eine Erfahrung mit dem aufgetretenen Vorhersagefehler gesammelt wird. Erzeuger oder Verbraucher, deren Vorhersagen stets korrekt sind und die keine Vorhersagefehler aufweisen,

### 3.3. Betrachtete steuerbare Verbrauchertypen und Steuerungsmodelle

haben demnach einen maximalen Trust-Wert; Erzeuger oder Verbraucher mit fehlerhaften Vorhersagen entsprechend einen niedrigen Trust-Wert.

#### 3.3. BETRACHTETE STEUERBARE VERBRAUCHERTYPEN UND STEUERUNGSMODELLE

Aufgrund der resultierenden Einschränkungen und Komforteinbußen für den Nutzer lässt sich nicht jeder Verbraucher potentiell aus der Ferne ansteuern bzw. an- oder ausschalten. So sollten z. B. im Haushaltsbereich Computer, Fernseher, Beleuchtung oder Herd immer auf Wunsch des Nutzers im vollen Umfang verfügbar sein und nicht plötzlich abgeschaltet werden. Das Gleiche gilt natürlich auch beispielsweise bei einigen Produktionsanlagen oder Verbrauchern, welche die öffentliche Sicherheit betreffen. Dennoch gibt es einige Verbrauchertypen, deren potentielle Steuerung möglich ist, da diese weitgehend unbemerkt oder ohne große Einschränkung erfolgen kann. Ähnlich den Kategorisierungen anderer Arbeiten (s. z. B. [69, 89, 83]), werden in dieser Arbeit die folgenden vier Kategorien von steuerbaren Verbrauchern betrachtet:

*Thermische Verbraucher* Zu der Kategorie der thermischen Verbraucher gehören solche Verbraucher, die elektrische Leistung für das Erzeugen von Kälte oder Wärme einsetzen, um das zu kühlende oder erwärmende Medium in einem bestimmten Temperaturbereich zu halten. Da sich die Innentemperatur relativ träge der Außentemperatur annähert, wird die elektrische Leistung normalerweise in regelmäßigen Abständen für kurze Zeit zugeführt. Solange die Temperatur im gewünschten Bereich bleibt, ist der Zeitpunkt der Leistungsaufnahme flexibel wählbar, ohne dass der Nutzer davon etwas bemerkt. Typische Vertreter dieser Kategorie sind z. B. Kühlschränke, Kühlhäuser, Gefriertruhen, Klimaanlageanlagen oder auch Wärmepumpen.

*Programmgetriebene Verbraucher* Diese Verbraucher sind dann im Einsatz, wenn der Nutzer eine bestimmte Aufgabe erledigt haben möchte. Der programmgetriebene Verbraucher spult zur Erledigung der Aufgabe daraufhin ein gewisses Programm ab. Zu dieser Kategorie von Verbrauchern gehören beispielsweise Geschirrspülmaschinen, Waschmaschinen oder Wäschetrockner. Nutzer können bei programmgetriebenen Verbrauchern angeben, bis zu welchem Zeitpunkt die Aufgabe

### 3. *Selbst-Organisation und Trust in Autonomen Verbraucherorganisationen*

erledigt sein muss; z. B. startet der Nutzer die Waschmaschine morgens und gibt an, dass die Wäsche bis abends um 17:00 Uhr fertig sein soll. Der konkrete Startzeitpunkt ist somit flexibel wählbar, solange die Aufgabe bis zu dem angegebenen Endzeitpunkt erledigt ist.

*Abschaltbare Verbraucher* Abschaltbare Verbraucher lassen ihre Leistungsaufnahme für einen gewissen Zeitraum unterbrechen oder reduzieren, wie es beispielsweise durch die Verordnung zu abschaltbaren Lasten bereits umgesetzt wird. Zu dieser Kategorie gehören vor allem Industrieverbraucher, wie z. B. Zementmühlen. Die Zeitpunkte, wann der Verbraucher abgeschaltet wird, sind dabei flexibel wählbar.

*Speicher* Zu der Kategorie der Speicher gehören diejenigen Verbraucher, die elektrische Leistung aufnehmen, Energie speichern und elektrische Leistung wieder abgeben können. Die Speicherung der Energie kann dabei z. B. über Batterien erfolgen, die zunehmend in Gebäuden installiert werden; genauso sind allerdings auch andere Formen wie Gasspeicher denkbar, die die aufgenommene elektrische Leistung in Gas umwandeln und das Gas wieder zur Gewinnung von elektrischer Leistung einsetzen. Ein Spezialfall der Speicher sind batteriebetriebene Elektrofahrzeuge, die als ein mobiler Speicher aufgefasst werden können und auch bei Bedarf in einem gewissen Rahmen elektrische Leistung in das Stromnetz abgeben, solange die Mobilität des Nutzers nicht gefährdet wird. Theoretisch ebenfalls in diese Kategorie fallen jegliche Geräte, die einen Akku besitzen, wie beispielsweise Laptops oder Smartphones – in dieser Arbeit werden aber nur größere Speicher und Elektrofahrzeuge betrachtet.

Selbstredend sind Verbraucher dieser Kategorien nicht beliebig steuerbar; die Steuerungsmodelle und -befehle müssen die technischen Bedingungen aber auch die Vorgaben der Nutzer berücksichtigen. Im Folgenden werden die in dieser Arbeit verwendeten Steuerungsmodelle für diese vier Kategorien von steuerbaren Verbrauchern vorgestellt, die ähnlich zu den in der Literatur üblichen Modellierungen sind [69, 89, 83]. Die Steuerungsmodelle sind in der Realität natürlich deutlich komplexer und für diese Arbeit abstrahiert, aber ausreichend realitätsnah.

### 3.3. Betrachtete steuerbare Verbrauchertypen und Steuerungsmodelle

#### Allgemein

Im Allgemeinen bezeichnet  $\mathcal{T}$  die Menge der äquidistanten diskreten Zeitschritte und  $t \in \mathcal{T}$  einen diskreten Zeitschritt. Der zeitliche Unterschied zwischen zwei diskreten Zeitschritten aus  $\mathcal{T}$  wird mit  $\Delta t$  bezeichnet. Die nachgefragte Leistung eines elektrischen Verbrauchers zu einem Zeitpunkt  $t \in \mathcal{T}$  wird durch  $P(t)$  dargestellt. Positive Leistungswerte werden im Folgenden in dieser Arbeit als nachgefragte bzw. aus dem Stromnetz entnommene Leistung interpretiert, wohingegen negative Leistungswerte als erzeugte bzw. in das Stromnetz eingespeiste Leistung interpretiert werden.

#### Thermische Verbraucher

Thermische Verbraucher benötigen eine Leistung  $P_{\text{off}} \in \mathbb{R}_0^+$  im Ruhezustand und eine konstante Leistung  $P_{\text{on}} \in \mathbb{R}^+$  im Betriebszustand – d.h. wenn das Gerät kühlt bzw. wärmt – wobei  $P_{\text{off}} < P_{\text{on}}$ . Die aufgenommene Leistung entspricht zu jedem Zeitpunkt entweder  $P_{\text{off}}$  oder  $P_{\text{on}}$ , so dass  $\forall t \in \mathcal{T} : P(t) \in \{P_{\text{on}}, P_{\text{off}}\}$ . Die zugehörige Temperatur zum Zeitpunkt  $t$  ist  $T(t) \in \mathbb{R}$ . Der vom Nutzer gewünschte Temperaturbereich wird durch die Minimaltemperatur  $T_{\text{min}} \in \mathbb{R}$  und die Maximaltemperatur  $T_{\text{max}} \in \mathbb{R}$  definiert. Demzufolge gilt  $\forall t \in \mathcal{T} : T(t) \in [T_{\text{min}}, T_{\text{max}}]$ . Die Veränderung der Temperatur im Betriebszustand von einem zum nächsten Zeitschritt wird mit  $\Delta T_{\text{on}} \in \mathbb{R}$  bezeichnet, wobei  $\Delta T_{\text{on}}$  negativ ist, wenn der thermische Verbraucher ein kühlendes Gerät ist, und positiv ist, wenn der thermische Verbraucher ein wärmendes Gerät ist. Analog dazu bezeichnet  $\Delta T_{\text{off}} \in \mathbb{R}$  die Veränderung der Temperatur vom einen zum nächsten Zeitschritt, wenn der Verbraucher im Ruhezustand ist.  $\Delta T_{\text{off}}$  ist positiv bei einem kühlenden Verbraucher und negativ bei einem wärmenden Verbraucher. Die Temperatur im Zeitschritt  $t + 1$  berechnet sich daher abhängig von der Leistungsaufnahme im Zeitschritt  $t$  wie folgt:

$$\forall t \in \mathcal{T} : T(t+1) = T(t) + \Delta T(t), \text{ wobei } \Delta T(t) = \begin{cases} \Delta T_{\text{on}} & \text{falls } P(t) = P_{\text{on}} \\ \Delta T_{\text{off}} & \text{falls } P(t) = P_{\text{off}} \end{cases}$$

Unter Berücksichtigung der Einhaltung der Temperaturschranken ist der Verbrauch flexibel zwischen  $P_{\text{on}}$  und  $P_{\text{off}}$  wählbar. Abbildung 3.2 stellt diese Zusammenhänge graphisch dar.

### 3. Selbst-Organisation und Trust in Autonomen Verbraucherorganisationen

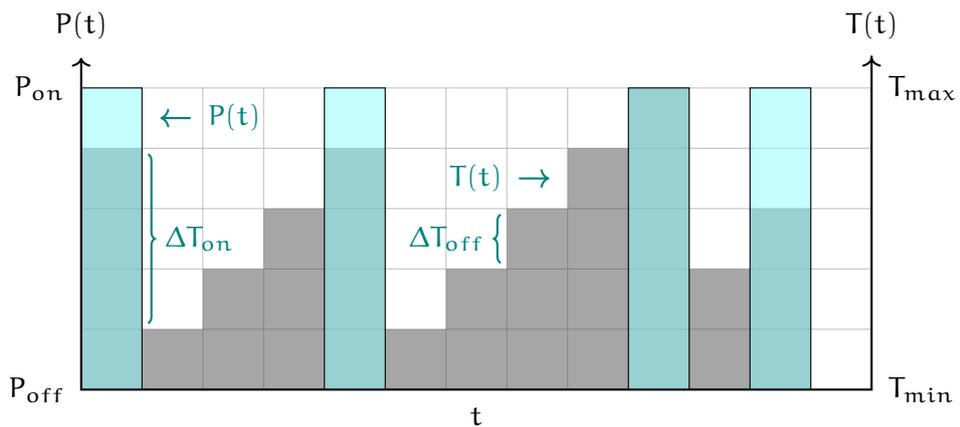


Abbildung 3.2.: Beispielhafte Last- und Temperaturkurve eines kühlenden thermischen Verbrauchers mit dem in dieser Arbeit verwendeten Steuerungsmodell über einen Zeitraum von einigen Zeitschritten. Der Verbrauch  $P(t)$  (Primärachse) ist durch die hellblaue Fläche gekennzeichnet, die sich abhängig von den Betriebszuständen entwickelnde Temperatur  $T(t)$  (Sekundärachse) ist durch die dunkelgraue Fläche gekennzeichnet. Die Betriebszustände wurden so gewählt, dass die Temperatur stets im gewünschten Bereich zwischen  $T_{\min}$  und  $T_{\max}$  bleibt.

#### Programmgetriebene Verbraucher

Analog zu den thermischen Verbrauchern haben programmgetriebene Verbraucher eine Leistung  $P_{\text{off}} \in \mathbb{R}_0^+$  im Ruhezustand und eine konstante Leistung  $P_{\text{on}} \in \mathbb{R}^+$  im Betriebszustand, wobei  $P_{\text{off}} < P_{\text{on}}$ . Auch bei programmgetriebenen Verbrauchern entspricht die aufgenommene Leistung zu jedem Zeitpunkt entweder  $P_{\text{on}}$  oder  $P_{\text{off}}$ . Der Nutzer kann einen frühesten Endzeitpunkt  $t_{\text{early}} \in \mathcal{T}$  bis zu dem das Programm frühestens beendet sein soll und einen spätesten Endzeitpunkt  $t_{\text{late}} \in \mathcal{T}$  bis zu dem das Programm spätestens beendet sein soll festlegen<sup>16</sup>, wobei  $t_{\text{early}} < t_{\text{late}}$ . Das Programm hat dabei eine Dauer von  $\tau_{\text{dur}} \in \mathbb{N}^+$  Zeitschritten, sobald es gestartet wurde. Der flexibel wählbare Startzeitpunkt  $t_{\text{start}} \in \mathcal{T}$  gibt an, zu welchem Zeitpunkt das Programm gestartet wird.  $t_{\text{start}}$  muss dabei so gewählt werden, dass das Programm frühestens zum Zeitpunkt  $t_{\text{early}}$  und spätestens zum Zeitpunkt  $t_{\text{late}}$  beendet ist, so dass  $t_{\text{early}} \leq t_{\text{start}} + \tau_{\text{dur}} \leq t_{\text{late}}$ . Da der

<sup>16</sup> Der Einfachheit halber wird hier nur von einem Programmdurchlauf in  $\mathcal{T}$  gesprochen; mehrere aufeinanderfolgende Programmdurchläufe mit entsprechend mehreren definierten Endzeitpunkten sind selbstverständlich ebenso möglich.

### 3.3. Betrachtete steuerbare Verbrauchertypen und Steuerungsmodelle

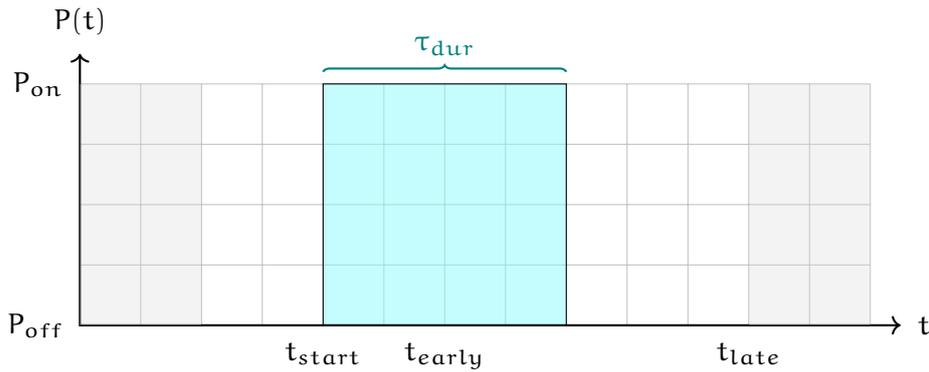


Abbildung 3.3.: Beispielhafte Lastkurve eines programmgetriebenen Verbrauchers mit dem in dieser Arbeit verwendeten Steuerungsmodell über einen Zeitraum von einigen Zeitschritten. Der Verbrauch  $P(t)$  ist durch die hellblaue Fläche gekennzeichnet.  $t_{\text{start}}$  wurde hier so gewählt, dass das vier Zeitschritte andauernde Programm ( $\tau_{\text{dur}} = 4$ ) nach  $t_{\text{early}}$  aber vor  $t_{\text{late}}$  beendet ist; genauso hätte das Programm auch bis zu zwei Zeitschritte vorher oder bis zu drei Zeitschritte nachher gestartet werden können.

programmgetriebene Verbraucher nur während des Programms im Betrieb ist, gilt  $\forall t \in \{t_{\text{start}}, \dots, t_{\text{start}} + \tau_{\text{dur}} - 1\} : P(t) = P_{\text{on}}$  und für alle anderen Zeitschritte  $P(t) = P_{\text{off}}$ . Ein Beispiel für eine Verbrauchskurve eines programmgetriebenen Verbrauchers auf Basis dieses Steuerungsmodells zeigt Abbildung 3.3.

#### Abschaltbare Verbraucher

Abschaltbare Verbraucher haben eine konstante Nachfrage  $P_{\text{on}} \in \mathbb{R}^+$  im Betrieb und eine konstante Nachfrage  $P_{\text{off}} \in \mathbb{R}_0^+$ , wenn die Last reduziert bzw. abgeschaltet ist. Dabei gilt  $P_{\text{off}} < P_{\text{on}}$  und  $\forall t \in \mathcal{T} : P(t) \in \{P_{\text{on}}, P_{\text{off}}\}$ , wobei  $P(t)$  flexibel wählbar ist. Abschaltbare Verbraucher lassen jedoch ihre Nachfrage nicht beliebig oft reduzieren bzw. abschalten, sondern spezifizieren eine maximale Anzahl an Zeitschritten  $\tau_{\text{off}} \in \mathbb{N}_0$ , zu denen die Nachfrage in einem gewissen Zeitraum  $\mathcal{T}_{\text{sub}} \subseteq \mathcal{T}$  – z. B. innerhalb eines Tages – reduziert bzw. abgeschaltet werden kann. Demnach gilt, betrachtet für alle solche Zeiträume:

$$\forall \mathcal{T}_{\text{sub}} \subseteq \mathcal{T} : \left| \{t \in \mathcal{T}_{\text{sub}} \mid P(t) = P_{\text{off}}\} \right| \leq \tau_{\text{off}}$$

Das Prinzip eines abschaltbaren Verbrauchers wird anhand Abbildung 3.4

### 3. Selbst-Organisation und Trust in Autonomen Verbraucherorganisationen

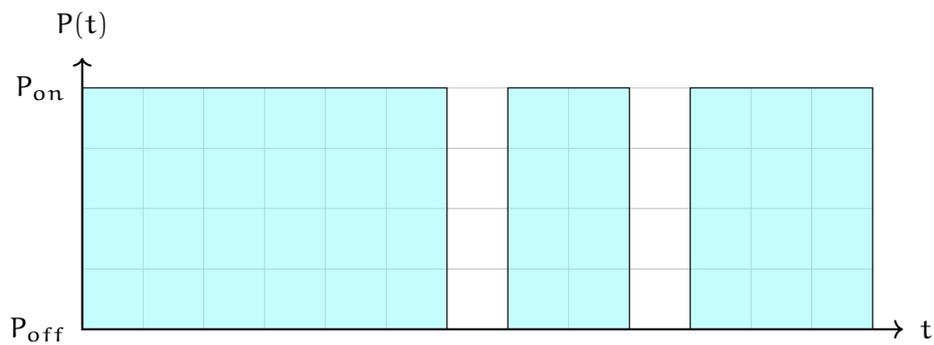


Abbildung 3.4.: Beispielhafte Lastkurve eines abschaltbaren Verbrauchers mit dem in dieser Arbeit verwendeten Steuermodell über einen Zeitraum  $\mathcal{T}_{\text{sub}}$  von einigen Zeitschritten. In diesem Beispiel ist  $\tau_{\text{off}} = 2$  und  $P(t)$  wurde so gewählt, dass die Nachfrage dementsprechend im Zeitraum  $\mathcal{T}_{\text{sub}}$  maximal zweimal unterbrochen wird.

illustriert.

#### Speicher

Speicher haben eine Minimalleistung  $P_{\text{min}} \in \mathbb{R}_0^-$  und eine Maximalleistung  $P_{\text{max}} \in \mathbb{R}^+$ . Dabei ist  $P_{\text{min}}$  die maximale Leistung, mit der der Speicher entladen werden kann und Leistung in das Netz abgeben kann, und  $P_{\text{max}}$  die maximale Leistung, mit der der Speicher aufgeladen werden kann und somit Leistung aus dem Netz bezieht. Die nachgefragte bzw. abgegebene Leistung des Speichers liegt stets zwischen  $P_{\text{min}}$  und  $P_{\text{max}}$ , so dass  $\forall t \in \mathcal{T} : P(t) \in [P_{\text{min}}, P_{\text{max}}]$ . Der Speicher besitzt eine minimale Speicherkapazität  $E_{\text{min}}$  und eine maximale Speicherkapazität  $E_{\text{max}}$ . Der Energielevel des Speichers zum Zeitpunkt  $t$  wird mit  $E(t)$  bezeichnet und muss zu jedem Zeitpunkt innerhalb der minimalen und maximalen Speicherkapazität liegen; daher gilt  $\forall t \in \mathcal{T} : E(t) \in [E_{\text{min}}, E_{\text{max}}]$ . Des Weiteren besitzt der Speicher einen prozentualen Wirkungsgrad  $e \in [0, 1]$ , der sowohl beim Auf- als auch beim Entladen des Speichers zum Tragen kommt. Abhängig von der flexibel wählbaren Leistung  $P(t)$  im Zeitpunkt  $t$ , entwickelt sich der Energielevel des Speichers für den Zeitpunkt  $t + 1$  folgendermaßen:

$$\forall t \in \mathcal{T} : E(t + 1) = E(t) + \Delta E(t), \text{ wobei } \Delta E(t) = P(t) \cdot \Delta t_{\text{hour}} \cdot e$$

$\Delta t_{\text{hour}}$  bezeichnet dabei den zeitlichen Unterschied  $\Delta t$  zwischen zwei aufeinanderfolgenden Zeitschritten in Stunden. Abbildung 3.5 illustriert die

### 3.3. Betrachtete steuerbare Verbrauchertypen und Steuerungsmodelle

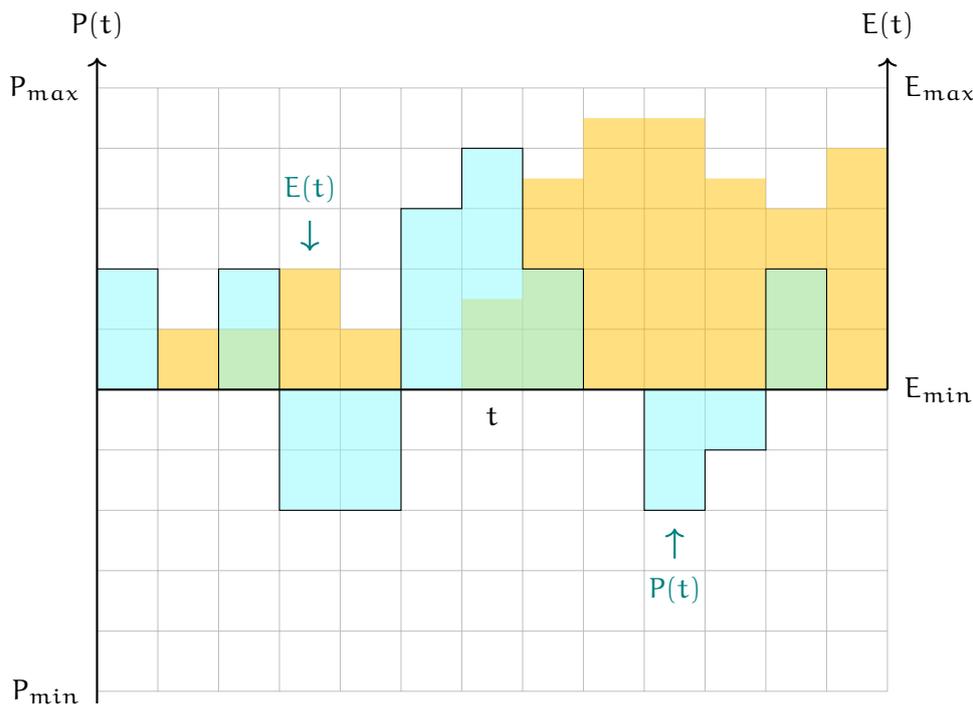


Abbildung 3.5.: Beispielhafte Last- und Energiekurve eines elektrischen Speichers mit dem in dieser Arbeit verwendeten Steuerungsmodell über einen Zeitraum von einigen Zeitschritten. Der Verbrauch  $P(t)$  (Primärachse) ist durch die hellblaue Fläche gekennzeichnet, der sich abhängig von der nachgefragten/abgegebenen Leistung entwickelnde Energielevel  $E(t)$  (Sekundärachse) ist durch die orangefarbene Fläche gekennzeichnet. Die Leistung wurde so gewählt, dass der Energielevel stets zwischen  $E_{\min}$  und  $E_{\max}$  bleibt.

eben geschilderten Zusammenhänge anhand einem Beispiel.

#### Elektrofahrzeuge

Batteriebetriebene Elektrofahrzeuge – im Folgenden nur noch mit Elektrofahrzeuge bezeichnet – sind eine besondere Art von Speicher, da sie zwar prinzipiell als Speicher genutzt werden können, aber primär dem Verwendungszweck der Mobilität folgen und die Speichermöglichkeiten daher limitierter als bei herkömmlichen, stationären Speichern sind. Analog zu den allgemeinen Speichern haben auch Elektrofahrzeuge eine Minimalleistung  $P_{\min} \in \mathbb{R}_0^-$ , eine Maximalleistung  $P_{\max} \in \mathbb{R}^+$ , eine minimale Batteriekapazi-

### 3. Selbst-Organisation und Trust in Autonomen Verbraucherorganisationen

tät  $E_{\min} \in \mathbb{R}_0^+$ , eine maximale Batteriekapazität  $E_{\max} \in \mathbb{R}_0^+$ , einen prozentualen Wirkungsgrad  $e \in [0, 1]$  und einen Energielevel  $E(t) \in [E_{\min}, E_{\max}]$ .

Bei Elektrofahrzeugen kommt nun hinzu, dass diese nur teilweise verfügbar und am Stromnetz angeschlossen sind. So gibt es einen Zeitpunkt der Ankunft (bzw. des Verbindens mit dem Stromnetz)  $t_{\text{arr}} \in \mathcal{T}$  und einen Zeitpunkt der geplanten Abfahrt<sup>17</sup> (bzw. des Trennens vom Stromnetz)  $t_{\text{dep}} \in \mathcal{T}$ , wobei natürlich  $t_{\text{arr}} \leq t_{\text{dep}}$ . Demnach ist die nachgefragte bzw. abgegebene Leistung  $P(t)$  nur für Zeitschritte  $t \in \{t_{\text{arr}}, \dots, t_{\text{dep}} - 1\}$  innerhalb des Intervalls  $[P_{\min}, P_{\max}]$  flexibel wählbar; für alle anderen Zeitschritte gilt  $P(t) = 0$ . Als Nutzer eines Elektrofahrzeugs möchte man weder für die nächste geplante Fahrt noch für spontane Fahrten oder Notfälle zu wenig Energie in der Batterie gespeichert haben. Daher spezifiziert der Nutzer einen für den geplanten Abfahrtszeitpunkt gewünschten Energielevel  $E_{\text{des}}^{\text{dep}} \in [E_{\min}, E_{\max}]$ , der zur Abfahrt mindestens gespeichert sein muss, so dass  $E_{\text{des}}^{\text{dep}} \leq E(t_{\text{dep}})$ . Außerdem spezifiziert der Nutzer einen gewünschten Mindestenergielevel  $E_{\text{des}}^{\text{min}} \in [E_{\min}, E_{\max}]$ , der stets an Energie für spontane Fahrten gespeichert sein soll. Da Elektrofahrzeuge jedoch nach einer Fahrt mit einem niedrigeren Energielevel ankommen können als via  $E_{\text{des}}^{\text{min}}$  gewünscht, muss ggf.  $\tau_{\text{init}} \in \mathbb{N}_0$  Zeitschritte lang die Batterie mit  $P_{\max}$  geladen werden, um  $E_{\text{des}}^{\text{min}}$  schnellstmöglich zu erreichen. Wie viele Zeitschritte es sein müssen berechnet sich wie folgt:

$$\tau_{\text{init}} = \begin{cases} \left\lceil \frac{E_{\text{des}}^{\text{min}} - E(t_{\text{arr}})}{P_{\max} \cdot \Delta t_{\text{hour}} \cdot e} \right\rceil & \text{wenn } E_{\text{des}}^{\text{min}} > E(t_{\text{arr}}) \\ 0 & \text{sonst} \end{cases}$$

Für die darauffolgenden Zeitschritte  $t \in \{t_{\text{arr}} + \tau_{\text{init}}, \dots, t_{\text{dep}}\}$  gilt folglich  $E(t) \in [E_{\text{des}}^{\text{min}}, E_{\max}]$ . Der Energielevel  $E(t)$  berechnet sich identisch zu dem Energielevel von herkömmlichen Speichern, allerdings beschränkt auf den verfügbaren Zeitraum zwischen  $t_{\text{arr}}$  und  $t_{\text{dep}}$ . Das Steuerungsmodell der Elektrofahrzeuge ist anhand einem Beispiel in Abbildung 3.6 dargestellt.

#### *Nicht steuerbare Verbraucher*

Nicht steuerbare Verbraucher werden in dieser Arbeit nicht gesondert modelliert und insbesondere wird nicht jeder einzelne Verbraucher im System

<sup>17</sup> Der Einfachheit halber wird hier nur von einer Ankunft und einer Abfahrt gesprochen; mehrere aufeinanderfolgende Fahrten sind selbstverständlich ebenso möglich.

### 3.3. Betrachtete steuerbare Verbrauchertypen und Steuerungsmodelle

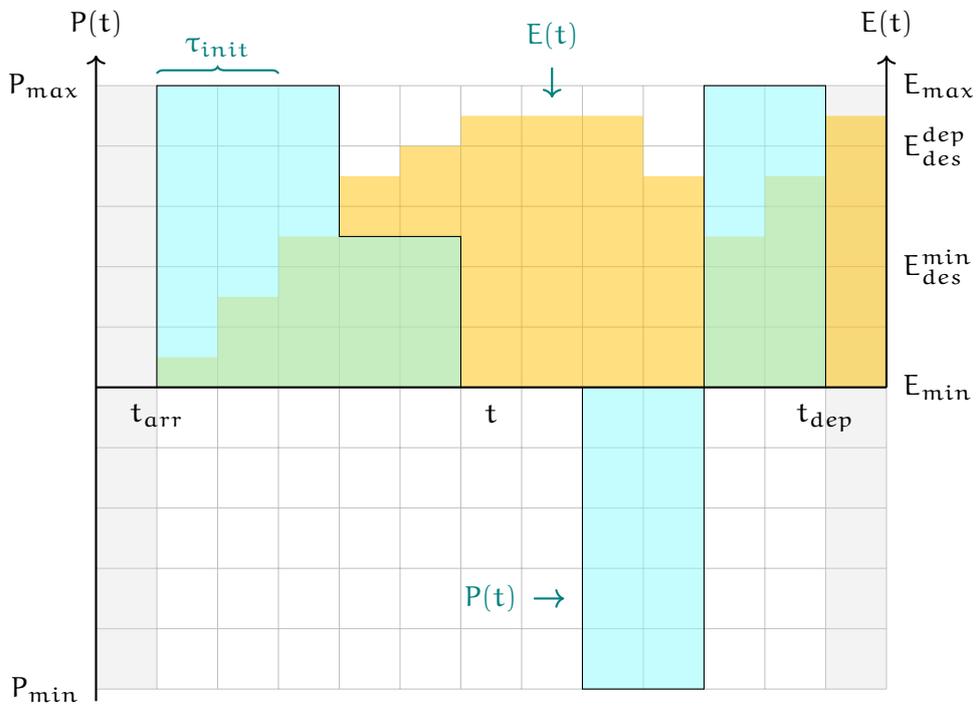


Abbildung 3.6.: Beispielhafte Last- und Energiekurve eines Elektrofahrzeugs mit dem in dieser Arbeit verwendeten Steuerungsmodell über einen Zeitraum von einigen Zeitschritten. Der Verbrauch  $P(t)$  (Primärachse) ist durch die hellblaue Fläche gekennzeichnet, der sich abhängig von der nachgefragten/abgegebenen Leistung entwickelnde Energielevel  $E(t)$  (Sekundärachse) ist durch die orangefarbene Fläche gekennzeichnet. Die ersten zwei Zeitschritte ( $\tau_{\text{init}} = 2$ ) nach der Ankunft  $t_{\text{arr}}$  wird die fast leere Batterie zunächst mit maximaler Leistung aufgeladen, damit der Energielevel den Mindestenergielevel  $E_{\text{des}}^{\text{min}}$  erreicht. Danach wird die Leistung so gewählt, dass dieses Level nicht mehr unterschritten wird und zur Abfahrt  $t_{\text{dep}}$  der Energielevel mindestens  $E_{\text{des}}^{\text{dep}}$  beträgt.

### 3. *Selbst-Organisation und Trust in Autonomen Verbraucherorganisationen*

durch einen eigenen Agenten mit eigener Nachfrage repräsentiert. Stattdessen repräsentieren diese Agenten eine Gruppe einzelner nicht steuerbarer Verbraucher – beispielsweise einen Haushalt, einen Wohnblock oder einen industriellen Verbraucher – und verwenden Lastkurven ähnlich den Standardlastprofilen.

#### 3.4. AUTONOME VERBRAUCHERORGANISATIONEN

Wie in Abschnitt 2.5 motiviert, ist eine zentrale Einsatzplanung für die riesige Anzahl an steuerbaren Verbrauchern nicht zielführend. Durch die Dekomposition der zentralen Einsatzplanung in kleinere Subprobleme wird hingegen eine skalierbare Einsatzplanung erreicht. Das bedeutet, dass die Einsatzplanung jeweils für kleinere Gruppen von Verbrauchern durchgeführt werden muss. Dies wird erreicht, indem Organisationsstrukturen geschaffen werden, welche die Gesamtheit aller Verbraucher – steuerbare und nicht steuerbare Verbraucher – in kleinere, paarweise disjunkte, autonom und voneinander unabhängig arbeitenden Organisationen von Verbrauchern aufteilen (s. Abbildung 3.7).<sup>18</sup> Eine jede solche Gruppe von Verbrauchern wird AVO genannt.

Die Menge aller Autonomen Verbraucherorganisationen verfolgt dabei gemeinsam das Ziel, die insgesamt im System vorliegende Residuallast zu glätten und somit die Einsatzplanung der steuerbaren Erzeuger zu erleichtern, die Kraftwerke effizienter zu betreiben und Kosten zu sparen. Dazu bekommt jede AVO einen Teil der im System vorliegenden nicht steuerbaren Erzeugung zugewiesen – wobei die Summe der Anteile der einzelnen Autonomen Verbraucherorganisationen die insgesamt im System vorhandene nicht steuerbare Erzeugung ergibt. Auf Basis der vorhergesagten nicht steuerbaren Leistung und des vorhergesagten Verbrauchs der in der AVO enthaltenen nicht steuerbaren Verbraucher wird die lokale Residuallast geglättet, indem eine autonome, periodische Einsatzplanung für einen zukünftigen Zeitraum für die in der AVO enthaltenen steuerbaren Verbraucher durchgeführt wird. Durch die Glättung der lokalen Residuallast in jeder AVO wird die insgesamt im System vorliegende Residuallast geglättet. Eine AVO wird im System wie die physikalischen Verbraucher durch einen Agenten

<sup>18</sup> Es werden ausnahmslos alle Systemteilnehmer gruppiert, d. h. es werden keine Systemteilnehmer ausgeschlossen.

### 3.4. Autonome Verbraucherorganisationen

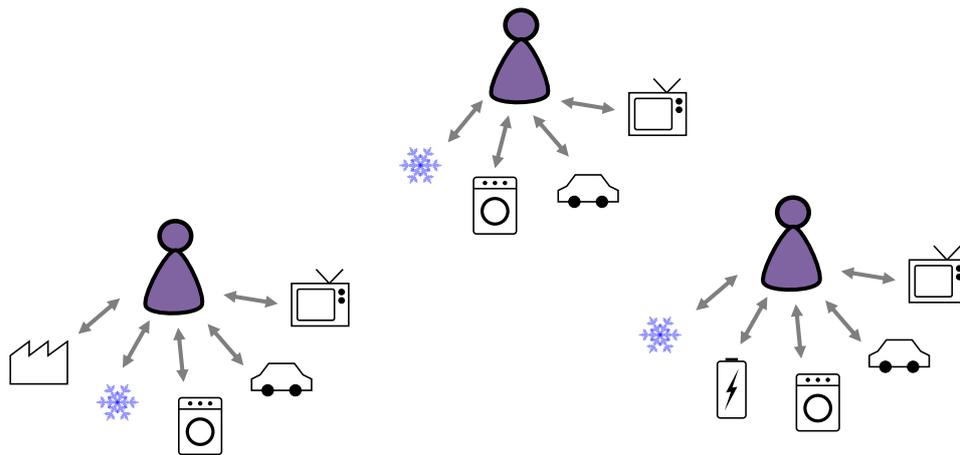


Abbildung 3.7.: Exemplarisches System Autonome Verbraucherorganisationen. In diesem kleinen Beispiel werden die 14 Verbraucher auf drei verschiedene Autonome Verbraucherorganisationen (in violett) aufgeteilt.

repräsentiert, der somit einen großen, virtuellen Verbraucher darstellt. Ein Ansatz für die autonome Einsatzplanung in Autonomen Verbraucherorganisationen wird in Kapitel 5 vorgestellt.

Wichtiger Bestandteil einer Einsatzplanung innerhalb von Autonomen Verbraucherorganisationen ist der Umgang mit Unsicherheiten, die zwangsläufig bei der Verwendung von Vorhersagen der Systemteilnehmer entstehen. So baut die Einsatzplanung in einer AVO auf die Vorhersagen (1) der zugewiesenen, nicht steuerbaren Erzeugung, (2) der enthaltenen nicht steuerbaren Verbraucher und (3) der enthaltenen steuerbaren Verbraucher auf. Um die bei diesen Vorhersagen entstehende Unsicherheiten besser zu quantifizieren, zu antizipieren und geeignete Gegenmaßnahmen zu ergreifen, wird in Autonomen Verbraucherorganisationen deshalb das Prinzip des Trusts verwendet. So werden die Systemteilnehmer anhand ihrer vergangenen Prognosefehlern als vertrauenswürdig oder nicht vertrauenswürdig eingestuft (s. Abschnitt 3.2) und diese Information bei der Zusammensetzung der Autonomen Verbraucherorganisationen berücksichtigt (s. Kapitel 4) sowie die gewonnenen Erfahrungen aus den Prognosefehlern bei der Einsatzplanung berücksichtigt (s. Kapitel 5).

Da jede AVO gleichermaßen für die Glättung der lokalen und damit der systemweiten Residuallast zuständig ist, spielt die Zusammensetzung der Autonomen Verbraucherorganisationen eine wichtige Rolle; diese muss so

### 3. Selbst-Organisation und Trust in Autonomen Verbraucherorganisationen

gewählt werden, dass das Systemziel optimal unterstützt wird. Bei der Zusammensetzung von Autonomen Verbraucherorganisationen gibt es drei wichtige Punkte zu berücksichtigen, die die lokale und systemweite Residuallastglättung bestmöglich unterstützen und somit die Robustheit und Effizienz des Systems erhöhen (siehe auch Kapitel 4):

*Komplexität* Aufgrund der Komplexität der Einsatzplanung dürfen Autonome Verbraucherorganisationen nicht zu groß sein, um eine ausreichend schnelle Durchführung der Einsatzplanung zu ermöglichen.

*Flexibilität* Zur idealen Unterstützung der lokalen Residuallastglättung ist es von Vorteil, wenn sich innerhalb einer AVO eine hohe Anzahl flexibler Verbraucher mit vielen Freiheitsgraden befinden.

*Ähnlichkeit* Die Bildung von zueinander ähnlichen Autonomen Verbraucherorganisationen – eine sog. *homogene Partitionierung* [12] – ermöglicht die bestmögliche, lokale Erfüllung des Systemziels in *jeder* AVO.

Die Schwierigkeit der Berücksichtigung dieser drei Punkte liegt darin, dass diese zum Teil orthogonal zueinander sind. Beispielsweise hat der Punkt Flexibilität das Ziel, dass eine hohe Anzahl an steuerbaren Verbrauchern in einer AVO enthalten ist, was in Konkurrenz zu dem Punkt Komplexität steht oder unter Umständen den Punkt Ähnlichkeit verletzt, wenn die hohe Anzahl an steuerbaren Verbrauchern nur in wenigen Autonomen Verbraucherorganisationen vorhanden wäre. Letztlich kommt es bei der Schaffung der Organisationsstrukturen daher darauf an, dass ein gesunder Mittelweg aus ähnlichen, flexiblen aber nicht zu großen Autonomen Verbraucherorganisationen gefunden wird.

Änderungen zur Laufzeit – z. B. durch Änderungen in der Umwelt, Veränderungen in der Flexibilität existierender Verbraucher oder auch das stetige Hinzukommen neuer und Ersetzen alter Verbraucher – können allerdings dafür sorgen, dass die Organisationsstruktur nicht mehr bestmöglich das Systemziel unterstützt. Daher dürfen die Organisationsstrukturen nicht vorgegeben oder statisch sein, sondern müssen sich selbst autonom zur Laufzeit an die geänderten Bedingungen anpassen, so dass das Systemziel wieder optimal unterstützt wird. Autonome Verbraucherorganisationen sind demnach nach Di Marzo Serugendo et al. [38] *selbst-organisierend* (siehe Abschnitt 3.1). Gleichwohl sollte die Systemstruktur relativ stabil bleiben und nicht permanent angepasst werden. Zwei Algorithmen, die für die

### 3.4. Autonome Verbraucherorganisationen

selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen zuständig sind und oben genannte Punkte berücksichtigen, werden in Kapitel 4 vorgestellt.

Autonome Verbraucherorganisationen sind somit ein Ansatz zum selbst-organisierten, trust-bewussten Demand Side Management in Smart Grids. Nach einer jetzt folgenden Diskussion zu verwandten Arbeiten werden in den darauffolgenden Kapiteln die einzelnen Techniken, die in diesem Ansatz verwendet werden, genauer behandelt.

#### *Stand der Technik und verwandte Arbeiten*

In diesem Abschnitt sollen neben einem groben Überblick über den Stand der Technik nur verwandte Arbeiten dargestellt werden, welche den allgemeinen Ansatz betreffen. Verwandte Arbeiten bezüglich einzelner Techniken werden in den jeweiligen Abschnitten behandelt, welche die Techniken vorstellen.

Generell gibt es viele Ansätze, um flexibilisierte elektrische Verbraucher in irgendeiner Form in den Steuerungsprozess einzubinden.

In der Praxis bereits eingesetzte Konzepte zur Einbindung von Verbrauchern in Steuerungsprozesse in Deutschland existieren z. B. von *Entelios*, mittlerweile ein Tochterunternehmen der *EnerNOC*, die Verbraucher wie z. B. die *Paulaner* Brauerei mit entsprechender Technik ausrüsten [39], so dass diese steuerbar werden und z. B. in einem virtuellen Kraftwerk wie dem der *Stadtwerke München* eingesetzt werden können [105]. Zudem sind durch die bereits erwähnte Verordnung zu abschaltbaren Lasten teilnehmende Großverbraucher in den Steuerungsprozess von Übertragungsnetzbetreibern eingebunden, wenn es die Netzsituation erfordert. Diese Verbraucher können entweder reaktiv auf größere Frequenzabweichungen automatisiert ihre Nachfrage drosseln oder bei Bedarf gezielt angesteuert werden, damit diese ihre Last reduzieren. Weil die Teilnahme nur für Großverbraucher mit einer Lastreduzierung von mindestens 5 MW erlaubt ist<sup>19</sup>, bieten Unternehmen wie z. B. *Next Kraftwerke* den Zusammenschluss mehrerer Unternehmen im virtuellen Kraftwerk *Next Pool* an [78]. Auch für die zunehmende Anzahl an dezentralen Speichern existieren Lösungen, die virtuelle Kraftwerke einsetzen, wie das beispielsweise *sonnen GmbH* mit der *sonnenCommunity* anbietet, um die Autarkie der Mitglieder durch die Speicherung und Nutzung von

<sup>19</sup> [https://www.gesetze-im-internet.de/enwg\\_2005/\\_13i.html](https://www.gesetze-im-internet.de/enwg_2005/_13i.html) (besucht am 23.03.2017)

### 3. Selbst-Organisation und Trust in Autonomen Verbraucherorganisationen

Energie aus dem virtuellen Speicher zu erhöhen [104]. *Open Energi* – ein Unternehmen aus dem Vereinigtem Königreich – rüstet Verbraucher mit Geräten aus, so dass diese bei Abweichungen der Netzfrequenz von 50 Hz wenn möglich ihre Nachfrage erhöhen oder senken [84].

Eines der Vorreiter-Projekte in Deutschland zu Smart Grids war das E-Energy-Programm [30]. In den dort enthaltenen Modellprojekten wie u. a. eTelligence [2], MeRegio [49] und Smart Watts [64] waren vor allem die Erprobung von regionalen Märkten zur Integration von erneuerbaren Energien und Verbrauchern Thema. Das Projekt Smart Nord [70] beschäftigte sich ebenfalls mit der Integration von erneuerbaren Energieerzeugern am Markt oder an der Bereitstellung von Systemdienstleistungen.

Zudem existieren in der Praxis erprobte Feldtests wie das Projekt *Smart Operator*<sup>20</sup> von der RWE Deutschland AG zu einem intelligenten Betrieb eines Ortsnetzes. Die Feldtests wurden in drei verschiedenen Ortsnetzen durchgeführt, die neben normalen Haushalten u. a. aus diversen Photovoltaikanlagen, Strom- bzw. Wärmespeichern sowie Haushalten mit intelligenten Haushaltsgeräten bestanden. Eine zentrale autonome Einheit in dem Ortsnetz, der Smart Operator, erfasst alle notwendigen Daten im Ortsnetz zu aktueller dargebotsabhängiger Einspeisung und aktueller Last und erstellt Prognosen der zukünftig zu erwartenden dargebotsabhängigen Leistung und Last [119]. Anhand dieser Daten steuert der Smart Operator im Ortsnetz die Nachfrage der flexiblen Lasten, so dass die im Ortsnetz eingespeiste dargebotsabhängige Leistung möglichst gut ausgenutzt wird und somit Kosten beim Netzausbau gespart werden können. Damit ist auch eine bessere Frequenzeinhaltung möglich [45].

Ein vielfach in der Literatur untersuchter Ansatz ist die Beeinflussung des Verbrauchs durch die Reaktion auf die aktuelle Netzfrequenz (siehe z. B. [46, 102]) oder auf aktuelle (teilweise komplexe) Preissignale (siehe z. B. [51, 117, 89, 42]), manchmal noch erweitert um weitere Signale wie aktuelle Emissionswerte [87]. Zwar haben solche Ansätze durchaus Vorteile wie eine geringere Komplexität und die verhältnismäßig einfache technische Umsetzung auf Seiten der Verbraucher, allerdings auch Nachteile: Neben der offensichtlich fehlenden Planbarkeit führen solche Betriebsweisen zudem oft zur Synchronisation der Verbraucher, so dass komplexe Desynchronisationsstrategien entwickelt und umgesetzt werden müssen.

Ein großer Fokus liegt zudem auf der autonomen Einsatzplanung von

<sup>20</sup> <https://www.lew.de/energiezukunft/smart-operator> (besucht am 01.02.2017)

Erzeugern bzw. Verbrauchern (siehe z. B. [118, 61, 47, 67]). Verwandte Arbeiten aus diesem Bereich werden in den späteren Kapiteln zu den einzelnen Techniken diskutiert.

Die Gruppierung von Erzeugern bzw. Erzeugern und Verbrauchern ist ein Ansatz, den viele Forscher untersuchen (s. z. B. [111, 82, 54, 69]). Einige davon werden in den späteren Kapiteln an passenderer Stelle näher diskutiert.

