



Dr.-Ing. Christian Hirsch

Fahrplanbasiertes Energiemanagement in Smart Grids



Scientific
Publishing

Dr.-Ing. Christian Hirsch

Fahrplanbasiertes Energiemanagement in Smart Grids

Fahrplanbasiertes Energiemanagement in Smart Grids

von
Dr.-Ing. Christian Hirsch

Dissertation, Karlsruher Institut für Technologie (KIT)
Fakultät für Wirtschaftswissenschaften

Tag der mündlichen Prüfung: 17. Dezember 2015
Referenten: Prof. Dr. Hartmut Schmeck
Prof. Dr.-Ing. Thomas Leibfried

Impressum



Karlsruher Institut für Technologie (KIT)
KIT Scientific Publishing
Straße am Forum 2
D-76131 Karlsruhe

KIT Scientific Publishing is a registered trademark of Karlsruhe
Institute of Technology. Reprint using the book cover is not allowed.

www.ksp.kit.edu



*This document – excluding the cover, pictures and graphs – is licensed
under the Creative Commons Attribution-Share Alike 3.0 DE License
(CC BY-SA 3.0 DE): <http://creativecommons.org/licenses/by-sa/3.0/de/>*



*The cover page is licensed under the Creative Commons
Attribution-No Derivatives 3.0 DE License (CC BY-ND 3.0 DE):
<http://creativecommons.org/licenses/by-nd/3.0/de/>*

Print on Demand 2017 – Gedruckt auf FSC-zertifiziertem Papier

ISBN 978-3-7315-0551-8
DOI 10.5445/KSP/1000056497

Kurzfassung

Bedingt durch die Energiewende wird vermehrt Strom aus erneuerbaren Quellen erzeugt. Der Trend hin zu dezentraler, volatiler Erzeugung führt jedoch schon heute zu Engpässen in Stromnetzen. Eine Lösung dieser Probleme verspricht die informationstechnische Vernetzung und Koordination von Stromverbrauchern, Stromerzeugern und Speichern in Smart Grids.

Neue Energiemanagement-Ansätze und die steigende Zahl heterogener Subsysteme erfordern geeignete Systemarchitekturen sowie intelligente Koordinationsmethoden. In dieser Arbeit wird eine generische hierarchische Architektur für Energiemanagement-Systeme eingeführt. Diese basiert auf der Observer/Controller-Architektur des Organic Computing und integriert diverse zeitliche, räumliche und strukturelle Ebenen der Koordination. Dabei können sowohl physikalische als auch virtuelle Entitäten flexibel eingebunden werden.

Den Kern der Arbeit bildet die Instanziierung dieser Architektur für ein fahrplanbasiertes Last- und Erzeugungsmanagement. Dabei wird eine Leistungsführung realisiert, welche vorgegebene Leistungsprofile durch die Aggregation einer Menge von intelligenten Verbrauchern und Erzeugern approximiert. Diese Entitäten handeln autonom und stellen definierte Flexibilitätensprofile bezüglich ihrer Leistungsprofile zur Verfügung. Die betrachteten Flexibilitätensprofile umfassen die Anpassung der Einspeisung und die zeitliche Verschiebung des Energieverbrauchs.

Um die Flexibilitätensprofile zu nutzen, werden gemischt-ganzzahlige Optimierungsprobleme formuliert. Diese beziehen neben der Approximationsgüte auch die Kosten für das Verwenden der Freiheitsgrade ein. Es werden sowohl skalare als auch multikriterielle Problemformulierungen untersucht. Zur Lösung werden genetische Algorithmen eingesetzt, mit besonderem Augenmerk auf gegenläufige Optimierungsziele. Die Optimierungsprobleme und Algorithmen sind unabhängig von konkreten Entitäten, sodass Einsatzmöglichkeiten in vielfältigen Energiemanagement-Szenarien existieren.

Der entwickelte Energiemanagement-Ansatz betrachtet Entitäten in dem physikalischen Kontext von Stromnetzen. Um Überlastungen zu vermeiden, werden Netzrestriktionen bei der Optimierung berücksichtigt. Zu diesem Zweck werden für einen zeitdiskreten Optimierungshorizont Leistungsflüsse berechnet, die auf Fahrplanprognosen von Entitäten beruhen. Neben intelligenten Verbrauchern werden auch konventionelle Verbraucher in Form von Haushalten einbezogen, die selbst keine Lastprognosen erstellen können. Daher werden diverse Prädiktionsverfahren gegenübergestellt und zur Lastprognose von einzelnen Haushalten auf Basis der Messdaten intelligenter Stromzähler angewandt.

Das Gesamtsystem wird mittels Simulationsstudien untersucht. Hierzu werden Szenarien definiert, welche verschiedene Aspekte des Last- und des Erzeugungsmanagements beleuchten. Evaluationen belegen die Einsatzfähigkeit des vorgestellten Energiemanagement-Ansatzes für eine Leistungsführung unter Berücksichtigung von Netzrestriktionen.

Danksagung

Die vorliegende Arbeit entstand während meiner mehrjährigen Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Angewandte Informatik und Formale Beschreibungsverfahren (AIFB) des Karlsruher Instituts für Technologie (KIT). Im Folgenden möchte ich meinen Dank all denjenigen aussprechen, die mich im Laufe dieser Zeit unterstützt haben.

Meinem Doktorvater Prof. Dr. Hartmut Schmeck gebührt mein großer Dank für das entgegengebrachte Vertrauen und die wissenschaftliche Freiheit, die er mir gewährt hat. Von seiner Erfahrung und seinen konstruktiven Hinweisen habe ich in vielfältiger Weise profitiert. Weiterer Dank gebührt Herrn Prof. Dr.-Ing. Thomas Leibfried für die bereitwillige Übernahme des Korreferats.

Bei meinen Kollegen der Forschungsgruppe „Effiziente Algorithmen“ bedanke ich mich für das produktive und angenehme Arbeitsklima sowie den fachlichen und überfachlichen Austausch. Besonderer Dank richtet sich an Herrn PD Dr. Pradyumn Kumar Shukla für die gemeinsame Forschung auf dem Gebiet der evolutionären Optimierung, welche das Thema meiner Dissertation geprägt hat. Ferner bedanke ich mich bei allen internen und externen Projektpartnern für die Zusammenarbeit.

Aus tiefstem Herzen danke ich meinen Freunden und meiner Familie, auf deren bedingungslose Unterstützung ich vertrauen kann. Stefanie, vielen Dank für Deine Liebe und Dein Verständnis. Du bist ein starker Rückhalt für mich.

Karlsruhe, Juni 2016

Christian Hirsch

Inhaltsverzeichnis

Notation	ix
1 Einleitung	1
1.1 Motivation: Von klassischen Stromnetzen zu Smart Grids . . .	2
1.1.1 Klassische Stromnetze	3
1.1.2 Smart Grids	5
1.2 Problemstellung: Flexible Leistungsführung	7
1.3 Lösungsansatz: Fahrplanbasiertes Energiemanagement . . .	9
1.4 Gliederung der Arbeit	12
2 Energiemanagement	13
2.1 Architekturen	13
2.1.1 Anforderungen	14
2.1.2 Multiagentensysteme	15
2.1.3 Observer/Controller-Architektur	17
2.2 Lastmanagement	22
2.2.1 Begriffsdefinition	23
2.2.2 Ansätze	27
2.3 Erzeugungsmanagement	34
3 Rahmenszenario	37
3.1 Annahmen	38
3.1.1 Entitäten	38
3.1.2 Energiemanager	41
3.2 Konkretisierung der Entitäten	44
3.2.1 Haushalte	44
3.2.2 Photovoltaik-Anlagen	50
3.3 Niederspannungsnetz	53

4	Architektur	57
4.1	Generische Architektur für Energiemanagement-Systeme . .	57
4.1.1	Abstraktionsschicht	58
4.1.2	Hierarchische Architektur	59
4.2	Konkrete Architektur für fahrplanbasiertes Energiemanagement	60
5	Lastprognose von Einzelhaushalten	65
5.1	Klassifikation von Prognoseverfahren	66
5.2	Implementierte Prognoseverfahren	69
5.2.1	Saisonale ARIMA-Modelle	69
5.2.2	Künstliche neuronale Netze	72
5.2.3	Vergleichstageverfahren und synthetische Lastprofile	74
5.3	Evaluation der Prognoseverfahren	74
5.3.1	Datenbasis	75
5.3.2	Fehlermaß	75
5.3.3	Ergebnisse	76
5.4	Zusammenfassung und Fazit	80
6	Optimierung	83
6.1	Optimierungsproblem anschaulich	83
6.2	Skalares Optimierungsproblem für das Lastmanagement . .	86
6.2.1	Unrestringiertes Problem	87
6.2.2	Restringiertes Problem	90
6.3	Skalares Optimierungsproblem für das Last- und Erzeugungsmanagement	91
6.4	Multikriterielles Optimierungsproblem	93
6.5	Überblick über Optimierungsalgorithmen	94
6.5.1	Klassifizierung	95
6.5.2	Genetische Algorithmen	96
6.5.3	Multikriterielle Optimierung	100
6.5.4	Präferenzen	102
6.6	Implementierte genetische Algorithmen	105
6.6.1	Algorithmus \mathcal{A}_{SO} : Skalare Optimierung	107
6.6.2	Algorithmus \mathcal{A}_{MO} : Multikriterielle Optimierung	108

6.6.3	Algorithmus \mathcal{A}_{PMO} : Präferenzbasierte multikriterielle Optimierung	110
6.6.4	Entscheidungsfindung	113
7	Evaluation	117
7.1	Lastmanagement-Szenarien	118
7.1.1	Szenario 1: Basisszenario für das Lastmanagement	118
7.1.2	Szenario 2: Variables Zielprofil	125
7.1.3	Szenario 3: Verkürzter Planungshorizont	127
7.1.4	Szenario 4: Hohe Netzbelastung	130
7.1.5	Szenario 5: Erhöhte Lastflexibilität durch Zunahme der verlagerbaren Energie	135
7.1.6	Szenario 6: Erhöhte Lastflexibilität durch Erhöhung der Anzahl von Verlagerungsangeboten	138
7.1.7	Szenario 7: Multikriterielle Optimierung	140
7.2	Last- und Erzeugungsmanagement-Szenarien	143
7.2.1	Szenario 8: Basisszenario für das Last- und Erzeugungsmanagement	144
7.2.2	Szenario 9: Präferenzbasierte multikriterielle Optimierung	147
7.2.3	Szenario 10: Multikriterielle Optimierung bei erhöhter Lastflexibilität	152
7.3	Diskussion	153
7.3.1	Flexibilität	153
7.3.2	Optimierung	154
7.3.3	Netzrestriktionen	156
7.3.4	Hierarchisches Energiemanagement	157
8	Zusammenfassung und Ausblick	159
8.1	Zusammenfassung	159
8.1.1	Fahrplanbasiertes Energiemanagement	159
8.1.2	Energiemanagement-Architektur	163
8.2	Ausblick	163
	Literaturverzeichnis	167

Mengen

\mathcal{M}	Menge (Großbuchstabe, kalligrafisch)
\mathbb{N}	Natürliche Zahlen mit Null
\mathbb{R}	Reelle Zahlen

Skalare, Vektoren und Matrizen

x	Skalar (Kleinbuchstabe)
\underline{x}	Spaltenvektor (Kleinbuchstabe, unterstrichen)
\underline{x}'	Transponierte des Vektors \underline{x}
\mathbf{A}	Matrix (Großbuchstabe, fett)
\mathbf{z}, z	Zufallsvariable \mathbf{z} (Kleinbuchstabe, fett) sowie deren Realisierung z (Kleinbuchstabe)
$\underline{\mathbf{Z}}, \underline{\mathbf{Z}}$	Zeitdiskreter stochastischer Prozess $\underline{\mathbf{Z}}$ (Großbuchstabe, fett, unterstrichen) sowie dessen Realisierung $\underline{\mathbf{Z}}$ (Großbuchstabe, unterstrichen)

Spezielle Variablen und Größen

a	Angestrebte Wirkleistungsverlagerung (in Watt)
\underline{A}	Wirkleistungsprofil (für jeden Zeitschritt in Watt), welches die Abweichung von einem Zielleistungsprofil darstellt
b	Schwellenwert eines künstlichen Neurons

B	Imaginärteil einer komplexen Admittanz $G + jB$ (in Siemens)
c	Fixer Preis für ein Verlagerungsangebot (in Euro)
d	Änderung der Leistung zwischen zwei aufeinanderfolgenden Zeitschritten (in Watt)
D	Ordnung der Differenzenbildung bei SARIMA-Prozessen
\tilde{D}	Ordnung saisonaler Differenzbildung bei SARIMA-Prozessen
e	Eingangssignal eines künstlichen Neurons
E	Entscheidungsmatrix des TOPSIS-Verfahrens
G	Realteil einer komplexen Admittanz $G + jB$ (in Siemens)
i	Stromstärke (in Ampere)
j	Imaginäre Einheit
$\underline{L}, \underline{l}$	Leistungsprofil \underline{L} sowie dessen Wert \underline{l} zu einem bestimmten Zeitpunkt
\mathcal{L}	Menge von Leistungsprofilen
M	Maximaler Trade-off zwischen Zielfunktionen einer eigentlich Pareto-optimalen Lösung
O	Normalisierte Entscheidungsmatrix des TOPSIS-Verfahrens
p	Wirkleistung (in Watt)
P	Ordnung eines autoregressiven Prozesses
\tilde{P}	Ordnung eines saisonalen autoregressiven Prozesses
q	Blindleistung (in var)
Q	Ordnung eines Moving-Average-Prozesses
\tilde{Q}	Ordnung eines saisonalen Moving-Average-Prozesses
S	Periode einer Saisonalität
u	Spannungsbetrag (in Volt) der komplexen Spannung $u \cdot e^{j\varphi}$
w	Gewichtsfaktor
x	Binäre Entscheidungsvariable

\mathcal{X}, \mathcal{Z}	Menge \mathcal{X} der zulässigen Lösungen eines Optimierungsproblems sowie deren Bildmenge \mathcal{Z}
$\underline{z}^+, \underline{z}^-$	Ideallösung \underline{z}^+ sowie Antiideallösung \underline{z}^-
Z	Gewichtete normalisierte Entscheidungsmatrix des TOPSIS-Verfahrens
δ^+, δ^-	Euklidischer Abstand einer Lösung zu der Ideallösung \underline{z}^+ bzw. zu der Antiideallösung \underline{z}^-
ϵ	Rauschterm
θ	Koeffizient eines Rauschterms eines Moving-Average-Prozesses
λ	Anzahl der erzeugten Kindindividuen pro Generation eines genetischen Algorithmus
μ	Populationsgröße eines genetischen Algorithmus
ν	Relative Nähe einer Lösung zu der Ideallösung \underline{z}^+
φ	Phasenwinkel (in Radiant) der komplexen Spannung $u \cdot e^{j\varphi}$
ϕ	Koeffizient eines Vergangenheitswerts eines autoregressiven Prozesses

Spezielle Funktionen und Operatoren

B	Verschiebungsoperator (Backshift-Operator)
$c(\cdot)$	Preisfunktion für ein Verlagerungsangebot
$d(\cdot)$	Dynamisierungsfunktion für das Standardlastprofil H0
$\Theta_Q(\cdot)$	Moving-Average-Polynom der Ordnung Q
$\tilde{\Theta}_{\tilde{Q}}(\cdot)$	Saisonales Moving-Average-Polynom der Ordnung \tilde{Q}
$\Phi_P(\cdot)$	Autoregressives Polynom der Ordnung P
$\tilde{\Phi}_{\tilde{P}}(\cdot)$	Saisonales autoregressives Polynom der Ordnung \tilde{P}
$\mathcal{N}(x, \sigma^2)$	Normalverteilung mit Erwartungswert x und Varianz σ^2
$\Pr(\mathbf{x} = x)$	Wahrscheinlichkeit für $\mathbf{x} = x$
∇	Differenzoperator

Untere Indizes und Wertebereiche

k, K	Knotenindex k für ein Stromnetz mit K Knoten
l, L	Leitungsindex l für ein Stromnetz mit L Leitungen
n, N	Einheitsindex n für eine Menge von N Einheiten
r, R	Funktionsindex r für ein multikriterielles Optimierungsproblem mit R Teilzielen
s, S	Lösungsindex s für eine Menge von S Lösungen eines Optimierungsproblems
t, T	Zeitindex t für einen Horizont von T diskreten Zeitschritten
v, V	Angebotsindex v für eine Menge von V Verlagerungsangeboten
κ, κ_n	Angebotsindex κ für eine Menge von κ_n Verlagerungsangeboten eines Verbrauchers n
π	Index für Erzeuger

Obere Indizes

adapt	Wert nach Leistungsverschiebung
diff	Wert eines Leistungsverlagerungsangebots
pred	Prädizierter Wert
sim	Simulierter Wert
ziel	Angestrebter Leistungswert

Einleitung

Umweltbewusstsein, Gesundheitsbewusstsein, Energiekrisen sowie das Bestreben, vorhandene Energiere Ressourcen ökonomisch und effizient zu nutzen, motivierten und motivieren weltweit die Substitution fossiler Energiequellen durch erneuerbare. In Deutschland ist dieser Prozess, zusammen mit Energieeinsparungsmaßnahmen und einer Steigerung der Energieeffizienz, unter dem Begriff Energiewende bekannt. Den energiepolitischen Beschlüssen der Bundesregierung zufolge soll der Anteil erneuerbarer Energien am Bruttostromverbrauch bis zum Jahr 2030 auf 50 % und bis 2050 auf 80 % erhöht werden [37, S. 11]. Gestützt durch politische Vorgaben und steigende Investitionen in erneuerbare Energien [21] ist ein stetiger Zuwachs der dezentralen Stromerzeugung aus regenerativen Quellen zu verzeichnen. Begleitet wird dieses Wachstum durch die Verfügbarkeit preisgünstigerer und effizienterer Technologien für die konventionelle, verteilte Energieerzeugung, was eine weitere Zunahme der Dezentralität bedingt [135, S. 11].

Bei der Integration dezentraler und volatiler Einspeisung ist zu berücksichtigen, dass Erzeugung und Verbrauch jederzeit ausgeglichen sein müssen, um eine stabile Netzfrequenz zu gewährleisten. Da eine Speicherung von Energie in großem Umfang derzeit nicht möglich ist, wird in konventionellen Stromnetzen die Erzeugung so geregelt, dass das Gleichgewicht erhalten bleibt. Steigende Volatilität und räumliche Verteilung der Erzeugung stellen jedoch die Stromnetze vor technische Herausforderungen und werfen die Frage auf, ob die traditionelle Betriebsweise beibehalten werden kann. Dies gilt in besonderem Maße für die Verteilnetze, da in diesen ein Großteil der dezentralen Anlagen angeschlossen wird [240].

Investitionen in die bestehende Netzinfrastruktur stellen eine Möglichkeit dar, den Herausforderungen zu begegnen. Dazu gehört beispielsweise

der Ausbau der Stromnetze und der Speichermöglichkeiten. Darüber hinaus müssen konventionelle Kraftwerke vorgehalten werden, die Ungleichgewichte zwischen Erzeugung und Verbrauch jederzeit ausgleichen können. Demgegenüber zeichnen sich Lösungen auf der Ebene der Koordination bestehender Anlagen und Systeme als günstigere Alternative ab [294]. Diese Lösungen setzen eine informations- und kommunikationstechnische Vernetzung der Einzelkomponenten und Akteure voraus und führen zu flexiblen, intelligenten Stromnetzen, den sogenannten Smart Grids.

1.1 Motivation: Entwicklung von klassischen Stromnetzen hin zu Smart Grids

Elektrische Energienetze gehören zu den größten und komplexesten Systemen, die von Menschen konstruiert wurden. Aus technischer Sicht werden die Sektoren Stromerzeugung, Stromübertragung und -verteilung sowie Stromverbrauch unterschieden. Eine schematische Übersicht liefert Abbildung 1.1. Der untere Teil zeigt Erzeuger und Verbraucher, die häufig in Stromnetzen zu finden sind. Die Erzeuger, Verbraucher und Komponenten im oberen Teil der Abbildung treten gegenwärtig vermehrt in Stromnetzen auf und motivieren die Entwicklung hin zu Smart Grids. Im mittleren Bereich des Bildes sind die Spannungsebenen des Stromnetzes angedeutet.

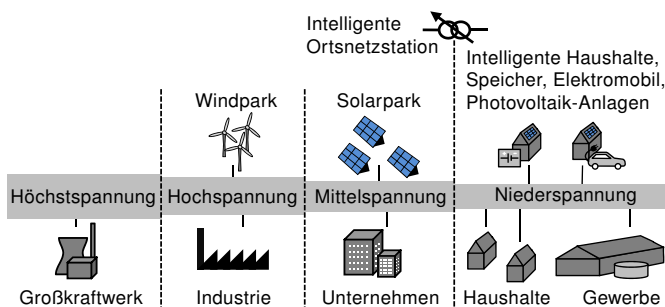


Abbildung 1.1 – Grundschemata von Stromnetzen. Die Verbraucher und Erzeuger im oberen Teil sind typisch für Smart Grids. Gleichwohl sind diese auch in konventionellen Stromnetzen wiederzufinden.

1.1.1 Klassische Stromnetze

Hohe Spannungen sind wichtig für eine verlustarme Übertragung elektrischer Energie über lange Distanzen. Bei den meisten Endkunden können diese Spannungen jedoch aus Sicherheits- und Kostengründen nicht genutzt werden. Infolgedessen werden Stromnetze auf hierarchisch gestuften Spannungsebenen betrieben. Anhand der Spannungsebenen werden in Deutschland üblicherweise folgende mittels Transformatoren gekoppelte Netze unterschieden [270, Kap. 10.1]:

- Transportnetze auf Höchstspannungsebene (220 kV oder 380 kV)
- Übertragungsnetze auf Hochspannungsebene (110 kV)
- Verteilnetze auf
 - Mittelspannungsebene (10 kV oder 20 kV)
 - Niederspannungsebene (0,4 kV oder 0,6 kV)

In Transportnetzen finden Stromflüsse, je nach Einspeise- und Lastsituation, in wechselnden Richtungen statt. Dagegen fließt der Strom in klassischen Verteilnetzen ohne dezentrale Erzeugung unidirektional zu den Verbrauchern. Die Hochspannungsnetze werden als Transport- oder als Verteilnetze genutzt.

Das deutsche Höchstspannungsnetz ist in vier Bereiche – die sogenannten Regelzonen – unterteilt, welche über Kuppelleitungen miteinander verbunden sind. Innerhalb einer Regelzone ist der Transportnetzbetreiber für das Leistungsgleichgewicht verantwortlich. Auf Höchstspannungsebene werden große Mengen Energie innerhalb und zwischen Regelzonen sowie über lange Distanzen zwischen Erzeuger- und Verbraucherschwerpunkten transportiert. In Umspannwerken wird die Spannung auf 110 kV herabgesetzt und auf verschiedene Regionen verteilt. Großverbraucher, wie zum Beispiel energieintensive Industriebetriebe, beziehen auf dieser Ebene ihren Strom; zudem sind Kraftwerke bis etwa 300 MW angebunden [120, Kap. 3.2]. Über Hochspannungsnetze wird Energie zwischen den Einspeisepunkten und Lastschwerpunkten transportiert oder in Ballungszentren mit hoher Lastdichte verteilt. In Umspannstationen wird die Hochspannung

auf Mittelspannung heruntertransformiert. Auf dieser Ebene werden Kraftwerke bis zu einer Erzeugungsleistung von etwa 10 MW sowie große Verbraucher, wie beispielsweise Kaufhäuser und Bürokomplexe, angeschlossen. Die Niederspannungsnetze sind über Ortsnetzstationen mit Mittelspannungsnetzen verbunden und versorgen Endverbraucher in Wohn- und Gewerbegebieten mit Energie.

Um den fluktuierenden Energiebedarf von Verbrauchern zu decken, wird in klassischen Stromnetzen die Erzeugungsleistung im Rahmen eines Erzeugungsmanagements angepasst. Dabei sind verschiedene Rahmenbedingungen zu beachten. Zum einen muss die Erzeugungskapazität so ausgelegt sein, dass Verbrauchsspitzen gedeckt werden können – auch wenn diese nur zu wenigen Zeitpunkten auftreten. Zum anderen ist die momentan benötigte Leistung bereitzustellen, sodass die Netzfrequenz innerhalb eines vorgeschriebenen Toleranzbereichs bleibt. Dieser Vorgang wird prinzipiell in zwei Stufen durchgeführt. In der ersten Stufe wird am Vortag des Belieferungszeitpunkts ein *planerischer* Ausgleich zwischen erzeugter und verbrauchter Wirkleistung zunächst auf Bilanzkreisebene angestrebt. Ein Bilanzkreis ist ein virtuelles Energiemengenkonto innerhalb einer Regelzone, welches eine Menge von Erzeugern und Verbrauchern umfasst und durch einen Bilanzkreisverantwortlichen bewirtschaftet wird. Auf Grundlage von bilanzkreisinternen Lastprognosen wird die benötigte Energie durch eigene Erzeugung und durch Energiehandel beschafft. Die jeweiligen Bilanzkreisverantwortlichen reichen die ermittelten Einspeisungen und Entnahmen in Form von viertelstündlich gerasterten Fahrplänen beim verantwortlichen Transportnetzbetreiber ein, welcher die resultierenden Leistungsflüsse auf technische Durchführbarkeit prüft [270, Kap. 17.1.2]. Sind nach Einreichung der Fahrpläne Abweichungen zwischen Erzeugung und Verbrauch absehbar, können diese durch Intraday-Handel reduziert werden.

Die zweite Stufe der Energiebereitstellung umfasst die *reaktive* Wahrung der Leistungsbalance in Echtzeit oder mit kurzer Vorlaufzeit. Hierbei werden auf Transportnetzebene die unvermeidbaren Abweichungen bei der Abwicklung der Fahrpläne durch Regelleistung ausgeglichen, welche durch Primär-, Sekundär- und Tertiärregelung erbracht wird. Diese Vorgänge unterscheiden sich in technischer Hinsicht sowie bezüglich Abrufprinzip und Abrechnungsmodalitäten. Wichtig ist, dass genügend Kapazität deterministisch verfügbar ist, damit bei Bedarf Regelleistung erbracht werden kann.

1.1.2 Smart Grids

In konventionellen Stromnetzen werden zentrale Steuerungskonzepte verfolgt, um eine große Menge von Verbrauchern mittels einer relativ kleinen Anzahl von steuerbaren Kraftwerken zu versorgen. Die massive Zunahme dezentraler und volatiler Erzeugung erschwert jedoch geplante und reaktive Energiebereitstellung und kann Netzprobleme auslösen [314]. Hierdurch wurde eine Trendwende eingeleitet; Flexibilitätspotenziale der dezentralen Erzeugung und der Nachfrageseite sollen ebenfalls zum Leistungsausgleich zwischen Einspeisung und Entnahme beitragen [38, S. 13]. Zu diesem Zweck sollen konventionelle, dezentrale Kraftwerke ihre Erzeugungsleistung anpassen, während die Einspeisung aus erneuerbaren Quellen bei geringer Nachfrage oder begrenzter Netzkapazität gedrosselt wird. Im Rahmen eines Lastmanagements können auch die Verbraucher durch zeitliche Verlagerung der Nachfrage am Leistungsausgleich beteiligt werden. Darüber hinaus können Speicherlösungen eine Flexibilisierung unterstützen.

Eine Umsetzung dieser Konzepte erfordert Kommunikationsinfrastrukturen einerseits und intelligente Koordinationsmechanismen andererseits. Diese sollen zusammen mit der physikalischen Netzinfrastruktur zu einem Smart Grid konvergieren, welches Erzeuger, Verbraucher und Netze zu einem automatisierten, zuverlässigen, robusten, sicheren, effizienten und nachhaltigen Energiesystem integriert [85]. Der erwartete Nutzen ist vielfältiger Art. Neben einer verbesserten Einbindung von Erzeugungsanlagen auf Basis erneuerbarer Energien soll durch die dezentrale Erzeugung eine lokale, effiziente Energiebereitstellung erfolgen. Die zusätzlichen Flexibilitäten ermöglichen eine Reduzierung der vorgehaltenen Spitzenlastkapazitäten und des Netzausbaubedarfs und senken das Risiko von Überlastungen. Ferner sollen neue Betriebsmittel und Messtechnik den Automatisierungsgrad vor allem in den Verteilnetzen erhöhen.

Smart Grids sind kein eindeutig definiertes System. Vielmehr stellen diese ein Konzept dar, das aus verschiedenen Perspektiven betrachtet wird. Demzufolge werden verschiedene Komponenten, Subsysteme und Dienste identifiziert, die zu einem intelligenten Energiemanagement beitragen. In diesem Zusammenhang wird der Begriff Energiemanagement für ein integriertes Last- und Erzeugungsmanagement gebraucht. Aspekte, die im Kontext von Smart Grids häufig untersucht werden, sind beispielsweise [85, 257]:

Flexibilitäten Ein grundlegender Aspekt ist die Nutzung der Flexibilität von Erzeugung und Verbrauch im Rahmen eines intelligenten Last- und Erzeugungsmanagements. Hierfür wurden zahlreiche Ansätze entwickelt, die von zentralem bis hin zu dezentralem Management reichen. In diesem Bereich sind beispielsweise virtuelle Kraftwerke angesiedelt, welche einen Verbund dezentraler Entitäten darstellen. Intelligente Gebäude sind ein weiterer wichtiger Baustein zur Erschließung der Flexibilität.

Speicher Elektrische und elektrochemische Speicher sind ebenfalls in der Lage, Flexibilitätspotenzial bereitzustellen. Diese Speicher liegen stationär vor oder mobil in Form von Elektroautos. Zudem werden weitere Speicherarten untersucht, zu denen beispielsweise Gasnetze oder thermische Speicher gehören.

Microgrids Microgrids sind regionale, abgeschlossene Teilnetze. Im Normalbetrieb sind diese mit dem übergeordneten Netz verbunden, können bei Bedarf jedoch auch im Inselbetrieb operieren.

Intelligente Stromzähler Um Informationen über Endkunden zu erhalten, werden intelligente Stromzähler eingesetzt, welche Verbrauchswerte in kurzen Zeitintervallen erfassen und diese an die zuständigen Stellen übertragen. Teilweise verfügen die intelligenten Zähler über Schnittstellen zur Fernsteuerung von angeschlossenen Geräten.

Netzzustand Die Ermittlung des Netzzustands spielt in Smart Grids eine wichtige Rolle. Vornehmlich werden hierzu Sensornetzwerke und Phasor-Measurement-Units eingesetzt.

Ausfallschutz Auf Basis der Sensorik in Stromnetzen ist es möglich, den Ausfallschutz zu verbessern. Es können Fehler im Vorfeld prädiziert oder bei Auftreten identifiziert werden. Darüber hinaus werden Mechanismen für eine Wiederherstellung nach Fehlern entwickelt.

Daten Smart Grids sind gekennzeichnet durch ein Datenaufkommen, welches im Vergleich zu klassischen Netzen stark erhöht ist. Diese Daten sind oftmals kritisch für die Privatsphäre der Akteure und für das Funktionieren der Netze. Es müssen daher Vorkehrungen zum Datenschutz und zur Datensicherheit getroffen werden.

Architekturen Architekturen für die Informations- und Kommunikationssysteme bilden die Grundlage der Integration aller Komponenten auf der Koordinationsebene. Hierbei sind Topologien mit verschiedenen Graden an Zentralität oder Dezentralität möglich. Die Kommunikation kann kabelgebunden oder auch kabellos erfolgen, wobei eine Vielzahl von Standards und Protokollen zu berücksichtigen ist.

1.2 Problemstellung: Flexible Leistungsführung

Wie beschrieben erfordert die Abkehr von der deterministischen, zentralen Struktur der Stromnetze hin zu stochastischen, dezentralen Systemen die Nutzung von Flexibilitätpotenzialen. Auf der Nachfrageseite kann dies im Rahmen eines Lastmanagements mit verschiedenen Zielen erfolgen. Oftmals wird der elektrische Verbrauch beispielsweise verschoben, um die Spitzenlasten zu reduzieren oder um Lasttäler aufzufüllen. Ein allgemeineres Ziel ist die flexible Lastführung (englisch: *flexible load shape*) [98]. Hierbei sollen definierbare Lastprofile mittels Lastverschiebungen bei unverändertem Gesamtenergiebedarf erzeugt werden. Findet dieser Vorgang unter Einbeziehung der Erzeugungsseite statt, so wird dieser im Folgenden als flexible Leistungsführung bezeichnet.

Im Mittelpunkt dieser Arbeit steht eine prädiktive flexible Leistungsführung, welche eine Planung mehrere Stunden im Voraus erlaubt. Das Ziel der Leistungsführung besteht darin, mittels einer Aggregation von Entitäten, welche Flexibilitäten bezüglich ihres Leistungsprofils anbieten, ein vorgegebenes Leistungsprofil möglichst genau zu approximieren. Hierbei ist nicht zwangsläufig ein Ausgleich von Angebot und Nachfrage an Energie gefordert; die Vorgabe eines Leistungsprofils stellt ein übergeordnetes Ziel dar, welches den Ausgleich als Spezialfall umfasst.

Die flexible Leistungsführung findet im Kontext von Smart Grids statt. Dabei gilt es, eine Reihe von Aspekten zu berücksichtigen:

Hierarchisierung Stromnetze umfassen eine sehr große Zahl von Komponenten und Akteuren. Sofern die Zahl der koordinierten Entitäten zu groß wird, stoßen zentrale Kontrollstrukturen an ihre Grenzen. In diesem Fall stellen hierarchische und dezentrale Ansätze weitere Optionen dar. Aufgrund des inhärent hierarchischen Charakters physikalischer Strom-

netze sind hierarchische Kontrollstrukturen eine naheliegende Alternative. Hierbei soll die Autonomie von Subsystemen bewahrt werden.

Heterogenität Im Rahmen einer flexiblen Leistungsführung können Entitäten vielfältiger Art aggregiert werden. Das Spektrum reicht beispielsweise von Haushaltsgeräten über intelligente Gebäude bis hin zu Microgrids. Diese Heterogenität muss sowohl auf der algorithmischen Ebene als auch auf der Architekturebene behandelt werden.

Flexibilität Bedingt durch die Heterogenität der Entitäten sind diverse Arten und Grade von Flexibilität verfügbar. Um Flexibilitäten für zahlreiche Anwendungsfälle nutzbar zu machen, muss eine mathematische Modellierung durchgeführt werden mit dem Ziel einer möglichst generischen Darstellung.

Mehrzielbetrachtung Eines der Ziele der flexiblen Leistungsführung stellt die bestmögliche Approximation vorgegebener Leistungsprofile dar. Zu diesem Zweck müssen die zur Verfügung stehenden Flexibilitäten genutzt werden. Diese Nutzung ist jedoch in der Regel mit Kosten verbunden. Die Kosten stellen daher ein zur Approximationsgüte gegenläufiges Ziel dar.

Planbarkeit Oftmals ist eine Planbarkeit von Leistungsprofilen erwünscht, beispielsweise um Energie zu handeln oder um die technische Umsetzbarkeit zu prüfen. Hierarchisch untergeordnete Systeme eines zu koordinierenden Systems können aufgrund deren Autonomie nicht direkt kontrolliert werden. Variable Strompreissignale sind ebenfalls nicht geeignet, da Reaktionen darauf lediglich abgeschätzt werden können.

Netzrestriktionen Eine flexible Leistungsführung darf sich nicht in allen Fällen ausschließlich auf die Koordinationsebene beschränken. Die beteiligten Entitäten sind über Stromnetze verbunden, welche physikalischen Restriktionen unterliegen. Wenn diese Restriktionen verletzt werden, ist das Energiemanagement nicht zielführend.

Prognose Prognosen der Leistungsprofile einzelner Entitäten sind grundlegend für planungsbasierte Energiemanagement-Ansätze. Diese werden zum einen für die Koordination auf Managementebene und zum anderen zur Prüfung der physikalischen Umsetzbarkeit benötigt.

1.3 Lösungsansatz: Fahrplanbasiertes Energiemanagement

Ausgehend von der beschriebenen Problemstellung wurde im Rahmen dieser Arbeit ein fahrplanbasierter Energiemanagement-Ansatz zur flexiblen Leistungsführung entwickelt und evaluiert. Dieser Ansatz ermöglicht eine zeitdiskrete Planung von aggregierten Leistungsprofilen für einen Zeithorizont von mehreren Stunden. Diese Arbeit umfasst die nachfolgend skizzierten Beiträge:

Energiemanagement-Architektur Als Grundlage des Energiemanagements wurde die Observer/Controller-Architektur [260] des Organic Computing weiterentwickelt. Kerngedanke war die strikte Trennung der Managementebene von den zu koordinierenden Entitäten. Dies wurde mittels einer Abstraktionsschicht umgesetzt, welche über Treiber die untergeordneten Entitäten kapselt. Durch die Trennung können zum einen die Koordinationsalgorithmen unabhängig von anderen Teilen des Systems entwickelt werden, sofern ein gemeinsames Datenmodell unterstützt wird. Auf diese Weise bleibt die Heterogenität der Entitäten auf der Managementebene verborgen. Zum anderen ist es möglich, Systeme beliebig zu aggregieren und diese wiederum als Subsysteme auf einer höheren Steuerungsebene zu verwenden. Dadurch unterstützt die Energiemanagement-Architektur sowohl hierarchische als auch dezentrale Kontrollstrukturen sowie deren Interaktion. Ferner weist die Architektur einen generischen Charakter auf und ist daher in der Anwendung nicht auf eine flexible Leistungsführung beschränkt. Es können Anwendungsfälle abgebildet werden, die verschiedenste Zielsetzungen sowie räumliche und zeitliche Auflösungen umfassen.

Problemformalisierung Das Approximieren eines vorgegebenen Leistungsprofils stellt ein Optimierungsproblem dar. Um dieses algorithmisch zu lösen, ist eine Problemformalisierung nötig. Hierzu muss zunächst die Flexibilität mathematisch beschrieben werden. In dieser Arbeit wurde Flexibilität als durchführbare Leistungsänderung modelliert. Diese Leistungsänderung bezieht sich auf den Fahrplan der korrespondierenden Entität und kann daher als Differenz-Leistungsprofil dargestellt werden. Auf Basis dieser Darstellung wurden verschiedene Arten von Flexibilität zur Abbildung diverser Entitäten modelliert und durch entsprechende

Treiber repräsentiert. Die generische Beschreibung beliebiger Flexibilitäten durch Leistungsprofile stellt eine Abstraktion dar, welche in der Energiemanagement-Architektur nutzbar ist. Auf Managementebene ist es unerheblich, wie eine Entität konkret beschaffen ist, da diese autonom handelt und nur im Rahmen ihres Flexibilitätspotenzials beeinflusst wird.

Dem Energiemanagement liegt die Idee zugrunde, dass Entitäten ihre Flexibilität gegen Bezahlung anbieten. Aus diesen Angeboten muss eine Auswahl getroffen werden, welche zu einem bestmöglichen Kompromiss zwischen Approximationsgüte und Kosten führt. Die Auswahl wurde als gemischt-ganzzahliges Optimierungsproblem modelliert, wobei sowohl skalare als auch multikriterielle Varianten formuliert wurden. Physikalische Netzrestriktionen bezüglich Spannung und Strom wurden als Nebenbedingungen in den Optimierungsproblemen berücksichtigt. Für die Analysen wurde ein 106-Knoten-Niederspannungsnetz gewählt, welches eine Menge von Haushalten und Photovoltaik-Anlagen umfasst. Dessen Leistungsflüsse wurden im Rahmen der Optimierung berechnet.

Optimierung Für die Optimierung wurden drei genetische Algorithmen genutzt, welche alternative Ansätze repräsentieren. Mittels des ersten Algorithmus wurde eine skalare Optimierung durchgeführt, welche die beiden Teilziele Approximationsgüte und Kosten in einer skalaren Zielfunktion zusammenfasst. Durch Gewichtungsfaktoren konnte dabei der Stellenwert der Teilziele festgelegt werden. Der zweite Algorithmus führt eine multikriterielle Optimierung durch, bei welcher beide Teilziele als separate Zielfunktionen berücksichtigt werden. Während Lösungen eines skalaren Problems anhand der eindimensionalen Zielfunktion geordnet werden können, existieren bei multikriteriellen Problemen Pareto-optimale Lösungen, die nicht miteinander vergleichbar sind. Diese bilden ein Spektrum an Kompromissen bezüglich der Teilziele ab. Im skalaren Fall werden lediglich einzelne Kompromisslösungen gefunden, welche die Gewichtung der Teilziele widerspiegeln und die Vielfalt an Entscheidungsmöglichkeiten nicht zum Ausdruck bringen. Bei einer multikriteriellen Betrachtung existieren Trade-offs zwischen Lösungen, die unerwünscht sein können. Für das Energiemanagement bedeutet dies beispielsweise, dass für eine geringe Reduzierung der Zielabweichung im Vergleich zu einer anderen Lösung ein unverhältnismäßig hoher Preis bezahlt werden

muss. Um Trade-offs zu limitieren, wurde der dritte Algorithmus genutzt. Dieser berücksichtigt definierbare Beschränkungen, sodass die Suche auf die präferierten Bereiche des Lösungsraums konzentriert wird.

Lastprognose Um Leistungsflüsse im Rahmen der Optimierung bestimmen zu können, werden die Leistungsprognosen der Netzknoten benötigt. In dieser Arbeit wurde vorausgesetzt, dass Erzeuger sowie Verbraucher in Form von intelligenten Gebäuden in der Lage sind, die Prognosen zu erstellen. Es wurde jedoch angenommen, dass ein Teil der Haushalte weder Flexibilität noch Prognosefähigkeit aufweist. Für solche Haushalte müssen kurzfristige Lastprognosen auf Basis der Messwerte intelligenter Stromzähler erstellt werden. Während Lastprognosen für Aggregationen von Verbrauchern in vielen Bereichen der Energiewirtschaft etabliert sind, gibt es nur sehr wenige Untersuchungen hinsichtlich der Lastprognose von Einzelhaushalten. Daher wurden zunächst die etablierten Prognoseverfahren klassifiziert. Diese können in klassische Verfahren, Verfahren der künstlichen Intelligenz und referenzbasierte Verfahren eingeteilt werden. Aus jeder dieser Klassen wurde zumindest ein Verfahren implementiert, um eine Übersicht über die Potenziale der Prognose zu erlangen. Zu den untersuchten Verfahren gehören saisonale ARIMA-Modelle, künstliche neuronale Netze, Vergleichstagerverfahren und die Prognose mittels synthetischer Lastprofile. Diese Verfahren wurden anhand von sechs realen Datensätzen evaluiert, welche jeweils Messwerte für mindestens ein Jahr umfassten.

Evaluierung Der Energiemanagement-Ansatz wurde mittels Simulationsstudien unter Betrachtung diverser Szenarien evaluiert. Diese sind in zwei Teile gegliedert, welche sich durch die Art der genutzten Flexibilitäten unterscheiden. Im ersten Teil wurde die flexible Leistungsführung mittels der Verbraucherseite realisiert. Im zweiten Teil wurden die Erzeuger hinzugenommen. Beide Teile umfassen sowohl Szenarien, in denen eine skalare Optimierung durchgeführt wurde, als auch Szenarien, in denen multikriteriell optimiert wurde. Hierbei wurden unter anderem verschiedene Planungshorizonte und angestrebte Leistungsprofile betrachtet. Ferner wurde der Einfluss der Art und der Höhe von Flexibilität untersucht. Das Berücksichtigen von Netzrestriktionen erwies sich als essenziell für die Identifikation von umsetzbaren Lösungen bei hoher Netzlast.

1.4 Gliederung der Arbeit

Das nächste Kapitel ordnet die vorliegende Arbeit in den Kontext des Energiemanagements ein. Hierfür wird zunächst ein Überblick über Architekturen für Energiemanagement-Systeme gegeben. Anschließend werden beste-hende Ansätze für das Lastmanagement und das Erzeugungsmanagement diskutiert.

Kapitel 3 präsentiert das Rahmenszenario, welches der Arbeit zugrunde liegt. Hierzu gehören die allgemeinen Annahmen, die bezüglich der Entitäten sowie des Energiemanagements getroffen werden. Auf Basis einer Formalisierung von Entitäten und deren Flexibilitäten werden die simulierten Entitäten definiert. Ferner wird das Niederspannungsnetz beschrieben, welches die simulierten Entitäten aufnimmt.

Die entwickelte Energiemanagement-Architektur wird in Kapitel 4 vorgestellt. Darüber hinaus werden weitere Anwendungsfälle skizziert, welche über die flexible Leistungsführung hinaus mit der Architektur abgebildet werden können. Zwei Kernfunktionalitäten innerhalb der Architektur sind das Erfassen des Systemzustands und darauf aufbauend die Koordination des Systems. Hierbei ist die Zustandserfassung mit einer Prädiktion des Systemzustands verbunden. In diesem Zusammenhang werden Lastprognosen für Einzelhaushalte in Kapitel 5 dargestellt. Nach einer Klassifizierung der Prognoseverfahren werden die implementierten Verfahren beschrieben. Diese werden anschließend evaluiert und gegenübergestellt. Die Koordination des Systems basiert in dieser Arbeit darauf, dass Flexibilitäten bezüglich der prognostizierten Fahrpläne abgerufen werden. Die zugehörigen Optimierungsprobleme werden in Kapitel 6 formuliert. Hierbei werden sowohl skalare als auch multikriterielle Varianten betrachtet. Daraufhin werden genetische Algorithmen im Allgemeinen und die drei implementierten Algorithmen im Speziellen beschrieben.

Der entwickelte Energiemanagement-Ansatz wird anhand von Simulationsstudien untersucht. Diese Studien werden in Kapitel 7 vorgestellt, ausgewertet und diskutiert. Den Abschluss der Arbeit bildet Kapitel 8 mit einer zusammenfassenden Betrachtung der Ergebnisse sowie mit einem Überblick über Erweiterungsmöglichkeiten.

Energiemanagement

Energiemanagement im Sinne dieser Arbeit umfasst die Koordination von Energieverbrauch und Energieerzeugung. Diese Koordination ist auf ein vorgegebenes Zielprofil ausgerichtet und wird unter Einbeziehung physikalischer Netzparameter vorgenommen. Das folgende Kapitel gibt zunächst einen Überblick über bestehende Architekturen für Energiemanagement-Systeme. Daraufhin werden die Konzepte des Lastmanagements und des Erzeugungsmanagements sowie Ansätze, die bisher auf diesen Gebieten entwickelt wurden, vorgestellt. In dieser Arbeit stehen Energiemanagement-Verfahren im Mittelpunkt, die auf einer fahrplanbasierten Koordination des Verbrauchs und der Erzeugung für einen Zeithorizont von mehreren Stunden beruhen. Ein Energiemanagement in Echtzeit wird nicht angestrebt. Daher werden in diesem Kapitel Ansätze, die einem Echtzeit-Betrieb dienen, nicht näher beschrieben. Ferner werden Stromnetze im stationären Betrieb betrachtet, der sich nach dem Abklingen aller durch Zustandsänderungen hervorgerufenen Ausgleichsvorgänge einstellt. Für dynamische Betrachtungen sei beispielsweise auf die Arbeiten [150, 152] verwiesen.