Lünsdorf schlägt in seiner Dissertation [69] die Bildung von Verbänden von Haushaltsgeräten zur autonomen Lastverschiebung vor. Ein solcher Verbund wird *virtuelles Gerät* genannt. Die Ausbildung von virtuellen Geräten erfolgt selbst-organisiert mittels einer dafür entwickelten Heuristik. Haushaltsgeräte nehmen am Steuerungsprozess teil indem sie für die Ansteuerung sog. Deltaprognosen erstellen, welche eine mögliche Lastverschiebung des jeweiligen Geräts auf Basis des geplanten Verbrauchs darstellt. Diese werden im zugehörigen virtuellen Gerät für alle enthaltenen Haushaltsgeräte aggregiert; ein zentraler Einsatzplanungsagent berechnet Fahrpläne für alle virtuellen Geräte, d. h. Zeitpunkte, an denen die Lastverschiebung stattfinden soll. Diese für das virtuelle Gerät erstellten Zeitpunkte der Lastverschiebung werden direkt an die enthaltenen Haushaltsgeräte übermittelt und von denjenigen versucht umzusetzen. Da alle Haushaltsgeräte in einem virtuellen Gerät mit dem für das virtuelle Geräte erstellten, selben Fahrplan angesteuert werden, werden in einem virtuellen Gerät Haushaltsgeräte gleichen Typs mit ähnlichen Lastverschiebungspotenzialen gruppiert, damit sich Lastverschiebungen nicht aufheben. Unsicherheiten spielen in der Arbeit von Lünsdorf eine untergeordnete Rolle; sog. Fehlerprognosen der Haushaltsgeräte sind zwar Teil des Verbundbildungsprozesses, um zu große virtuelle Geräte mit zu großen Prognosefehlern zu vermeiden, werden aber bei der Einsatzplanung nicht berücksichtigt, da angenommen wird, dass sich die prozentuale Abweichung vom Erwartungswert der Lastverschiebung gemäß dem schwachen Gesetz großer Zahlen in einer Gruppe von Verbrauchern reduzieren.

Eine naturgemäß verwandte Arbeit zu Autonomen Verbraucherorganisationen sind die Autonomen Virtuellen Kraftwerke (siehe z. B. [108, 14, 5]), auf deren Prinzip und Techniken die Autonomen Verbraucherorganisationen beruhen. Autonome Virtuelle Kraftwerke werden noch später in dieser Arbeit ausführlicher behandelt (siehe Kapitel 6).



## SELBST-ORGANISIERTE AUSBILDUNG VON AUTONOMEN VERBRAUCHERORGANISATIONEN

---

**ZUSAMMENFASSUNG** Dieses Kapitel stellt zwei Algorithmen zur Ausbildung von Autonomen Verbraucherorganisationen vor – eine Metaheuristik [12] und einen dezentralen agenten-basierten Ansatz [5]. Beide lösen im Allgemeinen das Partitionierungsproblem [12] und können mit beliebigen Zielfunktionen bestückt werden sowie Partitionierungsbedingungen wie die Anzahl an Partitionen und die Partitionsgrößen berücksichtigen. Bei der Ausbildung von Autonomen Verbraucherorganisationen wird eine homogene Partitionierung [12] hergestellt, die zueinander ähnliche Partitionen bildet.

# 4

**I**N Abschnitt 4.1 wird zunächst generell vorgestellt, wie die Selbst-Organisation von Autonomen Verbraucherorganisationen abläuft und welche Ziele sie dabei verfolgt. Daraufhin beschreibt Abschnitt 4.2 das zugrundeliegende Partitionierungsproblem [12], das bei der Ausbildung von Autonomen Verbraucherorganisationen zu lösen ist. Anschließend werden zwei verschiedene Algorithmen vorgestellt, die das Partitionierungsproblem auf zwei unterschiedliche Weisen lösen: Abschnitt 4.3 präsentiert PSOPP [12], einen diskreten Partikelschwarmoptimierer, wohingegen Abschnitt 4.4 mit dem Algorithmus SPADA [5] ein dezentraler, agenten-basierter Ansatz gezeigt wird.

### 4.1. SELBST-ORGANISATION IN AUTONOMEN VERBRAUCHERORGANISATIONEN

Wie in Kapitel 3 beschrieben, ist die Ausbildung von Autonomen Verbraucherorganisationen selbst-organisiert. Das bedeutet, dass die notwendigen Organisationsstrukturen autonom zur Laufzeit ausgebildet und während der Laufzeit selbstständig angepasst werden, sollten Änderungen in dem Verhalten der Agenten oder der Umwelt dazu führen, dass die vorliegende

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

Organisationsstruktur das Systemziel nicht mehr optimal unterstützt. Der Hauptgrund zur Ausbildung von Autonomen Verbraucherorganisationen ist Skalierbarkeit – die NP-schwere Einsatzplanung für die steuerbaren physikalischen Verbraucher muss schnell genug erfolgen, da die Fahrpläne spätestens zu dem Zeitpunkt verfügbar sein müssen, ab dem sie angefahren werden müssen; ein vorzeitiger Abbruch der Einsatzplanung wäre in vielen Fällen mit Qualitätseinbußen verbunden. Da die Komplexität der Einsatzplanung u. a. von der Anzahl der steuerbaren Verbraucher abhängt, wird Skalierbarkeit durch eine selbst-organisierte Problemdekomposition [107, 5] erreicht, die durch die Ausbildung von Autonomen Verbraucherorganisationen erfolgt. Wichtig dabei ist aber, dass die Autonomen Verbraucherorganisationen eine passende Größe haben und weder zu klein noch zu groß werden: Während zu große Organisationen zu viele steuerbare Verbraucher enthalten, für welche die Einsatzplanung durchgeführt werden muss, und die Einsatzplanung somit nicht schnell genug oder nur mit Einbußen bei der Qualität der Fahrpläne ausgeführt werden kann, sind zu kleine Organisationen mit zu wenigen steuerbaren Verbrauchern möglicherweise nicht flexibel genug, um sich bestmöglich den verschiedenen Charakteristiken der dargebotsabhängigen Leistung anzupassen und somit die Residuallast bestmöglich zu glätten. Es ist daher notwendig, dass die Algorithmen, die für eine selbst-organisierte Problemdekomposition eingesetzt werden, dafür sorgen, dass Partitionierungsbedingungen wie eine minimale Organisationsgröße  $s_{\min}$  nicht unterschritten und eine maximale Organisationsgröße  $s_{\max}$  nicht überschritten wird, um einen Trade-Off zwischen der Qualität der Lösungen und der Laufzeit zu erlauben [14, 5].

Die Einsatzplanung muss jedoch nicht nur schnell genug, sondern auch gut genug erfolgen. Da jede AVO unabhängig von den anderen Autonomen Verbraucherorganisationen arbeitet und einen essentiellen Beitrag zur Erreichung des globalen Systemziels liefert, ist es notwendig, dass jede AVO in etwa die gleichen Voraussetzungen hat wie alle anderen, um lokal die Residuallast glätten zu können. Qualitative Unterschiede bei den Systemteilnehmern hinsichtlich deren Möglichkeiten positiv zu der Erfüllung des Systemziels beizutragen und weil Teilnehmer aus dem System nicht ausgeschlossen werden können machen es erforderlich, dass gut und weniger gut geeignete Systemteilnehmer auf die verschiedenen Organisationen bestmöglich aufgeteilt und somit möglichst zueinander ähnliche Organisationen gebildet werden. Die Ausbildung von zueinander ähnlichen Organisationen

#### 4.1. Selbst-Organisation in Autonomen Verbraucherorganisationen

nennt sich *homogene Partitionierung* [12]. Eine homogene Partitionierung hat zur Folge, dass jede AVO ähnliche Eigenschaften wie das Gesamtsystem aufweist und somit *jede* AVO in der Lage ist, das Systemziel ähnlich gut zu erfüllen, wie es das Gesamtsystem theoretisch könnte. Dies verhindert demnach auch, dass Organisationen mit im Verhältnis zu anderen Organisationen überwiegend weniger gut geeigneten Verbrauchern gebildet werden. Solche Organisationen würden das Systemziel nicht optimal unterstützen oder wären verstärkt auf Hilfe von anderen Organisationen angewiesen; die Bildung zueinander ähnlichen Organisationen stärkt somit auch die Unabhängigkeit und Dezentralität von Agentenorganisationen [14]. Im Gegensatz zum *Anticlustering* (siehe [114]), was unähnliche Elemente in Partitionen gruppiert und somit auch für ähnliche Mittelwerte bestimmter Eigenschaften zwischen den Partitionen sorgen kann, ist eine homogene Partitionierung nicht auf das Schaffen von Partitionen von ähnlichen Mittelwerten beschränkt und gruppiert auch nicht notwendigerweise unähnliche Elemente, um dies zu erreichen [14]. Als Beispiel hierfür sei das Ausbilden von Agentenorganisationen, die eine ähnliche Summe bestimmter Eigenschaften zwischen den Partitionen aufweisen sollen, genannt. Eine detaillierte Erläuterung der Unterschiede zwischen einer homogenen Partitionierung und Anticlustering findet der interessierte Leser in der Dissertation von Anders [5].

Eine homogene Partitionierung von Autonomen Verbraucherorganisationen berücksichtigt den Trust-Wert – also die mittlere Abweichung von der Prognose –, die Flexibilität der Verbraucher und ihre maximale Nachfrage. Das bedeutet, dass sowohl vertrauenswürdige und nicht vertrauenswürdige Verbraucher als auch flexible und unflexible Verbraucher auf alle Organisationen verteilt werden müssen. Liegt eine derartige Verteilung vor, können die vertrauenswürdigen, flexiblen Verbraucher in einer AVO die Prognosefehler und die fehlende Flexibilität der nicht vertrauenswürdigen und unflexiblen Verbraucher innerhalb ihrer Möglichkeiten so gut wie möglich kompensieren. Besonders flexible Verbraucher sind beispielsweise Speicher, wohingegen z. B. ein vom Nutzer stark eingeschränkter programmgesteuerter Verbraucher weniger flexibel ist; d. h. die Flexibilität eines Verbrauchers ist sowohl abhängig von dem Typ des Verbrauchers, als auch vom Verhalten des Nutzers. Die Flexibilität eines Verbrauchers besteht dabei aus mehreren Dimensionen. So spielt dabei einerseits die Flexibilität der nachgefragten Leistung selbst eine Rolle – so ist die nachgefragte Leistung bei Speichern

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

und Elektrofahrzeugen innerhalb der maximalen Ladeleistung und der maximalen Entladeleistung flexibel wählbar, wohingegen die Nachfrage von thermischen oder programmgetriebenen Verbrauchern immer eine feste Größe hat. Des Weiteren ist auch die zeitliche Verfügbarkeit und innerhalb dieser die Freiheitsgrade ein wichtiger Faktor in der Flexibilität eines Verbrauchers. Beispielsweise ist ein herkömmlicher Speicher stets am Netz angeschlossen, wohingegen Elektrofahrzeuge auch auf der Straße unterwegs sind und somit nicht immer zur Verfügung stehen. Die Anwendung der Autonomen Virtuellen Kraftwerke hat ebenfalls das Ziel einer homogenen Partitionierung, die Kriterien wie den Trust-Wert und die Steuerbarkeit der Kraftwerke berücksichtigt [14].

Änderungen im Verhalten des Agenten (bzw. des Nutzers des elektrischen Verbrauchers) oder der Umwelt oder das Hinzukommen bzw. Wegfallen von Agenten können sich auf die Optimalität der Systemstruktur auswirken, so dass keine homogene Partitionierung mehr vorhanden ist. Aus diesem Grund können Anpassungen der Systemstruktur zur Laufzeit notwendig werden. Zu diesem Zweck beobachten die Organisationen laufend ihre Zusammensetzung und vergleichen sie mit derjenigen der anderen Organisationen, um festzustellen, wann eine homogene Partitionierung nicht mehr gegeben ist; konkret wird dabei der mittlere Trust-Wert und der Grad der Flexibilität beachtet. Hierfür werden jeweils Constraints formuliert, die nur eine maximale Abweichung des eigenen Werts von dem der anderen Organisationen erlauben. Wird nun zur Laufzeit festgestellt, dass eines der Constraints verletzt ist, wird eine Reorganisation ausgelöst, mit dem Ziel, dass danach wieder ein ordnungsgemäßer Zustand hergestellt ist. Eine Reorganisation sollte dabei spätestens bis zu dem Zeitpunkt, zu dem die nächste Einsatzplanung durchgeführt werden muss, abgeschlossen sein. Zu häufige Reorganisationen sollten allerdings vermieden werden, um eine stabile Systemstruktur zu erhalten. Eine homogene Partitionierung ist deutlich robuster gegenüber Umwelteinflüssen als eine Partitionierung bestehend aus homogenen Partitionen und sorgt somit dafür, dass weniger oft Reorganisationen durchgeführt werden müssen und eine stabilere Systemstruktur vorliegt, wie Anders gezeigt hat [5].

Diese Art und Weise der Wiederherstellung der homogenen Partitionierung nach einer Verletzung von Constraints mittels einer Reorganisation ist angelehnt an den von Nafz et al. [76] vorgestellten *Restore Invariant Approach* (RIA). In diesem Ansatz wird eine Invariante – eine Konjunktion von

## 4.2. Das Partitionierungsproblem

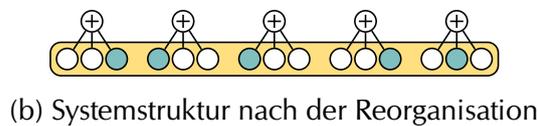
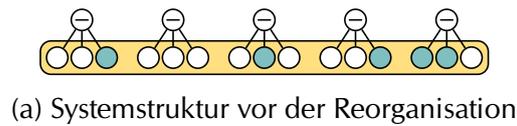


Abbildung 4.1.: Exemplarische Reorganisation von Agentenorganisationen, bei der eine homogene Partitionierung hinsichtlich Agenten mit weißer Eigenschaft  $\circ$  und blauer Eigenschaft  $\bullet$  etabliert wird. Aufgrund von Änderungen zur Laufzeit ist die vorliegende Systemstruktur von Organisationen nicht mehr optimal, denn die Agenten mit der blauen Eigenschaft sind nicht mehr ähnlich auf die Organisationen verteilt. Aufgrund der entdeckten Verletzung des Constraints wird eine Reorganisation angestoßen. Bei einer Reorganisation wird das Partitionierungsproblem für die Agenten in der orangefarbenen Box  gelöst und eine neue Systemstruktur gesucht, die eine homogene Partitionierung wieder herstellt. Die vor der Reorganisation vorhandenen Organisationen  $\ominus$  werden durch die neu gebildeten Organisationen  $\oplus$  ersetzt. Nach der Reorganisation sind die Agenten mit der blauen Eigenschaft auf die Organisationen wieder bestmöglich verteilt.

Constraints – formuliert, die gültige von nicht gültigen Systemzuständen trennt; die gültigen Systemzustände werden als *Korridor korrekten Verhaltens* bezeichnet. Wird ein Constraint verletzt, wird eine Reorganisation angestoßen – mit dem Ziel, das System zurück in den Korridor zu bringen. Dieser Vorgang wird oftmals durch eine *Observer/Controller-Architektur* umgesetzt [90].

Bei einer Reorganisation wird das sog. *Partitionierungsproblem* [12] (siehe Abschnitt 4.2) für die zu partitionierenden Agenten gelöst und – wenn gefunden – eine neue, bessere Systemstruktur etabliert (siehe Abbildung 4.1 zur Veranschaulichung der Zusammenhänge). Zwei Algorithmen, die zur Lösung des Partitionierungsproblems eingesetzt werden können, werden in Abschnitt 4.3 und Abschnitt 4.4 vorgestellt.

### 4.2. DAS PARTITIONIERUNGSPROBLEM

In diesem Abschnitt wird das allgemeine Partitionierungsproblem zusammengefasst, das der Ausbildung von Autonomen Verbraucherorganisationen

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

zugrunde liegt und in [12] vorgestellt wurde. Eine detaillierte Beschreibung des Partitionierungsproblems kann der interessierte Leser in der Dissertation von Anders finden [5]. Obwohl dieses Problem natürlich nicht nur in Multiagentensystemen relevant ist und sich beliebige Elemente statt Agenten partitionieren lassen, wird im Folgenden ohne Beschränkung der Allgemeinheit von Agenten die Rede sein.

Im *Set Partitioning Problem* (SPP) (vgl. [35]) wird eine Menge von Agenten  $A = \{a_1, \dots, a_n\}$  bestehend aus  $n > 1$  Agenten  $a_i$  in nichtleere, paarweise disjunkte Teilmengen partitioniert. Zusammen bilden diese Teilmengen – die sog. *Partitionen* – eine *Partitionierung*. Ziel im SPP ist das Finden einer Partitionierung mit minimalen Kosten; dies ist allerdings NP-schwer. Die optimale Partitionierung wird im SPP anhand im Vorhinein vorgegebenen, gültigen Partitionen gesucht. In dem *vollständigen SPP* (vgl. [66]) wird diese Einschränkung nicht gemacht, weswegen die Anzahl der gültigen Partitionen exponentiell mit  $n$  wächst. Die Anzahl der möglichen Partitionierungen kann in diesem Fall durch die sog. *Bellsche Zahl*  $B_n$  angegeben werden, die durch *Dobińskis Formel*  $B_n = \frac{1}{e} \cdot \sum_{k=0}^{\infty} \frac{k^n}{k!}$  [23] berechnet wird. Beispielsweise ist die Anzahl der möglichen Partitionierungen für 50 Elemente  $B_{50} \approx 1,86 \cdot 10^{47}$ . Das Berechnen von vorgegebenen, gültigen Partitionen und das Finden einer optimalen Partitionierung ist demnach mit extremen Aufwand verbunden.

In dem in diesem Kapitel betrachteten *Partitionierungsproblem* (PP) [12] werden im Gegensatz zum SPP aufgrund der schier unendlichen Anzahl möglicher Partitionen diese nicht im Voraus berechnet und vorgegeben. Zwar werden im PP nicht wie im vollständigen SPP alle möglichen Partitionierungen als gültig angesehen, allerdings sind im PP gültige Partitionen lediglich durch eine minimale Partitionsgröße  $s_{\min}$  und eine maximale Partitionsgröße  $s_{\max}$  sowie Partitionierungen durch eine minimale Anzahl an Partitionen  $n_{\min}$  und eine maximale Anzahl an Partitionen  $n_{\max}$  beschränkt, den sog. *Partitionierungsbedingungen*. Des Weiteren werden im Vergleich zum SPP keinerlei Annahmen bezüglich den Kosten einer Partitionierung bzw. der Zielfunktion gemacht – im SPP sind diese für jede Partition vorgegeben und müssen additiv sein. Stattdessen werden im PP beliebige Zielfunktionen bzw. Metriken erlaubt, die eine Partitionierung bewerten können; dadurch ist es möglich, dass das PP beispielsweise zur *Formierung von Koalitionen* (siehe z. B. [101]), für *strikt partitionierendes Clustering* (wie z. B. k-means [71]), für *Anticlustering* (siehe [114]) oder für eine *homogene Partitionierung* [12] gelöst

### 4.3. Ausbildung von Autonomen Verbraucherorganisationen mittels PSO

wird.

Partitionierungsprobleme werden in Multiagentensystemen von verschiedenen Algorithmen in einer Vielzahl von Anwendungsgebieten gelöst. So kommen derartige Algorithmen beispielsweise in Sensornetzen [122], in Produktionszellen [8], Kommunikationssystemen [3] oder im E-Commerce [26] zum Einsatz. Algorithmen, die das PP lösen, sind allerdings entweder (1) auf ein bestimmtes Problem in einer bestimmten Domäne spezialisiert – wie z. B. die zuvor genannten Beispiele –, (2) hängen von den Eigenschaften der Zielfunktion ab – wie z. B. die zuvor genannte Additivität im SPP – oder (3) die Spezifizierung von gewünschten Eigenschaften der resultierenden Partitionierung in Form der Größe und Anzahl der Partitionen – den *Partitionierungsbedingungen* – sind entweder nicht (siehe z. B. [81]) oder nur eingeschränkt möglich, wie beispielsweise bei dem k-means-Algorithmus [71], bei welchem der Nutzer vor der Anwendung genau spezifizieren muss, wie viele Cluster gebildet werden sollen. In x-means [52], eine Erweiterung von k-means, muss die Anzahl der zu bildenden Cluster zwar nicht vorher festgelegt werden, allerdings ist es auch dort nicht möglich, für die Anwendung sinnvolle Bereiche für die Anzahl und Größe von Partitionen festzulegen.

In diesem Kapitel werden nun zwei verschiedene Algorithmen vorgestellt, die das PP im Allgemeinen lösen, d. h. nicht auf eine bestimmte Domäne oder Zielfunktion zugeschnitten sind, und die Partitionierungsbedingungen berücksichtigen. Beide können durch Formulierung einer entsprechenden Zielfunktion für zahlreiche Anwendungen eingesetzt werden. Während der im nächsten Abschnitt vorgestellte Algorithmus eine mit globalem Wissen arbeitende Metaheuristik ist, wird in Abschnitt 4.4 ein dezentraler, agentenbasierter Ansatz präsentiert, der auf Basis von lokalem bzw. regionalem Wissen das PP löst.

### 4.3. AUSBILDUNG VON AUTONOMEN VERBRAUCHERORGANISATIONEN MIT EINEM PARTIKELSCHWARMOPTIMIERER

In diesem Abschnitt wird der Algorithmus *Particle Swarm Optimizer for the Partitioning Problem* (PSOPP) vorgestellt, der zuerst in [13] präsentiert und daraufhin in [12] in einer erweiterten Version publiziert wurde. Eine ausführliche Vorstellung von PSOPP inklusive einer verbesserten Bewegungsoperation findet in der Dissertation von Anders [5] statt. Die erweiterte Version [12],

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

mit der verbesserten Bewegungsoperation [5], wird in diesem Abschnitt zusammengefasst. Eine ausführliche Evaluierung hinsichtlich verschiedener Zielfunktionen und einen Vergleich mit dem x-means-Algorithmus findet sich in [12] und in [5]; zudem erfolgt ein detaillierter Vergleich von PSOPP mit dem agenten-basierten Ansatz SPADA (siehe Abschnitt 4.4) von Anders in seiner Dissertation [5].

PSOPP basiert auf der *Partikelschwarmoptimierung* (PSO) [55], eine Metaheuristik zur Suche von optimalen Lösungen in Optimierungsproblemen mit großen Suchräumen – ein Ansatz, den andere Ansätze aus der Literatur aufgrund des großen Suchraums des SPP bzw. PP ebenfalls verfolgen, indem sie beispielsweise ebenfalls Partikelschwarmoptimierung oder *Genetische Algorithmen* einsetzen (siehe z. B. [35, 4, 74]).

Wie zuvor bereits in Abschnitt 4.2 genannt, sind diese und die zuvor genannten Ansätze jedoch nicht für eine allgemeine Lösung des PP unter Berücksichtigung von Partitionierungsbedingungen anwendbar. Im Gegensatz dazu löst PSOPP das PP im Allgemeinen und ermöglicht zudem die Berücksichtigung von Partitionierungsbedingungen, also die Berücksichtigung von minimalen und maximalen Partitionsgrößen und einer minimalen und maximalen Anzahl an Partitionen. Das grundlegende Prinzip, auf dem PSOPP beruht, ist das iterative Anwenden von Mengenoperationen auf Partitionierungen; die Mengenoperationen machen dabei keinerlei Annahmen bzgl. der Zielfunktion und können daher für Partitionierungsprobleme mit beliebiger Zielfunktion eingesetzt werden. In PSOPP werden diese Operationen so angewandt, dass ausgehend von einer gültigen Partitionierung die erhaltene Partitionierung stets valide ist (d. h. eine Lösung des Partitionierungsproblems unter Berücksichtigung der Partitionierungsbedingungen); dies hat zum einen den Vorteil, dass der Suchraum kleiner ist und effizienter durchsucht werden kann und zum anderen, dass PSOPP wie viele andere Algorithmen zur Lösung eines Partitionierungsproblems ein Anytime-Algorithmus ist und somit jederzeit eine gültige Lösung zurückgeben kann, da er mit validen Partitionierungen initialisiert wird.

In Abschnitt 4.3.1 wird zuerst eine Einführung in Partikelschwarmoptimierung gegeben, woraufhin der Algorithmus PSOPP in Abschnitt 4.3.2 vorgestellt wird.

### 4.3. Ausbildung von Autonomen Verbraucherorganisationen mittels PSO

#### 4.3.1. EINFÜHRUNG IN PARTIKELSCHWARMOPTIMIERUNG

Zunächst wird im folgenden Abschnitt das grundlegende Prinzip von Partikelschwarmoptimierung eingeführt; eine Erweiterung dieser zur Anwendung auf diskrete Optimierungsprobleme erfolgt im darauf folgenden Abschnitt.

##### *Grundlegendes Prinzip von Partikelschwarmoptimierung*

Die von Kennedy und Eberhart vorgeschlagene Partikelschwarmoptimierung (PSO) [55] ist eine bio-inspirierte Metaheuristik zum Finden von Lösungen in Optimierungsproblemen. Vorbild von PSO ist das in der Natur beobachtbare Schwarmverhalten von Vögeln oder Fischen. Analog zu diesen bewegt sich in der PSO ein Schwarm von *Partikeln* in einem  $n$ -dimensionalen, kontinuierlichen *Suchraum*. Dabei repräsentiert die *Position* eines Partikels eine mögliche Lösung des Optimierungsproblems. Die Partikel *bewegen* sich *iterativ* mit einer bestimmten *Geschwindigkeit* durch den Suchraum mit dem Ziel, eine möglichst optimale Lösung zu finden. Die Qualität einer Lösung wird durch eine Fitnessfunktion bewertet, die eine Lösung umso höher bewertet, desto besser sie ist. Die Partikel explorieren jedoch nicht nur zufällig den Suchraum, sondern angelehnt an das Schwarmverhalten aus der Natur orientieren sie sich zudem auch an ihren benachbarten Schwarmgenossen. So ist jedem Partikel  $\Pi_i$  neben seiner bisher persönlich besten gefundenen Lösung  $B_i$  auch die bisher in seiner Nachbarschaft  $\mathcal{N}_i$  beste gefundene Lösung  $B_{\mathcal{N}_i}$  bekannt.<sup>21</sup> Die Beeinflussung der Bewegung eines Partikels durch diese zwei Positionen erlaubt das Exploitieren des Suchraums an Stellen, die sich bisher als relativ gut herausgestellt haben – mit der Hoffnung, in der dortigen Gegend oder auf dem Weg dort hin eine noch bessere Lösung zu finden. Konkret wird für den Partikel  $\Pi_i$  die Position  $x_i(t+1)$  für die nächste Iteration  $t+1$  auf Basis der aktuellen Position  $x_i(t)$  und der Geschwindigkeit  $v_i(t+1)$  für die nächste Iteration wie folgt bestimmt:

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (4.1)$$

$$v_i(t+1) = \omega \cdot v_i(t) + c_1 \cdot r_1 \cdot (B_i - x_i(t)) + c_2 \cdot r_2 \cdot (B_{\mathcal{N}_i} - x_i(t)) \quad (4.2)$$

mit  $\omega, c_1, c_2 \in \mathbb{R}_0^+$ ,  $r_1, r_2 \in [0, 1]$ , und  $\forall t : x_i(t), v_i(t), B_i, B_{\mathcal{N}_i} \in \mathbb{R}^n$

<sup>21</sup> Die Topologie der Nachbarschaft von Partikeln kann je nach Anwendung variieren; auch eine Vollvermaschung ist denkbar.

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

Die Geschwindigkeit  $v_i(t+1)$  der Iteration  $t+1$  hängt dabei neben der bisher persönlich besten gefundenen Lösung  $B_i$  und der bisher in der Nachbarschaft besten gefundenen Lösung  $B_{N_i}$  auch von der vorigen Geschwindigkeit  $v_i(t)$  ab. Die Konstanten  $\omega$ ,  $c_1$ , und  $c_2$  ermöglichen die Gewichtung der einzelnen Elemente der Geschwindigkeitsbestimmung und legen somit die Neigung der Partikel zur Exploration oder Exploitation fest. Die Zufallszahlen  $r_1$  und  $r_2$  sorgen für ein gewisses stochastisches Verhalten der Partikel und werden für jeden Partikel in jeder Iteration neu generiert. Haben alle Partikel terminiert, wird die global beste gefundene Lösung  $B$  als Ergebnis der PSO zurückgegeben. Mögliche Terminierungskriterien sind beispielsweise eine maximale Laufzeit, eine maximale Anzahl an Iterationen bzw. Bewegungen durch den Suchraum, das Erreichen eines vorher festgelegten minimalen Fitnesswerts oder auch eine Kombination dieser Möglichkeiten.

##### Diskrete Partikelschwarmoptimierung

Die im vorigen Abschnitt definierte PSO ist nur auf kontinuierliche Optimierungsprobleme anwendbar, allerdings nicht auf diskrete Optimierungsprobleme wie dem PP. Kennedy und Eberhart [56] haben daher eine Erweiterung der PSO auf  $n$ -dimensionale, binäre Suchräume eingeführt, die *Diskrete Partikelschwarmoptimierung* (dPSO). Die Positionen von Partikeln werden dort als Werte der Domäne  $\{0, 1\}^n$  definiert; die Bestimmung der Position eines Partikels in der nächsten Iteration erfolgt mittels einer angepassten Berechnung der Geschwindigkeit [56].

Einen anderen dPSO-Ansatz haben Garcia und Perez mit der *Jumping Particle Swarm Optimization* (jPSO) vorgestellt [44]. In jPSO bewegen sich die Partikel – unabhängig von einer Geschwindigkeit – durch den Suchraum indem sie von einer Position zur nächsten Position „hüpfen“:

$$x_i(t+1) = \begin{cases} \text{rdm}(x_i(t)) & \text{falls } r_i \leq c_{\text{rdm}} \\ \text{appr}(x_i(t), B_i) & \text{falls } c_{\text{rdm}} < r_i \leq c_{B_i}^* \\ \text{appr}(x_i(t), B_{N_i}) & \text{falls } c_{B_i}^* < r_i \leq c_{B_{N_i}}^* \\ \text{appr}(x_i(t), B) & \text{ansonsten} \end{cases} \quad (4.3)$$

mit  $c_{\text{rdm}}, c_{B_i}, c_{B_{N_i}}, c_B \in [0, 1]$ ,  $c_{\text{rdm}} + c_{B_i} + c_{B_{N_i}} + c_B = 1$ ,

$r_i \in [0, 1]$ ,  $c_{B_i}^* = c_{\text{rdm}} + c_{B_i}$ , und  $c_{B_{N_i}}^* = c_{\text{rdm}} + c_{B_i} + c_{B_{N_i}}$

### 4.3. Ausbildung von Autonomen Verbraucherorganisationen mittels PSO

Abhängig von der für jeden Partikel in jeder Iteration neu generierten gleichverteilten Zufallszahl  $r_i$  und den konstanten Wahrscheinlichkeiten  $c_{rdm}$ ,  $c_{B_i}$ ,  $c_{B_{N_i}}$  und  $c_B$  führt ein Partikel entweder eine Zufallsbewegung  $rdm(x_i(t))$  oder eine Annäherungsbewegung an die bisher persönlich beste gefundene Lösung  $appr(x_i(t), B_i)$ , an die bisher beste in der Nachbarschaft gefundene Lösung  $appr(x_i(t), B_{N_i})$  oder an die bisher beste global gefundene Lösung  $appr(x_i(t), B)$  aus. Durch entsprechende Festlegung der Wahrscheinlichkeiten  $c_{rdm}$ ,  $c_{B_i}$ ,  $c_{B_{N_i}}$  und  $c_B$  lässt sich somit wie in der ursprünglichen PSO das Verhalten eines Partikels hinsichtlich Exploration und Exploitation gewichten.

#### 4.3.2. EIN PARTIKELSCHWARMOPTIMIERER ZUR LÖSUNG DES PARTITIONIERUNGSPROBLEMS

In diesem Abschnitt wird nun PSOPP vorgestellt, ein diskreter Partikelschwarmoptimierer, der das Partitionierungsproblem löst und von JPSO inspiriert ist.

Wie in der PSO repräsentiert auch in PSOPP ein Partikel eine mögliche Lösung des Optimierungsproblems; in diesem Fall also eine Lösung des PP, d. h. eine Partitionierung der Menge von Agenten  $\mathcal{A}$ , welche die Partitionierungsbedingungen berücksichtigt. Demnach stellt die Position  $x_i(t)$  eines Partikels  $\Pi_i$  eine Partitionierung  $\mathcal{P}$  dar, die aus  $n_{min} \leq |\mathcal{P}| \leq n_{max}$  Partitionen besteht; jede Partition  $K \in \mathcal{P}$  enthält  $s_{min} \leq |K| \leq s_{max}$  Elemente.

Die Geschwindigkeit spielt wie in der JPSO bei der Bewegung eines Partikels in PSOPP keine Rolle. Dafür wird die Bewegung eines Partikels von seiner bisher persönlich besten gefundenen Lösung  $B_i$  und der bisher in seiner Nachbarschaft besten gefundenen Lösung  $B_{N_i}$  beeinflusst. Obwohl es für PSOPP kein Problem wäre, die Bewegung eines Partikels wie in der JPSO auch von der bisher global besten gefundenen Lösung  $B$  beeinflussen zu lassen, wird diese Funktionalität hier aus Gründen der Einfachheit bewusst weggelassen. Das bedeutet, übertragen auf Gleichung (4.3), dass  $c_B = 0$ .

Die in den späteren Abschnitten näher vorgestellten Zufalls- und Annäherungsbewegungen der Partikel stellen sicher, dass die Partitionierungsbedingungen während einer Bewegung nicht verletzt werden. Da der Suchraum dadurch nur noch gültige Lösungen des PP enthält, kann er deutlich eingeschränkt werden und die Suche nach optimalen Lösungen daher effizienter ablaufen.

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

Bevor nun die Bewegungsoperationen der Partikel in PSOPP vorgestellt werden, wird im folgenden Abschnitt das grundsätzliche Vorgehen von PSOPP beschrieben.

##### *Grundsätzliches Vorgehen des Algorithmus*

PSOPP beginnt zunächst damit, die gewünschte Anzahl an Partikeln zu erstellen und sie auf initiale Positionen im Suchraum zu setzen. Das können zufällig generierte Partitionierungen sein oder auch vordefinierte Partitionierungen, wie z. B. eine aktuell vorliegende Partitionierung bei einer Reorganisation der Systemstruktur. Sowohl die zufällig generierten Positionen als auch die vordefinierten Positionen müssen allerdings die Partitionierungsbedingungen einhalten.

Danach durchkämmen alle Partikel gleichzeitig iterativ so lange den Suchraum auf der Suche nach besseren Lösungen, bis ein Terminierungskriterium eingetreten ist. Im Detail führt ein Partikel  $\Pi_i$  in jeder Iteration die folgenden Aktionen aus (siehe auch Abbildung 4.2):

1. Evaluation der Fitness  $f(\mathcal{P})$  der repräsentierten Partitionierung  $\mathcal{P}$ .
2. Aktualisierung der bisher persönlich besten gefundenen Lösung  $B_i$  auf  $\mathcal{P}$ , falls die Fitness  $f(\mathcal{P})$  des Partikels besser ist als die Fitness  $f(B_i)$ . Außerdem Information aller anderen Partikel  $\Pi_j$ , die  $\Pi_i$  in ihrer Nachbarschaft  $\mathcal{N}_j$  enthalten, über die persönlich beste gefundene Lösung, so dass diese  $B_{\mathcal{N}_j}$  aktualisieren können – die beste in ihrer Nachbarschaft gefundene Lösung.
3. Aktualisierung der bisher in der Nachbarschaft  $\mathcal{N}_i$  besten gefundenen Lösung  $B_{\mathcal{N}_i}$ .
4. Terminierung, falls ein Terminierungskriterium eingetreten ist.
5. Ansonsten Bestimmung der nächsten Bewegung, indem eine Zufallszahl  $r_i \in [0, 1]$  auf Basis einer Gleichverteilung generiert wird. Diese Zufallszahl bestimmt, ob eine zufällige Bewegung oder eine Annäherungsbewegung angewandt wird und – im Falle einer Annäherungsbewegung – ob  $B_i$  oder  $B_{\mathcal{N}_i}$  angenähert wird (siehe Gleichung (4.3)).
6. Bestimmung der neuen Position  $\mathcal{P}'$  durch Anwendung der gewählten Bewegungsoperation auf  $\mathcal{P}$ .

### 4.3. Ausbildung von Autonomen Verbraucherorganisationen mittels PSO

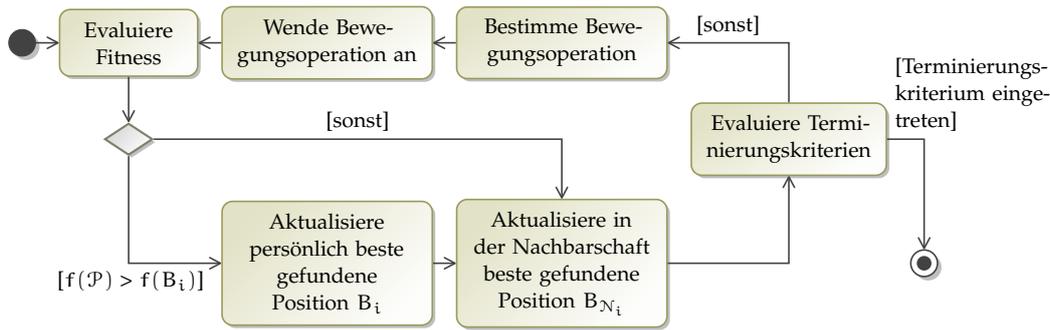


Abbildung 4.2.: Grundsätzliches Vorgehen eines Partikels in PSOPP, dargestellt als UML-Aktivitätsdiagramm (nach [12]).

Sobald alle Partikel terminiert haben, gibt PSOPP die beste gefundene Lösung  $B$  zurück; die Terminierungskriterien können je nach Anwendungsfall gewählt sein (siehe Abschnitt 4.3.1).

Im Folgenden werden die verschiedenen Bewegungsoperationen der Partikel vorgestellt. Zuerst werden die elementaren Bewegungsoperationen anhand der Zufallsbewegungen erklärt, bevor anschließend die Annäherungsbewegungen folgen.

#### Zufällige Bewegungen im Suchraum

Generell ist in PSOPP die Bewegung eines Partikels sowohl für Zufalls- als auch für Annäherungsbewegungen durch die Mengenoperationen *Split* und *Join* umgesetzt [18], die auf die repräsentierte Partitionierungen angewandt werden. Der angewandte Operator wird bei einer Bewegung zufällig bestimmt; kann der Operator nicht ohne eine Verletzung der Partitionierungsbedingungen angewandt werden, wird der andere Operator gewählt. Sind beide Operatoren aus diesem Grund nicht anwendbar, wird in PSOPP ein *Exchange* ausgeführt. Alle drei Operationen sind so ausgelegt, dass sie die Partitionierungsbedingungen berücksichtigen und die neu entstehende Partitionierung diese einhält.

Wie in [12] dient das Beispiel  $\mathcal{P}_* = \{\{a_1, a_2, a_4, a_5\}, \{a_3, a_6\}, \{a_7, a_8\}\}$  mit den enthaltenen Partitionen  $K_* = \{a_1, a_2, a_4, a_5\}$ ,  $L_* = \{a_3, a_6\}$  und  $M_* = \{a_7, a_8\}$  sowie den Partitionierungsbedingungen  $s_{\min} = n_{\min} = 2$  und  $s_{\max} = n_{\max} = 4$  im Folgenden der Illustration der vorgestellten Operationen.

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

**ZUFALLS-SPLIT** Die Split-Operation teilt eine *zufällig teilbare Partition*  $K \in \mathcal{P}$  in zwei neue, nichtleere, disjunkte Partitionen  $L$  und  $M$ , so dass  $K = L \cup M$ . Für die neu entstandene Partitionierung  $\mathcal{P}'$  gilt somit  $\mathcal{P}' = (\mathcal{P} \setminus \{K\}) \cup \{L, M\}$ . Die Split-Operation kann jedoch nur angewandt werden, wenn dadurch die Partitionierungsbedingungen nicht verletzt werden. Einerseits muss die Partition  $K$  groß genug sein ( $|K| \geq 2 \cdot s_{\min}$ ), so dass die zwei neu entstandenen Partitionen auch noch groß genug sind und die erforderliche minimale Partitionsgröße  $s_{\min}$  einhalten ( $|L|, |M| \geq s_{\min}$ ). Andererseits darf die Partitionierung  $\mathcal{P}$  nicht bereits  $n_{\max}$  Partitionen enthalten, denn die Anwendung des Split-Operators erhöht die Anzahl der enthaltenen Partitionen in  $\mathcal{P}'$  um 1 gegenüber  $\mathcal{P}$ . Die Menge von *zufällig teilbaren Partitionen*  $\sigma_{\text{rdm}}(\mathcal{P})$  ist somit wie folgt definiert:

$$\sigma_{\text{rdm}}(\mathcal{P}) := \{K \mid K \in \mathcal{P} \wedge |K| \geq 2 \cdot s_{\min} \wedge |\mathcal{P}| < n_{\max}\}$$

In dem Beispiel  $\mathcal{P}_*$  ist nur  $K_* = \{a_1, a_2, a_4, a_5\}$  zufällig teilbar, woraus sich beispielsweise die Partitionierung  $\mathcal{P}'_* = \{\{a_1, a_2\}, \{a_4, a_5\}, \{a_3, a_6\}, \{a_7, a_8\}\}$  ergeben könnte.

**ZUFALLS-JOIN** Die Join-Operation vereinigt eine *zufällig zusammenführbare Partition*  $K \in \mathcal{P}$  und ein *zufällig zusammenführbares Gegenstück*  $L \in \mathcal{P}$  (mit  $K \neq L$ ) in eine neue Partition  $M$ , so dass  $K \cup L = M$ . Für die neu entstandene Partitionierung  $\mathcal{P}'$  gilt somit  $\mathcal{P}' = (\mathcal{P} \setminus \{K, L\}) \cup \{K \cup L\}$ . Damit  $M$  die maximale Größe  $s_{\max}$  nicht überschreitet, müssen  $K$  und  $L$  klein genug sein ( $|K| + |L| \leq s_{\max}$ ). Außerdem darf  $\mathcal{P}$  nicht nur aus  $n_{\min}$  Partitionen bestehen, da der Join die Anzahl der enthaltenen Partitionen um 1 erniedrigt. Die Menge von *zufällig zusammenführbaren Partitionen*  $\iota_{\text{rdm}}(\mathcal{P})$  und *zufällig zusammenführbaren Gegenstücken*  $\iota_{\text{rdm}}^{\leftrightarrow}(K, \mathcal{P})$  ist somit wie folgt definiert:

$$\begin{aligned} \iota_{\text{rdm}}(\mathcal{P}) &:= \{K \mid K \in \mathcal{P} \wedge \iota_{\text{rdm}}^{\leftrightarrow}(K, \mathcal{P}) \neq \emptyset \wedge |\mathcal{P}| > n_{\min}\} \\ \iota_{\text{rdm}}^{\leftrightarrow}(K, \mathcal{P}) &:= \{L \mid L \in \mathcal{P} \wedge |K| + |L| \leq s_{\max} \wedge K \neq L\} \end{aligned}$$

In dem Beispiel  $\mathcal{P}_*$  sind  $L_* = \{a_3, a_6\}$  und  $M_* = \{a_7, a_8\}$  zufällig zusammenführbare Partitionen mit den zufällig zusammenführbaren Gegenstücken  $\{M_*\}$  bzw.  $\{L_*\}$ . Die Vereinigung von  $L_*$  und  $M_*$  ergibt  $\mathcal{P}'_* = \{\{a_1, a_2, a_4, a_5\}, \{a_3, a_6, a_7, a_8\}\}$ .

### 4.3. Ausbildung von Autonomen Verbraucherorganisationen mittels PSO

**ZUFALLS-EXCHANGE** Die Anwendung des Split- oder Join-Operators ist aufgrund der Partitionierungsbedingungen nicht immer möglich. Das ist offensichtlich der Fall, wenn  $s_{\min} = s_{\max}$  oder  $n_{\min} = n_{\max}$  gilt; aber auch in weniger eingeschränkten Fällen können solche Situationen auftreten, beispielsweise in der Partitionierung  $\mathcal{P} = \{\{a_1, a_2, a_3\}, \{a_4, a_5, a_6\}\}$  mit  $s_{\min} = 2$ ,  $s_{\max} = 4$ ,  $n_{\min} = 2$  und  $n_{\max} = 3$ . Damit die Partikel in solchen Situationen dennoch eine Bewegung ausführen können, bietet psopp einen Exchange-Operator an, der in einer einzigen Operation Elemente aus zwei Partitionen miteinander vertauscht.

Die Exchange-Operation vertauscht die echte Teilmenge  $\hat{K} \subset K$  (mit  $\hat{K} \neq \emptyset$  und  $|K| > 1$ ) und die Teilmenge  $\hat{L} \subseteq L$  ( $\hat{L}$  darf auch die leere Menge  $\emptyset$  sein) einer zufällig vertauschbaren Partition  $K \in \mathcal{P}$  und einem zufällig vertauschbaren Gegenstück  $L \in \mathcal{P}$ . Da  $\hat{K}$  eine nichtleere, echte Teilmenge von  $K$  ist und  $|K| > 1$ , sind auch die beiden neuen Partitionen nichtleer. Die Menge von zufällig vertauschbaren Partitionen  $\epsilon_{\text{rdm}}(\mathcal{P})$  und zufällig vertauschbaren Gegenständen  $\epsilon_{\text{rdm}}^{\leftrightarrow}(K, \mathcal{P})$  ist somit wie folgt definiert:

$$\begin{aligned}\epsilon_{\text{rdm}}(\mathcal{P}) &:\Leftrightarrow \{K \mid K \in \mathcal{P} \wedge |K| > 1\} \\ \epsilon_{\text{rdm}}^{\leftrightarrow}(K, \mathcal{P}) &:\Leftrightarrow \mathcal{P} \setminus \{K\}\end{aligned}$$

Der Austausch der zwei Teilmengen aus  $K$  und  $L$  muss allerdings sicherstellen, dass die neuen Partitionen  $K'$  und  $L'$  korrekte Partitionsgrößen zwischen  $s_{\min}$  und  $s_{\max}$  haben. Während die Größe der Partition  $\hat{K}$  zufällig zwischen 1 und  $|K| - 1$  gewählt werden kann, ist die Wahl der Größe der Partition  $\hat{L}$  abhängig von  $|\hat{K}|$ . Genauer muss  $|\hat{L}| \leq \min\{|L|, \min\{(|L| + |\hat{K}|) - s_{\min}, s_{\max} - (|K| - |\hat{K}|)\}\}$  und  $|\hat{L}| \geq \max\{(|L| + |\hat{K}|) - s_{\max}, \max\{0, s_{\min} - (|K| - |\hat{K}|)\}\}$  für die zufällig bestimmte Menge  $\hat{L}$  gelten, damit die entstehende Partitionierung  $\mathcal{P}' = (\mathcal{P} \setminus \{K, L\}) \cup \{(K \setminus \hat{K}) \cup \hat{L}, (L \setminus \hat{L}) \cup \hat{K}\}$  die minimale und maximale Partitionsgrößen  $s_{\min}$  und  $s_{\max}$  einhält.

In dem Beispiel  $\mathcal{P}_*$  kann z. B.  $\hat{K}_* = \{a_1, a_2, a_5\}$  und  $\hat{M}_* = \{a_7\}$  zwischen  $K_*$  und  $M_*$  ausgetauscht werden, was  $\mathcal{P}'_* = \{\{a_4, a_7\}, \{a_3, a_6\}, \{a_1, a_2, a_5, a_3\}\}$  ergibt.

#### Annäherung an andere Positionen

Während sich der vorherige Abschnitt auf Zufallsbewegungen der Partikel konzentriert hat, stehen in diesem Abschnitt Annäherungsbewegungen im Fokus. Wie bei der Auswahl des Operators der Zufallsbewegung wird auch

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

der Operator der Annäherungsbewegung zufällig gewählt. Die Annäherungsoperatoren stellen zudem sicher, dass nach deren Anwendung die Partitionierungsbedingungen weiter eingehalten werden.

Ziel einer Annäherungsbewegung ist es, die Ähnlichkeit zwischen der aktuellen und der anzunähernden Partitionierung zu erhöhen. Um zu verstehen, was das konkret für eine Annäherungsbewegung bedeutet, wird nachfolgend die *Ähnlichkeit von Partitionierungen* definiert, deren Definition Kudo und Murai [65] aufgestellt haben.

Die Ähnlichkeit von zwei Partitionierungen  $\mathcal{P}, \mathcal{Q}$  baut auf der Definition der *Schnittmenge von Partitionierungen* auf [65], die daher zuerst eingeführt wird:

$$\mathcal{P} \cap \mathcal{Q} := \{K \cap L \mid K \in \mathcal{P} \wedge L \in \mathcal{Q} \wedge K \cap L \neq \emptyset\} \quad (4.4)$$

Die Schnittmenge  $\mathcal{P} \cap \mathcal{Q}$  zweier Partitionierungen  $\mathcal{P}, \mathcal{Q}$  ist somit die Menge aller nichtleeren Schnittmengen von Partitionen in  $\mathcal{P}$  und  $\mathcal{Q}$ . Zum Beispiel ist  $\mathcal{S} \cap \mathcal{Q} = \{\{a_1, a_2\}, \{a_3\}, \{a_4\}\}$  die Schnittmenge von  $\mathcal{S} = \{\{a_1, a_2\}, \{a_3, a_4\}\}$  und von  $\mathcal{Q} = \{\{a_1, a_2, a_3\}, \{a_4\}\}$ .

Darauf aufbauend ist die Ähnlichkeit von Partitionierungen wie folgt definiert [65]:

$$\text{sim}(\mathcal{P}, \mathcal{Q}) := \frac{|\mathcal{P}| + |\mathcal{Q}|}{2 \cdot |\mathcal{P} \cap \mathcal{Q}|} \quad (4.5)$$

Die Ähnlichkeit  $\text{sim}(\mathcal{P}, \mathcal{Q}) \in ]0, 1]$  von zwei nichtleeren Partitionierungen  $\mathcal{P}, \mathcal{Q}$  ist folglich direkt proportional zu dem Verhältnis von der Summe ihrer Kardinalitäten zu der Kardinalität ihrer Schnittmenge. Somit steigt die Ähnlichkeit zweier Partitionierungen  $\mathcal{P}$  und  $\mathcal{Q}$  je kleiner die Mächtigkeit der Schnittmenge  $\mathcal{P} \cap \mathcal{Q}$  ist. Das bedeutet, dass je mehr Elemente in den gleichen Partitionen in  $\mathcal{P}$  und  $\mathcal{Q}$  enthalten sind, desto kleiner ist  $|\mathcal{P} \cap \mathcal{Q}|$  und desto ähnlicher sind sich die zwei Partitionierungen  $\mathcal{P}$  und  $\mathcal{Q}$ . Die maximale Ähnlichkeit  $\text{sim}(\mathcal{P}, \mathcal{Q}) = 1$  wird genau dann erreicht, wenn  $\mathcal{P} = \mathcal{Q}$ , da dann  $\mathcal{P} \cap \mathcal{Q} = \mathcal{P} = \mathcal{Q}$  gilt. Die vorigen Beispiele aufgreifend, ist die Ähnlichkeit  $\text{sim}(\mathcal{S}, \mathcal{Q}) = \frac{2+2}{2 \cdot 3} = \frac{4}{6}$  kleiner als die Ähnlichkeit  $\text{sim}(\mathcal{P}, \mathcal{Q}) = \frac{3+2}{2 \cdot 3} = \frac{5}{6}$ .

Gemäß der Definition der Ähnlichkeit kann sich die Ähnlichkeit zweier Partitionierungen  $\mathcal{P}$  und  $\mathcal{Q}$  beispielsweise durch die Vergrößerung der Anzahl der Partitionen in  $\mathcal{P}$  ohne Veränderung der Größe der Schnittmenge  $|\mathcal{P} \cap \mathcal{Q}|$  erhöhen. Das kann erreicht werden, indem eine Partition aus  $\mathcal{P}$  aufgeteilt wird, deren Elemente in zwei oder mehr Partitionen in

### 4.3. Ausbildung von Autonomen Verbraucherorganisationen mittels PSO

$\mathcal{Q}$  enthalten sind. Die Ähnlichkeit kann zudem durch Verkleinerung der Größe der Schnittmenge  $|\mathcal{P} \cap \mathcal{Q}|$  erhöht werden. Dazu muss eine Join- oder Exchange-Operation ausgeführt werden, welche Elemente vereinigt, die in  $\mathcal{Q}$  in einer einzelnen Partition enthalten, in  $\mathcal{P}$  jedoch in zwei oder mehr Partitionen enthalten sind. Am Rande sei bemerkt, dass die Definition der Ähnlichkeit lediglich zwei Partitionierungen hinsichtlich der Ähnlichkeit ihrer Zusammensetzung vergleicht, jedoch keinen Hinweis darauf gibt, wie viele Annäherungsoperationen auf eine Partitionierung angewandt werden müssen, um die Gleichheit der Partitionierungen herzustellen.

Im Folgenden werden die vorgestellten Operationen wie in [12] anhand der Partitionierung  $\mathcal{P}_* = \{\{a_1, a_2, a_4, a_5\}, \{a_3, a_6\}, \{a_7, a_8\}\}$  illustriert, welche die Partitionierung  $\mathcal{Q}_* = \{\{a_1, a_2\}, \{a_4, a_6, a_7\}, \{a_3, a_5, a_8\}\}$  annähert, wobei  $s_{\min} = n_{\min} = 2$  und  $s_{\max} = n_{\max} = 4$ .

**ANNÄHERUNGS-SPLIT** Wie sein Pendant bei den Zufallsbewegungen kann der Split-Operator für eine Annäherungsbewegung nur angewandt werden, wenn  $|\mathcal{P}| < n_{\max}$ . Zudem muss eine teilbare Partition  $K$  wiederum groß genug sein, um aufgeteilt zu werden. Partitionen, welche diese Eigenschaften erfüllen, sind Teil der Menge der *teilbaren Partitionen*  $\sigma(\mathcal{P}, \mathcal{Q})$ , die sich auf der Menge der *extrahierbaren Teilmengen*  $\sigma^\uparrow(K, \mathcal{P}, \mathcal{Q})$  stützt:

$$\begin{aligned} \sigma(\mathcal{P}, \mathcal{Q}) &:\Leftrightarrow \{K \mid K \in \mathcal{P} \wedge \sigma^\uparrow(K, \mathcal{P}, \mathcal{Q}) \neq \emptyset \wedge |\mathcal{P}| < n_{\max}\} \\ \sigma^\uparrow(K, \mathcal{P}, \mathcal{Q}) &:\Leftrightarrow \{L \mid L \in \mathcal{P} \cap \mathcal{Q} \wedge L \subset K \wedge |K \setminus L| \geq s_{\min} \wedge |L| \geq s_{\min}\} \end{aligned}$$

Die extrahierbare Teilmenge  $L \in \sigma^\uparrow(K, \mathcal{P}, \mathcal{Q})$  muss aus der Schnittmenge  $\mathcal{P} \cap \mathcal{Q}$  sein. Da  $L$  eine echte Teilmenge von  $K \in \mathcal{P}$  sein muss, kann der Annäherungs-Split-Operator daher nicht angewandt werden, wenn alle Partitionen aus  $\mathcal{P}$  Teilmengen von Partitionen aus  $\mathcal{Q}$  sind. Durch Anwendung dieses Operators erhöht sich die Ähnlichkeit zwischen  $\mathcal{P}$  und  $\mathcal{Q}$ , weil sich die Mächtigkeit von  $\mathcal{P}$  um 1 erhöht und sich die Schnittmenge der Partitionierungen nicht ändert, d. h.  $\mathcal{P}' \cap \mathcal{Q} = \mathcal{P} \cap \mathcal{Q}$ .

In dem Beispiel  $\mathcal{P}_*$  und  $\mathcal{Q}_*$  ist  $K_* = \{a_1, a_2, a_4, a_5\}$  die einzige teilbare Partition mit der extrahierbaren Teilmenge  $N_* = \{a_1, a_2\}$ .  $N_*$  ist zugleich das einzige Element von  $\sigma^\uparrow(K_*, \mathcal{P}_*, \mathcal{Q}_*)$ . Die Ausführung des Annäherungs-Splits ergibt somit die Partitionierung  $\mathcal{P}_*{}' = \{\{a_1, a_2\}, \{a_4, a_5\}, \{a_3, a_6\}, \{a_7, a_8\}\}$ .

**ANNÄHERUNGS-JOIN** Genau wie der Zufalls-Join kann der Annäherungs-Join nur angewandt werden, wenn  $|\mathcal{P}| > n_{\min}$ . Die *zusammenführbaren Par-*

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

titionen  $\iota(\mathcal{P}, \mathcal{Q})$  und die zusammenführbaren Gegenstücke  $\iota^{\leftrightarrow}(\mathcal{K}, \mathcal{P}, \mathcal{Q})$  sind wie folgt definiert [5]:<sup>22</sup>

$$\begin{aligned} \iota(\mathcal{P}, \mathcal{Q}) &: \Leftrightarrow \{K \mid K \in \mathcal{P} \wedge \iota^{\leftrightarrow}(\mathcal{K}, \mathcal{P}, \mathcal{Q}) \neq \emptyset \wedge |\mathcal{P}| > n_{\min}\} \\ \iota^{\leftrightarrow}(\mathcal{K}, \mathcal{P}, \mathcal{Q}) &: \Leftrightarrow \{L \mid L \in \mathcal{P} \wedge |K| + |L| \leq s_{\max} \wedge K \neq L \\ &\quad \wedge \underbrace{\exists \mathcal{R} \subseteq \mathcal{Q} : |\mathcal{R}| \geq x}_{C_1} \wedge \underbrace{\forall M \in \mathcal{R} : (M \cap K \neq \emptyset \wedge M \cap L \neq \emptyset)}_{C_2}\} \\ &\quad \text{mit } x = 1 + \left\lfloor \frac{|\mathcal{P} \cap \mathcal{Q}|}{|\mathcal{P}| + |\mathcal{Q}|} \right\rfloor \end{aligned}$$

Gegenüber dem Zufalls-Join sind die *zusammenführbaren Gegenstücke* um zwei zusätzliche Bedingungen  $C_1$  und  $C_2$  erweitert. Die Bedingung  $C_2$  stellt sicher, dass Elemente, die in einer einzigen Partition  $M \in \mathcal{Q}$  aber in  $\mathcal{P}$  in zwei verschiedenen Partitionen  $K$  und  $L$  enthalten sind, durch den Join zusammengeführt werden. Dementsprechend kann ein Annäherungs-Join nicht angewandt werden, wenn alle Partitionen aus  $\mathcal{Q}$  Teilmengen von Partitionen aus  $\mathcal{P}$  sind. Zwar verkleinert ein Annäherungs-Join die Größe der Partitionierung  $\mathcal{P}$  um 1, allerdings verringert sich gleichzeitig auch die Größe der Schnittmenge  $|\mathcal{P}' \cap \mathcal{Q}|$  um mindestens  $x$  – bedingt durch die Bedingung  $C_1$  in Kombination mit  $C_2$  –, wodurch sich die Ähnlichkeit zwischen  $\mathcal{P}$  und  $\mathcal{Q}$  erhöht.

In dem Beispiel  $\mathcal{P}_*$  und  $\mathcal{Q}_*$  ergibt sich  $x = 1 + \lfloor \frac{7}{3+3} \rfloor = 2$ . Für  $\mathcal{R} = \{\{a_4, a_6, a_7\}, \{a_3, a_5, a_8\}\} \subseteq \mathcal{Q}_*$  sind die Partitionen  $L_* = \{a_3, a_6\}$  und  $M_* = \{a_7, a_8\}$  zusammenführbare Partitionen mit den jeweiligen Gegenständen  $M_*$  und  $L_*$  [5]. Der Join ergibt  $\mathcal{P}'_* = \{\{a_1, a_2, a_4, a_5\}, \{a_3, a_6, a_7, a_8\}\}$ .

**ANNÄHERUNGS-EXCHANGE** Der Annäherungs-Exchange-Operator wird in Situationen ausgeführt, in denen kein Annäherungs-Split oder -Join möglich ist. Der Operator vertauscht Elemente einer nichtleeren echten Teilmenge  $\hat{K} \subset K$  mit einer möglicherweise leeren echten Teilmenge  $\hat{L} \subset L$  aus  $\mathcal{P}$  zwischen einer Partition  $K$  aus der Menge der *vertauschbaren Partitionen*  $\epsilon(\mathcal{P}, \mathcal{Q})$  und einer Partition  $L$  aus der Menge der *vertauschbaren Gegenstücke*  $\epsilon^{\leftrightarrow}(\mathcal{K}, \mathcal{P}, \mathcal{Q})$ , wobei  $2^{\mathcal{P} \cap \mathcal{Q}}$  die Potenzmenge der Schnittmenge  $\mathcal{P} \cap \mathcal{Q}$

<sup>22</sup> Dies ist die gegenüber der in [12] erfolgten Definition verbesserte Variante des Annäherungs-Joins aus [5].

### 4.3. Ausbildung von Autonomen Verbraucherorganisationen mittels PSO

bezeichnet:

$$\begin{aligned} \epsilon(\mathcal{P}, \mathcal{Q}) &: \Leftrightarrow \{K \mid K \in \mathcal{P} \wedge \epsilon^{\leftrightarrow}(K, \mathcal{P}, \mathcal{Q}) \neq \emptyset\} \\ \epsilon^{\leftrightarrow}(K, \mathcal{P}, \mathcal{Q}) &: \Leftrightarrow \left\{ L \mid L \in \mathcal{P} \wedge K \neq L \wedge \exists M \in \mathcal{Q} : \exists \hat{K} \subset K : \right. \\ &\left. \left( \hat{K} \cap M \neq \emptyset \wedge L \cap M \neq \emptyset \wedge \hat{K} \in 2^{\mathcal{P} \cap \mathcal{Q}} \wedge \left( \exists \hat{L} \subset L : \hat{L} \cap M = \emptyset \wedge \hat{L} \in 2^{\mathcal{P} \cap \mathcal{Q}} \right. \right. \right. \\ &\left. \left. \wedge s_{\min} \leq |(K \setminus \hat{K}) \cup \hat{L}| \leq s_{\max} \wedge s_{\min} \leq |(L \setminus \hat{L}) \cup \hat{K}| \leq s_{\max} \right) \right\} \end{aligned}$$

Das Ziel des Annäherungs-Exchange ist es, die Elemente  $\hat{K}$  und  $L \setminus \hat{L}$  zusammenzubringen, welche sich in  $\mathcal{Q}$  in der gemeinsamen Partition  $M$  befinden. Die zwei neuen Partitionen  $(K \setminus \hat{K}) \cup \hat{L}$  und  $(L \setminus \hat{L}) \cup \hat{K}$  müssen natürlich wieder die Partitionierungsbedingungen  $s_{\min}$  und  $s_{\max}$  einhalten.

Die Mächtigkeit der Partitionierung  $\mathcal{P}$  bleibt von der Anwendung des Operators unberührt. Die Größe der Schnittmenge  $|\mathcal{P} \cap \mathcal{Q}|$  reduziert sich allerdings mindestens um 1. Dies wird erreicht, indem zum einen  $\hat{L} \cap M = \emptyset$ ,  $\hat{K} \cap M \neq \emptyset$  und  $\hat{K} \in 2^{\mathcal{P} \cap \mathcal{Q}}$  sicherstellen, dass nicht nur Elemente von  $M$  zusammengebracht werden sondern auch die Anzahl der Partitionen, die Elemente aus  $M$  enthalten, um 1 reduziert wird. Zum anderen stellt  $\hat{L} \in 2^{\mathcal{P} \cap \mathcal{Q}}$  sicher, dass nicht eine bereits in der Schnittmenge  $\mathcal{P} \cap \mathcal{Q}$  enthaltene Teilmenge durch die Anwendung des Operators auseinandergebracht und auf zwei verschiedene Partitionen  $K$  und  $L$  aufgeteilt wird. Somit erhöht der Annäherungs-Exchange die Ähnlichkeit zwischen den Partitionierungen  $\mathcal{P}$  und  $\mathcal{Q}$ .

In dem Beispiel  $\mathcal{P}_*$  und  $\mathcal{Q}_*$  ist z. B.  $K_* = \{a_1, a_2, a_4, a_5\}$  eine vertauschbare Partition mit den vertauschbaren Gegenständen  $L_* = \{a_3, a_6\}$  und  $M_* = \{a_7, a_8\}$ . Beispielsweise könnten die Teilmengen  $\hat{K}_* = \{a_4\}$  und  $\hat{L}_* = \emptyset$  zwischen  $K_*$  und  $L_*$  vertauscht werden, wodurch sich die Partitionierung  $\mathcal{P}'_* = \{\{a_1, a_2, a_5\}, \{a_3, a_4, a_6\}, \{a_7, a_8\}\}$  ergibt.

In besonderen Fällen kann weder ein Exchange noch ein Split oder Join für eine Annäherungsbewegung an eine andere Position durchgeführt werden. Ein Beispiel hierfür und wie in solchen Situationen umgegangen werden kann findet sich in [12].

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

##### 4.4. AUSBILDUNG VON AUTONOMEN VERBRAUCHERORGANISATIONEN MIT EINEM AGENTEN-BASIERTEM ANSATZ

Fokus dieses Abschnitts ist der *Set Partitioning Algorithm for Distributed Agents* (SPADA), ein agenten-basierter Algorithmus zur Lösung des Partitionierungsproblems. SPADA ist inspiriert von einem dezentralen Clustering-Algorithmus von Ogston et al. [81] und wurde zunächst in einer einfachen Fassung in [15] veröffentlicht. Diese einfache Version [15] von SPADA beachtete jedoch keine Partitionierungsbedingungen wie die Größe und Anzahl der zu bildenden Partitionen. Darüber hinaus war es ihr nicht möglich, mit beliebigen Zielfunktionen für die Ausbildung von Partitionierungen zu arbeiten; beispielsweise konnte sie keine homogene Partitionierung [12] ausbilden. Eine substantiell überarbeitete Version von SPADA, die die Partitionierungsbedingungen respektiert und den Einsatz beliebiger Zielfunktionen zulässt und somit wie PSOPP das Partitionierungsproblem im Allgemeinen löst, wurde in [14] skizziert und in der Dissertation von Anders [5] ausführlich vorgestellt und evaluiert.

Obwohl sowohl PSOPP als auch SPADA das Partitionierungsproblem (PP) im Allgemeinen lösen, so unterscheiden sich die beiden Algorithmen wesentlich in ihrer Herangehensweise. Ist PSOPP eine bio-inspirierte Meta-Heuristik, die mit globalem Wissen arbeitet, ist SPADA ein agenten-basierter Ansatz, in dem die Agenten das PP selbst mit regionalem Wissen lösen. Ein Vorteil des regionalen Prinzips ist u. a., dass bei einer Reorganisation eine bestehende Partitionierung durch ausgewählte, regionale Veränderungen minimalinvasiv verändert werden kann und somit keine komplett neue Systemstruktur etabliert werden muss [14]. Ein Vergleich von PSOPP und SPADA, der die Stärken und Schwächen beider Ansätze unter verschiedenen Bedingungen beleuchtet, kann in der Dissertation von Anders [5] gefunden werden. So zeigt SPADA insbesondere in der multikriteriellen Optimierung Vorteile gegenüber PSOPP.

Dieser Abschnitt fasst nun die wesentlichen Eigenschaften von SPADA aus [15, 5] zusammen; eine ausführliche Darstellung kann in [5] gefunden werden. In Abschnitt 4.4.1 wird zunächst das zugrundeliegende Systemmodell vorgestellt [15], woraufhin Abschnitt 4.4.2 das prinzipielle Vorgehen des Algorithmus in Kürze zusammenfasst [5].

## 4.4. Agenten-basierte Ausbildung von Autonomen Verbraucherorganisationen

### 4.4.1. SYSTEMMODELL

Könnten zwar prinzipiell alle Agenten miteinander kommunizieren und interagieren, wird in SPADA auf einem Overlay-Netzwerk gearbeitet, was die Kommunikation und Interaktion zwischen den Agenten einschränkt und somit die Komplexität zur Lösung des PP reduziert. Dieses Overlay-Netzwerk besteht aus den teilnehmenden Agenten und den jeweils ihnen bekannten Agenten (den sog. *Acquaintances*) und wird *Acquaintances Graph* genannt. Der *Acquaintances Graph* ist ein gerichteter Graph, bestehend aus einer Menge von Knoten, welche die zu partitionierenden Agenten repräsentieren, und einer Menge von gerichteten Kanten, welche die *Acquaintances* zwischen den Agenten darstellen. Eine *Acquaintance* ist eine binäre Relation zwischen zwei Agenten und ist irreflexiv, nicht symmetrisch und nicht transitiv. Jeder Agent hat die gleiche Anzahl an *Acquaintances*, d. h. die Anzahl der ausgehenden Kanten pro Knoten ist gleich.

Partitionen werden im *Acquaintances Graph* durch Teilgraphen repräsentiert, die zueinander disjunkte Knoten enthalten. Zu diesem Zweck können die Kanten im *Acquaintances Graph* eine partitions-spezifische Markierung tragen. Diese Markierung drückt aus, dass die zwei assoziierten Agenten Teil der selben Partition sind. Die Bekanntschaftsbeziehung bleibt davon unberührt, d. h. die Markierung ist nur eine zusätzliche Information der Kante. Die Kanten im *Acquaintances Graph* werden daher in *markierte* und *unmarkierte Kanten* unterschieden. Eine Partition wird über die Menge der Agenten gekennzeichnet, die transitiv über markierte Kanten miteinander verbunden sind, welche die gleiche partitions-spezifische Markierung tragen; genauer gesagt werden Partitionen über die reflexiv-transitive Hülle der binären Relation der markierten Kanten definiert. Ein exemplarischer *Acquaintances Graph* ist in Abbildung 4.3 dargestellt.

Jede Partition besitzt einen ausgewählten Anführer, welcher Veränderungen an der Partitionierung vornehmen kann. Anführer einer Partition kann prinzipiell jeder Agent sein – innerhalb einer Partition ist jedoch nur ein Agent der Anführer. Dies ermöglicht einen geordneteren Ablauf und vermeidet inkonsistente Zustände. Agenten, die nicht Anführer einer Partition sind, nehmen nicht aktiv an der Veränderung der Partitionierung teil, können dieses Amt aber ggf. von einem aus der Partition ausscheidenden Anführer übernehmen.

Änderungen an der Partitionierung bilden auf Graphoperationen ab,

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

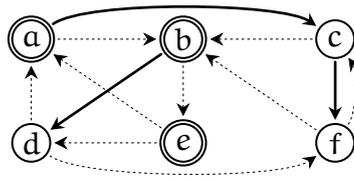


Abbildung 4.3.: Exemplarischer Acquaintances Graph für ein System von sechs Agenten (Quelle: [14]). Knoten stellen Agenten dar, die gerichteten Kanten Acquaintances; so hat beispielsweise der Agent d die Agenten a und f als Acquaintance. Die dicken Kanten repräsentieren markierte Kanten und kennzeichnen somit, dass die assoziierten Agenten Teil der selben Partition sind. Die Anführer einer Partition sind durch die doppelte Umrandung des Agenten gekennzeichnet. In dem in diesem Beispiel vorliegenden System gibt es somit die drei Partitionen  $\{a, c, f\}$ ,  $\{b, d\}$  und  $\{e\}$  mit den jeweiligen Anführern a, b und e.

welche die Markierungen auf Acquaintances ändern aber auch unter Umständen die Acquaintances selbst ändern können. Wird beispielsweise ein Agent von einer Partition in eine andere Partition integriert, müssen die Markierungen der alten Partition auf den eingehenden und ausgehenden Kanten des Agenten entfernt werden, die Markierung auf einer eingehenden Kante des Agenten, ausgehend von der neuen Partition, gesetzt werden und möglicherweise entstandene „Lücken“ in der transitiven Verbindung der Partitionsmitglieder der alten Partition geschlossen werden. Im einfachen Fall sind die voneinander getrennten Teile untereinander über Acquaintances bekannt und können über das Setzen einer Markierung die ordnungsgemäße Verbindung der Partition wieder herstellen; waren diese getrennten Teile der alten Partition allerdings nur über den aus der Partition entfernten Agenten bekannt, müssen neue Acquaintances zwischen diesen Teilen erstellt werden – unter Berücksichtigung der konstanten Anzahl an Acquaintances pro Knoten, d. h. es müssen auch Acquaintances an anderer Stelle entfernt werden. Ein Beispiel für das Entfernen eines Agenten aus einer Partition wird in Abbildung 4.4 dargestellt.

Eine wichtige Voraussetzung für das Gelingen des Algorithmus ist, dass der Acquaintances Graph schwach zusammenhängend ist. Gibt es beispielsweise zwei voneinander getrennte Teile des Acquaintances Graphs, wissen die Agenten aus dem einem Teil nichts von den Agenten aus dem anderen Teil und können somit weder miteinander agieren noch Agenten miteinander austauschen. Daher müssen sowohl die Initialisierung des

#### 4.4. Agenten-basierte Ausbildung von Autonomen Verbraucherorganisationen

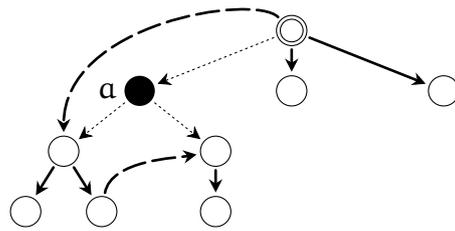


Abbildung 4.4.: Exemplarisches Entfernen des Agenten  $\alpha$  aus einer Partition im Acquaintances Graph (nach [15]). Zur Vereinfachung ist in dieser Darstellung nur ein Ausschnitt des Acquaintances Graphs dargestellt. Wie zuvor stellen die gerichteten Kanten die Acquaintances dar, wobei markierte Kanten durch die dicken Linien gekennzeichnet sind; der doppelt umrahmte Agent repräsentiert den Anführer. Durch das Entfernen von  $\alpha$  aus der Partition werden alle in  $\alpha$  eingehenden und alle von  $\alpha$  ausgehenden markierten Kanten zu unmarkierten Kanten (gestrichelte, dünne Kanten). Die durch das Entfernen von  $\alpha$  entstandenen voneinander getrennten Teile der Partition müssen durch neu erstellte markierte Kanten wieder verbunden werden (dargestellt durch die gestrichelten, dicken Kanten).

Acquaintances Graphs als auch die Graphoperationen auf dem Acquaintances Graph derart gestaltet sein, dass ein schwacher Zusammenhang des Acquaintances Graph besteht und erhalten bleibt. [5] beschreibt im Detail Graphoperationen auf dem Acquaintances Graph, die den schwachen Zusammenhang garantieren.

##### 4.4.2. GRUNDSÄTZLICHES VORGEHEN DES ALGORITHMUS

SPADA beginnt zunächst damit, den Acquaintances Graph für die zu partitionierenden Agenten zu initialisieren. Dieser wird ausgehend von der SPADA zur Verfügung gestellten initialen Partitionierung generiert. Wie auch bei PSOPP kann die initiale Partitionierung im Falle einer Reorganisation die aktuell vorhandene, zu reorganisierende Systemstruktur sein. Ebenso ist eine zufällig generierte Partitionierung möglich; bei solch einer ist aber darauf zu achten, dass diese die Partitionierungsbedingungen berücksichtigt. Für die Generierung des initialen Acquaintances Graphs muss für jede Partition der initialen Partitionierung ein gerichteter Graph bestehend aus markierten Kanten generiert werden, die jeweils die eindeutige, partitions-spezifische Markierung tragen, so dass jede Partition über die reflexiv-transitive Hülle der markierten Kanten definiert ist. Neben den markierten Kanten für die

#### 4. Selbst-organisierte Ausbildung von Autonomen Verbraucherorganisationen

Repräsentation der Partitionen müssen zusätzlich noch die unmarkierten Kanten generiert werden. Diese können zufällig generiert werden; allerdings derart, dass zum einen jeder Knoten die gleiche Anzahl an ausgehenden Kanten hat und zum anderen der Acquaintances Graph schwach zusammenhängend ist, damit keine voneinander getrennten Subsysteme entstehen, zwischen denen keine Informationen ausgetauscht werden können.

In SPADA [5] verbessern die Agenten die Partitionierung iterativ in sog. Optimierungsrunden bis ein Terminierungskriterium eingetreten ist. In jeder Optimierungsrunde versucht jeder Anführer anhand seines regionalen Wissens in Form der der Partition bekannten anderen Agenten bzw. Partitionen durch das Integrieren geeigneter neuer Agenten oder Ausschließen in der Partition enthaltener Agenten die Zusammensetzung der regionalen Partitionierung zu verbessern. Ist die Größe und die Anzahl der Partitionen durch die Vorgabe von Partitionierungsbedingungen eingeschränkt, wird dies von SPADA bei der Veränderung der (regionalen) Partitionierung berücksichtigt. Im Anschluss an die Veränderung der Partitionierung mischt der Anführer die Acquaintances aller Partitionsmitglieder. Dies dient der besseren Verbreitung von Wissen im Acquaintances Graph und fördert daher bessere Lösungen des Partitionierungsproblems, da sich dadurch die regionalen Sichten auf die Partitionierungen mit jeder Optimierungsrunde ändern und sich regionale Veränderungen am Acquaintances Graph ausbreiten. Diejenigen Agenten, die kein Anführer einer Partition sind, bleiben solange passiv, bis sie das Amt des Anführers einer Partition übernehmen. Wie genau die Schritte eines Anführers in einer Optimierungsrunde aussehen und wie im Detail sie versuchen, ihre regionale Partitionierung durch die Auswahl und Integration geeigneter neuer Agenten zu verbessern, und dabei die Partitionierungsbedingungen berücksichtigen, wird in [5] ausführlich beschrieben.

Wie PSOPP zeigt sich auch SPADA flexibel, was mögliche Terminierungskriterien angeht. So kann SPADA je nach Anwendungsfall beispielsweise nach einer maximalen Laufzeit, einer maximalen Anzahl an durchgeführten Optimierungsrunden oder nach dem Erreichen einer minimalen Fitness terminieren.

Ist eine globale Sicht auf die Partitionierung notwendig, weil ein Terminierungskriterium wie z. B. die Auswertung der Fitness es erfordert, wird diese Sicht in der erweiterten Version von SPADA von einem globalem Anführer übernommen, der diese Überprüfung einmal in jeder Optimierungsrunde

#### 4.4. Agenten-basierte Ausbildung von Autonomen Verbraucherorganisationen

durchführt. Wie PSOPP ist SPADA ein Anytime-Algorithmus, der jederzeit eine den Partitionierungsbedingungen gehorchende, gültige Lösung zurückliefern kann.



## REGIO-ZENTRALE, ROBUSTE STEUERUNG VON VERBRAUCHERN

---

**ZUSAMMENFASSUNG** In diesem Kapitel wird vorgestellt, wie eine Glättung der Residuallast in einem System von Autonomen Verbraucherorganisationen durchgeführt wird, die zudem mit Unsicherheiten, die durch Fehler in den Vorhersagen der nicht steuerbaren Nachfrage und der dargebotsabhängigen Leistung verursacht werden, umgehen kann.

# 5

**I**N Abschnitt 5.1 wird zunächst das Optimierungsproblem vorgestellt, das der Einsatzplanung von steuerbaren Verbrauchern – mit dem Ziel, die Residuallast zu glätten – zugrunde liegt. Die Betrachtung von Unsicherheiten findet in diesem Abschnitt noch nicht statt. Diese werden anschließend in Abschnitt 5.2 betrachtet und in der Form von *Trust-basierten Szenarien* [16] in das Optimierungsproblem integriert.

### 5.1. VERBRAUCHERSTEUERUNG ALS OPTIMIERUNGSPROBLEM

Wie bereits in Kapitel 2 motiviert, ist die Flexibilisierung der Nachfrage ein wichtiger Faktor für das Gelingen der Energiewende. Eine Möglichkeit, die flexibilisierte Nachfrage geeignet einzusetzen, ist die proaktive Einsatzplanung steuerbarer Verbraucher, also das Erstellen von Fahrplänen für einen gewissen Zeitraum. Die Einsatzplanung für steuerbare Verbraucher ist ein gemischt-ganzzahliges Optimierungsproblem – mit dem Ziel, die Residuallast zu glätten. Das zu lösende Optimierungsproblem ist somit ein Ressourcennivellierungsproblem. Da bei der Einsatzplanung verschiedenste Constraints der steuerbaren Verbraucher zu berücksichtigen sind (siehe Abschnitt 3.3), kann sie als ein *Constraint Satisfaction Optimization Problem* (CSOP) [112] formuliert werden. Im Folgenden wird nun das zu lösende Optimierungsproblem für die Glättung der Residuallast beschrieben, ange-

## 5. Regio-zentrale, robuste Steuerung von Verbrauchern

lehnt an die Formulierung der Einsatzplanung in Autonomen Virtuellen Kraftwerken [7, 10, 62]. Eine ausführliche Beschreibung der Einsatzplanung in Autonomen Virtuellen Kraftwerken kann in der Dissertation von Anders gefunden werden [5].

In der Einsatzplanung werden Fahrpläne über einen Zeitraum  $H$  mit einer zeitlichen Auflösung von  $\Delta\tau$  erstellt, wobei  $\Delta\tau$  ein ganzzahlig Vielfaches von  $\Delta t$  ist. Das bedeutet, dass die Fahrpläne für die  $N$  Zeitschritte der Menge  $\mathcal{W} = \{t_{\text{now}} + i \cdot \Delta\tau \mid i \in \{1, \dots, N\}\}$  berechnet werden, wobei  $t_{\text{now}}$  der aktuelle Zeitschritt ist<sup>23</sup> und  $H = N \cdot \Delta\tau$ . So berechnen beispielsweise in heutigen elektrischen Energieversorgungssystemen die Energieversorger typischerweise Fahrpläne mit einer zeitlichen Auflösung von 15 Minuten für den nächsten Tag. Da die zu treffenden Entscheidungen bzgl. der Nachfrage von steuerbaren Verbrauchern teilweise länger andauernde Auswirkungen haben – wie beispielsweise das Anschalten eines programmgetriebenen Verbrauchers, was die Nachfrage dieses Verbrauchers für die Dauer des Programms nicht mehr rückgängig machen kann und somit Flexibilität für darauf folgende Zeitpunkte raubt – ist es für die Qualität der Lösung der Einsatzplanung von Vorteil, wenn nicht nur der aktuelle oder die unmittelbar folgenden Zeitschritte berücksichtigt, sondern auch weiter entfernte Zeitschritte in die Einsatzplanung mit einbezogen werden. Da die Einsatzplanung nicht nur NP-schwer hinsichtlich der Anzahl steuerbarer Teilnehmer ist, sondern auch hinsichtlich der Anzahl  $N$  der Zeitschritte, für die Fahrpläne erstellt werden, darf  $N$  nicht zu groß werden. So beeinflusst die Wahl der Länge des Zeitraums  $H$  die Anzahl der Zeitschritte  $N$  und ist zudem ein entscheidender Faktor in der Einsatzplanung, was die Qualität der Lösungen und die Komplexität des Problems angeht. Gleichzeitig spielt die zeitliche Auflösung  $\Delta\tau$  der Fahrpläne eine wichtige Rolle in der Komplexität des Optimierungsproblems und sollte daher weder zu fein noch zu grob gewählt werden, um  $N$  nicht zu hoch bzw. die Fahrplanerstellung zu ungenau werden zu lassen.

Damit stets Fahrpläne vorliegen, muss die Einsatzplanung regelmäßig durchgeführt werden; d. h. spätestens dann, wenn der Zeitraum  $H$  seit der letzten Einsatzplanung vergangen ist. Eine häufigere Einsatzplanung, z. B. alle  $\Delta\tau$  Zeitschritte, ermöglicht allerdings eine Reaktion auf veränder-

23 Statt von dem aktuellen Zeitpunkt  $t_{\text{now}}$  auszugehen, wäre genauso gut ein anderer Zeitpunkt in der Zukunft denkbar, wenn bis zu diesem Zeitpunkt bereits Fahrpläne vorliegen – in dieser Arbeit wird aber immer vom aktuellen Zeitpunkt  $t_{\text{now}}$  ausgegangen.

### 5.1. Verbrauchersteuerung als Optimierungsproblem

te Bedingungen und ermöglicht dadurch eine Anpassung der Fahrpläne, wenn beispielsweise sich das Wetter anders entwickelt hat als angenommen. Eine Anpassung der Fahrpläne ist jedoch nicht immer für jeden Teilnehmer möglich, wie im Falle eines bereits aktivierten programmgetriebenen Verbrauchers.

Wie in Abschnitt 3.4 geschildert, erfolgt die Einsatzplanung nicht zentral für alle steuerbaren Verbraucher im ganzen System, sondern *regio-zentral*, d. h. innerhalb jeder Autonomen Verbraucherorganisation für die ihr untergeordneten steuerbaren Verbraucher. Die Menge der im System enthaltenen Autonomen Verbraucherorganisationen wird mit  $\Omega$  bezeichnet; im Folgenden wird die Einsatzplanung aus Sicht einer Autonomen Verbraucherorganisation  $\omega \in \Omega$  beschrieben. Die einer AVO  $\omega$  untergeordneten Agenten werden mit  $\mathcal{A}^\omega \subseteq \mathcal{A}$  bezeichnet; die untergeordneten steuerbaren Agenten mit  $\mathcal{D}^\omega \subseteq \mathcal{A}^\omega$ .

Die Einsatzplanung erfolgt auf Basis der nicht steuerbaren Leistung  $U^\omega$ . Diese ist zusammengesetzt aus der der AVO  $\omega$  zugewiesenen dargebotsabhängigen Leistung und der Nachfrage der in  $\omega$  enthaltenen nicht steuerbaren Verbraucher.  $U^\omega$  enthält sowohl die aktuelle nicht steuerbare Leistung  $U_{t_{\text{now}}}^\omega$  als auch die für jeden Zeitschritt  $t \in \mathcal{W}$  vorhergesagte nicht steuerbare Leistung  $U_t^\omega$ .

Um die Residuallast zu glätten, berechnet die AVO  $\omega$  Fahrpläne  $S^a$  für alle steuerbaren Agenten  $a$  aus der Menge der steuerbaren Verbraucher  $\mathcal{D}^\omega \subseteq \mathcal{A}^\omega$ . Ein Fahrplan  $S^a$  enthält die geplanten Zielvorgaben  $S_t^a$  für den Agenten  $a$  und alle Zeitpunkte  $t \in \mathcal{W}$ . Zudem enthält er mit  $S_{t_{\text{now}}}^a$  die aktuelle Nachfrage des Agenten  $a$ . Die Summe aller Fahrpläne der steuerbaren Teilnehmer  $\mathcal{D}^\omega$  ergibt die steuerbare Nachfrage  $S^\omega$ , mit  $\forall t \in t_{\text{now}} \cup \mathcal{W} : S_t^\omega = \sum_{a \in \mathcal{D}^\omega} S_t^a$ . Für die Berechnung der Fahrpläne für die steuerbaren Verbraucher benötigt die AVO somit Wissen über die Steuerungsmodelle der Verbraucher, darunter auch Vorhersagen über zukünftige Verfügbarkeiten, wie beispielsweise die voraussichtliche Ankunft und Abfahrt eines Elektrofahrzeugs.

Die Residuallast  $R^\omega$  ergibt sich aus der Summe der gesteuerten Nachfrage  $S^\omega$  und der nicht steuerbaren Leistung  $U^\omega$ , wobei  $R_{t_{\text{now}}}^\omega = S_{t_{\text{now}}}^\omega + U_{t_{\text{now}}}^\omega$  für den aktuellen Zeitschritt  $t_{\text{now}}$  und  $R_t^\omega = S_t^\omega + U_t^\omega$  für jeden Zeitpunkt  $t \in \mathcal{W}$ .

Bei der Erstellung der Fahrpläne für die steuerbaren Verbraucher ist die Einhaltung der Constraints der Steuerungsmodelle zwingend notwendig. Dies beinhaltet nicht nur die physikalischen Leistungswerte, sondern

## 5. Regio-zentrale, robuste Steuerung von Verbrauchern

auch interne Zustände bzw. vom Nutzer vorgegebene Constraints, wie beispielsweise die Temperatur bei einem thermischen Verbraucher oder der gewünschte Speicherstand eines Elektrofahrzeugs. Dementsprechend gibt es für jeden steuerbaren Verbraucher  $a$  eine Funktion  $M^a(S^a)$ , die den Fahrplan  $S^a$  auf die Einhaltung aller Constraints des Steuerungsmodells des Verbrauchers über den ganzen Zeitraum, den der Fahrplan abdeckt, überprüft, inklusive dem aktuellen Zustand. Je nach Steuerungsmodell beinhaltet die Überprüfung des Fahrplans zudem weitere Zeitschritte über den Fahrplan hinaus, um auch gültige Zustände in Anschluss an den Fahrplan zu garantieren. So wird vermieden, dass beispielsweise die Batterie eines Elektrofahrzeugs, das kurz nach dem Ende des Fahrplans abfahrtsbereit sein soll, im Fahrplan am Ende zu wenig aufgeladen ist und bis zur Abfahrt die erforderliche Menge nicht mehr erreichen kann. In dieser Arbeit werden die vom Nutzer vorgegebenen Constraints als harte Constraints angesehen, die immer zu erfüllen sind; eine Erweiterung auf weiche Constraints und die von Schiendorfer et al. vorgestellten *Constraint Relationships* [95], die Präferenzen über Constraints definieren, ist allerdings möglich und für zukünftige Arbeiten angedacht.

Damit die Residuallast geglättet wird, minimiert eine AVO  $\omega$  die absolute Differenz der Residuallast  $\Delta R_t^\omega = |R_t^\omega - R_{t-\Delta\tau}^\omega|$  zweier im Zeitraster  $\Delta\tau$  aufeinander folgender Zeitschritte. Zusätzlich wird die maximale für den Zeitraum der Einsatzplanung auftretende Differenz der Residuallast  $\Delta R_{\mathcal{W},\max}^\omega = \max\{\Delta R_t^\omega \mid t \in \mathcal{W}\}$  zweier aufeinander folgender Zeitschritte auf dem Zeitraster  $\Delta\tau$  minimiert, um gleichmäßigere Veränderungen der Residuallast gegenüber abrupten Veränderungen zu bevorzugen. In vorausgehenden Evaluierungen hat sich gezeigt, dass die Berücksichtigung von  $\Delta R_{\mathcal{W},\max}^\omega$  im Optimierungsproblem zu deutlich geringeren Anstiegen in der tatsächlichen Residuallast führt. Unter der Annahme, dass genügend Kraftwerkskapazitäten zur Verfügung stehen, soll die Residuallast dabei allerdings nicht möglichst niedrig gehalten werden; lediglich die Nivellierung der Residuallast, also das Verringern oder im optimalen Fall Vermeiden von Anstiegen der Residuallast, wird hier betrachtet.

Zusammengefasst muss eine AVO  $\omega$  folgendes Optimierungsproblem

### 5.1. Verbrauchersteuerung als Optimierungsproblem

lösen:

$$\begin{aligned} & \text{minimiere } \sum_{t \in \mathcal{W}} \Delta R_t^\omega + \Delta R_{\mathcal{W}, \max}^\omega & (5.1) \\ & \text{unter } \forall \alpha \in \mathcal{D}^\omega : M^\alpha(S^\alpha) \end{aligned}$$

Die Entscheidungsvariablen dieses Optimierungsproblems ist dabei die steuerbare Nachfrage  $S_t^\alpha$  der steuerbaren Verbraucher  $\alpha \in \mathcal{D}^\omega \subseteq \mathcal{A}^\omega$  für alle  $t \in \mathcal{W}$ , wobei die aktuelle Leistung  $S_{\text{now}}^\alpha$  der steuerbaren Verbraucher fix vorgegeben ist und nicht geändert werden kann.<sup>24</sup> Im Optimalfall, wenn die Residuallast vollständig geglättet wäre, würde die Zielfunktion demnach den Wert 0 zurückliefern. Die beiden Teilterme der Zielfunktion sind in dieser Zielfunktion gleichwertig gewichtet.

In dem Optimierungsproblem außen vor gelassen ist eine Betrachtung von Kosten. Die Integration solcher Kosten und die Minimierung selbiger wäre selbstverständlich möglich, steht aber in dieser Arbeit nicht im Vordergrund.

Denkbar wäre auch eine Gewichtung der Zeitschritte in dem Optimierungsproblem, so dass beispielsweise denjenigen Zeitpunkten, die nahe in der Zukunft sind, eine höhere Bedeutung zukommt, als den Zeitpunkten, die weiter entfernt liegen, und die Residuallast somit bevorzugt in der nahen Zukunft glatt ist als zu späteren Zeitpunkten. Unter der Annahme, dass die Einsatzplanung häufig durchgeführt wird und nicht erst, wenn die Fahrpläne nicht mehr aktuell sind, würden so die weiter entfernten Zeitpunkte bei der Einsatzplanung nicht unberücksichtigt bleiben, aber weniger Einfluss haben; durch die wiederholte Einsatzplanung würden sie dann zu einem späterem Zeitpunkt mit aktuellerem Wissen mit hoher Gewichtung berücksichtigt werden. In vorausgehenden Evaluierungen hat sich jedoch gezeigt, dass eine unterschiedliche Gewichtung der Zeitschritte zu schlechteren Ergebnissen führt.

Löst jede AVO  $\omega \in \Omega$  dieses Optimierungsproblem, wird die Residuallast in gesamten System geglättet. Insgesamt gilt  $\forall t \in \mathcal{T} : R_t = \sum_{\omega \in \Omega} R_t^\omega$ ,  $S_t = \sum_{\omega \in \Omega} S_t^\omega$  und  $U_t = \sum_{\omega \in \Omega} U_t^\omega$ .

<sup>24</sup> Theoretisch könnte auch  $S_{\text{now}}^\alpha$  noch angepasst werden, vorausgesetzt das Steuerungsmodell des Verbrauchers lässt dies zu. Unter der Annahme, dass im aktuellen Zeitschritt  $t_{\text{now}}$  aber die Nachfrage und Erzeugung im Gleichgewicht ist oder zumindest alle Anstrengungen unternommen wurden, um dies zu erreichen und die Abweichung von Nachfrage und Erzeugung so gering wie möglich ist – sei es durch gute Fahrpläne oder durch reaktive Maßnahmen der steuerbaren Kraftwerke/Verbraucher – würde eine Anpassung von  $S_{\text{now}}^\alpha$  keinen Vorteil bringen.

## 5. Regio-zentrale, robuste Steuerung von Verbrauchern

Nachdem nun das grundlegende Optimierungsproblem vorgestellt wurde, jedoch lediglich basierend auf Vorhersagen ohne Betrachtung von Unsicherheiten, wird jetzt im nächsten Abschnitt das Optimierungsproblem für den Umgang mit Unsicherheiten erweitert.