2.1 Architekturen

Intelligente Stromnetze bedingen eine erhöhte Komplexität des Netzbetriebs. Dies kann unter anderem auf die Einführung von Lastmanagement sowie auf die Zunahme der dezentralen Erzeugung und der Elektromobilität zurückgeführt werden. Hierdurch steigt die Zahl neuer Netzkomponenten, wie beispielsweise intelligente Stromzähler, Ladestationen oder Inverter, die erweiterte Funktionalitäten und Dienste anbieten. Dies wiederum resultiert in komplexen Netzwerken zahlreicher kommunizierender Kom-

ponenten. Um diese Komplexität zu beherrschen, ist der Einsatz aktueller SCADA-Systeme nicht mehr ausreichend [193]. Es sind neue Architekturen für ein flexibles, modulares und erweiterbares Energiemanagement nötig, welches dezentral oder hierarchisch ausgestaltet sein kann.

Bislang wurden verschiedene Energiemanagement-Architekturen vorgeschlagen. Diese sind jedoch meist sehr allgemein [44, 298, 330], fokussieren Kommunikationsaspekte [24, 169, 172, 334] oder vernachlässigen die Optimierung [285]. Agentenbasierte Ansätze und die Observer/Controller-Architektur des Organic Computing bieten vielversprechende Möglichkeiten, Systeme zu entwerfen, welche den neuen Anforderungen genügen.

2.1.1 Anforderungen

Eine Architektur dient zunächst als Plattform für das eigentliche Energiemanagement bzw. die entsprechenden Algorithmen. Hierzu ist die Koordination von Verbrauch und Erzeugung zu zählen, wobei die Flexibilität von Verbrauchern, Erzeugern und Speichern genutzt wird. In diesem Kontext sollte es möglich sein, physikalische Netzrestriktionen zu beachten. Des Weiteren sollte der Netzzustand berücksichtigt und ein optimaler Netzbetrieb unter Einsatz der Betriebsmittel gewährleistet werden. Optimalitätskriterien müssen im konkreten Anwendungsfall gewählt werden. Ferner sollten im Rahmen des Energiemanagements externe Vorgaben, beispielsweise von Leitständen, möglich sein.

Über die genannten Punkte hinaus werden nichtfunktionale Anforderungen an Energiemanagement-Architekturen gestellt. Diese sollten dezentrale und hierarchische Kontrollstrukturen sowie deren Interaktion unterstützen, um die Steuerungskomplexität zu reduzieren. Ferner sollte es möglich sein, Lernverfahren einzusetzen, um adaptives und robustes Systemverhalten zu erreichen. Des Weiteren müssen verschiedene Komponenten – sowohl neue als auch bestehende – flexibel integriert werden können. Erschwert wird die Interoperabilität durch eine Vielzahl konkurrierender Standards und Protokolle. Eine weitere Hürde ist das Übertragen der Implementierung eines Energiemanagement-Systems in den praktischen Einsatz. Bei neuen Energiemanagement-Ansätzen empfiehlt sich eine ausgiebige Analyse mittels Simulationen oder virtuellen Szenarien, bevor eine Nutzung in Feldtests in Frage kommt [129]. Allerdings ist die Migration eines

prototypischen Systems zu einer zuverlässigen Lösung für die Praxis nicht trivial [193]. Energiemanagement-Architekturen sollten diesen Schritt möglichst einfach gestalten.

2.1.2 Multiagentensysteme

Multiagentensysteme sind ein Teilgebiet der verteilten künstlichen Intelligenz, welches Prinzipien zum Erstellen komplexer Systeme basierend auf einer Menge von Agenten sowie die Koordination dieser Agenten zum Inhalt hat [293]. In den letzten drei Jahrzehnten haben Multiagentensysteme in einer Vielzahl von Anwendungsbereichen Einzug gehalten [146], beispielsweise im Verkehrs- und Transportwesen [41], in der Fertigung [276], in der Telekommunikation [323] und im Energiebereich [47]. Aufgrund ihres breiten Einsatzspektrums existiert für den Begriff des Agenten keine allgemein anerkannte Definition. Eine Möglichkeit, Agenten zu definieren liefern Russell und Norvig [263, Kap. 2.1]:

An agent is anything that can be viewed as perceiving its environment through sensors and acting upon that environment through effectors.

Ein Agent wird also sehr allgemein als etwas bezeichnet, das seine Umgebung wahrnimmt und diese auch beeinflusst. Franklin und Graesser gehen einen Schritt weiter und fordern, nachdem sie verschiedene Definitionen aus der Literatur gegenüberstellen, zusätzliche Eigenschaften von Agenten [92]:

An autonomous agent is a system situated within and part of an environment that senses that environment and acts on it, over time, in pursuit of its own agenda and so as to effect what it senses in the future.

Im Unterschied zur vorherigen Definition sind Agenten autonom, da sie nicht auf Benutzereingriffe angewiesen sind. Darüber hinaus sind diese Agenten proaktiv, das heißt sie handeln aus Eigeninitiative, um ihre Ziele zu erreichen. Zusätzlich dazu fordern Wooldridge und Jennings in ihrer Definition [327, Kap. 1.1], dass Agenten untereinander kommunizieren. Oftmals werden im Zusammenhang mit Agenten und Multiagentensystemen noch

weitere Eigenschaften aufgeführt, wie beispielsweise Lernfähigkeit [42, 229], Robustheit [93] oder Selbstorganisation [73, 326].

Diese Arbeit geht von einer relativ allgemeinen Definition für Agenten aus; zusätzliche Eigenschaften werden bei Bedarf genannt.

Definition (Agent). *Ein Agent ist eine physikalische oder virtuelle Entität, die ihre Umgebung wahrnehmen und darauf einwirken kann. Hierbei sind die Handlungen des Agenten darauf ausgerichtet, bestimmte Ziele zu erreichen.*

Definition (Multiagentensystem). *Ein System, welches aus mehreren miteinander kommunizierenden Agenten besteht, wird als Multiagentensystem bezeichnet.*

Wie in Tabelle 2.1 dargestellt, können Multiagentensysteme anhand der Topologie von Agentenbeziehungen sowie der Informationsflüsse kategorisiert werden. Es wird zwischen zentraler und dezentraler Topologie unterschieden [307]. Im ersten Fall existiert ein zentraler, übergeordneter Agent und eine Menge untergeordneter Agenten, wohingegen im zweiten Fall alle Agenten gleichberechtigt sind. Orthogonal zur Topologie wird direkte Kommunikation zwischen Agenten abgegrenzt von der indirekten Kommunikation, welche über die Umgebung der Agenten stattfindet. Diese Umgebung umfasst Zustandsvariablen, die von den Agenten wahrgenommen werden. Es existieren endogene und exogene Variablen. Erstere sind durch das Verhalten beliebiger Agenten veränderbar. Exogene Umgebungsvariablen hingegen können nur durch übergeordnete Agenten beeinflusst werden.

In der Matrix, welche durch Topologien und Informationsflüsse aufgespannt wird, sendet bei der direkten Kommunikation in zentraler Topologie die zentrale Instanz Befehle an nachgeordnete Agenten, wohingegen in einer dezentralen Topologie die Agenten untereinander gleichberechtigt kommunizieren. Sind die Informationsflüsse indirekt, kann in zentralen Systemen die übergeordnete Entität andere Agenten über exogene Umgebungsvariablen lenken. In dezentralen Systemen beobachten und verändern die Agenten zur indirekten Kommunikation endogene Umgebungsvariablen, was als Stigmiege bezeichnet wird [302].

Im Energiebereich wurden Multiagentensysteme aller vier Kategorien sowie deren Architekturen für diverse Anwendungsfälle beschrieben. Dazu gehören zum einen Anwendungen, die nur einen beschränkten Teil des

Tabelle 2.1 – Kategorisierung von Multiagentensystemen anhand der Topologie der Agentenbeziehungen und der Informationsflüsse, nach [307]

		Informationsfluss	
		Direkt	Indirekt
Topologie	Zentral	Befehl	Restriktion
	Dezentral	Konversation	Stigmergie

Energiemanagement-Spektrums aufgreifen. Beispiele hierfür sind Fehlerdiagnose [63], Schutzsysteme [239, 277], Zustandsüberwachung [46, 192, 313], Zustandsschätzung [180], Netzwiederherstellung [259, 287], Gebäude-Energiemanagement [147, 162, 316, 340], Strommärkte [319, 322], Lastmanagement [20] und Erzeugungsmanagement [148, 309]. Zum anderen existieren Multiagentensysteme, die mehrere dieser Anwendungen umfassen. Diese beschränken sich zumeist auf die physikalischen Aspekte des Energiemanagements [197, 337] oder auf das Abstimmen von Verbrauch und Erzeugung [57, 94, 164, 165, 212]. Nur wenige Multiagentensysteme betrachten Anwendungen aus beiden Bereichen [43, 171, 179, 242, 245]. Die meisten davon wurden für Microgrids entwickelt [177]. Eine ausführliche Übersicht über Multiagentensysteme im Energiebereich, deren Fähigkeiten, Interaktionen sowie eingesetzte Standards liefern McArthur *et al.* [193, 194].

Die betrachteten Multiagentensysteme decken die Aspekte des Energiemanagements und die in Abschnitt 2.1.1 genannten Anforderungen an die zugehörige Architektur nur teilweise ab. Eine umfassende Energiemanagement-Architektur sollte jedoch ein breites Spektrum umfassen. Die generische Architektur, die in Kapitel 4 vorgestellt wird, greift all diese Aspekte auf und integriert sie in ein gemeinsames Framework. Grundlage hierfür ist die Observer/Controller-Architektur. Im nächsten Abschnitt werden diese Architektur und existierende Anwendungen im Energiebereich beschrieben.

2.1.3 Observer/Controller-Architektur

Das Forschungsgebiet *Organic Computing* [208–210, 269] widmet sich den grundlegenden Herausforderungen komplexer Systeme in dynamischen

Umgebungen, wie beispielsweise Flexibilität, Adaptivität, Robustheit und Vertrauenswürdigkeit. Insbesondere sollten die Systeme lernfähig sein und sogenannte Selbst-x-Eigenschaften, wie Selbstorganisation oder Selbstkonfiguration, aufweisen. Aufgrund dieser Eigenschaften, die an lebende Organismen angelehnt sind, werden solche Systeme als organisch bezeichnet. Im Rahmen des DFG-Schwerpunktprogramms 1183 „Organic Computing“ wurden Anwendungen in verschiedenen Bereichen betrachtet, unter anderem in der Robotik [205], im Verkehrswesen [248] und in der Fertigung [271]. Hierbei wurde mit der Observer/Controller-Architektur [36, 207, 260] ein Rahmen geschaffen, organische Systeme zu entwerfen.

Die generische Observer/Controller-Architektur bildet, so wie in Abbildung 2.1 dargestellt, mit dem zu überwachenden System eine Art Regelkreis. Mit der Hilfe von Sensoren und Aktuatoren wird das sogenannte *System under Observation and Control* (SuOC) beobachtet und beeinflusst. Das SuOC kann ein beliebiges technisches Hardware- oder Software-System sein, wie zum Beispiel ein Traktor [329], ein Stromnetz [261], eine Ampelsteuerung [249] oder eine serviceorientierte Architektur [178]. Diese Systeme können aus einer großen Menge von autonomen Subsystemen oder Agenten bestehen, welche in ihrer Umgebung interagieren. Dabei muss das Gesamtsystem auch ohne die Koordinationsebene funktionsfähig bleiben, wobei jedoch unerwünschte Systemzustände erreicht werden können. Ziel ist es, die Selbstorganisation des SuOC zu unterstützen und einzugreifen, wenn unerwünschte Zustände drohen oder bereits eingetreten sind.

Die Beobachtung und die Beeinflussung des SuOC werden von einem sogenannten *Observer* und einem *Controller* umgesetzt, die zusammen eine Observer/Controller-Einheit bilden. Der Observer erfasst zunächst verschiedene Zustandsgrößen und speichert diese in einer Log-Datei. Im Rahmen einer Vorverarbeitung werden Rohdaten aufbereitet und abgeleitete Attribute bestimmt, die nicht direkt gemessen werden. Dies könnten beispielsweise Geschwindigkeiten sein, die aus Positionsmessungen berechnet werden. Die vorverarbeiteten Daten werden dann analysiert, um eine Beschreibung des aktuellen Systemzustands zu gewinnen. Gleichzeitig werden zukünftige Zustände prädiziert. Aktuelle und vorhergesagte Zustände werden mit den vorverarbeiteten Daten in aggregierter Form an den Controller weitergereicht. Der Controller umfasst zwei Ebenen. Auf der ersten Ebene werden die Situationsparameter auf durchzuführende Aktionen ab-

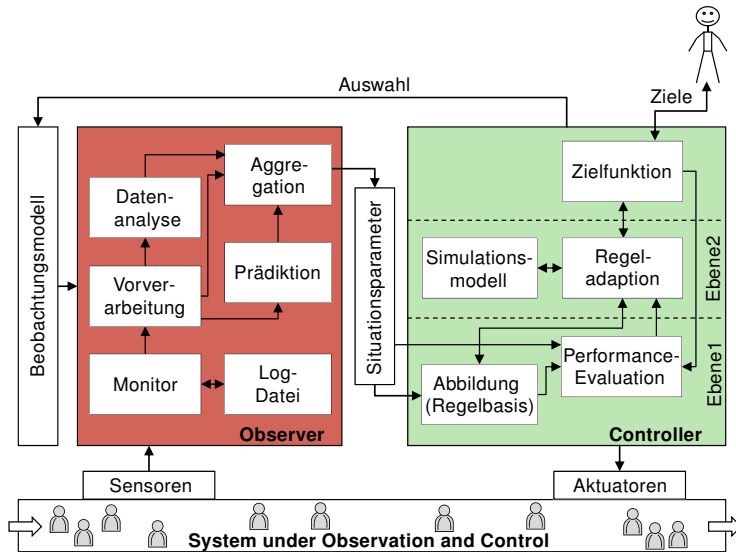


Abbildung 2.1 – Generische Observer/Controller-Architektur, nach [260]. Der Zustand des System unter Observation and Control wird durch Observer und Controller erfasst und beeinflusst. Diese bestehen aus generischen Subsystemen, die an Anwendungen angepasst werden.

gebildet. Nach Ausführung der Aktionen werden deren Auswirkungen zu späteren Zeitpunkten durch den Observer erfasst und in den Situationsparametern an den Controller weitergegeben. Dadurch kann die Performance der Abbildung hinsichtlich einer von außen vorgegebenen Zielfunktion evaluiert werden, sodass die Abbildung bei Bedarf angepasst werden kann. Auf der zweiten Ebene findet ebenfalls eine Adaption der Abbildung statt. Diese basiert jedoch auf einer Simulation des SuOC. Daher müssen keine Aktionen im realen SuOC durchgeführt werden, um Lernverfahren anzuwenden und die Abbildung anzupassen. Dieses Vorgehen erweist sich als nützlich, wenn die Auswirkungen von Aktionen ungewiss sind oder das SuOC nicht mit einer Vielzahl von Eingriffen konfrontiert werden soll, wie es für Lernverfahren nötig ist. Die Zerteilung des Controllers entspricht somit einer Aufteilung in Online- und Offline-Komponenten. Auf der ersten Ebene werden die Aktionen kurzfristig online ausgewählt und gelernt, während auf der




Abbildung 2.2 – Realisierungsvarianten der Observer/Controller-Architektur (O, rot: Observer; C, grün: Controller), nach [260]. Unterscheidungsmerkmal ist die Verteilung der Koordination.

zweiten Ebene offline eine längerfristige Optimierung stattfindet. Im Rahmen seiner Aufgaben kann der Controller Parameter eines Beobachtungsmodells ändern. Damit erhält er Einfluss darauf, welche Daten im Observer gemessen und wie diese verarbeitet werden.

Die Observer/Controller-Architektur stellt ein generisches *Framework* dar für ein weites Spektrum technischer Systeme. Dabei spezifiziert die Architektur die Komponenten, die für organische Systeme nötig sind, nicht jedoch deren konkrete Funktionsweise. So wird beispielsweise weder ein Prognoseverfahren vorgeschrieben noch wie die Abbildung der Situationsparameter auf die Aktionen beschaffen sein muss. Implementierungen der Architektur können daher Komponenten weglassen oder hinzufügen. Eine wichtige Rolle spielen jedoch – im Gegensatz zur klassischen Regelungstechnik – die Prinzipien und Methoden der künstlichen Intelligenz.

Es existieren diverse Realisierungsvarianten der Observer/Controller-Architektur, die in Abhängigkeit des Anwendungsfalls genutzt werden können. Abbildung 2.2a zeigt die zentrale Variante, bei der eine einzige Observer/Controller-Einheit für alle Komponenten zuständig ist. In der dezentralen Version aus Abbildung 2.2b existiert für jedes Subsystem eine Observer/Controller-Einheit. Die hierarchische Variante, wie in Abbildung 2.2c dargestellt, kombiniert die vorherigen beiden in einer mehrschichtigen Struktur.

Zu den vielfältigen Einsatzmöglichkeiten der Observer/Controller-Architektur gehören auch Anwendungen im Energiebereich. Allerdings *et al.* nutzen eine zweischichtige hierarchische Architektur, um ein Energiemanagement für intelligente Gebäude – sogenannte *Organic Smart Homes* – zu realisieren [9, 10, 13]. Eine Übersicht dieser Architektur zeigt Abbildung 2.3.




Abbildung 2.3 – Energiemanagement-Architektur des Organic Smart Home (O: Observer, C: Controller, HA: Hardware-Abstraktionsschicht), nach [9]

Jedem einzelnen Gerät und jeder Anlage ist jeweils eine spezifische, lokale Observer/Controller-Einheit zugeordnet. Diese erfasst und verarbeitet die Daten des Geräts und ist in der Lage, Steuersignale zu senden. Die lokalen Einheiten werden von einer übergeordneten Observer/Controller-Einheit koordiniert, welche für das Energiemanagement auf Gebäudeebene zuständig ist. Diese Einheit setzt darüber hinaus externe Vorgaben um. Dazu gehören sowohl Benutzervorgaben als auch Signale von Unternehmen, wie beispielsweise variable Stromtarife. Die Benutzerschnittstelle des Organic Smart Home wird von Becker beschrieben [26].

Um das Energiemanagement gegenüber den heterogenen Komponenten im Gebäude transparent zu gestalten, wird eine Hardware-Abstraktionsschicht eingefügt. Diese nutzt für jede Komponente Treiber zur Kapselung gerätespezifischer Eigenschaften und Kommunikationsprotokolle. Dadurch wird es möglich, die realen Komponenten durch Simulationsobjekte zu ersetzen, ohne den Management-Code anzupassen.

Das Energiemanagement wird mittels eines teilproblembasierten, evolutionären Optimierungsverfahrens umgesetzt [11, 12]. Die Teilprobleme werden durch die lokalen Observer/Controller-Einheiten bereitgestellt und in der darüber liegenden Ebene zu einem Gesamtproblem zusammengefügt und gelöst. Mauser *et al.* haben in diesem Zusammenhang Untersu-

chungen bezüglich der Codierung der Lösungen [187] und bezüglich der Parameter-Anpassung [188] des evolutionären Algorithmus durchgeführt. Ferner werden die Abhängigkeiten zwischen verschiedenen Energieträgern in der Optimierung berücksichtigt [189]. Mültin betrachtet die Integration von Elektrofahrzeugen [211].

Ein gebäudeübergreifender Energiemanagement-Ansatz wird von Kamper verfolgt [155]. Er nutzt einen Pool von Geräten zur Bereitstellung flexibler Lastkurven. Hierzu teilen die Geräte ihren Energiebedarf und ihre Freiheitsgrade über ein Peer-to-Peer-Netz untereinander mit. Bei Fahrplanänderungen wird versucht, unter Nutzung der Freiheitsgrade anderer Geräte intern einen Lastausgleich durchzuführen. Die angestrebte Gesamtlastkurve wird als Ungleichgewicht bzw. Fahrplanänderung in den Pool gebracht. Zur kurzfristigeren Lastganganpassung wurde das Verfahren um eine sogenannte „elitäre Gruppe“ erweitert [154, 156]. Diese umfasst eine Menge von Geräten, die ihren Verbrauch ohne Abstimmung mit dem Pool sofort ändern können. In den Arbeiten werden Netzrestriktionen nicht beachtet.

Die generische Observer/Controller-Architektur erfüllt wichtige, in Abschnitt 2.1.1 genannte, Anforderungen an eine Energiemanagement-Architektur. Es sind sowohl verteilte als auch zentrale und hierarchische Systeme umsetzbar. Darüber hinaus unterstützt sie maschinelle Lernverfahren und erlaubt externe Zielvorgaben. Daher wurde die Observer/Controller-Architektur in dieser Arbeit adaptiert und genutzt. In Kapitel 4 wird, aufbauend auf den Prinzipien des Organic Smart Home, eine Architektur für das Energiemanagement in intelligenten Stromnetzen präsentiert, die Interoperabilität sowie Übertragbarkeit eines Prototypen in die Praxis berücksichtigt.

2.2 Lastmanagement

Die Beeinflussung der Nachfrage von Energie wird als Lastmanagement bezeichnet. In manchen Definitionen schließt dieser Begriff, unter Berücksichtigung des Vorzeichens der Leistung, auch die Erzeugungsseite ein. Um eine bessere Abgrenzung zu ermöglichen, bezieht sich der Ausdruck Lastmanagement in dieser Arbeit jedoch ausschließlich auf die Nachfrageseite. In diesem Zusammenhang werden häufig die englischen Begriffe *Demand-Side-Management* (DSM) und *Demand-Response* genannt und zum Teil syn-

onym verwendet. Da kein einheitliches Verständnis der Begriffsbedeutungen besteht, werden im Folgenden einige Definitionen gegenübergestellt. Darauf aufbauend wird der Begriff des Lastmanagements abgegrenzt. Anschließend wird ein Überblick über bestehende Ansätze gegeben.

2.2.1 Begriffsdefinition

Der Begriff *Demand-Side-Management* wurde 1984 von Clark Gellings geprägt [317]. Laut Gellings umfasst DSM die Aktivitäten von Energieversorgungsunternehmen, die zu gewünschten Änderungen der Lastkurve führen. Hierzu gehören sowohl Änderungen der zeitlichen Verbrauchsmuster als auch des Gesamtenergieverbrauchs [98]:

DSM is the planning, implementation, and monitoring of those utility activities designed to influence customer use of electricity in ways that will produce desired changes in the utility's load shape, i. e., changes in the time pattern and magnitude of a utility's load. Utility programs falling under the umbrella of DSM include: load management, new uses, strategic conservation, electrification, customer generation, and adjustments in market share.

Ferner nennt Gellings sechs Ziele des DSM [98], die auch von anderen Autoren aufgegriffen werden [27, 218, 317]:

1. *Strategische Lastsenkung*: Hierbei wird der Gesamtenergieverbrauch über einen längeren Zeitraum reduziert, beispielsweise durch Austausch alter Verbraucher durch neue, energieeffizientere Verbraucher (siehe Abbildung 2.4a).
2. *Strategische Lasterhöhung*: Der gesamte Energieverbrauch wird erhöht (siehe Abbildung 2.4b). Dies lässt sich bewerkstelligen, indem beispielsweise Verbrennungsprozesse durch elektrische Prozesse ersetzt werden. Elektromobilität ist ein prominentes Beispiel dafür.
3. *Spitzenlastkappung*: Lastspitzen können von Energieversorgungsunternehmen durch Fernabschaltung von Verbrauchern reduziert werden (siehe Abbildung 2.4c). Der Gesamtenergieverbrauch kann sich ändern, beispielsweise wenn Beleuchtung abgeschaltet wird.

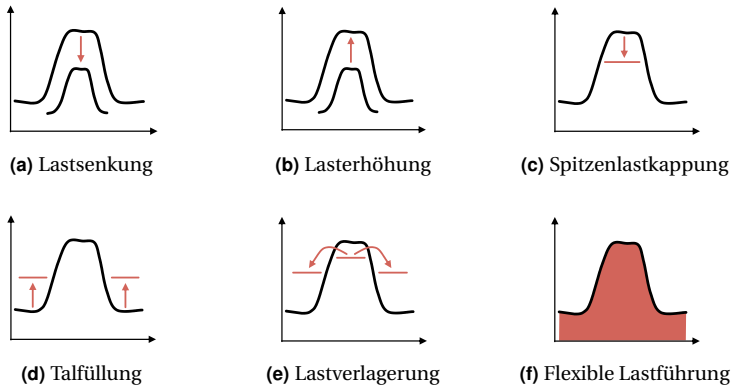


Abbildung 2.4 – Ziele des Demand-Side-Management, nach [98]. Die Teilabbildungen (a) und (b) repräsentieren strategische Ziele, wohingegen die Ziele in (c)–(f) kurzfristig sind.

4. *Auffüllen von Lasttälern*: In Schwachlastzeiten werden zusätzliche Verbraucher hinzugeschaltet (siehe Abbildung 2.4d). Dafür bieten sich beispielsweise thermische Speicher an. Auch hierbei kann sich der Gesamtenergieverbrauch ändern.
5. *Lastverlagerung*: Leistungsaufnahme wird von Spitzenlastzeiten in Schwachlastzeiten verschoben (siehe Abbildung 2.4e). Dabei wird lediglich der Zeitpunkt der Leistungsaufnahme verändert, nicht jedoch der Gesamtenergiebedarf.
6. *Flexible Lastführung*: Der Lastgang nimmt durch Lastverschiebungen zu beliebigen Zeiten eine definierbare Form an (siehe Abbildung 2.4f). Der Gesamtenergiebedarf bleibt hierbei gleich.

Die ersten beiden Ziele unterscheiden sich von den anderen durch die langfristige Änderung des Energieverbrauchs ohne definierte Verbrauchsmuster. Zwischen den Zielen 3–6, deren Fokus auf einer kurzfristigen Laständerung liegt, bestehen Abhängigkeiten. So ist es beispielsweise möglich, mittels einer Lastverlagerung sowohl Lasttäler zu füllen als auch Spitzenlasten zu kappen. Eine flexible Lastführung kann als allgemeinstes Ziel aufgefasst werden, da dieses die Ziele 3–5 subsumiert.

Die Maßnahmen zur Erreichung kurzfristiger DSM-Ziele werden meist unter den Begriffen Demand-Response oder Lastmanagement (englisch: *load management*) zusammengefasst. Allerdings bestehen Unterschiede im Zielumfang. Dieser reicht von allen Zielen 3–6 [4], über die Ziele 3–5 [234, 252] bis hin zu Einzelzielen. So umfasst Demand-Response zum Teil lediglich Spitzenlastkappung [145] oder Spitzenlastkappung und Lastverlagerung [195]. Gelegentlich sind auch abweichende Begriffsdefinitionen zu finden. Während sich Bellarmines Auffassung von DSM [27] mit derjenigen von Gellings [98] deckt, nutzt er Lastmanagement als Oberbegriff für DSM und Erzeugungsmanagement. Eine weiterführende Übersicht über Demand-Response in intelligenten Stromnetzen liefert Siano [284].

Palensky und Dietrich fassen unter dem Begriff DSM alle verbraucherseitigen Maßnahmen zusammen [228]:

DSM includes everything that is done on the demand side of an energy system, ranging from exchanging old incandescent light bulbs to compact fluorescent lights (CFLs) up to installing a sophisticated dynamic load management system.

Sie unterscheiden in Abhängigkeit des Zeithorizonts der zu erbringenden DSM-Leistung zwischen Energieeffizienz, statischen zeitvariablen Tarifen, Demand-Response und Regelenergie. Energieeffizienz entspricht der langfristigen strategischen Lastsenkung bei Gellings [98]. Statische zeitvariable Tarife gelten für mehrere Tage und ändern sich selten. Eine kürzere Reaktionszeit ermöglicht Demand-Response, welches eingeteilt wird in marktbasierendes Demand-Response und physikalisches Demand-Response. Zu den marktbasierenden Ansätzen gehören dynamische zeitvariable Tarife, die sich in kürzeren Intervallen ändern können als statische Tarife, und anreizbasierte Verschiebung, welche dem Endverbraucher die Entscheidung überlässt, einem Anreiz zu folgen. Noch kurzfristiger ist physikalisches Demand-Response durch bindende Verlagerungssignale und Notfallsignale. Regelenergie mittels DSM bildet das kurzfristige Ende des Spektrums und umfasst die frequenzabhängige Primärregelung und die Sekundärregelung.

Im Unterschied zu Gellings [98], welcher den Schwerpunkt auf die Lastkurvenformung legt, stehen bei Palensky und Dietrich die Maßnahmen und Wirkungshorizonte im Mittelpunkt [228]. Diese Maßnahmen ermöglichen eine Spitzenlastkappung, Talfüllung, Lastverlagerung und flexible Lastfüh-

rung. Auch wenn die strategische Lasterhöhung – im Gegensatz zur Energieeffizienz – nicht explizit aufgeführt wird, ist diese Teil der allgemeinen Definition. Insofern sind die Definitionen von Gellings sowie Palensky und Dietrich ähnlich, betrachten DSM jedoch aus einem anderen Blickwinkel.

Eto liefert eine weitere Definition für DSM, die sowohl Gesamtenergieverbrauch als auch Verbrauchsmuster herausstellt [83, Kap. 2]:

DSM encompasses a variety of utility activities designed to change the level or timing of customers' electricity demand.

Er unterteilt DSM-Programme in sieben Kategorien. Fünf dieser Kategorien bezwecken eine strategische Lastsenkung, zum Beispiel durch Informationsprogramme oder Installation energieeffizienter Technologien. Eine weitere Kategorie umfasst direkte Lastkontrolle beim Endkunden sowie Lastverschiebung mittels Speichertechnologien. Zur letzten DSM-Kategorie gehören statische und dynamische zeitvariable Tarife. Mittels dieser Programme können die von Gellings aufgeführten Ziele [98], bis auf die strategische Lasterhöhung, erreicht werden. Neben den bereits genannten Zielen kann direkte Lastkontrolle zur Spitzenlastkappung und Talfüllung eingesetzt werden. Dynamische zeitvariable Stromtarife, die in Echtzeit angepasst werden können, lassen sich der flexiblen Lastführung zuordnen.

Wie die vorgestellten Arbeiten zeigen, gibt es zahlreiche Definitionen für DSM, Demand-Response und Lastmanagement. Diese sind zwar ähnlich, jedoch nicht identisch. In dieser Arbeit werden die Begriffe DSM und Lastmanagement – ähnlich wie von Gellings [98] – wie folgt definiert.

Definition (DSM). *DSM umfasst alle Aktivitäten zur Beeinflussung zeitlicher Verbrauchsmuster, welche auf Spitzenlastkappung, Auffüllen von Lasttälern, Lastverlagerung oder flexible Lastführung abzielen. Ferner beinhaltet DSM alle Aktivitäten zur Änderung des Gesamtenergieverbrauchs mit dem Ziel einer langfristigen Lastsenkung oder -erhöhung.*

Definition (Lastmanagement). *Lastmanagement ist das Teilgebiet des DSM, welches die Änderung der zeitlichen Verbrauchsmuster umfasst.*

Im Mittelpunkt dieser Arbeit steht die flexible Lastführung, da diese das allgemeinste Ziel darstellt. Damit können die anderen Teilziele des Lastmanagements erreicht werden.

2.2.2 Ansätze

Obwohl der Begriff DSM erst 1984 geprägt wurde, existieren die Konzepte des DSM und des Lastmanagements schon seit über vier Jahrzehnten. 1978 wurden diese erstmals in die Gesetzgebung integriert [317]. Mit dem *National Energy Conservation Policy Act* und dem *Public Utility Regulatory Policy Act* reagierten die Vereinigten Staaten von Amerika auf die Unsicherheiten in der Energiepolitik der 1970er Jahre und die steigenden Energiepreise. Die Gesetze sollten Energiesparbemühungen vorantreiben und den Energieversorgern die Möglichkeit bieten, Lastmanagement-Programme auf den Weg zu bringen [159]. Durch diese Programme sollten Lastspitzen gesenkt werden, um den Ausbaubedarf der Stromnetze zu verringern [290]. Bedingt durch den steigenden Anteil dezentraler und volatiler Einspeisung und durch die Diskussion um intelligente Stromnetze hat das Thema Lastmanagement bis heute nicht an Aktualität verloren. Einen geschichtlichen Überblick über die Thematik liefern die Arbeiten [50, 83, 317].

Seit den Anfängen wurden zahlreiche Ansätze für das Lastmanagement entworfen. Einige wurden in Stromnetzen dauerhaft umgesetzt oder in Feldversuchen erprobt. Dieses Kapitel gibt einen Überblick über die *Konzepte* des Lastmanagements. Übersichten über implementierte Programme können den Arbeiten [2, 159, 275] entnommen werden. Die Internationale Energieagentur fasst 64 weltweit durchgeführt Projekte zusammen [144] und Torriti *et al.* stellen die Umsetzungen speziell in Europa dar [304].

Im Folgenden werden bestehende Lastmanagement-Ansätze vorgestellt. Diese können folgendermaßen klassifiziert werden:

- Direkte Lastkontrolle
- Abschaltbare Lasten
- Variable Strompreise
 - Statische zeitvariable Stromtarife
 - Dynamische zeitvariable Stromtarife
 - Echtzeit-Tarife
- Marktbasierte Ansätze
- Dezentrale Koordination

Direkte Lastkontrolle und abschaltbare Lasten

Eine klassische Form des Lastmanagements stellt die direkte Lastkontrolle dar. Zu diesem Zweck erteilen Endkunden einer zentralen Instanz, beispielsweise ihrem Energieversorgungsunternehmen, das Recht, bestimmte Geräte fernzusteuern. Meist werden diesbezüglich thermische Speicher [170, 312] und Klimaanlage [116, 338] genutzt. Die Eingriffe umfassen das Ein- und Ausschalten der Geräte oder das Setzen von Solltemperaturen. Als Ziel-funktion der Lastkontrolle werden oftmals die Betriebskosten oder die Höhe von Spitzenlasten genutzt [255]. Zu deren Minimierung kommen diverse Methoden zum Einsatz. Häufig werden dynamische Programmierung [19, 136, 320], lineare Programmierung [215], Fuzzylogik [29, 106] oder Scheduling-Algorithmen [6, 84] verwendet. Ein wichtiger Aspekt direkter Steuerung ist der Komfortverlust der Bewohner. Dieser wird in einigen Arbeiten modelliert und in der Optimierung berücksichtigt [56, 107, 111]. Newsham und Bowker haben weitere Studien zur direkten Lastkontrolle zusammengefasst [214].

Eng mit der direkten Lastkontrolle verwandt sind abschaltbare Lasten. Dabei wird kurzfristig auf Abruf für eine definierte Zeit die Verbrauchsleistung auf einen angeforderten Betrag reduziert. Im Unterschied zur direkten Lastkontrolle erfolgt die Steuerung durch die Verbraucher selbst. Teilweise werden abschaltbare Lasten in Kombination mit direkter Lastkontrolle genutzt [138]. Weitere Steuerungsverfahren für abschaltbare Lasten sind beispielsweise in den Arbeiten [53, 137] beschrieben. Die Steuerung kann auch in Verbindung mit der Einsatzplanung von Kraftwerken [15, 306] erfolgen, dem sogenannten Unit Commitment [227]. Hierbei werden die physikalischen Restriktionen von Stromnetzen in die Optimierung einbezogen.

Direkte Lastkontrolle und abschaltbare Lasten bergen mehrere entscheidende Nachteile. Zum einen ist die Steuerungskomplexität bei einer großen Menge von Verbrauchern sehr hoch [52], da diese einzeln gesteuert werden. Zum anderen geben Endkunden einen Teil ihrer Autonomie ab. Ferner kann ein sogenannter Rebound-Effekt auftreten [54, 82, 138, 214]: Während eines Kontrolleingriffs eingesparte Energie wird unmittelbar nach Beendigung des Eingriffs verbraucht und führt zu einer Lastspitze. Wurde beispielsweise eine Klimaanlage heruntergeregelt, so wird diese später die gewünschte Temperatur wiederherstellen. Synchronisieren sich auf diese Weise viele

Lasten, stellt sich nach einer Lastspitzenkappung eine neue Lastspitze ein, welche höher sein kann als die ursprünglich vermiedene.

Der in dieser Arbeit entwickelte Lastmanagement-Ansatz weist diese Probleme nicht auf. Rebound-Effekte werden vermieden, indem über einem Planungshorizont optimiert wird, innerhalb dessen die elektrische Energie verschoben wird. Zudem entscheiden Verbraucher oder Aggregationen von Verbrauchern in diesem skalierbaren, hierarchischen Ansatz selbstständig über ihren Energieverbrauch. Mit der Wahrung der Autonomie können Akzeptanzprobleme durch häufige Interventionen reduziert werden. Direkte Lastkontrolle und abschaltbare Lasten wurden für Notfallsituationen entwickelt und sollten selten genutzt werden [7], da diese einen Komfortverlust für Endkunden bedingen. Häufen sich solche Situationen durch zunehmend volatile Erzeugung, so steigt auch die Zahl der Eingriffe.

Variable Strompreise

Neben den direkten Formen des Lastmanagements, welche externen Instanzen Steuerungsmöglichkeiten einräumen, existiert eine Reihe von indirekten Lastmanagement-Ansätzen. Hierbei behalten Kunden ihre Steuerungskompetenz und werden anhand von Anreizen oder Steuersignalen gelenkt. Der Unterschied zum direkten Lastmanagement besteht darin, dass Kunden den Anreizen oder Signalen *ad libitum* folgen können oder auch nicht. So entscheiden sie, ob sie einen damit verbundenen finanziellen Vorteil wahrnehmen oder einen finanziellen Nachteil in Kauf nehmen wollen. Im Folgenden werden strompreisbasierte indirekte Verfahren vorgestellt.

Die Preise an Großhandelsmärkten für Strom schwanken stark zwischen den Zeiten mit niedrigem und hohem Stromverbrauch [267]. Endverbraucher bemerken diese Preisunterschiede jedoch meist nicht, da deren Strompreise normalerweise fest sind. Damit haben Kunden keinen Anreiz, ihre Verbrauchszeiten an Preisen zu orientieren. Daher wurden Lastmanagement-Ansätze entwickelt, die auf variablen Strompreisen beruhen. Hierbei wurden verschiedene Varianten umgesetzt [122, Kap. 3.3], die anhand ihrer Dynamik klassifiziert werden können. Die höchste Planbarkeit für Verbraucher liefern statische zeitvariable Stromtarife (englisch: *time-of-use tariffs*). Darin variieren die Preise zwischen verschiedenen Zeitblöcken [1, 48, 62]. Im einfachsten Fall gibt es zwei Blöcke [115], beispielsweise wenn für die

Nacht ein Niederstromtarif angeboten wird. Da statische zeitvariable Tarife im Normalfall mehrere Tage oder Wochen im Voraus festgelegt werden, kann nicht auf kurzfristige Ereignisse reagiert werden. Dies ist mit dynamischen zeitvariablen Tarifen (englisch: *critical peak pricing*) möglich. Im Bedarfsfall wird hierfür ein flacher oder ein statischer zeitvariabler Tarif kurzfristig für einen beschränkten Zeitraum geändert [86, 87, 119]. Die geringste Planbarkeit für Kunden bietet Echtzeit-Bepreisung (englisch: *real-time pricing*) [97, 108, 166, 223]. Dabei ist die Zeitspanne zwischen der Mitteilung der Strompreise und deren Inkrafttreten sehr kurz. In der Literatur gibt es hierzu verschiedene Angaben. Es wurden beispielsweise Zeiträume von maximal einem Tag [4] oder einer Stunde [339] festgelegt.

Ergänzend zu Strompreissignalen können auch Steuersignale versendet werden, die eine weitergehende Beeinflussung des Verbrauchsverhaltens erlauben. Eine Möglichkeit stellt die Beschränkung des Maximalverbrauchs dar, die für jeden einzelnen Verbraucher [13, 191, 336] oder für die Summe aller Verbraucher [161] erfolgen kann. Ramchurn *et al.* setzen ein Signal ein, das den CO₂-Ausstoß pro Energieeinheit abbildet [256]. Hillemacher nutzt Regelsignale, um eine relative Laständerung hervorzurufen [122].

Strompreissignale setzen Anreize, den Verbrauch in niedrigpreisige Zeitabschnitte zu verlagern. Zum Zeitpunkt der Generierung von Preissignalen ist die genaue Reaktion der Verbraucher noch unbekannt. Um dennoch das Lastverlagerungspotenzial zu berechnen, werden von der Instanz, welche die Signale generiert, Preiselastizitäten geschätzt. Diese beschreiben die Verbrauchssensitivität gegenüber Preisen [202]. Die realen Elastizitäten sind normalerweise unbekannt und hängen von vielen Faktoren ab. Mit preisbasierten Ansätzen ist im Vorfeld daher nur eine approximative Abschätzung der anfallenden Last möglich. Ferner können Strompreissignale Rebound-Effekte auslösen [96, 161]. Im Rahmen des in dieser Arbeit vorgestellten Ansatzes wird das Lastverlagerungspotenzial von den Verbrauchern selbst berechnet und gemeldet. Damit ist keine Schätzung von einer zentralen Instanz nötig, die potenziell mit höherer Unsicherheit behaftet ist.

Marktbasierte Ansätze

Elektronische Märkte finden in verschiedenen Bereichen Anwendung, beispielsweise bei der Ressourcenallokation, beim Scheduling oder zur Lö-

sung von Optimierungsproblemen [331]. Marktmechanismen werden zudem auch für das Lastmanagement eingesetzt [185]. Hierzu übermitteln Kunden Angebote in Form von Kurven, welche den Verbrauch oder die Verbrauchsänderung in Abhängigkeit des Strompreises beschreiben, an einen Markt [296, Kap. 2.2]. Zusammen mit den Angeboten der Erzeuger wird ein Clearing-Preis ermittelt. Dieser stellt das Signal für die Verbraucher dar, ihre Last anzupassen. Unter diesem Gesichtspunkt sind die marktbasierenden Ansätze zwischen den direkten und den indirekten Verfahren angesiedelt.

Zum Lastmanagement werden diverse Marktformen, Auktionsmechanismen, Bietstrategien und Preisfindungsalgorithmen genutzt (ökonomische Grundlagen können [182, 213] entnommen werden). Ein wichtiges Unterscheidungsmerkmal der Verfahren ist die Anzahl der Zeitintervalle, für die Energie gleichzeitig gehandelt wird. Einerseits gibt es Märkte für genau ein Intervall. Bei diesem Modell sind einzelne Intervalle unabhängig voneinander. Chen *et al.* untersuchen sowohl oligopolistische als auch kompetitive Märkte, um den Energieverbrauch an eine feste Erzeugung anzupassen [55]. Die Kunden bieten hierfür mittels linearer Angebotsfunktionen Laständerungen an. Nguyen *et al.* nutzen quadratische Angebotsfunktionen [216], wobei nur Lastkürzungen angeboten werden, jedoch nicht Lasterhöhungen. Preise und Laständerungen werden durch Lösen eines nichtlinearen Programms ermittelt. Dieselben Autoren nutzen auch Walrasianische Auktionen zur Preisermittlung [217]. Andererseits existieren Märkte, auf denen für mehrere Zeitintervalle gleichzeitig gehandelt wird. So bestimmen Su und Kirschen die Verbrauchsmengen an einem Day-Ahead-Markt unter Berücksichtigung linearer Grenznutzenfunktionen der Angebote [297]. Zur Preisfindung wird ein gemischt-ganzzahliges lineares Programm gelöst, wobei die Preise für alle Zeitintervalle eines Tages gleichzeitig ermittelt werden. Die Preisbestimmung kann auch auf ein Unit Commitment mit linearen Angebotsfunktionen der Verbraucher zurückgeführt werden [158].

Einige marktbasierende Ansätze beziehen bei der Preisbestimmung physikalische Netzrestriktionen ein. Oftmals werden aber nur maximale Leitungskapazitäten [206, 328] oder Übertragungskapazitäten zwischen Netz-Zonen [224] betrachtet. Es reicht jedoch nicht, die Spannung als 1 pu anzunehmen und die Blindleistung zu vernachlässigen, da Spannungsabweichungen ein häufiger Grund für Instabilitäten in Stromnetzen sind [58]. Manche Arbeiten beziehen daher auch die Spannungswerte mit ein [58, 201].

Der Handel an Märkten kann auch aus spieltheoretischer Sicht analysiert werden, indem Auktionen als Spiele aufgefasst werden. Käufer und Verkäufer sind in diesem Fall die Spieler. Die Angebotsfunktionen stellen ihre Strategien dar und der Gewinn ist abhängig von dem ermittelten Preis. Das Ziel ist es, ein Nash-Gleichgewicht zu finden [157]. Beispielsweise werden Vickrey-Auktionen unter spieltheoretischen Aspekten [173] sowie nicht-kooperative Auslastungsspiele zur Preisfindung untersucht [143]. Saad *et al.* geben eine Einführung in Spieltheorie sowie eine weiterführende Übersicht über spieltheoretische Ansätze im Lastmanagement [266].

Energieverbraucher, die an einem Lastmanagement teilnehmen, besitzen Freiheitsgrade bezüglich ihres Verbrauchs. Geräte, die oftmals herangezogen werden, sind Kühlschränke. Sofern deren Innentemperatur innerhalb eines bestimmten Intervalls bleibt, können die Zeiten variiert werden, zu denen Energie aufgenommen wird. Dies gilt auch für Klimaanlage und andere Geräte mit einem thermischen Speicher. Der thermische Zustand solcher Verbraucher zu einem spezifischen Zeitpunkt hängt unmittelbar von den vorhergehenden Zuständen ab. Um also ein Lastverlagerungsangebot für einen zukünftigen Zeitpunkt zu unterbreiten, müssen die Zustände bekannt sein, die zwischen jenem und dem aktuellen Zeitpunkt liegen. Angebotsfunktionen stellen eine Möglichkeit dar, diese Komplexität zu umgehen [203]. Die im Rahmen der Literaturanalyse betrachteten Ansätze umfassen keine realistische Methodik zur Abbildung der zeitlichen Abhängigkeiten auf Angebotsfunktionen für gleichzeitig mehrere aufeinanderfolgende Zeitpunkte. In manchen Fällen werden zwar temporale Zusammenhänge modelliert, diese sind jedoch nicht umfassend genug, die Realität adäquat zu beschreiben. So werden beispielsweise minimale und maximale zusammenhängende Verbrauchszeiten [158] oder Preiselastizitäten zwischen verschiedenen Zeitpunkten [315] berücksichtigt. Damit können die Zustände thermischer Speicher jedoch nicht erfasst werden. Eine weitere Möglichkeit, komplexe intertemporale Abhängigkeiten zu umgehen, ist die Beschränkung der Betrachtungen auf jeweils ein einziges Zeitintervall. Auf Märkten, die Laständerungen handeln, können allerdings Rebound-Effekte auftreten, wenn die Zeitintervalle unabhängig voneinander betrachtet werden [295].

Angebotsfunktionen sind meist stetig und konvex, da dies die Preisfindung erleichtert oder überhaupt erst ermöglicht. Aus der Stetigkeit folgt, dass die Verbrauchsänderung eine kontinuierliche Variable ist. In realen

Haushalten sind diese Größen hingegen oft diskret oder gemischt diskret und kontinuierlich [49, 200], da die Leistungsaufnahme einiger flexibler Geräte, wie Waschmaschinen, Wäschetrockner oder Geschirrspülmaschinen, nicht kontinuierlich gesteuert werden kann. Daher ist die Stetigkeitsannahme nicht in allen Fällen gerechtfertigt.