### 5.2. UMGANG MIT UNSICHERHEITEN BEI DER VERBRAUCHERSTEUERUNG

Wichtiger Bestandteil bei der Einsatzplanung sind die Vorhersagen der nicht steuerbaren Leistung – also die Vorhersagen der nicht steuerbaren Verbraucher und der dargebotsabhängigen Erzeuger. Doch auch die Vorhersagen steuerbarer Verbraucher, beispielsweise die zeitliche Verfügbarkeit von Elektrofahrzeugen, spielen dabei eine Rolle. Da diese Vorhersagen den Einflüssen der Umwelt bzw. des Nutzers unterliegen, sind sie naturgemäß mit Unsicherheiten behaftet und fehlerhaft. Solche Abweichungen in den Vorhersagen führen demnach in den meisten Fällen auch zu Fehlern in der Einsatzplanung und dadurch zu schlechteren Ergebnissen, was die Glättung der Residuallast betrifft.<sup>25</sup>

Entscheidender Punkt für eine erfolgreiche Einsatzplanung ist also der Umgang mit Unsicherheiten: Unsicherheiten müssen quantifiziert und antizipiert werden und in die Einsatzplanung miteinbezogen werden.

Ein von Anders et al. entwickeltes Konzept, das für die Quantifizierung und Antizipation derartiger Unsicherheiten eingesetzt werden kann und auch bereits erfolgreich für die Quantifizierung und Antizipation von Unsicherheiten in der autonomen Einsatzplanung für Autonome Virtuelle Kraftwerke eingesetzt wurde [7], sind *Trust-basierte Szenarien* (TBS) [16]. Bevor dieses Konzept nun in Abschnitt 5.2.2 auf das Optimierungsproblem der Glättung der Residuallast angewandt wird, werden TBS zunächst in Abschnitt 5.2.1 kurz vorgestellt.

#### 5.2.1. TRUST-BASIERTE SZENARIEN

In diesem Abschnitt werden die wesentlichen Merkmale und das Zustandekommen von *Trust-basierten Szenarien* (TBS) aus [16, 14] zusammengefasst

<sup>25</sup> Nicht alle Typen von Vorhersagefehlern führen zu schlechteren Ergebnissen: Ein konstanter Vorhersagefehler würde beispielsweise nichts an der Charakteristik der ungesteuerten Leistung ändern und somit die Glättung der Residuallast nicht negativ beeinflussen.

dargestellt. Für Details sei der interessierte Leser auf [5] verwiesen; dort gibt Anders eine ausführliche, formal präzise Beschreibung von Trust-basierten Szenarien und evaluiert diese ausführlich – inklusive einem Vergleich mit Hidden Markov Modellen.

TBS sind ein Ansatz zur Approximation eines stochastischen Prozesses, der dem Verhalten eines einzelnen oder einer Gruppe von Interaktionspartnern zugrundeliegende liegt. TBS werden zur Laufzeit generiert und eignen sich besonders für Situationen, in denen das vergangene Verhalten eines Agenten auf das zukünftige Verhalten schließen lässt, dieses sich jedoch aufgrund von zeitabhängigen Änderungen im Verhalten nicht durch einen einfachen Trust- oder Reputations-Wert wie einem Mittelwert, ggf. noch kombiniert mit zusätzlichen Informationen wie einer Varianz oder der Konfidenz, abbilden lässt.

Die Basis von TBS sind in Interaktionen gesammelte Erfahrungen, die zur Laufzeit gesammelt werden (siehe Lebenszyklus von Trust-Werten, Abschnitt 3.2). In diesem Fall stellen Erfahrungen Abfolgen von Verhalten dar, z. B. Abfolgen von Abweichungen des tatsächlichen Verhaltens von dem prognostiziertem Verhalten wie beispielsweise Prognoseabweichungen dargebotsabhängiger Leistung. Das Sammeln von Erfahrungen, die das Verhalten über mehrere Zeitschritte enthalten, ermöglicht das Abbilden und Berücksichtigen von zeitabhängigen Verhalten: So ist es z. B. in elektrischen Energieversorgungssystemen möglich, dass auf eine Prognoseabweichung bestimmten Ausmaßes im nächsten Schritt eine weitere Prognoseabweichung gleichen Ausmaßes folgt. Die gesammelten Erfahrungen werden klassiert, indem die jeweiligen einzelnen Verhalten in zuvor festgelegte Klassen eingeteilt werden. So können Prognoseabweichungen beispielsweise mithilfe eines Normalisierungsfaktors wie dem bisher größten gemessenen Prognosefehler normalisiert und entsprechenden Klassen zugeordnet werden. Die Breite der Klassen bestimmt somit die Genauigkeit der Klassierung. Die Breite der Klassen kann je nach Anwendung definiert werden und kann auch für die unterschiedlichen Zeitschritte unterschiedlich breit sein, wenn z. B. die Genauigkeit der Einschätzung des Verhaltens für Zeitpunkte weiter in der Zukunft für die aktuelle Betrachtung nicht ganz so wichtig ist wie die für zeitnahe Zeitpunkte. Eine solche klassierte Abfolge von Verhalten stellt ein TBS dar. Die Häufigkeit von TBS mit gleicher klassierter Abfolge in Relation zu den Häufigkeiten von TBS anderer klassierter Abfolgen bestimmt die angenommene Wahrscheinlichkeit, dass eine solche Abfolge von Verhalten

## 5. Regio-zentrale, robuste Steuerung von Verbrauchern

in der Zukunft auftritt. Die Breite der Klassen bestimmt somit nicht nur die Genauigkeit der Klassierungen, sondern hat u. a. auch Auswirkungen auf die Häufigkeit und Anzahl von TBS. Durch die Kombination aller TBS und dem Hinzufügen einer Wurzel  $r$ , die beispielsweise den aktuellen Zustand beschreibt, entsteht ein *Trust-basierter Szenariobaum* (engl. *Trust-Based Scenario Tree*, TBST). TBS, die das gleiche Präfix an klassierten Verhalten besitzen, teilen sich einen Ast in dem TBST bis zu der Stelle, an der sich das klassierte Verhalten unterscheidet. Die Kanten im TBST sind mit Übergangswahrscheinlichkeiten versehen, die der Häufigkeit der Übergänge von der Klasse des Verhaltens zu der Klasse des anderen Verhaltens entsprechen. Das TBS, das man erhält, wenn ausgehend von der Wurzel an jeder Abzweigung im TBST die Kante mit der höchsten Wahrscheinlichkeit genommen wird, nennt sich *antizipiertes Szenario* – das antizipierte Szenario muss jedoch nicht notwendigerweise auch das wahrscheinlichste TBS im TBST sein. Ein Beispiel, das die Entstehung eines TBST aus einer Menge an gesammelten Erfahrungen illustriert, ist in Abbildung 5.1 dargestellt.

Mit einem TBST erhält man somit zur Laufzeit eine auf empirischen Daten basierende Wahrscheinlichkeitsfunktion, die eine diskrete Wahrscheinlichkeitsverteilung über mehrere Zeitschritte definiert und den dem Verhalten des Interaktionspartners zugrundeliegenden stochastischen Prozess approximiert. Ein TBST ermöglicht somit Vorhersagen über mögliche Verhalten eines Interaktionspartners in der Zukunft.

Der Vorteil von TBS gegenüber anderen Ansätzen, die Szenarien bzw. Szenariobäume verwenden (siehe z. B. [123]), oder anderen Vorhersagemodellen wie Hidden Markov Modelle [24], liegt vor allem in der Gewinnung der TBS zur Laufzeit und der Möglichkeit, Zeitabhängigkeiten im Verhalten zu berücksichtigen.

### 5.2.2. ROBUSTE STEUERUNG VON VERBRAUCHERN MIT TRUST-BASIERTEN SZENARIEN

In diesem Abschnitt werden nun *Trust-basierte Szenarien* (TBS) [16] eingesetzt, um die Steuerung der Verbraucher, wie sie in Abschnitt 5.1 vorgestellt wurde, robust gegenüber Unsicherheiten zu machen. Konkret werden TBS dafür eingesetzt, die Unsicherheiten der nicht steuerbaren Leistung  $U$  zu quantifizieren und zu antizipieren – mögliche Vorhersagefehler steuerbarer Verbraucher werden hier nicht betrachtet. Die Formulierung des robusten Optimierungsproblems für steuerbare Verbraucher erfolgt analog zu der

## 5.2. Umgang mit Unsicherheiten bei der Verbrauchersteuerung

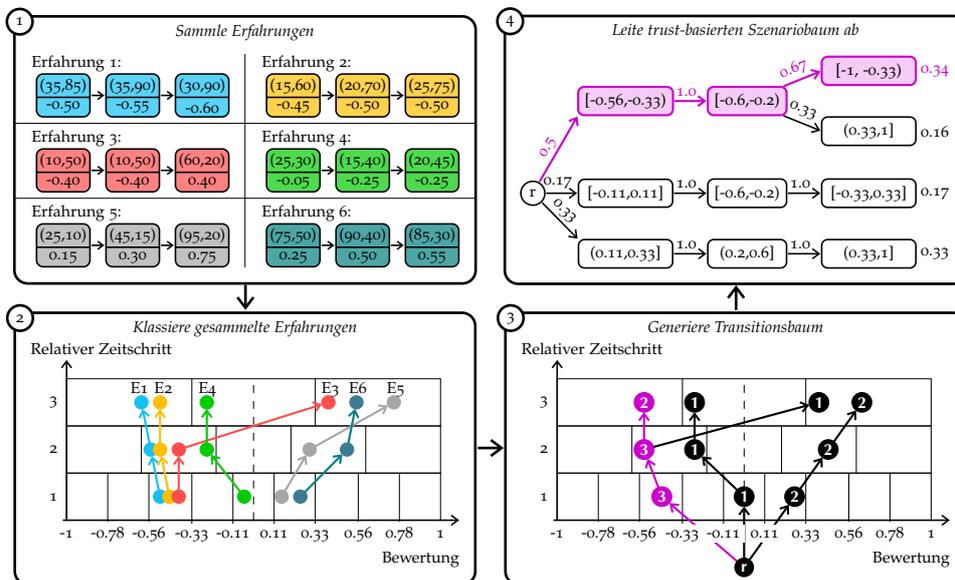


Abbildung 5.1.: Exemplarischer Ablauf zur Erstellung eines Trust-basierten Szenarioabbaums aus einer Menge von gesammelten Erfahrungen (aus [14]). In diesem Beispiel werden Abfolgen von Prognoseabweichungen der Länge drei als Erfahrungen gesammelt (s. Schritt 1). Erfahrung 1 enthält z. B. eine Abfolge von Abweichungen der tatsächlichen Leistung von der vorhergesagten Leistung von -50, -55 und -60; die Abweichungen werden in diesem Beispiel auf Werte zwischen -1 und 1 mit einem Normalisierungsfaktor von 100 normalisiert. Für die Generierung eines TBST werden die gesammelten Erfahrungen zunächst klassiert (s. Schritt 2) – in diesem Beispiel nimmt die Breite der Klassen für weiter entfernte Zeitschritte zu. Durch das Zusammenfassen aller Übergänge von einer Klasse zu einer Klasse des nächsten Zeitschritts in einen Pfad und dem Hinzufügen einer Wurzel  $r$  ergibt sich in Schritt 3 ein Transitionsbaum (die Zahlen in den Knoten stellt die Häufigkeit der Übergänge von der Klasse des Vorgängerknotens zu der Klasse dieses Knotens dar), aus dem letztendlich der TBST mit den entsprechenden Übergangswahrscheinlichkeiten abgeleitet werden kann (s. Schritt 4). Jeder Pfad von der Wurzel zu einem Blatt ist ein TBS. Für Prognosen über die zukünftige Entwicklung wird der jeweilige Mittelwert der Klasse herangezogen; so würde für das oberste Szenario in diesem Beispiel – das antizipierte Szenario – mit der Wahrscheinlichkeit von 34 % eine Abweichungsabfolge von -44.5, -40 und -66.5 erwartet werden (unter erneuter Verwendung des Normalisierungsfaktors von 100).

## 5. Regio-zentrale, robuste Steuerung von Verbrauchern

robusten Fahrplanerstellung in Autonomen Virtuellen Kraftwerken [7], wo Fahrpläne für steuerbare Kraftwerke auf Basis von TBS, die die erwartete Residuallast abbilden, erstellt werden.

Wie zuvor im Optimierungsproblem ohne Unsicherheiten, benötigt die AVO  $\omega$  wie gehabt eine Vorhersage über die ungesteuerte Leistung  $U^\omega$  für die Zeitschritte aus  $\mathcal{W}$ . Auf Basis der vergangenen Vorhersagen von  $U^\omega$  und den zugehörigen gesammelten Erfahrungen bzgl. den Abweichungen der tatsächlichen ungesteuerten Leistung von der vorhergesagten ungesteuerten Leistung, generiert eine AVO  $\omega$  wie in Abschnitt 5.2.1 beschrieben einen TBST, der die erwarteten Abweichungen der ungesteuerten Leistung  $U^\omega$  enthält. Dieser wird mit der aktuellen Vorhersage zu einem weiteren TBST  $U_\uparrow^\omega$  verrechnet, indem die Vorhersage auf alle TBS des Abweichungs-TBST addiert wird. Als Wurzel des von  $U_\uparrow^\omega$  wird die aktuelle ungesteuerte Leistung  $U_{t_{\text{now}}}^\omega$  verwendet. Dieser TBST enthält somit die erwarteten ungesteuerten Leistungen für die nächsten Zeitschritte aus  $\mathcal{W}$ , wobei jeder Knoten  $U_n^\omega \in U_\uparrow^\omega$  einem Zeitschritt aus  $\mathcal{W}$  bzw. im Falle der Wurzel dem aktuellen Zeitschritt  $t_{\text{now}}$  zugeordnet werden kann.

Anstatt nun nur für die vorhergesagte ungesteuerte Leistung oder für ein einzelnes TBS wie dem antizipiertem Szenario aus  $U_\uparrow^\omega$  die Einsatzplanung durchzuführen, werden die Fahrpläne in der robusten Einsatzplanung für den ganzen TBST  $U_\uparrow^\omega$  erstellt. Die einzelnen TBS fließen jedoch nicht gleichwertig in das Optimierungsproblem ein, sondern werden anhand ihrer jeweiligen Wahrscheinlichkeit gewichtet, so dass für die *erwartete* ungesteuerte Leistung optimiert wird. Eine Optimierung unter Unsicherheit durch Einbezug mehrerer Szenarien entspricht den Gedanken von *Stochastic Programming* [100]; die Lösung des Optimierungsproblems für den ganzen TBST ist in diesem Fall ein mehrstufiges stochastisches Programm. Dadurch, dass eine Einsatzplanung über mehrere Szenarien durchgeführt wird, ist es prinzipiell möglich, Szenarien zur Laufzeit zu wechseln, wenn sich der angenommene Verlauf der ungesteuerten Leistung beispielsweise als falsch erwiesen hat. Die reaktive Anpassung der Leistung steuerbarer Kraftwerke mit der Möglichkeit des Wechsels eines Szenarios hat sich im Kontext der Autonomen Virtuellen Kraftwerke als sehr lohnenswert herausgestellt [10].

Werden die Fahrpläne für den ganzen TBST  $U_\uparrow^\omega$  erstellt, bedeutet dies, dass jeder Fahrplan jedes steuerbaren Verbrauchers auch ein Baum  $S_\uparrow^a$  mit der aktuellen Nachfrage  $S_{t_{\text{now}}}^a$  als Wurzel ist, der die selbe Struktur und die selben Übergangswahrscheinlichkeiten hat wie  $U_\uparrow^\omega$ ; jeder Knoten  $n \in S_\uparrow^a$

## 5.2. Umgang mit Unsicherheiten bei der Verbrauchersteuerung

kann also genau einem eindeutigen Knoten aus  $U_T^\omega$  zugeordnet werden. Die Summe aller Fahrplanbäume<sup>26</sup> der untergeordneten steuerbaren Verbraucher  $\mathcal{D}^\omega \subseteq \mathcal{A}^\omega$  ergibt den gesamten Fahrplanbaum  $S_T^\omega$  der AVO  $\omega$  mit  $S_{t_{\text{now}}}^\omega$  als Wurzel. Demzufolge ergibt sich für die Residuallast von  $\omega$  ebenfalls ein Baum  $R_T^\omega$  mit  $R_{t_{\text{now}}}^\omega$  als Wurzel, der aus der Summe von  $U_T^\omega$  und  $S_T^\omega$  entsteht.

Wichtig bei der Berechnung eines Fahrplanbaumes ist, dass jede Transition von einem Knoten des Baumes zu einem nachfolgenden Knoten des Baumes mit dem Steuerungsmodell des Agenten vereinbar ist, d. h. jeder Pfad von der Wurzel bis zu einem Blatt des Knotens muss mit dem Steuerungsmodell konform sein. An dem Beispiel eines programmgetriebenen Verbrauchers veranschaulicht bedeutet dies, dass ein in einem Knoten  $n$  angeschalteter programmgetriebener Verbraucher für alle Nachfolgeknoten im Fahrplanbaum für die restliche Dauer des Programms angeschaltet sein muss; allerdings bedeutet das nicht zwangsweise, dass der programmgetriebene Verbraucher auch in anderen Knoten in einem anderem Teil des Baumes, die nicht von diesem Knoten  $n$  aus erreichbar sind, angeschaltet sein muss. Anstatt eines einfachen Fahrplans in Form eines Pfades wie in Abschnitt 5.1 muss die Funktion  $M^a(S_T^a)$  demzufolge den ganzen Fahrplanbaum  $S_T^a$  auf die Einhaltung aller Constraints des Steuerungsmodells überprüfen. Zusätzlich muss  $M^a(S_T^a)$  darüber hinaus erneut dafür Sorge tragen, dass auch nachfolgende Zeitschritte nach den Blättern des Baumes gültige Zustände in den Steuerungsmodellen ermöglichen.

Das für eine AVO  $\omega$  zu lösende Optimierungsproblem unter Berücksichtigung von Unsicherheiten lautet wie folgt:

$$\begin{aligned} & \text{minimiere} \quad \sum_{n \in R_T^\omega \setminus \{R_{t_{\text{now}}}^\omega\}} \Delta R_n^\omega \cdot p_n + \Delta R_{T, \text{max}}^\omega & (5.2) \\ & \text{unter } \forall a \in \mathcal{D}^\omega : M^a(S_T^a) \end{aligned}$$

Im Gegensatz zu dem Optimierungsproblem ohne Unsicherheiten (siehe Gleichung (5.1)) wird die Glättung der Residuallast über den ganzen Residuallastbaum  $R_T^\omega$  durchgeführt. Konkret bedeutet dies, dass mit  $\Delta R_n^\omega = |R_n^\omega - R_{f_n}^\omega|$  die absolute Differenz der Residuallast zwischen dem Knoten  $n \in R_T^\omega \setminus \{R_{t_{\text{now}}}^\omega\}$  und seinem Vorgängerknoten  $f_n$  aus dem Baum  $R_T^\omega$

26 Die Summe bzw. Differenz zweier Bäume identischer Struktur, in der jeder Knoten des einen Baumes eindeutig einem Knoten des anderen Baumes zugeordnet werden kann, entspricht der Summe bzw. Differenz der einzelnen Knoten.

## 5. Regio-zentrale, robuste Steuerung von Verbrauchern

minimiert wird.  $\Delta R_n^\omega$  wird mit der Wahrscheinlichkeit  $p_n$ , dass der Knoten  $n$  von der Wurzel  $R_{t_{\text{now}}}^\omega$  aus erreicht wird, multipliziert. Dadurch wird die *erwartete* absolute Differenz der Residuallast minimiert und wahrscheinlichere Szenarien haben folglich größere Bedeutung bei der Optimierung als unwahrscheinliche Szenarien. Analog zu Gleichung (5.1) fließt zudem die *erwartete* maximale Differenz der Residuallast von einem zum nächsten Zeitschritt  $\Delta R_{T,\text{max}}^\omega = \max\{\Delta R_n^\omega \cdot p_n \mid n \in R_T^\omega \setminus \{R_{t_{\text{now}}}^\omega\}\}$  in das Optimierungsproblem ein. Auch bei  $\Delta R_{T,\text{max}}^\omega$  wird dementsprechend die Wahrscheinlichkeit der Knoten berücksichtigt.

### 5.3. VERWANDTE ARBEITEN

Wie bereits in Abschnitt 3.4 diskutiert, gibt es in der Literatur diverse Ansätze, um Verbraucher aktiv in den Betrieb elektrischer Energieversorgungssysteme miteinzubeziehen, darunter auch reaktive Ansätze, in denen Verbraucher beispielsweise auf die Frequenz (siehe z. B. [46, 102]) oder auf Preissignale (siehe z. B. [51, 117, 89, 42]) reagieren.

Die in der Forschergemeinde untersuchten Ansätze zu einer Steuerung von Verbrauchern via Fahrplänen sind oft beschränkt auf die Betrachtung bestimmter Typen, wie beispielsweise die Untersuchung von verschiedenen Ladestrategien von Elektrofahrzeugen (siehe z. B. [116]) oder die Steuerung von einer Gruppe von Klimaanlageanlagen (siehe z. B. [92]), oder auf die Optimierung des Verbrauchs von Geräten in einem Haushalt (siehe z. B. [20]). Eine Selbst-Organisation hinsichtlich adaptiver Verbraucherorganisationen findet in derartigen Ansätzen in der Regel nicht statt, genauso wenig wie eine Betrachtung von Unsicherheiten in Form von möglichen Szenarien der Zukunft.

Ogston et al. stellen in [82] mittels einem einfachen Steuerungsmechanismus dar, dass das Bilden von Clustern von Kühlschränken und die koordinierte Steuerung darin bessere Ergebnisse liefert, als der unkoordinierte Energieverbrauch dieser. Dabei wird insbesondere untersucht, wie sich die Zusammensetzung der Cluster auf die Lösungsqualität auswirkt und wie viele Cluster für das betrachtete Problem zu den besten Lösungen führen; zu viele Cluster bieten zu wenig Flexibilität, wohingegen zu wenige Cluster jeweils einen zu hohen Koordinationsaufwand besitzen. Über den relativ einfachen Steuerungsmechanismus hinaus geht das Papier allerdings nicht; auch keine Aussagen zu Algorithmen, die die Cluster ausbilden sollen,

werden getroffen. Zudem findet keine Betrachtung von Unsicherheiten statt.

Ein Ansatz zur Steuerung von Verbrauchern in selbst-organisierenden Virtuellen Geräten hat Lünsdorf in seiner Dissertation vorgestellt (siehe Abschnitt 3.4). Dieser Ansatz ist jedoch zugeschnitten auf die Gruppierung gleichartiger Geräte in einem Verbund und berücksichtigt keine Unsicherheiten in der Einsatzplanung; insbesondere erstellt er keine robusten Fahrpläne für verschiedene Entwicklungen der Zukunft.

Ansätze zu Virtuellen Kraftwerken werden in Kapitel 6 vorgestellt; Ansätze zu einem koordiniertem Supply Demand Management, die sowohl Erzeuger als auch Verbraucher beinhalten, werden in Kapitel 7 diskutiert (siehe z. B. [118, 61, 47, 67]).



### III.

## SELBST-ORGANISIERTES, TRUST-BEWUSSTES SUPPLY DEMAND MANAGEMENT

In diesem Teil der Arbeit werden *Autonome Verbraucherorganisationen* in den bestehenden Ansatz der *Autonomen Virtuelle Kraftwerke* integriert.



## AUTONOME VIRTUELLE KRAFTWERKE

---

**ZUSAMMENFASSUNG** Dieses Kapitel stellt das Konzept der *Autonomen Virtuellen Kraftwerke* vor, die eine autonome, skalierbare Einsatzplanung für steuerbare Kraftwerke unter Unsicherheiten ermöglichen.

# 6

**A**UTONOME Virtuelle Kraftwerke [108] sind auf Kraftwerksseite das Pendant zu Autonomen Verbraucherorganisationen. Ziel dieses Kapitels ist es, Autonome Virtuelle Kraftwerke in dem Detailgrad vorzustellen, wie es für das Verständnis der weiteren Arbeit notwendig ist. Für detailliertere Informationen, die den gesamten Ansatz und die einzelnen Teilaspekte näher beleuchten, sei der interessierte Leser auf [108, 14, 5] verwiesen.

### 6.1. GRUNDPRINZIP VON AUTONOMEN VIRTUELLEN KRAFTWERKEN

*Autonome Virtuelle Kraftwerke* (AVKW) [108] sind ein Ansatz, um mit den Herausforderungen der Skalierbarkeit und Unsicherheiten (siehe Abschnitt 2.5) in zukünftigen Smart Grids umzugehen. Autonome Virtuelle Kraftwerke sind selbst-organisiert ausgebildete disjunkte Gruppen von Kraftwerken, in denen jeweils lokal durch eine autonome, periodische Einsatzplanung für die beinhalteten steuerbaren Kraftwerke ein Teil der im System anliegenden Residuallast gedeckt wird. Die NP-schwere Einsatzplanung für die große Anzahl an steuerbaren Kraftwerken – insbesondere unter Berücksichtigung von potentiell steuerbaren Kraftwerken wie Biomasse-Anlagen, die heutzutage zumeist nach eigenen Interessen in das elektrische Energieversorgungssystem einspeisen und nicht von außen gesteuert werden – wird somit durch eine selbst-organisierte Problemdekomposition skalierbar.

Die Ausbildung von Autonomen Virtuellen Kraftwerken ist ebenfalls eine Instanz eines *Partitionierungsproblems* (PP) [12] und kann somit mit den Algorithmen PSOPP [12] (siehe Abschnitt 4.3) und SPADA [5] (siehe

## 6. Autonome Virtuelle Kraftwerke

Abschnitt 4.4) gelöst werden. Das Ziel bei der Ausbildung von Autonomen Virtuellen Kraftwerken ist eine *homogene Partitionierung* [12]. Dabei werden Kriterien wie die Steuerbarkeit von steuerbaren Kraftwerken sowie die Vertrauenswürdigkeit – also die Prognosefehler – berücksichtigt [14], damit alle AVKW in etwa gleich viel Steuerungspotential besitzen und mit etwa gleich großen Unsicherheiten konfrontiert sind. Dadurch ist jedes AVKW ähnlich gut gerüstet, um die lokal anliegende Last zu befriedigen, wodurch sich insgesamt ein robusteres System ergibt, das das Systemziel – das Gleichgewicht zwischen Erzeugung und Nachfrage – besser erfüllen kann.

Die in dem System vorliegenden Unsicherheiten in Form der Prognosefehler dargebotsabhängiger Erzeuger und der Verbraucher werden zum einen bei der Ausbildung Autonomer Virtueller Kraftwerke betrachtet, indem die Systemteilnehmer anhand ihrer Prognosefehler auf die Autonomen Virtuellen Kraftwerke verteilt werden (siehe vorheriger Absatz). Zum anderen führen AVKW eine robuste Einsatzplanung auf Basis von *Trust-basierten Szenarien* (TBS) [16] durch, wodurch die Quantifizierung und Antizipation von Unsicherheiten in der zu deckenden Residuallast ermöglicht wird [7].

Im Gegensatz zu der Einsatzplanung in Autonomen Verbraucherorganisationen ist das zugrundeliegende Problem in der robusten Einsatzplanung der Autonomen Virtuellen Kraftwerke [7, 6, 62] ein über mehrere Zeitschritte hinweg zu lösendes *Ressourcenallokationsproblem* [115]. In einem Ressourcenallokationsproblem ist das Ziel, dass bereitgestellte und nachgefragte Ressourcen zu möglichst geringen Kosten exakt übereinstimmen. Bezogen auf die Einsatzplanung in AVKW bedeutet das, dass die Residuallast der nachgefragten Ressource entspricht und durch die geeignete Allokation von Leistung der steuerbaren Kraftwerke gedeckt werden muss. Dabei gilt es selbstverständlich zu beachten, dass Kraftwerke nur im Rahmen ihres Steuerungsmodells steuerbar sind und z. B. aufgrund ihrer Änderungsgeschwindigkeit nur begrenzt ihre Leistung ändern können (siehe Abschnitt 2.1), was auch einen rein reaktiven Betrieb nicht möglich macht.

Um auf mögliche Abweichungen der Residuallast zu reagieren und diese zu kompensieren, ist es den physikalischen Kraftwerken möglich, reaktive Anpassungen vorzunehmen und ggf. von ihrem Fahrplan abzuweichen bzw. in ein anderes Szenario zu wechseln [10]. Durch die zusätzliche Berücksichtigung von vorzuhaltenden Reserven während der Einsatzplanung in Autonomen Virtuellen Kraftwerken wird diese Möglichkeit weiter verstärkt [62].

### 6.1. Grundprinzip von Autonomen Virtuellen Kraftwerken

Jedes AVKW hat die Aufgabe, einen Teil der im System anliegenden Residuallast zu befriedigen. Damit dieser Teil auch tatsächlich von einem AVKW gedeckt werden kann, muss die Zuweisung des Anteils derart erfolgen, dass Faktoren wie beispielsweise die in einem AVKW maximal verfügbare Leistung beachtet werden. Das bedeutet, dass an einer übergeordneten Stelle, dem sogenannten Wurzel-AVKW, die gesamte im System vorhandene Residuallast auf die im System befindlichen AVKW geeignet verteilt werden muss – es muss also im Wurzel-AVKW eine Einsatzplanung für die AVKW durchgeführt werden. Die einzelnen AVKW agieren somit jeweils als ein virtuelles, großes steuerbares Kraftwerk und bekommen ihre zu deckende Residuallast in Form eines Fahrplanes zugewiesen, auf Basis der sie dann ihrerseits in einer Einsatzplanung Fahrpläne für ihre untergeordneten steuerbaren Kraftwerke erstellen. Damit das Wurzel-AVKW bei der Einsatzplanung für die AVKW nicht die Steuerungsmodelle aller im System teilnehmenden steuerbaren Kraftwerke verwenden muss – was die Aufteilung der Kraftwerke in AVKW ad absurdum führen würde – ist es notwendig, dass AVKW dem übergeordneten Wurzel-AVKW ein abstraktes Steuerungsmodell zur Verfügung stellen, das die aggregierten Eigenschaften der untergeordneten steuerbaren Kraftwerke abstrahiert. Dazu gehören beispielsweise die aggregierte Minimal- und Maximalleistung, aber auch andere komplexere Abhängigkeiten. Die hierfür verwendeten Techniken zur Modellabstraktion haben Schiendorfer et al. in [94] vorgestellt.

Sind alle AVKW in einer flachen Hierarchie dem Wurzel-AVKW untergeordnet, ist die Komplexität der Einsatzplanung durch die Problemdekomposition zwar reduziert, skaliert jedoch nicht beliebig: Eine größere Anzahl an Systemteilnehmern würde (1) die Größe der AVKW erhöhen und somit dort die jeweilige Einsatzplanung immer komplexer werden lassen (2) und/oder die Anzahl der AVKW, für die das Wurzel-AVKW Fahrpläne zu berechnen hat, größer werden lassen und somit die Komplexität im Wurzel-AVKW erhöhen. Statt einer flachen Hierarchie bilden Autonome Virtuelle Kraftwerke deshalb eine hierarchische Systemstruktur mit beliebiger Tiefe, mit dem Wurzel-AVKW an der Spitze. Jedes AVKW enthält somit potentiell weitere AVKW, für die es Fahrpläne zu berechnen hat. Ein Beispiel einer solchen Hierarchie zeigt Abbildung 6.1.

Die selbst-organisierte Bildung der Hierarchie [109, 107, 5] ist getrieben von der Dauer der Berechnung der Fahrpläne für die untergeordneten Kraftwerke eines AVKW. Benötigt ein AVKW beispielsweise länger für die

## 6. Autonome Virtuelle Kraftwerke

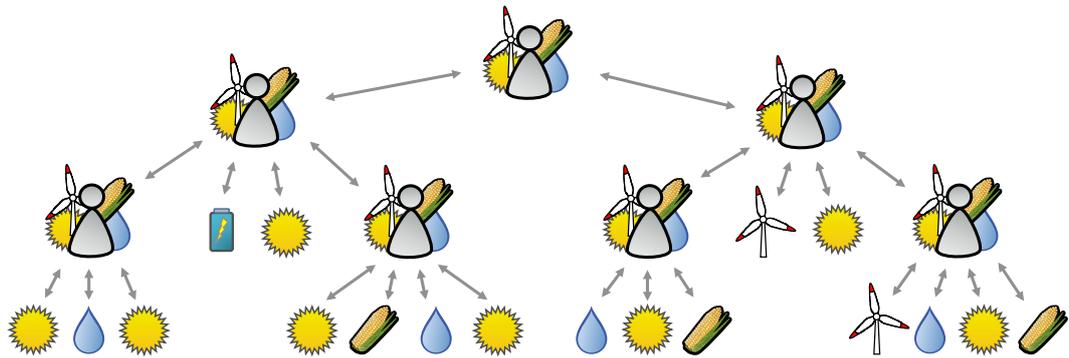


Abbildung 6.1.: Exemplarische hierarchische Systemstruktur Autonomer Virtueller Kraftwerke (Quelle: [14]). Kraftwerke bilden selbst-organisiert eine Hierarchie von Autonomen Virtuellen Kraftwerken, in der Autonome Virtuelle Kraftwerke sowohl physikalische Kraftwerke (Blätter) als auch weitere Autonome Virtuelle Kraftwerke (innere Knoten) beinhalten können. Da jedes Autonome Virtuelle Kraftwerk nur für die direkt untergeordneten Kraftwerke Fahrpläne erstellen muss, wird die Komplexität der Einsatzplanung verringert. Das Autonome Virtuelle Kraftwerk an der Wurzel des Baumes ist das sog. Wurzel-AVKW.

Einsatzplanung als einen zuvor festgelegten Schwellwert, wird das Partitionierungsproblem lokal für die untergeordneten Kraftwerke gelöst und unter diesem AVKW eine weitere Hierarchieebene eingeführt (siehe Abbildung 6.2 für eine Illustration). Die dadurch entstehenden Partitionen – AVKW – werden dem bisherigem AVKW untergeordnet; die Anzahl untergeordneter Kraftwerke dieses AVKW reduziert sich folglich, womit auch die Komplexität der Einsatzplanung reduziert wird und schnellere Berechnungszeiten in der Einsatzplanung erzielt werden können. Umgekehrt können sich auch AVKW auflösen, wenn die Dauer der Einsatzplanung unter einen zuvor festgelegten Schwellwert fällt.<sup>27</sup> Die untergeordneten Kraftwerke eines aufgelösten AVKW werden dann dem Vater-AVKW des aufgelösten AVKW zugeordnet. Dieser Schritt des Auflöses von AVKW ist notwendig, um einerseits die Flexibilität innerhalb der AVKW ausreichend hoch zu halten und andererseits um Hierarchien mit unnötiger Tiefe zu vermeiden – denn jede weitere Hierarchieebene führt durch die notwendige Modellabstraktion potentiell Ungenauigkeiten in der Einsatzplanung ein, die das Erreichen des Systemziels erschweren [96]. Gleichzeitig ist allerdings auch immer noch eine Reorganisation unter einem AVKW innerhalb einer Hierarchieebene möglich,

<sup>27</sup> Das Wurzel-AVKW ist fester Bestandteil des Systems und kann sich nicht auflösen.

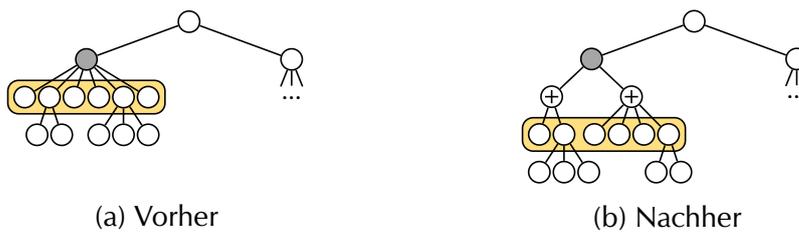


Abbildung 6.2.: Einführung einer neuen Hierarchieebene unter einem Autonomem Virtuellen Kraftwerk (nach [14]). Nachdem das graue AVKW  $\bullet$  eine Verletzung des Constraints festgestellt hat, welches fordert, dass die Dauer der Einsatzplanung unter einen maximalen Schwellwert zu sein hat, wird für die untergeordneten Kraftwerke, markiert durch die orangefarbene Box  $\square$ , ein Partitionierungsproblem gelöst. In diesem Beispiel werden zwei neue AVKW – dargestellt durch  $\oplus$  – unterhalb des grauen AVKW erstellt.

wenn innerhalb dieser keine homogene Partitionierung mehr existiert. Die Reorganisation findet dann nur für den betroffenen Teil des Systems statt. Ein Beispiel einer Reorganisation innerhalb einer Hierarchieebene ist in Abbildung 6.3 dargestellt. Die Überwachung dieser Constraints und das entsprechende Reorganisieren des Systems übernimmt eine hierarchische Regelschleife [109], die auf jedem AVKW ausgeführt wird. Das Überwachen der Constraints und das Reorganisieren der Systemstruktur mit dem Ziel, dass die Constraints nach der Reorganisation wieder erfüllt sind, entspricht dabei den Gedanken des *Restore Invariant Approach* (RIA) [76] (siehe auch Kapitel 4).

Der Ablauf der robusten Einsatzplanung in hierarchischen Autonomem Virtuellen Kraftwerken [7] wird in Kapitel 7 dargestellt.

## 6.2. VERWANDTE ARBEITEN

Virtuelle Kraftwerke als Darstellung für eine Gruppe von Kraftwerken – und teilweise Verbrauchern – sind ein verbreiteter Ansatz in der Forschung zur Lösung der Probleme in zukünftigen elektrischen Energieversorgungssystemen und werden teilweise bereits in der Praxis eingesetzt, wie etwa bei den Stadtwerken München [105] oder bei Next Kraftwerke [79].

In vielen dieser Ansätze sind Virtuelle Kraftwerke ein statischer Zusammenschluss von dezentralen Energieerzeugern, die von einer zentralen Stelle aus koordiniert werden [68], manchmal auch limitiert auf bestimmte Typen

## 6. Autonome Virtuelle Kraftwerke

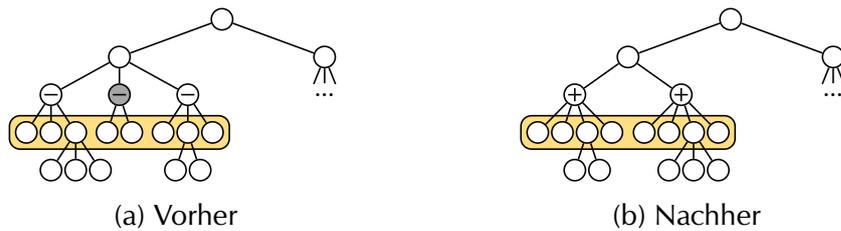


Abbildung 6.3.: Reorganisation innerhalb einer Hierarchieebene unter einem Autonomen Virtuellen Kraftwerk (nach [14]). Nachdem das graue AVKW  $\ominus$  eine Verletzung des Constraints festgestellt hat, welches die homogene Partitionierung überwacht, wird für den betroffenen Teil der Hierarchie, d. h. die untergeordneten Kraftwerke und die Neffen von  $\ominus$ , markiert durch die orangefarbene Box  $\square$ , ein Partitionierungsproblem gelöst. In diesem Beispiel werden die zu partitionierenden Kraftwerke in zwei neue AVKW  $\oplus$  partitioniert, die die drei alten AVKW  $\ominus$  ersetzen.

von Kraftwerken [98]. Oft ist ihr Zweck, den Teilnehmern die Teilnahme an Märkten zu ermöglichen (siehe z. B. [21]) oder diese in bereits existierende Steuerungsmechanismen einzubinden. Ein Ansatz, der beide Sichtweisen kombiniert, wird in [22] vorgestellt. Dort findet eine Aufteilung in *Technical Virtual Power Plants* und *Commercial Virtual Power Plants* statt. Dabei werden erstgenannte zur Erbringung von Systemdienstleistungen im Verteilnetz eingesetzt, wohingegen letztere ein Konzept zur Teilnahme der enthaltenen dezentralen Energieerzeuger an einem Energiemarkt darstellen.

Ein Ansatz mit dynamischen Virtuellen Kraftwerken wird von Tröschel in seiner Dissertation vorgeschlagen [111]. Dort betrachtet er eine dynamische Holarchie von Virtuellen Kraftwerken, die dezentrale Energiewandlungsanlagen gruppieren. In jedem dieser Virtuellen Kraftwerke wird eine reaktive Einsatzplanung durchgeführt, die das Ziel hat, durch reaktive Anpassungen an existierenden Fahrplänen auftretende Prognoseabweichungen zu kompensieren. Eine Reorganisation der Virtuellen Kraftwerke wird durchgeführt, wenn diese nicht mehr dazu in der Lage sind, die reaktiven Anpassungen möglichst lokal vorzunehmen. Im Gegensatz zu Autonomen Virtuellen Kraftwerken ist der Zweck der von Tröschel vorgeschlagenen Virtuellen Kraftwerke lediglich eine reaktive Einsatzplanung; eine proaktive Einsatzplanung wird darin nicht ausgeführt.

Der Ansatz der Autonomen Virtuellen Kraftwerke, mit der selbst-organisierten Problemdekomposition mittels einer Hierarchie, die sich zur Laufzeit an veränderte Bedingungen anpassen kann und in der autonom eine robuste

## 6.2. Verwandte Arbeiten

Einsatzplanung unter Berücksichtigung von Unsicherheiten durchgeführt wird, ist in dieser Art und Weise und mit den verwendeten Techniken einzigartig in der Forscherlandschaft.



## ZUSAMMENFÜHRUNG VON AUTONOMEN VERBRAUCHERORGANISATIONEN UND AUTONOMEN VIRTUELLEN KRAFTWERKEN

---

**ZUSAMMENFASSUNG** Fokus dieses Kapitels ist das Zusammenführen der zwei Konzepte der Autonomen Verbraucherorganisationen und der Autonomen Virtuellen Kraftwerke in ein gemeinsames System für ein Supply Demand Management unter Unsicherheiten. Dazu wird vorgestellt, wie Autonome Verbraucherorganisationen in die Hierarchie von Autonomen Virtuellen Kraftwerken integriert werden können und in den Steuerungsprozess eingebunden werden. Des Weiteren präsentiert dieses Kapitel, wie sich dies auf die Selbst-Organisations-Prozesse auswirkt.

# 7

**U**m ein Verständnis dafür zu bekommen, wie Autonome Verbraucherorganisationen in die Hierarchie Autonomer Virtueller Kraftwerke integriert werden können, wird in Abschnitt 7.1 zunächst die robuste Einsatzplanung in einer Hierarchie von Autonomen Virtuellen Kraftwerken [7, 62] dargestellt. Darauf aufbauend wird in Abschnitt 7.2 ein Ansatz zur Integration von Autonomen Verbraucherorganisationen in die Hierarchie von Autonomen Virtuellen Kraftwerken präsentiert. Dazu wird diskutiert, wie der Steuerungsprozess in einem solchen System abläuft und welche Auswirkungen die Integration von Autonomen Verbraucherorganisationen in Autonome Virtuelle Kraftwerke auf die Selbst-Organisations-Prozesse hat.

### 7.1. ROBUSTE EINSATZPLANUNG IN AUTONOMEN VIRTUELLEN KRAFTWERKEN

Dieser Abschnitt stellt die robuste Einsatzplanung in Autonomen Virtuellen Kraftwerken vor und ist eine Zusammenfassung aus [7, 62]; eine detaillierte Beschreibung der robusten Einsatzplanung in Autonomen Virtuellen

## 7. Zusammenführung von AVO und AVKW

Kraftwerken befindet sich in der Dissertation von Anders [5].

Die robuste Einsatzplanung in der hierarchischen Struktur Autonomer Virtueller Kraftwerke läuft top-down ab, d. h. ausgehend von dem Wurzel-AVKW werden Fahrpläne (bzw. Fahrplanbäume auf Basis von TBST – im Folgenden wird der Begriff Fahrplan synonym zu einem Fahrplanbaum verwendet) für die untergeordneten steuerbaren Kraftwerke und AVKW erstellt. Jedes AVKW wiederum erstellt Fahrpläne für seine untergeordneten steuerbaren Kraftwerke und AVKW auf Basis des für ihn erstellten Fahrplans, also die von ihm zu deckende Residuallast. Unten in der Hierarchie angekommen sind demnach alle steuerbaren Kraftwerke mit einem Fahrplan versorgt.

Damit die Einsatzplanung im Wurzel-AVKW gestartet werden kann, benötigt es eine Prognose der lokalen Residuallast. Die lokale Residuallast des Wurzel-AVKW setzt sich zusammen aus der im System anliegenden Last und der antizipierten Residuallast direkt untergeordneter AVKW minus der Leistung der direkt untergeordneten dargebotsabhängigen Erzeuger. Da im bisherigen Verfahren zur robusten Einsatzplanung in Autonomen Virtuellen Kraftwerken davon ausgegangen wird, dass die Last lediglich im Wurzel-AVKW anliegt, ist die lokale Residuallast in einem gewöhnlichem AVKW rekursiv definiert als die antizipierte Residuallast direkt untergeordneter AVKW minus der Leistung der direkt untergeordneten dargebotsabhängigen Erzeuger. Die antizipierte Residuallast seitens eines AVKW wird mit Hilfe von *Trust-basierte Szenarien* (TBS) [16] bestimmt. Auf Basis der vorangegangenen Vorhersagen der lokalen Residuallast wird ein TBST erstellt, der die erwarteten Abweichungen der lokalen Residuallast enthält. Die Verrechnung dieses TBST mit der aktuellen Vorhersage der lokalen Residuallast ergibt einen TBST über die erwartete lokale Residuallast, wodurch man, durch Wahl des antizipierten Szenarios aus diesem Baum, die antizipierte lokale Residuallast erhält, die dem übergeordneten AVKW mitgeteilt wird. Dadurch, dass die antizipierte statt der vorhergesagten lokalen Residuallast nach oben gereicht wird, nimmt das AVKW auch die Verantwortung auf sich, auftretende Abweichungen von der antizipierten lokalen Residuallast lokal zu kompensieren.

Wird einem AVKW ein Fahrplan von einem übergeordneten AVKW zugewiesen, muss es diesen Fahrplan durch eine eigene Einsatzplanung auf seine untergeordneten Kraftwerke weiter verteilen. Dazu verrechnet es das antizipierte Szenario seines zugewiesenen Fahrplans mit dem TBST, der die Abweichungen der lokalen Residuallast enthält. Der daraus entstandene

TBST mit der zu verteilenden Residuallast wird anschließend in der Einsatzplanung verwendet, um Fahrpläne für die darunter liegenden steuerbaren Kraftwerke zu berechnen.

## 7.2. INTEGRATION VON AUTONOMEN

### VERBRAUCHERORGANISATIONEN IN AUTONOME VIRTUELLE KRAFTWERKE

In diesem Abschnitt wird nun beschrieben, wie die Integration von Autonomen Verbraucherorganisationen in das System der Autonomen Virtuellen Kraftwerke erfolgt, um ein koordiniertes autonomes Supply Demand Management unter Unsicherheiten zu ermöglichen.

Wie in Abschnitt 7.1 ersichtlich wurde, wird die Einsatzplanung in Autonomen Virtuellen Kraftwerken im Wurzel-avkw initiiert. Dort wird zum einen die Vorhersage der insgesamt im System anliegenden Last abgefragt und zum anderen die in der Hierarchie bottom-up aufgesammelte Vorhersagen der dargebotsabhängigen Erzeuger verwendet. Auf der anderen Seite arbeiten Autonome Verbraucherorganisationen auf Basis einer Vorhersage der dargebotsabhängigen Leistung, die den Autonomen Verbraucherorganisationen zugewiesen wird.

Ein natürlicher Ansatz wäre nun, die im Wurzel-avkw vorliegende aggregierte Vorhersage der dargebotsabhängigen Leistung an die Menge der Autonomen Verbraucherorganisationen zu reichen. Ein einfacher Mechanismus, der die gesamte dargebotsabhängige Leistung proportional zu der durchschnittlichen Nachfrage der Autonomen Verbraucherorganisationen zuweist, könnte nun dafür sorgen, dass jede Autonome Verbraucherorganisation auf Basis der zugewiesenen dargebotsabhängigen Leistung, wie in Kapitel 5 beschrieben, eine robuste Einsatzplanung durchführt. Ist die Einsatzplanung in den Autonomen Verbraucherorganisationen abgeschlossen, wird die antizipierte Nachfrage – d. h. die antizipierte nicht-steuerbare Nachfrage sowie das antizipierte Szenario der Fahrplanbäume – jeder Autonomen Verbraucherorganisation zu einer gesamten Lastvorhersage aggregiert und dem Wurzel-avkw mitgeteilt. Das Wurzel-avkw kann daraufhin auf Basis dieser aggregierten Lastvorhersage wie gehabt die robuste Einsatzplanung für die Kraftwerke anstoßen.

Die Vorteile dieses Ansatzes liegen primär in der einfachen Umsetzung. So müssen die getrennten Systeme der Autonomen Virtuellen Kraftwerke

## 7. Zusammenführung von AVO und AVKW

und der Autonomen Verbraucherorganisationen lediglich über eine einfache Schnittstelle gekoppelt werden, die den Autonomen Verbraucherorganisationen die Vorhersage der dargebotsabhängigen Erzeuger übermittelt und die den Autonomen Virtuellen Kraftwerken die Vorhersage der nachgefragten Leistung übergibt. Sowohl die Einsatzplanung in den Autonomen Virtuellen Kraftwerken als auch die Einsatzplanung in den Autonomen Verbraucherorganisationen können unverändert ablaufen. Auch die selbst-organisierte Strukturausbildung muss in beiden Systemen nicht angepasst werden.

Ein anderer Ansatz, der diese Nachteile nicht hat, ist die Integration von Autonomen Verbraucherorganisationen direkt in die Hierarchie von Autonomen Virtuellen Kraftwerken. Autonome Verbraucherorganisationen werden in diesem Ansatz Autonomen Virtuellen Kraftwerken direkt untergeordnet, so dass die Autonomen Virtuellen Kraftwerke neben einer lokalen dargebotsabhängigen Erzeugung auch eine lokale Nachfrage haben. Unsicherheiten, die beispielsweise durch nicht-steuerbare Verbraucher in einer im AVKW enthaltenen AVO entstehen, können somit wenn möglich lokal innerhalb dieses AVKW kompensiert werden, ohne andere Teile des Systems zu beeinträchtigen, wie es im Fall des zuvor vorgestellten Ansatzes wäre, wo auftretende Abweichungen der nachgefragten Leistung vom Wurzel-AVKW ausgehend in dem System der Autonomen Virtuellen Kraftwerke behoben werden müsste, womit die AVKW womöglich gar nicht gerechnet haben. Zudem bildet die Integration von Autonomen Verbraucherorganisationen in Autonome Virtuelle Kraftwerke die Realität hinsichtlich der physikalischen Infrastruktur des elektrischen Energieversorgungssystems besser ab, auch wenn dies in dieser Arbeit nicht relevant ist, sondern erst in zukünftigen Arbeiten angegangen wird. Die Anzahl untergeordneter Autonome Verbraucherorganisationen eines Autonomen Virtuellen Kraftwerks kann beliebig groß sein. Genauso kann es Autonome Virtuelle Kraftwerke geben, die keine untergeordneten Autonomen Verbraucherorganisationen haben. Abbildung 7.1 zeigt eine beispielhafte Illustration eines solchen Systems.

Der Nachteil dieses Ansatzes ist die etwas komplexere Umsetzung gegenüber dem zuvor genannten Ansatz. So muss der Ablauf der Einsatzplanung in Autonomen Virtuellen Kraftwerken leicht modifiziert werden. Die selbst-organisierte Strukturausbildung muss derart angepasst werden, dass eine Struktur aus Autonomen Virtuellen Kraftwerken und Autonomen Verbraucherorganisationen geschaffen wird, die das Systemziel optimal unterstützt.

In Abschnitt 7.2.1 erfolgt nun eine kurze Vorstellung des Steuerungspro-

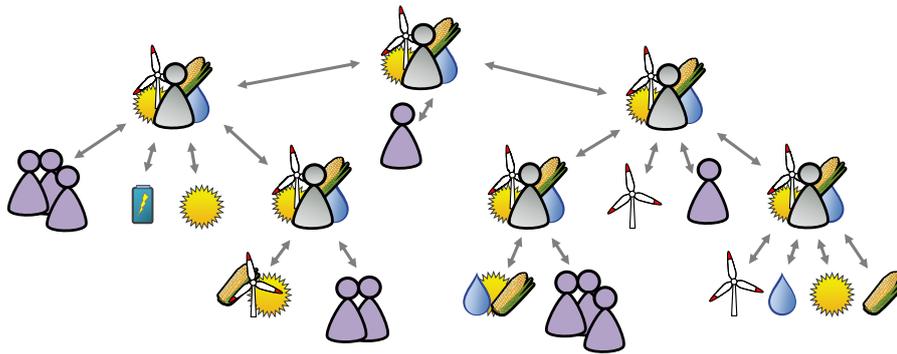


Abbildung 7.1.: Exemplarisches System Autonomer Virtueller Kraftwerke mit integrierten Autonomen Verbraucherorganisationen (in Anlehnung an [14]). Autonome Verbraucherorganisationen (in violett) werden Autonomen Virtuellen Kraftwerken untergeordnet. Dabei kann ein AVKW auch keine untergeordnete AVO haben, wie in diesem Beispiel das AVKW ganz rechts.

zesses in einem solchen System, woraufhin in Abschnitt 7.2.2 der Ablauf der Selbst-Organisation vorgestellt wird.

### 7.2.1. ABLAUF DES KOMBINIERTEN STEUERUNGSPROZESSES IM SYSTEM

Wie zuvor wird im Wurzel-AVKW für die Einsatzplanung steuerbarer Kraftwerke eine Vorhersage der lokalen Residuallast benötigt. Im Gegensatz zu dem in Abschnitt 7.1 geschilderten Vorgehen, ist die lokale Residuallast in einem System aus AVKW und AVO in jedem AVKW gleich definiert. Die lokale Residuallast setzt sich zusammen aus der antizipierten Residuallast direkt untergeordneter AVKW, der antizipierten Nachfrage direkt untergeordneter Autonome Verbraucherorganisationen und der Leistung direkt untergeordneter dargebotsabhängiger Erzeuger. Das bedeutet, dass ein AVKW für das Hochreichen der antizipierten lokalen Residuallast an sein übergeordnetes AVKW eine antizipierte Nachfrage der direkt untergeordneten Autonomen Verbraucherorganisationen benötigt, also eine Einsatzplanung für alle untergeordneten Autonomen Verbraucherorganisationen durchgeführt werden muss, die die lokale Residuallast glättet. Die AVKW geben demnach eine geglättete, antizipierte lokale Residuallast an ihr übergeordnetes AVKW. Die Einsatzplanung Autonome Verbraucherorganisationen läuft aus Sicht der Hierarchie also Bottom-Up, wohingegen die Einsatzplanung für Autonome

## 7. Zusammenführung von AVO und AVKW

Virtuelle Kraftwerke im Anschluss Top-Down ausgeführt wird.

Damit eine Autonome Verbraucherorganisation seinem übergeordneten AVKW eine Vorhersage über die antizipierte Nachfrage geben kann, muss sie auf Basis der Vorhersage der lokal im AVKW untergeordneten dargebotsabhängigen Erzeuger eine Glättung der Residuallast durchführen. Dazu ist es notwendig, dass die dargebotsabhängige Leistung des Autonomen Virtuellen Kraftwerks auf die untergeordneten Autonomen Verbraucherorganisationen aufgeteilt wird. Diese wird proportional zu der durchschnittlich nachgefragten Leistung der Autonomen Verbraucherorganisationen zugewiesen.

### 7.2.2. ABLAUF DER SELBST-ORGANISATION IM SYSTEM

Werden Autonome Verbraucherorganisationen in Autonome Virtuelle Kraftwerke wie beschrieben integriert, hat das auch Auswirkungen darauf, wie die selbst-organisierte Ausbildung der Systemstruktur abläuft. So ist zum einen zu klären, wie eine Reorganisation von Autonomen Verbraucherorganisationen abzulaufen hat, wenn diese innerhalb einer Hierarchie von Autonomen Virtuellen Kraftwerken stattfindet. Zum anderen ist zu klären, wie die hierarchische Ausbildung Autonomer Virtueller Kraftwerke unter Berücksichtigung der integrierten Autonomen Verbraucherorganisationen abläuft.

#### *Selbst-organisierte Reorganisation von Autonomen Verbraucherorganisationen in einer Hierarchie von Autonomen Virtuellen Kraftwerken*

Prinzipiell ändert sich bei der selbst-organisierten Reorganisation von Autonomen Verbraucherorganisationen, wenn sie Teil der Hierarchie von Autonomen Virtuellen Kraftwerken sind, nicht viel gegenüber dem Fall, wenn sie für sich alleine betrachtet werden (siehe Kapitel 4). So ist lediglich das Partitionierungsproblem nicht mehr für die gesamten im System befindlichen Verbraucher zu lösen, sondern für diejenigen Verbraucher, deren Autonome Verbraucherorganisationen demselben Autonomen Virtuellen Kraftwerk untergeordnet sind (siehe Abbildung 7.2 für ein Beispiel).

Die Kriterien zur Ausbildung von Autonomen Verbraucherorganisationen bleiben unverändert, d. h. es soll nach wie vor eine homogene Partitionierung gemäß der Flexibilität und des Trust-Werts der Verbraucher bestehen. Die Überprüfung seitens der Autonomen Verbraucherorganisationen, ob

## 7.2. Integration von AVO in AVKW

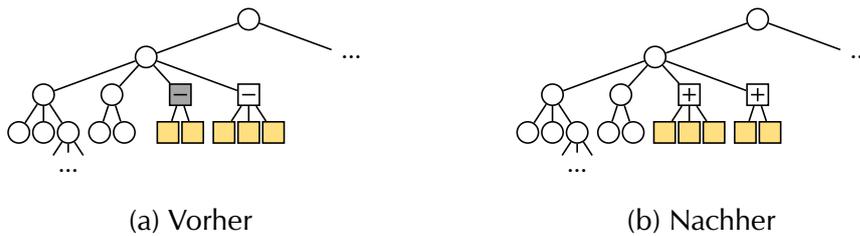


Abbildung 7.2.: Reorganisation von Autonomem Verbraucherorganisationen in einem Autonomem Virtuellem Kraftwerk. Kraftwerke (Blätter) und Autonome Virtuelle Kraftwerke (innere Knoten) sind als Kreise, Verbraucher (Blätter) und Autonome Verbraucherorganisationen (innere Knoten) als Quadrate dargestellt. Nachdem die graue AVO  $\blacksquare$  eine Verletzung des Constraints festgestellt hat, dass die Einhaltung der homogenen Partitionierung überwacht, wird für den betroffenen Teil der Hierarchie, d. h. die Kinder und Neffen von  $\blacksquare$ , markiert in Orange  $\blacksquare$ , ein Partitionierungsproblem gelöst. In diesem Beispiel werden die zu partitionierenden Verbraucher in zwei neue AVO  $\boxplus$  partitioniert, die die zwei alten AVO  $\blacksquare$  ersetzen.

eine homogene Partitionierung aktuell vorliegt, ist auf die benachbarten Autonomem Verbraucherorganisationen, die demselben Autonomem Virtuellem Kraftwerk untergeordnet sind, beschränkt. Wird von einer Autonomem Verbraucherorganisation festgestellt, dass das Constraint, das überprüft, ob eine homogene Partitionierung vorliegt, verletzt ist, stößt es eine Reorganisation für die eigenen und die untergeordneten Verbrauchern der benachbarten Autonomem Verbraucherorganisationen in demselben Autonomem Virtuellem Kraftwerk an. Das zu lösende Partitionierungsproblem kann dann wie gehabt von PSOPP oder SPADA gelöst werden (siehe Kapitel 4).

Für das übergeordnete Autonome Virtuelle Kraftwerk ändert sich nichts, außer dass es im Anschluss an die Reorganisation darüber informiert werden muss, welche neuen Autonomem Verbraucherorganisationen ihm fortan untergeordnet sind und die alten ersetzen.

Für den Fall, dass nur eine einzige Autonome Verbraucherorganisation einem Autonomem Virtuellem Kraftwerk untergeordnet ist, ist selbstverständlich eine Reorganisation nicht möglich.

## 7. Zusammenführung von AVO und AVKW

### *Selbst-organisierte Ausbildung von hierarchischen Autonomen Virtuellen Kraftwerken mit Autonomen Verbraucherorganisationen*

Im Gegensatz zu der Reorganisation Autonomer Verbraucherorganisationen muss bei der Reorganisation Autonomer Virtueller Kraftwerke mehr angepasst werden.

**REORGANISATION INNERHALB EINER HIERARCHIEEBENE** Autonome Virtuelle Kraftwerke haben weiterhin das Ziel, eine homogene Partitionierung zu erreichen. Diese muss nun allerdings neben den die Kraftwerke betreffenden Kriterien wie die Steuerbarkeit und der Prognosefehler der Kraftwerke auch die Verbraucher mit einbeziehen. Bei einer Reorganisation wird daher das Partitionierungsproblem für Kraftwerke und Verbraucher gemeinsam gelöst. Daran beteiligt sind alle Autonomen Virtuellen Kraftwerke in der selben Nachbarschaft, also alle Autonomen Virtuellen Kraftwerke, die demselben Vater-AVKW direkt untergeordnet sind. Zu partitionieren ist die Gesamtheit der jeweils untergeordneten Kraftwerke und Verbraucher untergeordneter Autonomer Verbraucherorganisationen aller beteiligten Autonomen Virtueller Kraftwerke. Abbildung 7.3 zeigt diesen Zusammenhang an einem Beispiel.

Wurde das Partitionierungsproblem wie oben beschrieben mit einem Algorithmus wie PSOPP oder SPADA gelöst (siehe Kapitel 4), sind Autonome Virtuelle Kraftwerke entstanden, welche nur eine Menge an Verbrauchern enthalten, jedoch keine Autonomen Verbraucherorganisationen. Daher muss innerhalb jedes Autonomen Virtueller Kraftwerks im Anschluss noch das Partitionierungsproblem für die Verbraucher gelöst werden, um eine Menge an Autonomen Verbraucherorganisationen zu erhalten. Unter Umständen, wenn die Menge an Verbrauchern verhältnismäßig gering ist, kann das auch zu einer einzigen Autonomen Verbraucherorganisation führen, wenn die Partitionierungsbedingungen das zulassen, also  $n_{\min} = 1$  und die Anzahl an zu partitionierenden Verbrauchern kleiner ist als  $2 \cdot s_{\min}$ .

**EINFÜHREN EINER NEUEN HIERARCHIEEBENE** Soll eine neue Hierarchieebene unterhalb eines AVKW eingeführt werden, weil dieses AVKW den Schwellwert überschreitet, der die maximale Dauer für die Einsatzplanung definiert, muss wie im Fall der Reorganisation innerhalb einer Hierarchieebene das Partitionierungsproblem für Kraftwerke und Verbraucher gemeinsam gelöst

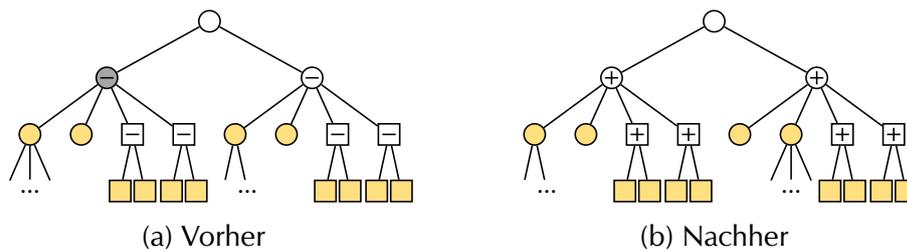


Abbildung 7.3.: Reorganisation innerhalb einer Hierarchieebene unter einem Autonomem Virtuellem Kraftwerk. Kraftwerke (Blätter) und Autonome Virtuelle Kraftwerke (innere Knoten) sind als Kreise, Verbraucher (Blätter) und Autonome Verbraucherorganisationen (innere Knoten) als Quadrate dargestellt. Nachdem das graue AVKW  $\ominus$  eine Verletzung des Constraints festgestellt hat, welches überprüft, ob eine homogene Partitionierung vorliegt, wird für den betroffenen Teil der Hierarchie, also die untergeordneten Kraftwerke und Verbraucher und die jeweiligen Neffen, markiert in Orange  $\odot$   $\blacksquare$ , ein Partitionierungsproblem gelöst. In diesem Beispiel werden zwei neue AVKW – dargestellt durch  $\oplus$  – erstellt. Im Anschluss muss in beiden neu erstellten Autonomen Virtuellen Kraftwerken nachgelagert das Partitionierungsproblem für die zugeordneten Verbraucher  $\blacksquare$  gelöst werden. Die dabei neu entstehenden Autonomen Verbraucherorganisationen sind durch  $\boxplus$  dargestellt.

werden. Konkret wird es für alle direkt untergeordneten Kraftwerke des betroffenen AVKW sowie für alle Verbraucher, die in den untergeordneten Autonomen Verbraucherorganisationen enthalten sind, gelöst. Wurde unterhalb des AVKW eine neue Hierarchiestufe mit neuen AVKW erstellt, ist innerhalb dieser im Anschluss noch das Partitionierungsproblem für die jeweiligen Mengen an Verbrauchern zu lösen, um die jeweiligen untergeordneten Autonomen Verbraucherorganisationen zu erhalten. Abbildung 7.4 illustriert dies an einem kleinen Beispiel.

**AUFLÖSEN EINES AUTONOMEN VIRTUELLEN KRAFTWERKS** Das Auflösen eines Autonomen Virtuellen Kraftwerks bei Unterschreitung des Schwellwerts, der die minimale Einsatzplanungsdauer definiert, läuft genauso ab, wie im Fall ohne integrierte Autonome Verbraucherorganisationen (siehe Kapitel 6). Das bedeutet, dass das AVKW welches sich auflöst, seine untergeordneten Kraftwerke – und zusätzlich seine untergeordneten Autonomen Verbraucherorganisationen – seinem übergeordnetem AVKW zuordnet.

## 7. Zusammenführung von AVO und AVKW

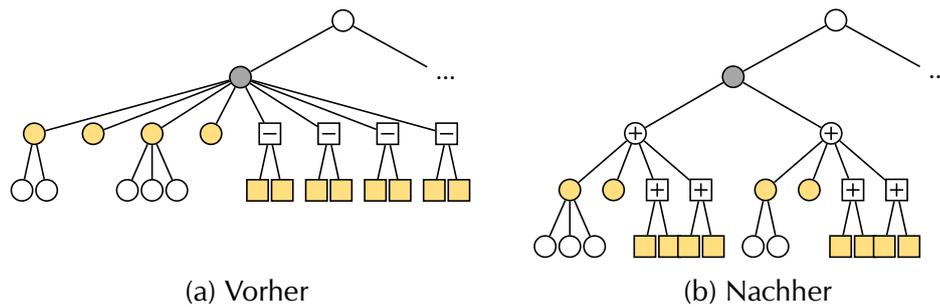


Abbildung 7.4.: Einführung einer neuen Hierarchieebene unter einem Autonomem Virtuellem Kraftwerk. Kraftwerke (Blätter) und Autonome Virtuelle Kraftwerke (innere Knoten) sind als Kreise, Verbraucher (Blätter) und Autonome Verbraucherorganisationen (innere Knoten) als Quadrate dargestellt. Nachdem das graue AVKW  $\ominus$  eine Verletzung des Constraints festgestellt hat, welches fordert, dass die Dauer der Einsatzplanung unter einen maximalen Schwellwert zu sein hat, wird für die untergeordneten Kraftwerke und die in den untergeordneten Autonomen Verbraucherorganisationen enthaltenen Verbraucher, markiert in Orange  $\ominus$   $\square$ , ein Partitionierungsproblem gelöst. In diesem Beispiel werden zwei neue AVKW – dargestellt durch  $\oplus$  – erstellt, die im Anschluss noch das Partitionierungsproblem für die ihnen zugeordneten Verbraucher zu lösen haben. Die dabei neu entstandenen Autonomen Verbraucherorganisationen sind durch  $\boxplus$  dargestellt.

### 7.3. VERWANDTE ARBEITEN

In der Literatur gibt es einige Ansätze zu einem Supply Demand Management in Smart Grids. Die Art und Weise, wie eine selbst-organisierte Hierarchie von Erzeugern und Verbrauchern eine Einsatzplanung über mehrere Zeitschritte unter der Betrachtung von Unsicherheiten durchführen ist in dieser Kombination und unter den verwendeten Techniken soweit bekannt jedoch einzigartig.

Ansätze wie der PowerMatcher [61], DEZENT [118] oder Stigspace [67] sind beispielsweise Verfahren, die mittels unterschiedlicher markt-basierter Mechanismen ein Supply Demand Management durchführen. Neben der fehlenden Fähigkeit, Fahrpläne für mehrere Zeitschritte zu erstellen [61, 118], fehlt diesen Ansätzen der Umgang mit Unsicherheiten.

Hinrichs präsentiert in seiner Dissertation [47] die Heuristik COHDA [48] zur verteilten kombinatorischen Optimierung. Diese Heuristik läuft vollkommen dezentral ab und hat das Ziel, eine Einsatzplanung anhand eines global bekannten Ziels durch eine verteilte Konsensbildung unter den Systemteilnehmern durchzuführen. Dazu haben die Systemteilnehmer eine Nachbarschaftsbeziehung untereinander, um sowohl Informationen über ihre eigenen aktuell gewählten Konfigurationen als auch die Konfigurationen der Nachbarn auszutauschen. Anhand des sich aufbauenden und aktualisierenden Wissens passen die Systemteilnehmer iterativ ihre eigene Konfiguration an, bis sich ein Konsens gebildet hat. Neben der vollkommen anderen, dezentralen Herangehensweise unterscheidet sich COHDA von dem hier betrachteten Ansatz vor allem dadurch, dass keinerlei Unsicherheiten betrachtet werden.

In [54] werden von Kamper und Schmeck Gerätepools von flexiblen Erzeugern und Verbrauchern betrachtet, die innerhalb eines Bilanzkreises einen Ausgleich von kurzfristigen Schwankungen durchführen. Die auszugleichenden Schwankungen können dabei sowohl intern als auch extern sein. Sogenannte Elitäre Gruppen, deren Zusammensetzung sich dynamisch ändern kann, übernehmen dabei den sofortigen Ausgleich kleinerer Schwankungen, wohingegen der restliche Gerätepool für den Ausgleich größerer und länger andauernder Schwankungen verantwortlich ist. Eine proaktive Einsatzplanung auf Basis von Unsicherheiten findet in diesem Ansatz nicht statt.



## IV.

# EVALUATION UND SCHLUSS

Im letzten Teil der Arbeit findet eine ausführliche Evaluierung des Ansatzes statt. Außerdem wird die Arbeit durch eine Zusammenfassung der erzielten Ergebnisse und der Identifizierung offener Forschungsfragen und zukünftiger Arbeiten abgeschlossen.



**ZUSAMMENFASSUNG** In diesem Kapitel findet eine ausführliche Evaluierung des in dieser Arbeit vorgestellten Ansatzes statt. Dazu werden zunächst Autonome Verbraucherorganisationen in verschiedenen Evaluationsszenarien untersucht und gezeigt, dass die robuste Einsatzplanung in Autonomen Verbraucherorganisationen trotz vorliegender Unsicherheiten die Residuallast erfolgreich glätten kann. Anschließend erfolgt die Betrachtung eines Systems von Autonomen Virtuellen Kraftwerken zusammen mit Autonomen Verbraucherorganisationen.

**I**N diesem Kapitel soll die robuste Steuerung von elektrischen Verbrauchern in Autonomen Verbraucherorganisationen und deren Integration in eine Hierarchie von Autonomen Virtuellen Kraftwerken simulativ evaluiert werden. Dazu werden zunächst in Abschnitt 8.1 die Evaluationsziele genannt; anschließend erfolgt eine Schilderung des generellen Evaluationsaufbaus in Abschnitt 8.2 und eine Aufführung der gesammelten Daten und ausgewerteten Metriken in Abschnitt 8.3. In Abschnitt 8.4 folgt eine Evaluierung, die sich nur auf die robuste Einsatzplanung in Autonomen Verbraucherorganisationen fokussiert. Dazu werden verschiedenen Evaluationsszenarien aufgestellt und die darin erzielten Ergebnisse vorgestellt und diskutiert. Im Anschluss wird in Abschnitt 8.5 ein System von Autonomen Virtuellen Kraftwerken gekoppelt mit Autonomen Verbraucherorganisationen betrachtet. Auch dort werden unterschiedliche Evaluationsszenarien aufgestellt und im Anschluss die Evaluierungsergebnisse vorgestellt und diskutiert. Abschnitt 8.6 schließt dieses Kapitel mit einem Fazit ab.

### 8.1. EVALUATIONSZIELE

Ziel dieser Evaluation ist die Untersuchung folgender Fragestellungen:

## 8. Evaluation

- Führt die Einsatzplanung im Allgemeinen zu besseren Ergebnissen als im ungesteuerten Fall?
- Werden Unsicherheiten in der ungesteuerten Leistung durch den Einsatz von TBS adäquat quantifiziert und antizipiert, so dass eine Einsatzplanung mittels TBS unter Unsicherheiten zu besseren Resultaten führt, als sich nur auf die Vorhersagen zu verlassen?
- Bringen Fahrpläne für einen ganzen TBST Vorteile gegenüber einem Fahrplan lediglich für das antizipierte Szenario?
- Können Autonome Verbraucherorganisationen, die gemäß einer homogenen Partitionierung gebildet sind, das Systemziel besser erreichen, als Autonome Verbraucherorganisationen, die aus ähnlichen Verbrauchern bestehen?
- Wie ist der Zusammenhang zwischen der Lösungsqualität und der Größe einer AVO? Welche Rolle spielt dabei die Zusammensetzung einer AVO?
- Was sind die Auswirkungen verschiedener Planungshorizonte auf die Ergebnisse und die Komplexität?
- Gibt es neben der veränderten Residuallast weitere positive oder negative Auswirkungen auf den Betrieb Autonomer Virtueller Kraftwerke, wenn Autonome Verbraucherorganisationen in die Hierarchie von Autonomen Virtuellen Kraftwerken integriert werden?

### 8.2. EVALUATIONSAUFBAU

Die Evaluation wurde in dem Multiagentensystem TEMAS [11] durchgeführt. Die Simulation erfolgte runden-basiert, wobei jede Runde einem diskreten Zeitschritt entsprach. Der zeitliche Unterschied  $\Delta t$  zwischen zwei diskreten Zeitschritten betrug 15 Minuten; ebenso das Zeitraster  $\Delta \tau$ , für das Fahrpläne erstellt werden. Fahrpläne wurden in jedem Zeitschritt neu berechnet. Die Anzahl an Zeitschritten  $N$ , für die Fahrpläne erstellt wurden, wurde in verschiedenen Evaluationsszenarien variiert und ihre Auswirkungen untersucht; Details dazu folgen in den nachfolgenden Abschnitten.

### 8.3. Evaluationsmetriken und ausgewertete Daten

Für die Quantifizierung und Antizipation von Unsicherheiten wurden die TBS aufgrund von vorhergehenden Versuchen wie folgt parametrisiert: TBS wurden auf der Basis der 50 letzten Erfahrungen generiert; die Klassenbreite des ersten relativen Zeitschritts betrug 0,5 % der maximalen Prognoseabweichung dieser Erfahrungen, die der letzten Klasse 10 %.

Das Optimierungsproblem und die Steuerungsmodelle wurden für den Optimierer CPLEX<sup>28</sup> – einem Standard-Tool zur Lösung von Optimierungsproblemen – formuliert und davon gelöst. Dabei wurde CPLEX eine maximale Lösungszeit von 30 s vorgegeben und die bis dahin gefundene Lösung verwendet. Fand CPLEX schon vor Ablauf dieser Zeit eine optimale Lösung, wurde diese sofort zurückgegeben.

Je nach Evaluationsszenario wurden verschiedene Systemkonfigurationen von Verbrauchern, Erzeugern, Autonomen Verbraucherorganisationen und Autonomen Virtuellen Kraftwerken generiert und untersucht. Diese werden im Detail in den zugehörigen Abschnitten, in denen sie relevant sind, vorgestellt.

Für jedes Evaluationsszenario wurden 50 Simulationsläufe durchgeführt und die Ergebnisse gemittelt. Jeder Simulationslauf führte dabei 192 diskrete Zeitschritte aus, was einer simulierten Dauer von zwei Tagen entspricht.

Im Rahmen der Evaluierung fand keine Selbst-Organisation statt, d. h. die jeweils vorliegende Systemstruktur hatte von Beginn bis Ende des Simulationslaufes Bestand.

### 8.3. EVALUATIONSMETRIKEN UND AUSGEWERTETE DATEN

An dieser Stelle sollen in Kürze die für die Evaluation notwendigen Daten und Metriken erläutert werden.

Die wichtigsten Metriken betreffen die Glättung der Residuallast. Dazu stellt  $\Delta R_{\mu}^{\omega}$  die durchschnittlich pro Autonomer Verbraucherorganisation  $\omega \in \Omega$  pro Zeitschritt  $t$  aufgetretene absolute Differenz  $\Delta R_t^{\omega} = |R_t^{\omega} - R_{t-1}^{\omega}|$  der Residuallast zum vorherigen Zeitschritt dar, gemittelt über alle Autonomen Verbraucherorganisationen, Zeitschritte und Simulationsläufe.

Analog dazu stellt  $\Delta U_{\mu}^{\omega}$  die durchschnittlich pro Autonomer Verbraucherorganisation  $\omega \in \Omega$  pro Zeitschritt  $t$  aufgetretene absolute Differenz

<sup>28</sup> IBM ILOG CPLEX Optimizer, Version 12.6: <http://www-01.ibm.com/software/commerce/optimization/cplex-optimizer/index.html> (besucht am 10.03.2017)

## 8. Evaluation

$\Delta U_t^\omega = |U_t^\omega - U_{t-1}^\omega|$  der ungesteuerten Leistung zum vorherigen Zeitschritt dar, gemittelt über alle Autonomen Verbraucherorganisationen, Zeitschritte und Simulationsläufe. Die Gegenüberstellung von  $\Delta U_\mu^\omega$  und  $\Delta R_\mu^\omega$  zeigt auf, ob die aus einer Einsatzplanung resultierende gesteuerte Nachfrage die durch die ungesteuerte Leistung gegebenen absoluten Differenzen reduzieren kann. Ist dem so, gilt  $\Delta R_\mu^\omega < \Delta U_\mu^\omega$ . Dass dies gilt ist zwar erstrebenswert, muss durch eine Einsatzplanung aber auch nicht zwingend gegeben sein, wenn beispielsweise zahlreiche programmgetriebene Verbraucher oder Elektrofahrzeuge gleichzeitig eine hohe Nachfrage verursachen, die nicht besser verteilt werden kann.

Durch  $\Delta^2 R_\mu^\omega$  werden die mittleren Änderungen  $|\Delta R_t^\omega - \Delta R_{t-1}^\omega|$  von einem Zeitschritt zum nächsten Zeitschritt  $t$  dargestellt, gemittelt über alle Zeitschritte und Simulationsläufe. Kleine  $\Delta^2 R_\mu^\omega$  spiegeln somit gleichmäßige, glatte Veränderungen der Residuallast wider, wohingegen größere  $\Delta^2 R_\mu^\omega$  auf wechselnde Veränderungen und somit eine unruhigere Residuallast hinweisen. Jedoch ist die alleinige Interpretation von  $\Delta^2 R_\mu^\omega$  ohne Betrachtung von  $\Delta R_\mu^\omega$  unter Umständen irreführend: So verursacht eine konstant steigende oder fallende Residuallast einen kleinen Wert  $\Delta^2 R_\mu^\omega$ , wohingegen eine mehr oder weniger glatte Residuallast, die lediglich minimal um einen Wert hin- und herpendelt, einen größeren Wert  $\Delta^2 R_\mu^\omega$  liefert.  $\Delta^2 R_\mu^\omega$  sollte daher immer im Zusammenhang mit  $\Delta R_\mu^\omega$  betrachtet werden.

$R_{\min}$ ,  $R_{\max}$  und  $R_\downarrow = R_{\max} - R_{\min}$  bezeichnen die im ganzen System in einem Simulationslauf minimal aufgetretene Residuallast, die maximal aufgetretene Residuallast und die Spreizung der Residuallast, jeweils gemittelt über alle Simulationsläufe. Obwohl zum einen die Zielfunktion des Optimierungsproblems nicht das Ziel hat, die Spreizung der Residuallast zu minimieren bzw. die minimale oder maximale Residuallast zu beschränken und somit unter Umständen zu einer größeren Spreizung führt – ein glattes, hohes Plateau der Residuallast würde beispielsweise einem niedrigerem, aber unruhigerem Verlauf der Residuallast bevorzugt – und zum anderen je nach Verfügbarkeit der Verbraucher gar keine Möglichkeit besteht, die Spreizung der Residuallast zu verändern – z. B. tagsüber laufende programmgetriebene Verbraucher –, werden diese Daten in der Evaluation ausgewertet und diskutiert, um zu erfahren, ob bzw. wie sich die Flexibilisierung der Nachfrage unter verschiedenen Bedingungen auf  $R_\downarrow$  auswirkt.

$R_\mu$ ,  $S_\mu$  und  $U_\mu$  stellen die im ganzen System durchschnittlich pro Zeitschritt ermittelte Residuallast, gesteuerte Nachfrage bzw. ungesteuerte Leis-

#### 8.4. Demand Side Management: Evaluationsszenarien und -ergebnisse

tung dar, jeweils gemittelt über alle Zeitschritte und Simulationsläufe.

Im Gegensatz dazu repräsentiert  $\Delta P$  die absolute Abweichung der erzeugten Leistung von der tatsächlichen Residuallast im gesamten System, gemittelt über alle Zeitschritte und Simulationsläufe.

Die durchschnittlich benötigte Dauer einer AVO für die Berechnung der Fahrpläne, gemittelt über alle  $\omega \in \Omega$ , alle Zeitschritte und alle Simulationsläufe, wird mit  $T^\omega$  bezeichnet. Analog dazu bezeichnet  $T^\lambda$  die durchschnittlich benötigte Dauer eines AVKW für die Berechnung von Fahrplänen, ebenfalls gemittelt über alle Autonomen Virtuellen Kraftwerke, alle Zeitschritte und alle Simulationsläufe.

Die durchschnittliche Anzahl an Trust-basierten Szenarien, die in einem Autonomen Virtuellen Kraftwerk für die Erstellung von Fahrplänen vorlag, wird mit  $\#TBS^\lambda$  bezeichnet. Diese ist ebenfalls über alle AVKW, Zeitschritte und Simulationsläufe gemittelt.

#### 8.4. DEMAND SIDE MANAGEMENT: EVALUATIONSSZENARIEN UND -ERGEBNISSE

In diesem Abschnitt liegt der Fokus zunächst auf der robusten Einsatzplanung in Autonomen Verbraucherorganisationen, also dem reinen Demand Side Management. Die Integration mit Autonomen Virtuellen Kraftwerken wird im darauf folgenden Abschnitt untersucht (siehe Abschnitt 8.5).

Jede AVO bekam in der Evaluation eine ungesteuerte Leistung  $U^\omega$  vorgegeben, die auf realen Lastdaten basierte<sup>29</sup>. Das beinhaltete somit auch die Nachfrage untergeordneter nicht steuerbarer Verbraucher, die im Folgenden nicht mehr als Teil der Systemkonfiguration aufgefasst werden. Für die Untersuchung der Auswirkungen von zeitabhängigen Unsicherheiten wurden für die ungesteuerte Leistung  $U^\omega$  verschiedene Abfolgen von Prognosefehlern verwendet. So konnte die tatsächliche ungesteuerte Leistung von der vorhergesagten ungesteuerten Leistung (1) in der Abfolge 0%, 1%, 0%, -1% und 0%, oder (2) in der Abfolge 0%, 2%, 3%, 2%, 0%, -2%, -3%, -2% und 0%, oder (3) fünf Zeitschritte am Stück mit 0% abweichen. Nach jeder solchen Abfolge von Abweichungen wurde zufällig (gleichverteilt) die nächste Abfolge von Abweichungen ausgewählt.

<sup>29</sup> LEW Netzdaten, <https://www.lew-verteilnetz.de/stromnetz/netz/netzdaten> (besucht am 20.03.2017)

## 8. Evaluation

Für die Evaluation wurden verschiedene Modelle von thermischen Verbrauchern, programmgetriebenen Verbrauchern und Elektrofahrzeugen mit realitätsnahen Daten generiert. Die Modelle programmgetriebener Verbraucher wurden dabei so generiert, dass diese tagsüber betrieben wurden; im frühesten Fall konnte ein programmgetriebener Verbraucher bereits um 6:00 Uhr gestartet werden, im spätesten Fall musste ein programmgetriebener Verbraucher um 1:00 Uhr beendet sein.  $t_{\text{early}}$  und  $t_{\text{late}}$  wurden dabei voneinander abhängig generiert, so dass der Abstand dieser Zeitpunkte mindestens eine Stunde, maximal jedoch sechs Stunden betrug. Elektrofahrzeuge hatten eine zufällige Ankunftszeit  $t_{\text{arr}}$  zwischen 9:00 Uhr und 22:30 Uhr, und fuhren zu einem zufälligen Zeitpunkt  $t_{\text{dep}}$  zwischen 5:00 Uhr und 18:30 Uhr.  $t_{\text{arr}}$  und  $t_{\text{dep}}$  wurden dabei auch voneinander abhängig generiert, so dass der Abstand zwischen Ankunft und Abfahrt mindestens fünf Stunden, jedoch weniger als ein Tag betrug. Zwischen der Abfahrt und der Ankunft eines Elektrofahrzeugs wurde der letztmalige Batteriestand zufällig reduziert, mindestens jedoch um 20 %. Die maximale Ladeleistung  $P_{\text{max}}$  eines Elektrofahrzeugs wurde zufällig zwischen 3,7 kW, 11 kW und 22 kW gewählt, wobei die ersteren beiden jeweils dreimal so wahrscheinlich waren wie letztere; die maximale Entladeleistung  $P_{\text{min}}$  entsprach dabei der negierten maximalen Ladeleistung  $P_{\text{max}}$ . Sowohl bei programmgetriebenen Verbrauchern als auch bei Elektrofahrzeugen veränderten sich die zeitabhängigen Parameter über die Simulation mehrerer Tage hinweg nicht, d. h. ein Elektrofahrzeug, das an einem Tag um 18:00 Uhr ankam, tat das auch am nächsten Tag. Die übrigen generierten Parameter für die Steuerungsmodelle basierten auf Normalverteilungen, deren Parametrisierung Tabelle 8.1 entnommen werden können.

Wurden Fahrpläne für steuerbare Verbraucher für einen ganzen TBST berechnet und nicht nur für ein TBS oder nur für die Vorhersage, dann haben die steuerbaren Verbraucher ihre Nachfrage gemäß dem antizipierten Szenario im nächsten Zeitschritt gewählt. Für das Evaluationsszenario, in welchem die potentiell steuerbaren Verbraucher nicht gesteuert wurden, verhielten sich diese wie folgt: Thermische Verbraucher waren so lange an- bzw. ausgeschaltet, bis ihre Temperatur im nächsten Zeitschritt das zulässige Temperaturintervall verlassen hätte; in diesem Fall wechselten sie vom angeschalteten Zustand in den ausgeschalteten Zustand und umgekehrt. Die programmgetriebenen Verbraucher schalteten sich im ungesteuerten Fall zum frühestmöglichen Startzeitpunkt an. Ungesteuerte Elektrofahrzeuge

#### 8.4. Demand Side Management: Evaluationsszenarien und -ergebnisse

<b>Thermische Verbraucher</b>	
$P_{\text{on}}$	$\mu = 1,00; \sigma = 0,10$
$P_{\text{off}}$	0
$T_{\text{min}}$	$\mu = 3,00; \sigma = 0,50$
$T_{\text{max}}$	$\mu = 8,00; \sigma = 0,50$
$\Delta T_{\text{on}}$	$\mu = -0,10; \sigma = 0,01$
$\Delta T_{\text{off}}$	$\mu = 0,03; \sigma = 0,003$
<b>Programmgetriebene Verbraucher</b>	
$P_{\text{on}}$	$\mu = 2,50; \sigma = 0,25$
$P_{\text{off}}$	0
$\tau_{\text{dur}}$	$\mu = 120,00; \sigma = 15,00$
<b>Elektrofahrzeuge</b>	
$E_{\text{min}}$	0
$E_{\text{max}}$	$\mu = 22,00; \sigma = 4,00$
$e$	$\mu = 0,85; \sigma = 0,03$
$E_{\text{des}}^{\text{min}}$	$\mu = 0,20; \sigma = 0,03$
$E_{\text{des}}^{\text{dep}}$	$\mu = 0,80; \sigma = 0,05$

Table 8.1.: Verwendete Werte für die normal-verteilte Generierung einiger Parameter der Steuerungsmodelle von thermischen Verbrauchern, programmgetriebenen Verbrauchern und Elektrofahrzeugen.  $\tau_{\text{dur}}$  ist in Minuten angegeben; der generierte Wert wurde dabei auf ein Vielfaches von 15 Minuten gerundet.  $E_{\text{des}}^{\text{min}}$  und  $E_{\text{des}}^{\text{dep}}$  sind in Prozent der maximalen Kapazität  $E_{\text{max}}$  angegeben.

## 8. Evaluation

luden ihre Batterie unmittelbar nach ihrer Ankunft schnellstmöglich bis zu ihrer maximalen Kapazität auf. Die Leistungen der potentiell steuerbaren Verbraucher im nicht gesteuerten Fall wurden auf die vorgegebene ungesteuerte Leistung  $U^{\omega}$  hinzu addiert – allerdings waren diese Leistungen keinen Unsicherheiten unterworfen.

Um die in Abschnitt 8.1 geäußerten Fragen zu beantworten, werden hierfür in diesem Abschnitt verschiedene Systemkonfigurationen und Evaluationsszenarien untersucht. Dazu werden zunächst homogene Partitionen betrachtet, also Autonome Verbraucherorganisationen, die aus ähnlichen Verbrauchern bestehen. Anhand dieser kleinen Systeme wird zunächst betrachtet, ob die robuste Einsatzplanung unter Unsicherheiten in Autonomen Verbraucherorganisationen prinzipiell zu einer erfolgreichen Glättung der Residuallast führt. Zudem ermöglicht dies die gesonderte Betrachtung der verschiedenen Verbrauchertypen und ihrer Unterschiede hinsichtlich ihrer jeweiligen Möglichkeiten zur Glättung der Residuallast beizutragen. Anschließend liegt der Fokus auf heterogenen Partitionen und dem Vergleich dieser mit den erzielten Ergebnissen der homogenen Partitionen. Abschließend wird die Anzahl an Autonomen Verbraucherorganisationen bei gleichbleibender Anzahl an Verbrauchern reduziert, um die Auswirkungen der Partitionsgrößen auf die Lösungsqualität zu untersuchen.

### 8.4.1. HOMOGENE PARTITIONEN

Zuerst werden in dieser Evaluation die Ergebnisse von homogenen Partitionen betrachtet. Konkret wurden hierfür drei verschiedene Systemkonfigurationen untersucht: (1) ein System bestehend aus fünf AVO, die jeweils zehn thermische Verbraucher enthielten; (2) ein System von fünf AVO, bestehend jeweils aus zehn programmgetriebenen Verbrauchern; (3) und ein System aus fünf AVO, bestehend aus jeweils zehn Elektrofahrzeugen. Diese Systemkonfigurationen werden im Nachfolgenden mit TV50, PV50 und EF50 bezeichnet.

Für die Untersuchungen hinsichtlich der generellen Performanz und des Umgangs mit Unsicherheiten wurden für jede dieser Systemkonfigurationen fünf verschiedene Evaluationsszenarien durchgeführt. So wurden in einem Evaluationsszenario Fahrpläne lediglich auf Basis der prognostizierten ungesteuerten Leistung  $U^{\omega}$  erstellt (TV50-p, PV50-p bzw. EF50-p), in einem weiteren Evaluationsszenario nur für die antizipierte ungesteuerte Leistung

#### 8.4. Demand Side Management: Evaluationsszenarien und -ergebnisse

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
EF50-a	0,646 $\pm 0,223$	0,587 $\pm 0,147$	1,260 $\pm 0,322$	171,698 $\pm 10,972$	262,362 $\pm 8,250$	90,664 $\pm 18,379$	224,118 $\pm 22,344$	27,381 $\pm 27,666$	58,491 $\pm 4,125$
EF50-o	0,111 $\pm 0,127$	0,027 $\pm 0,037$	1,252 $\pm 0,322$	200,244 $\pm 4,757$	239,752 $\pm 3,189$	39,508 $\pm 7,128$	224,120 $\pm 11,331$	27,363 $\pm 30,418$	64,880 $\pm 9,338$
EF50-p	1,039 $\pm 0,261$	1,006 $\pm 0,224$	1,263 $\pm 0,322$	179,016 $\pm 6,875$	261,149 $\pm 6,631$	82,132 $\pm 11,346$	223,951 $\pm 17,486$	27,198 $\pm 28,727$	63,465 $\pm 7,035$
EF50-t	0,626 $\pm 0,215$	0,591 $\pm 0,143$	1,245 $\pm 0,325$	174,012 $\pm 12,192$	261,695 $\pm 8,096$	87,682 $\pm 18,884$	224,803 $\pm 22,275$	28,053 $\pm 27,877$	157,110 $\pm 27,674$
EF50-u	2,574 $\pm 1,782$	2,501 $\pm 2,087$	2,574 $\pm 1,782$	132,025 $\pm 1,977$	343,440 $\pm 7,517$	211,415 $\pm 8,017$	228,885	—	—

Table 8.2.: Evaluationsergebnisse für EF50 mit  $N = 16$ : nur auf Basis des antizipierten Szenarios, mit perfektem Wissen, nur auf Basis der Vorhersage, mit ganzem TBST und ungesteuert. Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in *ms* angegeben; alle anderen Werte sind in *kW* angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

aus dem TBST  $U_{\uparrow}^{\omega}$  (TV50-a, PV50-a bzw. EF50-a) und in einem weiteren Evaluationsszenario für den ganzen TBST  $U_{\uparrow}^{\omega}$  (TV50-t, PV50-t bzw. EF50-t). Als Vergleichsmaßstäbe wurde zum einen ein Evaluationsszenario unter optimalen Bedingungen, in dem die Unsicherheiten exakt vorhergesagt wurden, untersucht (TV50-o, PV50-o bzw. EF50-o) sowie zum anderen ein Evaluationsszenario betrachtet, in dem die potentiell steuerbaren Verbraucher nicht steuerbar waren (TV50-u, PV50-u bzw. EF50-u).