Der in dieser Arbeit entwickelte Ansatz benötigt keine Beschreibung von Laständerungen mittels Funktionen. Anstatt dessen werden Lastgänge genutzt, sodass intertemporale Zusammenhänge berücksichtigt werden können. Insbesondere wird keine Annahme bezüglich Stetigkeit und Konvexität getroffen.

Dezentrale Koordination

Eine weitere Möglichkeit, Lastmanagement zu betreiben, besteht im Einsatz dezentraler Verfahren. Diese streben eine Koordination der Last mittels lokaler Interaktionen von Verbrauchern an. In den Arbeiten von Li *et al.* kommunizieren Verbraucher indirekt mittels Stigmergie [174–176]. Hierfür nutzen sie ein Medium, auf dem sie ihren prognostizierten Verbrauch bekannt geben. Darüber hinaus existiert ein weiterer Agent, welcher die Summe aller Verbräuche auf dem Medium veröffentlicht. Das Ziel des Systems wird in Form des maximal erlaubten Gesamtverbrauchs ebenfalls auf dem Medium mitgeteilt. So erhalten die einzelnen Verbraucher die Möglichkeit, ihren Lastgang für den Planungshorizont iterativ bis zur Konvergenz oder zum Eintritt eines Abbruchkriteriums zu adaptieren. Bei Hinrichs *et al.* basiert die Kommunikation zwischen Verbrauchern ebenfalls auf Stigmergie, ist jedoch auf lokale Nachbarschaften beschränkt [125]. Die Verbraucher passen ihre prädierten Lastgänge an, bis die Abweichung des Lastgangs der Nachbarschaft von einem Ziel-Lastgang möglichst gering ist. In den Arbeiten von Kamper kommunizieren Verbraucher direkt miteinander, um Fahrplanänderungen zu koordinieren und einen Ziel-Lastgang umzusetzen [154–156]. Weitere dezentrale Ansätze finden sich in den Arbeiten [161, 246].

Kennzeichnend für die dezentralen Verfahren ist das Fehlen einer zentralen Kontrollinstanz. Dies hat einerseits den Vorteil, dass die Verfahren in der Regel mit zunehmender Anzahl an Verbrauchern gut skalieren. Andererseits können aber keine Netzrestriktionen beim Lastmanagement berücksichtigt

werden, da Lastflüsse zentral berechnet werden müssen. Um sowohl eine gute Skalierbarkeit zu gewährleisten als auch die Netzrestriktionen zu beachten, verfolgt diese Arbeit einen hierarchischen Ansatz. Darin findet eine Auswahl von Lastverlagerungsangeboten an zentraler Stelle statt. Die Angebote werden jedoch von Entitäten unterbreitet, die autonom agieren.

2.3 Erzeugungsmanagement

Während das relativ neue Paradigma der Nachfragesteuerung zunehmend an Bedeutung gewinnt, ist ein Management der Erzeugungsseite unabdingbar für Stromnetze. Wie beim DSM werden auch hier verschiedene Zeithorizonte unterschieden: von der Netz- und Kraftwerksausbauplanung [74, 109, 253], welche Jahre im Voraus betrieben wird, bis hin zur Primärregelung [60, 204] in Echtzeit. Im Mittelpunkt dieser Arbeit steht fahrplanbasiertes Energiemanagement, welches Lastmanagement und Erzeugungsmanagement integriert betrachtet, wobei der Zeithorizont von einigen Minuten bis hin zu mehreren Stunden reicht. Dabei kann Erzeugungsmanagement wie folgt definiert werden.

Definition (Erzeugungsmanagement). *Erzeugungsmanagement bezeichnet die Anpassung der Energieerzeugung hinsichtlich vorgegebener Kriterien.*

Traditionell wird der Einsatz von konventionellen Kraftwerken am Vortag zentral geplant mit dem Ziel einer kostenoptimalen Energieerzeugung. Hierbei muss ein prognostizierter Verbrauch gedeckt werden. Dieses Optimierungsproblem wird als Economic Dispatch bezeichnet. Werden zusätzlich Leitungskapazitäten berücksichtigt, handelt es sich um ein Security-Constrained Economic Dispatch. Beim Economic Dispatch werden Fahrpläne für die betriebsbereiten Kraftwerke basierend auf deren Erzeugungskosten festgelegt. Im Unterschied dazu werden beim Unit Commitment die Betriebszeiten von Kraftwerken geplant. Diese Planung erfolgt normalerweise für einen Tag bis hin zu einer Woche und berücksichtigt Regelreserven. Ein weiteres klassisches Optimierungsproblem ist der Optimal Power Flow. Ziel dabei ist es, die optimalen stationären Betriebsverhältnisse von Stromnetzen zu bestimmen. Optimalität bezieht sich dabei beispielsweise auf Erzeugungskosten, Systemverluste, Emissionen oder Anzahl von Steue-

ungsmaßnahmen. Typische Steuerungsgrößen sind Energieerzeugung sowie Einstellungen von Betriebsmitteln wie Transformator-Stufenstellern, Phasenschiebern oder schaltbaren Kondensatoren. Die Optimierung wird unter Berücksichtigung von Netzrestriktionen durchgeführt. Eine mathematische Formulierung der beschriebenen Optimierungsprobleme sowie Lösungsmethoden werden von Zhu vorgestellt [341]. Darüber hinaus wurden modellprädiktive Verfahren vorgeschlagen [121], die neben konventionellen Kraftwerken auch erneuerbare Erzeugungskapazität und Speicher in die Optimierung einbeziehen. Diese können auch dezentral ausgeführt werden [151, 153].

Neben den klassischen Ansätzen können manche der Lastmanagement-Verfahren zudem für das Erzeugungsmanagement eingesetzt werden. Wie von Hillemacher beschrieben, eignen sich Strompreissignale dazu, die Einspeisung steuerbarer Erzeugungsanlagen in Zeitabschnitte zu verlegen, in denen eine höhere Vergütung gezahlt wird [122]. Marktbasierende Ansätze können sowohl Angebote von flexiblen Verbrauchern als auch Erzeugern verbinden [17, 30, 264, 265]. Spieltheoretische Betrachtungen wurden ebenfalls angestellt [318, 342]. Ferner existieren auch dezentrale Verfahren zur Koordinierung von Erzeugungsanlagen [124, 125].

Derzeit sind Stromnetze durch eine Zunahme von dezentraler Einspeisung geprägt. Für viele dieser Anlagen ist die individuelle Teilnahme an Energiemärkten – bedingt durch Größenbeschränkungen – nicht möglich. Darüber hinaus ist die Teilnahme oftmals nicht attraktiv aufgrund der Gefahr, das angebotene Erzeugungsprofil nicht einhalten zu können. Vor diesem Hintergrund wurden virtuelle Kraftwerke entwickelt, um die Freiheitsgrade von dezentralen Energieerzeugungsanlagen zu nutzen. Ein virtuelles Kraftwerk ist ein Verbund von dezentralen Erzeugungsanlagen und steuerbaren Verbrauchern, der nach außen hin wie ein einziges Kraftwerk auftritt [251]. Solch eine Aggregation reduziert die Steuerungskomplexität auf einer übergeordneten Ebene, da nicht mehr die einzelnen Teilsysteme separat gesteuert werden müssen. Darüber hinaus kann der Verbund ab einer bestimmten Größe Netzdienstleistungen anbieten, auch wenn dies den einzelnen Entitäten aufgrund von regulatorischen Bestimmungen verwehrt bleibt. Mit steigender Anzahl an Erzeugungsanlagen und steigender Diversifikation der Erzeugungstechnologien kann für die Teilnahme an Energiemärkten das Prognoserisiko reduziert werden.

Basierend auf deren Einsatzzweck werden technische und kommerzielle virtuelle Kraftwerke unterschieden [251]. Technische virtuelle Kraftwerke sind in der Lage, Netzdienstleistungen anzubieten. Sie bestehen aus Entitäten, die im selben Netzgebiet liegen und deren Standort bekannt ist. Unter Kenntnis des elektrischen Netzes ist es möglich, den Netzzustand in den Betrieb des virtuellen Kraftwerks einzubeziehen. Beispiele für technische virtuelle Kraftwerke finden sich in den Arbeiten [183, 184, 241]. Dagegen finden in kommerziellen virtuellen Kraftwerken die physikalischen Netze keine Berücksichtigung. Stattdessen wird die wirtschaftliche Nutzung der Entitäten auf Elektrizitätsmärkten optimiert. Die einzelnen Entitäten müssen somit nicht auf derselben Spannungsebene oder in geographischer Nähe zueinander liegen. Ansätze für kommerzielle virtuelle Kraftwerke wurden beispielsweise in den Arbeiten [113, 231, 325, 345] veröffentlicht.

Microgrids [168] stellen einen weiteren Ansatz dar, Stromnetze in Zonen zu gliedern, die unabhängig voneinander gesteuert werden können. Bei diesen steht ein Inselbetrieb und somit auch der Echtzeit-Aspekt im Mittelpunkt. Daher werden Microgrids an dieser Stelle nicht weiter betrachtet.

Der in Kapitel 6 vorgestellte Ansatz bindet Erzeugungsanlagen und Verbraucher in ein fahrplanbasiertes Energiemanagement ein, welches Netzzustände berücksichtigt. Wie bei virtuellen Kraftwerken werden Aggregationen von Subsystemen gebildet, die nach außen als Einheit auftreten. Die in Kapitel 4 beschriebene Architektur ist darüber hinaus in der Lage, netzebenenübergreifende Aggregationen abzubilden, wie sie beispielsweise in kommerziellen virtuellen Kraftwerken vorkommen.

Rahmenszenario

Das Rahmenszenario, welches im Folgenden beschrieben wird, umfasst das Last- und Erzeugungsmanagement in Smart Grids. Im zugrundeliegenden Stromnetz befinden sich herkömmliche und intelligente Erzeuger und Verbraucher. Diese werden durch ihre Leistungsprofile charakterisiert, welche aufgrund des Vorzeichens der Leistung eine Unterscheidung zwischen Erzeugung und Verbrauch gewährleisten. Da das Energiemanagement auf Basis der Leistungsprofile erfolgt, wird im Sinne einer einheitlichen Betrachtungsweise für Erzeuger und Verbraucher der Überbegriff *Entität* genutzt. Die intelligenten Entitäten stehen im Mittelpunkt der Betrachtungen, so dass diese im Folgenden einfach als Entitäten bezeichnet werden. Handelt es sich um herkömmliche, d. h. nichtintelligente, Entitäten, so wird explizit darauf hingewiesen.

Mit dem Begriff der Entität wird keine Festlegung getroffen, welcher Art Verbraucher oder Erzeuger konkret sind. Es können beispielsweise Waschmaschinen, Haushalte, virtuelle Kraftwerke oder auch komplette Strom-Subnetze sein. In Kapitel 4 wird eine Architektur für Energiemanagement-Systeme präsentiert, welche diverse Entitäten auf verschiedenen Hierarchieebenen einbindet.

Die Entitäten stellen einem Energiemanager gegen Bezahlung Flexibilität bezüglich ihres Leistungsprofils zur Verfügung. Der Energiemanager führt eine flexible Leistungsführung derart durch, dass er das Leistungsprofil des Netzes an ein Zielprofil annähert. Hierfür wählt er aus Angeboten von Entitäten die geeigneten aus. Neben dem Zielprofil spielen auch Kosten für die Nutzung der Flexibilität eine Rolle. Die flexible Leistungsführung erfolgt unter Beachtung der physikalischen Bedingungen, denen das Stromnetz unterliegt. Um eine Abgrenzung zu der in Abschnitt 2.2 beschriebenen fle-

xiblen Lastführung zu ermöglichen, wird der Begriff der flexiblen Leistungsführung genutzt. Erstere berücksichtigt nur die Nachfrageseite, während letztere sowohl die Nachfrage- als auch die Erzeugungseite umfasst.

Dieses Kapitel präsentiert zunächst die allgemeinen Annahmen, auf welchen das Rahmenszenario basiert. Darauf aufbauend werden die Modellierungen konkreter Erzeuger und Verbraucher und die eines Stromnetzes für Simulationen vorgestellt. Das Rahmenszenario ist die Grundlage für die Darstellungen und Analysen der darauffolgenden Kapitel. Diese betrachten zwar abgeleitete Szenarien, jedoch gelten die in diesem Kapitel präsentierten Annahmen und Modellierungen unverändert.

3.1 Annahmen

Das Rahmenszenario unterliegt der zentralen Annahme, dass Nachfrage von Energie zu einem gewissen Grad zeitlich variabel ist. Zwar können Entitäten ihren Verbrauch verlagern, dieser bleibt aber in Summe über den Planungshorizont gleich. Ferner kann die erzeugte Energiemenge innerhalb bestimmter Intervalle angepasst werden. Weitere Annahmen bezüglich der Entitäten und des Energiemanagements werden nachfolgend dargestellt.

3.1.1 Entitäten

Es wird davon ausgegangen, dass die Entitäten eine Steuereinrichtung besitzen, um Lastverschiebungen automatisiert durchzuführen. Somit sind die Entitäten in der Lage, kurzfristig auf externe Signale eines Energiemanagers zu reagieren. Ein Beispiel für eine solche Umsetzung ist das in Abschnitt 2.1.3 vorgestellte Organic Smart Home. Das interne Energiemanagement einer Entität obliegt dieser selbst. Diese kann auf externe Signale eines Energiemanagers reagieren, muss dies aber nicht. Somit gibt es keine direkten Eingriffe einer übergeordneten Instanz. Neben den intelligenten Entitäten befinden sich auch konventionelle Entitäten, die keine Steuereinrichtung und folglich keine Lastflexibilität besitzen, im Stromnetz. Diese müssen ebenfalls berücksichtigt werden, da im Rahmen des Energiemanagements Leistungsflussberechnungen durchgeführt werden.

Ferner wird davon ausgegangen, dass jede Entität eine Prognose ihres Leistungsprofils – einen sogenannten Fahrplan – bis zu 24 Stunden im Vor-

aus mit einer zeitlichen Auflösung von 15 Minuten erstellen kann. Der Fahrplan stellt eine Zeitreihe $\underline{L}^{\text{pred}}$ dar, welche Wirkleistung p_t und Blindleistung q_t für die äquidistanten Zeitschritte $t = 1, \dots, T$ umfasst:

$$\underline{L}^{\text{pred}} = \{ \underline{L}_t^{\text{pred}} \}_{t=1, \dots, T} = \left\{ \begin{pmatrix} p_t \\ q_t \end{pmatrix} \right\}_{t=1, \dots, T}.$$

Innerhalb des Zeitintervalls, welches durch einen Zeitschritt repräsentiert wird, ist die Leistung als konstant angenommen. Da alle Zeitintervalle die gleiche Länge aufweisen, können die Begriffe Leistung und Verbrauch im Folgenden sinnlich verwendet werden. Hierbei beziehen sich positive Werte auf eine Energieerzeugung, während negative Werte einen Energieverbrauch angeben. In den betrachteten Szenarien gilt bei einem maximalen Planungshorizont von 24 Stunden und einer zeitlichen Auflösung von 15 Minuten stets $T \leq 96$. In der genutzten Notation werden Zeitreihen durch unterstrichene Großbuchstaben bezeichnet und Vektoren durch unterstrichene Kleinbuchstaben. Skalare werden ohne Unterstreichung dargestellt.

Das prognostizierte Profil einer Entität bildet die Grundlage für deren Abrechnung. Ähnlich einem Bilanzkreis im liberalisierten Strommarkt ist die Entität dafür verantwortlich, das geplante Leistungsprofil tatsächlich umzusetzen. Mit dieser Annahme wird verhindert, dass Entitäten versuchen, spekulativ ihren Gewinn zu steigern ohne eine Gegenleistung zu erbringen. Würden keine prognostizierten Profile gemeldet, könnten Entitäten ohne Überprüfungsmöglichkeit beliebige Leistungsverchiebungen angeben. Konkrete Bepreisungs- und Anreizmodelle für eine solche Abrechnung werden in dieser Arbeit nicht näher behandelt.

Konventionelle Entitäten sind nicht in der Lage, eine Prognose durchzuführen, besitzen jedoch Lastgangzähler. Diese erfassen die Leistung mit einer zeitlichen Auflösung von 15 Minuten und übermitteln die Werte an eine Instanz, welche eine Prognose für T Zeitschritte vornimmt.

Auf Basis ihres prädierten Profils kann eine Entität einem Energiemanager die Leistungsverlagerungen $\underline{L}^{\text{diff}}$ anbieten. Dabei handelt es sich um ein konkretes Verlagerungsprofil

$$\underline{L}^{\text{diff}} = \{ \underline{L}_t^{\text{diff}} \}_{t=1, \dots, T} = \left\{ \begin{pmatrix} \Delta p_t \\ \Delta q_t \end{pmatrix} \right\}_{t=1, \dots, T} \quad (3.1)$$

oder um ein intervallartiges Angebot

$$\underline{I}^{\text{diff}} = \{I_t^{\text{diff}}\}_{t=1,\dots,T} = \left\{ \left(\begin{array}{l} [\Delta p_t^{\min}, \Delta p_t^{\max}] \\ [\Delta q_t^{\min}, \Delta q_t^{\max}] \end{array} \right) \right\}_{t=1,\dots,T}. \quad (3.2)$$

Im ersten Fall wird für jeden Zeitpunkt eine feste Leistungsänderung angegeben. Das zweite Angebot gibt für jeden Zeitpunkt ein Intervall vor, innerhalb dessen der Energiemanager einen Wert für die Leistungsänderung festlegen kann. Diese Wahl ist über mehrere Zeitschritte hinweg nicht beliebig, sondern kann durch Nebenbedingungen der Entität eingeschränkt werden. Wie in Abschnitt 2.2.2 dargestellt, eignet sich Gleichung (3.1) insbesondere zur Beschreibung des Verlagerungspotenzials von Verbrauchern. Hingegen bietet Gleichung (3.2) eine höhere Flexibilität, die vor allem für Energieerzeuger von Nutzen ist. Eine mögliche Nebenbedingung ist dann beispielsweise die Beschränkung der Änderungsgeschwindigkeit der Leistung, wie in Abschnitt 6.3 dargelegt.

Aus dem prognostizierten Leistungsprofil und dem Verlagerungsangebot einer Entität kann das resultierende Profil

$$\underline{I}^{\text{adapt}} = \{I_t^{\text{adapt}}\}_{t=1,\dots,T} = \left\{ \left(\begin{array}{l} p_t + \Delta p_t \\ q_t + \Delta q_t \end{array} \right) \right\}_{t=1,\dots,T}$$

ermittelt werden. Für Angebot (3.1) können die Werte für Δp_t und Δq_t direkt übernommen werden, während diese für Angebot (3.2) innerhalb der vorgegebenen Intervalle von einem Energiemanager gewählt werden müssen.

Nimmt der Energiemanager ein Angebot an, so führt die entsprechende Entität die Verlagerung durch. Hierfür erhält diese vom Energiemanager eine Vergütung. Die Höhe der Vergütung wird von der Entität vor Angebotsabgabe festgelegt und spiegelt deren Kosten und Aufwand für die Leistungsverchiebung wider. So können beispielsweise höhere Kosten entstehen, wenn Strompreissignale mit verschiedenen Preisstufen eingesetzt werden. Falls es sich bei der Entität um einen Haushalt handelt, kommt es durch die Verlagerung möglicherweise auch zu Komforteinbußen, welche auf Grund der Vergütung in Kauf genommen werden.

Ein Angebot der Form (3.1) kann durch den Energiemanager entweder unverändert als Ganzes angenommen oder abgelehnt werden. Im Falle ei-

ner Annahme erhält die Entität die Vergütung $c_{\underline{L}^{\text{diff}}}$, welche vor Angebotsabgabe festgelegt worden war, und fährt das angepasste Profil $\underline{L}^{\text{adapt}}$ ab. Die Kosten für ein Angebot der Form (3.2) sind abhängig von den tatsächlich festgelegten Werten $\Delta p_t \in [\Delta p_t^{\text{min}}, \Delta p_t^{\text{max}}]$ und $\Delta q_t \in [\Delta q_t^{\text{min}}, \Delta q_t^{\text{max}}]$ für den Planungshorizont $t = 1, \dots, T$. Im Allgemeinen können die Kosten als Funktion $c(\underline{L}^{\text{diff}})$ ausgedrückt werden.

Die Entitäten müssen sich nicht auf die Abgabe eines einzelnen Verlagerungsangebots beschränken. Es können auch konkurrierende oder unabhängige Angebote unterbreitet werden. Aus einer Menge konkurrierender Angebote kann der Energiemanager maximal eines auswählen. Diese Angebote stellen Verlagerungsalternativen dar, die nicht gleichzeitig umgesetzt werden können. Solche Alternativen treten beispielsweise in Haushalten auf. Hier können Geräte wie Waschmaschinen oder Geschirrspüler in jedem Angebot mit verschiedenen Startzeiten eingeplant werden, sind jedoch nur einmal ohne Benutzereingriffe lauffähig. Aus einer Menge unabhängiger Angebote können beliebig viele ausgewählt werden. In Haushalten tritt dieser Fall auf, wenn unabhängige Geräte an jeweils höchstens einem Angebot beteiligt sind. Der Startzeitpunkt einer Waschmaschine könnte beispielsweise für ein Angebot verlagert werden, während der Geschirrspüler für ein anderes Angebot umgeplant wird.

3.1.2 Energiemanager

Um eine flexible Leistungsführung zu realisieren, stehen dem Energiemanager N Entitäten zur Verfügung. Diese geben bezüglich ihrer prognostizierten Profile

$$\underline{L}_n^{\text{pred}} = \left\{ \underline{L}_{tn}^{\text{pred}} \right\}_{t=1, \dots, T} = \left\{ \begin{pmatrix} p_{tn} \\ q_{tn} \end{pmatrix} \right\}_{t=1, \dots, T}, \quad n = 1, \dots, N,$$

eine Menge \mathcal{L} von V Verlagerungsangeboten ab:

$$\mathcal{L} = \left\{ \underline{L}_v^{\text{diff}} \mid v = 1, \dots, V \right\}.$$

Da keine Angebotspflicht besteht und jede Entität auch mehrere konkurrierende oder unabhängige Angebote unterbreiten kann, gilt im Allgemeinen $V \neq N$.

Von den unterbreiteten Angeboten akzeptiert der Energiemanager eine Teilmenge $\mathcal{B} \subseteq \mathcal{L}$, welche unter Berücksichtigung der Kosten zu einer möglichst guten Annäherung an ein Zielprofil

$$\underline{L}^{\text{ziel}} = \{p_t^{\text{ziel}}\}_{t=1,\dots,T}$$

führt. Im Idealfall wird das Zielprofil genau erreicht, jedoch ist dies aufgrund der nutzbaren Flexibilitäten nicht immer gewährleistet. In dieser Arbeit wird flexible Leistungsführung bezüglich der Wirkleistung analysiert, sodass $\underline{L}^{\text{ziel}}$ nur Wirkleistungen p_t^{ziel} umfasst. Die Blindleistung wird als gegeben angesehen und in den Leistungsflussberechnungen berücksichtigt.

Da der Energiemanager das Zielprofil sowie die Prognosen der Entitäten kennt, wird im Folgenden die Zeitreihe

$$\underline{A} = \{a_t\}_{t=1,\dots,T} = \left\{ p_t^{\text{ziel}} - \sum_{n=1}^N p_{tn} \right\}_{t=1,\dots,T}$$

der prognostizierten Abweichung vom Zielleistungsprofil betrachtet. Dabei wurde die Abweichung derart definiert, dass deren Vorzeichen mit dem Vorzeichen der angestrebten Verlagerung übereinstimmt. Die einzelnen Abweichungen sind ein Maß für die Präferenzen des Energiemanagers bezüglich der Leistungsverschiebungen. Je größer ein Wert a_t betragsmäßig ist, desto größer sollte die Leistungsänderung zum Zeitpunkt t sein, d. h. desto mehr Entitäten sollten sich tendenziell an der Verlagerung beteiligen.

Um Verlagerungsangebote von Entitäten abzurufen, teilt diesen der Energiemanager seine Präferenzen in Form diskreter Wahrscheinlichkeitsverteilungen mit. Zu diesem Zweck berechnet er – für die positiven und negativen Werte von \underline{A} separat – eine Verteilung bezüglich der diskreten Zeitpunkte. Hierfür werden die Werte a_t als absolute Häufigkeiten interpretiert und die entsprechenden relativen Häufigkeiten bestimmt. Die Verteilungen können von den Entitäten bei der Bestimmung ihrer Verlagerungsangebote genutzt werden. Zwar sind diese Verteilungen keine verpflichtenden Vorgaben, eine Konformität steigert jedoch die Chance, dass ein Angebot akzeptiert wird.

Bei der Auswahl der Angebote spielen zwei Faktoren eine Rolle. Zum einen sind dies die Kosten

$$f_1(\mathcal{B}) = \sum_{\underline{L}^{\text{diff}} \in \mathcal{B}} c(\underline{L}^{\text{diff}})$$

für die Inanspruchnahme der akzeptierten Angebote und zum anderen die Abweichung

$$f_2(\mathcal{B}) = \sum_{t=1}^T \left(\sum_{\underline{l}^{\text{diff}} \in \mathcal{B}} \underline{l}^{\text{diff}}(t, 1) - a_t \right)^2$$

vom Zielprofil. Hierbei bezeichnet $\underline{l}^{\text{diff}}(t, 1)$ das erste Element des Vektors $\underline{l}_t^{\text{diff}}$, also die Wirkleistungsänderung Δp_t . Als Maß für die gesamte Abweichung dient die Summe der quadratischen Abweichungen jedes Zeitschritts. Durch das Quadrieren werden große Abweichungen stärker gewichtet. Dieser Modellierung liegt somit die Annahme zugrunde, dass große Abweichungen gravierender sind als kleine. Dabei ist es irrelevant, ob die Abweichung positiv oder negativ ist.

Um eine flexible Leistungsführung umzusetzen, müssen Optimierungsprobleme formuliert werden, welche die zu berücksichtigenden Ziele und Nebenbedingungen umfassen und eine Auswahl der Verlagerungsangebote ermöglichen. Solche Optimierungsprobleme werden in Kapitel 6 für verschiedene Szenarien präsentiert. Hierbei stellen die prognostizierten Profile Vorgaben dar, welche später tatsächlich umgesetzt werden müssen. Aufgrund technischer und stochastischer Einflüsse können dabei Abweichungen auftreten. Diese werden jedoch nicht im Rahmen des fahrplanbasierten Ansatzes dieser Arbeit behandelt und müssen durch nachgelagerte Mechanismen, wie beispielsweise Primärregelleistung oder reaktive Einsatzplanung [305], ausgeglichen werden.

Ferner ist es für diese Arbeit unerheblich, wer die Rolle des Energiemanagers im Elektrizitätsversorgungssystem wahrnimmt. Das Management kann von bestehenden oder noch zu etablierenden Akteuren übernommen werden, wie zum Beispiel Bilanzkreisverantwortlichen, Energieversorgungsunternehmen, Energielieferanten, Energiedienstleistern, Netzbetreibern, Demand-Side-Managern oder dynamischen Bilanzkreisbewirtschaftern [123]. Die Akteure können bei der Durchführung der Aufgaben ganz unterschiedliche Ziele verfolgen und lokale oder auch globale Sichtweisen vertreten. Aufgrund der Universalität der Modellierung kann eine Vielzahl von Ansätzen abgebildet werden.

3.2 Konkretisierung der Entitäten

Der in dieser Arbeit entwickelte Energiemanagement-Ansatz basiert auf dem Konzept von generischen Entitäten, die Verbraucher oder Erzeuger darstellen können. Die Optimierungsprobleme, die in Kapitel 6 formuliert werden, sind so allgemein, dass eine Vielzahl verschiedener Entitäten abgebildet werden kann. Um eine Evaluierung durchzuführen, müssen jedoch konkrete Entitäten simuliert werden. Im Rahmenszenario wird ein Niederspannungsnetz betrachtet, das eine Menge von Haushalten und Photovoltaik-Anlagen umfasst. Deren Modellierung wird nachfolgend beschrieben.

3.2.1 Haushalte

Um Energiemanagement-Simulationen durchzuführen, müssen zunächst die Leistungsprofile der Haushalte generiert werden. Sind diese bekannt, können im nächsten Schritt Verschiebepotenziale ermittelt werden.

Generierung von Lastprofilen

Die Stromerzeugung im klassischen Energiesystem muss sich jederzeit dem Verbrauch anpassen. Daher werden möglichst genaue Lastdaten benötigt, um die Stromnetze zu entwerfen, zu betreiben und die Erzeugung zu planen. Da bisher in Deutschland bei kleinen Abnehmern zumeist keine Lastgangzähler installiert sind, bedient man sich sogenannter Standardlastprofile [196], welche die nicht gemessenen Lastprofile durch eine hinreichend genaue Prognose im Viertelstundentakt ersetzen sollen. Standardlastprofile werden für verschiedene Gruppen von Verbrauchern (Haushalte, Landwirtschaft, Gewerbe) genutzt, bei denen jeweils ein ähnliches Verbrauchsverhalten anzunehmen ist. Für große Zahlen von Stromverbrauchern liefert dieses Vorgehen eine relativ genaue Vorhersage, da sich Fluktuationen einzelner Verbraucher gegenseitig aufheben.

Da Verbrauchsmuster schwanken, werden unterschiedliche Lastprofile verwendet, die von Jahreszeit (Sommer, Übergangszeit, Winter) und von charakteristischen Tagen (Werktag, Samstag, Sonntag) abhängen. Abbildung 3.1a zeigt exemplarisch das deutsche Standardlastprofil H0 des Bundesverbands der Energie- und Wasserwirtschaft für die Sommermonate.

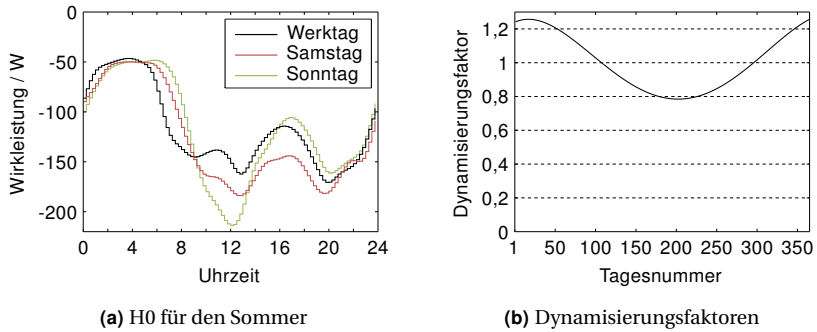


Abbildung 3.1 – Standardlastprofil H0 für einen Jahresverbrauch von 1000 kWh sowie Dynamisierungsfaktoren. Negative Leistungswerte geben einen Energieverbrauch an.

Hierbei weist – der Konvention in dieser Arbeit folgend – der Verbrauch ein negatives Vorzeichen auf. Das Profil H0 ist auf einen Jahresverbrauch von 1000 kWh normiert. Um einen glatteren Übergang zwischen Jahreszeiten zu erhalten, wird das Standardlastprofil dynamisiert [332, Kap. 4.2.1], indem die Verbrauchswerte jedes Tages mit einem zugehörigen Faktor multipliziert werden. Der Dynamisierungsfaktor $d(m)$ für den Tag m eines Jahres, mit $m = 1, \dots, 365$ bzw. $m = 1, \dots, 366$ für Schaltjahre, berechnet sich zu:

$$d(m) = -3,92 \cdot 10^{-10} \cdot m^4 + 3,2 \cdot 10^{-7} \cdot m^3 - 7,02 \cdot 10^{-5} \cdot m^2 + 2,1 \cdot 10^{-3} \cdot m + 1,24.$$

Der Verlauf der Dynamisierungsfunktion für ein gesamtes Jahr ist in Abbildung 3.1b dargestellt.

Die Standardlastprofile eignen sich dazu, Lastgänge einer großen Zahl von Verbrauchern im Mittel abzubilden. Lastgänge von einzelnen Verbrauchern weisen jedoch, wie in Abbildung 3.2a deutlich zu sehen ist, eine wesentlich höhere Varianz auf und können mit diesen Standardprofilen nicht adäquat abgebildet werden. Aus diesem Grund wurden in der Vergangenheit verschiedene Studien durchgeführt, um die statistische Verteilung von Lasten zu einem bestimmten Zeitpunkt in Niederspannungsnetzen zu ermitteln. Diese Studien basieren zum Teil auf realen Messdaten und zum Teil auf Simulationen. In Abhängigkeit von Faktoren wie dem Aggregationsniveau, der zeitliche Auflösung oder den Simulationsparametern wurden dabei potenzielle Wahrscheinlichkeitsverteilungen zur Beschreibung

von Lasten identifiziert. Herman *et al.* nutzen in ihren Studien Weibull-, Erlang-, Beta- und Normalverteilungen [117, 118]. Ghosh *et al.* verwenden Normalverteilungen, logarithmische Normalverteilungen und Betaverteilungen [103]. Carpaneto und Chicco vergleichen neun verschiedene Verteilungen [45]. Seppälä modelliert Lasten durch logarithmische Normalverteilungen sowie Normalverteilungen [273, 274], während Fikri Normalverteilungen [90] und Probst *et al.* logarithmische Normalverteilungen [247] einsetzen. Aus den Studien kann keine eindeutige Präferenz für eine Wahrscheinlichkeitsverteilung abgeleitet werden; das geeignete Modell ist anwendungsspezifisch zu wählen. In dieser Arbeit wird aufgrund der Einfachheit eine Normalverteilung zugrunde gelegt.


Da die Modellierung von Haushalten nicht im Fokus dieser Arbeit steht, findet im Rahmen der Generierung von Lastgängen keine Abbildung auf Geräteebene statt. Anstatt dessen werden Haushalte durch künstliche Lastprofile repräsentiert, welche auf dem dynamisierten Standardlastprofil H0 und einer Normalverteilungsannahme basieren. Dies senkt sowohl den Modellierungsaufwand als auch die benötigte Rechenzeit für Simulationen. Zur Generierung der Wirkleistungsprofile von Haushalten wird zunächst mittelwertfreies, normalverteiltes Rauschen zum dynamisierten H0-Profil $\underline{P}^{\text{H0}}$ addiert:

$$\tilde{p}_t^{\text{sim}} = p_t^{\text{H0}} + \mathcal{N}\left(0, (5 \cdot p_t^{\text{H0}})^2\right), \quad t = 1, \dots, T.$$

Die Standardabweichung der Wirkleistung \tilde{p}_t^{sim} im Zeitschritt t entspricht hierbei der fünffachen Leistung p_t^{H0} des Standardlastprofils in diesem Zeitschritt. Daraufhin wird ein Tiefpassfilter in Form eines zentrierten gleitenden Mittelwerts der Ordnung 3 auf \tilde{P}^{sim} angewandt, um das simulierte Haushaltslastprofil $\underline{P}^{\text{sim}}$ zu erstellen:

$$p_t^{\text{sim}} = \frac{1}{3} \left(\tilde{p}_{t-1}^{\text{sim}} + \tilde{p}_t^{\text{sim}} + \tilde{p}_{t+1}^{\text{sim}} \right), \quad t = 2, \dots, T-1. \quad (3.3)$$

Für $t = 1$ und $t = T$ wird der Durchschnitt aus den beiden angrenzenden Werten von \tilde{P}^{sim} gebildet. Die Werte für die Standardabweichung und die Ordnung der Mittelwertbildung wurden experimentell ermittelt. Mit den angegebenen Werten generierte Lastprofile wiesen im Vergleich zu realen Lastprofilen vergleichbare Charakteristika auf.



(a) Zufällig generiertes Profil, reales Profil und H0 (b) Durchschnitt aus 1000 zufällig generierten Profilen im Vergleich zu H0

Abbildung 3.2 – Generierte und reale Lastprofile gegenüber dem Standardprofil H0. Generierte Profile weisen einen ähnlichen Verlauf wie reale Lastprofile auf und approximieren in größerer Zahl das H0-Profil.

Ein auf diese Weise erstelltes Wirkleistungsprofil ist zusammen mit einem real gemessenen Profil in Abbildung 3.2a dargestellt. Diese wurden zuvor auf den Verbrauch des H0-Profiles skaliert. In der Abbildung ist zu erkennen, dass das generierte Lastprofil vergleichbare Eigenschaften besitzt wie das reale Profil. Zum einen fluktuiert die bezogene Leistung über weite Zeiträume bei kleinen Werten. Dies ist auf Haushaltsgeräte zurückzuführen, welche einen thermischen Speicher besitzen, wie beispielsweise Kühl- oder Gefrierschränke. Um zu gewährleisten, dass die Temperaturen dieser Speicher innerhalb definierter Grenzen bleiben, müssen die Geräte regelmäßig betrieben werden. Dies gilt auch für die Zeiträume, in denen keine Bewohner anwesend sind. Zum anderen gibt es einige Zeitpunkte, die sich durch einen wesentlich höheren Energiebedarf abheben. Dieser entsteht beispielsweise durch Haushaltsgeräte mit hohem Energieverbrauch, wie Backöfen und Waschmaschinen. Wie aus Abbildung 3.2b ersichtlich wird, nähert sich der Durchschnitt einer großen Zahl von Profilen, welche auf die beschriebene Art generiert werden, dem H0-Profil an.

Da das H0-Profil lediglich Wirkleistung berücksichtigt, wird zur Generierung von Blindleistungsprofilen der Leistungsfaktor $\cos \varphi = 0,95$ (induktiv) zugrunde gelegt. Durch ein vorgegebenes Wirkleistungsprofil ist somit die zugehörige Blindleistung eindeutig bestimmt.

Tabelle 3.1 – Für die Simulationen getroffene Annahmen bezüglich der jährlichen Energieerzeugung durch Photovoltaik-Anlagen und des jährlichen Energieverbrauchs von Haushalten [39] in Abhängigkeit der Haushaltsgröße

Anzahl Haushaltsbewohner	Jährliche Energieerzeugung (kWh)	Jährlicher Energieverbrauch (kWh)
1	3000	2050
2	4000	3440
3	5000	4050
4	6000	4750
5	7000	5370

Um Haushalte verschiedener Größe zu simulieren, werden die generierten Lastprofile entsprechend dem Jahresverbrauch skaliert. Für den jährlichen Verbrauch der Haushalte einer bestimmten Größe werden die in Tabelle 3.1 aufgeschlüsselten statistische Werte [39] genutzt.

Flexibilität

Den Betrachtungen zur Flexibilität liegt jeweils ein festgelegter Planungshorizont zugrunde. Die im letzten Abschnitt beschriebenen simulierten Profile dienen als Lastprognose der Haushalte für diesen Planungshorizont. Basierend darauf werden die möglichen Lastverschiebungen der intelligenten Haushalte berechnet. Hierzu sind prinzipiell zwei Schritte nötig. Zunächst werden die Zeitschritte identifiziert, aus denen die Last verschoben werden kann, um anschließend die Zeitschritte zu bestimmen, in welche diese Last verschoben wird. Ersteres entspricht einer Reduzierung des Verbrauchs und Zweiteres einer Erhöhung in den entsprechenden Zeitschritten. In Summe gleichen sich die Lasterhöhungen und -senkungen jedes Haushalts über dem Planungshorizont aus, sodass die Gesamtnachfrage konstant bleibt.

Die Berechnung der Verlagerungsangebote nach Gleichung (3.1) wird durch eine Reihe von Parametern gesteuert. Einige davon werden für alle in Kapitel 7 betrachteten Szenarien einheitlich festgelegt. Andere hingegen werden variiert, um deren Einfluss auf die flexible Leistungsführung zu ermitteln. Einer dieser Parameter ist die Anzahl der Zeitschritte, in denen die

Last reduzierbar ist. Damit kann die verschiebbare Leistung unmittelbar beeinflusst werden, wie in Abschnitt 7.1.5 beschrieben. Die konkreten Zeitschritte, die an der Verschiebung teilnehmen, werden anhand der Präferenzen des Energiemanagers ausgewählt. Wie in Abschnitt 3.1.2 dargestellt, berechnet der Energiemanager hierzu eine Wahrscheinlichkeitsverteilung auf Basis der Abweichungen vom Zielprofil. Die Bestimmung der Zeitschritte anhand der Verteilung unterliegt einer Fehlerwahrscheinlichkeit von 10 %. Mit dieser Wahrscheinlichkeit wird ein Zeitschritt für eine Lastsenkung ausgewählt, in dem der Energiemanager eine Lasterhöhung anfordert.

Nach Identifizierung der einzelnen Zeitschritte, in denen die Last reduziert werden kann, muss der Umfang der Verschiebung festgelegt werden. In den untersuchten Szenarien beträgt dieser zwischen 50 % und 100 % der Last in dem entsprechenden Zeitschritt. Der konkrete Wert wird einer Gleichverteilung folgend zufällig ermittelt. Die in einem Zeitschritt verschiebbare Last kann auf mehrere andere Zeitschritte aufgeteilt werden. Damit wird die Flexibilität bestimmter Geräte und Anlage abgebildet, die einen thermischen Speicher aufweisen, wie beispielsweise Kühlschränke, Klimaanlage und Wärmepumpen. Diese können den elektrischen Verbrauch auf verschiedene Zeitintervalle aufteilen, um eine Zieltemperatur zu halten. In den Simulationen wird die Anzahl der Aufspaltungen der verschiebbaren Leistung durch eine Zufallsvariable s abgebildet. Diese folgt einer Poisson-Verteilung mit Erwartungswert 0,6 (siehe Abbildung 3.3). Für $s = 0$ wird die gesamte verschiebbare Last in einen einzigen Zeitschritt verschoben. Für $s = 1$ wird die Last einmal aufgeteilt und in zwei verschiedene Zeitschritte verschoben. Bei $s = 2$ finden zwei Aufspaltungen statt, sodass die Last in drei Zeitschritte aufgeteilt wird. Analog wird für die weiteren Realisierungen von s verfahren, wobei die Leistung jeweils gleichmäßig aufgeteilt wird.

Der letzte Schritt zur Erstellung eines Verlagerungsangebots besteht in der Bestimmung der Zeitschritte, in welche die Last verschoben wird, d. h. in denen der Verbrauch erhöht wird. Diese Zeitschritte werden ebenfalls auf Grundlage der Wahrscheinlichkeitsverteilung, welche durch den Energiemanager berechnet wurde, mit einer Fehlerwahrscheinlichkeit von 10 % bestimmt. Die durchgeführte Verschiebung beträgt maximal zehn Stunden. Dies ist eine konservative Schätzung, die niedriger angesetzt ist als in manchen anderen Studien, die Verschiebemöglichkeiten von beispielsweise bis zu 16 Stunden [186, Kap. 3.2.5] oder bis zu 18 Stunden [311] annehmen.




Abbildung 3.3 – Wahrscheinlichkeitsfunktion einer Poisson-verteilten Zufallsvariable s mit Erwartungswert 0,6

Zu einem Verlagerungsangebot gehört neben den Verbrauchsänderungen auch ein Preis für die Inanspruchnahme der Verlagerung, welchen der Haushalt vom Energiemanager fordert. In den Simulationen wird der Arbeitspreis für Verlagerungsangebote anhand einer Normalverteilung mit einem Erwartungswert von 0,1 Euro/kWh und einer Standardabweichung von 0,02 Euro/kWh festgelegt. Der feste Gesamtpreis eines Angebots ergibt sich durch Multiplikation des Arbeitspreises mit der verschobenen Energie. Der Arbeitspreis von Verlagerungsangeboten liegt unter den Verbrauchskosten, welche in Deutschland im Jahr 2015 für Privathaushalte im Schnitt beinahe 0,3 Euro/kWh betragen [292]. Diese Festlegung wurde getroffen, da durch die Verschiebungen kein zusätzlicher Verbrauch generiert wird. Es sollen lediglich die Dienstleistung der Lastverschiebung sowie die dadurch entstehenden Komforteinbußen vergütet werden.

Haushalte müssen sich nicht auf die Abgabe eines einzigen Verlagerungsangebots beschränken. Sofern Angebote automatisiert berechnet werden können, ist es naheliegend, dass mehrere gleichzeitig erstellt werden. In Abschnitt 7.1.6 wird untersucht, wie sich die Anzahl der Angebote auf die flexible Leistungsführung auswirkt.

3.2.2 Photovoltaik-Anlagen

Entsprechend dem Vorgehen bei den Haushalten werden für Photovoltaik-Anlagen zunächst Erzeugungsprofile generiert. Anschließend kann das Flexibilitätspotenzial ermittelt werden.




Abbildung 3.4 – Photovoltaik-Standardprofile für verschiedene Monate bei einer jährlichen Erzeugung von 1000 kWh


Generierung von Erzeugungsprofilen

Analog zu den Standardlastprofilen für Haushalte wurden für die Photovoltaik-Einspeisung ebenfalls Standardprofile erstellt. Diese werden anhand des Monats unterschieden, sodass zwölf Kurven existieren. Abbildung 3.4 zeigt das Standard einspeiseprofil EV0 des Bundesverbands der Energie- und Wasserwirtschaft für die Monate Januar, April und Juli. Darin ist der Einfluss der Jahreszeit bezüglich Sonnenscheindauer und Einstrahlungsinintensität deutlich erkennbar.

Wie das H0-Profil repräsentiert auch das EV0-Profil den Durchschnitt einer großen Zahl von gemessenen Profilen. Damit weist dieses im Vergleich zu realen Profilen eine geringere Varianz auf. Aus diesem Grund wird zur Generierung der Einspeiseprofile wiederum zunächst mittelwertfreies, normalverteiltes Rauschen zum EV0-Profil $\underline{p}^{\text{EV0}}$ addiert:

$$\tilde{p}_t^{\text{sim}} = p_t^{\text{EV0}} + \mathcal{N}\left(0, (p_t^{\text{EV0}})^2\right), \quad t = 1, \dots, T.$$

Hier entspricht die Standardabweichung der Wirkleistung \tilde{p}_t^{sim} zu einem Zeitpunkt t der Leistung p_t^{EV0} des Standardprofils zu diesem Zeitpunkt. Für dieses Profil wird entsprechend Gleichung (3.3) der zentrierte gleitende Mittelwert der Ordnung 3 berechnet, um das simulierte Profil $\underline{p}^{\text{sim}}$ zu erhalten. Für die simulierten Photovoltaik-Anlagen wird ein Leistungsfaktor von 1 zugrunde gelegt, sodass keine Blindleistung eingespeist oder bezogen wird.



(a) Zufällig generiertes Profil, reales Profil und EV0
 (b) Durchschnitt aus 1000 zufällig generierten Profilen im Vergleich zu EV0

Abbildung 3.5 – Generierte und reale Photovoltaik-Profile gegenüber dem Standardprofil EV0 für den Monat August. Generierte Profile weisen einen ähnlichen Verlauf wie reale Erzeugungsprofile auf und approximieren in größerer Zahl das künstliche EV0-Profil.