##### Ergebnisse zu EF50

Die in der Systemkonfiguration EF50 erzielten Ergebnisse zu den Evaluationsszenarien EF50-a, EF50-o, EF50-p, EF50-t und EF50-u für den Planungshorizont von  $N = 16$  sind in Tabelle 8.2 dargestellt.

Sofort ersichtlich ist, dass alle Evaluationsszenarien mit einer Einsatzplanung deutlich besser abschneiden als EF50-u. Werden die Elektrofahrzeuge nicht gesteuert und laden sich nach Ankunft sofort voll auf, führt das zu einer deutlich weniger glatten Residuallast mit höheren Werten von  $\Delta R_{\mu}^{\omega}$  und  $\Delta^2 R_{\mu}^{\omega}$  verglichen mit den anderen Evaluationsszenarien von EF50. Auch die Spreizung der Residuallast ist mehr als doppelt so groß wie im schlechtesten anderen Evaluationsszenario.

Vergleicht man EF50-p mit EF50-a und EF50-t, wird deutlich, dass der Ein-

## 8. Evaluation

satz von TBS die im System durch Unsicherheiten verursachten vorliegenden Prognosefehler reduziert. So werden in EF50-a die durchschnittlich pro AVO  $\omega$  vorliegenden absoluten Änderungen der ungesteuerten Leistung  $\Delta U_{\mu}^{\omega}$  von 1,260 kW durch eine Einsatzplanung auf eine durchschnittliche absolute Differenz der Residuallast  $\Delta R_{\mu}^{\omega}$  von 0,646 kW reduziert; das entspricht einer Reduktion um 48,73 %. Ähnlich gut schneidet EF50-t ab und kann  $\Delta U_{\mu}^{\omega}$  durch die Einsatzplanung von 1,245 kW auf 0,626 kW um 49,72 % reduzieren, wohingegen EF50-p lediglich eine vergleichsweise geringe Reduktion von 17,74 % erzielen kann. EF50-t erzielt somit im Schnitt etwas bessere Ergebnisse hinsichtlich der Residuallastglättung als EF50-a. Die mit Abstand besten Ergebnisse fährt das als Vergleichsmaßstab dienende Evaluationszenario EF50-o unter optimalen Bedingungen mit perfekten Vorhersagen ein, dessen  $\Delta R_{\mu}^{\omega}$  um satte 91,13 % geringer ist als  $\Delta U_{\mu}^{\omega}$ .

Wie bereits zuvor angemerkt, führt eine flexibilisierte Nachfrage in EF50 zu einer deutlich geringeren Spreizung der Residuallast gegenüber einer ungesteuerten Nachfrage; die Spreizung der Residuallast  $R_{\downarrow}$  ist in EF50-a, EF50-p und EF50-t in etwa auf einem Niveau; die kleinen Unterschiede sind vermutlich den Schwankungen und den zufälligen Unsicherheiten der ungesteuerten Leistung zuzuordnen. EF50-o liefert auch hier klar die geringste Spreizung der Residuallast, EF50-u fällt deutlich ab.

In Bezug auf  $T^{\omega}$ , die durchschnittliche Dauer pro Autonomer Verbraucherorganisation für die Berechnung von Fahrplänen, schneiden die Evaluationszenarien, die Fahrpläne nur für ein einziges TBS zu berechnen hatten, erwartungsgemäß mit vergleichbaren Zeiten ab, die rund 60 ms betragen. In EF50-t, wo Fahrpläne für einen ganzen TBST berechnet wurden, war  $T^{\omega}$  mit 157,110 ms in etwa 2,5 mal so groß.

Tabelle 8.3 zeigt die Ergebnisse für das Evaluationszenario EF50-t für die verschiedenen Planungshorizonte  $N = 4$ ,  $N = 8$ ,  $N = 16$  und  $N = 32$ . Wie aus den Daten ersichtlich ist, profitieren die Autonomen Verbraucherorganisationen deutlich von längeren Planungshorizonten: Durch die weitere Vorausschau kann die Nachfrage der Elektrofahrzeuge besser verteilt werden und sorgt somit für eine glattere Residuallast. Dies zeigt sich in den sinkenden Werten von  $\Delta R_{\mu}^{\omega}$  und  $\Delta^2 R_{\mu}^{\omega}$ . So fällt beispielsweise  $\Delta R_{\mu}^{\omega}$  um 24,50 %, wenn Fahrpläne für die nächsten 32 Zeitschritte berechnet werden anstatt für die nächsten vier Zeitschritte.  $\Delta R_{\mu}^{\omega}$  ist dabei bei steigendem  $N$  um 36,88 %, 45,32 %, 49,72 % bzw. 52,04 % geringer als der jeweilige Wert von  $\Delta U_{\mu}^{\omega}$ . Die zusätzlich erzielten Verbesserungen fallen demnach mit stei-

#### 8.4. Demand Side Management: Evaluationsszenarien und -ergebnisse

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
EF50-t, N = 4	0,796 $\pm 0,475$	0,672 $\pm 0,248$	1,261 $\pm 0,327$	143,818 $\pm 8,512$	277,149 $\pm 9,230$	133,331 $\pm 15,566$	223,060 $\pm 39,376$	26,289 $\pm 35,612$	40,128 $\pm 4,387$
EF50-t, N = 8	0,689 $\pm 0,325$	0,595 $\pm 0,156$	1,260 $\pm 0,318$	158,830 $\pm 12,675$	266,824 $\pm 8,332$	107,994 $\pm 19,019$	223,762 $\pm 29,504$	27,013 $\pm 30,967$	71,767 $\pm 10,066$
EF50-t, N = 16	0,626 $\pm 0,215$	0,591 $\pm 0,143$	1,245 $\pm 0,325$	174,012 $\pm 12,192$	261,695 $\pm 8,096$	87,682 $\pm 18,884$	224,803 $\pm 22,275$	28,053 $\pm 27,877$	157,110 $\pm 27,674$
EF50-t, N = 32	0,601 $\pm 0,189$	0,591 $\pm 0,166$	1,253 $\pm 0,323$	195,289 $\pm 8,231$	256,579 $\pm 6,520$	61,290 $\pm 13,132$	225,228 $\pm 12,998$	28,473 $\pm 26,438$	398,105 $\pm 63,580$

Table 8.3.: Evaluationsergebnisse für EF50-t mit unterschiedlichen Planungshorizonten: N = 4, N = 8, N = 16 und N = 32. Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in ms angegeben; alle anderen Werte sind in kW angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

gendem Planungshorizont immer geringer aus. Gleiches lässt sich bei  $\Delta^2 R_{\mu}^{\omega}$  beobachten; die Sprünge von  $\Delta^2 R_{\mu}^{\omega}$  mit größerem N sind nicht mehr ganz so groß sind wie mit kleinem N, bzw. stagnieren sogar. Gleichzeitig steigt aber auch wie erwartet die Dauer für die Berechnung der Fahrpläne an und ist mit 398,105 ms im Fall von N = 32 rund zehnmal so groß wie die durchschnittlich benötigten 40,128 ms im Fall von N = 4.

Neben einer verbesserten Glättung der Residuallast führt ein längerer Planungshorizont zudem zu einer fallenden Spreizung der Residuallast;  $R_{\min}$  und  $R_{\max}$  nähern sich mit steigendem N aneinander an, so dass die Spreizung der Residuallast bei N = 32 nur noch 45,97% der Spreizung der Residuallast bei N = 4 beträgt.

#### Ergebnisse zu PV50

In Tabelle 8.4 sind die Ergebnisse für die Systemkonfiguration PV50 und die Szenarien PV50-a, PV50-o, PV50-p, PV50-t und PV50-u zu sehen, durchgeführt für N = 16.

Auffällig ist zunächst, dass im Vergleich zu EF50 die Spanne zwischen dem abermals schlechtesten Szenario PV50-u und dem besten Szenario PV50-o weniger groß ist, als es bei EF50 der Fall war. Das liegt an der geringeren Flexibilität der programmgetriebenen Verbraucher im Vergleich zu den Elektrofahrzeugen, so dass die Vorteile einer flexibilisierten Nachfrage nicht ganz so deutlich ausfallen. Dennoch reduzieren alle Evaluationsze-

## 8. Evaluation

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
PV50-a	1,282 ± 0,326	0,853 ± 0,284	1,253 ± 0,324	129,929 ± 1,452	265,149 ± 3,979	135,220 ± 4,358	207,965 ± 41,358	11,214 ± 8,909	152,984 ± 55,436
PV50-o	1,158 ± 0,324	0,801 ± 0,270	1,253 ± 0,328	130,223 ± 1,523	264,259 ± 3,930	134,036 ± 4,144	208,012 ± 41,413	11,249 ± 9,022	152,277 ± 54,644
PV50-p	1,338 ± 0,356	0,849 ± 0,299	1,251 ± 0,327	130,050 ± 1,565	268,364 ± 4,321	138,314 ± 3,956	208,059 ± 41,732	11,296 ± 8,860	142,761 ± 46,445
PV50-t	1,275 ± 0,329	0,851 ± 0,287	1,256 ± 0,318	129,834 ± 1,480	265,566 ± 3,519	135,732 ± 3,645	208,014 ± 41,419	11,266 ± 8,846	671,139 ± 584,579
PV50-u	1,536 ± 0,559	1,065 ± 0,537	1,536 ± 0,559	129,831 ± 1,445	265,987 ± 2,678	136,156 ± 2,962	208,030 ± 42,236	—	—

Tabelle 8.4.: Evaluationsergebnisse für PV50 mit  $N = 16$ : nur auf Basis des antizipierten Szenarios, mit perfektem Wissen, nur auf Basis der Vorhersage, mit ganzem TBST und ungesteuert. Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in *ms* angegeben; alle anderen Werte sind in *kW* angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

narien, die eine Einsatzplanung durchführen,  $\Delta R_{\mu}^{\omega}$  gegenüber PV50-u um 16,54 % (PV50-a), 12,89 % (PV50-p) und 16,99 % (PV50-t), bzw. um 24,61 % unter optimalen Bedingungen. Relativ ähnlich sieht die Situation für  $\Delta^2 R_{\mu}^{\omega}$  aus. Interessanterweise ist jedoch nur PV50-o tatsächlich dazu in der Lage,  $\Delta R_{\mu}^{\omega}$  gegenüber den vorliegenden Veränderungen der ungesteuerten Leistung  $\Delta U_{\mu}^{\omega}$  durch eine Einsatzplanung zu reduzieren; die Reduktion fällt mit 7,58 % aber im Vergleich zu EF50 relativ gering aus. Die anderen drei Evaluationsszenarien mit einer Einsatzplanung erhöhen  $\Delta U_{\mu}^{\omega}$  hingegen um 2,31 % (PV50-a), 6,95 % (PV50-p) bzw. 1,51 % (PV50-t). Das unterstreicht die verhältnismäßig geringe Flexibilität programmtriebener Verbraucher gegenüber Elektrofahrzeugen.

Im Vergleich von PV50-a, PV50-p und PV50-t zeigt sich demnach erneut, dass der Einsatz von TBS bessere Ergebnisse liefert, als eine lediglich auf Vorhersagen basierende Einsatzplanung. PV50-t weist dabei leichte Vorteile gegenüber PV50-a auf; allerdings werden diese durch eine deutlich höhere durchschnittliche Dauer für die Fahrplanberechnung  $T^{\omega}$  erkauft, die mit durchschnittlich 671,139 ms mehr als viermal so groß ist wie die Zeiten für ein TBS (um die 150 ms). Verglichen mit den Werten von  $T^{\omega}$  in EF50 lässt sich außerdem feststellen, dass die Werte von PV50 höher sind. Das liegt daran, dass das Optimierungsproblem aufgrund der diskreten Nachfrage von

#### 8.4. Demand Side Management: Evaluationsszenarien und -ergebnisse

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
PV50-t, N = 4	1,290 ± 0,370	0,864 ± 0,320	1,254 ± 0,319	129,992 ± 1,542	272,268 ± 5,045	142,277 ± 5,078	208,065 ± 42,355	11,310 ± 10,354	68,899 ± 10,594
PV50-t, N = 8	1,282 ± 0,352	0,844 ± 0,298	1,265 ± 0,323	129,644 ± 1,616	268,648 ± 4,061	139,004 ± 4,073	208,112 ± 42,066	11,347 ± 9,619	149,326 ± 40,882
PV50-t, N = 16	1,275 ± 0,329	0,851 ± 0,287	1,256 ± 0,318	129,834 ± 1,480	265,566 ± 3,519	135,732 ± 3,645	208,014 ± 41,419	11,266 ± 8,846	671,139 ± 584,579
PV50-t, N = 32	1,288 ± 0,328	0,852 ± 0,285	1,256 ± 0,316	129,940 ± 1,522	263,845 ± 4,769	133,906 ± 4,755	207,862 ± 41,361	11,116 ± 9,124	3159,118 ± 2695,515

Table 8.5.: Evaluationsergebnisse für PV50-t mit unterschiedlichen Planungshorizonten: N = 4, N = 8, N = 16 und N = 32. Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in ms angegeben; alle anderen Werte sind in kW angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

programmgetriebenen Verbrauchern ( $P(t) \in \{P_{\text{on}}, P_{\text{off}}\}$ ) komplexer zu lösen ist als für Elektrofahrzeuge, deren Nachfrage kontinuierlich ist ( $P_{\min} \leq P(t) \leq P_{\max}$ ).

Bezüglich der Werte zur Spreizung der Residuallast sind alle Evaluationsszenarien in etwa auf einem Niveau, d. h. im Vergleich zu EF50 gibt es hier keine deutlichen Unterschiede zwischen den Evaluationsszenarien. Auch hier sind die kleinen Unterschiede vermutlich den Schwankungen und den zufälligen Unsicherheiten der ungesteuerten Leistung zuzuordnen.

Table 8.5 zeigt die Ergebnisse für PV50-t für die unterschiedlichen Planungshorizonte N = 4, N = 8, N = 16 und N = 32. Anders als in EF50 profitiert zwar auch PV50 grundsätzlich von einer größeren Anzahl an Zeitschritten, für die Fahrpläne erstellt werden, jedoch nur in einem gewissen Rahmen.  $\Delta R_{\mu}^{\omega}$  und  $\Delta^2 R_{\mu}^{\omega}$  liefern für N = 4 die schlechtesten Werte. Die geringste Steigerung von  $\Delta R_{\mu}^{\omega}$  gegenüber  $\Delta U_{\mu}^{\omega}$  mit 1,34 % weist die Einsatzplanung für 8 Zeitschritte auf, dicht gefolgt von der Einsatzplanung für 16 Zeitschritte mit einer Steigerung von 1,51 %. Die Einsatzplanung für N = 32 erzielt eine Steigerung von 2,55 %. Dafür ist die Spreizung der Residuallast bei N = 32 am geringsten; mit steigendem N sinkt  $R_{\downarrow}$ .

Besonders bemerkbar macht sich die steigende Komplexität in Form der steigenden Anzahl an Zeitschritten in der steigenden Dauer für die Berechnung der Fahrpläne, denn hier sind die Unterschiede größer als bei EF50: Lag dort der Unterschied zwischen N = 4 und N = 32 bei einer rund zehnfach so hohen Berechnungszeit, ist hier in PV50 die durchschnittliche

## 8. Evaluation

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
TV50-a	0,835 $\pm 0,278$	0,596 $\pm 0,110$	1,249 $\pm 0,318$	141,569 $\pm 1,516$	260,608 $\pm 4,358$	119,038 $\pm 4,500$	208,265 $\pm 34,081$	11,508 $\pm 2,515$	6363,60 $\pm 4780,37$
TV50-o	0,545 $\pm 0,365$	0,276 $\pm 0,100$	1,261 $\pm 0,327$	145,547 $\pm 0,623$	258,171 $\pm 2,788$	112,623 $\pm 2,810$	208,247 $\pm 33,915$	11,496 $\pm 2,694$	5181,41 $\pm 4849,62$
TV50-p	1,372 $\pm 0,314$	1,026 $\pm 0,251$	1,268 $\pm 0,313$	139,994 $\pm 2,176$	263,132 $\pm 4,567$	123,138 $\pm 4,733$	208,238 $\pm 33,959$	11,484 $\pm 2,342$	7275,22 $\pm 5033,90$
TV50-t	0,841 $\pm 0,288$	0,630 $\pm 0,119$	1,264 $\pm 0,322$	142,351 $\pm 1,601$	259,074 $\pm 3,385$	116,724 $\pm 3,668$	208,260 $\pm 33,987$	11,502 $\pm 2,622$	12472,61 $\pm 4988,56$
TV50-u	1,631 $\pm 0,376$	1,243 $\pm 0,313$	1,631 $\pm 0,376$	140,231 $\pm 2,038$	266,733 $\pm 3,781$	126,502 $\pm 4,591$	208,233 $\pm 34,532$	—	—

Tabelle 8.6.: Evaluationsergebnisse für TV50 mit  $N = 8$ : nur auf Basis des antizipierten Szenarios, mit perfektem Wissen, nur auf Basis der Vorhersage, mit ganzem TBST und ungesteuert. Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in *ms* angegeben; alle anderen Werte sind in *kW* angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

Zeit von 3159,118 ms im Fall von  $N = 32$  mehr als 45-mal so hoch wie für  $N = 4$  (68,899 ms). Das liegt vor allem darin begründet, dass, wie bereits zuvor erwähnt, das zu lösende Optimierungsproblem komplexer ist.

### Ergebnisse zu TV50

Die in den Simulationsläufen erzielten Ergebnisse für TV50 für den Planungshorizont  $N = 8$  sind in Tabelle 8.6 dargestellt.

Auffällig – trotz des verhältnismäßig kleinen Planungshorizonts von  $N = 8$  – ist die deutlich höhere durchschnittliche Dauer der Einsatzplanung  $T^{\omega}$  gegenüber EF50 und PV50. So liefert selbst das Evaluationsszenario von TV50 mit dem geringsten Wert von  $T^{\omega}$ , TV50-o, mit in etwa 5,181 s um ein Vielfaches höhere Berechnungszeiten als die bisher langsamste durchschnittliche Zeit für  $N = 8$  mit 149,326 ms (in dem Evaluationsszenario PV50-t). Noch deutlicher fällt der Unterschied aus, wenn  $T^{\omega}$  für TV50-t betrachtet wird: Diese ist mit durchschnittlich 12,473 s noch einmal mehr als doppelt so hoch als von TV50-o. Auch der Unterschied von TV50-t für die Planungshorizonte  $N = 4$  und  $N = 8$  (siehe Tabelle 8.7) fällt deutlicher aus, als in den bisherigen Vergleichen der Werte von  $T^{\omega}$  über verschiedene Planungshorizonte. So ist  $T^{\omega}$  in TV50-t für  $N = 8$  in etwa um den Faktor 12 höher als für  $N = 4$ . Ursächlich für die deutlichen längeren Zeiten zur Berechnung von

#### 8.4. Demand Side Management: Evaluationsszenarien und -ergebnisse

Fahrplänen ist, dass das Optimierungsproblem für thermische Verbraucher nochmals komplexer zu lösen ist als für programmgetriebene Verbraucher: Ist bei beiden Typen von Verbrauchern zwar die Nachfrage diskret, so ist die Anzahl möglicher Lösungen bei thermischen Verbrauchern deutlich höher als bei programmgetriebenen Verbrauchern, die zum einen nur innerhalb eines gewissen Zeitraums ihre Nachfrage flexibilisieren können und zum anderen dabei nur der Startzeitpunkt  $t_{\text{start}}$  gewählt werden muss und danach für die Dauer des Programms die Nachfrage festgelegt ist. Bei thermischen Verbrauchern ist hingegen die Entscheidung, ob der Verbraucher in Betrieb ist oder nicht, für jeden Zeitpunkt abhängig vom internen Zustand zu treffen.

Hinsichtlich den Daten bezüglich der Glättung der Residuallast treten in TV50 keine großen Überraschungen auf. Auch in dieser Systemkonfiguration ist jedes Evaluationsszenario, in dem eine Einsatzplanung durchgeführt wird, dem Evaluationsszenario TV50-u ohne Einsatzplanung überlegen. Auffällig ist jedoch, dass TV50-p gegenüber TV50-a, TV50-o und TV50-t deutlicher abfällt als in den zuvor untersuchten Systemkonfigurationen und lediglich eine Verbesserung von  $\Delta R_{\mu}^{\omega}$  gegenüber TV50-u um 15,88 % erreicht und es im Gegensatz zu den anderen Evaluierungsszenarien mit Einsatzplanung nicht schafft,  $\Delta R_{\mu}^{\omega}$  niedriger als  $\Delta U_{\mu}^{\omega}$  zu halten. Stattdessen ist  $\Delta R_{\mu}^{\omega}$  um 8,20 % höher als  $\Delta U_{\mu}^{\omega}$ . Dafür erreichen die anderen Evaluationsszenarien eine größere Verbesserung als in PV50: TV50-a, TV50-o bzw. TV50-t erreichen eine Reduktion von  $\Delta R_{\mu}^{\omega}$  gegenüber  $\Delta U_{\mu}^{\omega}$  um 33,15 %, 56,78 % bzw. 33,47 %. Daraus folgt auch, dass TV50-t und TV50-a in etwa auf einem Niveau liegen; ist TV50-t minimal besser als TV50-a hinsichtlich dem Verhältnis von  $\Delta R_{\mu}^{\omega}$  zu  $\Delta U_{\mu}^{\omega}$ , so ist es im Fall von  $\Delta^2 R_{\mu}^{\omega}$  umgekehrt. Die durchschnittliche Fahrplanberechnungsdauer  $T^{\omega}$  von TV50-t ist dabei jedoch fast doppelt so groß. Allerdings erzielt TV50-t gegenüber TV50-a mit einem Wert von 116,724 kW gegenüber 119,038 kW durchschnittlich eine geringere Spreizung der Residuallast. Insgesamt erreichen sowohl TV50-a als auch TV50-t deutlich bessere Ergebnisse als TV50-p und zeigen somit auch in dieser Systemkonfiguration, dass der Einsatz von TBS zur Reduktion von Unsicherheiten für das System große Vorteile bietet.

In Tabelle 8.7 ist der Vergleich von TV50-t mit  $N = 4$  und  $N = 8$  zu sehen. Wie bereits zuvor diskutiert steigt  $T^{\omega}$  um knapp den Faktor zwölf an, wenn für acht anstatt für vier Zeitschritte Fahrpläne erstellt werden. Gegenüber der Reduktion von  $\Delta R_{\mu}^{\omega}$  gegenüber  $\Delta U_{\mu}^{\omega}$  liefert TV50-t mit  $N = 4$

## 8. Evaluation

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
TV50-t, N = 4	0,865 $\pm 0,299$	0,644 $\pm 0,128$	1,256 $\pm 0,319$	140,889 $\pm 1,487$	261,406 $\pm 4,225$	120,516 $\pm 4,632$	208,291 $\pm 34,881$	11,539 $\pm 2,515$	1046,619 $\pm 894,243$
TV50-t, N = 8	0,841 $\pm 0,288$	0,630 $\pm 0,119$	1,264 $\pm 0,322$	142,351 $\pm 1,601$	259,074 $\pm 3,385$	116,724 $\pm 3,668$	208,260 $\pm 33,987$	11,502 $\pm 2,622$	12472,606 $\pm 4988,565$

Tabelle 8.7.: Evaluationsergebnisse für TV50-t mit unterschiedlichen Planungshorizonten: N = 4 und N = 8. Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in *ms* angegeben; alle anderen Werte sind in *kW* angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

eine Reduktion um 31,13 % und somit 2,34 % weniger als TV50-t mit N = 8 (33,47 %). Aufgrund der periodischen, wiederkehrenden Nachfrage thermischer Verbraucher können diese offenbar von längeren Planungshorizonten weniger profitieren als Elektrofahrzeuge. Aus den Daten ersichtlich ist zudem, dass ein größerer Planungshorizont zu einer geringeren Spreizung der Residuallast führt.

Aufgrund der bereits im Verhältnis sehr langen Dauer für die Berechnung der Fahrpläne und den verhältnismäßig geringen Steigerungen, wenn für acht anstatt vier Zeitschritte Fahrpläne berechnet wurden, wurden keine Simulationsläufe zu N = 16 oder gar N = 32 durchgeführt. Vorläufige Tests ergaben bereits bei N = 16, dass selbst nach 180 Sekunden die Autonomen Verbraucherorganisationen noch keine optimale Lösung gefunden hatten.

### Fazit

In Gesamtbetrachtung der Systemkonfigurationen EF50, PV50 und TV50 lässt sich festhalten, dass durchgängig die Flexibilisierung der Nachfrage zu deutlich besseren Ergebnissen führt als eine ungesteuerte Nachfrage. Je nach Systemkonfiguration sind diese jedoch unterschiedlich stark ausgeprägt: Die relativ unflexiblen programmgetriebenen Verbraucher können die Residuallast weniger gut glätten, als es die thermischen Verbraucher und insbesondere die Elektrofahrzeuge können. Elektrofahrzeuge, mit ihrer Möglichkeit sowohl Leistung auf- als auch abzugeben, erzielen dabei mit Abstand die besten Ergebnisse.

Ebenso hat sich in allen Systemkonfigurationen gezeigt, dass eine robuste Einsatzplanung auf Basis von Trust-basierten Szenarien weitaus erfolgrei-

cher ist, als sich lediglich auf die mit Unsicherheiten behafteten Prognosen zu verlassen. Wie in der robusten Einsatzplanung in Autonomen Virtuellen Kraftwerken, wo TBS erfolgreich zur Quantifizierung und Antizipation von Unsicherheiten in der Residuallast eingesetzt werden [7, 5], hat sich im Kontext der robusten Einsatzplanung in Autonomen Verbraucherorganisation somit ebenfalls bestätigt, dass TBS ein geeignetes Mittel sind, um Unsicherheiten im nicht steuerbaren Anteil der Residuallast zu quantifizieren und antizipieren. Die Einsatzplanung auf Basis des ganzen Trust-basierten Szenariobaums und die Einsatzplanung lediglich auf Basis des antizipierten Szenarios befanden sich im Allgemeinen in etwa auf einem Niveau, wobei die Einsatzplanung für einen ganzen TBST im Schnitt leicht bessere Resultate erzielte, und das obwohl die Einsatzplanung in den Simulationen jeden Zeitschritt ausgeführt wurde und die steuerbaren Verbraucher ihre Nachfrage im Falle der Einsatzplanung für einen ganzen TBST für den nächsten Zeitschritt nach dem antizipierten Szenario gewählt haben. Daran lässt sich erkennen, dass in der Planung für mehrere Szenarien und der dadurch erfolgten Berücksichtigung anderer möglichen Entwicklungen in der Zukunft robustere Entscheidungen getroffen werden. Da sich die Festlegung auf ein einziges Szenario jedoch als falsch herausstellen kann, weil sich die ungesteuerte Leistung anders entwickelt als zuvor antizipiert, ist der Vorteil der Einsatzplanung auf Basis eines ganzen TBST sogar noch größer, wenn ein Wechsel des Szenarios zur Laufzeit ermöglicht wird [10], insbesondere wenn nicht in jedem Zeitschritt eine Einsatzplanung durchgeführt wird. Nachteil der Einsatzplanung für einen ganzen TBST sind jedoch die klar längeren Berechnungszeiten für die Fahrpläne. Unerreicht blieben die als Vergleichsmaßstab durchgeführten Evaluationsszenarien, die eine Einsatzplanung unter optimalen Bedingungen, d. h. perfekten Vorhersagen, durchführten.

Des Weiteren ist das zu lösende Optimierungsproblem für eine Autonome Verbraucherorganisation, die nur aus thermischen Verbrauchern besteht, weitaus schwieriger zu lösen, als für eine Autonome Verbraucherorganisation, die nur aus programmgetriebenen Verbrauchern besteht. Das haben die viel größeren durchschnittlichen Fahrplanberechnungszeiten gezeigt. Die Glättung der Residuallast für eine Gruppe von Elektrofahrzeugen, die die kürzesten Fahrplanberechnungszeiten aufweisen, hingegen geht verhältnismäßig schnell von statten. Interessant zu beobachten wird sein, wie sich die Fahrplanberechnungszeiten in einer homogenen Partitionierung mit heterogenen Partitionen entwickeln werden – dies wird im nächsten

## 8. Evaluation

Abschnitt untersucht.

In allen Systemkonfigurationen hat sich wie erwartet herausgestellt, dass ein längerer Planungshorizont im Prinzip bessere Ergebnisse liefert als ein kurzer Planungshorizont mit  $N = 4$ . Die unterschiedlichen Systemkonfigurationen haben davon jedoch unterschiedlich stark profitiert. So ist es den besonders flexiblen Elektrofahrzeugen bei größerer Weitsicht besser möglich, ihre Nachfrage den Begebenheiten der ungesteuerten Leistung anzupassen. Die weniger flexiblen programmgetriebenen Verbraucher profitieren auch von einem größeren Planungshorizont, indem sie ihr Programm im Rahmen ihrer zeitlichen Möglichkeiten potentiell zu einem späteren, aber günstigeren Zeitpunkt starten, aber nicht in dem Maße wie bei den Elektrofahrzeugen. Und auch die thermischen Verbraucher können von einem längeren Planungshorizont profitieren; mit ihrer immer wiederkehrenden, periodischen Nachfrage können sie allerdings aus einem deutlich größeren Planungshorizont nicht so stark profitieren wie Elektrofahrzeuge – stattdessen steigt die Fahrplanberechnungszeit massiv an. So steigt die Qualität der Residuallastglättung bei EF50 auch noch bei dem längsten untersuchten Planungshorizont  $N = 32$  an, wohingegen bei PV50 die besten Ergebnisse bereits bei  $N = 8$  erzielt werden konnten. Die verbesserten Ergebnisse bei längeren Planungshorizonten gehen allerdings auf Kosten der Dauer für die Berechnung der Fahrpläne; insbesondere bei TV50 sind bereits bei  $N = 8$  sehr hohe Zeiten von durchschnittlich über zwölf Sekunden erreicht.

Die zwar nicht Teil der Zielfunktion seiende aber in der Evaluierung mit ausgewertete Spreizung der Residuallast nimmt mit einer flexibilisierten Nachfrage gegenüber einer nicht gesteuerten Nachfrage deutlich ab. Des Weiteren führen im Allgemeinen längere Planungshorizonte zu geringeren Spreizungen der Residuallast. Eine Tendenz hinsichtlich welche Art der Einsatzplanung – auf Basis der Vorhersage, auf Basis des antizipierten Szenarios oder auf Basis des ganzen TBST – durchschnittlich die geringste Spreizung der Residuallast verursacht, lässt sich über die verschiedenen Systemkonfigurationen hinweg nicht beobachten; lediglich unter optimalen Bedingungen werden stets die geringsten Spreizungen der Residuallast erzielt.

Zusammengefasst lässt sich festhalten, dass die Glättung der Residuallast durch die Einsatzplanung für steuerbare Verbraucher gute Ergebnisse liefert und somit einen wichtigen Beitrag zur Erfüllung des Systemziels beiträgt, indem Kraftwerke mit weniger starken Schwankungen konfrontiert werden

#### 8.4. Demand Side Management: Evaluationsszenarien und -ergebnisse

und die Spreizung der Residuallast gesenkt wird. Insbesondere die Einbindung von Elektrofahrzeugen in ein Demand Side Management zeigt sehr großes Potential.

##### 8.4.2. HETEROGENE PARTITIONEN

Im Gegensatz zum vorherigen Abschnitt, in dem Autonome Verbraucherorganisationen mit homogener Zusammensetzung betrachtet wurden, werden in diesem Abschnitt nun heterogen zusammengesetzte Autonome Verbraucherorganisationen, die hinsichtlich ihres Verbrauchertyps somit eine homogene Partitionierung bilden, betrachtet. Dazu wurden dieselben Verbraucher und Steuerungsmodelle verwendet wie im vorherigen Abschnitt; allerdings wurden diese nun gemeinsam in einem System betrachtet und nicht in getrennten Systemen wie zuvor. Gemäß dem Prinzip der homogenen Partitionierung waren diese 150 Verbraucher auf 15 verschiedene Autonome Verbraucherorganisationen mit heterogener Zusammensetzung aufgeteilt, jeweils wieder bestehend aus zehn Verbrauchern. Diese Systemkonfiguration wird im Folgenden mit O15 bezeichnet. Um die erzielten Ergebnisse heterogener Partitionen mit homogenen Partitionen direkt miteinander vergleichen zu können, wurden zusätzlich in einer weiteren Systemkonfiguration dieselben 150 Verbraucher auf 15 verschiedene Autonome Verbraucherorganisationen mit homogener Zusammensetzung wie in dem vorherigem Abschnitt aufgeteilt. Dabei bestand jede AVO jeweils aus zehn Verbrauchern. Die Bezeichnung dieser lautet O15H. Wie in den zuvor betrachteten Systemkonfigurationen bekam in diesem vergrößerten System von O15 und O15H erneut jede AVO  $\omega$  dieselbe ungesteuerte Leistung  $U^\omega$  zugewiesen, so dass die gesamte im System vorliegende ungesteuerte Leistung und die dazugehörigen Unsicherheiten in etwa dreimal so groß waren wie zuvor.

Analog zu dem vorherigen Abschnitt werden erneut Evaluationsszenarien unter optimalen Bedingungen (O15-o), auf Basis der Vorhersage (O15-p), auf Basis des antizipierten Szenarios (O15-a), auf Basis des ganzen TBST (O15-t) und mit ungesteuerten potentiell steuerbaren Verbrauchern durchgeführt (O15-u). Für die Systemkonfiguration auf Basis homogener Partitionen O15H wurde zum Vergleich lediglich das Evaluationsszenario auf Basis eines ganzen TBST untersucht (O15H-t).

## 8. Evaluation

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
O15-a	0,833 ± 0,230	0,620 ± 0,169	1,259 ± 0,317	444,049 ± 7,681	784,051 ± 10,586	340,002 ± 12,544	640,331 ± 102,776	50,052 ± 33,354	149,956 ± 33,760
O15-o	0,440 ± 0,323	0,144 ± 0,141	1,258 ± 0,319	472,911 ± 1,814	784,860 ± 6,109	311,949 ± 6,786	640,396 ± 100,515	50,126 ± 35,187	148,422 ± 26,690
O15-p	1,219 ± 0,325	0,986 ± 0,236	1,260 ± 0,322	466,524 ± 6,164	787,199 ± 9,873	320,675 ± 11,299	640,181 ± 94,711	49,927 ± 33,048	157,079 ± 37,382
O15-t	0,829 ± 0,229	0,637 ± 0,164	1,253 ± 0,323	451,131 ± 7,008	783,938 ± 10,245	332,807 ± 11,464	640,495 ± 101,561	50,206 ± 32,001	714,348 ± 435,288
O15-u	1,954 ± 0,788	1,728 ± 0,891	1,954 ± 0,788	409,509 ± 3,069	850,051 ± 8,500	440,542 ± 9,350	645,096 ± 130,043	—	—

Tabelle 8.8.: Evaluationsergebnisse für O15 mit  $N = 16$ : nur auf Basis des antizipierten Szenarios, mit perfektem Wissen, nur auf Basis der Vorhersage, mit ganzem TBST und ungesteuert. Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in *ms* angegeben; alle anderen Werte sind in *kW* angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

### Ergebnisse zu O15

Zunächst werden die für O15 erzielten Ergebnisse diskutiert; der Vergleich mit O15H erfolgt im Anschluss.

Tabelle 8.8 zeigt die in O15 erzielten Ergebnisse für O15-a, O15-o, O15-p, O15-t und O15-u für einen Planungshorizont von  $N = 16$ .

Wenig überraschend sind die Werte von  $\Delta R_{\mu}^{\omega}$  auch in O15-u mit Abstand am höchsten. Zudem bestätigt sich auch in O15, was bereits zuvor in den anderen Systemkonfigurationen mit homogener Zusammensetzung feststellbar war: O15-a sowie O15-t schneiden bzgl. der Glättung der Residuallast besser ab als O15-p und bestätigen auch in dieser Systemkonfiguration den Vorteil des Einsatzes von TBS für den Umgang mit Unsicherheiten in der Einsatzplanung. So führen sowohl O15-a als auch O15-t zu einem 33,84 % geringeren Wert von  $\Delta R_{\mu}^{\omega}$  gegenüber  $\Delta U_{\mu}^{\omega}$ ; demgegenüber stehen 3,25 % von O15-p. Der Vergleichsmaßstab O15-o erreicht auch in O15 die besten Werte von  $\Delta R_{\mu}^{\omega}$ ; mit 0,440 kW ist dieser um 77,31 % geringer als die 1,954 kW von O15-u.

Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist zwar langsamer als in EF50, bewegt sich in O15 mit ca. 714 ms etwa auf einem Niveau wie in PV50 (ca. 671 ms) und ist damit weitaus geringer als bei TV50, wo bereits bei  $N = 8$  durchschnittliche Zeiten von über

#### 8.4. Demand Side Management: Evaluationsszenarien und -ergebnisse

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
O15-t, N = 4	0,922 $\pm 0,532$	0,731 $\pm 0,273$	1,253 $\pm 0,320$	404,098 $\pm 4,978$	801,138 $\pm 12,474$	397,040 $\pm 13,789$	639,584 $\pm 125,518$	49,314 $\pm 48,976$	77,285 $\pm 4,892$
O15-t, N = 8	0,855 $\pm 0,336$	0,635 $\pm 0,164$	1,254 $\pm 0,318$	418,080 $\pm 6,983$	793,624 $\pm 11,261$	375,544 $\pm 13,696$	639,527 $\pm 116,845$	49,241 $\pm 42,039$	187,180 $\pm 40,870$
O15-t, N = 16	0,829 $\pm 0,229$	0,637 $\pm 0,164$	1,253 $\pm 0,323$	451,131 $\pm 7,008$	783,938 $\pm 10,245$	332,807 $\pm 11,464$	640,495 $\pm 101,561$	50,206 $\pm 32,001$	714,348 $\pm 435,288$

Table 8.9.: Evaluationsergebnisse für O15-t mit unterschiedlichen Planungshorizonten: N = 4, N = 8 und N = 16. Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in ms angegeben; alle anderen Werte sind in kW angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

12 s erreicht wurden. Offensichtlich reduziert sich die Komplexität des Optimierungsproblems unter Beteiligung thermischer Verbraucher, wenn für eine heterogene Partition mit zusätzlich anderen Verbrauchertypen eine Einsatzplanung durchgeführt werden muss.

In Tabelle 8.9 sind die Resultate für die unterschiedlichen Planungshorizonte N = 4, N = 8 und N = 16 zu sehen. Offenbar kann auch O15 verhältnismäßig stark von steigenden Planungshorizonten profitieren: Die Reduktion von  $\Delta R_{\mu}^{\omega}$  gegenüber  $\Delta U_{\mu}^{\omega}$  beträgt 26,42 %, 31,82 % bzw. 33,84 % für N = 4, N = 8 bzw. N = 16. Auch  $\Delta^2 R_{\mu}^{\omega}$  nimmt mit zunehmenden Planungshorizont ab. Doch nicht nur  $\Delta R_{\mu}^{\omega}$  und  $\Delta^2 R_{\mu}^{\omega}$ , sondern auch die Spreizung der Residuallast  $R_{\downarrow}$  kann wesentlich von längeren Planungshorizonten profitieren.

Selbstverständlich steigen auch die Zeiten  $T^{\omega}$  mit steigendem Planungshorizont. Wie bereits zuvor erwähnt, bewegen sich diese in etwa auf einem Niveau mit den Zeiten der Autonomen Verbraucherorganisationen bestehend aus programmgetriebenen Verbrauchern.

#### Vergleich von O15 mit O15H

Die von O15 und O15H erzielten Ergebnisse für N = 8 sind in Tabelle 8.10 gegenübergestellt.

Wie vermutet, erzielt O15H für einen Planungshorizont von N = 8 schlechtere Werte bezüglich  $\Delta R_{\mu}^{\omega}$  als O15. So kann O15-t den Wert von  $\Delta R_{\mu}^{\omega}$  gegenüber O15-u um 56,24 % reduzieren, wohingegen O15H-t eine Reduktion um 50,61 % erreicht. Die durchschnittlich in einer AVO anliegenden

## 8. Evaluation

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
O15-t	0,855 $\pm 0,336$	0,635 $\pm 0,164$	1,254 $\pm 0,318$	418,080 $\pm 6,983$	793,624 $\pm 11,261$	375,544 $\pm 13,696$	639,527 $\pm 116,845$	49,241 $\pm 42,039$	187,180 $\pm 40,870$
O15H-t	0,965 $\pm 0,250$	0,707 $\pm 0,166$	1,259 $\pm 0,317$	436,788 $\pm 11,822$	775,033 $\pm 8,434$	338,246 $\pm 17,255$	639,518 $\pm 102,022$	49,255 $\pm 33,016$	4316,819 $\pm 1672,769$

*Tabelle 8.10.:* Vergleich der Evaluationsergebnisse von O15-t mit O15H-t für den Planungshorizont  $N = 8$ . Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in *ms* angegeben; alle anderen Werte sind in *kW* angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

absoluten Differenzen der ungesteuerten Leistung  $\Delta U_{\mu}^{\omega}$  können durch eine flexibilisierte Nachfrage in O15-t um 31,82 %, in O15H-t dagegen nur um 23,35 % verringert werden. Ähnlich sieht es bei  $\Delta^2 R_{\mu}^{\omega}$  aus: Auch hier erreicht O15-t gegenüber O15-u geringere Werte. Somit lässt sich festhalten, dass O15 gegenüber O15H sowohl geringere durchschnittliche Veränderungen der Residuallast zulässt als auch für gleichmäßigere Veränderungen der Residuallast sorgt.

Interessanterweise führt O15H jedoch zu geringeren Spreizungen der Residuallast.

Ein deutlicher Unterschied zwischen O15 und O15H ist außerdem in den Werten  $T^{\omega}$  für die durchschnittliche Dauer für die Berechnung der Fahrpläne zu sehen. Braucht O15-t durchschnittlich nur 187,180 ms für die Einsatzplanung in jeder Autonomen Verbraucherorganisation, so benötigt O15H-t hierfür 4,317 s. Das ist natürlich denjenigen Autonomen Verbraucherorganisationen geschuldet, die nur aus thermischen Verbrauchern bestehen und im Schnitt mehr als zwölf Sekunden für ihre Einsatzplanung benötigen (siehe Abschnitt 8.4.1). Die deutlich niedrigere Fahrplanberechnungszeit ist ein großer Vorteil für O15: Um auf vergleichbare Zeiten zu kommen, kann das Optimierungsproblem in O15 komplexer und beispielsweise der Planungshorizont vergrößert werden. Vergleicht man nämlich O15-t für  $N = 16$  mit O15H-t für  $N = 8$ , so werden die Unterschiede in  $\Delta R_{\mu}^{\omega}$  nochmals größer und O15 erreicht dann sogar eine geringere Spreizung der Residuallast, und das, obwohl die durchschnittliche Fahrplanberechnungszeit mit 714,348 ms immer noch weitaus kürzer ist als die 4,317 s von O15H.

### Fazit

Das Fazit für die Evaluierung heterogener Partitionen – bestehend aus unterschiedlichen Verbrauchertypen – fällt sehr ähnlich aus zu dem Fazit für homogene Partitionen (siehe Abschnitt 8.4.1). So erzielen auch die heterogenen Partitionen wie die homogenen Partitionen sehr gute Ergebnisse bezüglich der Glättung der Residuallast und übertrumpfen die Variante ohne Einsatzplanung deutlich.

Auch die Berücksichtigung von TBS in der robusten Einsatzplanung hat erneut die im System vorherrschenden Unsicherheiten gut quantifiziert und antizipiert und bestätigt somit die Ergebnisse des vorherigen Abschnitts und der robusten Einsatzplanung in Autonomen Virtuellen Kraftwerken [7, 5]. Gegenüber der Einsatzplanung basierend auf den Vorhersagen liefert die robuste Einsatzplanung basierend auf TBS die besseren Ergebnisse; die Einsatzplanung, die lediglich auf Basis des antizipierten Szenarios stattfand, war dabei auf einem Niveau mit der Einsatzplanung für einen ganzen TBST.

Im direkten Vergleich mit den Ergebnissen des gleichen Systems – aber mit einer Aufteilung in homogene Partitionen – hat sich bestätigt, dass heterogene Partitionen unter gleichen Bedingungen die Residuallast besser glätten können. Zudem benötigen diese wesentlich weniger Zeit für ihre Einsatzplanung. So kann die Einsatzplanung für heterogene Partitionen beispielsweise mit einem größeren Planungshorizont nochmals bessere Ergebnisse liefern – trotz immer noch deutlich kürzeren Fahrplanberechnungszeiten gegenüber O15H. Dies unterstreicht die Vorteile einer homogenen Partitionierung von Autonomen Verbraucherorganisationen gegenüber anderen Zielfunktionen im Partitionierungsproblem.

### 8.4.3. GRÖßERE PARTITIONEN

In diesem Teil der Evaluierung wird die Auswirkung der Größe von Autonomen Verbraucherorganisationen auf die Lösungsqualität untersucht. Zu diesem Zweck wurden erneut dieselben Verbraucher und Steuerungsmodelle verwendet, wie in den vorherigen Abschnitten. Im Vergleich zum vorherigen Abschnitt, in dem die 150 Verbraucher auf 15 Autonome Verbraucherorganisationen aufgeteilt wurden, waren in diesem Abschnitt die Verbraucher auf fünf Autonome Verbraucherorganisationen der Größe 30 verteilt. Diese Autonome Verbraucherorganisationen hatten zudem eine um den Faktor drei höhere vorgegebene ungesteuerte Leistung  $U^\omega$  gegenüber

## 8. Evaluation

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
O5-a	2,276 ± 0,696	1,663 ± 0,414	3,754 ± 0,967	437,826 ± 11,406	783,820 ± 17,019	345,994 ± 22,318	639,041 ± 105,064	48,791 ± 39,341	392,881 ± 117,031
O5-o	1,087 ± 1,062	0,166 ± 0,201	3,754 ± 0,998	470,753 ± 2,957	759,562 ± 9,848	288,810 ± 10,689	638,554 ± 102,637	48,300 ± 42,444	383,026 ± 74,037
O5-p	3,465 ± 0,917	2,886 ± 0,673	3,749 ± 0,969	454,460 ± 8,169	794,746 ± 14,015	340,286 ± 17,812	639,201 ± 97,852	48,967 ± 37,971	404,649 ± 182,778
O5-t	2,272 ± 0,705	1,725 ± 0,438	3,780 ± 0,986	441,958 ± 9,900	786,205 ± 15,359	344,247 ± 15,921	639,407 ± 103,711	49,117 ± 37,399	1367,884 ± 595,749
O5-u	5,031 ± 1,812	3,773 ± 1,734	5,031 ± 1,812	404,818 ± 3,591	855,747 ± 10,972	450,928 ± 12,129	645,313 ± 130,168	—	—

Tabelle 8.11.: Evaluationsergebnisse für O5 mit  $N = 16$ : nur auf Basis des antizipierten Szenarios, mit perfektem Wissen, nur auf Basis der Vorhersage, mit ganzem TBST und ungesteuert. Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in *ms* angegeben; alle anderen Werte sind in *kW* angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

den vorgegebenen ungesteuerten Leistungen der Autonomen Verbraucherorganisationen aus dem vorherigen Abschnitt, so dass diese mit vergleichbaren Unsicherheiten konfrontiert waren. Diese Systemkonfiguration wird im Folgenden mit O5 bezeichnet.