Abbildung 3.5a zeigt ein zufällig generiertes Erzeugungsprofil sowie ein reales Profil. Diese wurden auf die Erzeugung des EV0-Profiles skaliert. Beide Profile weisen eine vergleichbare Charakteristik auf. Von Sonnenaufgang bis zur Nachmittagsspitze nimmt die Erzeugung zu und sinkt daraufhin bis zum Sonnenuntergang wieder ab. Zwischenzeitlich kann es wetterbedingt immer wieder zu Einbrüchen der Erzeugungsleistung kommen. In Abbildung 3.5b ist erkennbar, dass sich der Durchschnitt einer Vielzahl von generierten Profilen dem EV0-Profil annähert.

Einigen der simulierten Haushalte werden Photovoltaik-Anlagen zugeordnet. Die Größe der Anlagen orientiert sich dabei an der Haushaltsgröße und ist in Tabelle 3.1 angegeben. Mangels Statistiken, welche eine Zuordnung zwischen den beiden Größen ermöglichen, wurden die Photovoltaik-Anlagen so dimensioniert, dass sie den Jahresenergieverbrauch der entsprechenden Haushalte etwas übersteigen.

Flexibilität

Das Flexibilitätspotenzial von Photovoltaik-Anlagen besteht in einer Absenkung der Einspeiseleistung. Entsprechend Gleichung (3.2) kann der Energiemanager für alle Zeitschritte des Planungshorizonts eine Leistungsän-

derung im Intervall $[\Delta p_t^{\min}, \Delta p_t^{\max}] := [-p_t^{\text{sim}}, 0]$ festlegen. Der Wert $-p_t^{\text{sim}}$ führt dabei zu einer vollständigen Drosselung, während der Wert 0 einer unbeeinflussten Einspeisung entspricht.

Die Kosten, welche für den Energiemanager anfallen, sind abhängig von der Höhe der gedrosselten Einspeisung. In den betrachteten Szenarien wird für jedes Angebot der Arbeitspreis basierend auf einer Normalverteilung mit dem Erwartungswert 0,15 Euro/kWh und einer Standardabweichung von 0,02 Euro/kWh festgelegt. Diese Preise liegen im Bereich der EEG-Einspeisevergütung für Photovoltaik-Anlagen, die seit 2014 in Betrieb genommen wurden [40, Kap. 11]. Die Vergütung entschädigt den Anlagenbetreiber für die entgangenen Einnahmen durch die Absenkung der Einspeisung.

3.3 Niederspannungsnetz

Die in dieser Arbeit betrachteten Last- und Erzeugungsmanagement-Szenarien beziehen Netzrestriktionen in die Optimierung ein. Grundlage hierfür bildet das in Abbildung 3.6 gezeigte 106-Knoten-Niederspannungsnetz in einphasiger Darstellung [163]. Dessen Struktur ist typisch für vorstädtische Gebiete und umfasst 101 Einfamilienhäuser. Die Verteilung der Haushaltsgrößen entspricht den Angaben des Bundesamts für Statistik [291, Kap. 1.1]. Knotennummern sowie Haushaltsgrößen sind in den Kästen der einzelnen Netzknoten in Abbildung 3.6 vermerkt. Darüber hinaus besitzen einige der Häuser Photovoltaik-Anlagen. Diese werden durch Doppelkreuze markiert.

Im Rahmen des Energiemanagements werden Restriktionen bezüglich der Knotenspannungen und der Ströme betrachtet. Diese werden mittels Leistungsflussberechnungen aus den vorgegebenen Leistungen der Entitäten bestimmt. Die Grundlage hierfür bilden die aus der Kirchhoffschen Knotenpunktregel abgeleiteten Leistungsflussgleichungen für jeden Knoten $i = 1, \dots, K$ [59, S. 445]:

$$\begin{aligned} p_i &= 3u_i \left[\sum_{k=1}^K u_k [G_{ik} \cos(\varphi_i - \varphi_k) + B_{ik} \sin(\varphi_i - \varphi_k)] \right], \\ q_i &= 3u_i \left[\sum_{k=1}^K u_k [G_{ik} \sin(\varphi_i - \varphi_k) - B_{ik} \cos(\varphi_i - \varphi_k)] \right]. \end{aligned} \quad (3.4)$$

Hierbei bezeichnen p_i bzw. q_i die Wirk- bzw. Blindleistung in Knoten i eines K -Knoten-Netzes. Die entsprechenden Spannungsbeträge und Phasenwinkel werden durch u_i und φ_i dargestellt. G_{ik} bzw. B_{ik} stellen für $i \neq k$ den Real- bzw. Imaginärteil der Koppeladmittanzen zwischen Knoten i und Knoten k dar; für $i = k$ entsprechen diese Werte dem Real- bzw. Imaginärteil der Queradmittanz des entsprechenden Knotens.

Die Admittanzen des Netzes werden aus den Kabellängen, die ebenfalls in Abbildung 3.6 eingetragen sind, und dem Kabeltyp bestimmt. In den Simulationen wurden Parameter von Kabeln des Typs NAYY 4×50 SE [120, S. 744] hinterlegt.

Jeder Netzknoten wird durch die vier Größen p, q, u und φ sowie zwei Gleichungen charakterisiert. Im simulierten Niederspannungsnetz sind für die Knoten 2–106 die Größen p und q aufgrund der Fahrpläne bekannt. Daher existieren für diese Knoten jeweils zwei Gleichungen und zwei unbekannte Größen.

Das Niederspannungsnetz wird vom übergeordneten Mittelspannungsnetz in Knoten 1 gespeist. Dieser dient als Bilanzknoten, sodass p und q erst nach Abschluss der Leistungsflussrechnung festgelegt werden können. Benötigt wird dieser, da die Summe aller Leistungen einschließlich der Netzverluste Null sein muss. Vor der Leistungsflussberechnung ist die Höhe der Verluste jedoch noch unbekannt. Darüber hinaus wird für die Berechnung von Leistungsflüssen angenommen, dass Betrag und Phase der Spannung des Bilanzknotens eingepreist sind. Der Betrag entspricht dabei dem Referenzwert der Spannung und der Phasenwinkel wird gleich Null gesetzt [59, S. 445]. Aus diesen Gründen werden die beiden Gleichungen des Bilanzknotens bei der Leistungsflussberechnung nicht berücksichtigt.

Die Leistungsflussberechnung umfasst die Bestimmung der unbekanntenen Größen des Gleichungssystems, welches aus den Leistungsflussgleichungen (3.4) gebildet wird. Da die Gleichungen nichtlinear sind, werden zur Lösung des Gleichungssystems iterative Verfahren eingesetzt. In dieser Arbeit wird das Newton-Raphson-Verfahren [270, Kap. G.2.1.3] basierend auf einer bestehenden Implementierung genutzt. Mittels der berechneten Knotenspannungen und der Admittanzen können schließlich die Ströme ermittelt werden.

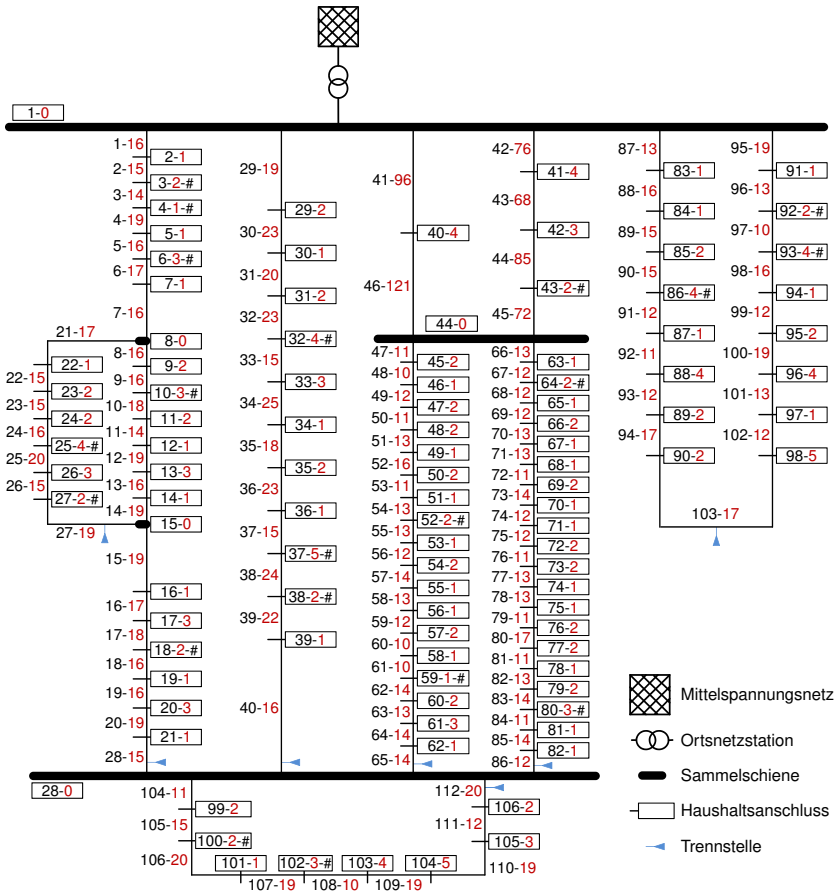


Abbildung 3.6 – Simuliertes 106-Knoten-Niederspannungsnetz. Netzknoten werden beschrieben durch deren Nummer (schwarz) und die Anzahl der Personen (rot), die in dem Haushalt wohnen, welcher sich am entsprechenden Knoten befindet. An Sammelschienen sind keine Haushalte direkt angeschlossen. Photovoltaik-Anlagen werden durch Doppelkreuze angezeigt. Die Zahlen an den Kabeln geben die Kabelnummer (schwarz) und die Kabellänge in Metern (rot) an.

Smart Grids sind charakterisiert durch die Netzinfrastruktur einerseits und die Informations- und Kommunikationssysteme andererseits. Im Rahmen dieser Arbeit wird davon ausgegangen, dass die Netzinfrastruktur vorhanden ist und dass die Entitäten über Kommunikationseinrichtungen verfügen, die einen Datenaustausch ermöglichen. Auf dieser Grundlage erfolgt ein Energiemanagement, welches auf die Koordination von Erzeugung und Verbrauch abzielt. Dieses Kapitel präsentiert eine Architektur, welche die Entitäten auf der Managementebene integriert. Die Architektur beschreibt die Zusammensetzung der Entitäten sowie deren Zusammenwirken. Diese Konzepte werden zunächst auf einer generischen Ebene vorgestellt, welche diverse Anwendungsfälle abbilden kann. Daraufhin wird die Architektur für den betrachteten Fall des fahrplanbasierten Energiemanagements konkretisiert. Die einzelnen Architekturkomponenten werden in den darauffolgenden Kapiteln detailliert beschrieben.

4.1 Generische Architektur für Energiemanagement-Systeme

Die Heterogenität und die hohe Anzahl von Entitäten in Smart Grids stellen, wie in Abschnitt 1.2 beschrieben, hohe Anforderungen an das Energiemanagement. Im Folgenden wird dargelegt, wie diesen Herausforderungen auf Architekturebene begegnet werden kann. Die vorgestellte Architektur basiert auf der Observer/Controller-Architektur, welche in Abschnitt 2.1.3 beschrieben wurde. Die Darstellungen sind an die Publikationen [190, 261] angelehnt.




Abbildung 4.1 – Observer/Controller-Architektur mit Entitäten-Abstraktionsschicht. Kerngedanke ist die Entkopplung der Managementebene von konkreten Entitäten.

4.1.1 Abstraktionsschicht

Die Heterogenität der Entitäten äußert sich sowohl auf der Kommunikationsebene als auch auf der Koordinationsebene. Bei der Kommunikation kommen beispielsweise diverse Protokolle zum Einsatz, die proprietär sein können. Für die Koordination können verschiedene Flexibilitäten genutzt werden; eine Waschmaschine weist beispielsweise eine andere Art von Flexibilität auf als eine Photovoltaik-Anlage.

Um die Heterogenität zu überwinden, wurde eine strikte Entkopplung der Managementebene von den Entitäten vorgenommen. Zu diesem Zweck wurde die Observer/Controller-Architektur um eine Entitäten-Abstraktionsschicht zwischen dem zu koordinierenden System und der Observer/Controller-Einheit erweitert, wie in Abbildung 4.1 dargestellt. Analog zur Hardware-Abstraktionsschicht des Organic Smart Home [9] umfasst die Entitäten-Abstraktionsschicht Treiber, welche die individuellen Entitäten kapseln und eine einheitliche Schnittstelle für die Observer/Controller-Einheit bereitstellen. Diese Schnittstelle verbirgt zum einen das unterliegende Kommunikationsprotokoll der Entitäten. Zum anderen wird die Art der kommunizierten Daten für Klassen von Entitäten vereinheitlicht.

Durch die Abstraktionsschicht können Koordinationsalgorithmen unabhängig von anderen Teilen des Systems implementiert werden. Sofern Treiber bereitgestellt werden, muss die Observer/Controller-Einheit bei Veränderungen der Entitäten nicht adaptiert werden. Ferner können neuartige Entitäten in das Management eingebunden werden, falls diese die Datenschnittstelle unterstützen.

Im Rahmen des Energiemanagements dieser Arbeit bezieht sich der Begriff der Entität auf einen beliebigen Erzeuger oder Verbraucher. Die in diesem Kapitel vorgestellte generische Architektur geht jedoch über diesen Anwendungsfall hinaus. Eine Entität kann beispielsweise auch ein Netzbetriebsmittel sein, welches an der Koordination beteiligt ist.

4.1.2 Hierarchische Architektur

Wenn die Zahl der zu koordinierenden Entitäten zu groß wird, stoßen zentrale Kontrollstrukturen an ihre Grenzen. Dann stellen hierarchische und dezentrale Ansätze eine Alternative dar. Wie in Abschnitt 2.1.3 beschrieben, können diese Kontrollstrukturen mittels Observer/Controller-Architektur realisiert werden. Angelehnt an die hierarchische Struktur von Stromnetzen verfolgt diese Arbeit einen hierarchischen Ansatz. Demzufolge ist zwischen den Managementebenen und den Spannungsebenen zu unterscheiden.

Beim Hierarchisieren, zum Beispiel in holonischen Systemen [94], erweist sich die Entitäten-Abstraktionsschicht als hilfreich. Aufgrund einheitlicher Schnittstellen können Systeme beliebig aggregiert und wiederum als Subsysteme verwendet werden, wie in Abbildung 4.2 dargestellt. Da Observer/Controller-Einheiten ausschließlich mit Treibern kommunizieren, ist es unerheblich, ob die Entität dahinter ein physikalisches oder ein aggregiertes, virtuelles Konstrukt ist. Höhere Managementebenen können sich auch auf anderen Spannungsebenen als die koordinierten Entitäten befinden.

Die Architektur ist zwar hierarchisch aufgebaut, jedoch können Managementebenen auch dezentrale Subsysteme aufweisen, welche durch die Abstraktionsschicht gekapselt sind. Es werden daher hierarchische und dezentrale Koordinationsstrukturen sowie deren Interaktion unterstützt.

Durch die generische Architektur ist keine Festlegung auf ein konkretes Einsatzszenario oder die einzubindenden Entitäten getroffen. Es können Anwendungsfälle abgebildet werden, die verschiedenste Zielsetzungen sowie räumliche und zeitliche Auflösungen umfassen. Ferner können sich die koordinierten Entitäten auf beliebigen Spannungsebenen befinden. Einige Beispiele für Einsatzmöglichkeiten der Architektur sind in Abbildung 4.3 dargestellt. Darin befinden sich Gebäude-Energiemanagement-Systeme auf der untersten Managementebene. Mit dem Organic Smart Home wurde ein solches intelligentes Gebäude in Abschnitt 2.1.3 vorgestellt. Eine Ebene

darüber können Last- und Erzeugungsmanagement-Systeme abgebildet werden, die eine Menge von intelligenten Gebäuden koordinieren. Diese Gebäude können über verschiedene Netze verteilt sein. Ein weiteres Beispiel für eine potenziell netzübergreifende Aggregation sind virtuelle Kraftwerke [251]. Diese bündeln verteilte Entitäten und sind dadurch in der Lage, Dienstleistungen anzubieten, welche durch die einzelnen Entitäten nicht erbracht werden könnten. Eine Ebene darüber ist ein System für das Netzmanagement angesiedelt. Dieses koordiniert eine Menge von Entitäten wie zum Beispiel virtuelle Kraftwerke und intelligente Ortsnetzstationen. Durch die hierarchische Modellierung wurde die Anzahl der zu koordinierenden Systeme reduziert. Da es sich um eine generische Architektur handelt, müssen die Koordinationsziele und die Algorithmen im konkreten Fall für jede Ebene separat festgelegt werden.

In den genannten Anwendungsfällen tritt eine Vielzahl von Akteuren auf, die diverse Ziele verfolgen und verschiedene Koordinationsmethoden einsetzen. Diesbezüglich wird durch Einsatz der generischen Architektur keine Festlegung getroffen. Eine Interaktion der Akteure wird beispielsweise über Zielvorgaben in der Observer/Controller-Architektur unterstützt und durch die Entitäten-Abstraktionsschicht begünstigt.

4.2 Konkrete Architektur für fahrplanbasiertes Energiemanagement

Für das fahrplanbasierte Energiemanagement dieser Arbeit wurde die generische Architektur instanziiert. Die wichtigsten Komponenten sind in Abbildung 4.4 dargestellt. Darin bleiben Implementierungsdetails der Observer/Controller-Architektur, wie Log-Datei oder Monitor, unberücksichtigt.

Das System unter Observation and Control umfasst die Entitäten, welche in Abschnitt 3.2 beschrieben wurden. Hierzu gehören intelligente Gebäude, die zum Teil mit Photovoltaik-Analgen ausgestattet sind, sowie klassische Gebäude, die zwar intelligente Stromzähler besitzen aber keine Flexibilitäten anbieten. Diese Entitäten werden in der Abstraktionsschicht gekapselt und durch eine allgemeine Schnittstelle ersetzt. Die Daten, welche für das Energiemanagement über die Schnittstelle übertragen werden, umfassen Zählermesswerte, Fahrpläne und Verlagerungsangebote.

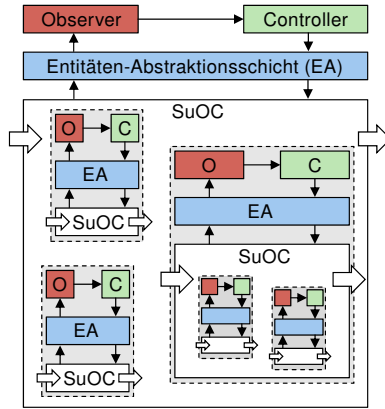


Abbildung 4.2 – Generische hierarchische Energiemanagement-Architektur basierend auf der erweiterten Observer/Controller-Architektur. Mittels Entitäten-Abstraktionsschicht können Systeme beliebig aggregiert und wiederum als Subsysteme auf einer höheren Koordinations-ebene verwendet werden.

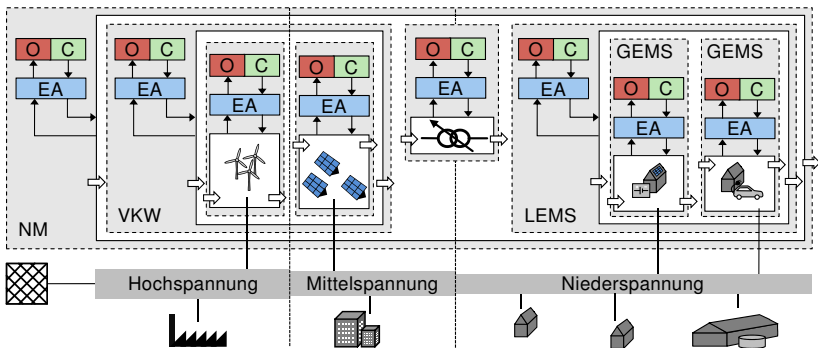


Abbildung 4.3 – Grundschemata von Stromnetzen aus Abbildung 1.1 erweitert um die generische Energiemanagement-Architektur für diverse Anwendungsfälle, angelehnt an [261]. Diese Anwendungsfälle umfassen Gebäude-Energiemanagement-Systeme (GEMS), Last- und Erzeugungsmanagement-Systeme (LEMS), virtuelle Kraftwerke (VKW) und Netzmanagement (NM). Die Energiemanagement-Architektur umfasst Observer (O), Controller (C) sowie Entitäten-Abstraktionsschicht (EA).

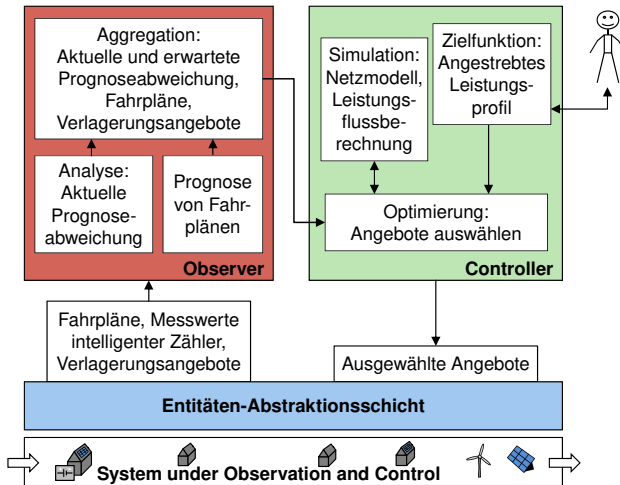


Abbildung 4.4 – Funktionale Komponenten der instanziierten Energiemanagement-Architektur

Wie in Abschnitt 3.1.1 dargestellt, werden Entitäten durch ihren Fahrplan beschrieben. Da der Energiemanager keine direkten Eingriffe durchführt, müssen die Entitäten keine internen Informationen preisgeben. Intelligente Gebäude sind in der Lage, selbst Fahrpläne zu prognostizieren. Für die anderen Gebäude nimmt der Observer eine Prognose auf Basis der Zählermesswerte vor. Diese Prognosen werden in Kapitel 5 vorgestellt.

Darüber hinaus werden die aktuellen Zählermesswerte genutzt, um während der Fahrplanabwicklung Abweichungen von der Prognose zu ermitteln. Der Abwicklungszeitraum eines Fahrplans umfasst die Zeitschritte, für welche die Fahrplanprognose durchgeführt wurde. Innerhalb dieses Zeitraums versuchen die Entitäten, die prognostizierten Fahrpläne in die Tat umzusetzen. Wenn eine festgestellte Abweichung zu groß wird, können noch vor Ende des Abwicklungszeitraums neue Prognosen angestoßen oder Flexibilitäten abgefragt werden. Dieser Aspekt wurde im Rahmen dieser Arbeit jedoch nicht weiter untersucht.

Die Flexibilitäten der Entitäten werden durch Verlagerungsangebote ausgedrückt. Diese umfassen, wie in Abschnitt 3.1.1 bereits beschrieben, Diffe-

renzprofile mit Nebenbedingungen sowie die dazugehörigen Preise. Differenzprofile geben die möglichen Leistungsänderungen bezogen auf einen prognostizierten Fahrplan an und können verschiedene Arten von Flexibilität ausdrücken. Verlagerungsangebote dieser Form stellen eine Abstraktion dar, welche die einheitliche Beschreibung der Flexibilität diverser Entitäten ermöglicht. Neben der Beschreibung von Entitäten durch Fahrpläne bildet diese Darstellung von Flexibilitäten die Grundlage für eine Kapselung der Entitäten durch Treiber.

Fahrpläne und Verlagerungsangebote sind Informationen, die im Controller im Rahmen der Optimierung genutzt werden. Dabei werden die Verlagerungsangebote ausgewählt, die in Anspruch genommen werden. Auswahlkriterien sind die Approximation des angestrebten Leistungsprofils sowie die Kosten. Das Zielprofil kann entweder vom Energiemanager selbst festgelegt oder von einer höheren Managementebene vorgegeben werden. Die Optimierung wird in Kapitel 6 detailliert diskutiert. Im Rahmen der Optimierung werden Restriktionen eines zugrundeliegenden Stromnetzes bezüglich der zulässigen Ströme und Spannungen berücksichtigt. Zu diesem Zweck werden Leistungsflussberechnungen durchgeführt, wie in Abschnitt 3.3 beschrieben.

Lastprognose von Einzelhaushalten

Im Rahmenszenario wurden klassische Entitäten von den intelligenten Entitäten abgegrenzt. Ein Unterscheidungsmerkmal ist unter anderem die Fähigkeit, Leistungsprognosen zu erstellen. Im Unterschied zu intelligenten Entitäten können die klassischen Entitäten nicht selbstständig ihr Leistungsprofil prognostizieren. Um Leistungsflüsse bei der Optimierung im Rahmen des Energiemanagements zu bestimmen, werden die Prognosen der Leistungswerte aller Netzknoten benötigt. In den betrachteten Szenarien wird davon ausgegangen, dass Entitäten, die Photovoltaik-Anlagen repräsentieren, intelligent sind. Es wird jedoch angenommen, dass ein Teil der Haushalte keine automatisierte Steuerungsmöglichkeit und keine Prognosefähigkeit, wie beispielsweise von Bao *et al.* für die Geräteebene beschrieben [22], besitzt. Die einzige Information, die über einen solchen Haushalt zur Verfügung steht, ist der gemessene aggregierte Verbrauch. Die Aggregation bezieht sich hierbei auf alle Verbraucher des Haushalts. Aus diesem Grund werden im Folgenden Lastprognosen für Einzelhaushalte untersucht, die auf Messdaten intelligenter Stromzähler mit einer zeitlichen Auflösung von 15 Minuten basieren. Des Weiteren stehen Wetterdaten zur Verfügung, die für Vorhersagen genutzt werden können. Dieses Kapitel ist eng angelehnt an die Darstellungen in der Publikation [128]. Implementierung und Evaluation der Verfahren wurden in der Arbeit [95] durchgeführt.

Bisher werden Lastprognosen vorwiegend für große Mengen von Haushalten akkumuliert durchgeführt, zum Beispiel auf regionaler und nationaler Ebene oder für die Gesamtheit der Kunden eines Energieversorgers [112, 301]. Aufgrund der flächendeckend installierten Ferraris-Stromzähler war eine feinere räumliche und zeitliche Auflösung der Vorhersagen nicht praktikabel. Daher gibt es nur sehr wenige Studien über die Prognose der Last-

gänge von Einzelhaushalten. Zur Prädiktion von einzelnen und kumulierten Lastgängen werden zahlreiche Verfahren genutzt und kombiniert. Dabei werden neben dem historischen Lastverlauf zum Teil exogene Einflussgrößen berücksichtigt. Vor allem meteorologische Größen wirken sich auf den Energieverbrauch aus. Die Umgebungstemperatur hat den größten Einfluss, da diese in unmittelbarem Zusammenhang mit der Regelung des Raumklimas [127] und dem damit verbundenen Stromverbrauch steht.

Im Folgenden werden die Prognoseverfahren zunächst klassifiziert. Anschließend werden die Verfahren vorgestellt, welche im Rahmen der Lastprognose für Einzelhaushalte näher untersucht wurden. Diese decken alle im ersten Schritt identifizierten Klassen von Verfahren zur kurzfristigen Prognose ab. Abschließend wird die Prognosegüte auf Basis realer Verbrauchs- und Temperaturdaten evaluiert.

5.1 Klassifikation von Prognoseverfahren

Eine Klassifikation der Prognoseverfahren ist beispielsweise anhand des Prognosehorizonts möglich. Im Allgemeinen werden dabei langfristige, mittelfristige und kurzfristige Prognosen unterschieden [167]. Langfristige Prognosen werden mindestens ein Jahr im Voraus erstellt und beispielsweise bei der Netzausbauplanung genutzt. Der Zeithorizont mittelfristiger Vorhersagen liegt zwischen einer Woche und einem Jahr. Diese Prognosen werden zum Beispiel bei der Planung von Wartungen und der Beschaffung von Brennstoffen benötigt. Kurzfristige Prognosen werden wenige Stunden bis Tage im Voraus erstellt und dienen unter anderem der Betriebsführung von Stromnetzen, wie beispielsweise der Lastflussanalyse oder der Startzeitplanung von Erzeugungsanlagen. Aufgrund unterschiedlicher Vorlaufzeiten unterscheiden sich die Prognoseverfahren und deren Variablen. Da für diese Arbeit ein Planungshorizont von bis zu 24 Stunden gewählt wurde, beschränken sich die folgenden Betrachtungen auf kurzfristige Prognosen.

Eine Klassifikation der Verfahren kann auch anhand der Prognosemethode vorgenommen werden. Konzeptuelle Übersichten neueren Datums über die Methoden, welche bei der Prognose von kumulierten Lasten zum Einsatz kommen, sind in den Studien [5, 88, 112, 167] zu finden. Darüber hinaus wurden experimentelle Studien durchgeführt, die verschiedene Ver-

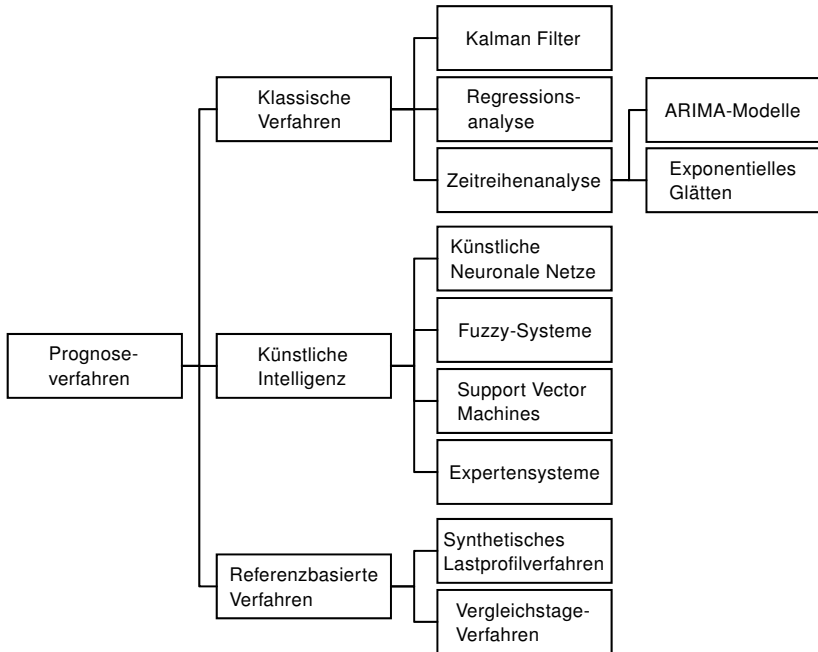


Abbildung 5.1 – Klassifikation von Prognoseverfahren

fahren vergleichen [126, 286, 301, 324]. Anhand der Literatur können Prognosemethoden, wie in Abbildung 5.1 dargestellt, in drei Klassen eingeteilt werden: klassische Methoden, Methoden der künstlichen Intelligenz und referenzbasierte Methoden.

Klassische Methoden nutzen mathematische Modelle, welche den Zusammenhang zwischen der Last und mindestens einer unabhängigen Eingangsgröße beschreiben. Diese Modelle werden auf Grundlage der zurückliegenden zeitlichen Entwicklung erstellt und können linear oder nichtlinear sein. Lastprognosemethoden im Energiesystem setzen aus dem Bereich der klassischen Methoden häufig Kalman Filter [3, 268], Regressionsanalyse [134, 344] und Zeitreihenanalyse ein. Die Zeitreihenanalyse wird meist mittels ARIMA-Modellen [16, 139, 233] oder durch exponentielles Glätten [300] durchgeführt.

Auf dem Gebiet der künstlichen Intelligenz wird versucht, menschliche Fähigkeiten, wie Gedächtnis oder Lernverhalten, nachzubilden. Normalerweise findet keine analytische Modellierung statt, sodass die Verfahren tolerant gegenüber Nichtlinearitäten und Unsicherheiten sind. Am häufigsten werden zur Lastprognose künstliche neuronale Netze [219, 272, 289] eingesetzt. Darüber hinaus finden auch Fuzzy-Systeme [181, 230], Support Vector Machines [51, 220] und Expertensysteme [254, 258] Anwendung.

Die referenzbasierten Prognosemethoden sind am einfachsten anzuwenden, da kein theoretisches Modell erstellt oder angepasst werden muss. Stattdessen werden Referenzwerte unmittelbar als Prognose genutzt. Diese Referenzwerte können beispielsweise aus synthetischen Lastprofilen wie dem H0-Profil stammen. Beim Vergleichstagesverfahren werden historische Werte ausgewählt, welche an Tagen gemessen wurden, die mit dem zu prognostizierenden Tag vergleichbar sind [131]. Die Vergleichbarkeit kann unter anderem anhand des Wetters oder des Tagtyps gegeben sein.

Die aufgeführten Verfahren wurden zum Teil auch für die Lastprognose von einzelnen Haushalten eingesetzt. Gerwig liefert eine strukturierte Übersicht über diesbezügliche Studien [101]. Die meisten dieser Studien betrachten Zeitschritte einer Länge von 30 Minuten oder 60 Minuten. Bedingt durch die längeren Intervalle werden die Lastgänge geglättet, sodass diese Ergebnisse nicht direkt übertragbar sind auf die in dieser Arbeit genutzte Intervalllänge von 15 Minuten. Lediglich zwei Studien nutzen eine zeitliche Diskretisierung von 15 Minuten. Ghofrani *et al.* setzen zur Prognose das Kalman Filter ein [102]. Hierbei betrachten sie einen Prognosehorizont von maximal einer Stunde. Veit *et al.* erstellen Lastprognosen bis zu 24 Stunden im Voraus mittels ARIMA-Modellen, exponentieller Glättung und künstlichen neuronalen Netzen [310]. Dabei werden im Rahmen der Prognosen keine Wetterdaten einbezogen.

Für diese Arbeit wurden Verfahren ausgewählt, welche für eine Lastprognose von bis zu 24 Stunden unter Berücksichtigung von Wetterdaten eingesetzt wurden. Dabei sollten alle drei Klassen von Verfahren vertreten sein. Da ARIMA-Modelle und künstliche neuronale Netze in der jeweiligen Klasse die am häufigsten genutzten Verfahren sind und in vielen Anwendungsfällen gute Ergebnisse liefern [88, 101, 167], wurden diese ausgewählt. Aus der dritten Klasse wurden sowohl das Vergleichstagesverfahren als auch das synthetische Lastprofilverfahren genutzt.

5.2 Implementierte Prognoseverfahren

Zur Lastprognose von Einzelhaushalten wurden ausgewählte Verfahren, die üblicherweise für kumulierte Lastgänge eingesetzt werden, implementiert und adaptiert. Zunächst werden diese Verfahren theoretisch vorgestellt.

5.2.1 Saisonale ARIMA-Modelle

Saisonale ARIMA-Modelle (SARIMA-Modelle) [160], welche zur Familie der Box-Jenkins-Modelle [34] gehören, wurden stellvertretend für die Gruppe der klassischen Verfahren untersucht. ARIMA-Modelle bilden interne Strukturen von Zeitreihen ab, wie beispielsweise Autokorrelationen und Saisonalitäten. Grundlegend ist die Interpretation eines Lastgangs als Zeitreihe $\underline{Z} = \{z_t\}_{t=1,\dots,T}$. Diese stellt die Realisierung eines stochastischen Prozesses $\underline{Z} = \{z_t\}_{t=1,\dots,T}$ dar und besteht aus T beobachteten Werten zu den Zeitpunkten $t = 1, \dots, T$. Dabei wird angenommen, dass der Wert z_t der Zeitreihe zum Zeitpunkt t lediglich von Rauschtermen sowie gewichteten historischen Werten der Zeitreihe linear abhängt.

SARIMA-Modelle werden aus verschiedenen Teilmodellen gebildet. Elementare Bausteine sind Moving-Average-Prozesse der Ordnung Q , welche als MA(Q)-Prozesse bezeichnet werden. Diese werden definiert als:

$$z_t = \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_Q \epsilon_{t-Q}, \quad (5.1)$$

mit den Koeffizienten $\theta_1, \dots, \theta_Q$ und weißem Rauschen ϵ_t . Mit Hilfe des Verschiebungsoperators B , mit

$$B^D z_t = z_{t-D},$$

und des Polynoms

$$\Theta_Q(B) = 1 + \theta_1 B^1 + \theta_2 B^2 + \dots + \theta_Q B^Q$$

kann Gleichung (5.1) vereinfacht werden zu:

$$z_t = \Theta_Q(B) \epsilon_t.$$

Weitere elementare Bausteine von SARIMA-Modellen sind autoregressive Prozesse der Ordnung P , oder kurz AR(P)-Prozesse. Die Realisierung eines

AR(P)-Prozesses zu einem Zeitpunkt t hängt von P gewichteten Vergangenheitswerten und einem Rauschterm ϵ_t ab:

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_P z_{t-P} + \epsilon_t.$$

Mit dem Polynom

$$\Phi_P(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_P B^P$$

kann dieser Prozess geschrieben werden als:

$$\Phi_P(B) z_t = \epsilon_t.$$

Die Kombination der AR(P)- und MA(Q)-Modelle führt zum ARMA(P, Q)-Modell [324, S. 83]

$$z_t - \phi_1 z_{t-1} - \phi_2 z_{t-2} - \dots - \phi_P z_{t-P} = \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_Q \epsilon_{t-Q},$$

welches auch dargestellt werden kann als

$$\Phi_P(B) z_t = \Theta_Q(B) \epsilon_t. \quad (5.2)$$

Hierbei wird Stationarität des Prozesses \underline{Z} vorausgesetzt. Es kann gezeigt werden [34, Kap. 3.1.1], dass jeder stationäre stochastische Prozess sowohl durch Moving-Average-Prozesse als auch durch autoregressive Prozesse approximiert werden kann. Wenn beide Modelle kombiniert werden, besitzt das resultierende Modell jedoch eine niedrigere Ordnung [34, Kap. 3.1.4].

Sofern die Zeitreihe $\underline{z} = \{z_t\}_{t=1, \dots, T}$ eine homogene Instationarität aufweist, kann diese durch D -faches Differenzieren in eine stationäre Zeitreihe $\underline{z}' = \{z'_t\}_{t=1, \dots, T}$, mit

$$z'_t = (1-B)^D z_t = \nabla^D z_t,$$

überführt werden [324, S. 95], wobei der Differenzoperator ∇ definiert wird durch:

$$\nabla z_t = (1-B) z_t.$$

Einsetzen in Gleichung (5.2) liefert ein *integriertes* ARMA-Modell, welches als ARIMA(P, D, Q)-Modell bezeichnet wird:

$$\Phi_P(B) \nabla^D z_t = \Theta_Q(B) \epsilon_t. \quad (5.3)$$

Lastprofile von Haushalten weisen in der Regel Periodizitäten verschiedener Länge S auf, die unter anderem durch Tageszeit, Wochentag und Jahreszeit beeinflusst werden. In dem Fall werden *saisonale* ARIMA-Modelle (SARIMA-Modelle) genutzt; diese werden als $\text{SARIMA}(P, D, Q) \times (\tilde{P}, \tilde{D}, \tilde{Q})_S$ -Modelle bezeichnet. Hierbei stellen (P, D, Q) und $(\tilde{P}, \tilde{D}, \tilde{Q})_S$ die Ordnungen des saisonunabhängigen und des saisonalen Teils dar. Mit dem Differenzoperator ∇_h , wobei

$$\nabla_h z_t = (1 - B^h) z_t$$

gilt, und

$$\begin{aligned}\tilde{\Phi}_{\tilde{P}}(B^S) &= 1 - \tilde{\phi}_S B^S - \tilde{\phi}_{2,S} B^{2,S} - \dots - \tilde{\phi}_{\tilde{P},S} B^{\tilde{P},S}, \\ \tilde{\Theta}_{\tilde{Q}}(B^S) &= 1 + \tilde{\theta}_S B^S + \tilde{\theta}_{2,S} B^{2,S} + \dots + \tilde{\theta}_{\tilde{Q},S} B^{\tilde{Q},S}\end{aligned}$$

können SARIMA-Modelle auf Grundlage von Gleichung (5.3) kompakt geschrieben werden [324, S. 96]:

$$\Phi_P(B) \tilde{\Phi}_{\tilde{P}}(B^S) \nabla^D \nabla_S^{\tilde{D}} z_t = \Theta_Q(B) \tilde{\Theta}_{\tilde{Q}}(B^S) \epsilon_t. \quad (5.4)$$

Mit diesem Modell können Zusammenhänge der Zeitreihenwerte sowohl innerhalb einer Periode als auch zwischen Perioden abgebildet werden.

Um Prognosen durchzuführen, waren für jede Zeitreihe die Differenzierungsgrade, Ordnungen und Koeffizienten des Modells (5.4) zu ermitteln. Dies erfolgte nach der Box-Jenkins-Methode in den drei Schritten Modellidentifikation, Parameterschätzung und Modellvalidierung [34, Kap. 1.3.2]. Im Rahmen der Modellidentifikation wurden zunächst, wie in [95, Kap. 4.3] beschrieben, die Differenzierungsgrade D und \tilde{D} sowie die Ordnungen P, \tilde{P}, Q und \tilde{Q} mit Hilfe der Autokorrelationsfunktion und der partiellen Autokorrelationsfunktion [232, Kap. 2.3] ermittelt. Anschließend wurden die Koeffizienten der Polynome $\Phi, \tilde{\Phi}, \Theta$ und $\tilde{\Theta}$ mittels der in Matlab implementierten Maximum-Likelihood-Methode bestimmt. Bei der Modellvalidierung wurden mehrere angepasste Modelle verglichen und eines davon mittels des Schwarz-Bayes-Kriteriums [324, S. 84], welches Modelle anhand von Anpassungsgüte und Komplexität bewertet, ausgewählt. Diese Schritte wurden wiederholt, bis ein Modell die Zeitreihe zufriedenstellend abbildete. Da SARIMA-Modelle linear sind, wurden keine Temperaturabhängigkeiten modelliert. Diese stehen in einem nichtlinearen Zusammenhang zur Last [134].




Abbildung 5.2 – Modell eines künstlichen Neurons, nach [128]. Die Eingangssignale werden zunächst gewichtet und summiert. Aus dieser Summe wird dann mittels Aktivierungsfunktion und Schwellenwert die Ausgabe des künstlichen Neurons berechnet.

5.2.2 Künstliche neuronale Netze

Stellvertretend für Verfahren der künstlichen Intelligenz wurden künstliche neuronale Netze [149, Kap. 27] implementiert. Diese sind in der Lage, nicht-lineare Zusammenhänge abzubilden, die beispielsweise zwischen Lastverlauf und Lufttemperatur bestehen. Ferner benötigen künstliche Neuronale Netze kein mathematisches Systemmodell, welches die Beziehungen zwischen Lastdaten und anderen Einflussgrößen definiert. Stattdessen sind diese in der Lage, solche Zusammenhänge zu erlernen.

Das biologisch motivierte künstliche Neuron ist eine einfache Informationsverarbeitungseinheit, welche als reelle Vektoren $\underline{e} = (e_1, e_2, \dots, e_n)$ kodierte Eingangssignale verarbeitet. Wie in Abbildung 5.2 dargestellt, wird zunächst jede Vektorkomponente e_i mit einem Faktor w_i , dem synaptischen Gewicht, multipliziert. Eine Aktivierungsfunktion f erzeugt aus der Summe der gewichteten Eingänge und einem konstanten Schwellenwert b die Ausgabe y . Die Aktivierungsfunktion wird in Abhängigkeit des Anwendungsfalls und des gewünschten Lernverfahrens gewählt. Mathematisch lässt sich ein künstliches Neuron beschreiben durch

$$y = f\left(\sum_{i=1}^n w_i e_i + b\right).$$

In künstlichen neuronalen Netzen werden künstliche Neuronen miteinander verbunden, sodass die Ausgabe eines Neurons als Eingabe anderer Neuronen dient. Oftmals werden die künstlichen Neuronen dabei in Schichten angeordnet. Von einer Eingabeschicht, an welcher die Eingangsdaten anliegen, werden die verarbeiteten Signale über Zwischenschichten bis zu




Abbildung 5.3 – Vorwärtsgerichtetes künstliches neuronales Netz bestehend aus drei Schichten, von denen jede in einem anderen Grauton dargestellt ist [128]. Die Neuronen aufeinanderfolgender Schichten sind vollständig miteinander verbunden.

einer Ausgabeschicht propagiert. In sogenannten vorwärtsgerichteten Netzen existieren keine Zyklen, sodass der Informationsfluss ausschließlich in eine Richtung stattfindet. Diese Netztopologie kommt am häufigsten bei der Lastprognose zum Einsatz [112] und wird daher auch in dieser Arbeit näher betrachtet. Abbildung 5.3 zeigt ein solches künstliches neuronales Netz bestehend aus einer Eingabeschicht, einer Zwischenschicht und einer Ausgabeschicht. Die Ausgabeschicht umfasst zwar nur ein einzelnes künstliches Neuron, jedoch ist die Anzahl von Ausgabe-Neuronen beliebig.

Anhand der Anzahl der Neuronen in der Ausgabeschicht werden in dieser Arbeit zwei Typen von künstlichen neuronalen Netzen unterschieden. Mit Netzen des Typs 1 wird das gesamte Lastprofil in einem Schritt prognostiziert. Bei einem Prognosehorizont von 24 Stunden und einer zeitlichen Auflösung von 15 Minuten umfasst die Ausgabeschicht 96 Neuronen. Im Unterschied dazu wird mit Netzen des Typs 2 genau ein Leistungswert prognostiziert für einen Zeitschritt in einem definierten zeitlichen Abstand in der Zukunft. Bei diesem Vorgehen werden für eine 24-stündige Prognose daher 96 verschiedene Netze benötigt. Zu Evaluationszwecken wurden lediglich Netze für 8-Stunden-Vorhersagen untersucht.

Für die beiden Netztypen wurden jeweils drei Subtypen betrachtet, die sich anhand der Eingabeschicht unterscheiden. Der Eingang von Netzen des Typs 1.1 besteht aus dem aktuellen Leistungswert und den 96 Leistungswerten der vorhergehenden 24 Stunden. Modelle des Typs 1.2 enthalten zusätzlich 96 weitere Neuronen für die Lastdaten des Zeitabschnitts, der genau eine Woche vor dem zu prognostizierenden Zeitraum liegt. Für Netze des Typs 1.3 wird die Eingabeschicht von Modell 1.2 um 24 Neuronen erweitert, welche die Außentemperatur des zu prognostizierenden Zeitraums in stündlicher Auflösung repräsentieren.

Netze des Typs 2 wurden ebenfalls in drei Varianten erstellt und weisen vier, fünf bzw. sechs Eingabeneuronen auf. Die Eingangsvariablen der Netze des Typs 2.1 umfassen den Tagestyp, den aktuellen Leistungswert sowie die Leistungswerte einen Tag und eine Woche vor dem zu prognostizierenden Zeitschritt. Ferner wird in Netztyp 2.2 die Leistung zwei Wochen vor dem Prognosezeitpunkt und in Netztyp 2.3 zusätzlich die Temperatur zum Prognosezeitpunkt berücksichtigt.

Die betrachteten Netze wurden als vollständig verbunden angenommen, sodass jedes Neuron eine Verbindung zu allen Neuronen der folgenden Schicht aufweist. Dem üblichen Ansatz folgend, wurde nur eine Zwischenschicht modelliert [127]. Es wurden Netze mit Zwischenschichten verschiedener Größe evaluiert, um die erfolgversprechendste Größe zu bestimmen. Dabei wurden für Netze des Typs 1, je nach Lastprofil, Neuronenzahlen von 25–40 ermittelt und für die Netze des Typs 2 Anzahlen von 7–13.

Als Aktivierungsfunktion der künstlichen Neuronen wird der Tangens Hyperbolicus genutzt. Wenn die Topologie eines künstlichen neuronalen Netzes und die Aktivierungsfunktionen festgelegt sind, können Gewichte und Schwellenwerte bestimmt werden. Dieser Schritt wird, motiviert durch die Vorgänge im Gehirn, als Lernen bezeichnet. Zur Ermittlung der Parameter wird oftmals ein iterativer Ansatz gewählt. Für die vorliegende Arbeit wurde die Matlab-Implementierung des Backpropagation-Algorithmus [262] verwendet.

5.2.3 Vergleichstageverfahren und synthetische Lastprofile

Aus der Kategorie der referenzbasierten Verfahren wurde zum einen das Vergleichstageverfahren betrachtet. Dabei wird der Durchschnitt aus dem Leistungswert der letzten und der vorletzten Woche vor dem zu prognostizierenden Zeitschritt gebildet. Zum anderen wurde zur Lastprognose das auf den jeweiligen Jahresverbrauch skalierte Standardlastprofil H0 genutzt.

5.3 Evaluation der Prognoseverfahren

Die beschriebenen Verfahren wurden im Rahmen der Arbeit [95] evaluiert. Dieser Abschnitt fasst die wichtigsten Ergebnisse zusammen. Für eine detaillierte Darstellung sei auf die genannte Arbeit verwiesen.

5.3.1 Datenbasis

Zur Evaluation der Lastprognoseverfahren standen sechs anonymisierte, reale Datensätze zur Verfügung, die in Baden-Württemberg aufgezeichnet worden waren. Jeder Datensatz umfasste die gemessenen durchschnittlichen Wirkleistungswerte in Watt für 15-Minuten-Intervalle. Für fünf Datensätze waren Informationen über den Standort des Haushalts in Form von Postleitzahlen verfügbar, sodass Lufttemperaturdaten zugeordnet werden konnten. Diese Datensätze, im Folgenden als D1, D2, D3, D4 bzw. D5 bezeichnet, gehörten zu einem 1-, 2-, 3-, 4- bzw. 5-Personen-Haushalt. Die Leistungsdaten lagen für den Zeitraum 01.01.2010–28.02.2011 vor. Darüber hinaus wurden jedem Datensatz stündlich gemessene Lufttemperaturen von der jeweils nächstgelegenen Wetterstation zugeordnet, die im *Web-based Weather Request and Distribution System* des Bundesministeriums für Verkehr, Bau und Stadtentwicklung verfügbar war. Der sechste Datensatz, als D6 bezeichnet, repräsentierte die kumulierte Energienachfrage von 675 Haushalten im Zeitraum 01.01.2011–01.01.2012. Da der genaue Standort der einzelnen Haushalte unbekannt war, konnten keine Wetterdaten zugeordnet werden.

5.3.2 Fehlermaß

Für die Bewertung der Verfahren wurden die Messwerte jedes Datensatzes in zwei Teile aufgespaltet. Ein Teil wurde ausschließlich für die Bestimmung der Modellparameter verwendet. Diese Daten umfassten die ersten 20 Wochen der Lastwerte. Die verbleibenden Daten wurden für die Evaluation der Verfahren genutzt. Dieser Teil umfasste 40 Wochen für die Datensätze D1–D5 und 32 Wochen für D6. Obwohl für die referenzbasierten Verfahren keine Parameter bestimmt werden müssen, wurden auch diese Verfahren ausschließlich anhand des Evaluierungsdatensatzes bewertet.

Als Fehlermaß wurde der mittlere absolute prozentuale Fehler (englisch: *mean absolute percentage error*, MAPE) herangezogen, welcher definiert ist durch:

$$\text{MAPE} = \frac{1}{E} \sum_{i=1}^E \left| \frac{z_i^{\text{pred}} - z_i}{z_i} \right| \cdot 100\%. \quad (5.5)$$

Dabei bezeichnet E die Anzahl der Beobachtungen, z_i^{pred} einen prognostizierten Wert und z_i den entsprechenden gemessenen Wert. In der Literatur zu Lastprognosen wird dieses Fehlermaß am häufigsten verwendet [112].

Im vorliegenden Fall wird der MAPE über mehreren Beobachtungsmengen ermittelt. Zum einen wird der Prognosefehler für einen spezifischen Prognosehorizont h berechnet. Sofern der Evaluierungsdatensatz E zu prognostizierende Tage mit jeweils T Zeitschritten umfasst, wird der MAPE für den Prognosehorizont von h Zeitschritten ($1 \leq h \leq T$) berechnet durch:

$$\text{MAPE}_h = \frac{1}{E} \sum_{t=0}^{E-1} \left| \frac{z_{t \cdot T+h}^{\text{pred}} - z_{t \cdot T+h}}{z_{t \cdot T+h}} \right| \cdot 100 \%,$$

wobei $z_{t \cdot T+h}^{\text{pred}}$ die prognostizierte Leistung im Zeitschritt $t \cdot T + h$ bezeichnet und $z_{t \cdot T+h}$ die gemessene Leistung. Damit ist es möglich, die Prognosen für einen spezifischen Zeithorizont zu beurteilen, beispielsweise alle prognostizierten Lasten, die 75 Minuten in der Zukunft liegen. Zum anderen wird der mittlere Prognosefehler MAPE_\emptyset über alle Prognosehorizonte berechnet, um vollständige Prognosen für T Zeitschritte zu bewerten:

$$\text{MAPE}_\emptyset = \frac{1}{T} \sum_{h=1}^T \text{MAPE}_h.$$

Im Folgenden werden Prognosen für 24 Stunden bei einer zeitlichen Auflösung von 15 Minuten betrachtet, sodass $T = 96$ gilt.

5.3.3 Ergebnisse

Die ermittelten Prognoseabweichungen der referenzbasierten Methoden und der SARIMA-Modelle sind in Tabelle 5.1 aufgeführt. Das Vergleichstagerverfahren führte auf allen Datensätzen bis auf D1 im Schnitt zu 15,2 Prozentpunkte geringeren Prognosefehlern als das synthetische Lastprofilverfahren auf Basis des H0-Profiles. Da das synthetische Lastprofil, vom Gesamtjahresverbrauch abgesehen, nicht an die individuellen Datensätze angepasst wird, war das schlechtere Abschneiden zu erwarten. Aufgrund der hohen Volatilität des Lastprofils des 1-Personen-Haushalts hatten vergangene Leistungswerte nur geringe Aussagekraft für die Prognose, sodass der Prognosefehler 1,4 Prozentpunkte höher lag als beim Lastprofilverfahren.

Tabelle 5.1 – Prognosefehler ($MAPE_{\emptyset}$) für die referenzbasierten Verfahren, das SARIMA-Verfahren und die künstlichen neuronalen Netze des Typs 1 [128]. Den niedrigsten Prognosefehler (dunkelgrau markiert) lieferte auf allen Datensätzen das SARIMA-Verfahren. Der kleinste Prognosefehler unter den künstlichen neuronalen Netzen ist jeweils hellgrau markiert. Da für Datensatz D6 keine Wetterdaten vorlagen, konnten keine künstlichen neuronalen Netze vom Typ 1.3 genutzt werden.

Daten- satz	Vergleichsta- geverfahren	H0- Profil	SARIMA- Verfahren	Neuronale Netze		
				Typ 1.1	Typ 1.2	Typ 1.3
D1	94,71 %	93,31 %	86,42 %	91,58 %	93,53 %	117,72 %
D2	37,84 %	46,17 %	33,24 %	39,18 %	40,02 %	41,08 %
D3	36,90 %	53,30 %	32,06 %	58,47 %	59,25 %	60,23 %
D4	42,42 %	67,36 %	30,60 %	34,76 %	35,24 %	37,41 %
D5	56,38 %	69,43 %	50,39 %	76,32 %	73,68 %	74,06 %
D6	6,38 %	19,63 %	5,43 %	9,51 %	10,83 %	—

Wie in Tabelle 5.1 abzulesen ist, waren die Prognosefehler des SARIMA-Verfahrens durchweg niedriger als die Prognosefehler der referenzbasierten Verfahren. Im Schnitt lag dieser Unterschied bei 5,8 Prozentpunkten verglichen zum jeweils besten referenzbasierten Verfahren. Dabei nahm die Prognosegüte, mit Ausnahme des 5-Personen-Haushalts, mit zunehmender Haushaltsgröße ebenfalls zu. Dies ist darauf zurückzuführen, dass sich Unregelmäßigkeiten in den Lebensgewohnheiten einer Person mit zunehmender Haushaltsgröße schwächer auswirken. Datensatz D5 stellte hierbei mit seiner höheren Volatilität die Ausnahme dar. D6 sticht durch einen deutlich niedrigeren Prognosefehler hervor. Hier traten bereits Skaleneffekte auf [303]: Das aggregierte Lastprofil wies einen wesentlich gleichmäßigeren Verlauf auf und war damit leichter zu prognostizieren.

In Tabelle 5.1 sind auch die Prognosefehler für die künstlichen neuronalen Netze vom Typ 1 aufgeführt. Modell 1.2 schnitt auf allen Datensätzen besser ab als Modell 1.3. Dies spricht dafür, dass der Informationsgewinn bezüglich der Temperatur die höhere Komplexität des Netzes 1.3 nicht rechtfertigte. Auf fünf von sechs Datensätzen lieferte Modell 1.1 unter den drei Netzen vom Typ 1 die besten Prognosen. Auch hier überwog der Nachteil der höheren Komplexität gegenüber der Abhängigkeit des Lastverlaufs von

weiter zurückliegenden Messwerten. Dabei konnte eine Überanpassung der Netze beim Lernen ausgeschlossen werden, wie in [95] beschrieben. Gegenüber dem Vergleichstagesverfahren schnitten künstliche neuronale Netze auf vier Datensätzen schlechter ab und gegenüber dem synthetischen Lastprofilverfahren auf zwei Datensätzen. Dies deutet darauf hin, dass die Netzarchitektur vom Typ 1 nicht geeignet ist für Lastprognosen von Einzelhaushalten. Im Gegensatz hierzu werden zur Prognose von aggregierten Lastprofilen vergleichbare Netzarchitekturen am häufigsten genutzt, wobei diese meist gute Ergebnisse erzielen [127].

Neben den Netzen vom Typ 1 wurden kleinere Netze vom Typ 2 implementiert. Da für jeden zu prognostizierenden Zeithorizont ein separates Netz nötig gewesen wäre, wurde lediglich ein Netz für den Horizont von 8 Stunden erstellt, um einen Vergleich mit den Netzen vom Typ 1 herzustellen. Bei den Netzen vom Typ 2 zeigte sich, dass Wetterinformationen und ältere Messwerte erfolgreich in die Prognose eingebracht werden konnten, wie in Tabelle 5.2 abzulesen ist. Netztyp 2.2 führte auf vier von sechs Datensätzen zu kleineren Prognosefehlern als Netztyp 2.1, während Netztyp 2.3 auf vier von fünf Datensätzen bessere Werte als Netztyp 2.1 lieferte. Eine eindeutige Bevorzugung von Netztyp 2.2 oder 2.3 war nicht möglich. Ersterer führte auf zwei von fünf Datensätzen zu einem durchschnittlich 2,8 Prozentpunkte kleineren Prognosefehler, während letzterer auf den anderen drei Datensätzen im Schnitt 1,5 Prozentpunkte kleinere Fehler verursachte.

Tabelle 5.2 – Prognosefehler (MAPE₃₂) der 8-Stunden-Prognosen von künstlichen neuronalen Netzen des Typs 1 und 2 [128]. Das Verfahren mit dem geringsten Prognosefehler ist für jeden Datensatz grau markiert. Da für D6 keine Wetterdaten vorlagen, waren Netze vom Typ 1.3 und 2.3 nicht nutzbar.

Datensatz	Typ 1.1	Typ 1.2	Typ 1.3	Typ 2.1	Typ 2.2	Typ 2.3
D1	92,27 %	93,58 %	108,40 %	88,28 %	89,06 %	93,76 %
D2	39,48 %	40,09 %	42,10 %	36,37 %	35,09 %	36,02 %
D3	59,24 %	61,22 %	62,21 %	39,24 %	35,52 %	34,04 %
D4	34,56 %	35,54 %	37,02 %	34,99 %	35,35 %	34,74 %
D5	75,69 %	70,96 %	74,29 %	61,28 %	56,58 %	54,05 %
D6	9,85 %	10,79 %	—	6,08 %	5,89 %	—

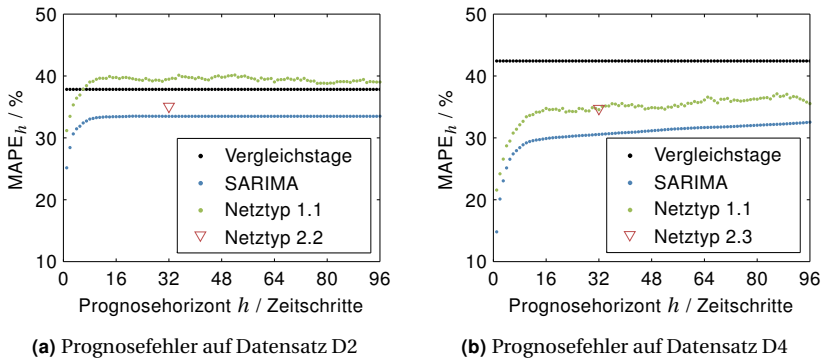


Abbildung 5.4 – Prognosefehler ($MAPE_h$) in Abhängigkeit des Prognosehorizonts [95]. Für die künstlichen neuronalen Netze ist jeweils für die Typen 1 und 2 das Ergebnis des Netzes mit dem geringsten durchschnittlichen Fehler ($MAPE_\emptyset$) dargestellt.

Im Vergleich zu den besten Netzen des Typs 1 wiesen die besten Netze des Typs 2 im vorliegenden Anwendungsfall auf fünf Datensätzen geringere Prognosefehler auf, wobei die Verbesserung zwischen 3,96 und 25,2 Prozentpunkten lag. Auf Datensatz D4 war der Prognosefehler der Netze vom Typ 1 hingegen um 0,20 Prozentpunkte kleiner. Des Weiteren führte das jeweils beste Netz vom Typ 2 auf allen Datensätzen zu geringeren Prognosefehlern als das Vergleichstageverfahren. Demzufolge konnten die kleineren künstlichen neuronalen Netze für Lastprognosen von Einzelhaushalten erfolgreich genutzt werden. Insbesondere gegenüber Netzarchitektur 1 wiesen die Netze vom Typ 2 Vorteile auf. Gegenüber den SARIMA-Modellen führten die künstlichen neuronalen Netze jedoch zu höheren Prognosefehlern.

Die bisher vorgestellten Ergebnisse bezogen sich auf die Aggregation aller Prognosehorizonte. Der Prognosefehler variierte allerdings für verschiedene Prognosehorizonte. Abbildung 5.4 zeigt, wie sich der Prognosefehler in Abhängigkeit des Prognosehorizonts entwickelte. Dargestellt sind hier die Ergebnisse für die Datensätze D2 und D4, die repräsentativ für alle betrachteten Datensätze sind. Durch den $MAPE_\emptyset$ wurde eine Rangfolge der Verfahren bezüglich der Prognoseabweichung hergestellt. Aus den Abbildungen wird ersichtlich, dass diese Rangfolge über den gesamten Prognosehorizont erhalten blieb – mit Ausnahme des Vergleichstageverfahrens. Wenn ein Ver-

fahren im Mittel einen geringeren Prognosefehler erzeugte als ein anderes Verfahren, so galt dies auch für jeden einzelnen Prognosehorizont.

Der Fehler des Vergleichstagesverfahrens war über den gesamten Prognosehorizont konstant. Dies ist darauf zurückzuführen, dass die Lastwerte von zwei Vorwochen eingingen, die unabhängig vom konkreten Prognosehorizont waren. Bei den anderen Prognoseverfahren war eine Zunahme des Fehlers über den Prognosehorizont zu erkennen. Für die Horizonte von bis zu zwei Stunden war dieser Anstieg besonders ausgeprägt. Der Grund hierfür lag in der Nutzung von Verbrauchswerten bei der Prognose, welche kurz vor dem zu prognostizierenden Zeitschritt gemessen worden waren. Für die unmittelbar folgenden Zeitschritte erlaubten diese Werte gute Schätzungen. Je länger der Prognosehorizont wurde, desto geringer wurde jedoch der Einfluss der letzten gemessenen Lastwerte. Dann nahm, ähnlich wie beim Vergleichstagesverfahren, der Einfluss der Werte der Vorwoche zu, sodass sich der Prognosefehler nur noch geringfügig veränderte.

5.4 Zusammenfassung und Fazit

Während Lastprognosen für Aggregationen von Verbrauchern in vielen Bereichen der Energiewirtschaft etabliert sind, gibt es kaum Untersuchungen hinsichtlich der Lastprognose von Einzelhaushalten [101]. Die wenigen Studien, welche diesbezüglich durchgeführt wurden, basieren entweder auf gröberer Zeitdiskretisierung oder nutzen keine Wetterdaten. Um eine an den betrachteten Anwendungsfall angepasste Lastprognose zu erstellen, wurden zunächst die Verfahren klassifiziert, die für Lastprognosen im Allgemeinen eingesetzt werden. Diese können in referenzbasierte Verfahren, Verfahren der künstlichen Intelligenz und klassische Verfahren eingeteilt werden. Aus jeder dieser Klassen wurde mindestens ein Verfahren implementiert, um eine breite Übersicht über Potenziale der Prognose zu erhalten. Diese Verfahren wurden anhand von sechs realen Datensätzen evaluiert, von denen fünf in Einzelhaushalten aufgezeichnet worden waren. Einer der Datensätze bildete den aggregierten Verbrauch von 675 Haushalten ab.

Aus der Klasse der referenzbasierten Verfahren wurden ein Vergleichstagesverfahren sowie ein synthetisches Lastprofilverfahren basierend auf dem H0-Lastprofil betrachtet. Diese Verfahren benötigen kein formales Modell

und werden in der Energiewirtschaft häufig eingesetzt. In der durchgeführten Studie sollten diese Verfahren das Mindestmaß an Prognosequalität festlegen, welches von den komplexeren Verfahren eingehalten werden sollte, um einen sinnvollen Einsatz zu ermöglichen.

Künstliche neuronale Netze sind die Verfahren der künstlichen Intelligenz, welche in der Literatur am häufigsten zum Einsatz kommen. Daher wurden künstliche neuronale Netze in zwei Architekturvarianten mit jeweils drei Ausprägungen untersucht. Beide Architekturtypen waren vorwärts gerichtet und bestanden aus drei vollständig verbundenen Schichten. Der Unterschied bestand in der Anzahl der Eingabe- und Ausgabeneuronen. Netze vom Typ 1 erstellten in einem Schritt die Lastprognose für alle Prognosehorizonte, während Netze vom Typ 2 die Prognose für einen einzigen festen Horizont erstellten. Bedingt durch die höhere Zahl von zu präzisierenden Werten, wiesen Netze des Typs 1 mehr Neuronen in der Eingabeschicht und in der Zwischenschicht auf als Netze des Typs 2. Den 11–19 Neuronen bei Typ 2 standen 218–353 Neuronen bei Typ 1 gegenüber. Die Prognoseergebnisse legen nahe, dass die größeren Architekturen nicht zweckmäßig für den betrachteten Anwendungsfall sind. Es wurden drei Netze des Typs 1 untersucht, die sich durch die Eingangsdaten unterschieden. Trotz zusätzlicher historischer Lastdaten und zusätzlicher Temperaturdaten sank die Prognosequalität der größeren Netze. Das beste der drei Netze vom Typ 1 lieferte nur auf zwei von sechs Datensätzen bessere Prognosen als das Vergleichstageverfahren. Demgegenüber wiesen Vorhersagen der Netze vom Typ 2 geringere Prognosefehler als das Vergleichstageverfahren auf. Dabei erhöhten zusätzliche Last- und Temperaturdaten die Prognosequalität. Dieser Architekturtyp erwies sich somit für den Anwendungsfall als geeignet.

Saisonale ARIMA-Verfahren, als Vertreter der klassischen Verfahren, lieferten von allen betrachteten Verfahren die genauesten Lastprognosen. Deren Prognosefehler war auf allen Datensätzen am geringsten. Auf den aggregierten Lastdaten betrug der Prognosefehler 5,4 %, gemessen als MAPE. In manchen Studien werden mittels SARIMA-Modellen Prognosefehler unter 3 % erreicht [301]. Die zugrunde liegenden Datensätze aggregieren jedoch den Verbrauch von Großstädten oder größeren Regionen und weisen dadurch eine wesentlich geringere Volatilität auf.

Zusammenfassend wurde gezeigt, dass künstliche neuronale Netze und SARIMA-Verfahren für die kurzfristige Lastprognose von Einzelhaushalten

geeignet sind. Sofern aktuelle Messwerte intelligenter Stromzähler vorliegen, können bessere Prognosen erstellt werden als mittels Vergleichstagesverfahren und Standardlastprofilen. Dennoch liegen die Prognosefehler aufgrund der Volatilität des Verbrauchs deutlich höher als bei räumlich aggregierten Lasten. Die SARIMA-Verfahren führten bei Einzelhaushalten zu Prognosefehlern zwischen 30,6 % und 86,4 %.

In Kapitel 3 wurde das Rahmenszenario für ein Energiemanagement mit dem Ziel der flexiblen Leistungsführung beschrieben. Hierzu wurde ein Optimierungsproblem skizziert. Dieses Kapitel knüpft an jener Stelle an und stellt das Optimierungsproblem zunächst anschaulich dar. Daraufhin werden mathematische Formulierungen des Problems präsentiert. Abschließend werden drei genetische Algorithmen zu deren Lösung beschrieben.

6.1 Optimierungsproblem anschaulich


Die Formulierung des Optimierungsproblems zur flexiblen Leistungsführung beruht auf den Annahmen aus Abschnitt 3.1.2. Demnach kennt der Energiemanager die Leistungsprognosen der Entitäten und das Zielprofil für die Aggregation der Entitäten. Hieraus kann die Zielabweichung für den Planungshorizont berechnet werden. Ferner erhält der Energiemanager von den Entitäten Verlagerungsangebote. Diese geben für jeden Zeitschritt die Änderung der Leistung der entsprechenden Entität an und entsprechen damit einem Differenzprofil bezogen auf die ursprüngliche Prognose.

Das Optimierungsproblem ist unabhängig von den konkreten Werten der Leistungsprognosen und des Zielprofils. Es werden ausschließlich die Änderungen bezüglich der bekannten Prognosen und die Zielabweichungen betrachtet. Diese Differenzgrößen enthalten alle nötigen Informationen. Die Zielabweichung wird bezüglich eines Wirkleistungsprofils minimiert; daher sind die im Folgenden betrachteten Leistungswerte Wirkleistungen.


Abbildung 6.1 veranschaulicht das Prinzip der Optimierung für einen Planungshorizont von sechs Zeitschritten. Die roten Säulen stellen für jeden Zeitschritt die angestrebten Verlagerungen dar. Diese entsprechen den Ab-

weichungen vom Zielprofil, welche in Abschnitt 3.1.2 so definiert wurden, dass deren Vorzeichen mit den Vorzeichen der angestrebten Verlagerungen übereinstimmen. Die grünen, blauen und schwarzen Säulen, die in Abbildung 6.1a nebeneinander stehen, repräsentieren die Verlagerungsangebote von drei Entitäten. Angebot 1, dargestellt durch breite Säulen, ist ein intervallartiges Angebot, wie es in Gleichung (3.2) auf Seite 40 definiert wurde. Wie in Abschnitt 3.1.1 motiviert, repräsentiert dieses die Flexibilität eines Erzeugers. Hierbei kann der Energiemanager innerhalb der Intervalle, welche durch die Säulen angedeutet sind, die Leistungsänderungen für jeden Zeitschritt einzeln festlegen. Die Intervalle reichen von den unteren bis zu den oberen Ende der Säulen, wobei negative Werte einer Einspeisedrosselung entsprechen und positive Werte einer Erhöhung. In jedem Zeitschritt muss eine Änderung von 0 W möglich sein, sodass der Energiemanager Änderungen ablehnen kann. Die Angebote 2 und 3, dargestellt durch schmale Säulen, sind feste Angebote, wie durch Gleichung (3.1) auf Seite 39 beschrieben. Diese stammen von Verbrauchern und können entweder für *alle* Zeitschritte akzeptiert oder abgelehnt werden. Die Verlagerungen jedes Verbrauchers ergeben in Summe jeweils Null, sodass der Gesamtverbrauch unverändert bleibt. Dies muss nicht für Zielprofil und Erzeugung gelten.

Das Optimierungsproblem des Energiemanagers besteht darin, aus den Angeboten diejenigen auszuwählen, welche in Summe die angestrebten Verlagerungen möglichst gut approximieren. Hierbei müssen zwei Möglichkeiten der Summation unterschieden werden. Zum einen kann, für jeden Zeitschritt einzeln, die Summe der Angebote eines Zeitschritts gebildet werden. Zum anderen können die Angebote über die Zeitschritte hinweg addiert werden. Für das vorliegende Optimierungsproblem kommt zunächst die erste Variante zum Einsatz, d. h. die Zeitschritte werden getrennt betrachtet. Dies ist in Abbildung 6.1b veranschaulicht. Werden die ersten beiden Angebote akzeptiert und das dritte abgelehnt, so ist für jeden Zeitschritt die Summe aus Angebot 1 und Angebot 2 zu bilden. In der Abbildung ist dies durch Stapeln der grünen und blauen Säulen angedeutet. Dabei sind die Höhen der blauen Säulen fest und die Höhen der grünen Säulen variabel. Es ist zu beachten, dass Angebot 2 für alle Zeitschritte des Planungshorizonts akzeptiert wird; Leistungsänderungen einzelner Zeitschritte unabhängig voneinander auszuwählen ist nicht möglich. Anschaulich bedeutet dies, dass die blauen Säulen in allen Zeitschritten zu berücksichtigen sind.



(a) Angestrebte Verlagerung sowie drei Verlagerungsangebote



(b) Angebote 1 und 2 wurden akzeptiert, Angebot 3 abgelehnt

Abbildung 6.1 – Prinzipdarstellung des Optimierungsproblems für drei Verlagerungsangebote mit einem Planungshorizont von sechs Zeitschritten. Die Säulen repräsentieren Leistungsänderungen. Schmale Säulen stellen feste Werte dar und breite Säulen variable Werte.

Die verbleibende Zielabweichung pro Zeitschritt nach Auswahl der Angebote entspricht der Differenz zwischen der Summe der akzeptierten Angebote und dem Zielprofil. In Abbildung 6.1b wird diese Abweichung durch horizontale, gepunktete Linien dargestellt. In den Zeitschritten 2 und 3 wird die angestrebte Leistungsänderung nicht erreicht. Hingegen kann in den anderen Zeitschritten durch geeignete Wahl von Angebot 1 das Zielprofil eingehalten werden. Die Approximation des gesamten Zielprofils wird schließlich bewertet, indem die verbleibenden Zielabweichungen über alle Zeitschritte hinweg addiert werden. Dabei können die Werte der Abweichungen quadriert werden, um hohe Abweichungen stärker zu gewichten.

Zur Wahrung der Übersichtlichkeit wurden in den Darstellungen bisher zwei Aspekte der Optimierung vernachlässigt. Dazu gehören zum einen Nebenbedingungen, die technische Restriktionen modellieren. Beispiels-

weise könnte die Änderungsrate der Erzeugung physikalisch beschränkt sein. Zum anderen wurden die Kosten für die Verlagerungsangebote nicht betrachtet, welche bei der Auswahl der Angebote ebenfalls eine Rolle spielen. In klassischen Optimierungsproblemen der Energiewirtschaft, wie dem Economic Dispatch oder dem Unit Commitment, stellen die Kosten das zu minimierende Ziel dar. Der Abgleich von Erzeugung und Verbrauch wird dabei als Gleichheitsnebenbedingung berücksichtigt. Da in der Regel genügend Erzeugungskapazitäten zur Deckung des prognostizierten Bedarfs vorhanden sind, ist diese Nebenbedingung erfüllbar. Der in dieser Arbeit betrachtete Energiemanagement-Ansatz setzt nicht voraus, dass mittels der Angebote der Entitäten das Zielprofil exakt erreicht werden kann. Würde die Zielerreichung als Nebenbedingung formuliert, so wäre die Existenz gültiger Lösungen nicht sichergestellt. Aus diesem Grund wird, neben den Kosten, die Abweichung von dem vorgegebenen Leistungsprofil als zweite Zielfunktion modelliert. Lösungen, welche das Zielprofil exakt abbilden, minimieren die zweite Zielfunktion. Die erste Zielfunktion sorgt dafür, dass unter diesen Lösungen die günstigste gewählt wird.

Bei der Optimierung gilt es, zwischen Minimierung der Zielabweichung und Minimierung der Kosten einen Kompromiss zu finden. Beide Ziele sind gegenläufig, da eine geringere Abweichung normalerweise erzielt wird durch eine höhere Leistungsverschiebung, und damit durch höhere Kosten. Es existieren mehrere Möglichkeiten, die gleichzeitige Minimierung durchzuführen. Einerseits kann das Problem skalarisiert werden, zum Beispiel indem eine gewichtete Summe der Zielfunktionen optimiert wird. Andererseits kann eine multikriterielle Optimierung durchgeführt werden. In den folgenden Abschnitten wird das vorgestellte Optimierungsproblem unter Berücksichtigung der zuvor genannten Aspekte mathematisch modelliert. Es wird eine skalare und eine multikriterielle Formulierung präsentiert.

6.2 Skalares Optimierungsproblem für das Lastmanagement

Zunächst wird das in Abschnitt 6.1 dargestellte Optimierungsproblem für Lastmanagement-Szenarien formuliert, welche ausschließlich Verbraucher umfassen. Dabei werden zwei Problemformulierungen betrachtet, die sich durch die Nebenbedingungen unterscheiden.

6.2.1 Unrestringiertes Problem

Bleiben Netzrestriktionen vorerst unberücksichtigt, so kann das Optimierungsproblem als binäres Programm formuliert werden:

$$\min f(\underline{x}) = w_1 \sum_{n=1}^N c_n x_n + w_2 \sum_{t=1}^T \left(\sum_{n=1}^N (p_{tn} x_n) - a_t \right)^2 \quad (\text{P1})$$

$$\text{u. d. N.} \quad x_n \in \{0, 1\}, \quad n = 1, \dots, N.$$

Darin bezeichnet c_n die Kosten für das gesamte Angebot von Entität n über alle Zeitschritte des Optimierungshorizonts. Ferner stellt p_{tn} die zu verlagernde Wirkleistung von Entität n zum Zeitpunkt t und a_t die Ziel-Wirkleistungsverlagerung zum Zeitpunkt t dar. In Abbildung 6.1 wird beispielsweise die schwarze Säule in Zeitschritt 1 mit p_{13} bezeichnet und a_2 entspricht der roten Säule in Zeitschritt 2.

Die Zielfunktion bezieht zwei Einflussfaktoren ein, die unterschiedlich gewichtet werden können. Zum einen ist dies der Preis der Verlagerungsangebote, welcher mit dem Gewicht w_1 eingeht. Zum anderen wird die Summe der quadrierten Zielabweichungen jeder Zeiteinheit mit w_2 gewichtet. Auf diese Weise finden beide Ziele entsprechend ihrer Bedeutung für den Energiemanager Berücksichtigung. Der Vektor \underline{x} besteht aus den binären Entscheidungsvariablen x_n für $n = 1, \dots, N$, welche angeben, ob das Verlagerungsangebot von Entität n als Ganzes angenommen ($x_n = 1$) oder abgelehnt ($x_n = 0$) wird.

Im Folgenden wird die Komplexität des Optimierungsproblems (P1) diskutiert. Hierzu wird zunächst eine äquivalente Formulierung der Zielfunktion aufgestellt, die nur aus quadratischen Termen besteht. Anschließend wird der Bezug zu einem \mathcal{NP} -schweren Problem hergestellt.

Die Zielfunktion kann so umformuliert werden, dass die quadratische Differenz im zweiten Summanden verschwindet. Für $t \in \{1, \dots, T\}$ gilt:

$$\begin{aligned} \left(\sum_{n=1}^N (p_{tn} x_n) - a_t \right)^2 &= \left(\sum_{n=1}^N p_{tn} x_n \right)^2 - 2a_t \sum_{n=1}^N (p_{tn} x_n) + a_t^2 \\ &= \sum_{n_1=1}^N \sum_{n_2=1}^N (p_{tn_1} p_{tn_2} x_{n_1} x_{n_2}) - 2a_t \sum_{n=1}^N (p_{tn} x_n) + a_t^2. \end{aligned}$$

Für die zweite Umformung wurde das Multinomialtheorem [198, Kap. 1.7.2]

$$(x_1 + x_2 + \dots + x_n)^\alpha = \sum_{\substack{\alpha_1, \dots, \alpha_n \in \mathbb{N} \\ \alpha_1 + \dots + \alpha_n = \alpha}} \frac{\alpha!}{\alpha_1! \alpha_2! \dots \alpha_n!} x_1^{\alpha_1} x_2^{\alpha_2} \dots x_n^{\alpha_n}$$

mit $\alpha = 2$ genutzt. Damit kann die Zielfunktion aus Problem (P1) geschrieben werden als

$$\begin{aligned} f(\underline{x}) &= w_1 \sum_{n=1}^N (c_n x_n) \\ &\quad + w_2 \sum_{t=1}^T \left(\sum_{n_1=1}^N \sum_{n_2=1}^N (p_{tn_1} p_{tn_2} x_{n_1} x_{n_2}) - 2a_t \sum_{n=1}^N (p_{tn} x_n) + a_t^2 \right) \\ &= \sum_{n=1}^N (\tilde{c}_n x_n) + \sum_{n_1=1}^N \sum_{n_2=1}^N (\tilde{p}_{n_1 n_2} x_{n_1} x_{n_2}) + \sum_{n=1}^N (\tilde{p}_n x_n) + \tilde{a} \\ &= \sum_{n=1}^N (b_n x_n) + \sum_{n_1=1}^N \sum_{n_2=1}^N (\tilde{p}_{n_1 n_2} x_{n_1} x_{n_2}) + \tilde{a}, \end{aligned}$$

mit $\tilde{a} = w_2 \sum_{t=1}^T a_t^2$, $b_n = \tilde{c}_n + \tilde{p}_n$, $\tilde{c}_n = w_1 c_n$ und $\tilde{p}_n = -2w_2 \sum_{t=1}^T a_t p_{tn}$, $\tilde{p}_{n_1 n_2} = w_2 \sum_{t=1}^T p_{tn_1} p_{tn_2}$.

Da x_n binär ist, gilt $x_n^2 = x_n$. Daher kann $f(\underline{x})$ ohne Beschränkung der Allgemeinheit als

$$f(\underline{x}) = \tilde{a} + \sum_{n_1=1}^N \sum_{n_2=1}^N \bar{p}_{n_1 n_2} x_{n_1} x_{n_2}$$

ausgedrückt werden, mit

$$\bar{p}_{n_1 n_2} = \begin{cases} \tilde{p}_{n_1 n_2} + b_{n_1} & \text{für } n_1 = n_2 \\ \tilde{p}_{n_1 n_2} & \text{für } n_1 \neq n_2. \end{cases}$$

Damit kann (P1) folgendermaßen dargestellt werden:

$$\min f(\underline{x}) = \tilde{a} + \sum_{n_1=1}^N \sum_{n_2=1}^N \bar{p}_{n_1 n_2} x_{n_1} x_{n_2} \quad (\text{P1}')$$

$$\text{u. d. N.} \quad \underline{x} \in \{0, 1\}^N.$$

Der konstante Summand \tilde{a} ist vernachlässigbar, da dieser keinen Einfluss auf die Lösung \underline{x} und die Problemkomplexität besitzt. Problem (P1') entspricht somit dem unrestringierten binären quadratischen Programm [105]

$$\min q(\underline{x}) = \sum_{m=1}^N \sum_{n=1}^N q_{mn} x_m x_n \quad (\text{P2})$$

$$\text{u. d. N.} \quad \underline{x} \in \{0, 1\}^N,$$

welches im Allgemeinen \mathcal{NP} -schwer ist [18, 105, 114, 199]. Es gibt jedoch in Polynomialzeit lösbare Spezialfälle, vor allem für konvexe $q(\underline{x})$ [8, 23, 25, 235, 236, 243]. Im Folgenden wird (P2) in Matrixform geschrieben:

$$\min q(\underline{x}) = \underline{x}' \mathbf{Q} \underline{x}$$

$$\text{u. d. N.} \quad \underline{x} \in \{0, 1\}^N.$$

Dabei ist $\mathbf{Q} = (q_{tn})_{t,n \in \{1, \dots, N\}}$ die Matrix der Koeffizienten aus (P2) und \underline{x}' der zu \underline{x} transponierte Vektor. Nun wird eine gültige Probleminstanz mit indefiniter Matrix \mathbf{Q} konstruiert. In diesem Fall ist das Optimierungsproblem nicht konvex [89].

Sei $N = T = 2$, d. h. es gibt zwei Entitäten und der Planungshorizont beträgt zwei Zeiteinheiten. Ferner seien die Vektoren

$$\underline{a} = \begin{pmatrix} 2 \\ 0 \end{pmatrix}, \quad \underline{p}_1 = \begin{pmatrix} 1 \\ -1 \end{pmatrix}, \quad \underline{p}_2 = \begin{pmatrix} -1 \\ 1 \end{pmatrix}$$

gegeben. Dabei sind \underline{p}_1 und \underline{p}_2 die Verlagerungsangebote beider Entitäten. Die Preise und Gewichte seien $c_1 = c_2 = 1$ und $w_1 = w_2 = 1$. Dann gilt für \mathbf{Q} :

$$\begin{aligned} \mathbf{Q} &= \begin{pmatrix} \bar{p}_{11} & \bar{p}_{12} \\ \bar{p}_{21} & \bar{p}_{22} \end{pmatrix} = \begin{pmatrix} \tilde{p}_{11} + b_1 & \tilde{p}_{12} \\ \tilde{p}_{21} & \tilde{p}_{22} + b_2 \end{pmatrix} = \begin{pmatrix} \tilde{p}_{11} + \tilde{c}_1 + \tilde{p}_1 & \tilde{p}_{12} \\ \tilde{p}_{21} & \tilde{p}_{22} + \tilde{c}_2 + \tilde{p}_2 \end{pmatrix} \\ &= \begin{pmatrix} 2+1-4 & -2 \\ -2 & 2+1+4 \end{pmatrix} = \begin{pmatrix} -1 & -2 \\ -2 & 7 \end{pmatrix}. \end{aligned}$$

Die Matrix ist indefinit, da das Produkt $\underline{x}' \mathbf{Q} \underline{x}$ verschiedene Vorzeichen aufweist für die Vektoren

$$\underline{x}_1 = \begin{pmatrix} 1 \\ 0 \end{pmatrix} \quad \text{und} \quad \underline{x}_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}.$$

Diese Überlegung kann verallgemeinert werden. Für jede beliebige Problemgröße existieren Instanzen, die nicht konvex sind. Dies gilt beispielsweise dann, wenn es Zeitintervalle gibt, in denen die Verlagerungsangebote von mindestens zwei Entitäten m und n verschiedene Vorzeichen besitzen. Dann ist es – mathematisch und physikalisch – möglich, a derart zu wählen, dass ohne Beschränkung der Allgemeinheit \tilde{p}_m positiv und \tilde{p}_n negativ wird. Ist \tilde{p}_n hinreichend klein, wird q_{nn} negativ und q_{mm} positiv, sodass Q indefinit ist. Offensichtlich ist das betrachtete Problem also \mathcal{NP} -schwer.

6.2.2 Restringiertes Problem

Um Angebote zu unterbreiten, die in Optimierungsproblem (P1) betrachtet werden, legen sich Verbraucher auf ein Verlagerungsprofil fest. Ist Konsument n jedoch in der Lage, κ_n konkurrierende Angebote gleichzeitig abzugeben, sollten diese in der Optimierung berücksichtigt werden. Problem (P1) kann in diesem Falle umformuliert werden zu:

$$\min f(\underline{x}) = w_1 \sum_{n=1}^N \sum_{\kappa=1}^{\kappa_n} c_{\kappa,n} x_{\kappa,n} + w_2 \sum_{t=1}^T \left(\sum_{n=1}^N \sum_{\kappa=1}^{\kappa_n} (p_{\kappa,tn} x_{\kappa,n}) - a_t \right)^2 \quad (\text{P3})$$

u. d. N. $\sum_{\kappa=1}^{\kappa_n} x_{\kappa,n} \leq 1, \quad n = 1, \dots, N$

$$x_{\kappa,n} \in \{0, 1\}, \quad \kappa = 1, \dots, \kappa_n, \quad n = 1, \dots, N.$$

Dabei stellt $c_{\kappa,n}$ die Kosten von Angebot κ der Entität n dar. Das zugehörige Verlagerungsangebot für Zeitpunkt t wird durch $p_{\kappa,tn}$ bezeichnet. Für jedes der κ_n Verlagerungsangebote wird eine binäre Entscheidungsvariable $x_{\kappa,n}$ eingeführt. Die als Ungleichungen formulierten Nebenbedingungen stellen sicher, dass von jeder Entität maximal ein Angebot angenommen wird.

Wie unmittelbar zu erkennen, ist Problem (P1) ein Spezialfall von (P3) mit $\kappa_n = 1$ für alle $n = 1, \dots, N$. Demzufolge ist auch Problem (P3) \mathcal{NP} -schwer.

Je nach Anwendungsfall ist es möglich, den beteiligten Entitäten Netzknoten zuzuordnen. Dann können Optimierungsprobleme derart formuliert werden, dass ausschließlich Lösungen zulässig sind, welche das Stromnetz nicht überlasten. Problem (P3) kann hierfür um Nebenbedingungen erwei-

tert werden, welche die physikalischen Netzrestriktionen für Spannungen und Ströme modellieren. Dies führt zum binären Programm

$$\min f(\underline{x}) = w_1 \sum_{n=1}^N \sum_{\kappa=1}^{\kappa_n} c_{\kappa,n} x_{\kappa,n} + w_2 \sum_{t=1}^T \left(\sum_{n=1}^N \sum_{\kappa=1}^{\kappa_n} (p_{\kappa,tn} x_{\kappa,n}) - a_t \right)^2$$

u. d. N.

$$\sum_{\kappa=1}^{\kappa_n} x_{\kappa,n} \leq 1, \quad n = 1, \dots, N \quad (\text{P4})$$

$$x_{\kappa,n} \in \{0, 1\}, \quad \kappa = 1, \dots, \kappa_n, \quad n = 1, \dots, N$$

$$u_k^{\min} \leq u_k \leq u_k^{\max}, \quad k = 1, \dots, K$$

$$i_l^{\min} \leq i_l \leq i_l^{\max}, \quad l = 1, \dots, L.$$

Hierbei bezeichnet u_k den Betrag der Spannung an Knoten k , während i_l den Betrag des Stromes auf Leitung l angibt. Diese Werte werden mittels Leistungsflussberechnungen wie in Abschnitt 3.3 beschrieben ermittelt. T entspricht der Anzahl an Zeiteinheiten, N der Anzahl an steuerbaren Entitäten, K der Anzahl an Netzknoten und L der Anzahl an Netzleitungen. An dieser Stelle ist anzumerken, dass nur hinsichtlich der Wirkleistung optimiert wird. Die Leistungsflussberechnungen berücksichtigen jedoch auch die Blindleistungen, welche somit in die Nebenbedingungen einfließen.

6.3 Skalares Optimierungsproblem für das Last- und Erzeugungsmanagement

Neben den Leistungsprofilen der Verbraucher werden nun auch die Leistungsprofile von Erzeugern in die Optimierung einbezogen. Verlagerungsangebote von Verbrauchern können weiterhin entweder vollständig angenommen oder abgelehnt werden. Erzeugung kann hingegen in jedem einzelnen Zeitschritt modifiziert werden. Dazu definieren die zugehörigen Verlagerungsangebote für jeden Zeitschritt ein Intervall, innerhalb dessen die Anpassung unter Berücksichtigung von Nebenbedingungen möglich ist.

Die Entitäten können reine Verbraucher, reine Erzeuger oder eine Kombination davon sein, beispielsweise Haushalte mit Photovoltaik-Anlagen. Daher können Entitäten Leistungsänderungsangebote unterbreiten, wel-

che sowohl den Verbrauch als auch die Erzeugung betreffen. Dies führt zu folgendem gemischt-ganzzahligen Optimierungsproblem:

$$\begin{aligned} \min f(\underline{x}, \underline{p}_\pi) = & w_1 \sum_{n=1}^N \left(\sum_{\kappa=1}^{\kappa_n} c_{\kappa,n} x_{\kappa,n} + \sum_{t=1}^T c_{\pi,tn}(p_{\pi,tn}) \right) \\ & + w_2 \sum_{t=1}^T \left(\sum_{n=1}^N \sum_{\kappa=1}^{\kappa_n} (p_{\kappa,tn} x_{\kappa,n}) + \sum_{n=1}^N p_{\pi,tn} - a_t \right)^2 \\ \text{u. d. N.} \quad & \sum_{\kappa=1}^{\kappa_n} x_{\kappa,n} \leq 1, \quad n = 1, \dots, N \\ & x_{\kappa,n} \in \{0, 1\}, \quad \kappa = 1, \dots, \kappa_n, \quad n = 1, \dots, N \\ & p_{\pi,tn}^{\min} \leq p_{\pi,tn} \leq p_{\pi,tn}^{\max}, \quad t = 1, \dots, T, \quad n = 1, \dots, N \\ & p_{\pi,tn}^{\min} \cdot p_{\pi,tn}^{\max} \leq 0, \quad t = 1, \dots, T, \quad n = 1, \dots, N \\ & d_{tn}^{\min} \leq p_{\pi,tn} - p_{\pi,(t-1)n} \leq d_{tn}^{\max}, \quad t = 2, \dots, T, \quad n = 1, \dots, N \\ & d_{tn}^{\min} \cdot d_{tn}^{\max} \leq 0, \quad t = 2, \dots, T, \quad n = 1, \dots, N \\ & u_k^{\min} \leq u_k \leq u_k^{\max}, \quad k = 1, \dots, K \\ & i_l^{\min} \leq i_l \leq i_l^{\max}, \quad l = 1, \dots, L. \end{aligned} \tag{P5}$$

Der in der Zielfunktion mit w_1 gewichtete Summand berechnet weiterhin die Kosten. Der Summand, welcher mit dem Gewicht w_2 eingeht, stellt die Zielabweichung dar. Dabei bezeichnet $c_{\kappa,n}$ die Kosten des Verlagerungsangebots κ von Konsument n und $p_{\kappa,tn}$ bezeichnet die verlagerbare Wirkleistung zum Zeitpunkt t . Die binären Variablen $x_{\kappa,n}$ kodieren die Entscheidung über die Annahme der festen Verlagerungsangebote. Die Kosten für eine Änderung der Erzeugungsleistung von Produzent n zur Zeit t um den Betrag $p_{\pi,tn}$ werden durch $c_{\pi,tn}(p_{\pi,tn})$ ausgedrückt. Hierbei ist $c_{\pi,tn}$ eine beliebige Kostenfunktion, die nichtlinear sein kann. Der Vektor \underline{p}_π umfasst reellwertige Entscheidungsvariablen $p_{\pi,tn}$ für $t = 1, \dots, T$ und $n = 1, \dots, N$. Diese sind durch $p_{\pi,tn}^{\min}$ und $p_{\pi,tn}^{\max}$ beschränkt, wobei die vierte Nebenbedingung sicherstellt, dass 0 in diesem Intervall liegt. Eine Ablehnung des Angebots für Zeitpunkt t wird durch $p_{\pi,tn} = 0$ ausgedrückt.