Wie auch in den vorherigen Abschnitten werden erneut Evaluationsszenarien unter optimalen Bedingungen (O5-o), auf Basis der Vorhersage (O5-p), auf Basis des antizipierten Szenarios (O5-a), auf Basis des ganzen TBST (O5-t) und mit ungesteuerten potentiell steuerbaren Verbrauchern durchgeführt (O5-u).

### Ergebnisse zu O5

Die in O5 erzielten Ergebnisse für den Planungshorizont  $N = 16$  sind in Tabelle 8.11 dargestellt.

Was zunächst auffällt, ist dass die gestiegene zugewiesene ungesteuerte Leistung  $U^{\omega}$  in entsprechend höheren Werten von  $\Delta R_{\mu}^{\omega}$  und  $\Delta U_{\mu}^{\omega}$  resultiert. Wie bisher auch, ist das Evaluationsszenario mit komplett ungesteuerter Nachfrage bzw. unter optimalen Bedingungen am schlechtesten bzw. am besten. Auch die Verhältnisse zwischen O5-a, O5-p und O5-t haben sich nicht verändert: In O5-p ist  $\Delta R_{\mu}^{\omega}$  7,58 % niedriger als  $\Delta U_{\mu}^{\omega}$ , wohingegen eine robuste Einsatzplanung auf Basis von TBS weitaus bessere Ergebnisse

#### 8.4. Demand Side Management: Evaluationsszenarien und -ergebnisse

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\min}$	$R_{\max}$	$R_{\downarrow}$	$R_{\mu}$	$S_{\mu}$	$T^{\omega}$
O5-t, N = 4	2,510 $\pm 1,774$	1,971 $\pm 0,691$	3,784 $\pm 0,966$	393,110 $\pm 11,116$	805,276 $\pm 11,985$	412,166 $\pm 17,597$	639,129 $\pm 133,813$	48,859 $\pm 54,244$	205,799 $\pm 40,379$
O5-t, N = 8	2,369 $\pm 1,081$	1,768 $\pm 0,425$	3,762 $\pm 0,970$	403,113 $\pm 14,030$	793,847 $\pm 15,497$	390,734 $\pm 21,466$	638,279 $\pm 123,592$	48,002 $\pm 48,896$	495,690 $\pm 90,320$
O5-t, N = 16	2,272 $\pm 0,705$	1,725 $\pm 0,438$	3,780 $\pm 0,986$	441,958 $\pm 9,900$	786,205 $\pm 15,359$	344,247 $\pm 15,921$	639,407 $\pm 103,711$	49,117 $\pm 37,399$	1367,884 $\pm 595,749$

Table 8.12.: Evaluationsergebnisse für O5-t mit unterschiedlichen Planungshorizonten: N = 4, N = 8 und N = 16. Die durchschnittliche Dauer für die Berechnung der Fahrpläne  $T^{\omega}$  ist in ms angegeben; alle anderen Werte sind in kW angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

ermöglicht. So ist  $\Delta R_{\mu}^{\omega}$  in O5-a um 39,37% niedriger als  $\Delta U_{\mu}^{\omega}$ , O5-t reduziert  $\Delta U_{\mu}^{\omega}$  um leicht bessere 39,89%.

Die pro Autonomer Verbraucherorganisation benötigte durchschnittliche Fahrplanberechnungszeit ist bei denjenigen Evaluationsszenarien, die nicht auf Basis eines TBST Fahrpläne zu berechnen hatten, wiederum in etwa auf einem Niveau und liegt dort bei rund 400 ms. Die größere Komplexität bei der Einsatzplanung für einen TBST resultiert auch in O5 in einer höheren durchschnittlichen Fahrplanberechnungszeit. Mit 1,368 s ist sie mehr als dreimal so groß.

Bezüglich der Spreizung der Residuallast in O5 bewegen sich O5-a, O5-p und O5-t wieder in etwa auf einem Niveau; O5-o bzw. O5-u liefern wie auch in den anderen Systemkonfigurationen die geringste bzw. größte Spreizung.

In Tabelle 8.12 sind die Resultate von O5 für die Planungshorizonte N = 4, N = 8 und N = 16 zu sehen. Die Unterschiede zwischen den verschiedenen Planungshorizonten ähneln stark den Unterschieden von O15. So sind auch hier Verbesserungen von  $\Delta R_{\mu}^{\omega}$  und  $\Delta^2 R_{\mu}^{\omega}$  mit steigendem Planungshorizont zu sehen; die Reduktion gegenüber  $\Delta U_{\mu}^{\omega}$  beträgt bei steigendem N 33,67%, 37,03% bzw. 39,89% und ist demnach in allen Planungshorizonten besser als bei O15 (26,42%, 31,82% bzw. 33,84%). Auch die altbekannten reduzierten Spreizungen der Residuallast und die steigenden Fahrplanberechnungszeiten sind erneut vorhanden.

## 8. Evaluation

### Vergleich von O5 mit O15

Im Vergleich zu O15 erzielt O5 bessere Ergebnisse bezüglich der Glättung der Residuallast. So sind zwar die Werte von  $\Delta R_{\mu}^{\omega}$  höher – das ist jedoch der dreifach höheren zugewiesenen ungesteuerten Leistung  $U^{\omega}$  geschuldet, was auch in den Evaluationsszenarien, in denen eine Einsatzplanung durchgeführt wird, zu einem dreimal so hohen Wert von  $\Delta U_{\mu}^{\omega}$  gegenüber den vergleichbaren Evaluationsszenarien aus O15 führt. In Relation zu  $\Delta U_{\mu}^{\omega}$ , sind die in O5 erreichten  $\Delta R_{\mu}^{\omega}$  nämlich niedriger:  $\Delta R_{\mu}^{\omega}$  ist um 39,37 %, 71,04 %, 7,58 % bzw. 39,89 % niedriger (für O5-a, O5-o, O5-p bzw. O5-t) als das entsprechende  $\Delta U_{\mu}^{\omega}$ . Die in O15 in den analogen Evaluationsszenarien erzielten Verbesserungen betragen dagegen nur 33,84 %, 65,02 %, 3,25 % bzw. 33,84 % und bewegen sich daher ca. 4–6 % unter denjenigen von O5.

Die in O5 größere Anzahl an Verbrauchern innerhalb einer Autonomen Verbraucherorganisation, für die eine Einsatzplanung durchgeführt werden muss, führt allerdings klarerweise auch zu einer höheren Dauer für die Berechnung von Fahrplänen. Im Schnitt ist diese in O5 in etwa 2–3 mal so hoch wie in O15 und daher noch im Rahmen.

Die Spreizung der Residuallast ist in O15 in etwa auf vergleichbarem Niveau wie in O5. Im Evaluationsszenario unter optimalen Bedingungen wird in O5 eine geringere Spreizung der Residuallast erzielt, in den anderen Evaluationsszenarien eine etwas schlechtere.

### Fazit

Aus den Evaluierungsdaten geht hervor, dass Autonome Verbraucherorganisationen mit einer größeren Anzahl an Verbrauchern – in diesem Fall 30 – die dadurch gewonnene Flexibilität besser ausnutzen können und zu einer besseren durchschnittlichen Glättung der Residuallast führen, als Autonome Verbraucherorganisationen mit einer kleineren Anzahl an Verbrauchern – in diesem Fall 10. Die dadurch größere Komplexität des Optimierungsproblems führt allerdings zu größeren durchschnittlichen Fahrplanberechnungszeiten. Sinnvolle Partitionsgrößen sind folglich ein Trade-Off zwischen einer besseren Glättung der Residuallast und niedrigeren Fahrplanberechnungszeiten – genauso wie in Autonomen Virtuellen Kraftwerken, deren Partitionsgrößen ebenfalls ein Trade-Off zwischen Lösungsqualität und Fahrplanberechnungszeiten ist [14].

#### 8.4.4. FAZIT ZUM DEMAND SIDE MANAGEMENT

Im Gesamten betrachtet, hat sich über alle Systemkonfigurationen gezeigt, dass die Glättung der Residuallast in Autonomen Verbraucherorganisationen unter Unsicherheiten gute Resultate liefert. Dabei ist festzuhalten, dass in allen untersuchten Fällen eine Einsatzplanung gegenüber keiner Einsatzplanung, wo keine Flexibilisierung des Verbrauchs stattfindet, zu bevorzugen war; selbst die Einsatzplanung auf Basis fehlerhafter Vorhersagen führte bereits zu einer glatteren Residuallast. Wurden jedoch Trust-basierte Szenarien [16] in der Einsatzplanung eingesetzt, konnten die vorliegenden Vorhersagefehler reduziert werden, so dass sich wesentlich bessere Ergebnisse bezüglich der Glättung der Residuallast erzielen ließen. Dies bestätigt die guten Ergebnisse des Einsatzes von TBS in der robusten Einsatzplanung von Autonomen Virtuellen Kraftwerken [7, 5]. Dass die Unsicherheiten jedoch nicht perfekt antizipiert werden konnten, haben die als Vergleichsmaßstab herangezogenen Evaluationsszenarien gezeigt, welche eine Einsatzplanung unter perfekten Vorhersagen ausführten; diese lieferten in allen Evaluierungen mit Abstand die besten Resultate.

Die Betrachtung unterschiedlicher Systemkonfigurationen hat gezeigt, dass die verschiedenen Verbrauchertypen unterschiedliches Potential zur Glättung der Residuallast aufweisen. Die besonders flexiblen, als Speicher fungierenden, Elektrofahrzeuge wiesen dabei trotz der geringsten Fahrplanberechnungszeiten das meiste Potential auf. Aber auch programmgetriebene und thermische Verbraucher sind dazu in der Lage, die Residuallast glatter zu machen. Allerdings benötigt eine Einsatzplanung für Autonome Verbraucherorganisationen, die ausschließlich aus Verbrauchern desselben Typs bestehen, insbesondere für thermische Verbraucher um ein Vielfaches länger.

Die Evaluierung hat außerdem auch gezeigt, dass Autonome Verbraucherorganisationen, die gemäß einer homogenen Partitionierung [12] gebildet sind und eine Mischung von Verbrauchern unterschiedlichen Typs enthalten, bessere Resultate erzielen, als solche Autonome Verbraucherorganisationen, die ausschließlich aus Verbrauchern desselben Typs bestehen. Die Größe von Autonomen Verbraucherorganisationen hat dabei einen Einfluss auf die Qualität der Lösung – größere Organisationen liefern aufgrund ihrer größeren Flexibilität zwar bessere Lösungen, benötigen dafür aber auch länger für die Einsatzplanung. Genauso verhält es sich für die Größe des

## 8. Evaluation

Planungshorizonts; es hat sich in allen Systemkonfigurationen gezeigt, dass die Glättung der Residuallast bessere Resultate erzielt, wenn ein längerer Planungshorizont gewählt wird, da so die Nachfrage besser an zukünftige Entwicklungen angepasst werden kann. Aber auch hier führt die gewonnene Lösungsqualität zu höheren Fahrplanberechnungszeiten.

### 8.5. SUPPLY DEMAND MANAGEMENT: EVALUATIONSSZENARIEN UND -ERGEBNISSE

In diesem Abschnitt liegt der Fokus auf der Untersuchung der Auswirkungen von Autonomen Verbraucherorganisationen auf Autonome Virtuelle Kraftwerke. Das bedeutet, dass in diesem Abschnitt nun ein System bestehend aus Autonomen Verbraucherorganisationen und Autonomen Virtuellen Kraftwerken zum Supply Demand Management betrachtet wird.

An dem grundsätzlichen Evaluationsaufbau und -ablauf ändert sich in diesem Abschnitt nichts gegenüber dem vorherigen Abschnitt; die veränderten und zusätzlichen Bedingungen werden nun vorgestellt.

Für die Generierung von Kraftwerksmodellen mit plausiblen Nennleistungen wurden öffentlich verfügbare Daten von EnergyMap<sup>30</sup> verwendet, die bis zum Jahre 2014 aktuelle Daten zu den Erzeugern aus erneuerbaren Energien in Deutschland gesammelt und analysiert haben. Dazu wurde auf dem verfügbaren Datensatz über die verschiedenen Anlagentypen eine empirische Wahrscheinlichkeitsverteilung der Nennleistungen basierend auf einer Klasseneinteilung erstellt und daraus dann zufällig 98 Kraftwerksmodelle generiert, wovon 35 steuerbar waren. Im Falle steuerbarer Kraftwerke wurden des Weiteren typische Daten für die Änderungsgeschwindigkeiten verwendet. Eine Abbildung der Änderungsgeschwindigkeit auf Kosten oder eine komplexere Kostenfunktion für steuerbare Kraftwerke, die unterschiedlichen Auslastungen des Kraftwerks unterschiedliche Kosten zuordnet, wurde dabei nicht verwendet. Das bedeutet, dass für die Messung der Vorteile für Kraftwerke, die sich durch die Einsatzplanung von Verbrauchern ergeben, wie zuvor die Metriken bezüglich der Glättung der Residuallast herangezogen werden. Dargebotsabhängige Erzeuger – Windkraftanlagen und Photovoltaikanlagen – speisten in der Evaluation anhand des in der Simulation vorliegenden Wetters, das auf real aufgetretenen Wetterdaten

<sup>30</sup> <http://www.energymap.info/> (besucht am 21.03.2017)

## 8.5. Supply Demand Management: Evaluationsszenarien und -ergebnisse

basierte<sup>31</sup>, ein. Die Vorhersage der dargebotsabhängigen Erzeuger unterlag dabei Unsicherheiten: So wich die tatsächliche dargebotsabhängige Leistung von der vorhergesagten dargebotsabhängigen Leistung in der Abfolge 0 %, 20 %, 0 % und -20 % ab, unterlag also relativ hohen Vorhersagefehlern.

Die 98 Kraftwerke waren in einer kleinen Hierarchie, bestehend aus drei Autonomen Virtuellen Kraftwerken, enthalten. Dabei waren dem Wurzel-avkw mehrere Kraftwerke und die zwei anderen avkw untergeordnet. Die Einsatzplanung in avkw erfolgte immer auf einem ganzen TBST der Residuallast, wurde also nicht, wie es im vorherigen und in diesem Abschnitt für die AVO der Fall war, auf das antizipierte Szenario oder die Vorhersage beschränkt. Die Leistung steuerbarer Kraftwerke wurde jedoch für jeden Zeitschritt auf Basis des im Fahrplan enthaltenen antizipierten Szenarios gewählt. Eine reaktive Anpassung der Leistung steuerbarer Kraftwerke fand nicht statt.

Auf Seiten der Verbraucher waren die nicht-steuerbaren Verbraucher mit denselben Unsicherheiten wie im vorherigen Abschnitt versehen. Die ungesteuerte Leistung Autonomer Verbraucherorganisationen setzte sich zusammen aus der zugewiesenen dargebotsabhängigen Leistung des übergeordneten avkw und aus der nicht-steuerbaren Nachfrage der AVO und unterlag somit den Unsicherheiten beider. Die Evaluation in diesem Abschnitt wurde für zwei unterschiedliche Systemkonfigurationen von Verbrauchern durchgeführt.

In einem etwas konservativeren Szenario wurden 775 Verbrauchermodelle generiert, deren Nachfrage im Vergleich zu der Nachfrage nicht-steuerbarer Verbraucher einen eher kleineren Anteil von ca. 15 % ausmachte. Die gesamte Nachfrage dieser steuerbaren Verbraucher und die Nachfrage nicht-steuerbarer Verbraucher war dabei so gewählt, dass die 98 Kraftwerke diese problemlos decken konnten und der Anteil der dargebotsabhängigen Leistung an der Deckung der Nachfrage in etwa 33 % betrug, also vergleichbar mit der heutigen Situation [29]. Diese Systemkonfiguration wird im weiteren Verlauf SD-now genannt. Die 775 Verbraucher wurden in dieser Systemkonfiguration auf 35 verschiedene Autonome Verbraucherorganisationen partitioniert, so dass jede AVO knapp über 20 steuerbare Verbraucher enthielt.

In einem etwas optimistischeren Szenario, wie es in einigen Jahren mit einer Verbreitung von steuerbaren Verbrauchern und von Elektrofahrzeugen

31 <http://www.lfl.bayern.de/>, Daten aus dem Jahr 2010

## 8. Evaluation

in der Realität vorliegen könnte, wurden 950 Verbrauchermodelle generiert, deren Nachfrage im Vergleich zu der Nachfrage nicht-steuerbarer Verbraucher einen größeren Anteil als in SD-now hatten, nämlich ca. 34 %. Das entspricht in etwa den Schätzungen von Brooks et al. [25]. Diese Systemkonfiguration wird im Folgenden mit SD-fut bezeichnet. Die 950 Verbraucher wurden in SD-fut auf eine etwas größere Menge von 50 Autonomen Verbraucherorganisationen partitioniert, so dass auch in dieser Systemkonfiguration jede AVO im Schnitt knapp unter 20 steuerbare Verbraucher enthielt. Um auch die Veränderungen der kommenden Jahre auf Seiten der Erzeuger abzubilden, wurden in SD-fut die Nennleistungen der dargebotsabhängigen Erzeuger etwas nach oben skaliert, so dass diese letztendlich in den Simulationen einen relativ hohen Anteil von 61 % an der gesamten erzeugten Leistung hatten; das entspräche nach aktuellen Zielvorgaben des Ausbaus erneuerbarer Energien einem Zeitpunkt von in etwa dem Jahr 2035 [29].

Die jeweiligen Autonomen Verbraucherorganisationen waren gleichmäßig auf die Autonomen Virtuellen Kraftwerke aufgeteilt.

### *Generierung der Steuerungsmodelle in SD-now und SD-fut*

Konkret wurden in SD-now 350 thermische Verbraucher, 350 programmgetriebene Verbraucher, 35 abschaltbare Verbraucher, 10 Speicher und 30 Elektrofahrzeuge generiert. Die Parametrisierung der Steuerungsmodelle für thermische Verbraucher, programmgetriebene Verbraucher und für Elektrofahrzeuge entsprach dabei derjenigen aus Abschnitt 8.4. Die Modelle abschaltbarer Verbraucher wurden so generiert, dass sie entweder um 0:00, 6:00 oder 8:00 Uhr gestartet wurden und entweder um 18:00, 20:00 oder 0:00 Uhr beendet worden sind. In dem dadurch möglichen Zeitraum von 10–24 Stunden konnten sie insgesamt für maximal 30, 45 oder 60 Minuten abgeschaltet werden (entsprechend zwei, drei oder vier Zeitschritte). Im ungesteuerten Fall fragten abschaltbare Verbraucher permanent während des Zeitraums ihrer Verfügbarkeit Leistung nach. Die maximale Entladeleistung  $P_{\min}$  herkömmlicher Speicher entsprach der generierten maximalen Ladeleistung  $P_{\max}$ . Herkömmliche Speicher waren im ungesteuerten Fall sehr simpel gestrickt; diese füllten sich einfach schnellstmöglich auf und verbrauchten danach keine Leistung mehr. Einen Überblick über die Parametrisierung der zufällig generierten Parameter der Steuerungsmodelle abschaltbarer Verbraucher und Speicher gibt Tabelle 8.13.

## 8.5. Supply Demand Management: Evaluationsszenarien und -ergebnisse

In der anderen Systemkonfiguration SD-fut wurden 350 thermische Verbraucher, 350 programmgetriebene Verbraucher, 25 abschaltbare Verbraucher, 25 Speicher und 200 Elektrofahrzeuge generiert. Somit wurde im Vergleich zu SD-now die Anzahl der Elektrofahrzeuge stark erhöht, um der erwarteten Zunahme an Elektrofahrzeugen in der Zukunft gerecht zu werden. Auch der Mittelwert für die Generierung der maximalen Batteriekapazität wurde gegenüber SD-now stark erhöht, um die zukünftigen Entwicklungen der Batterieforschung zu berücksichtigen. So geht beispielsweise eine Studie im Auftrag des Umweltbundesamtes [97] davon aus, dass im Jahre 2050 Batteriekapazitäten in Elektrofahrzeugen von 100 kWh möglich sind. Des Weiteren sind die maximalen Ladeleistungen für Elektrofahrzeuge an eine bessere Ladeinfrastruktur und bessere Ladecontroller angepasst, so dass wesentlich schnellere Ladegeschwindigkeiten möglich sind.  $P_{\max}$  eines Elektrofahrzeugs wurde in SD-fut zufällig zwischen 11, 22, 43, 150 und 350 kW gewählt, wobei erstere und letztere dreimal weniger wahrscheinlich waren wie die anderen maximalen Ladeleistungen. Obwohl generell erwartet wird, dass der Verbrauch einzelner elektrischer Geräte aufgrund von Effizienzsteigerungen zukünftig abnimmt [106], wurde in dieser Systemkonfiguration der Verbrauch der weiteren einzelnen Verbraucher erhöht, um die Anzahl der im System befindlichen Verbraucher nicht unnötig zu erhöhen, aber um gleichzeitig das erhöhte Potential an flexibilisierter Nachfrage abzubilden. Eine Übersicht über die verwendeten Parameter für die zufällige Generierung der Steuerungsmodelle ist in Tabelle 8.14 zu sehen.

Die zeitabhängigen Parameter wurden in SD-fut wie in SD-now bzw. wie im vorherigen Abschnitt generiert.

### 8.5.1. KONSERVATIVES SYSTEM

Wie zuvor erwähnt, wurden in SD-now die 775 Verbraucher auf 35 Autonome Verbraucherorganisationen verteilt, die ihrerseits den 3 Autonomen Virtuellen Kraftwerken zugeordnet waren. Die AVO und AVKW wurden jeweils nach einer homogenen Partitionierung gebildet.

Analog zu den Systemkonfigurationen in Abschnitt 8.4, wurden auch für SD-now verschiedene Evaluationsszenarien durchgeführt. Dies beinhaltet ein Evaluationsszenario unter optimalen Bedingungen (SD-now-o), d. h. mit perfekten Vorhersagen der ungesteuerten Leistung (also der dargebotsab-

## 8. Evaluation

<b>Abschaltbare Verbraucher</b>	
$P_{on}$	$\mu = 75,0; \sigma = 5,0$
$P_{off}$	0
<b>Speicher</b>	
$E_{min}$	0
$E_{max}$	$\mu = 8,0; \sigma = 2,0$
$P_{max}$	$\in \{3, 7; 11; 22\}$
$e$	$\mu = 0,85; \sigma = 0,03$

*Tabelle 8.13.:* Verwendete Werte für die zufällige Generierung einiger Parameter der Steuerungsmodelle von abschaltbaren Verbrauchern und Speichern in SD-now. Ein Großteil der Parameter wurde mittels einer Normalverteilung generiert.  $P_{max}$  eines Speichers wurde gleichverteilt aus der angegebenen Menge gewählt.

hängigen Erzeuger und der nicht-steuerbaren Verbraucher), auf Basis der Vorhersage ungesteuerter Leistung (SD-now-p), auf Basis des antizipierten Szenarios der ungesteuerten Leistung (SD-now-a), auf Basis des ganzen TBST ungesteuerter Leistung (SD-now-t) und mit ungesteuertem Verbrauch (SD-now-u). Zu beachten dabei ist, dass die AVKW in *allen* Evaluationsszenarien Fahrpläne für einen ganzen TBST erstellt haben.

Der Planungshorizont war für AVO auf  $N = 8$  festgelegt, da dies im vorherigen Abschnitt (siehe Abschnitt 8.4) gute Ergebnisse bei schnellen Fahrplanberechnungszeiten geliefert hat. Der Planungshorizont von AVKW betrug  $N = 4$ , wie er in AVKW üblicherweise verwendet wird [10, 62].

### *Ergebnisse zu SD-now*

Die Ergebnisse zu SD-now sind in Tabelle 8.15 dargestellt.

Betrachtet man zunächst die erzielten Ergebnisse bezüglich der Glättung der Residuallast, so lässt sich festhalten, dass Autonome Verbraucherorganisationen auch im Kontext der Autonomen Virtuellen Kraftwerke dazu in der Lage sind, die Residuallast zu glätten und die Spreizung der Residuallast zu reduzieren. So liefert SD-now-u den schlechtesten Wert von  $\Delta R_{\mu}^{\omega}$ . Auch der Einsatz von TBS führt erneut zu besseren Ergebnissen als das Vertrauen auf die vorhergesagte ungesteuerte Leistung und bestätigt somit die Ergebnisse aus Abschnitt 8.4. Was hingegen überrascht, ist dass SD-now-o auf einem Niveau mit SD-now-a und SD-now-t liegt und nur leicht bessere Ergebnisse erreicht. So gelingt es SD-now-o die absoluten Differenzen in  $\Delta U_{\mu}^{\omega}$  um

## 8.5. Supply Demand Management: Evaluationsszenarien und -ergebnisse

<b>Thermische Verbraucher</b>	
$P_{on}$	$\mu = 2,0; \sigma = 0,2$
$P_{off}$	0
$T_{min}$	$\mu = 3,0; \sigma = 0,5$
$T_{max}$	$\mu = 8,0; \sigma = 0,5$
$\Delta T_{on}$	$\mu = -0,1; \sigma = 0,01$
$\Delta T_{off}$	$\mu = 0,03; \sigma = 0,003$
<b>Programmgetriebene Verbraucher</b>	
$P_{on}$	$\mu = 5,0; \sigma = 0,5$
$P_{off}$	0
$\tau_{dur}$	$\mu = 120,0; \sigma = 15,0$
<b>Abschaltbare Verbraucher</b>	
$P_{on}$	$\mu = 150,0; \sigma = 5,0$
$P_{off}$	0
<b>Speicher</b>	
$E_{min}$	0
$E_{max}$	$\mu = 16,0; \sigma = 3,0$
$P_{max}$	$\in \{3,7; 11; 22\}$
$e$	$\mu = 0,9; \sigma = 0,03$
<b>Elektrofahrzeuge</b>	
$E_{min}$	0
$E_{max}$	$\mu = 100,0; \sigma = 10,0$
$e$	$\mu = 0,9; \sigma = 0,03$
$E_{des}^{min}$	$\mu = 0,2; \sigma = 0,03$
$E_{des}^{dep}$	$\mu = 0,8; \sigma = 0,05$

*Tabelle 8.14.:* Verwendete Werte für die zufällige Generierung einiger Parameter der Steuerungsmodelle von thermischen Verbrauchern, programmgetriebenen Verbrauchern, abschaltbaren Verbrauchern, Speichern und Elektrofahrzeugen in SD-fut. Ein Großteil der Parameter wurde mittels einer Normalverteilung generiert.  $\tau_{dur}$  ist in Minuten angegeben; der generierte Wert wurde dabei auf ein Vielfaches von 15 Minuten gerundet.  $P_{max}$  eines Speichers wurde gleichverteilt aus der angegebenen Menge gewählt.  $E_{des}^{min}$  und  $E_{des}^{dep}$  sind in Prozent der maximalen Kapazität  $E_{max}$  angegeben.

## 8. Evaluation

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\downarrow}$	$T^{\omega}$	$T^{\lambda}$	$\Delta P$	$\#TBS^{\lambda}$
SD-now-a	39,452 $\pm 13,065$	13,549 $\pm 8,249$	54,883 $\pm 12,418$	8413,464 $\pm 77,272$	156,410 $\pm 9,685$	77,348 $\pm 13,081$	74,713 $\pm 80,653$	1,037 $\pm 0,069$
SD-now-o	39,156 $\pm 12,936$	13,819 $\pm 9,009$	54,889 $\pm 12,400$	8424,343 $\pm 64,307$	157,417 $\pm 9,240$	451,395 $\pm 131,120$	0,061 $\pm 0,135$	4,997 $\pm 0,015$
SD-now-p	48,486 $\pm 18,188$	28,330 $\pm 9,945$	54,891 $\pm 12,369$	8942,854 $\pm 61,603$	302,504 $\pm 250,601$	79,439 $\pm 12,520$	75,605 $\pm 79,361$	1,040 $\pm 0,072$
SD-now-t	39,466 $\pm 13,018$	13,574 $\pm 8,163$	54,891 $\pm 12,399$	8445,012 $\pm 75,925$	167,996 $\pm 21,882$	78,138 $\pm 13,867$	75,389 $\pm 79,770$	1,036 $\pm 0,062$
SD-now-u	55,225 $\pm 13,192$	12,952 $\pm 12,384$	55,225 $\pm 13,192$	9432,174 $\pm 67,216$	—	75,633 $\pm 17,093$	75,793 $\pm 78,833$	1,030 $\pm 0,049$

Table 8.15.: Evaluationsergebnisse für SD-now: nur auf Basis des antizipierten Szenarios, mit perfektem Wissen, nur auf Basis der Vorhersage, mit ganzem TBST und ungesteuert. Die durchschnittlichen Dauern für die Berechnung der Fahrpläne  $T^{\omega}$  und  $T^{\lambda}$  sind in *ms* angegeben; alle anderen Werte bis auf  $\#TBS^{\lambda}$  sind in *kW* angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

28,66 % zu reduzieren – SD-now-a erreicht eine Reduktion um 28,12 % und SD-now-t erzielt ein um 28,10 % geringeres  $\Delta R_{\mu}^{\omega}$  gegenüber  $\Delta U_{\mu}^{\omega}$ . SD-now-a und SD-now-t sind also auch in dieser Systemkonfiguration auf einem Level. Bezüglich  $\Delta^2 R_{\mu}^{\omega}$  liefern SD-now-a und SD-now-t sogar bessere Resultate als SD-now-o. Offenbar ist es in dieser Systemkonfiguration unter den vorliegenden Unsicherheiten den TBS möglich, die Unsicherheiten auf ein Minimum zu reduzieren.

Die durchschnittlichen Fahrplanberechnungszeiten  $T^{\omega}$  innerhalb von AVO sind in SD-now-p im Vergleich zu den anderen Evaluationsszenarien ziemlich hoch. Die mitunter großen Abweichungen der tatsächlichen von der vorhergesagten ungesteuerten Leistung und die daraus folgenden großen Abweichungen des aktuellen Zustands  $U_{t_{\text{now}}}^{\omega}$  von den vorhergesagten  $U_t^{\omega}$  für  $t \in \mathcal{W}$  führen in dieser Systemkonfiguration anscheinend dazu, dass das Optimierungsproblem auf Basis der Vorhersage in manchen Situationen in der Komplexität deutlich ansteigt. Dies erklärt auch die im Vergleich extrem hohe Standardabweichung. Ansonsten ist die Fahrplanberechnungszeit in SD-now-t nicht unerwartet aufgrund der Berechnung für einen TBST etwas höher als für SD-now-a und SD-now-o.

Die Analyse der Daten  $T^{\lambda}$ ,  $\Delta P$  und  $\#TBS^{\lambda}$  zeigt, dass AVKW offenbar neben einer glatteren Residuallast nicht weiter von der von Autonomen Verbrau-

## 8.5. Supply Demand Management: Evaluationsszenarien und -ergebnisse

cherorganisationen durchgeführten Residuallastglättung profitieren können. Abgesehen von SD-now-o, gibt es in den Evaluationsszenarien SD-now-a, SD-now-p, SD-now-t und SD-now-u keine nennenswerten Unterschiede in der durchschnittlichen Fahrplanberechnungszeit  $T^\lambda$ , die Abweichung  $\Delta P$  der erzeugten Leistung von der Residuallast bewegt sich relativ zur durchschnittlich vorliegenden Residuallast (über alle Evaluationsszenarien im Schnitt ca. 7675 kW) in allen Szenarien im Promillebereich und auch die Anzahl der TBS pro AVKW weicht in den verschiedenen Evaluationsszenarien nicht nennenswert voneinander ab. Erstaunlich ist jedoch die auffallend hohe  $\#TBS^\lambda$  in SD-now-o, die auch zu den verhältnismäßig hohen Fahrplanberechnungszeiten  $T^\lambda$  führt. Dies liegt darin begründet, dass die Residuallastglättung nicht jeden Zeitschritt zu den exakt gleichen Ergebnissen führt und somit kleine Abweichungen in den Vorhersagen der steuerbaren Nachfrage entstehen. Aufgrund der unterschiedlichen Ausprägungen dieser kleineren Abweichungen und der gewählten Parametrisierung der TBS, dass die Breite der Klassen der TBS auf Basis der maximalen Prognoseabweichung bestimmt wird, konnte es im Zusammenspiel mit den perfekten Vorhersagen der dargebotsabhängigen Erzeuger und der nicht-steuerbaren Verbraucher zu einer derartig hohen Anzahl an TBS kommen.

### 8.5.2. ZUKÜNFTIGES SYSTEM

Die 950 Verbraucher in SD-fut waren auf 50 Autonome Verbraucherorganisationen verteilt, die ihrerseits den 3 Autonomen Virtuellen Kraftwerken zugeordnet waren. Die AVO und AVKW wurden wie in SD-now jeweils nach einer homogenen Partitionierung gebildet.

Die Evaluation von SD-fut wurde wie SD-now durchgeführt, d. h. es wurden erneut die bekannten Evaluationsszenarien untersucht: SD-fut-a, SD-fut-o, SD-fut-p, SD-fut-t und SD-fut-u.

Die Autonomen Virtuellen Kraftwerke erstellten in allen Evaluationsszenarien Fahrpläne für einen ganzen TBST mit dem Planungshorizont  $N = 4$ . Die AVO erstellten Fahrpläne für einen Planungshorizont von  $N = 8$ .

#### *Ergebnisse zu SD-fut*

Die von SD-fut erzielten Resultate sind in Tabelle 8.16 zu sehen.

Die Ergebnisse bestätigen auch in SD-fut, dass die Glättung der Residuallast der Autonomen Verbraucherorganisationen im Zusammenspiel mit

## 8. Evaluation

	$\Delta R_{\mu}^{\omega}$	$\Delta^2 R_{\mu}^{\omega}$	$\Delta U_{\mu}^{\omega}$	$R_{\downarrow}$	$T^{\omega}$	$T^{\lambda}$	$\Delta P$	$\#TBS^{\lambda}$
SD-fut-a	9,825 $\pm 7,259$	6,157 $\pm 3,766$	36,594 $\pm 13,330$	13921,166 $\pm 240,571$	120,664 $\pm 3,770$	78,401 $\pm 13,915$	593,360 $\pm 1496,901$	1,029 $\pm 0,042$
SD-fut-o	8,505 $\pm 7,413$	3,675 $\pm 3,840$	36,609 $\pm 13,291$	13775,915 $\pm 156,441$	121,325 $\pm 3,712$	427,633 $\pm 127,884$	519,258 $\pm 1531,222$	5,000 $\pm 0,001$
SD-fut-p	24,209 $\pm 17,242$	32,252 $\pm 6,718$	36,568 $\pm 13,277$	16067,771 $\pm 186,984$	122,016 $\pm 11,276$	77,681 $\pm 12,618$	618,154 $\pm 1553,590$	1,027 $\pm 0,044$
SD-fut-t	9,820 $\pm 7,263$	6,245 $\pm 3,832$	36,559 $\pm 13,298$	13898,286 $\pm 216,470$	131,298 $\pm 15,848$	78,478 $\pm 13,792$	593,100 $\pm 1495,511$	1,027 $\pm 0,043$
SD-fut-u	40,809 $\pm 14,814$	20,582 $\pm 14,753$	40,809 $\pm 14,814$	19369,609 $\pm 149,668$	—	75,912 $\pm 17,950$	584,577 $\pm 1514,459$	1,029 $\pm 0,045$

Table 8.16.: Evaluationsergebnisse für SD-fut: nur auf Basis des antizipierten Szenarios, mit perfektem Wissen, nur auf Basis der Vorhersage, mit ganzem TBST und ungesteuert. Die durchschnittlichen Dauern für die Berechnung der Fahrpläne  $T^{\omega}$  und  $T^{\lambda}$  sind in ms angegeben; alle anderen Werte bis auf  $\#TBS^{\lambda}$  sind in kW angegeben. Alle Ergebnisse sind gemittelt über 50 Simulationsläufe pro Evaluationsszenario; die Werte nach  $\pm$  stellen die jeweiligen Standardabweichungen dar.

Autonomen Virtuellen Kraftwerken gut funktioniert und die Spreizung der Residuallast deutlich reduziert. Wie üblich ist der ungesteuerte Verbrauch am schlechtesten. Auch die Einsatzplanung auf Basis von Vorhersagen schneidet wieder deutlich schlechter ab als die Varianten mit Einsatzplanung auf Basis von TBST. So erreicht SD-fut-p einen Wert von  $\Delta R_{\mu}^{\omega}$ , der um 33,80 % niedriger ist als  $\Delta U_{\mu}^{\omega}$ , wohingegen SD-fut-a einen um 73,15 % und SD-fut-t einen um 73,14 % reduzierten Wert erzielt. Somit erreichen auch in SD-fut die beiden Evaluationsszenarien SD-fut-a und SD-fut-t gleichwertige Resultate. Und auch in SD-fut ist das Evaluationsszenario unter optimalen Bedingungen, SD-fut-o, im Gegensatz zu den Resultaten aus Abschnitt 8.4 nicht so viel besser wie die Einsatzplanung unter Unsicherheiten. Mit einer Reduktion von 76,77 % der Differenzen  $\Delta U_{\mu}^{\omega}$  der ungesteuerten Leistung erzielt es nur knapp bessere Ergebnisse als SD-fut-a und SD-fut-t. Insgesamt wird deutlich, dass der gestiegene Anteil an flexibilisierter Nachfrage einen Vorteil bringt, trotz ebenfalls höherer Unsicherheiten verursacht durch eine höhere dargebotsabhängige Leistung. So sind die erzielten Ergebnisse bezüglich der Glättung der Residuallast durch die Bank besser als in SD-now.

Die Fahrplanberechnungszeiten  $T^{\omega}$  befinden sich in SD-fut in etwa auf einem Niveau, wobei SD-fut-t aufgrund des durchschnittlich etwas mehr

## 8.5. Supply Demand Management: Evaluationsszenarien und -ergebnisse

als ein Szenario enthaltenen TBST (nicht in der Tabelle dargestellt) leicht höhere Zeiten aufweist. Die negativen Ausschläge der Fahrplanberechnungszeiten in SD-fut-p sind deutlich weniger ausgeprägt als in SD-now-p, aber gelegentlich noch vorhanden (siehe die leicht erhöhte Standardabweichung).

Wie in SD-now bestätigt sich auch in SD-fut, dass neben der glatteren Residuallast sich keine weiteren Vorteile für Autonome Virtuelle Kraftwerke ergeben. Die durchschnittlichen Fahrplanberechnungszeiten  $T^\lambda$  für AVKW bewegen sich auf dem gleichen Niveau wie in SD-now und auch die Anzahl an TBS in einem AVKW  $\#TBS^\lambda$  ist vergleichbar und ohne Auffälligkeiten. Lediglich SD-fut-o zeigt wieder ein auffälliges Verhalten mit einer hohen Anzahl an TBS; dies kann jedoch mit der gleichen Begründung wie in SD-now erklärt werden. Was allerdings im Gegensatz zu SD-now andere Resultate liefert, ist die durchschnittliche absolute Abweichung  $\Delta P$  der erzeugten Leistung von der Residuallast, die deutlich höher ausfällt als in SD-now. Grund dafür ist, was aus den Daten der Tabelle nicht ersichtlich ist, dass in dieser Systemkonfiguration die Einspeisung dargebotsabhängiger Erzeuger zeitweise derart hoch ist, dass die Residuallast über einen längeren Zeitraum negativ ist. So bewegt sich  $R_{\min}$  in den Evaluationsszenarien im Schnitt bei in etwa  $-6750 \text{ kW}$ , was auch die im Vergleich zu SD-now hohe Spreizung der Residuallast erklärt. Die negative Residuallast ist auch ein Indiz dafür, dass trotz des relativ hohen Anteils an flexibilisierter Nachfrage in dieser Systemkonfiguration, Speicher und die Kopplung des elektrischen Energieversorgungssystems mit anderen Versorgungsnetzen wie dem Gas- oder Wärmenetz einen wichtigen Beitrag zum stabilen Betrieb elektrischer Energieversorgungssysteme in Zukunft leisten müssen. Mit Ausnahme von SD-fut-o, dessen Anteil von  $\Delta P$  an der durchschnittlich aufgetretenen Residuallast  $R_\mu$  unter 10 % liegt, bewegen sich die anderen vier Evaluationsszenarien aber in etwa auf einem Niveau in dem Bereich von 10,80–11,76 %.

### 8.5.3. FAZIT ZUM SUPPLY DEMAND MANAGEMENT

Mit Blick auf SD-now und SD-fut lässt sich festhalten, dass sich die in Abschnitt 8.4 erzielten Ergebnisse bezüglich der Residuallastglättung unter Unsicherheiten auch in einem System von Autonomen Virtuellen Kraftwerken und Autonomen Verbraucherorganisationen bestätigen. Dabei schnitt die Systemkonfiguration SD-fut, die mit ca. 34 % einen höheren Anteil an

## 8. Evaluation

steuerbarer Nachfrage enthielt, deutlich besser ab als die Systemkonfiguration SD-now, deren Anteil an steuerbarer Nachfrage nur in etwa 15 % betrug.

Außerdem hat sich gezeigt, dass Autonome Virtuelle Kraftwerke abgesehen von der geglätteten Residuallast nicht weiter von der Einsatzplanung in Autonomen Verbraucherorganisationen profitieren können. So bleiben die durchschnittlichen Fahrplanberechnungszeiten, die Anzahl der TBS, für die Fahrpläne berechnet werden müssen, und die Abweichung zwischen erzeugter Leistung und zu deckender Residuallast unabhängig von der Einsatzplanung steuerbarer Verbraucher auf einem Level.

### 8.6. ZUSAMMENFASSUNG

In Gesamtbetrachtung aller durchgeführten Evaluierungen in diesem Kapitel, lässt sich als Fazit ziehen, dass die Einsatzplanung von steuerbaren Verbrauchern unter allen untersuchten Umständen Vorteile bezüglich der Glättung der Residuallast gegenüber einer ungesteuerten Nachfrage hat. Längere Planungshorizonte liefern dabei bessere Ergebnisse als kürzere, allerdings zu dem Preis von längeren Fahrplanberechnungszeiten. Ebenso hat sich gezeigt, dass Autonome Verbraucherorganisationen, die eine homogene Partitionierung [12] bilden, bessere Resultate erzielen als Autonome Verbraucherorganisationen, die aus gleichen Verbrauchertypen bestehen. Zudem profitieren Autonome Verbraucherorganisationen in einer homogenen Partitionierung von kürzeren Fahrplanberechnungszeiten, da sich die Einsatzplanung für eine Gruppe bestehend nur aus thermischen Verbrauchern als deutlicher komplexer herausgestellt hat, als für andere Verbrauchertypen. Größere Autonome Verbraucherorganisationen liefern dabei zwar aufgrund der steigenden Flexibilität bessere Ergebnisse als kleinere Autonome Verbraucherorganisationen, benötigen jedoch aufgrund der Komplexität der Einsatzplanung auch länger dafür. Die Wahl geeigneter Partitionsgrößen ist somit, wie die Wahl des Planungshorizonts, ein Trade-Off zwischen Lösungsqualität und der benötigten Zeit.

Alles in allem hat sich wie in der robusten Einsatzplanung der Autonomen Virtuellen Kraftwerke [7, 62] der Einsatz von Trust-basierten Szenarien (TBS) [16] zur Quantifizierung und Antizipation von Unsicherheiten in der nicht-steuerbaren Leistung auch in Autonomen Verbraucherorganisationen als tauglich herausgestellt. So konnten die Unsicherheiten, die durch

Vorhersagefehler in der nicht-steuerbaren Leistung verursacht wurden, deutlich reduziert werden. Dadurch konnten gegenüber einer Einsatzplanung, die lediglich auf Basis der Vorhersagen ausgeführt wurde, deutlich bessere Ergebnisse erzielt werden.

Im Zusammenspiel mit Autonomen Virtuellen Kraftwerken bestätigen sich zwar die Fähigkeiten der Autonomen Verbraucherorganisationen, die Residuallast unter Unsicherheiten zu glätten und eine geringere Spreizung der Residuallast zu erreichen, wodurch die Kraftwerke effizienter betrieben werden können, mit weniger Schwankungen der Residuallast zurechtkommen müssen und aufgrund der geringeren Spreizung der Residuallast theoretisch weniger steuerbare Kraftwerke hierfür benötigen. Allerdings konnten Autonome Virtuelle Kraftwerke davon abgesehen in den untersuchten Evaluierungsszenarien nicht noch in irgendeiner anderen Form profitieren. Weder werden die Unsicherheiten, mit denen Autonome Virtuelle Kraftwerke konfrontiert sind, reduziert noch führt die Glättung der Residuallast durch Autonome Verbraucherorganisationen zu einer kürzeren Fahrplanberechnungszeit oder qualitativ besseren Lösungen hinsichtlich der Deckung der Residuallast.



## FAZIT UND AUSBLICK

---

Dieses Kapitel schließt die vorliegende Arbeit mit einer Zusammenfassung der erreichten Ergebnisse und einem Ausblick auf zukünftige Arbeiten und offenen Fragestellungen ab.

# 9

### 9.1. ZUSAMMENFASSUNG DER ERREICHTEN ERGEBNISSE

Zukünftige Smart Grids sind auf eine Flexibilisierung der Nachfrage angewiesen, um das elektrische Energieversorgungssystem stabil betreiben zu können. In dieser Arbeit wurde hierfür ein Ansatz zum autonomen Supply Demand Management durch eine proaktive Einsatzplanung für steuerbare Verbraucher in einem selbst-organisierendem System vorgestellt. Der Ansatz stützt sich dabei auf die entwickelten Algorithmen und Techniken, die im Rahmen der selbst-organisierten, autonomen Einsatzplanung für *Autonome Virtuelle Kraftwerke* [108, 5] entwickelt wurden, überträgt diese auf die Verbraucher und verbindet diese beiden Ansätze.

Zwei zentrale Herausforderungen, die bei einem autonomen Betrieb elektrischer Energieversorgungssysteme entstehen, sind (1) *Skalierbarkeit* bei der Einsatzplanung und (2) *Unsicherheiten*, verursacht durch Ungenauigkeiten in den Vorhersagen der Systemteilnehmer. Um diese Herausforderungen zu meistern, werden in dieser Arbeit die Verbraucher selbst-organisiert in *Autonome Verbraucherorganisationen* gruppiert, in denen jeweils lokal eine autonome Einsatzplanung unter Betrachtung von Unsicherheiten durch den Einsatz des sozialen Konzepts der Vertrauenswürdigkeit für die darin enthaltenen steuerbaren Verbraucher durchgeführt wird.

Die selbst-organisierte Ausbildung Autonomer Verbraucherorganisationen ist wie die Ausbildung von Autonomen Virtuellen Kraftwerken eine Instanz des *Partitionierungsproblems* [12] und kann daher mit den beiden Algorithmen PSOPP [12], eine bio-inspirierte Metaheuristik zur Lösung des Partitionierungsproblems, und SPADA [5], ein dezentraler, agenten-basierter Algorithmus zur Lösung des Partitionierungsproblems, gelöst werden. Damit alle Autonomen Verbraucherorganisationen im System ähnliche Eigen-

## 9. Fazit und Ausblick

schaften haben, somit die Einsatzplanung ähnlich gut durchführen können und es keine Schwachstellen im System gibt, und dadurch für eine höhere Robustheit bezüglich des Erreichens des Systemziels sorgen, bilden Autonome Verbraucherorganisationen – wie Autonome Virtuelle Kraftwerke – eine *homogene Partitionierung* [12]. Dies hat zur Folge, dass flexible und unflexible Verbraucher wie auch vertrauenswürdige und nicht vertrauenswürdige Verbraucher gleichermaßen auf alle Autonomen Verbraucherorganisationen im System aufgeteilt werden. Dass Autonome Verbraucherorganisationen, die eine homogene Partitionierung bilden, dazu in der Lage sind, bessere Ergebnisse zu liefern als Autonome Verbraucherorganisationen, die Verbraucher gleichen Typs enthalten, hat die Evaluierung in Kapitel 8 gezeigt.