Somit wird insgesamt modelliert, dass Angebote von Verbrauchern als Ganzes zu einem festen Preis akzeptiert werden, während die Leistung der

Erzeuger von Zeitschritt zu Zeitschritt geändert und entsprechend bepreist werden kann. Werden die reellen Variablen auf die Darstellung in Abbildung 6.1b zurückgeführt, entsprechen die unteren Enden der grünen Säulen den $p_{\pi,t1}^{\min}$ und die oberen Enden den $p_{\pi,t1}^{\max}$. Die Werte $p_{\pi,t1}$ werden durch die gepunkteten Linien repräsentiert, welche die grünen Säulen schneiden.

Es sei angemerkt, dass der Index κ eine Variable ist, die ein konkretes Verlagerungsangebot eines Verbrauchers bestimmt. Demgegenüber repräsentiert der Index π keine Zahl, sondern kennzeichnet, dass die zugehörige Variable oder Funktion zu einem Erzeuger gehört. Folglich könnte π weggelassen werden; der Deutlichkeit halber wird dieser Index jedoch mitgeführt.

Die fünfte Nebenbedingung beschränkt die Änderungsgeschwindigkeit der Leistung, während die sechste Nebenbedingung garantiert, dass die Änderungsgeschwindigkeit 0 erlaubt ist, sodass Angebote abgelehnt werden können. Die weiteren Bezeichnungen in (P5) entsprechen denen in (P4).

Problem (P4) stellt einen Spezialfall von Problem (P5) dar. Hierfür wird die Flexibilität der Erzeugungseite außer Acht gelassen. Dies entspricht den Werten $c_{\pi,tn} = 0$ und $p_{\pi,tn} = 0$ für $n = 1, \dots, N$ und $t = 1, \dots, T$.

Ogleich in diesem Abschnitt Verbrauchsänderungen mit festen Angeboten in Verbindung gebracht wurden und Erzeugungsänderungen mit anpassbaren Angeboten, ist die vorgestellte Modellierung nicht darauf beschränkt. Sofern Entitäten in der Lage sind, ihre ausführbare Verbrauchsänderung in Form eines Intervalls auszudrücken, können diese flexiblen Angebote Eingang in die Optimierung finden. Ebenso kann Einspeiseänderung als festes Differenzprofil, das angenommen oder verworfen wird, angeboten werden. Dies kann ebenfalls durch Problem (P5) abgebildet werden. Die Modellierung wurde in den Abschnitten 2.2 und 2.3 diskutiert.

6.4 Multikriterielles Optimierungsproblem

Bisher wurden lediglich skalare Zielfunktionen formuliert. Diese fassten verschiedene zu optimierende Teilaspekte mittels Gewichtungsfaktoren zusammen. Wie in Abschnitt 6.5 beschrieben, weist das Vorgehen jedoch Nachteile auf. Daher wird eine weitere konzeptuelle Möglichkeit der Problemformulierung betrachtet, bei welcher die Teilziele durch verschiedene Zielfunktionen gleichzeitig Berücksichtigung finden. Werden Zielabweichung

und Kosten jeweils als Zielfunktion aufgefasst, lautet das multikriterielle Optimierungsproblem mit den Bezeichnungen aus (P5) wie folgt:

$$\begin{aligned}
 \min f_1(\underline{x}, \underline{p}_\pi) &= \sum_{n=1}^N \left(\sum_{\kappa=1}^{\kappa_n} c_{\kappa,n} x_{\kappa,n} + \sum_{t=1}^T c_{\pi,t,n}(p_{\pi,t,n}) \right) \\
 \min f_2(\underline{x}, \underline{p}_\pi) &= \sum_{t=1}^T \left(\sum_{n=1}^N \sum_{\kappa=1}^{\kappa_n} (p_{\kappa,t,n} x_{\kappa,n}) + \sum_{n=1}^N p_{\pi,t,n} - a_t \right)^2 \\
 \text{u. d. N.} \quad & \sum_{\kappa=1}^{\kappa_n} x_{\kappa,n} \leq 1, \quad n = 1, \dots, N \\
 & x_{\kappa,n} \in \{0, 1\}, \quad \kappa = 1, \dots, \kappa_n, \quad n = 1, \dots, N \quad (\text{P6}) \\
 & p_{\pi,t,n}^{\min} \leq p_{\pi,t,n} \leq p_{\pi,t,n}^{\max}, \quad t = 1, \dots, T, \quad n = 1, \dots, N \\
 & p_{\pi,t,n}^{\min} \cdot p_{\pi,t,n}^{\max} \leq 0, \quad t = 1, \dots, T, \quad n = 1, \dots, N \\
 & d_{t,n}^{\min} \leq p_{\pi,t,n} - p_{\pi,(t-1)n} \leq d_{t,n}^{\max}, \quad t = 2, \dots, T, \quad n = 1, \dots, N \\
 & d_{t,n}^{\min} \cdot d_{t,n}^{\max} \leq 0, \quad t = 2, \dots, T, \quad n = 1, \dots, N \\
 & u_k^{\min} \leq u_k \leq u_k^{\max}, \quad k = 1, \dots, K \\
 & i_l^{\min} \leq i_l \leq i_l^{\max}, \quad l = 1, \dots, L.
 \end{aligned}$$

Das Konzept der Optimalität, welches skalaren Problemen zugrunde liegt, kann im multikriteriellen Fall nicht angewandt werden. An die Stelle eines eindeutigen Optimums tritt bei mehreren unvereinbaren Zielfunktionen eine Menge von Kompromisslösungen. Für gewöhnlich wird dann ein Optimalitätskonzept genutzt, welches von Francis Ysidro Edgeworth [76] und Vilfredo Pareto [237, 238] entwickelt wurde. Dieses Konzept wird im nächsten Abschnitt zusammen mit den Optimierungsalgorithmen vorgestellt.

6.5 Überblick über Optimierungsalgorithmen

Die Optimierungsprobleme, welche für das hier betrachtete Energiemanagement zu lösen sind, gehören zu den ganzzahligen und gemischt-ganzzahligen Problemen. Es wurden sowohl skalare als auch multikriterielle Varianten formuliert. Für all diese Problemklassen existieren eine Reihe von Opti-

mierungsalgorithmen mit unterschiedlichen Eigenschaften. Diese werden im Folgenden diskutiert. Daraufhin werden genetische Algorithmen und einige Besonderheiten multikriterieller Optimierung beschrieben.

6.5.1 Klassifizierung

Bei der Klassifizierung der Algorithmen zur Lösung skalarer ganzzahliger und gemischt-ganzzahliger Optimierungsprobleme ist zu unterscheiden zwischen exakten und approximativen Verfahren. Exakte Verfahren finden stets die optimale Lösung, sofern diese existiert. Hierzu zählen beispielsweise Schnittebenenverfahren, Branch-and-Bound-Verfahren und Branch-and-Cut-Verfahren [61, 110]. Nachteil solcher Ansätze bei \mathcal{NP} -schweren Problemen ist die Rechenzeit, die im schlechtesten Fall exponentiell mit der Problemgröße ansteigt.

Im Unterschied zu exakten Verfahren liefern approximative Verfahren nicht zwangsläufig optimale Lösungen. Häufig werden jedoch optimale oder annähernd optimale Lösungen in polynomieller Zeit gefunden [225]. Zu den approximativen Verfahren zählen Heuristiken und Metaheuristiken. Heuristiken suchen gute Lösungen in angemessener Zeit, wobei im Allgemeinen keine Aussage darüber getroffen werden kann, ob die ermittelte Lösung optimal ist [79]. Insbesondere sind Heuristiken problemspezifisch, sodass diese nicht für verschiedene Problemklassen anwendbar sind. Im Gegensatz dazu sind Metaheuristiken nicht an spezielle Probleme gebunden. Dies sind iterative Verfahren, die mittels untergeordneter Heuristiken einen Suchraum erforschen [226, Kap. 1]. Die einzelnen Heuristiken müssen jedoch problemspezifisch implementiert werden. Zu den häufig genutzten Metaheuristiken zählen unter anderem Tabu-Suche, Partikelschwarm-Optimierung und evolutionäre Algorithmen [32, 33, 99]. Diese Verfahren bieten Lösungsmöglichkeiten für viele Optimierungsprobleme in Energiesystemen, wie Zustandsschätzung, Unit Commitment, Engpassmanagement und Netzausbauplanung [71, 288]. Ferner gibt es neben den Reinformen Ansätze zur Kombination exakter und approximativer Verfahren [31].

Bei den Algorithmen für multikriterielle Optimierungsprobleme werden ebenfalls exakte Verfahren sowie Heuristiken und Metaheuristiken unterschieden [78]. Aufgrund des andersartigen Optimalitätskonzepts können die Verfahren zur Lösung skalarer Optimierungsprobleme nicht ohne Wei-

teres angewandt werden. Exakte Verfahren nutzen oftmals Skalarisierungsansätze. Dabei wird ein multikriterielles Problem in ein skalares, parametrisiertes Problem umgewandelt, welches ein eindeutiges Optimum besitzt. Das skalare Problem wird dann unter verschiedenen Parameterbelegungen wiederholt gelöst, um mehrere Kompromisslösungen zu generieren [81]. Das Summieren und Gewichten der Zielfunktionen von Problem (P6) stellt beispielsweise eine Skalarisierung dar, die zu Optimierungsproblem (P5) führt. Für einen detaillierteren Überblick über exakte und heuristische Verfahren sei auf andere Arbeiten verwiesen [28, 77, 79, 279].

Metaheuristiken werden zur Lösung multikriterieller Optimierungsprobleme sehr häufig genutzt. Viele skalare Verfahren wurden für den multikriteriellen Fall adaptiert [14, 80, 104]. Eine Übersicht über Einsatzmöglichkeiten in Energiesystemen liefern Pindoriya *et al.* [244]. Unter den Metaheuristiken zeichnen sich die evolutionären Algorithmen durch sehr gute Ergebnisse aus und finden daher häufig Anwendung [299].

Zur Lösung der formulierten Optimierungsprobleme wurden genetische Algorithmen ausgewählt. Diese gehören zu den evolutionären Algorithmen und sind somit approximative Verfahren. Exakte Lösungen sind im vorgegebenen Szenario nicht gefordert, da Lastprognosen ohnehin mit Unsicherheiten behaftet sind. Vielmehr steht die Eigenschaft der Algorithmen im Vordergrund, für \mathcal{NP} -schwere Probleme in kurzer Zeit auch für größere Instanzen gute Lösungen zu finden. Ein weiteres Merkmal genetischer Algorithmen ist ebenfalls von Bedeutung. Diese arbeiten populationsbasiert, nutzen also eine Menge von Lösungen parallel. Wie in Abschnitt 6.5.4 beschrieben, erweist sich dies als hilfreich bei der Betrachtung von Kompromissen zwischen den Zielfunktionen.

6.5.2 Genetische Algorithmen

Genetische Algorithmen, die ein Teilgebiet der evolutionären Algorithmen darstellen, wurden von John Henry Holland entwickelt [132, 133]. Bis in die heutige Zeit wurden zahlreiche Varianten entworfen, sowohl für skalare als auch für multikriterielle Probleme. Der folgende Abschnitt beschreibt genetische Algorithmen und die zugrunde liegenden Prinzipien allgemein. Diese sind unabhängig von der Anzahl der Zielfunktionen. Besonderheiten multikriterieller Optimierungsprobleme präsentiert Abschnitt 6.5.3.

Genetische Algorithmen sind an den biologischen Evolutionsprozess angelehnt, was sich auch in der Terminologie zeigt. Bei der Nachbildung der Evolution mittels Algorithmen kommt es zwangsläufig zu Abstraktionen, da nicht alle Vorgänge detailliert modelliert werden können. Im Mittelpunkt steht eine Menge von Individuen, die als Population bezeichnet wird. Die Individuen werden einer simulierten Evolution unterzogen, wobei sie sich „fortpflanzen“ und einem Selektionsdruck unterliegen [321, Kap. 2.2].

Jedes Individuum stellt eine Lösung des Optimierungsproblems dar und wird durch eine Zeichenkette repräsentiert, die in Analogie zur biologischen Evolution „Chromosom“ genannt wird. Häufig werden zur Repräsentation Zeichenketten aus binären oder reellen Variablen gewählt, welche die Entscheidungsvariablen kodieren. Die einzelnen Abschnitte des Chromosoms stellen die „Gene“ dar. Deren Ausprägungen bestimmen die Werte der Variablen. In diesem Zusammenhang werden, analog zur Biologie, die Chromosomen als Genotypen und die Lösungen als Phänotypen bezeichnet, um Lösungen und deren Repräsentationen zu unterscheiden.

Die Individuen werden wie Organismen behandelt, die als Population evolutionäre Zyklen durchlaufen. Ein Zyklus – auch als eine „Generation“ bezeichnet – besteht aus der Anwendung von Operatoren für Selektion, Rekombination und Mutation. Werden Start- und Endpunkte hinzugefügt, so ergibt sich der in Abbildung 6.2 dargestellte Ablauf [321, Kap. 2.2]:

- (1) Zunächst wird eine initiale Population bestehend aus μ Individuen erzeugt. Oft werden die Individuen zufällig generiert. Diese können auch das Ergebnis einer Heuristik oder einer anderen Optimierung sein, sodass die Suche bereits in aussichtsreichen Gebieten beginnt.
- (2) Die Anfangskandidaten werden anhand der Zielfunktionen und der Verletzung von Nebenbedingungen bewertet. Diese Bewertung dient zum einen als Grundlage für die spätere Fortpflanzungsselektion und beeinflusst zum anderen das Überleben des Individuums, d. h. den Übergang in die nächste Generation. Das Ergebnis der Bewertung kann als eine Art Fitness, oder relative Eignung, des Individuums angesehen werden. Daher wird die Bewertungsfunktion auch als Fitnessfunktion bezeichnet. Bei Minimierungsproblemen ist die Fitness eines Individuums umso höher, je niedriger der Zielfunktionswert der Lösung ist und je weniger die Nebenbedingungen verletzt werden.

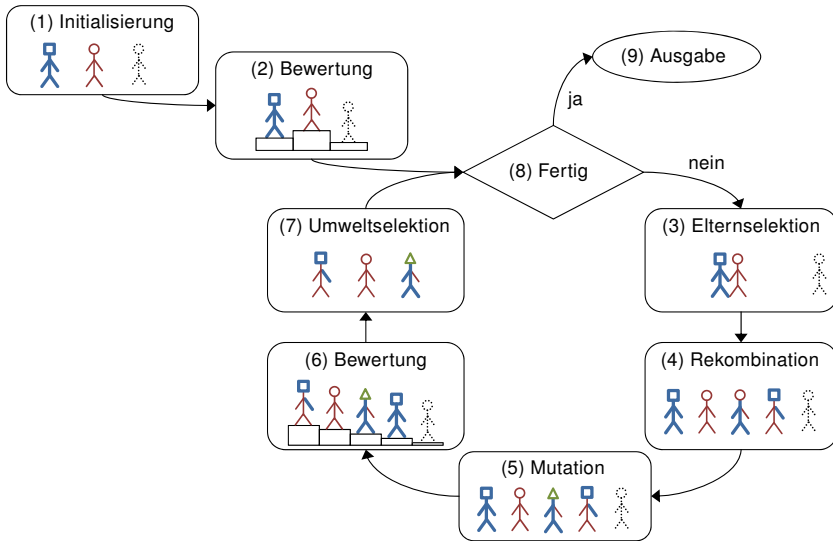


Abbildung 6.2 – Evolutionärer Zyklus, angelehnt an [321, Kap. 2.2]. Die abgebildeten Individuen durchlaufen nach der Initialisierung einen Zyklus.

- (3) Der Generationszyklus beginnt mit der Elternselektion. Die Bewertung jedes Individuums wird dabei herangezogen, um die Zahl dessen Nachkommen festzulegen. Zu den bekannten Selektionsschemata gehören unter anderem fitnessproportionale Selektion, Turniererlektion und stochastisches universelles Sampling [65, Kap. 4.2].
- (4) Mit einer gewissen Wahrscheinlichkeit werden die ausgewählten Elternindividuen in dem nächsten Schritt kombiniert, um λ neue Lösungen – die Kindindividuen – zu erzeugen. Rekombinationsoperatoren generieren aus zwei oder mehr Eltern mindestens ein Kindindividuum. Ein solcher Operator ist der in Abbildung 6.3 veranschaulichte 2-Punkt-Crossover. Im Beispiel werden binäre Zeichenketten als Genotypen genutzt. Zur Durchführung der Rekombination werden zunächst zufällig zwei Punkte innerhalb des Chromosoms gewählt. Zwischen diesen Punkten werden dann die Gensequenzen der beiden Elternindividuen ausgetauscht. Der Operator generiert somit zwei

Nachkommen. Der 2-Punkt-Crossover kann auch bei Genotypen angewandt werden, die aus reellen Variablen bestehen. Häufig wird in diesem Fall allerdings der SBX-Operator eingesetzt [66, 69].

- (5) Nach der Rekombination werden zufällige Änderungen an Chromosomen der Kindindividuen vorgenommen. Diese Mutationen sind in der Regel klein und werden selten durchgeführt. Bei binären Genotypen ist die Bit-Flip-Mutation weit verbreitet. Hierbei werden an zufälligen Stellen der Chromosomen Bits invertiert. Im Falle von reellen Genotypen können zu reellen Werten Zufallszahlen addiert werden, welche einer vorgegebenen Verteilung folgen. Wie die Rekombination dient auch die Mutation der Erzeugung neuer Individuen. Hierfür wird bei der Mutation jedoch lediglich *ein* Individuum benötigt. In genetischen Algorithmen ist die Rekombination der primäre Suchoperator, während der Mutation eine geringere Bedeutung zukommt [65, Kap. 4.2]. Daher ist die Rekombinationswahrscheinlichkeit meist wesentlich höher als die Mutationswahrscheinlichkeit.
- (6) Nach Anwendung der Rekombinations- und Mutationsoperatoren werden die Kind- oder auch die Elternindividuen bewertet.
- (7) Diese Bewertung wird für eine Umweltselektion herangezogen, bei der diejenigen Individuen ausgewählt werden, welche die nächste Generation bilden. Hierbei sollten die besseren Individuen aufgenommen werden; gleichzeitig sollte auch Diversität gewährleistet werden, um eine vorzeitige Konvergenz zu vermeiden. Für die Auswahl der nächsten Generation können verschiedene Individuenmengen herangezogen werden. Es können entweder nur die Kindindividuen Berücksichtigung finden oder eine Menge bestehend aus Kind- und Elternindividuen. Im ersten Falle können die besten Lösungen aus der Population verschwinden, sodass es zu Rückschritten in der Entwicklung kommt. In der Regel werden Populationen konstanter Größe verwendet, sodass die Umweltselektion μ Individuen liefert.
- (8) Der evolutionäre Zyklus wird so lange durchlaufen, bis eine Terminierungsbedingung erfüllt ist. Dies könnte beispielsweise der Fall sein, wenn eine zufriedenstellende Lösung gefunden oder wenn eine vorgegebene Zahl von Funktionsauswertungen vorgenommen wurde.




Abbildung 6.3 – Rekombination durch 2-Punkt-Crossover für binäre Genotypen. Es werden zufällig zwei Punkte gewählt, zwischen denen die Gensequenzen der Eltern getauscht werden.

- (9) Die ermittelten Lösungen, oder eine Teilmenge davon, werden als Ergebnis ausgegeben.

6.5.3 Multikriterielle Optimierung

Die Optimierung multikriterieller Probleme durch genetische Algorithmen weist im Vergleich zur Optimierung skalarer Probleme grundlegende Unterschiede bei der Bewertung, also in den Schritten (2) und (6), auf. Diese sind darauf zurückzuführen, dass nicht mehr alle Lösungen miteinander vergleichbar sind. Die Konsequenzen werden im Folgenden diskutiert.

Ein multikriterielles Optimierungsproblem kann ohne Beschränkung der Allgemeinheit dargestellt werden als ein Minimierungsproblem

$$\min \underline{f}(\underline{x}) = (f_1(\underline{x}), f_2(\underline{x}), \dots, f_R(\underline{x}))' \quad (\text{P7})$$

$$\text{u. d. N.} \quad \underline{x} \in \mathcal{X}$$

mit den Zielfunktionen $f_r: \mathbb{R}^N \rightarrow \mathbb{R}$ für $r = 1, \dots, R$ und einer Menge $\mathcal{X} \subseteq \mathbb{R}^N$ von zulässigen Lösungen. Ein solches Problem ist für $N = 3$ und $R = 2$ in Abbildung 6.4 skizziert. Die linke Seite zeigt den Suchraum, d. h. den Raum, in dem die Optimierungsvariablen angegeben werden. Die zulässigen Lösungen \mathcal{X} sind durch den grauen Körper dargestellt. Auf der rechten Seite ist der Zielraum veranschaulicht. In diesem Raum werden die Lösungen miteinander verglichen. Der Suchraum wird durch f auf den Zielraum abgebildet. Insbesondere wird \mathcal{X} abgebildet auf $\underline{\mathcal{Z}} = f(\overline{\mathcal{X}}) = \{\underline{z} = f(\underline{x}) \mid \underline{x} \in \mathcal{X}\}$.

Skalare Probleme stellen Spezialfälle des Problems (P7) für $R = 1$ dar. Deren Zielraum ist eindimensional und weist eine Totalordnung auf. Hingegen ist der Zielraum bei multikriteriellen Problemen R -dimensional. Für $R > 1$ kann dieser nicht total geordnet werden [91]. Folglich gibt es Lösungen,




Abbildung 6.4 – Suchraum (links) und Zielraum (rechts, nach [65, Kap. 3.1.4]) bei multikriterieller Optimierung. Der graue Körper im Suchraum kennzeichnet die Menge \mathcal{X} der zulässigen Lösungen und wird durch f auf \mathcal{Z} im Zielraum abgebildet. Die Pareto-optimale Menge \mathcal{X}^* im Suchraum ist das Urbild der Pareto-Front \mathcal{Z}^* .

die nicht miteinander vergleichbar sind. Daher muss das Optimalitätskonzept der skalaren Optimierung ersetzt werden. Oftmals wird dabei die Pareto-Optimalität verwendet, die eine Halbordnung im Zielraum induziert. Grundlegend hierfür ist der Begriff der Pareto-Dominanz.

Definition (Pareto-Dominanz). *Eine Lösung $\underline{x}^* \in \mathcal{X}$ dominiert eine Lösung $\underline{x} \in \mathcal{X}$ im Sinne von Pareto genau dann, wenn $f_r(\underline{x}^*) \leq f_r(\underline{x})$ für $r = 1, \dots, R$ gilt und $f_{r^*}(\underline{x}^*) < f_{r^*}(\underline{x})$ für mindestens ein $r^* \in \{1, \dots, R\}$.*

Werden zwei Lösungen $\underline{x}^{(1)}$ und $\underline{x}^{(2)}$ auf Pareto-Dominanz geprüft, können drei Fälle auftreten: $\underline{x}^{(1)}$ dominiert $\underline{x}^{(2)}$, $\underline{x}^{(2)}$ dominiert $\underline{x}^{(1)}$ oder $\underline{x}^{(1)}$ und $\underline{x}^{(2)}$ befinden sich in keinem Dominanzverhältnis zueinander. Stehen zwei Lösungen zur Auswahl, ist die dominierende Lösung zu bevorzugen, da diese in allen Zielfunktionen mindestens so gut abschneidet wie die dominierte Lösung. Sofern keine der beiden Lösungen die andere dominiert, ist die Wahl nicht mehr offensichtlich. In diesem Fall muss der Anwender die Lösung bestimmen, welche für ihn den besseren Kompromiss darstellt.

Mit dem Konzept der Pareto-Dominanz können nun die Begriffe der Pareto-Optimalität und der Pareto-optimalen Menge definiert werden.

Definition (Pareto-Optimalität, Pareto-optimale Menge). *Lösung $\underline{x}^* \in \mathcal{X}$ ist Pareto-optimal genau dann, wenn keine Lösung $\underline{x} \in \mathcal{X}$ existiert, die \underline{x}^* dominiert. Die Pareto-optimale Menge \mathcal{X}^* eines multikriteriellen Optimierungsproblems ist die Menge aller Pareto-optimalen Lösungen $\underline{x}^* \in \mathcal{X}$.*

In genetischen Algorithmen werden Populationen betrachtet, die eine Menge von Lösungen darstellen. Da Suchräume normalerweise sehr groß sind, umfassen die Populationen nur eine Teilmenge der möglichen Lösungen. In diesem Zusammenhang ist der Begriff der nicht-dominierten Menge von Bedeutung.

Definition (Nicht-dominierte Menge). Sei $\widetilde{\mathcal{X}} \subseteq \mathcal{X}$ eine Menge von Lösungen. Die zugehörige nicht-dominierte Menge umfasst alle Lösungen $\underline{x}^* \in \widetilde{\mathcal{X}}$, die von keiner Lösung $\underline{x} \in \widetilde{\mathcal{X}}$ dominiert werden.

Die bisherigen Definitionen bezogen sich auf die Lösungen im Suchraum von Optimierungsproblemen. Folgende Definition kennzeichnet das Bild der Pareto-optimalen Menge unter f .

Definition (Pareto-Front). Das Bild der Pareto-optimalen Menge \mathcal{X}^* im Zielraum, d. h. die Menge $\underline{\mathcal{Z}}^* = \underline{f}(\mathcal{X}^*) = \{\underline{z} = \underline{f}(\underline{x}) \mid \underline{x} \in \mathcal{X}^*\}$, heißt Pareto-Front.

Sowohl die Pareto-optimale Menge als auch die Pareto-Front sind in Abbildung 6.4 in Rot dargestellt. Ein multikriterielles Problem zu lösen, bedeutet die Pareto-optimale Menge zu finden. Da oftmals keine analytische Beschreibung der Pareto-optimalen Menge bekannt ist und diese unendlich viele Elemente enthalten kann, beschränkt sich die Suche in der Regel darauf, einige Elemente dieser Menge zu ermitteln. Im Falle von genetischen Algorithmen sollte idealerweise die nicht-dominierte Menge der finalen Population Pareto-optimale Elemente enthalten. Da diese Algorithmen jedoch keine Garantie dafür liefern, optimale Lösungen zu finden, sollte das Bild der finalen Population unter f zumindest in der Nähe der Pareto-Front liegen. Darüber hinaus ist es wünschenswert, dass diese Lösungen gleichmäßig über die gesamte Pareto-Front verteilt sind, um eine breites Spektrum an Kompromisslösungen abzudecken.

6.5.4 Präferenzen

Im Rahmen der multikriteriellen Optimierung können Anwender Präferenzen bezüglich der Kompromisslösungen ausdrücken. Diese Präferenzen können vor der Optimierung (a priori), währenddessen (progressiv) oder danach (a posteriori) eingebracht werden [308, Kap. 2.6.1].

Zu den Ansätzen, die Präferenzen a priori einbeziehen, gehört beispielsweise die Skalarisierung des multikriteriellen Problems durch Bildung einer gewichteten Summe der Zielfunktionen. Bereits vor der Optimierung muss demnach eine Entscheidung bezüglich der Wichtigkeit der Optimierungskriterien getroffen werden. Die Gewichte exakt festzulegen bevor alternative Lösungen bekannt sind, ist bei Fehlen genauer Zielvorstellungen jedoch normalerweise nicht praktikabel [35]. Durch dieses Vorgehen entfällt darüber hinaus die Möglichkeit, verschiedene Kompromisse abzuwägen. Um dennoch eine Menge von Kompromisslösungen zu finden, muss die Optimierung mit verschiedenen Gewichtsvektoren wiederholt werden. Dieses Vorgehen kann jedoch Nachteile bergen [65, Kap. 3.1]. Zum einen resultiert eine gleichmäßig verteilte Menge von Gewichtsvektoren nicht notwendigerweise in einer gleichmäßigen Approximation der Pareto-Front. Zum anderen können bestimmte Pareto-optimale Lösungen nicht gefunden werden, sofern \mathcal{Z} nicht konvex ist. Dies ist auf der rechten Seite von Abbildung 6.4 veranschaulicht. Im zweidimensionalen Zielraum führt eine Gewichtung der Zielfunktionen mit w_1 und w_2 , also das Minimieren von $f(x) = w_1 f_1(x) + w_2 f_2(x)$, zu Konturgeraden mit der Steigung $-w_1/w_2$. Entlang einer Konturgerade nimmt die aggregierte Zielfunktion denselben Wert an. Da es sich um ein Minimierungsproblem handelt, ist die Tangente an \mathcal{Z} gesucht, welche den niedrigsten Funktionswert aufweist, also möglichst weit links unten liegt. Die blaue Gerade in Abbildung 6.4 ist eine solche Tangente durch die Punkte A und B . Es gibt jedoch keine Kombination der Gewichte w_1 und w_2 , die zu einer „minimalen“ Tangente im Abschnitt zwischen A und B führt [65, Kap. 3.1.4]. Dies liegt daran, dass immer eine Tangente an \mathcal{Z} mit der gleichen Steigung existiert, die zu einem niedrigeren Funktionswert gehört und außerhalb des Abschnitts zwischen A und B liegt. Eine Minimierung der gewichteten Summe der Zielfunktionen schließt daher Teile der Pareto-optimalen Menge aus der Lösungsmenge aus.

Progressive Verfahren bringen Präferenzen während des Optimierungsprozesses ein. Dabei wechseln sich Berechnungsschritte und Dialoge mit dem Anwender ab. Da während eines Optimierungslaufs im Rahmen des Energiemanagements keine Interaktionen mit Anwendern geplant sind, wird diese Kategorie von Verfahren nicht weiter betrachtet.

Verfahren, die Präferenzen a posteriori berücksichtigen, betrachten die Zielfunktionen zunächst als gleichwertig. Die Optimierung liefert ein mög-

lichst breites Spektrum an Pareto-optimalen Lösungen. Nach dem Optimierungsprozess muss eine zu realisierende Lösung gewählt werden. Zu diesem Zeitpunkt ist bereits bekannt, welche Kompromisse möglich sind.

Im Folgenden werden Präferenzen betrachtet, die zwar a priori in die Optimierung eingebracht werden, jedoch keine Skalarisierung bewirken. Daher muss a posteriori eine Lösung ausgewählt werden. Zunächst wird ein von Arthur Geoffrion formuliertes Optimalitätskonzept betrachtet.

Definition (Geoffrion-eigentliche Pareto-Optimalität [100]). *Eine Lösung $\underline{x}^+ \in \mathcal{X}$ ist Geoffrion-eigentlich Pareto-optimal, wenn \underline{x}^+ Pareto-optimal ist und wenn eine Zahl $M > 0$ existiert, sodass für alle $i \in \{1, \dots, R\}$ und $\underline{x} \in \mathcal{X}$ mit $f_i(\underline{x}) < f_i(\underline{x}^+)$ ein $j \in \{1, \dots, R\}$ existiert, für das $f_j(\underline{x}^+) < f_j(\underline{x})$ gilt sowie*

$$\frac{f_i(\underline{x}^+) - f_i(\underline{x})}{f_j(\underline{x}) - f_j(\underline{x}^+)} \leq M. \quad (6.1)$$

Die Geoffrion-eigentliche Pareto-Optimalität ist eine strengere Form der Pareto-Optimalität, bei der der Quotient (*Trade-off*) in Ungleichung (6.1) beschränkt ist durch eine endliche Zahl M . Geht man einen Schritt weiter und gibt ein M vor, gelangt man zu folgender Definition.

Definition (Geoffrion- M -eigentliche Pareto-Optimalität [278]). *Sei $M > 0$ gegeben. Lösung $\underline{x}^+ \in \mathcal{X}$ ist Geoffrion- M -eigentlich Pareto-optimal, wenn \underline{x}^+ Pareto-optimal ist und für alle $i \in \{1, \dots, R\}$ und $\underline{x} \in \mathcal{X}$ mit $f_i(\underline{x}) < f_i(\underline{x}^+)$ ein $j \in \{1, \dots, R\}$ existiert, für das $f_j(\underline{x}^+) < f_j(\underline{x})$ gilt sowie*

$$\frac{f_i(\underline{x}^+) - f_i(\underline{x})}{f_j(\underline{x}) - f_j(\underline{x}^+)} \leq M. \quad (6.2)$$

Wird anstatt der Pareto-Optimalität das Konzept der Geoffrion- M -eigentlichen Pareto-Optimalität genutzt, kann a priori ein M vorgegeben werden. Dieser Parameter beschränkt die Verschlechterung in einer Zielfunktion, die in Kauf genommen wird für eine Verbesserung in einer anderen Zielfunktion. Eine solche Beschränkung erscheint im hier betrachteten Energiemanagement sinnvoll, sofern für eine kleine Annäherung an das Zielprofil kein beliebig hoher Preis gezahlt werden soll. Umgekehrt sollte für eine geringfügig günstigere Lösung keine starke Abweichung vom Zielprofil akzeptiert werden. Aus dieser Betrachtungsweise heraus kann der Begriff der

„eigentlichen Pareto-Optimalität“ erklärt werden, da in der Praxis eigentlich nur ein Teil der Pareto-optimalen Lösungen von Bedeutung ist. Diese Information kann im Rahmen der multikriteriellen Optimierung genutzt werden, um die Suche auf die präferierten Bereiche zu konzentrieren und die verfügbare Rechenzeit sinnvoll zu investieren. Die endliche Population in genetischen Algorithmen muss dann nicht mehr die gesamte Pareto-Front approximieren, sondern nur noch eine interessante Teilmenge.

Zum Finden Geoffrion-*M*-eigentlich Pareto-optimaler Lösungen werden paarweise Vergleiche zwischen Lösungen durchgeführt. Da genetische Algorithmen auf einer Lösungsmenge operieren, sind solche Vergleiche innerhalb einer Population problemlos möglich. Damit wird einer der Vorteile populationsbasierter Algorithmen deutlich. Weitere Gründe für den Einsatz populationsbasierter Verfahren werden von Prügel-Bennett diskutiert [250].

In Kapitel 7 werden verschiedene Arten von Präferenzen beim Energiemanagement gegenübergestellt. Es werden sowohl mit verschiedenen Gewichten skalarisierte Optimierungsprobleme gelöst als auch multikriterielle Probleme, bei denen a posteriori eine Lösung ausgewählt wird. Ferner wird das Konzept der Geoffrion-*M*-eigentlichen Pareto-Optimalität zur Fokussierung der Suche genutzt. Die implementierten genetischen Algorithmen werden im folgenden Abschnitt vorgestellt. Eine weitergehende Analyse von Präferenzen im Rahmen der Optimierung liefern Shukla *et al.* [280].

6.6 Implementierte genetische Algorithmen

Zur Implementierung der genetischen Algorithmen wurde das Java-basierte Framework *jMetal* [75] verwendet und erweitert. Darin wurden drei generationsbasierte Algorithmen implementiert, die in Abhängigkeit der Anzahl von Zielfunktionen sowie der berücksichtigten Präferenzen eingesetzt wurden. Die allgemeine Schrittfolge zur Durchführung genetischer Algorithmen wurde bereits in Abschnitt 6.5.2 erläutert. An dieser Stelle werden die konkreten Genotypen sowie die genutzten Operatoren eingeführt.

Alle implementierten Algorithmen verwenden dieselbe genotypische Kodierung. Die Lastmanagement-Probleme umfassen ausschließlich binäre Entscheidungsvariablen. Aus diesem Grund werden die Chromosomen für diese Probleme durch binäre Zeichenketten repräsentiert, deren Länge der

Anzahl der Entscheidungsvariablen entspricht. Beim Erzeugungsmanagement sind kontinuierliche Variablen nötig. Diese werden in den Chromosomen durch reelle Variablen abgebildet. Lösungen der Probleme für kombiniertes Last- und Erzeugungsmanagement werden durch zwei Zeichenketten dargestellt, welche jeweils die binären und reellen Variablen umfassen.

Für kontinuierliche Variablen wurde eine reelle Kodierung gewählt, da sich diese für viele Optimierungsprobleme als vorteilhaft erwiesen hat [64]. Bei der Lösung der Energiemanagement-Probleme wurde diese Vermutung bestätigt. Die implementierten Algorithmen lieferten mit der gemischten Kodierung bessere Ergebnisse als mit einer reinen Binärkodierung.

Variablenbelegungen der initialen Individuen in Schritt (1) erfolgen für alle Algorithmen zufällig. Die Werte werden einer Gleichverteilung folgend so gewählt, dass diese für die kontinuierlichen Variablen jeweils zwischen den minimalen und maximalen zulässigen Werten liegen. Binäre Variablen werden zufällig mit 0 oder 1 belegt. Die genetischen Operatoren wurden so implementiert, dass die Zulässigkeit bezüglich der Wertebereiche erhalten bleibt. Physikalische Nebenbedingungen müssen dabei nicht erfüllt sein.

Da Rekombination (4) und Mutation (5) direkt auf dem Genotyp operieren, können für die drei Algorithmen dieselben Operatoren genutzt werden. Hierbei werden die gleichen Parameterwerte und Wahrscheinlichkeiten nach gängigen Richtlinien festgelegt, um eine Vergleichbarkeit der Ergebnisse über mehrere Szenarien hinweg zu ermöglichen. Die binären Chromosomen bzw. die binären Abschnitte gemischter Chromosomen werden durch einen 2-Punkt-Crossover rekombiniert, während bei den reellen Abschnitten der SBX-Operator zum Einsatz kommt. Für letzteren wurde der Verteilungsindex $\eta_c = 20$ festgelegt [70]. Die Rekombinationswahrscheinlichkeit betrug in allen Fällen 90 %.

Bei der Mutation wird wiederum zwischen binären und reellen Genen unterschieden. Die Mutation der binären Gene erfolgt durch den Bit-Flip-Operator. Bei reellen Genen wird eine polynomiale Mutation [68] durchgeführt mit dem Verteilungsindex $\eta_m = 20$ [70]. Nach einer weit verbreiteten Empfehlung wurden Mutationswahrscheinlichkeiten von $1/n$ gewählt [222], wobei n der Länge der jeweiligen Zeichenkette entspricht.

Als Abbruchkriterium für die genetischen Algorithmen in Schritt (8) dient jeweils eine maximale Zahl von Funktionsauswertungen. Dieses Kriterium kann auch dann genutzt werden, wenn die Laufzeit der Algorithmen auf-

grund von festgelegten Reaktionszeiten beschränkt werden muss. Die genaue Zahl von Funktionsauswertungen sowie die damit zusammenhängende Populationsgröße wurden für die Szenarien des Lastmanagements sowie des Last- und Erzeugungsmanagements verschieden festgelegt. Die Werte sind in den entsprechenden Abschnitten in Kapitel 7 aufgeführt.

Unterschiede zwischen den drei implementierten Algorithmen treten bei der Bewertung der Individuen (Schritte (2) und (6)) und bei der Selektion (Schritte (3) und (7)) auf. Hierbei spielen die Dimension des Zielraums und die Präferenzen eine Rolle. Diese Faktoren sind auch für die Ausgabe in Schritt (9) von Bedeutung. Für skalare Probleme kann die beste Lösung einer Population bestimmt werden. Bei multikriteriellen Problem existiert in der Regel eine Menge von Pareto-optimalen Lösungen bzw. von Geoffrion- M -eigentlich Pareto-optimalen Lösungen. Nachfolgend werden zunächst die verschiedenen Selektions- und Bewertungsmechanismen der Algorithmen erläutert. Diese vervollständigen die Beschreibung der Algorithmen. Daraufhin wird für den multikriteriellen Fall die Wahl einer umzusetzenden Lösung aus einer Menge von gleichwertigen Lösungen dargestellt.

6.6.1 Algorithmus \mathcal{A}_{SO} : Skalare Optimierung

Der Algorithmus \mathcal{A}_{SO} wurde für die Optimierung skalarer Probleme implementiert. Zur Bewertung von Individuen werden sowohl deren Zielfunktionswert als auch die Summe der Restriktionsverletzungen herangezogen. Mittels dieser beiden Werte ist es möglich, Individuen zu vergleichen. Dabei können drei Fälle auftreten [65, Kap. 7.5]: beide Lösungen sind zulässig, genau eine Lösung ist zulässig, beide Lösungen sind unzulässig. Im ersten Fall ist die Lösung mit dem niedrigeren Zielfunktionswert zu bevorzugen und im zweiten Fall die zulässige Lösung. Um die Suche in Richtung des zulässigen Bereichs zu lenken, wird im dritten Fall die Lösung mit der niedrigeren Restriktionsverletzung bevorzugt.

Dieses Vergleichsschema wird genutzt, um die Individuen einer Population zu sortieren. Danach stehen die zulässigen Lösungen, sofern vorhanden, nach Zielfunktionswert aufsteigend sortiert vor den unzulässigen Lösungen. Letztere sind nach Restriktionsverletzung aufsteigend sortiert. Jedem Individuum wird daraufhin ein Rang zugewiesen, welcher der Position des Individuums in der sortierten Liste entspricht. Das beste Individuum

erhält somit den Rang 1, da eine Minimierung der Zielfunktion angestrebt wird.

Die Rangzuordnung wird bei der Elternselektion und bei der Umweltselektion genutzt. Die Umweltselektion beschränkt sich auf die Elterngeneration, d. h. die μ Individuen umfassende Population zu Beginn eines evolutionären Zyklus in Schritt (3). Daraus werden die beiden besten Individuen – die sogenannte „Elite“ – in die nächste Generation übernommen. Bei gleichbleibender Populationsgröße werden die restlichen $\lambda = \mu - 2$ Individuen für die nächste Generation durch Reproduktion und Mutation generiert. Im Rahmen der Umweltselektion überleben demzufolge alle λ Kindindividuen. Die Auswahl der Eltern für die Reproduktion erfolgt mittels einer Turnirselektion, bei der jeweils zwei zufällig gewählte Individuen gegeneinander antreten. Dabei gewinnt das Individuum mit dem kleineren Rang.

Die Auswahl einer Lösung nach Inkrafttreten der Abbruchbedingung gestaltet sich bei der skalaren Optimierung einfach. Auf Grundlage der Bewertung kann die Lösung mit Rang 1 als beste Lösung ausgegeben werden.

6.6.2 Algorithmus \mathcal{A}_{MO} : Multikriterielle Optimierung

Algorithmus \mathcal{A}_{MO} basiert auf dem von Deb *et al.* [67, 70] entwickelten multikriteriellen Optimierungsalgorithmus NSGA-II (*Non-dominated Sorting Genetic Algorithm II*). Im Unterschied zu NSGA-II umfassen die Chromosomen gleichzeitig sowohl binäre als auch reelle Gene. Daher müssen für jedes Individuum, wie oben beschrieben, binäre und reelle Rekombinations- und Mutationsoperatoren angewendet werden. Die weiteren Schritte wurden von NSGA-II übernommen.

In die Bewertung von Individuen werden erneut Zielfunktionswerte und Restriktionsverletzungen einbezogen. Da der Zielraum mehrdimensional ist, kann jedoch nicht wie bei Algorithmus \mathcal{A}_{SO} eine eindeutige Reihenfolge aller Individuen bestimmt werden. Beim Vergleichen zweier Lösungen können weiterhin die im letzten Abschnitt genannten drei Fälle eintreten. Ist eine der Lösungen unzulässig, wird die zulässige Lösung favorisiert. Sind beide Lösungen unzulässig, so entscheidet wiederum die Restriktionsverletzung. Falls beide Lösungen zulässig sind, wird das Prinzip der Pareto-Dominanz genutzt. Dieses erlaubt eine Partitionierung der Lösungsmenge in Teilmengen nicht-dominierter Lösungen.

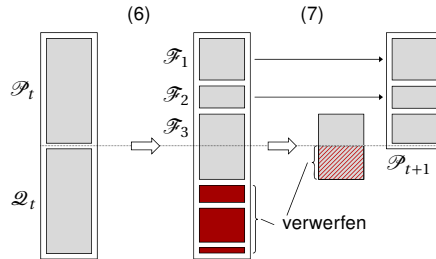


Abbildung 6.5 – Bewertung und Umweltselktion in NSGA-II, nach [70]. In Schritt (6) findet eine nicht-dominierte Sortierung aller Individuen unter Berücksichtigung der Restriktionsverletzungen statt. Innerhalb jeder Front werden Crowding-Distanzen berechnet. Schritt (7) umfasst die Umweltselktion auf Basis der Fronten und der Crowding-Distanz. Falls eine Front nur teilweise in die nächste Generation übernommen werden kann, werden deren Individuen anhand der Crowding-Distanz sortiert und ausgewählt.

Dieses Schema der nicht-dominierten Sortierung unter Berücksichtigung der Restriktionsverletzungen ist in Abbildung 6.5 links skizziert. Resultat ist eine Menge von Teilpopulationen, welche in NSGA-II „Fronten“ genannt werden. Hierbei dominiert keines der Elemente einer Front ein anderes Element derselben Front. Untereinander können die Fronten allerdings sortiert werden. Sofern eine Population zulässige Lösungen enthält, umfasst die erste Front \mathcal{F}_1 die nicht-dominierte Menge. Jedes Element einer Front \mathcal{F}_i mit $i > 1$ wird von mindestens einem Element der Front \mathcal{F}_{i-1} dominiert, falls \mathcal{F}_i zulässige Lösungen enthält. Andernfalls weisen die Elemente aus \mathcal{F}_i höhere Restriktionsverletzungen als die Elemente aus \mathcal{F}_{i-1} auf. Ein Algorithmus für diese Sortierung wird von Deb *et al.* vorgeschlagen [67]. Dabei wird zunächst die nicht-dominierte Menge bestimmt, welche die Front \mathcal{F}_1 bildet, und vorläufig aus der Population entfernt. Daraufhin wird die nicht-dominierte Menge der verbleibenden Lösungen bestimmt. Diese bildet \mathcal{F}_2 und wird ebenfalls temporär entfernt. Das Vorgehen wird iterativ fortgeführt, bis alle Lösungen erfasst sind.

Nach der Sortierung kann jedem Individuum ein Rang zugewiesen werden, welcher der Nummer der Front entspricht, der das Individuum angehört. Darüber hinaus wird den Individuen mit der Crowding-Distanz ein weiteres Attribut zugewiesen. Dieses berücksichtigt die Nachbarschaft von Individuen innerhalb einer Front und ist eine Maßzahl für die Dichte wei-

terer Lösungen um eine bestimmte Lösung herum. Je höher die Crowding-Distanz eines Individuums ist, desto größer ist der Abstand zu den umliegenden Individuen derselben Front.

Die Bewertung in Abbildung 6.5 bezieht sich auf Schritt (6) des genetischen Algorithmus. Es nehmen alle Individuen der Menge $\mathcal{P}_t \cup \mathcal{Q}_t$ teil, welche sich aus der Elterngeneration \mathcal{P}_t und der Menge \mathcal{Q}_t der Kindindividuen zusammensetzt. In Schritt (2) wird entsprechend eine Bewertung der initialen Population \mathcal{P}_1 vorgenommen.

Abbildung 6.5 veranschaulicht auf der rechten Seite die Umweltselektion für die Menge $\mathcal{P}_t \cup \mathcal{Q}_t$, welche 2μ Individuen umfasst. Die Anzahl λ der generierten Kindindividuen entspricht demzufolge der Populationsgröße μ . Beginnend bei \mathcal{F}_1 werden die Fronten $\mathcal{F}_1, \dots, \mathcal{F}_i$ komplett in die nächste Population \mathcal{P}_{t+1} übernommen, solange die Zahl der Individuen in $\cup_{f=1}^i \mathcal{F}_f$ nicht μ übersteigt. Falls dann \mathcal{P}_{t+1} noch unvollständig ist, werden die Elemente von \mathcal{F}_{i+1} bezüglich der Crowding-Distanz sortiert. Die Individuen mit der höchsten Crowding-Distanz werden bis zur Kapazitätsgrenze in \mathcal{P}_{t+1} aufgenommen.

Berücksichtigen der Crowding-Distanz bei der Umweltselektion dient der Diversitätswahrung in der Population. Daher wird die Crowding-Distanz auch bei der Elternselektion genutzt. Im Rahmen der Turnierselektion wird das Individuum mit dem besseren Rang gewählt. Stammen beide Individuen aus derselben Front, wird das Individuum mit der höheren Crowding-Distanz favorisiert, da in dessen Umgebung weniger Individuen liegen.

Wenn der Optimierungszyklus abgeschlossen ist, wird \mathcal{F}_1 als Lösung ausgegeben. Diese Front umfasst gewöhnlich mehrere nicht-dominierte Lösungen. Daher muss diejenige Lösung ausgewählt werden, die umgesetzt werden soll. Die Auswahl, welche unabhängig vom Optimierungsalgorithmus erfolgt, wird in Abschnitt 6.6.4 beschrieben.

6.6.3 Algorithmus \mathcal{A}_{PMO} : Präferenzbasierte multikriterielle Optimierung

Shukla *et al.* präsentieren den Algorithmus pNSGA-II [281], welcher eine Weiterentwicklung von NSGA-II zur Berücksichtigung von Präferenzen darstellt. Der Algorithmus \mathcal{A}_{PMO} entspricht pNSGA-II, wobei die gleichen Änderungen bezüglich der Repräsentation von Lösungen sowie der Rekombination und der Mutation vorgenommen wurden wie in Algorithmus \mathcal{A}_{MO} .

Grundsätzlich ist das Vorgehen identisch zu Algorithmus \mathcal{A}_{MO} , weist bei der Partitionierung der Lösungsmenge in Fronten jedoch einen entscheidenden Unterschied auf. In den Schritten (2) und (6) findet zunächst weiterhin eine nicht-dominierte Sortierung unter Berücksichtigung der Restriktionsverletzungen statt. Aus der nicht-dominierten Menge \mathcal{F}_1 wird daraufhin eine Front \mathcal{F}_0 abgespalten, welche alle Geoffrion- M -eigentlich Pareto-optimalen Lösungen umfasst. Hierzu finden paarweise Vergleiche entsprechend Ungleichung (6.2) statt. Der Parameter M , welcher die Trade-offs beschränkt, kann vor der Optimierung frei gewählt werden. Durch dieses Vorgehen erhalten die Geoffrion- M -eigentlich Pareto-optimalen Lösungen einen besseren Rang und werden bei den Selektionen bevorzugt. Auf diese Weise wird die Suche in die präferierten Bereiche gelenkt.

Wie sich die zusätzliche Front auf die Umweltselektion auswirkt, ist schematisch in Abbildung 6.6 dargestellt. Zu Beginn der Ausführung von Algorithmus \mathcal{A}_{PMO} ist die erste Front, wie in Abbildung 6.6a gezeigt, in der Regel kleiner als die Gesamtpopulation. Daher werden sowohl \mathcal{F}_0 als auch \mathcal{F}_1 in die neue Population \mathcal{P}_{t+1} übernommen. In diesem Fall zeigt die neue Front keine Auswirkung auf die Umweltselektion. Bei der Elternselektion hingegen werden die Elemente aus \mathcal{F}_0 bevorzugt. Wird der Algorithmus weiter ausgeführt, so steigt die Anzahl der nicht-dominierten Elemente und damit auch die Größe von \mathcal{F}_1 . In dieser Phase übersteigt die Größe von \mathcal{F}_1 irgendwann die Populationsgröße. Dieser Zustand ist in Abbildung 6.6b skizziert. Falls \mathcal{F}_0 kleiner als eine Population ist, gehen alle Elemente dieser Front in die nächste Generation über. Statt die Crowding-Distanz zur Selektion zu nutzen, werden die Geoffrion- M -eigentlich Pareto-optimalen Lösungen ausgewählt. Die Crowding-Distanz wird lediglich benötigt, um die Population \mathcal{P}_{t+1} mit Elementen aus \mathcal{F}_1 aufzufüllen. In der Endphase von Algorithmus \mathcal{A}_{PMO} umfasst \mathcal{F}_0 mehr Individuen als die nächste Population aufnehmen kann. Die überlebenden Individuen werden, wie in Abbildung 6.6c dargestellt, über die Crowding-Distanz innerhalb von \mathcal{F}_0 ermittelt. Auch in diesem Fall wirken sich somit die Präferenzen auf die Umweltselektion aus, da \mathcal{F}_1 nicht in die nachfolgende Generation übergeht.

Die optimalen Lösungen der in diesem Kapitel formulierten Energiemanagement-Probleme und vieler anderer realer Probleme sind unbekannt, sodass die Güte der ermittelten Lösungen nicht präzise ermittelt werden kann. Aus diesem Grund werden Optimierungsalgorithmen oftmals an-

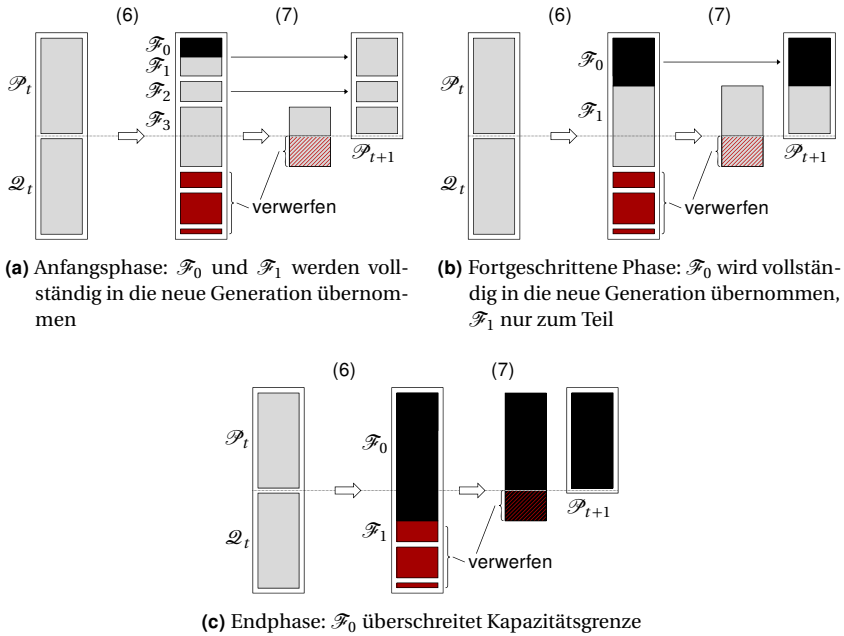


Abbildung 6.6 – Bewertung und Umweltselektion in Algorithmus \mathcal{A}_{PMO} über verschiedene Phasen hinweg, nach [281]. Es werden die gleichen Schritte wie in Algorithmus \mathcal{A}_{MO} durchgeführt mit dem Unterschied, dass die Geoffrion- M -eigentlichen Pareto-optimalen Lösungen aus \mathcal{F}_1 in eine eigene Front \mathcal{F}_0 (schwarz) ausgelagert werden.

hand von Testproblemen bewertet, deren Optima bekannt sind. Eine Reihe solcher Testprobleme [140, 141, 343] wurde auch zur Evaluation von pNSGA-II eingesetzt [281]. Die Ergebnisse belegen, dass der Algorithmus gute Konvergenzeigenschaften besitzt und dass darüber hinaus die ermittelten Lösungen eine hohe Diversität aufweisen.

In dieser Arbeit wurden, von der gewichteten Skalarisierung abgesehen, ausschließlich Präferenzen bezüglich der Geoffrion- M -eigentlichen Pareto-Optimalität betrachtet. Mit dem vorgestellten Ansatz, eine Front \mathcal{F}_0 abzuspalten, können jedoch zahlreiche Arten von Präferenzen a priori einbezogen werden. Shukla *et al.* analysieren weitere Präferenzmodelle [282, 283], welche sie im Rahmen der Optimierung einbringen. Ferner untersuchen

Hirsch *et al.* variable Präferenzen [130], die in Abhängigkeit der konkreten Punkte im Zielraum festgelegt werden. In den genannten Studien konnten die Leistungsfähigkeit und die vielfältige Anwendbarkeit des Ansatzes gezeigt werden.

6.6.4 Entscheidungsfindung

Die multikriterielle Optimierung der Energiemanagement-Probleme liefert eine Menge von Pareto-optimalen oder Geoffrion- M -eigentlich Pareto-optimalen Lösungen. Hieraus muss die umzusetzende Alternative ausgewählt werden. Dieser Schritt wird als multiattributive Entscheidungsfindung (englisch: *multi-attribute decision making* – MADM) bezeichnet [335].

In dieser Arbeit kommt die *Technique for Order Preference by Similarity to Ideal Solution* (TOPSIS), die von Hwang und Yoon entwickelt wurde [142, Kap. 2.3.5], zum Einsatz. Grundidee dabei ist, diejenige Lösung auszuwählen, die einerseits einen möglichst geringen Abstand zu einer Ideallösung und andererseits einen möglichst hohen Abstand zu einer Antiideallösung aufweist. Ausgehend von einer Lösungsmenge $\{\underline{x}_1, \dots, \underline{x}_S\}$, deren Elemente aus \mathbb{R}^N stammen, sowie den Zielfunktionen $f_r: \mathbb{R}^N \rightarrow \mathbb{R}$ für $r = 1, \dots, R$, welche auch als Attribute bezeichnet werden, kann die Entscheidungsmatrix

$$\mathbf{E} = (e_{sr})_{s \in \{1, \dots, S\}, r \in \{1, \dots, R\}} = \begin{pmatrix} f_1(\underline{x}_1) & f_2(\underline{x}_1) & \cdots & f_R(\underline{x}_1) \\ f_1(\underline{x}_2) & f_2(\underline{x}_2) & \cdots & f_R(\underline{x}_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_1(\underline{x}_S) & f_2(\underline{x}_S) & \cdots & f_R(\underline{x}_S) \end{pmatrix}$$

erzeugt werden. Das TOPSIS-Verfahren umfasst folgende Schritte [333]:

1. Berechnung einer normalisierten Entscheidungsmatrix $\mathbf{O} \in \mathbb{R}^{S \times R}$ mit den Komponenten

$$o_{sr} = \frac{e_{sr}}{\sqrt{\sum_{s=1}^S e_{sr}^2}}, \quad s \in \{1, \dots, S\}, r \in \{1, \dots, R\}.$$

Dadurch werden die Dimensionen der Attribute entfernt und die Spaltenvektoren der Matrix normiert, sodass eine Vergleichbarkeit der Attribute möglich ist.

2. Gewichtung der Attribute mittels w_1, \dots, w_R . Aus der Multiplikation der einzelnen Spalten der normalisierten Entscheidungsmatrix mit den zugehörigen Gewichtungsfaktoren resultiert die gewichtete normalisierte Entscheidungsmatrix $\mathbf{Z} = (z_{sr})_{s \in \{1, \dots, S\}, r \in \{1, \dots, R\}}$. Deren Komponenten berechnen sich folglich durch $z_{sr} = w_r o_{sr}$.
3. Berechnung der Ideallösung \underline{z}^+ und der Antiideallösung \underline{z}^- . Diese setzen sich komponentenweise jeweils aus den besten bzw. schlechtesten Attributwerten zusammen:

$$\underline{z}^+ = (z_1^+, \dots, z_R^+)', \quad z_r^+ = \min_s z_{sr}, \quad r = 1, \dots, R$$

und

$$\underline{z}^- = (z_1^-, \dots, z_R^-)', \quad z_r^- = \max_s z_{sr}, \quad r = 1, \dots, R.$$

4. Bestimmung der euklidischen Abstände jeder Alternative zu der Ideallösung und der Antiideallösung. Diese werden berechnet durch

$$\delta_s^+ = \sqrt{\sum_{r=1}^R (z_{sr} - z_r^+)^2}, \quad s = 1, \dots, S$$

und

$$\delta_s^- = \sqrt{\sum_{r=1}^R (z_{sr} - z_r^-)^2}, \quad s = 1, \dots, S.$$

5. Berechnung der relativen Nähe zur Ideallösung. Diese wird für jede Alternative \underline{z}_s , welche Zeile s der gewichteten normalisierten Entscheidungsmatrix \mathbf{Z} entspricht, definiert als:

$$\nu_s = \frac{\delta_s^-}{\delta_s^+ + \delta_s^-}, \quad s = 1, \dots, S.$$

Der Wert ν_s ist umso größer, je weiter die Alternative \underline{z}_s von der Antiideallösung entfernt liegt und je näher an der Ideallösung. Er liegt im Intervall $[0, 1]$ und nimmt die Werte 0 bzw. 1 an, wenn \underline{z}_s der Antiideal- bzw. Ideallösung entspricht.

Nach Durchführung dieser Schritte wird die Lösung umgesetzt, welche den höchsten Wert für ν_s aufweist. Die Wahl deckt sich mit dem intuitiven Verständnis, dass Lösungen zu bevorzugen sind, welche näher an der bestmöglichen Lösung liegen und weiter weg von der schlechtestmöglichen. Es ist anzumerken, dass für die Entscheidungsfindung im Rahmen des Energiemanagements in dieser Arbeit keine Gewichtung a posteriori vorgenommen wurde. Im zweiten Schritt des TOPSIS-Verfahrens galt somit $w_1 = w_2 = \dots = w_R$.

Die in den vorhergehenden Kapiteln beschriebenen Energiemanagement-Konzepte wurden mit Hilfe von Simulationsstudien evaluiert, in denen verschiedene Szenarien betrachtet wurden. Das zugrunde liegende Rahmenszenario wurde in Kapitel 3 vorgestellt. Dieses übergeordnete Szenario bildet das Grundgerüst, auf dem alle Szenarien aufbauen, welche in diesem Kapitel untersucht werden.

Die Evaluation gliedert sich in zwei Teile, welche sich durch den Umfang des durchgeführten Energiemanagements unterscheiden. Im ersten Teil wird das Lastmanagement und im zweiten Teil das kombinierte Last- und Erzeugungsmanagement betrachtet. Beide Teile umfassen sowohl Szenarien, in denen eine skalare Optimierung durchgeführt wird, als auch Szenarien, in denen multikriteriell optimiert wird.

Zunächst wird in beiden Teilen ein Basisszenario beschrieben, das jeweils eine Standardbelegung für Parameterwerte umfasst. In den darauffolgenden Szenarien werden diese Parameter variiert. Ziel ist es, deren Einfluss auf das Energiemanagement zu analysieren und dabei zu evaluieren, inwiefern sich der entwickelte Energiemanagement-Ansatz für verschiedene Einsatzszenarien eignet. Insbesondere wurden folgende Parameter untersucht:

- Zielvorgabe für das Leistungsprofil
- Länge des Planungshorizonts
- Netzbelastung
- Flexibilitätspotenzial
- Präferenzen bei der Optimierung

Wie in Kapitel 3 dargestellt, werden in den Szenarien neben intelligenten auch konventionelle Haushalte betrachtet. Für letztere müssen auf Grundlage von gemessenen Verbrauchswerten Lastprognosen erstellt werden. Im Rahmen der Simulation der Szenarien wurde keine erneute Prognose für die konventionellen Haushalte durchgeführt, da ohnehin schon die generierten Profile (siehe Abschnitt 3.2.1) vorlagen. Diese wurden auf Basis der Ergebnisse in Kapitel 5 mit einem Prognosefehler von 50 % belegt. Für die intelligenten Entitäten, welche die Prognose selbst erstellen, wurde ein Fehler von 10 % angenommen.

Bei den zur Lösung der Optimierungsprobleme eingesetzten genetischen Algorithmen handelt es sich um stochastische Verfahren, die Pseudozufallszahlen einsetzen. Daher wurde jedes Szenario 20 Mal simuliert, wobei die Pseudozufallszahlengeneratoren für jeden Lauf verschieden initialisiert wurden. Die Pseudozufallszahlengeneratoren der entsprechenden Simulationsläufe verschiedener Szenarien wurden jeweils mit dem gleichen Wert initialisiert. Dies bedeutet, dass zum Beispiel im fünften Simulationslauf von Szenario 1 der gleiche Pseudozufallszahlengenerator-Initialisierungswert wie im fünften Lauf von Szenario 2 genutzt wurde. Daher waren die Leistungsprofile der Entitäten im unoptimierten Zustand in beiden Läufen identisch, sofern die gleichen Entitäten beteiligt waren.

7.1 Lastmanagement-Szenarien

In den folgenden Betrachtungen zum Lastmanagement umfasst das Niederspannungsnetz, welches in Abschnitt 3.3 dargestellt wurde, ausschließlich Verbraucher. Die Photovoltaik-Anlagen bleiben hierbei unberücksichtigt. Dies ermöglicht eine Abschätzung des Potenzials einer flexiblen Leistungsführung durch Energieverbraucher.

7.1.1 Szenario 1: Basisszenario für das Lastmanagement

Für das Lastmanagement-Basisszenario wurden zunächst Werte der zu untersuchenden Parameter festgelegt. Diese wurden nicht im Rahmenszenario für alle abgeleiteten Szenarien einheitlich definiert. Die Parameterwerte stellen plausible Annahmen für ein Lastmanagement im Normalbetrieb dar und bilden den Ausgangspunkt für die folgenden Szenarien. Sofern nicht

explizit angegeben, werden die Parameterwerte in den weiteren Lastmanagement-Ansätzen beibehalten.

Als Zielvorgabe für das über alle Entitäten aggregierte Leistungsprofil wurden flache Profile angenommen. Diese sind beispielsweise für Energieversorgungsunternehmen vorteilhaft, unter anderem weil vorhandene Kapazitäten besser ausgelastet und Investitionen in neue Kapazitäten verzögert werden können [221]. Als konstanter Zielwert des flachen Profils wurde in den Simulationen der mittlere Verbrauch aller Entitäten im Planungshorizont festgelegt. Falls die Entitäten eine beliebig hohe Flexibilität aufwiesen, könnte dieses Zielprofil realisiert werden, ohne den Gesamtverbrauch zu verändern. Die Berechnung des durchschnittlichen Verbrauchs wurde auf Basis der Leistungsprognosen der Entitäten vorgenommen.

Der Planungshorizont wurde auf 24 Stunden, also 96 Zeitschritte, festgelegt. Diese Werte kommen in der Energiewirtschaft häufig vor, wie beispielsweise bei der Tageseinsatzplanung [124, Kap. 3.1].

Die Netzbelastung wurde im Basisszenario nicht verändert. Demzufolge deckten die 101 Haushaltsentitäten ihren standardmäßigen Verbrauch.

Das Flexibilitätspotenzial kann in den Szenarien über zwei Parameter gesteuert werden: zum einen die Anzahl der Zeitschritte, in denen die Last verschiebbar ist, und zum anderen die Anzahl an Verlagerungsangeboten, die jede Entität unterbreiten kann. Im Basisszenario wurde für den Planungshorizont die Leistung von 10–20 Zeitschritten als verschiebbar angenommen. Die konkrete Anzahl von Zeitschritten wurde für jedes Verlagerungsangebot in diesem Intervall zufällig gewählt. Ferner war maximal ein Verlagerungsangebot je Planungshorizont zulässig ($\kappa_n = 1$ in den Problemen (P3), (P4) und (P6)), wobei eine Angebotsabgabe nicht zwingend erforderlich war. Im Schnitt gaben 90 % der Entitäten ein Angebot ab.

Im Basisszenario wurde das skalare Problem (P4) betrachtet. Spezielle Präferenzen bezüglich der Gewichtung der Teilziele Approximationsgüte und Kosten wurden nicht angenommen. Daher wurden die Gewichtungsfaktoren $w_1 = w_2 = 1$ gesetzt. Im Rahmen der Optimierung fand eine Normierung der Zielfunktionen statt, um die Vergleichbarkeit der Teilziele zu gewährleisten.

Zur Optimierung wurde im Basisszenario Algorithmus \mathcal{A}_{SO} (siehe Abschnitt 6.6.1) eingesetzt. Die Parameterbelegung für die Rekombinations- und Mutationsoperatoren wurde bereits in Abschnitt 6.6 beschrieben.

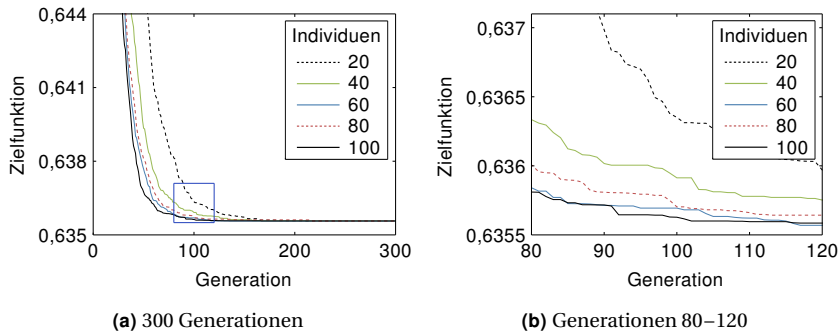


Abbildung 7.1 – Szenario 1: Beste Lösung (Mittelwert über 20 Simulationsläufe) in Abhängigkeit der Generationen des genetischen Algorithmus für verschiedene Populationsgrößen. Die Zielfunktion ist normiert. Der in (b) gezeigte Ausschnitt ist durch ein Rechteck in (a) markiert.

Darüber hinaus mussten noch eine geeignete Populationsgröße sowie eine maximale Anzahl von Funktionsauswertungen als Abbruchkriterium gewählt werden. Hierzu wurde eine Parameterstudie durchgeführt, deren Ergebnis in Abbildung 7.1 zu sehen ist. Abbildung 7.1a zeigt, für verschiedene Populationsgrößen, den durchschnittlichen Funktionswert der besten Lösung einer Population in Abhängigkeit der Generation. Der Durchschnitt wurde über die 20 Simulationsläufe gebildet, wobei jeder Lauf einen Zeitraum von einem Tag simulierte. Da ein Minimierungsproblem vorliegt, sind kleine Zielfunktionswerte erstrebenswert. Algorithmus \mathcal{A}_{SO} wurde mit den Populationsgrößen $\mu \in \{20, 40, 60, 80, 100\}$ durchgeführt, sodass g Generationen $\mu \cdot g$ Funktionsauswertungen entsprechen. Die ersten 70 Generationen verbesserte sich der Funktionswert für alle Populationsgrößen deutlich. Danach wurden die Verbesserungen mit steigender Populationsgröße zwar kleiner, die größeren Populationen führten jedoch zu besseren Lösungen. Ab etwa Generation 100 führten die drei größten Populationen nur noch zu geringen Verbesserungen der Lösungsgüte, wie in Abbildung 7.1b zu sehen ist. Hier führten die 60, 80 und 100 Individuen umfassenden Populationen zu vergleichbaren Ergebnissen. Daher wurde für das Basisszenario eine Populationsgröße von 60 Individuen gewählt und die Optimierung nach 6000 Funktionsevaluationen abgebrochen. Diese Parameterwerte wurden für alle Lastmanagement-Szenarien beibehalten.




Abbildung 7.2 – Szenario 1: Zielvorgabe für die Leistung sowie unoptimierte und optimierte aggregierte Leistungsprofile für eine Woche (Mittelwerte über 20 Simulationsläufe). Negative Werte entsprechen einem Verbrauch.

Abbildung 7.2 zeigt das zeitlich aufgelöste Ergebnis der Leistungsführung für einen Simulationshorizont von einer Woche im August beginnend bei einem Montag. Darin stellt die schwarze Kurve den unoptimierten aggregierten Lastgang aller Entitäten dar. Hierbei erstellten die Entitäten keine Verlagerungsangebote, sondern führen ihr Profil ohne Beeinflussung ab. Die blaue Kurve entspricht der Zielvorgabe für das aggregierte Profil, welches auf Grundlage der Prognose der Entitäten erstellt wurde. Wie beschrieben ist das Zielprofil für jeden Planungshorizont von 24 Stunden konstant. Die rote Kurve stellt die aggregierte Leistung dar, welche durch die flexible Leistungsführung hervorgerufen wurde. Alle Kurven repräsentieren die entsprechenden Mittelwerte über 20 Simulationsläufe. Aus der Abbildung wird ersichtlich, dass sich die Leistung an die Zielvorgabe annähert. Insbesondere konnten Leistungsspitzen gesenkt werden. Die abgebildeten Werte des optimierten Profils umfassen bereits die Prognosefehler.

Über jeden einzelnen Tag hinweg lassen die Leistungskurven vergleichbare Verläufe erkennen. Daher werden die Abweichungen von den Zielvorgaben stellvertretend für den ersten Wochentag in Abbildung 7.3 näher dargestellt. Das optimierte Profil liegt im Mittel in den meisten Zeitschritten näher an der Zielvorgabe als das unoptimierte Profil. Dies kam überwiegend dadurch zustande, dass der Verbrauch der Morgen-, Mittags- und Abendstunden in die Nacht- und frühen Morgenstunden verschoben wurde. Am Nachmittag wurden kaum Lastverschiebungen durchgeführt, da der Verbrauch in der Nähe der Zielvorgaben lag.




Abbildung 7.3 – Szenario 1: Abweichung von der Zielvorgabe für einen Wochentag. Bei den unoptimierten und optimierten Leistungsprofilen treten negative Werte auf, wenn die aggregierte Last kleiner als die Ziellast ist, z. B. da der Verbrauch zu hoch ist (Erzeugung wird positiv gezählt und Verbrauch negativ). Die dunkelgrüne Kurve bildet die Differenzen der Beträge der Abweichungen im unoptimierten und im optimierten Fall ab (Mittelwerte). Positive Werte entsprechen dabei einer geringeren Zielabweichung im optimierten Fall. Die Standardabweichung der Betragsdifferenzen über 20 Simulationsläufe ist in Hellgrün eingezeichnet.

Die Verschiebungen wurden durch Präferenzbekundungen des Energiemanagers angeregt. Diese wurden, wie in Abschnitt 3.1.2 beschrieben, anhand der prognostizierten Zielabweichung erstellt. Eine größere Zielabweichung führte zu einer höheren Verschiebepreferenz, die wiederum bei den Entitäten eine höhere Wahrscheinlichkeit für eine Verschiebung hervorrief. Diese Tatsache spiegelt sich im Verlauf der dunkelgrünen Kurve wider, welche die Differenz der Beträge der Zielabweichungen im unoptimierten und im optimierten Fall darstellt. In jedem Zeitschritt wurde der Betrag der optimierten Zielabweichung (rote Kurve) vom Betrag der unoptimierten Zielabweichung (schwarze Kurve) subtrahiert, sodass ein positiver Wert der dunkelgrünen Kurve einer Verringerung der Zielabweichung durch die Optimierung entspricht. In den Zeitschritten, in denen die unoptimierte Zielabweichung relativ hoch ist, und damit auch die Verschiebepreferenz, wird mehr Last verschoben als in Zeitpunkten mit niedriger Zielabweichung.

Die dunkelgrüne Kurve der Differenzen der Zielabweichungsbeträge in Abbildung 7.3 zeigt für $t = 1, \dots, 96$ die Mittelwerte m_t über 20 Simulationsläufe. Bei einer Standardabweichung σ_t entsprechen die oberen und unteren Enden der hellgrünen Balken $m_t + \sigma_t$ und $m_t - \sigma_t$. Da diese überwiegend im positiven Bereich liegen, wurde die Zielabweichung reduziert.

Tabelle 7.1 – Simulationsergebnisse für Zielabweichung, Energieverlagerung und Kosten in Szenario 1. Die statistischen Werte beziehen sich auf 20 Simulationsläufe.

Merkmal	Mittelwert	Std.abw.	Minimum	Maximum
Zielabw. unopt. (MAPE)	28,35	0,78	27,05	29,76
Zielabw. opt. (MAPE)	21,84	1,22	19,95	25,04
Verlagerbare Energie (%)	9,92	0,43	9,13	10,83
Verlagerte Energie (%)	4,73	0,49	2,99	5,32
Kosten (Euro/Tag)	3,52	0,35	2,29	3,89

Quantitativ wird diese Verbesserung in Tabelle 7.1 erfasst. Während die Abweichung von der Zielvorgabe ohne Optimierung im Schnitt bei 28,35 % lag, konnte diese durch die Lastverschiebungen auf 21,84 % gesenkt werden. Berechnet wurden die Abweichungen über den Planungshorizont anhand des MAPE (Gleichung (5.5)). Wie die jeweiligen Minimal- und Maximalwerte belegen, wurde in jedem Simulationslauf eine Verbesserung erzielt. Dabei wurden von den Entitäten durchschnittlich 9,92 % der Gesamtenergie zur Verschiebung angeboten. Von der Gesamtenergie nutzte der Energiemanager 4,73 % im Rahmen der flexiblen Leistungsführung. Dies entspricht etwa 34 kWh bei einem Gesamtverbrauch aller Entitäten von 725 kWh im betrachteten Zeitraum. Durch die Verschiebungen entstanden keine neuen Leistungsspitzen, die höher waren als die im unoptimierten Zustand bereits vorhandenen Spitzen. Im Schnitt wurden diese durch die Optimierung um 7,32 % gesenkt, wobei in jedem Simulationslauf eine Senkung erzielt wurde. Die Kosten des Energiemanagers für die Verschiebungen beliefen sich auf 3,52 Euro für den simulierten Tag. Dieser Betrag ist durch die Verlagerungskosten von näherungsweise 0,1 Euro/kWh für Haushalte erklärbar.

Die Werte bezüglich der verschiebbaren Energie und der tatsächlich verschobenen Energie wiesen einen deutlichen Unterschied auf. Es wurde nur annähernd die Hälfte der Flexibilität in Anspruch genommen. Die Erklärung hierfür ist in der Formulierung des Optimierungsproblems zu suchen, dessen Zielfunktion Kosten und Zielerreichung gleichermaßen einbezieht. Lösungen stellen somit einen Kompromiss zwischen den Kosten für die akzeptierten Angebote einerseits und der erreichten Zielvorgabe andererseits dar. Da die Zielfunktion beide Werte zu einem Skalar zusammenfasst, kann

anhand der Bewertung von Lösungen nicht beurteilt werden, welche Verbesserungen bezüglich der beiden Teilziele möglich sind. Die umgesetzte Lösung könnte demzufolge bereits die minimale Zielabweichung erreicht haben, welche im Rahmen der Angebote umsetzbar war. Dieser Fall tritt beispielsweise dann auf, wenn verschiedene Verlagerungsangebote unvereinbar sind, da ein Angebot für manche Zeitschritte eine Senkung der Last vorsieht, während ein anderes Angebot Lasterhöhungen vornimmt. Aufgrund der kombinatorischen Struktur des Optimierungsproblems sind weitere Fälle denkbar, in denen eine Zunahme von Angeboten nicht zu einer besseren Erfüllung der Zielvorgabe führt. Ferner kann eine Ablehnung von Angeboten auch kostenbedingt erfolgen, wobei ein breites Spektrum an Kompromissen zwischen Kosten und Zielerreichung möglich ist.

Diese Überlegungen sind nicht auf heuristische Lösungen beschränkt, deren Optimalität nicht nachweisbar ist. Sie gelten auch, sofern die optimale Lösung des skalaren Optimierungsproblems für eine bestimmte Gewichtung der Teilziele bekannt ist. Jene Lösung stellt lediglich einen Punkt auf der Pareto-Front dar, welcher noch keine Rückschlüsse auf deren Verlauf zulässt. Um Aussagen bezüglich der Kompromisse und der Pareto-Front zu treffen, muss entweder das skalare Optimierungsproblem mit verschiedenen Gewichtungsfaktoren gelöst oder eine multikriterielle Optimierung durchgeführt werden. Diese Aspekte werden in Szenario 7 untersucht.

Im Rahmen der Optimierung wurden Leistungsflussberechnungen vorgenommen, um physikalische Netzrestriktionen zu berücksichtigen. Hierbei traten im Basisszenario keine Restriktionsverletzungen auf. Das in Abschnitt 3.3 beschriebene 106-Knoten-Niederspannungsnetz befand sich in jedem Zeitschritt in einem stabilen Zustand. Dies war aufgrund der Standardlast und der realitätsnahen Modellierung des Stromnetzes zu erwarten.

Abbildung 7.4 zeigt beispielhaft die Effektivwerte des Stroms und der Spannung für einen spezifischen Zeitschritt. In Abbildung 7.4a werden die Ströme durch alle Kabel im Zeitschritt 20:30–20:45 Uhr dargestellt. Für diese Zeit wurde innerhalb des simulierten Tages im unoptimierten Betrieb die höchste Stromstärke festgestellt. Diese betrug 21,9 A und lag damit deutlich unter dem Limit von 142 A für die modellierten Kabel. Ebenfalls für diesen Zeitschritt sind auch die Stromstärken im optimierten Betrieb abgebildet. Durch Verlagerung wurde die Last in den Abendstunden gesenkt (siehe Abbildung 7.3) und damit auch die Ströme durch die meisten Kabel. Der

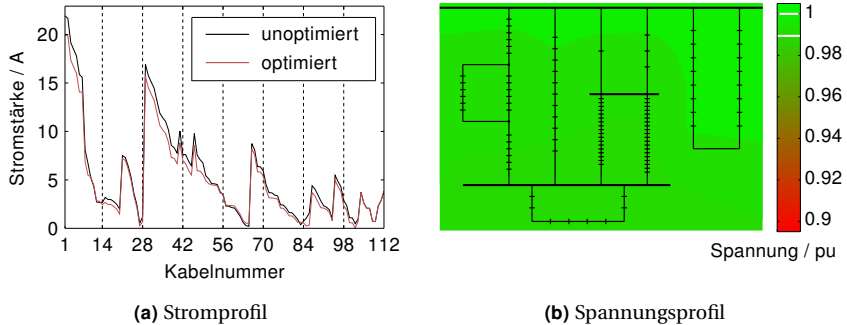


Abbildung 7.4 – Szenario 1: Strom und Spannung im simulierten Stromnetz. Die linke Seite zeigt die Ströme durch alle Kabel für den Zeitschritt, in dem im unoptimierten Betrieb die höchste Stromstärke auftrat. Die rechte Seite zeigt die Spannungen im unoptimierten Betrieb im Zeitschritt, in dem die höchste Abweichung vom Nennwert auftrat. Die maximal und die minimal auftretenden Spannungen sind in der Farbskala markiert.

sägezahnartige Verlauf der Kurven lässt die Straßenzüge erkennen, entlang derer die Stromstärke in Richtung Ortsnetzstation zunahm. Die Kabelnummern sind Abbildung 3.6 auf Seite 55 zu entnehmen.

Abbildung 7.4b zeigt das Spannungsprofil des Stromnetzes im unoptimierten Betrieb für die Zeit 13:00–13:15 Uhr. Hier wurde die höchste Abweichung von der Nennspannung festgestellt. Da das simulierte Netz ausschließlich Verbraucher umfasste, handelte es sich dabei um eine Spannungssenkung. Diese betrug 0,97 % und lag somit innerhalb des Intervalls zulässiger Abweichungen von der Versorgungsspannung von $\pm 10\%$, die nach DIN EN 50160 [72, Kap. 4.2.2.1] für Niederspannungsnetze festgelegt wurden.

7.1.2 Szenario 2: Variables Zielprofil

Nachdem im Basisszenario flache Leistungsprofile mit einem konstanten Wert als Zielvorgabe genutzt wurden, wird im zweiten Szenario ein variables Zielprofil betrachtet. Hierfür wurde die reale Einspeisung aus Windenergie¹

¹ <http://www.eex-transparency.com/homepage/power/germany-austria/production/usage/actual-wind-power-generation/actual-wind-power-generation-table->, abgerufen am 21.10.2015

in stündlicher Auflösung in der Regelzone von TransnetBW am 17. August 2014 auf den Verbrauch des simulierten Netzes skaliert. Dieses Profil ist in Abbildung 7.5 dargestellt. Ein Anwendungsfall für die flexible Leistungsführung mit einem derartigen Profil ist die erhöhte Nutzung dargebotsabhängiger Energie. Die Abbildung enthält ferner die über 20 Simulationsläufe aggregierten unoptimierten und optimierten Leistungsprofile. Aufgrund der oben beschriebenen Generierung von Pseudozufallszahlen stimmen die unoptimierten Leistungsprofile in den Szenarien 1 und 2 überein.

Durch das Energiemanagement konnte auch für das variable Zielprofil, bei gleicher Ausgangslage wie im Basisszenario, eine verbesserte Approximation erzielt werden. Dies ist anhand von Abbildung 7.5 ersichtlich und wird in Tabelle 7.2 quantifiziert. Bei der Abweichung von der Zielvorgabe unterschieden sich die beiden Szenarien. Im unoptimierten Netz lag die Zielabweichung in Szenario 2 durchschnittlich etwa 13 Prozentpunkte höher als in Szenario 1. Gemessen am MAPE war das flache Zielprofil somit dem unoptimierten aggregierten Profil ähnlicher als das Windprofil. Im zweiten Szenario wurde mit dem verschobenen Energieanteil von 4,59 % eine Senkung der Zielabweichung von 9,79 % erzielt. Eine Änderung der Abweichung, welche das Doppelte der verschobenen Energie übersteigt, erscheint zunächst nicht intuitiv. Dies ist jedoch auf die Definition des MAPE zurückzuführen, welcher ein relatives Maß darstellt. Das Verschieben einer Energieeinheit führt in der Regel nicht zu einer prozentual entsprechenden Veränderung der Abweichung.




Abbildung 7.5 – Szenario 2: Zielvorgabe für die Leistung sowie unoptimierte und optimierte aggregierte Leistungsprofile (Mittelwerte über 20 Läufe)

Tabelle 7.2 – Simulationsergebnisse für Szenario 2

Merkmal	Mittelwert	Std.abw.	Minimum	Maximum
Zielabw. unopt. (MAPE)	41,59	1,64	37,78	43,74
Zielabw. opt. (MAPE)	31,80	1,53	28,35	34,43
Verlagerbare Energie (%)	9,56	0,54	8,75	10,90
Verlagerte Energie (%)	4,59	0,36	4,10	5,29
Kosten (Euro/Tag)	3,38	0,27	2,98	3,90

Die weiteren Werte für verlagerbare Energie, verlagerte Energie und die Kosten in Szenario 2 sind vergleichbar mit den Werten in Szenario 1. Weitere Simulationen mit verschiedenen zufälligen Zielvorgaben lieferten ebenfalls ähnliche Ergebnisse. Dies belegt, dass eine flexible Leistungsführung unabhängig von der konkreten Zielvorgabe für die Leistung möglich ist. Da keine physikalischen Netzrestriktionen verletzt wurden und sich das Stromnetz, analog zum Basisszenario, jederzeit in einem stabilen Zustand befand, werden diese Ergebnisse nicht detailliert dargestellt.

7.1.3 Szenario 3: Verkürzter Planungshorizont

Im dritten Szenario werden die Auswirkungen einer Verkürzung des Planungshorizonts auf das Energiemanagement gezeigt. Hierfür wurden, mit Ausnahme des Planungshorizonts, erneut die Parameterwerte des Basisszenarios genutzt. Im Rahmen der Simulationen wurden zwei Planungshorizonte mit einer Dauer von 12 Stunden und von 6 Stunden betrachtet.

Analog zum Vorgehen in Szenario 1 wurden für jeden Planungshorizont weiterhin flache Zielleistungskurven zugrunde gelegt. Über einen simulierten Tag hinweg ergaben sich daher zwei bzw. vier konstante Abschnitte, wie in Abbildung 7.6 zu erkennen ist. Durch die Optimierung wurde auch in diesem Szenario eine Annäherung an die Zielvorgabe erreicht. Daher verlaufen die dunkelgrünen Kurven in Abbildung 7.7, welche die Betragsdifferenzen zwischen unoptimierter und optimierter Zielabweichung darstellen, überwiegend im positiven Bereich.

Die Zahl der Zeitschritte eines Planungshorizonts, in denen eine Lastverschiebung durchführbar war, wurde in Szenario 3 proportional zur Länge

des Planungshorizonts gekürzt. Daher wies die verschiebbare Energie für Planungshorizonte von 24, 12 und 6 Stunden annähernd gleiche Werte auf. Diese sind in Tabelle 7.3 zusammengefasst. Trotz eines nahezu identischen Verschiebepotenzials sank die tatsächlich verschobene Energie mit abnehmender Horizontlänge von 4,73 % über 4,59 % auf 3,90 %. Zurückzuführen ist dies auf die abnehmende Zahl kombinatorischer Möglichkeiten, eine Lastverschiebung in einem kürzeren Zeitraum durchzuführen. Dadurch steigt die Wahrscheinlichkeit, dass Angebote miteinander unvereinbar sind.

Ein Vergleich der Verbesserungen, welche durch die Optimierung erzielt wurden, ist nicht ohne Weiteres möglich. Zum einen unterschieden sich bereits im unoptimierten Betrieb die Abweichungen. Je kürzer der Planungshorizont, desto geringer war die Gesamtabweichung von dem abschnittsweise flachen Zielprofil. Mit zunehmender Anzahl dieser Abschnitte wurde das aggregierte Leistungsprofil bereits im Ausgangszustand besser approximiert. Zum anderen müssten energiewirtschaftliche Betrachtungen angestellt werden, um den Nutzen der Zielprofile zu bewerten. Die Zielabweichung war bei einem Planungshorizont von 24 Stunden zwar höher als bei den kürzeren Horizonten, jedoch ist ein über den gesamten Zeitraum glatteres Profil unter Umständen vorteilhafter. An den Enden der kürzeren Planungshorizonte treten oftmals Sprünge zwischen den Werten der Zielvorgabe auf, die Sprünge im aggregierten Leistungsprofil hervorrufen.




Abbildung 7.6 – Szenario 3: Zielprofil sowie unoptimierte und optimierte Leistungsprofile (Mittelwerte) für kürzere Planungshorizonte

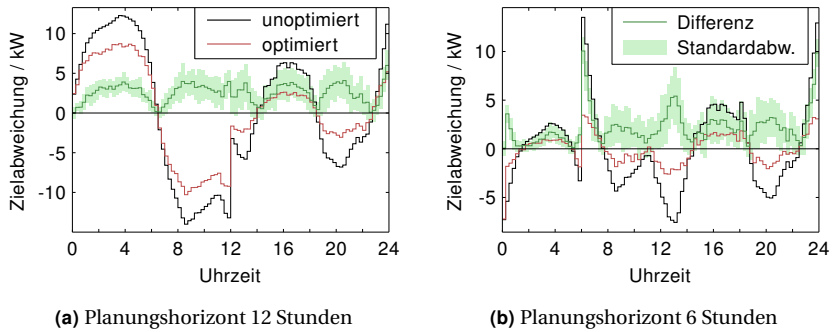



Abbildung 7.7 – Szenario 3: Abweichung von der Zielvorgabe. Bei den unoptimierten und optimierten Leistungsprofilen treten negative Werte auf, wenn die aggregierte Last kleiner als die Ziellast ist. Die dunkelgrünen Kurven bilden die Differenzen zwischen den Beträgen der Abweichungen im unoptimierten und im optimierten Fall ab (Mittelwerte). Positive Werte entsprechen dabei einer geringeren Zielabweichung im optimierten Fall.

Tabelle 7.3 – Simulationsergebnisse für Szenario 3 bezüglich der Planungshorizonte von 12 Stunden ($T = 48$) und von 6 Stunden ($T = 24$)

Merkmal	Mittelwert	Std.abw.	Minimum	Maximum
$T = 48$				
Zielabw. unopt. (MAPE)	26,77	1,18	23,93	28,43
Zielabw. opt. (MAPE)	18,03	1,04	16,40	19,85
Verlagerbare Energie (%)	9,91	0,32	9,35	10,65
Verlagerte Energie (%)	4,59	0,21	4,21	5,06
Kosten (Euro/Tag)	3,33	0,17	2,97	3,65
$T = 24$				
Zielabw. unopt. (MAPE)	12,53	0,66	11,28	13,71
Zielabw. opt. (MAPE)	5,55	0,50	4,57	6,47
Verlagerbare Energie (%)	9,74	0,28	9,15	10,35
Verlagerte Energie (%)	3,90	0,16	3,60	4,27
Kosten (Euro/Tag)	2,75	0,13	2,45	2,97



(a) Zielvorgabe und aggregierte Profile

(b) Zielabweichung der aggregierten Profile

Abbildung 7.8 – Szenario 4: Aggregierte Leistungsprofile im unoptimierten und optimierten Betrieb sowie Abweichung dieser Profile von der Zielvorgabe. Negative Abweichungen treten auf, wenn die aggregierte Last kleiner als die Ziellast ist. Die dunkelgrüne Kurve bildet die Differenzen zwischen den Beträgen der Abweichungen im unoptimierten und im optimierten Fall ab. Positive Werte entsprechen einer geringeren Zielabweichung im optimierten Fall. Bis auf die in Hellgrün dargestellte Standardabweichung bilden die Kurven Mittelwerte über alle Simulationsläufe ab. Die Optimierung berücksichtigt Netzrestriktionen.

7.1.4 Szenario 4: Hohe Netzbelastung

Das simulierte Niederspannungsnetz wurde unter Normallast nicht an die Belastungsgrenze gebracht. Daher schränkten die Netzrestriktionen des Optimierungsproblems den Suchraum nicht ein. Im vierten Szenario wird aus diesem Grunde untersucht, welche Auswirkungen eine flexible Leistungsführung unter hoher Netzbelastung hat. Zu diesem Zweck wurde, bei gleicher Parameterbelegung wie im Basisszenario, der Verbrauch jeder Entität um das Achtfache erhöht. Um den Einfluss der Netzrestriktionen zu ermitteln, werden die Optimierungsprobleme (P3) und (P4) gegenübergestellt. Diese unterscheiden sich dahingehend, dass Nebenbedingungen bezüglich Strom und Spannung in Problem (P3) unberücksichtigt bleiben.

Die aggregierten Leistungsprofile, welche in Abbildung 7.8a dargestellt sind, lassen eine Annäherung an das Zielprofil im optimierten Betrieb, bei dem Netzrestriktionen einbezogen wurden, erkennen. Die mittleren Zielabweichungen vor und nach der Optimierung sind in Abbildung 7.8b dargestellt und bestätigen die Verbesserung. Entsprechende Zahlenwerte sind in Tabelle 7.4 zusammengefasst. Darin finden sich auch die Ergebnisse der

Tabelle 7.4 – Simulationsergebnisse für Szenario 4 mit und ohne Netzrestriktionen. Zielabweichung im unoptimierten Betrieb sowie verlagerbare Energie waren in beiden Fällen identisch.