Die in Kapitel 5 vorgestellte autonome Einsatzplanung innerhalb einer Autonomen Verbraucherorganisation hat zum Ziel, dass die Residuallast – die Differenz zwischen Last und der Einspeisung nicht-steuerbarer Kraftwerke wie Photovoltaikanlagen – geglättet wird. Dies ermöglicht einen effizienteren Betrieb für steuerbare Kraftwerke und reduziert die Schwankungen der Residuallast, die für steuerbare Kraftwerke aufgrund ihrer Trägheit, wenn möglich, klein zu halten sind. Zusätzlich kann dies den teuren Zukauf von Regelleistung zum Ausgleich von Differenzen zwischen der erzeugten und nachgefragten Leistung reduzieren. Die Tauglichkeit des Ansatzes hat sich in der Evaluierung in Kapitel 8 gezeigt, wo eine Einsatzplanung in allen Fällen einer ungesteuerten Nachfrage überlegen war.

Da die Einsatzplanung jedoch auf Vorhersagen diverser Systemteilnehmer angewiesen ist, die zwangsläufig Ungenauigkeiten aufweisen, ist die Einsatzplanung mit Unsicherheiten konfrontiert. Ein Ansatz zur Quantifizierung und Antizipation solcher Unsicherheiten sind *Trust-basierte Szenarien* [16], mit denen sich zur Laufzeit auf Basis vergangener Erfahrungen Aussagen über mögliche Entwicklungen der Zukunft, d. h. mögliche zukünftige Prognosefehler, machen lassen. Durch die Integration von TBS in die Einsatzplanung für steuerbare Verbraucher ist es möglich, Unsicherheiten bei der Glättung der Residuallast zu quantifizieren und zu antizipieren und dadurch bessere Lösungen zu erhalten. Dies wurde in der Evaluierung des Ansatzes in Kapitel 8 gezeigt.

Ein Ansatz, der Autonome Verbraucherorganisationen mit Autonomen Virtuellen Kraftwerken für ein Supply Demand Management integriert, wurde in Kapitel 7 vorgestellt. Abgesehen von der Glättung der Residuallast konnten in der Evaluierung jedoch keine weiteren Vorteile für Autonome

Virtuelle Kraftwerke gezeigt werden.

## 9.2. OFFENE FRAGESTELLUNGEN UND AUSBLICK AUF ZUKÜNFTIGE ARBEITEN

Mit dem Abschluss dieser Arbeit gibt es noch weitere Anknüpfungspunkte für interessante zukünftige Arbeiten.

Wurden in dieser Arbeit in der Einsatzplanung nur Unsicherheiten betrachtet, die von dargebotsabhängigen Erzeugern oder nicht-steuerbaren Verbrauchern stammen, sollen in Zukunft auch solche Unsicherheiten in der Einsatzplanung berücksichtigt werden, die von steuerbaren Verbrauchern ausgehen. So können unter anderem die Vorhersagen über die Abfahrtszeiten von Elektrofahrzeugen fehlerhaft sein; eine Berücksichtigung vergangener Erfahrungen über falsch vorhergesagte Abfahrtszeitpunkte könnte in der Einsatzplanung beispielsweise in Form einer erwarteten Abfahrtszeit integriert werden.

Ein Ansatz zur Einsatzplanung, der das ermöglichen würde, ist der markt-basierte Mechanismus TruCAOS [6, 62]. TruCAOS ist ein markt-basiertes Verfahren, bei dem ein Auktionator die Marktteilnehmer auf ein über mehrere Zeitschritte gehendes Angebot bieten lässt. TruCAOS wird in der robusten Einsatzplanung von Autonomen Virtuellen Kraftwerken zur Deckung der Residuallast durch die steuerbaren Kraftwerke eingesetzt. Die Vorteile von TruCAOS gegenüber einem regio-zentralen Verfahren sind vor allem die geringeren Laufzeiten, verursacht durch die geringere Komplexität des Verfahrens. Außerdem wird die Privatheit der Steuerungsmodelle und Daten der Marktteilnehmer gewahrt, da diese aufgrund der Abgabe von Geboten, die keine Details zu dem Steuerungsmodell enthalten, nicht preisgegeben werden müssen. War TruCAOS bisher ausgelegt auf das Lösen von Ressourcenallokationsproblemen, d. h. die exakte Befriedigung einer Nachfrage durch die Bereitstellung von Ressourcen, kann er durch die Implementierung der entsprechenden Schnittstellen für das Optimierungsproblem, wie der Auswahl von Gewinner-Angeboten und den Terminierungskriterien, auch für die Glättung der Residuallast in Autonomen Verbraucherorganisationen eingesetzt werden.

Die Teilnahme von Verbrauchern bzw. Autonomen Verbraucherorganisationen an einem reaktiven Mechanismus innerhalb von Autonomen Virtuellen Kraftwerken [10] zur Kompensation von aufgetretener Abweichungen zwi-

## 9. Fazit und Ausblick

schen erzeugter und nachgefragter Leistung auf Basis der Fahrplanbäume wird ein weiterer interessanter Punkt sein.

Des Weiteren werden in zukünftigen Arbeiten die nutzer-definierten Constraints, die in dieser Arbeit als harte Constraints aufgefasst wurden, wie beispielsweise der gewünschte Ladestand des Elektrofahrzeugs zum Abfahrtszeitpunkt, der späteste gewünschte Endzeitpunkt eines programmgetriebenen Verbrauchers oder die festgelegten Temperaturgrenzen eines thermischen Verbrauchers, als weiche Constraints aufgefasst, die unter Umständen verletzt werden können. Der Nutzer kann zudem durch die Angabe von *Constraint Relationships* [95] Präferenzen über diese weichen Constraints ausdrücken und somit festlegen, welche weichen Constraints wichtiger sind als andere. Die Berücksichtigung von weichen Constraints gibt dem Optimierungsproblem mehr Spielraum und ermöglicht so unter Umständen, zum Beispiel große Ausschläge der Residuallast nach oben oder unten durch das Verletzen weicher Constraints abzuschwächen, wenn keine andere Möglichkeit besteht. Ein wichtiger Faktor dabei ist sicherlich, dass die weichen Constraints nicht zu häufig verletzt werden oder nicht derart verletzt werden, dass der Nutzer in seiner Nutzung des Verbrauchers eingeschränkt ist – denn das würde zu massiven Akzeptanzproblemen führen.

Ein offener Punkt ist die Beachtung der physikalischen Stromnetzinfrastruktur, von der in dieser Arbeit abstrahiert wurde, wie beispielsweise die Berücksichtigung der verschiedenen Spannungsebenen, in die das Stromnetz in einer hierarchischen Art und Weise eingeteilt ist, und von Leitungs- und Ortsnetzstationskapazitäten. So wird der Strom üblicherweise von den hohen Spannungsebenen, an der die großen Kraftwerke angeschlossen sind, nach unten zu den niedrigen Spannungsebenen verteilt; die umgekehrte Richtung, wie es beispielsweise bei einem Überschuss an Leistung aus Photovoltaikanlagen in Niederspannungsnetzen der Fall sein kann, ist unerwünscht. Wird die physikalische Infrastruktur daher ebenfalls beachtet, müssen die Steuerungsprozesse derartige Bedingungen berücksichtigen. Zudem hat die physikalische Infrastruktur auch einen Einfluss auf die Selbst-Organisations-Prozesse. So ist beispielsweise denkbar, dass die Selbst-Organisation von Erzeugern und Verbrauchern nur noch in einem Netzabschnitt und nicht darüber hinaus erlaubt ist, insbesondere wenn andere Netzbetreiber berücksichtigt werden.

Ein weiterer Punkt in zukünftigen Arbeiten wird die Weiterentwicklung

## *9.2. Offene Fragestellungen und Ausblick auf zukünftige Arbeiten*

der Steuerungsmodelle und der zugrundeliegenden Verhaltensmuster der Nutzer sein, so dass diese noch realitätsnäher werden und die Simulation noch näher die Realität abbilden kann. Gleichzeitig bedeutet dies auch, dass die Generierung der Steuerungsmodelle auf der Basis von realistischeren Daten erfolgen und mehr Abhängigkeiten zwischen einzelnen Parametern berücksichtigen muss. Dies gilt insbesondere dann, wenn wie zuvor erwähnt die Netzstruktur beachtet wird, so dass beispielsweise größere Verbraucher nicht an Niederspannungsnetzen angeschlossen sind. Auch die Spezifizierung möglicher weiterer nutzer-definierter oder technischer Constraints gehört zu diesem Punkt. So ist es beispielsweise denkbar, durch eine entsprechende Formulierung eines Constraints die Beanspruchung der Batterien von Elektrofahrzeugen zu reduzieren, um längere Batterielebenszeiten zu ermöglichen – denn aktuell ist es möglich, dass diese permanent beansprucht wird.



## LITERATUR

---

- [1] Agora Energiewende. *Die Energiewende im Stromsektor: Stand der Dinge 2015. Rückblick auf die wesentlichen Entwicklungen sowie Ausblick auf 2016*. Forschungsber. Agora Energiewende, Jan. 2016.
- [2] M. Agsten et al. „Abschlussbericht eTelligence“. In: *EWE AG, Oldenburg, Technical Report* (2012).
- [3] Mohammad Abdullah Al Faruque, Rudolf Krist und Jörg Henkel. „ADAM: Run-time Agent-based Distributed Application Mapping for on-chip Communication“. In: *Proceedings of the 45th ACM/IEEE Design Automation Conference*. Anaheim, California: ACM, 2008, S. 760–765. ISBN: 978-1-60558-115-6.
- [4] Shafiq Alam, Gillian Dobbie und Patricia Riddle. „An Evolutionary Particle Swarm Optimization Algorithm for Data Clustering“. In: *2008 IEEE Swarm Intelligence Symposium*. Sep. 2008, S. 1–6.
- [5] Gerrit Anders. „Self-Organized Robust Optimization in Open Technical Systems“. Dissertation. Universität Augsburg, 2016.
- [6] Gerrit Anders, Alexander Schiendorfer, Florian Siefert, Jan-Philipp Steghöfer und Wolfgang Reif. „Cooperative Resource Allocation in Open Systems of Systems“. In: *ACM Transactions on Autonomous and Adaptive Systems* 10.2 (Juni 2015), 11:1–11:44. ISSN: 1556-4665.
- [7] Gerrit Anders, Alexander Schiendorfer, Jan-Philipp Steghöfer und Wolfgang Reif. „Robust Scheduling in a Self-Organizing Hierarchy of Autonomous Virtual Power Plants“. In: *ARCS 2014; 2014 Workshop Proceedings on Architecture of Computing Systems*. Feb. 2014, S. 1–8.
- [8] Gerrit Anders, Hella Seebach, Florian Nafz, Jan-Philipp Steghöfer und Wolfgang Reif. „Decentralized Reconfiguration for Self-Organizing Resource-Flow Systems Based on Local Knowledge“. In: *2011 8th IEEE International Conference and Workshops on Engineering of Autonomic and Autonomous Systems*. Apr. 2011, S. 20–31.

- [9] Gerrit Anders, Hella Seebach, Jan-Philipp Steghöfer, Wolfgang Reif, Elisabeth André, Jörg Hähner, Christian Müller-Schloer und Theo Ungerer. „The Social Concept of Trust as Enabler for Robustness in Open Self-Organising Systems“. In: *Trustworthy Open Self-Organising Systems*. Hrsg. von Wolfgang Reif, Gerrit Anders, Hella Seebach, Jan-Philipp Steghöfer, Elisabeth André, Jörg Hähner, Christian Müller-Schloer und Theo Ungerer. Bd. 7. Autonomic Systems. Springer International Publishing, 2016, S. 1–16. ISBN: 978-3-319-29199-4.
- [10] Gerrit Anders, Florian Siefert, Michael Mair und Wolfgang Reif. „Proactive Guidance for Dynamic and Cooperative Resource Allocation under Uncertainties“. In: *2014 IEEE Eighth International Conference on Self-Adaptive and Self-Organizing Systems*. Sep. 2014, S. 21–30.
- [11] Gerrit Anders, Florian Siefert, Nizar Msadek, Rolf Kiefhaber, Oliver Kosak, Wolfgang Reif und Theo Ungerer. *TEMAS – A Trust-Enabling Multi-Agent System for Open Environments*. Techn. Ber. 2013-04. Universität Augsburg, Apr. 2013.
- [12] Gerrit Anders, Florian Siefert und Wolfgang Reif. „A Heuristic for Constrained Set Partitioning in the Light of Heterogeneous Objectives“. In: *Agents and Artificial Intelligence*. Hrsg. von Béatrice Duval, Jaap van den Herik, Stephane Loiseau und Joaquim Filipe. Bd. 9494. Lecture Notes in Computer Science. Springer International Publishing, 2015, S. 223–244. ISBN: 978-3-319-27946-6.
- [13] Gerrit Anders, Florian Siefert und Wolfgang Reif. „A Particle Swarm Optimizer for Solving the Set Partitioning Problem in the Presence of Partitioning Constraints“. In: *Proceedings of the International Conference on Agents and Artificial Intelligence - Volume 2: ICAART*. 2015, S. 151–163. ISBN: 978-989-758-074-1.
- [14] Gerrit Anders, Florian Siefert, Alexander Schiendorfer, Hella Seebach, Jan-Philipp Steghöfer, Benedikt Eberhardinger, Oliver Kosak und Wolfgang Reif. „Specification and Design of Trust-Based Open Self-Organising Systems“. In: *Trustworthy Open Self-Organising Systems*. Hrsg. von Wolfgang Reif, Gerrit Anders, Hella Seebach, Jan-Philipp Steghöfer, Elisabeth André, Jörg Hähner, Christian Müller-Schloer und Theo Ungerer. Bd. 7. Autonomic Systems. Springer International Publishing, 2016, S. 17–53. ISBN: 978-3-319-29199-4.

- [15] Gerrit Anders, Florian Siefert, Jan-Philipp Steghöfer und Wolfgang Reif. „A Decentralized Multi-agent Algorithm for the Set Partitioning Problem“. In: *PRIMA 2012: Principles and Practice of Multi-Agent Systems*. Hrsg. von Iyad Rahwan, Wayne Wobcke, Sandip Sen und Toshiharu Sugawara. Bd. 7455. Lecture Notes in Computer Science. Springer Berlin Heidelberg, 2012, S. 107–121. ISBN: 978-3-642-32728-5.
- [16] Gerrit Anders, Florian Siefert, Jan-Philipp Steghöfer und Wolfgang Reif. „Trust-Based Scenarios – Predicting Future Agent Behavior in Open Self-organizing Systems“. In: *Self-Organizing Systems*. Hrsg. von Wilfried Elmenreich, Falko Dressler und Vittorio Loreto. Bd. 8221. Lecture Notes in Computer Science. Springer Berlin Heidelberg, 2014, S. 90–102. ISBN: 978-3-642-54139-1.
- [17] Hans-Jürgen Appelrath, Henning Kagermann und Christoph Mayer. *Future Energy Grid. Migrationspfade ins Internet der Energie*. acatech STUDIE. Springer Berlin Heidelberg, 2012.
- [18] Krzysztof R. Apt und Andreas Witzel. „A Generic Approach to Coalition Formation“. In: *International Game Theory Review* 11.03 (2009), S. 347–367.
- [19] BDEW Bundesverband der Energie- und Wasserwirtschaft e.V. *Energie-Info: Stromverbrauch im Haushalt*. Juli 2016. URL: [https://www.bdew.de/internet.nsf/id/0D6DOC20786B2929C1257FE90030A849/\\$file/BDEW\\_Stromverbrauch%20im%20Haushalt\\_Stand\\_Juli%202016.pdf](https://www.bdew.de/internet.nsf/id/0D6DOC20786B2929C1257FE90030A849/$file/BDEW_Stromverbrauch%20im%20Haushalt_Stand_Juli%202016.pdf) (besucht am 01. 11. 2016).
- [20] Birger Becker, Florian Allending, Ulrich Reiner, Mattias Kahl, Urban Richter, Daniel Pathmaperuma, Hartmut Schmeck und Thomas Leibfried. „Decentralized Energy-Management to Control Smart-Home Architectures“. In: *Architecture of Computing Systems - ARCS 2010: 23rd International Conference, Hannover, Germany, February 22-25, 2010. Proceedings*. Hrsg. von Christian Müller-Schloer, Wolfgang Karl und Sami Yehia. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, S. 150–161. ISBN: 978-3-642-11950-7.
- [21] Sebastian Beer, H.-Jürgen Appelrath und Michael Sonnenschein. „Towards a Self-Organization Mechanism for Agent Associations in Electricity Spot Markets“. In: Okt. 2011.

## Literatur

- [22] I. Bel, A. Valenti, J. Maire, J. M. Corera und P. Lang. „Innovative Operation with Aggregated Distributed Generation“. In: *Proc. of the 19th International Conference on Electricity Distribution*. 2007.
- [23] C.M. Bender, D.C. Brody und B.K. Meister. „Quantum field theory of partitions“. In: *Journal of Mathematical Physics* 40 (1999), S. 3239.
- [24] Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Bd. 1. Information Science and Statistics. Springer-Verlag New York, Inc., 2006.
- [25] Alec Brooks, Ed Lu, Dan Reicher, Charles Spirakis und Bill Wehl. „Demand Dispatch“. In: *IEEE Power and Energy Magazine* 8.3 (Mai 2010), S. 20–29. ISSN: 1540-7977.
- [26] F. Buccafurri, D. Rosaci, G. Sarnè und D. Ursino. „An Agent-Based Hierarchical Clustering Approach for E-commerce Environments“. In: *E-Commerce and Web Technologies*. Hrsg. von Kurt Bauknecht, A Tjoa und Gerald Quirchmayr. Bd. 2455. Lecture Notes in Computer Science. Springer, 2002, S. 109–118. ISBN: 978-3-540-44137-3.
- [27] Bundesministerium für Umwelt, Naturschutz, Bau und Reaktorsicherheit (BMUB). *Klimabilanz Elektromobilität*. 2015. URL: [http://www.bmub.bund.de/fileadmin/Daten\\_BMU/Download\\_PDF/Verkehr/emob\\_klimabilanz\\_2015\\_bf.pdf](http://www.bmub.bund.de/fileadmin/Daten_BMU/Download_PDF/Verkehr/emob_klimabilanz_2015_bf.pdf) (besucht am 01. 11. 2016).
- [28] Bundesministerium für Verkehr, Bau und Stadtentwicklung. *Elektromobilität – Deutschland als Leitmarkt und Leitanbieter*. Juni 2011.
- [29] Bundesministerium für Wirtschaft und Energie (BMWi). *Erneuerbare Energien in Zahlen. Nationale und internationale Entwicklung im Jahr 2015*. Sep. 2016.
- [30] Bundesministerium für Wirtschaft und Energie (BMWi). *Smart Energy made in Germany. Erkenntnisse zum Aufbau und zur Nutzung intelligenter Energiesysteme im Rahmen der Energiewende*. Mai 2014.
- [31] Bundesministerium für Wirtschaft und Energie (BMWi). *Strom 2030. Langfristige Trends – Aufgaben für die kommenden Jahre. Impulspapier*. Sep. 2016.

- [32] Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen. 3. *Quartalsbericht 2015 zu Netz- und Systemsicherheitsmaßnahmen. Viertes Quartal 2015 sowie Gesamtjahresbetrachtung 2015*. 2. Aug. 2016. URL: [https://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/Allgemeines/Bundesnetzagentur/Publikationen/Berichte/2016/Quartalsbericht\\_Q4\\_2015.pdf?\\_\\_blob=publicationFile&v=1](https://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/Allgemeines/Bundesnetzagentur/Publikationen/Berichte/2016/Quartalsbericht_Q4_2015.pdf?__blob=publicationFile&v=1) (besucht am 01.11.2016).
- [33] Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen. *Bundesnetzagentur – Kraftwerksliste*. 18. Nov. 2016. URL: [https://www.bundesnetzagentur.de/cln\\_1412/DE/Sachgebiete/ElektrizitaetundGas/Unternehmen\\_Institutionen/Verorgungssicherheit/Erzeugungskapazitaeten/Kraftwerksliste/kraftwerksliste-node.html](https://www.bundesnetzagentur.de/cln_1412/DE/Sachgebiete/ElektrizitaetundGas/Unternehmen_Institutionen/Verorgungssicherheit/Erzeugungskapazitaeten/Kraftwerksliste/kraftwerksliste-node.html) (besucht am 01.12.2016).
- [34] Bundesregierung. *Klimaschutzplan 2050 – Klimaschutzpolitische Grundsätze und Ziele der Bundesregierung*. 14. Nov. 2016. URL: [http://www.bmub.bund.de/fileadmin/Daten\\_BMU/Download\\_PDF/Klimaschutz/klimaschutzplan\\_2050\\_bf.pdf](http://www.bmub.bund.de/fileadmin/Daten_BMU/Download_PDF/Klimaschutz/klimaschutzplan_2050_bf.pdf) (besucht am 13.03.2017).
- [35] P.C. Chu und J.E. Beasley. „Constraint Handling in Genetic Algorithms: The Set Partitioning Problem“. English. In: *Journal of Heuristics* 4.4 (1998), S. 323–357. ISSN: 1381-1231.
- [36] United Nations Framework Convention on Climate Change. *Adoption of the Paris Agreement*. FCCC/CP/2015/L.9/Rev.1. 12. Dez. 2015.
- [37] Deutsche Energie-Agentur GmbH (dena). *dena-Netzstudie II. Integration erneuerbarer Energien in die deutsche Stromversorgung im Zeitraum 2015 – 2020 mit Ausblick 2025*. Techn. Ber. Deutsche Energie-Agentur GmbH (dena), Nov. 2010.
- [38] Giovanna Di Marzo Serugendo, Marie-Pierre Gleizes und Anthony Karageorgos. „Self-organization in Multi-agent Systems“. In: *The Knowledge Engineering Review* 20.2 (Juni 2005), S. 165–189. ISSN: 0269-8889.
- [39] EnerNOC, Inc. *Grüne Dividende durch intelligente Steuerung des Energiebedarfs*. 2016. URL: [http://www.enernoc.de/themes/bluemasters/images/case\\_studies/pdfs/P14318\\_cs-paulaner-de.pdf](http://www.enernoc.de/themes/bluemasters/images/case_studies/pdfs/P14318_cs-paulaner-de.pdf) (besucht am 01.09.2016).

## Literatur

- [40] ENTSO-E. *Continental Europe Operation Handbook – Policy 1: Load-Frequency Control and Performance*. 2009.
- [41] ENTSO-E. *Continental Europe Operation Handbook – Policy 5: Emergency Operations*. 2015.
- [42] Christoph M. Flath, Jens P. Ilg, Sebastian Gottwalt, Hartmut Schmeck und Christof Weinhardt. „Improving Electric Vehicle Charging Coordination Through Area Pricing“. In: *Transportation Science* 48.4 (2014), S. 619–634.
- [43] Fraunhofer-Institute for Wind Energy and Energy System Technology (IWES). *The European Power System in 2030: Flexibility Challenges and Integration Benefits. An Analysis with a Focus on the Pentilateral Energy Forum Region*. Forschungsber. im Auftrag von Agora Energiewende, Juni 2015.
- [44] F. Javier Martínez Garcia und José A. Moreno Perez. *Jumping Frogs Optimization: a new swarm method for discrete optimization*. Techn. Ber. 3. Department of Statistics, O.R. und Computing, University of La Laguna, Tenerife, Spain: Documentos de Trabajo del DEIOC, 2008.
- [45] Philipp Goergens, Fabian Potratz, Moritz Cramer, Armin Schnettler und Stefan Willing. „Review of the Smart Operator in the Field“. In: *CIREN Workshop 2016, CIREN 2016, 14.06.2016-15.06.2016, Helsinki, Finland*. 14. Juni 2016.
- [46] Donald J. Hammerstrom, Jerry Brous, David P. Chassin, Gale R. Horst, Robert Kajfasz, Preston Michie, Terry V. Oliver, Teresa A. Carlon, Conrad Eustis, Olof M. Jarvegren, W. Marek, R.L. Munson und R.G. Pratt. *Pacific Northwest GridWise™ Testbed Demonstration Projects; Part II. Grid Friendly™ Appliance Project*. Techn. Ber. Pacific Northwest National Laboratory (PNNL), Richland, WA (US), 2007.
- [47] Christian Hinrichs. „Selbstorganisierte Einsatzplanung dezentraler Akteure im Smart Grid“. Diss. Carl von Ossietzky Universität Oldenburg, 2014.
- [48] Christian Hinrichs, Sebastian Lehnhoff und Michael Sonnenschein. „COHDA: A Combinatorial Optimization Heuristic for Distributed Agents“. In: *International Conference on Agents and Artificial Intelligence*. Springer. 2013, S. 23–39.

- [49] Christian Hirsch, Lutz Hillemacher, Carsten Block, Alexander Schuller und Dominik Möst. „Simulations in the Smart Grid Field Study MeRegio. Simulationen im MeRegio Smart Grid Feldtest“. In: *it-Information Technology Methoden und innovative Anwendungen der Informatik und Informationstechnik* 52.2 (2010), S. 100–106.
- [50] Bryan Horling und Victor Lesser. „A Survey of Multi-agent Organizational Paradigms“. In: *The Knowledge Engineering Review* 19.4 (Dez. 2004), S. 281–316. ISSN: 0269-8889.
- [51] Marija Ilic, Jason W. Black und Jill L. Watz. „Potential Benefits of Implementing Load Control“. In: *2002 IEEE Power Engineering Society Winter Meeting. Conference Proceedings*. Bd. 1. 2002, S. 177–182.
- [52] Tsunenori Ishioka. „An expansion of X-means for automatically determining the optimal number of clusters“. In: *Proceedings of the International Conference on Computational Intelligence*. 2005, S. 91–96.
- [53] Catholijn M. Jonker und Jan Treur. „Formal Analysis of Models for the Dynamics of Trust Based on Experiences“. In: *Multi-Agent System Engineering*. Hrsg. von Francisco J. Garijo und Magnus Boman. Bd. 1647. Lecture Notes in Computer Science. Springer Berlin / Heidelberg, 1999, S. 221–231. ISBN: 978-3-540-66281-5.
- [54] Andreas Kamper und Hartmut Schmeck. „Adaptives verteiltes Lastmanagement in Bilanzkreisen“. In: *Informatik-Spektrum* 35 (2 2012), S. 102–111. ISSN: 0170-6012.
- [55] James Kennedy und Russell Eberhart. „Particle Swarm Optimization“. In: *Neural Networks, 1995. Proceedings., IEEE International Conference on*. Bd. 4. Nov. 1995, S. 1942–1948.
- [56] James Kennedy und Russell C. Eberhart. „A Discrete Binary Version of the Particle Swarm Algorithm“. In: *1997 IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation*. Bd. 5. Okt. 1997, S. 4104–4108.
- [57] Rolf Kiefhaber, Gerrit Anders, Florian Siefert, Theo Ungerer und Wolfgang Reif. „Confidence as a Means to Assess the Accuracy of Trust Values“. In: *2012 IEEE 11th International Conference on Trust, Security and Privacy in Computing and Communications*. Juni 2012, S. 690–697.

- [58] Rolf Kiefhaber, Ralf Jahr, Nizar Msadek und Theo Ungerer. „Ranking of Direct Trust, Confidence, and Reputation in an Abstract System with Unreliable Components“. In: *2013 IEEE 10th International Conference on Ubiquitous Intelligence and Computing and 2013 IEEE 10th International Conference on Autonomic and Trusted Computing*. Dez. 2013, S. 388–395.
- [59] Marian Klobasa. „Dynamische Simulation eines Lastmanagements und Integration von Windenergie in ein Elektrizitätsnetz auf Landesebene unter regelungstechnischen und Kostengesichtspunkten“. Dissertation. ETH Zürich, 2007.
- [60] Marian Klobasa, Thomas Erge und Bernhard Wille-Hausmann. *Integration von Windenergie in ein zukünftiges Energiesystem unterstützt durch Lastmanagement. Endbericht*. Techn. Ber. Fraunhofer-Institut für System- und Innovationsforschung (ISI) und Fraunhofer-Institut für Solare Energiesysteme (ISE), Juli 2009.
- [61] Koen Kok, Cor Warmer und René Kamphuis. „PowerMatcher: Multiagent Control in the Electricity Infrastructure“. In: *Proceedings of the 4th International Joint Conference on Autonomous Agents and Multiagent Systems*. AAMAS '05. The Netherlands: ACM, 2005, S. 75–82. ISBN: 1-59593-093-0.
- [62] Oliver Kosak, Gerrit Anders, Florian Siefert und Wolfgang Reif. „An Approach to Robust Resource Allocation in Large-Scale Systems of Systems“. In: *2015 IEEE 9th International Conference on Self-Adaptive and Self-Organizing Systems*. Sep. 2015, S. 1–10.
- [63] Kraftfahrt-Bundesamt. *Kraftfahrt-Bundesamt – Umwelt – Bestand an Pkw in den Jahren 2007 bis 2016 nach ausgewählten Kraftstoffarten*. URL: [http://www.kba.de/DE/Statistik/Fahrzeuge/Bestand/Umwelt/b\\_umwelt\\_z.html](http://www.kba.de/DE/Statistik/Fahrzeuge/Bestand/Umwelt/b_umwelt_z.html) (besucht am 26. 03. 2017).
- [64] Julian Krengel, Marcel Scheibmayer und Matthias Deindl. „Identification scheme and name service in the Internet of Energy“. In: *Innovative Smart Grid Technologies (ISGT), 2013 IEEE PES*. IEEE. 2013, S. 1–6.

- [65] Yasuo Kudo und Tetsuya Murai. „On a Criterion of Similarity between Partitions Based on Rough Set Theory“. In: *Rough Sets, Fuzzy Sets, Data Mining and Granular Computing: 12th International Conference, RSFDGrC 2009, Delhi, India, December 15-18, 2009. Proceedings*. Hrsg. von Hiroshi Sakai, Mihir Kumar Chakraborty, Aboul Ella Hassanien, Dominik Ślęzak und William Zhu. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, S. 101–108. ISBN: 978-3-642-10646-0.
- [66] Robin Lamarche-Perrin, Yves Demazeau und Jean-Marc Vincent. „A Generic Algorithmic Framework to Solve Special Versions of the Set Partitioning Problem“. In: *2014 IEEE 26th International Conference on Tools with Artificial Intelligence (ICTAI)*. Nov. 2014, S. 891–897.
- [67] Jiaming Li, Geoffrey Poulton und Geoffrey James. „Coordination of Distributed Energy Resource Agents“. In: *Applied Artificial Intelligence* 24.5 (2010), S. 351–380.
- [68] P. Lombardi, M. Powalko und K. Rudion. „Optimal operation of a virtual power plant“. In: *Power Energy Society General Meeting (PES '09)*. IEEE, 2009, S. 1–6.
- [69] Ontje Lünsdorf. „Selbstorganisation virtueller Geräte für das Lastmanagement von Kleinverbrauchern“. Diss. Carl von Ossietzky Universität Oldenburg, 20. März 2012.
- [70] Michael Sonnenschein Lutz Hoffmann, Hrsg. *Smart Nord Final Report*. Smart Nord Final Report. Uni Hannover, Apr. 2015. Kap. Overview on Sub-Project Two: Grid Stabilizing Ancillary Services, S. 95–96.
- [71] J. MacQueen. „Some methods for classification and analysis of multivariate observations“. In: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics*. Berkeley, Calif.: University of California Press, 1967, S. 281–297.
- [72] Stephen Paul Marsh. „Formalising Trust as a Computational Concept“. Diss. University of Stirling, 1994.
- [73] D. Harrison McKnight, Larry L. Cummings und Norman L. Chervany. „Initial Trust Formation in New Organizational Relationships“. In: *The Academy of Management Review* 23.3 (1998), S. 473–490. ISSN: 03637425.

- [74] D. W. van der Merwe und A. P. Engelbrecht. „Data Clustering using Particle Swarm Optimization“. In: *Evolutionary Computation, 2003. CEC '03. The 2003 Congress on*. Bd. 1. Dez. 2003, S. 215–220.
- [75] Lik Mui, Mojdeh Mohtashemi und Ari Halberstadt. „A Computational Model of Trust and Reputation“. In: *Proceedings of the 35th Annual Hawaii International Conference on System Sciences*. Jan. 2002, S. 2431–2439.
- [76] Florian Nafz, Hella Seebach, Jan-Philipp Steghöfer, Gerrit Anders und Wolfgang Reif. „Constraining Self-organisation Through Corridors of Correct Behaviour: The Restore Invariant Approach“. In: *Organic Computing – A Paradigm Shift for Complex Systems*. Hrsg. von Christian Müller-Schloer, Hartmut Schmeck und Theo Ungerer. Bd. 1. Autonomic Systems. Springer, 2011, S. 79–93. ISBN: 978-3-0348-0129-4.
- [77] Nationale Plattform Elektromobilität (NPE). *Zweiter Bericht der Nationalen Plattform Elektromobilität*. Mai 2011. URL: [http://nationale-plattform-elektromobilitaet.de/fileadmin/user\\_upload/Redaktion/zweiter\\_bericht\\_nationale\\_plattform\\_elektromobilitaet.pdf](http://nationale-plattform-elektromobilitaet.de/fileadmin/user_upload/Redaktion/zweiter_bericht_nationale_plattform_elektromobilitaet.pdf) (besucht am 01. 11. 2016).
- [78] Next Kraftwerke GmbH. *Abschaltverordnung – was ist das?* URL: <http://www.next-kraftwerke.de/wissen/regelenergie/abschaltverordnung> (besucht am 01. 11. 2016).
- [79] Next Kraftwerke GmbH. *Virtuelles Kraftwerk Next Pool*. URL: <https://www.next-kraftwerke.de/virtuelles-kraftwerk> (besucht am 01. 11. 2016).
- [80] NOAA National Centers for Environmental Information. *State of the Climate: Global Analysis for Annual 2016*. 2017. URL: <https://www.ncdc.noaa.gov/sotc/global/201613> (besucht am 26. 03. 2017).
- [81] Elth Ogston, Benno Overeinder, Maarten Van Steen und Frances Brazier. „A Method for Decentralized Clustering in Large Multi-Agent Systems“. In: *Proceedings of the 2nd International Joint Conference on Autonomous Agents and Multiagent Systems*. 2003, S. 789–796.
- [82] Elth Ogston, Astrid Zeman, Mikhail Prokopenko und Geoff James. „Clustering Distributed Energy Resources for Large-Scale Demand Management“. In: *First International Conference on Self-Adaptive and Self-Organizing Systems (SASO 2007)*. Juli 2007, S. 97–108.

- [83] Frauke Oldewurtel, Theodor Borsche, Matthias Bucher, Philipp Fortenbacher, Marina González Vayá, Tobias Haring, Johanna L. Mathieu, Olivier Mégel, Evangelos Vrettos und Göran Andersson. „A Framework for and Assessment of Demand Response and Energy Storage in Power Systems“. In: *2013 IREP Symposium Bulk Power System Dynamics and Control - IX Optimization, Security and Control of the Emerging Power Grid*. Aug. 2013, S. 1–24.
- [84] Open Energi. *Our Technology – Open Energi*. URL: <http://www.openergi.com/our-technology/> (besucht am 01. 12. 2016).
- [85] Sarvapali D. Ramchurn, Dong Huynh und Nicholas R. Jennings. „Trust in multi-agent systems“. In: *The Knowledge Engineering Review* 19.01 (2004), S. 1–25.
- [86] Sarvapali D. Ramchurn, Nicholas R. Jennings, Carles Sierra und Lluís Godo. „Devising a Trust Model for Multi-Agent Interactions Using Confidence and Reputation“. In: *Applied Artificial Intelligence* 18.9-10 (2004), S. 833–852. ISSN: 0883-9514.
- [87] Sarvapali D. Ramchurn, Perukrishnen Vytelingum, Alex Rogers und Nicholas R. Jennings. „Agent-based Homeostatic Control for Green Energy in the Smart Grid“. In: *ACM Transactions on Intelligent Systems Technology* 2.4 (Juli 2011), 35:1–35:28. ISSN: 2157-6904.
- [88] Sarvapali D. Ramchurn, Perukrishnen Vytelingum, Alex Rogers und Nicholas R. Jennings. „Putting the “Smarts” into the Smart Grid: A Grand Challenge for Artificial Intelligence“. In: *Communications of the ACM* 55.4 (2012), S. 86–97.
- [89] Sarvapali D. Ramchurn, Perukrishnen Vytelingum, Alex Rogers und Nick Jennings. „Agent-based Control for Decentralised Demand Side Management in the Smart Grid“. In: *The 10th International Conference on Autonomous Agents and Multiagent Systems - Volume 1. AAMAS '11*. Taipei, Taiwan: International Foundation for Autonomous Agents und Multiagent Systems, 2011, S. 5–12. ISBN: 0-9826571-5-3, 978-0-9826571-5-7.
- [90] Urban Richter, Moez Mnif, Jürgen Branke, Christian Müller-Schloer und Hartmut Schmeck. „Towards a generic observer/controller architecture for Organic Computing“. In: *36. Jahrestagung der GI*. Bd. 93. LNI. GI, 2006, S. 112–119. ISBN: 978-3-88579-187-4.

## Literatur

- [91] Joeri Rogelj, Michel den Elzen, Niklas Höhne, Taryn Fransen, Hanna Fekete, Harald Winkler, Roberto Schaeffer, Fu Sha, Keywan Riahi und Malte Meinshausen. „Paris Agreement climate proposals need a boost to keep warming well below 2 °C“. In: *Nature* 534.7609 (Juni 2016), S. 631–639.
- [92] N. Ruiz, I. Cobelo und J. Oyarzabal. „A Direct Load Control Model for Virtual Power Plant Management“. In: *IEEE Transactions on Power Systems* 24.2 (Mai 2009), S. 959–966. ISSN: 0885-8950.
- [93] Jordi Sabater und Carles Sierra. „Social ReGreT, a Reputation Model Based on Social Relations“. In: *SIGecom Exchanges* 3.1 (Dez. 2001), S. 44–56. ISSN: 1551-9031.
- [94] Alexander Schiendorfer, Gerrit Anders, Jan-Philipp Steghöfer und Wolfgang Reif. „Abstraction of Heterogeneous Supplier Models in Hierarchical Resource Allocation“. In: *Transactions on Computational Collective Intelligence XX*. Lecture Notes in Computer Science 9420 (2015). Hrsg. von Ngoc Thanh Nguyen, Ryszard Kowalczyk, Béatrice Duval, Jaap van den Herik, Stephane Loiseau und Joaquim Filipe, S. 23–53.
- [95] Alexander Schiendorfer, Jan-Philipp Steghöfer, Alexander Knapp, Florian Nafz und Wolfgang Reif. „Constraint Relationships for Soft Constraints“. English. In: *Research and Development in Intelligent Systems XXX*. Hrsg. von Max Bramer und Miltos Petridis. Springer International Publishing, 2013, S. 241–255. ISBN: 978-3-319-02620-6.
- [96] Alexander Schiendorfer, Jan-Philipp Steghöfer und Wolfgang Reif. „Synthesis and Abstraction of Constraint Models for Hierarchical Resource Allocation Problems“. In: *Proceedings of the 6th International Conference on Agents and Artificial Intelligence - Volume 2: ICAART*. SciTePress, März 2014, S. 15–27. ISBN: 978-989-758-016-1.
- [97] Martin Schmied, Philipp Wüthrich, Rainer Zah, Hans-Jörg Althaus und Christa Friedl. *Postfossile Energieversorgungsoptionen für einen treibhausgasneutralen Verkehr im Jahr 2050: Eine verkehrsträgerübergreifende Bewertung. Im Auftrag des Umweltbundesamtes*. Apr. 2014.
- [98] C. Schulz, G. Roder und M. Kurrat. „Virtual power plants with combined heat and power micro-units“. In: *2005 International Conference on Future Power Systems*. Nov. 2005.

- [99] F.C. Schweppe, B. Daryanian und R.D. Tabors. „Algorithms for a spot price responding residential load controller“. In: *IEEE Transactions on Power Systems* 4.2 (Mai 1989), S. 507–516.
- [100] Alexander Shapiro, Darinka Dentcheva und Andrzej Ruszczyński. *Lectures on Stochastic Programming: Modeling and Theory*. Bd. 16. MOS-SIAM Series on Optimization. Society for Industrial und Applied Mathematics (SIAM), 2014.
- [101] Onn Shehory und Sarit Kraus. „Methods for Task Allocation via Agent Coalition Formation“. In: *Artificial Intelligence* 101.1-2 (1998), S. 165–200.
- [102] Joe A. Short, David G. Infield und Leon L. Freris. „Stabilization of Grid Frequency Through Dynamic Demand Control“. In: *IEEE Transactions on Power Systems* 22.3 (Aug. 2007), S. 1284–1293. ISSN: 0885-8950.
- [103] Pierluigi Siano. „Demand response and smart grids—A survey“. In: *Renewable and Sustainable Energy Reviews* 30 (Feb. 2014), S. 461–478.
- [104] sonnen GmbH. *sonnenCommunity | sonnen*. URL: <https://www.sonnenbatterie.de/de/sonnenCommunity> (besucht am 01. 10. 2016).
- [105] Stadtwerke München GmbH. *Virtuelles Kraftwerk: M/Partnerkraft*. URL: <https://www.swm.de/geschaeftskunden/dienstleistungen/virtuelles-kraftwerk> (besucht am 01. 12. 2016).
- [106] Rainer Stamminger. *Synergy Potential of Smart Domestic Appliances in Renewable Energy Systems*. Shaker Verlag, 11. Apr. 2009. 256 S. ISBN: 3832280820.
- [107] Jan-Philipp Steghöfer. „Large-Scale Open Self-Organising Systems: Managing Complexity with Hierarchies, Monitoring, Adaptation, and Principled Design“. Diss. Universität Augsburg, 2014.
- [108] Jan-Philipp Steghöfer, Gerrit Anders, Florian Siefert und Wolfgang Reif. „A System of Systems Approach to the Evolutionary Transformation of Power Management Systems“. In: *Proceedings of INFORMATIK 2013 – Workshop on “Smart Grids”*. Bd. P-220. Lecture Notes in Informatics. Bonner Köllen Verlag, 2013.

## Literatur

- [109] Jan-Philipp Steghöfer, Pascal Behrmann, Gerrit Anders, Florian Siefert und Wolfgang Reif. „HiSPADA: Self-Organising Hierarchies for Large-Scale Multi-Agent Systems“. In: *Proceedings of the Ninth International Conference on Autonomic and Autonomous Systems (ICAS)*. IARIA, 2013, S. 71–76. ISBN: 978-1-61208-257-8.
- [110] Jan-Philipp Steghöfer, Rolf Kiefhaber, Karin Leichtenstern, Yvonne Bernard, Lukas Klejnowski, Wolfgang Reif, Theo Ungerer, Elisabeth André, Jörg Hähner und Christian Müller-Schloer. „Trustworthy Organic Computing Systems: Challenges and Perspectives“. In: *Autonomic and Trusted Computing: 7th International Conference, ATC 2010, Xi'an, China, October 26-29, 2010. Proceedings*. Hrsg. von Bing Xie, Juergen Branke, S. Masoud Sadjadi, Daqing Zhang und Xingshe Zhou. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, S. 62–76. ISBN: 978-3-642-16576-4.
- [111] Martin Tröschel. „Aktive Einsatzplanung in holonischen Virtuellen Kraftwerken“. Diss. Carl von Ossietzky Universität Oldenburg, 2010.
- [112] Edward P. K. Tsang. *Foundations of Constraint Satisfaction*. Computation in Cognitive Science. Academic Press, 1993. ISBN: 978-0-12-701610-8.
- [113] United States Department of Energy. „Grid 2030“: A National Vision for Electricity's Second 100 Years. Techn. Ber. United States Department of Energy, Juli 2003.
- [114] Ventzeslav Valev. „Set Partition Principles Revisited“. In: *Advances in Pattern Recognition*. Hrsg. von Adnan Amin, Dov Dori, Pavel Pudil und Herbert Freeman. Bd. 1451. Lecture Notes in Computer Science. Springer Berlin Heidelberg, 1998, S. 875–881. ISBN: 978-3-540-64858-1.
- [115] Timothy Van Zandt. „Hierarchical Computation of the Resource Allocation Problem“. In: *European Economic Review* 39.3-4 (Apr. 1995), S. 700–708.
- [116] Jan Vornberger, Martin Tröschel, Astrid Nieße und H.-Jürgen Apperath. „Optimized Charging Management for Electric Vehicles“. In: *Proceedings of IRENEC 2011*. Okt. 2011.

- [117] Perukrishnen Vytelingum, Thomas D. Voice, Sarvapali D. Ramchurn, Alex Rogers und Nicholas R. Jennings. „Agent-based Micro-storage Management for the Smart Grid“. In: *Proceedings of the 9th International Conference on Autonomous Agents and Multiagent Systems: Volume 1 - Volume 1*. AAMAS '10. Toronto, Canada: International Foundation for Autonomous Agents und Multiagent Systems, 2010, S. 39–46. ISBN: 978-0-9826571-1-9.
- [118] Horst F. Wedde. „DEZENT – A Cyber-Physical Approach for Providing Affordable Regenerative Electric Energy in the Near Future“. In: *38th EUROMICRO Conference on Software Engineering and Advanced Applications (SEAA'12)*. 2012, S. 241–249.
- [119] S. Willing, T. Smolka, A. Stolte, J. Nilges, C. Matrose, S. Nykamp und A. Schnettler. „Improving quality of supply and usage of assets in distribution grids by introducing a ‚Smart Operator‘“. In: *22nd International Conference and Exhibition on Electricity Distribution (CIRED 2013)*. Juni 2013, S. 1–4.
- [120] Michael Wooldridge. „Intelligent Agents“. In: *Multiagent Systems*. Hrsg. von Gerhard Weiss. MIT Press, 2013. Kap. 1.
- [121] WVI Prof. Dr. Wermuth Verkehrsforschung und Infrastrukturplanung GmbH. *Erhebung zum motorisierten Wirtschaftsverkehr in Deutschland 2009/2010. Kraftfahrzeugverkehr in Deutschland 2010 (KiD 2010)*. Forschungsber. im Auftrag des Bundesministeriums für Verkehr, Bau und Stadtentwicklung (BMVBS), 24. Apr. 2012.
- [122] Ossama Younis und Sonia Fahmy. „HEED: A Hybrid, Energy-Efficient, Distributed Clustering Approach for Ad Hoc Sensor Networks“. In: *IEEE Transactions on Mobile Computing* 3 (2004), S. 366–379. ISSN: 1536-1233.
- [123] B. Zhang, P.B. Luh, E. Litvinov, T. Zheng, F. Zhao, J. Zhao und C. Wang. „Electricity Auctions with Intermittent Wind Generation“. In: *Power and Energy Society General Meeting*. IEEE. 2011, S. 1–8.