Merkmal	Mittelwert	Std.abw.	Minimum	Maximum
<i>Mit und ohne Netzrestriktionen</i>				
Zielabw. unopt. (MAPE)	28,35	0,78	27,05	29,76
Verlagerbare Energie (%)	9,89	0,44	9,04	10,83
<i>Mit Netzrestriktionen</i>				
Zielabw. opt. (MAPE)	22,12	1,63	20,12	26,23
Verlagerte Energie (%)	4,99	0,82	2,68	6,58
Kosten (Euro/Tag)	29,99	4,94	16,71	40,51
<i>Ohne Netzrestriktionen</i>				
Zielabw. opt. (MAPE)	21,87	1,33	19,95	25,61
Verlagerte Energie (%)	4,68	0,57	2,51	5,32
Kosten (Euro/Tag)	27,85	3,23	15,63	31,16

Optimierung ohne Netzrestriktionen. Diese lieferte mit einem MAPE von 21,87 % eine geringfügig bessere Approximation des Zielprofils als die Optimierung unter Berücksichtigung von Netzrestriktionen mit einem MAPE von 22,12 %. Dieses bessere Ergebnis wurde darüber hinaus durch 6,21 % weniger Energieverlagerung und damit geringere Kosten erzielt.

Die Gründe dafür sind bei näherer Betrachtung der Stromprofile ersichtlich. Hierzu werden statt der Mittelwerte nun einzelne repräsentative Läufe betrachtet, da eine Durchschnittsbildung über 20 Simulationsläufe Lastspitzen reduziert. Abbildung 7.9 zeigt die Effektivwerte der Ströme durch alle Kabel für zwei Simulationsläufe jeweils im Zeitschritt, der im unoptimierten Betrieb die höchste Stromstärke aufwies. In Abbildung 7.9a ist das Stromprofil des ersten Laufs für den Zeitschritt 20:30–20:45 Uhr dargestellt und in Abbildung 7.9b das Stromprofil des zweiten Laufs für 19:30–19:45 Uhr. Es ist zu erkennen, dass in Lauf 1 die Kabel 1–5 überlastet waren, wobei Kabel 1 die höchste Stromstärke von 186 A aufwies. Diese lag deutlich über der Belastungsgrenze der modellierten Kabel von 142 A. Eine Übersicht über Stromnetztopologie und Kabelnummern zeigt Abbildung 3.6 auf Seite 55.

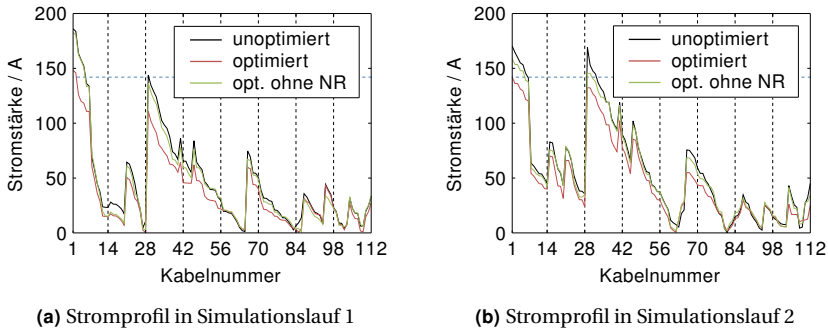


Abbildung 7.9 – Szenario 4: Stromprofil im Niederspannungsnetz für zwei exemplarische Simulationsläufe. Dargestellt sind die Profile in den Zeitschritten, in welchen im unoptimierten Betrieb jeweils die höchste Stromstärke auftrat (20:30–20:45 Uhr in Lauf 1 und 19:30–19:45 Uhr in Lauf 2). Die rote Kurve stellt die Ströme im optimierten Betrieb dar, bei welchem Netzrestriktionen berücksichtigt wurden. Die grüne Kurve zeigt die Ströme nach einer Optimierung ohne Berücksichtigung von Netzrestriktionen. Die maximale Belastbarkeit der Kabel wird durch eine horizontale, blaue Linie angezeigt.

Die Überlast wurde durch die Optimierung ohne Restriktionen nur unwesentlich gesenkt. Die ersten fünf Kabel waren immer noch überlastet und Kabel 1 führte einen Strom von 182 A. Durch die Optimierung mit Netzrestriktionen wurde die Last auf Kabel 1 auf 148 A gesenkt. Darüber hinaus wurden die Kabel 3–5 nun unterhalb der Belastungsgrenze betrieben. Im zweiten Lauf wies wiederum Kabel 1 die höchste Belastung auf. Die Spitzenbelastung von 170 A sank nach der Optimierung ohne bzw. mit Netzrestriktionen auf 158 A bzw. 142 A. Während im unoptimierten Betrieb zehn Kabel einer Überlast ausgesetzt waren, sank diese Zahl durch die Optimierung ohne Netzrestriktionen auf sieben. Nach der Optimierung unter Berücksichtigung von Netzrestriktionen wurden hingegen alle Kabel innerhalb des zulässigen Bereichs betrieben. Hierfür musste jedoch mehr Energie verschoben werden.

Die betrachteten Ströme stellen lediglich eine Momentaufnahme dar. Aus der Reduzierung der Stromstärke in einem Zeitschritt unterhalb die Belastungsgrenze können keine Rückschlüsse auf die anderen Zeitschritte gezogen werden, da durch die Lastverschiebungen neue Lastspitzen entstehen können. Daher wird in Abbildung 7.10 der Stromverlauf auf Kabel 1 über

den Simulationszeitraum dargestellt. Abgebildet sind die Werte für die beiden betrachteten Simulationsläufe. Die Stromverläufe zeigen, dass durch die Optimierung mit Netzrestriktionen keine neuen Überlasten auf Kabel 1 entstanden. Dies trifft ebenfalls auf alle anderen Kabel des Stromnetzes zu. In Simulationslauf 1 konnte die elf Zeitschritte andauernde Überlastsituation in den Abendstunden auf zwei Zeitschritte reduziert werden. In diesen beiden verbleibenden Zeitschritten wurde die Überlast von 31,0 % bzw. 16,9 % auf 4,2 % bzw. 2,1 % des Maximalstroms reduziert. Die Überlastung in den Morgen- und Mittagsstunden wurde vermieden. Der Stromverlauf nach der Optimierung ohne Berücksichtigung von Netzrestriktionen wies am Abend immer noch eine deutliche Überschreitung des Maximalwerts in fünf Zeitschritten auf. Darüber hinaus trat um 8:30 Uhr eine weitere Überschreitung auf. Im zweiten Simulationslauf ergab sich ein ähnliches Bild. Hier kam nach der Optimierung unter Berücksichtigung von Netzrestriktionen keine Überlastung mehr vor. Nach der Optimierung ohne Netzrestriktionen wurden die Lastspitzen zwar gesenkt, waren aber dennoch ausgeprägt.

Des Weiteren wurde auch eine Reduzierung der Leistungsspitzen erreicht. Über alle Simulationsläufe gemittelt, wurde die Spitzenlast durch die Optimierung mit Netzrestriktionen um 8,58 % gesenkt. Dieser Anteil lag nach Optimierung ohne Netzrestriktionen bei 7,54 %.

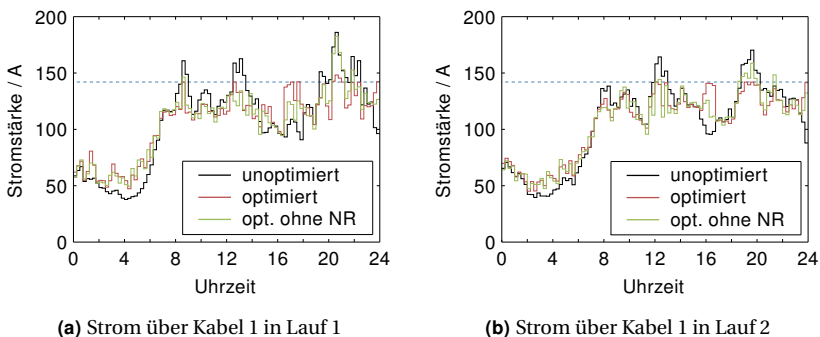


Abbildung 7.10 – Szenario 4: Stromverlauf durch Kabel 1 über einen Tag für zwei Simulationsläufe. Die maximale Belastbarkeit des Kabels wird durch eine blaue Linie angezeigt.

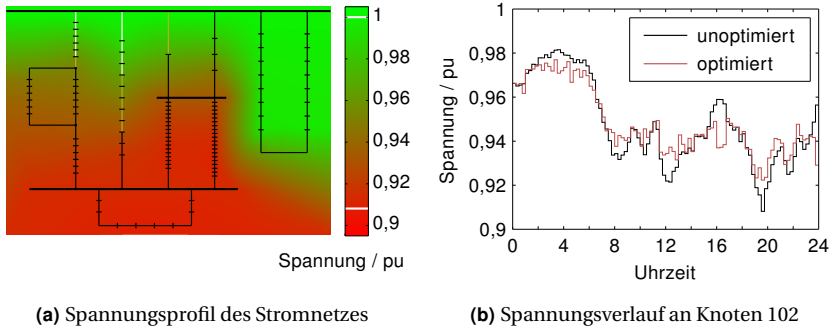


Abbildung 7.11 – Szenario 4: Knotenspannungen. Teilabbildung (a) zeigt das Spannungsprofil des Stromnetzes in Simulationslauf 2 im unoptimierten Betrieb im Zeitschritt 19:30–19:45 Uhr. Zu dieser Zeit trat die höchste Abweichung der Spannung von ihrem Nennwert auf (Knoten 102). Die maximale und die minimale Spannung sind in der Farbskala markiert. Weiß dargestellte Kabel haben ihre Kapazitätsgrenze überschritten, während gelbe Kabel diese Grenze zu mindestens 80 % erreicht, aber noch nicht überschritten, haben. Teilabbildung (b) zeigt den Spannungsverlauf an Netzknoten 102 über einen simulierten Tag hinweg.

In den Simulationsläufen wurden die Restriktionen bezüglich der Spannung nicht verletzt. Die höchste Spannungsabsenkung wurde im zweiten Simulationslauf festgestellt. Diese betrug 9,2 % der Nennspannung und trat um 19:30 Uhr an Knoten 102 auf. Das entsprechende Spannungsprofil des Stromnetzes ist in Abbildung 7.11a dargestellt. Die maximale Absenkung wurde durch die Optimierung mit Netzrestriktionen auf 7,8 % reduziert. Abbildung 7.11b zeigt, dass hierbei in anderen Zeitschritten keine neuen Spannungsspitzen entstanden. Dieser Effekt ist nicht auf die Netznebenbedingungen zurückzuführen, da diese erst ab einer Abweichung von 10 % von der Nennspannung verletzt wurden. Vielmehr trat die Kappung der Spannungsspitzen als Folge der Glättung des Leistungsprofils auf und war daher auch bei der Optimierung ohne Netzrestriktionen zu beobachten.

Zusammenfassend wurde festgestellt, dass Netzrestriktionen zu berücksichtigen sind, um umsetzbare Fahrpläne zu erzeugen. Wo es nicht möglich war, einen optimierten Fahrplan ohne Verletzung der Netzrestriktionen zu finden, wurde diese Verletzung im Vergleich zum unoptimierten Betrieb deutlich reduziert. Die Optimierung ohne Netzrestriktionen führte zu Fahrplänen, welche physikalische Grenzen des Stromnetzes überschritten.

7.1.5 Szenario 5: Erhöhte Lastflexibilität durch Zunahme der verlagerbaren Energie

Der Parameterwert für die Anzahl von Zeitschritten, in denen Energie an einem simulierten Tag verschiebbar ist, führte im Basisszenario zu einer möglichen Verlagerung von etwa 10 % des Gesamtverbrauchs. Unter der Prämisse, dass Energieverlagerung automatisiert erfolgt, stellt diese Zahl eine vorsichtige Annahme dar. Andere Studien gehen zum Beispiel von deutlich höheren Werten zwischen 15 % und 19 % [122, Kap. 4.1] oder sogar von 40 % [252] aus.

Um eine höhere Flexibilität der Verbraucherseite zu simulieren, wurde in Szenario 5 die Anzahl der Zeitschritte mit Verlagerungspotenzial gesteigert. Von den 10–20 Zeitschritten (Parameterbelegung 1) des Basisszenarios ausgehend wurden 20–30 (Parameterbelegung 2), 30–40 (Parameterbelegung 3) und 40–50 Zeitschritte (Parameterbelegung 4) betrachtet. Die entsprechenden Ergebnisse sind in Tabelle 7.5 aufgeführt. Aufgrund der bereits beschriebenen Erstellung der Haushaltsprofile und der Generierung von Pseudozufallszahlen waren die unoptimierten Ausgangsprofile für alle Parameterbelegungen identisch, sodass eine Vergleichbarkeit der Ergebnisse gewährleistet ist.

Die verlagerbare Energie nahm durch die Erhöhung des Flexibilitätspotenzials für die ersten drei Parameterbelegungen stetig zu. Für Parameterbelegung 4 war nur noch eine geringe Zunahme zu verzeichnen. Dies kann auf die Erstellung der Verlagerungsangebote von Haushalten basierend auf Verlagerungspräferenzen des Energiemanagers zurückgeführt werden. Dabei trat der Fall ein, dass nicht genügend Zeitschritte innerhalb eines Planungshorizonts vorhanden waren, in denen eine Lastsenkung durchzuführen war. Dann umfassten die einzelnen Verlagerungsangebote weniger Zeitschritte mit Laständerungen als tatsächlich durch die Parameterbelegung vorgegeben war. Dies stellt eine plausible Modellierung für die einzelnen Entitäten dar, weil diese durch eine zu umfangreiche Verlagerung die Zielabweichung erhöhen und somit die Chance auf eine Annahme ihres Angebots verschlechtern würden. Tatsächlich lieferten Simulationen, in denen die Anzahl der Zeitschritte mit Laständerung in den Angeboten nicht wie beschrieben beschränkt wurde, schlechtere Ergebnisse bezüglich der aggregierten Zielabweichung.

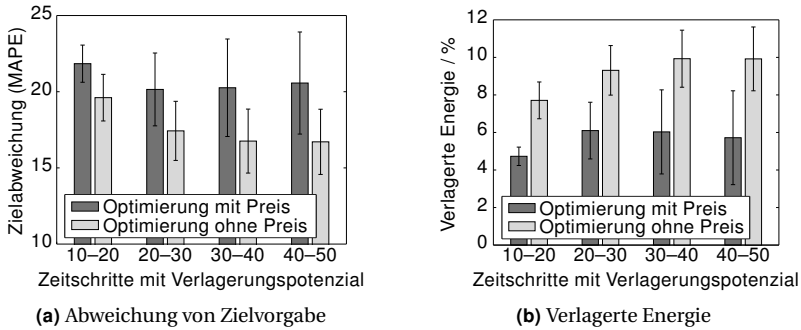


Abbildung 7.12 – Szenario 5: Zielabweichung und verlagerte Energie in Abhängigkeit des Verlagerungspotenzials. Die dunkelgrauen Balken repräsentieren Werte, die unter Berücksichtigung der Kosten bei der Optimierung ermittelt wurden. Demgegenüber wurden für die Werte, die durch hellgraue Balken veranschaulicht werden, die Kosten bei der Optimierung außer Acht gelassen. Die Balkenhöhen repräsentieren die Mittelwerte über 20 Simulationsläufe und die Antennen die zugehörigen Standardabweichungen.

Die ermittelten Werte für die durchschnittliche Zielabweichung und deren Standardabweichung sind in Abbildung 7.12a durch dunkelgraue Balken veranschaulicht. Während die Zielabweichung durch Parameterbelegung 2 gesenkt wurde, blieb sie danach trotz Erhöhung der Flexibilität annähernd konstant. Gleichzeitig stieg die Varianz der Zielabweichung, sodass einige der Simulationsläufe schlechtere Ergebnisse lieferten als das Basisszenario. Insbesondere gab es vereinzelte Läufe, in denen für Parameterbelegung 3 und 4 keine Lastverschiebung stattfand. Dies ist in Tabelle 7.5 anhand der Werte von 0 % in der Minimum-Spalte zu erkennen. Wie in Abbildung 7.12b dargestellt, wurde in den Simulationen mit Parameterbelegung 2 mehr Energie verschoben als in Simulationen mit Belegung 1. Danach nahm die verlagerte Energie mit steigender Flexibilität leicht ab.

Zusammenfassend ist festzustellen, dass die verlagerbare Energie mit zunehmender Anzahl von Zeitschritten, in denen Laständerungen möglich waren, bis zu einem gewissen Grad ebenfalls zunahm. Diese Zunahme des Potenzials führte aber nicht zwangsläufig zu einer höheren Verlagerung. Grund hierfür war nicht die fehlende Möglichkeit einer Annäherung an das Zielprofil. Es wäre möglich gewesen, kombinatorisch eine Teilmenge der Angebote auszuwählen, welche die Abweichung von dem vorgegebenen

Tabelle 7.5 – Simulationsergebnisse für Szenario 5. Es wurde die Anzahl z an Zeitschritten variiert, in denen Energie verlagerbar war. Die Werte in Standardschriftgröße repräsentieren Ergebnisse, die unter Berücksichtigung der Kosten bei der Optimierung entstanden. Der entsprechende Wert, welcher ohne Berücksichtigung der Kosten entstand, ist als Index aufgeführt. Eine Tilde zeigt an, dass beide Werte gleich sind. Die Zielabweichung im unoptimierten Betrieb war für alle betrachteten Fälle identisch.

Merkmal	Mittelwert	Std.abw.	Minimum	Maximum
<i>Alle Parameterbelegungen</i>				
Zielabw. unopt. (MAPE)	28,35 _~	0,78 _~	27,05 _~	29,76 _~
$z \in [10, 20]$				
Zielabw. opt. (MAPE)	21,84 _{19,61}	1,22 _{1,53}	19,95 _{17,62}	25,04 _{23,08}
Verlagerbare Energie (%)	9,92 _~	0,43 _~	9,13 _~	10,83 _~
Verlagerte Energie (%)	4,73 _{7,71}	0,49 _{0,98}	2,99 _{5,24}	5,32 _{9,05}
Kosten (Euro/Tag)	3,52 _{5,84}	0,35 _{0,74}	2,29 _{4,11}	3,89 _{6,76}
$z \in [20, 30]$				
Zielabw. opt. (MAPE)	20,15 _{17,43}	2,39 _{1,94}	17,27 _{14,13}	28,13 _{21,78}
Verlagerbare Energie (%)	15,36 _~	0,57 _~	14,04 _~	16,54 _~
Verlagerte Energie (%)	6,10 _{9,31}	1,51 _{1,32}	0,67 _{6,06}	7,28 _{11,39}
Kosten (Euro/Tag)	4,69 _{7,27}	1,18 _{1,01}	0,49 _{4,93}	5,77 _{8,93}
$z \in [30, 40]$				
Zielabw. opt. (MAPE)	20,26 _{16,76}	3,20 _{2,10}	15,74 _{12,53}	29,57 _{21,90}
Verlagerbare Energie (%)	19,50 _~	0,83 _~	17,68 _~	20,89 _~
Verlagerte Energie (%)	6,03 _{9,93}	2,24 _{1,52}	0,00 _{6,50}	8,26 _{12,45}
Kosten (Euro/Tag)	4,74 _{7,95}	1,80 _{1,21}	0,00 _{5,35}	6,66 _{10,02}
$z \in [40, 50]$				
Zielabw. opt. (MAPE)	20,57 _{16,71}	3,35 _{2,14}	16,42 _{13,56}	29,19 _{21,48}
Verlagerbare Energie (%)	20,79 _~	1,46 _~	19,06 _~	23,76 _~
Verlagerte Energie (%)	5,72 _{9,92}	2,50 _{1,70}	0,00 _{6,31}	8,93 _{12,59}
Kosten (Euro/Tag)	4,49 _{8,00}	2,02 _{1,38}	0,00 _{5,23}	7,10 _{10,17}

nen flachen Zielprofil reduziert hätte. Dies zeigen die Ergebnisse, welche in Abbildung 7.12b durch die hellgrauen Balken dargestellt werden. Hierfür wurde in der Optimierung ausschließlich die Zielabweichung berücksichtigt, indem in der Zielfunktion von Problem (P4) durch den Gewichtungsfaktor $w_1 = 0$ der Kostenanteil eliminiert wurde. Dadurch wurde bei identischen Ausgangsprofilen und Verlagerungsangeboten in allen Fällen eine höhere Nutzung des Flexibilitätspotenzials als im Standardfall für $w_1 = 1$ erreicht. Gleichzeitig wurde das Zielprofil besser angenähert. Die numerischen Werte sind in Tabelle 7.5 als Indizes an den korrespondierenden Werten für den Standardfall aufgeführt.

Dass die Zielabweichung trotz höherer Flexibilität nicht weiter reduziert werden konnte, ist dem Kompromiss zwischen dieser Abweichung und den Kosten geschuldet. Die gefundene Lösung repräsentiert einen solchen möglichen Kompromiss. Ein anderer, wenn auch extremer, Kompromiss wurde gefunden, indem die Kosten nicht berücksichtigt wurden. Aus einer Lösung alleine – und auch aus den beiden gezeigten Lösungen zusammen – kann das Spektrum an realisierbaren Kompromissen nicht hinreichend abgeschätzt werden. Diese Problemstellung wird im Rahmen der multikriteriellen Optimierung näher betrachtet.

7.1.6 Szenario 6: Erhöhte Lastflexibilität durch Erhöhung der Anzahl von Verlagerungsangeboten

Neben der Erhöhung der verlagerbaren Energiemenge stellt die Erhöhung der Anzahl von Verlagerungsangeboten eine weitere Möglichkeit dar, eine größere Lastflexibilität anzubieten. In Szenario 6 waren die Entitäten in der Lage, konkurrierende Angebote abzugeben, von denen maximal eines ausgewählt werden konnte. Die Anzahl der Angebote wird in Optimierungsproblem (P4) durch κ_n für $n = 1, \dots, N$ modelliert. Dieser Parameter wurde variiert, wobei für jede der N Entitäten derselbe Wert gewählt wurde. Alle anderen Parameter wurden analog zum Basisszenario gesetzt.

Die Ergebnisse der 20 Simulationsläufe sind in Tabelle 7.6 gelistet. Um einen direkten Vergleich zu erleichtern, wurden die Ergebnisse des Basisszenarios aus Tabelle 7.1 ($\kappa_n = 1$) ebenfalls aufgenommen. Zur Berechnung der verlagerbaren Energie wurde ein einziges Angebot für jede Entität herangezogen. Hierbei wurde das Angebot gewählt, welches die höchste verla-

Tabelle 7.6 – Simulationsergebnisse für Szenario 6. Es wurde die Anzahl κ_n von konkurrierenden Verlagerungsangeboten pro Entität variiert. Die Werte in Standardschriftgröße repräsentieren die Ergebnisse, die unter Berücksichtigung der Kosten bei der Optimierung entstanden. Der entsprechende Wert, welcher ohne Berücksichtigung der Kosten entstand, ist als Index aufgeführt. Eine Tilde zeigt an, dass beide Werte gleich sind. Die Zielabweichung im unoptimierten Betrieb war für alle betrachteten Fälle identisch.

Merkmal	Mittelwert	Std.abw.	Minimum	Maximum
$\kappa_n = 1, \dots, 4$				
Zielabw. unopt. (MAPE)	28,35 _~	0,78 _~	27,05 _~	29,76 _~
$\kappa_n = 1$				
Zielabw. opt. (MAPE)	21,84 _{19,61}	1,22 _{1,53}	19,95 _{17,62}	25,04 _{23,08}
Verlagerbare Energie (%)	9,92 _~	0,43 _~	9,13 _~	10,83 _~
Verlagerte Energie (%)	4,73 _{7,71}	0,49 _{0,98}	2,99 _{5,24}	5,32 _{9,05}
Kosten (Euro/Tag)	3,52 _{5,84}	0,35 _{0,74}	2,29 _{4,11}	3,89 _{6,76}
$\kappa_n = 2$				
Zielabw. opt. (MAPE)	21,01 _{17,62}	1,91 _{1,75}	19,10 _{14,77}	26,58 _{21,14}
Verlagerbare Energie (%)	11,42 _~	0,49 _~	10,08 _~	12,10 _~
Verlagerte Energie (%)	5,04 _{8,90}	1,12 _{1,01}	1,42 _{6,53}	6,00 _{10,38}
Kosten (Euro/Tag)	3,71 _{6,79}	0,84 _{0,76}	1,00 _{5,06}	4,44 _{7,97}
$\kappa_n = 3$				
Zielabw. opt. (MAPE)	20,45 _{16,60}	2,56 _{1,60}	17,85 _{14,22}	29,21 _{20,39}
Verlagerbare Energie (%)	12,45 _~	0,54 _~	11,39 _~	13,30 _~
Verlagerte Energie (%)	5,38 _{9,51}	1,53 _{1,03}	0,05 _{6,96}	6,60 _{10,99}
Kosten (Euro/Tag)	3,94 _{7,25}	1,12 _{0,78}	0,03 _{5,39}	4,78 _{8,41}
$\kappa_n = 4$				
Zielabw. opt. (MAPE)	20,15 _{16,13}	2,71 _{1,57}	17,41 _{12,92}	28,26 _{18,82}
Verlagerbare Energie (%)	12,85 _~	0,47 _~	11,93 _~	13,45 _~
Verlagerte Energie (%)	5,60 _{9,81}	1,64 _{0,90}	0,46 _{7,85}	6,77 _{11,23}
Kosten (Euro/Tag)	4,09 _{7,49}	1,20 _{0,65}	0,32 _{6,19}	4,85 _{8,40}

gerbare Gesamtenergiemenge umfasste. Alle konkurrierenden Angebote zu summieren liefert keine realistische Abschätzung des Verlagerungspotenzials, da maximal eine der Verlagerungen durchgeführt werden kann. Aus der Tabelle ist abzulesen, dass die verlagerbare Energie mit steigender Flexibilität leicht zunahm. Der Grund hierfür ist, dass die Wahrscheinlichkeit steigt, eine umfangreichere Verlagerung zu erzeugen, wenn sich die Anzahl von Angeboten erhöht. Da jeweils nur die maximale verlagerbare Energie einer Entität bei der Berechnung des Potenzials berücksichtigt wurde, hatten geringere verlagerbare Energiemengen keine Auswirkung.

Mit steigendem Flexibilitätspotenzial erhöhte sich auch die verlagerte Energiemenge leicht. Dies führte im Mittel zu einer abnehmenden Abweichung des aggregierten Leistungsprofils von der Zielvorgabe. Gleichzeitig nahm mit einer höheren Anzahl von Angeboten auch die Zahl der Entscheidungsvariablen des Optimierungsproblems zu. Bei gleichbleibender Zahl von Funktionsauswertungen des genetischen Algorithmus führte dies zu einer steigenden Varianz der Ergebnisse.

Ein Vergleich mit den Ergebnissen aus Szenario 5 zeigt, dass die Zielabweichungen nach der Optimierung ähnliche Werte annahmen. Hierfür musste in Szenario 6 jedoch weniger Energie verlagert werden. Demzufolge konnte die Flexibilität, die von einer höheren Zahl von Angeboten geringen Energieumfangs zur Verfügung gestellt wurde, effizienter genutzt werden als eine kleinere Zahl von Angeboten hohen Umfangs. Analog zu Tabelle 7.5 sind in Tabelle 7.6 die Ergebnisse einer Optimierung ohne Berücksichtigung der Kosten eingetragen. Diese zeigen die minimale Zielabweichung auf, die mittels der Verlagerungsangebote umsetzbar war. Auch hier sind die Mittelwerte der entsprechenden Abschnitte der beiden Tabellen vergleichbar. Wie bei der Optimierung mit Kostenberücksichtigung musste in Szenario 6 weniger Energie verlagert werden. Während die Werte im Mittel vergleichbar sind, waren die Varianzen in Szenario 6 kleiner. Dies spricht für eine zuverlässigere Nutzbarkeit der Flexibilitäten.

7.1.7 Szenario 7: Multikriterielle Optimierung

Wie in den vorhergehenden Szenarien festgestellt wurde, kann anhand einer einzigen Lösung des skalaren Optimierungsproblems keine Aussage bezüglich des Spektrums an möglichen Kompromissen zwischen Zielab-




Abbildung 7.13 – Szenario 7: Finale Populationen der genetischen Algorithmen \mathcal{A}_{SO} und \mathcal{A}_{MO} für skalare und multikriterielle Optimierung. Wie in Abschnitt 6.4 dargestellt, beschreibt Zielfunktion f_1 die Kosten einer Lösung und f_2 die Summe der quadratischen Abweichungen zwischen erzeugtem Leistungsprofil und Zielprofil. Durch blaue Quadrate dargestellte Lösungen sind das Resultat skalarer Optimierung ohne Berücksichtigung der Kosten. Die besten Lösungen der skalaren Probleme und das mittels TOPSIS ausgewählte Element der nicht-dominierten Menge sind Rot abgebildet.

weichung und Kosten getroffen werden. Daher wurde in Szenario 7 zur Umsetzung einer flexiblen Leistungsführung eine multikriterielle Optimierung des Problems (P6) mittels Algorithmus \mathcal{A}_{MO} (siehe Abschnitt 6.6.2) vorgenommen. Hierbei blieb jedoch die Erzeugungsseite noch unberücksichtigt, sodass die entsprechenden Terme in Problem (P6) entfielen. Es wurde erneut die Parameterbelegung des Basisszenarios zugrunde gelegt. Insbesondere umfasste eine Population des genetischen Algorithmus weiterhin 60 Individuen bei einem Abbruchkriterium von 6000 Funktionsevaluationen. Ferner konnten die Entitäten maximal ein Verlagerungsangebot abgeben ($\kappa_n = 1$, $n = 1, \dots, N$), welches 10–20 Zeitschritte mit einer Lastreduzierung und der dazugehörigen Anzahl von Lasterhöhungen umfasste.

Die Ergebnisse der multikriteriellen Optimierung in Form der nicht-dominierten Menge der letzten Population waren für alle 20 Simulationsläufe vergleichbar. Eine aggregierte grafische Darstellung für alle Läufe ist bedeutungslos, da in den Läufen verschiedene Probleminstanzen gelöst wurden. Daher werden in Abbildung 7.13 die gefundenen Lösungen im Zielraum für zwei repräsentative Simulationsläufe gezeigt. Darüber hinaus sind die

finalen Populationen der skalaren Optimierung aus Szenario 1 für die korrespondierenden Läufe ebenfalls dargestellt. Diese können verglichen werden, da aufgrund der Initialisierung des Pseudozufallszahlengenerators für beide Szenarien die gleichen unoptimierten Leistungsprofile und die gleichen Verlagerungsangebote generiert wurden. Daher waren die gleichen Probleminstanzen in den entsprechenden Simulationsläufen zu lösen. Des Weiteren sind in Abbildung 7.13 die Ergebnisse einer Optimierung der skalaren Probleminstanzen ohne Berücksichtigung der Kosten dargestellt. Wie in Szenario 5 beschrieben, wurde hierfür in der Zielfunktion von Problem (P4) der Kostenanteil durch den Gewichtungsfaktor $w_1 = 0$ beseitigt.

Die finalen Populationen der multikriteriellen Optimierung umfassten, wie anhand von Abbildung 7.13 deutlich wird, ausschließlich nicht-dominierte Lösungen. Diese zeigten ein breites Spektrum an Trade-offs auf: von günstigeren Lösungen mit einer höheren Zielabweichung bis hin zu teureren Lösungen mit einer geringeren Zielabweichung. Im Vergleich dazu beschränkten sich die Lösungen der skalaren Optimierung auf einen kleinen Bereich des Zielraums. Die meisten dieser Lösungen standen in keinem Dominanzverhältnis zu den multikriteriellen Lösungen. Eine eindeutige Bevorzugung war somit nicht möglich. Die Lösungen der skalaren Optimierung unter Berücksichtigung der Kosten reihten sich in die Front der multikriteriellen Lösungen ein. Im Gegensatz hierzu wurden ohne Berücksichtigung der Kosten Lösungen gefunden, welche die Front erweiterten. Diese lieferten zwar geringfügig niedrigere Zielabweichungen, verlagerten jedoch mehr Energie und führten dadurch zu höheren Kosten.

Nach Abschluss einer multikriteriellen Optimierung muss die Entscheidung getroffen werden, welche Lösung umgesetzt wird. Sofern kein Entscheidungsträger die Auswahl manuell trifft, muss diese automatisiert erfolgen. Dafür kann beispielsweise das in Abschnitt 6.6.4 beschriebene TOPSIS-Verfahren eingesetzt werden. Die damit in 20 Simulationsläufen erzielten Ergebnisse sind in Tabelle 7.7 zusammen mit den Ergebnissen der skalaren Optimierung aufgeführt. Im Mittel zeigen die durch TOPSIS ausgewählten Lösungen eine höhere Abweichung von der Ziellast, sind aber günstiger. Aufgrund der leicht gebogenen und gleichmäßigen Form der Fronten weisen die Elemente in der Nähe der Mitte den geringsten Abstand zur Ideallösung auf und werden daher gewählt. Lösungen der skalaren Probleme liegen dagegen weiter in Richtung der geringeren Zielabweichung auf den Fronten.

Tabelle 7.7 – Simulationsergebnisse für Szenario 7. Die Werte ergeben sich bei Umsetzung der Lösung, welche durch TOPSIS ausgewählt wurde. Die korrespondierenden Werte der skalaren Optimierung aus Szenario 1 sind als Indizes aufgeführt. Eine Tilde zeigt identische Werte an.

Merkmal	Mittelwert	Std.abw.	Minimum	Maximum
Zielabw. unopt. (MAPE)	28,35 _~	0,78 _~	27,05 _~	29,76 _~
Zielabw. opt. (MAPE)	23,82 _{21,84}	1,25 _{1,22}	22,21 _{19,95}	26,55 _{25,04}
Verlagerbare Energie (%)	9,92 _~	0,43 _~	9,13 _~	10,83 _~
Verlagerte Energie (%)	2,90 _{4,73}	0,58 _{0,49}	1,64 _{2,99}	4,29 _{5,32}
Kosten (Euro/Tag)	2,14 _{3,52}	0,43 _{0,35}	1,22 _{2,29}	3,18 _{3,89}

Dieser Sachverhalt kann nicht a priori aus der Gewichtung der Teilziele bei der skalaren Optimierung geschlossen werden. Um einen Überblick über die Entscheidungsalternativen zu gewinnen, müssten mehrere Optimierungsläufe für das skalare Problem mit verschiedenen Teilzielgewichtungen ausgeführt werden. Hier liegt der Vorteil der multikriteriellen Optimierung. Nach einem Optimierungslauf steht bereits eine breite Entscheidungsbasis zur Verfügung. Falls nötig, kann dafür in Schritt 2 des TOPSIS-Verfahrens a posteriori eine Gewichtung der Teilziele vorgenommen werden. Somit sind die Werte in Tabelle 7.7 lediglich als eine von vielen Entscheidungsmöglichkeiten zu verstehen.

7.2 Last- und Erzeugungsmanagement-Szenarien

Die Lastmanagement-Szenarien haben aufgezeigt, dass das Flexibilitätspotenzial von Verbrauchern für eine fahrplanbasierte flexible Leistungsführung genutzt werden kann. Aufgrund der starren kombinatorischen Angebote konnte das Zielprofil jedoch nur eingeschränkt approximiert werden. Daher werden im Folgenden zusätzlich zu den bereits betrachteten Haushalten Photovoltaik-Anlagen stellvertretend für Erzeuger in das Energiemanagement eingebunden. Diese stellen, wie in Abschnitt 3.2.2 dargelegt, ein höheres Flexibilitätspotenzial zur Verfügung. In den Leistungsflussberechnungen gehört jede Photovoltaik-Anlage physikalisch zu einem Haushalt. Für die Optimierung gelten Erzeuger dagegen als eigenständige Entitäten, deren Angebote unabhängig von den Angeboten der Haushalte sind.

7.2.1 Szenario 8: Basisszenario für das Last- und Erzeugungsmanagement

Analog zum Basisszenario für das Lastmanagement wurde ein Szenario für das Last- und Erzeugungsmanagement definiert, welches als Basis der folgenden Szenarien dient. Hierfür wurde weiterhin das Stromnetz zugrunde gelegt, das in Abschnitt 3.3 beschrieben wurde. Neben den Haushalten wurden die 20 Photovoltaik-Analgen betrachtet, die in Abbildung 3.6 auf Seite 55 durch Doppelkreuze angezeigt werden. Die weiteren Parameter orientierten sich ebenfalls an Szenario 1. Als Zielvorgabe wurden flache Leistungsprofile gewählt, deren Wert der mittleren prädierten Leistung aller Entitäten im Planungshorizont entsprach. Der Planungshorizont von 24 Stunden und die Flexibilität der Haushalte, Energie in 10–20 Zeitschritten zu verlagern, wurden beibehalten. Ebenso gaben Haushalte weiterhin maximal ein Verlagerungsangebot pro Planungshorizont ab. Die Einspeisung der Photovoltaik-Anlagen wurde als vollständig drosselbar angenommen.

Um die flexible Leistungsführung umzusetzen, wurde Optimierungsproblem (P5) mittels Algorithmus \mathcal{A}_{SO} (siehe Kapitel 6.6.2) gelöst. Dabei wurden die Zielfunktionen für Zielabweichung und für Kosten mit $w_1 = w_2 = 1$ gleich gewichtet. Die beiden Nebenbedingungen bezüglich der Änderungsgeschwindigkeit der Leistung entfielen, da Photovoltaik-Anlagen diesen physikalischen Restriktionen nicht unterliegen.

Angesichts der gestiegenen Anzahl von Entscheidungsvariablen wurde erneut eine Parameterstudie bezüglich Populationsgröße und Abbruchkriterium des genetischen Algorithmus durchgeführt. Die beste gefundene Lösung in Abhängigkeit der Generation ist in Abbildung 7.14 für mehrere Populationsgrößen dargestellt. Ab etwa Generation 100 waren nur noch geringe Verbesserungen feststellbar. Ferner führten die beiden größten betrachteten Populationen von 200 und 250 Individuen zu ähnlichen Ergebnissen. Aus diesen Gründen wurde für den genetischen Algorithmus eine Populationsgröße von 200 Individuen gewählt mit einem Abbruch nach 20000 Funktionsevaluationen.

Die aggregierten Leistungsprofile für Szenario 8 im unoptimierten und im optimierten Betrieb sind in Abbildung 7.15a dargestellt. Darin ist zu erkennen, dass die Leistungsspitzen durch die Optimierung deutlich reduziert wurden und sich das Leistungsprofil dem flachen Zielprofil annäherte.

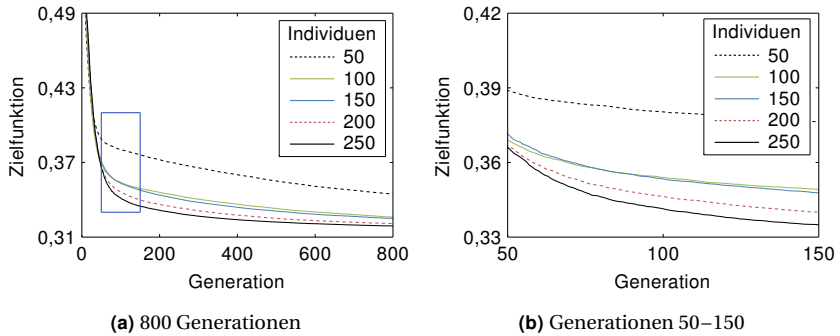


Abbildung 7.14 – Szenario 8: Beste Lösung (Mittelwert über 20 Simulationsläufe) in Abhängigkeit der Generationen des genetischen Algorithmus für verschiedene Populationsgrößen. Die Zielfunktion ist normiert. Der in Teilabbildung (b) gezeigte Ausschnitt ist durch ein Rechteck in (a) markiert.

Insbesondere wenn Solarenergie zur Verfügung stand, konnte die hohe Flexibilität der entsprechenden Entitäten genutzt werden, um eine gute Annäherung an die Zielvorgabe zu erreichen. Der Energieverbrauch der Morgen- und Abendstunden wurde zum Teil in die Mittags- und Nachmittagszeit verschoben, um die zur Verfügung stehende Erzeugung zu nutzen. Aufgrund der geringeren Flexibilität der Verbraucher konnten die Morgen- und Abendspitzen nicht so stark gesenkt werden wie die Mittagsspitzen. Die Verbesserung der Approximation des Zielprofils in Abhängigkeit der Zeit wird durch die grüne Kurve in Abbildung 7.15b dargestellt. Dies bestätigt die deutliche Reduzierung der Zielabweichung zwischen 10 und 18 Uhr.

Im simulierten Zeitraum von 24 Stunden erzeugten die Photovoltaik-Anlagen im Schnitt pro Simulationslauf 356 kWh Energie im unoptimierten Betrieb. Der Energieverbrauch betrug im selben Zeitraum 725 kWh. Nach Abzug des Eigenverbrauchs der Haushalte wurden insgesamt 932 kWh umgesetzt, d. h. entweder erzeugt oder verbraucht. Hiervon waren, wie in Tabelle 7.8 abzulesen ist, 45,42 % flexibel im Rahmen der Angebote. Dazu gehörte sowohl die drosselbare Erzeugung als auch der verlagerbare Verbrauch. Durch Optimierung wurden 7,11 % der umgesetzten Energiemenge verlagert, was 66 kWh entspricht. Gleichzeitig wurde die Einspeisung um 110 kWh, bzw. 11,80 % der umgesetzten Energiemenge, gedrosselt.

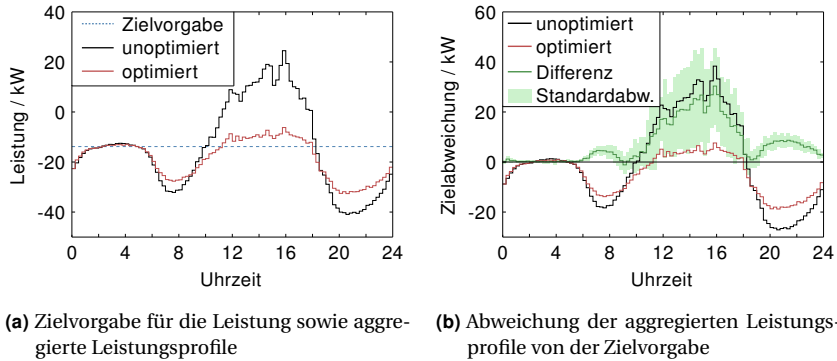


Abbildung 7.15 – Szenario 8: Aggregierte Leistungsprofile im unoptimierten und optimierten Betrieb sowie Abweichung dieser Profile von der Zielvorgabe. Negative Abweichungen treten auf, wenn die aggregierte Leistung kleiner als die Zielleistung ist. Die dunkelgrüne Kurve bildet die Differenz zwischen den Beträgen der Abweichungen im unoptimierten und im optimierten Fall ab. Positive Werte entsprechen dabei einer geringeren Zielabweichung im optimierten Fall. Bis auf die in Hellgrün dargestellte Standardabweichung bilden die Kurven Mittelwerte über alle Simulationsläufe ab.

In Szenario 1 wies die Abweichung von der Zielvorgabe im unoptimierten Betrieb gemessen im MAPE einen Wert von 28,35 % auf. Diese Abweichung stieg in Szenario 8 auf 115,07 %. Durch die Einspeisung der Photovoltaik-Anlagen kam es tagsüber zu hohen positiven Abweichungen vom Zielprofil, während morgens und abends hohe negative Spitzen auftraten. Im Mittel stieg daher die Abweichung stark. Nach der Optimierung sank die Abweichung auf 58,51 %, was einer Reduktion von 49,15 % im Vergleich zum unoptimierten Wert entspricht. Im Vergleich dazu betrug die Reduktion der Abweichung im ersten Szenario 22,96 %. Diese Werte verdeutlichen, dass Erzeugungsmanagement das Flexibilitätspotenzial deutlich steigerte.

Vor dem Hintergrund einer Optimierung der Teilziele Abweichung und Kosten ist eine Lösung lediglich als einer der vielen möglichen Kompromisse anzusehen. In der Regel können sowohl Lösungen erzeugt werden, die eine niedrigere Zielabweichung aufweisen, als auch Lösungen mit geringeren Kosten. Diese Aspekte werden im nächsten Szenario betrachtet.

Im simulierten Niederspannungsnetz traten in Szenario 8 weder im unoptimierten noch im optimierten Betrieb Netzengpässe auf. Die maximale

Tabelle 7.8 – Simulationsergebnisse für Szenario 8. Die Prozentangaben beziehen sich auf die Energie, die abzüglich Eigenverbrauch im unoptimierten Betrieb insgesamt umgesetzt wurde.

Merkmal	Mittelwert	Std.abw.	Minimum	Maximum
Zielabw. unopt. (MAPE)	115,07	24,86	76,64	156,90
Zielabw. opt. (MAPE)	58,51	14,24	34,97	81,18
Flexible Energie (%)	45,42	3,55	39,48	51,75
Verlagerter Verbrauch (%)	7,11	0,49	6,31	8,47
Gedrosselte Erzeugung (%)	11,80	1,30	9,32	14,42
Kosten (Euro/Tag)	23,56	2,69	19,88	28,39

Spannungserhöhung im Vergleich zur Nennspannung betrug 1,24 % und die maximale Spannungsabsenkung 0,87 %. Die Stromstärke überschritt 30A nicht und lag damit unter dem maximal zulässigen Wert von 142A.

7.2.2 Szenario 9: Präferenzbasierte multikriterielle Optimierung

In Szenario 9 wurde das Last- und Erzeugungsmanagement unter dem Gesichtspunkt einer multikriteriellen Optimierung, die Präferenzen a priori einbezieht, analysiert. Die betrachteten Präferenzen begrenzten die akzeptierten Trade-offs zwischen Lösungen, wobei das Konzept der Geoffrion-*M*-eigentlichen Pareto-Optimalität (siehe Kapitel 6.5.4) genutzt wurde.

Zunächst wird ein Vergleich angestellt zwischen der skalaren Optimierung in Szenario 8 und einer multikriteriellen Optimierung. Hierzu wurde das multikriterielle Problem (P6) mittels Algorithmus \mathcal{A}_{MO} gelöst. Beide Algorithmen wurden in den entsprechenden Simulationsläufen mit den gleichen Leistungsprofilen sowie Angeboten der Entitäten gestartet. Die Ausgabe des multikriteriellen Algorithmus, d. h. die nicht-dominierte Menge der finalen Population, ist zusammen mit der finalen Population der skalaren Optimierung für zwei Simulationsläufe in Abbildung 7.16 zu sehen. Die gezeigten Läufe sind repräsentativ für alle durchgeführten Simulationsläufe. Die beste Lösung des skalaren Problems wurde zum Teil durch Lösungen des multikriteriellen Problems dominiert (siehe Abbildung 7.16a für Lauf 1). In den anderen Läufen konnte die Lösung in die Front der nicht-dominierten Lösungen eingereiht werden (siehe Abbildung 7.16b für Lauf 2).

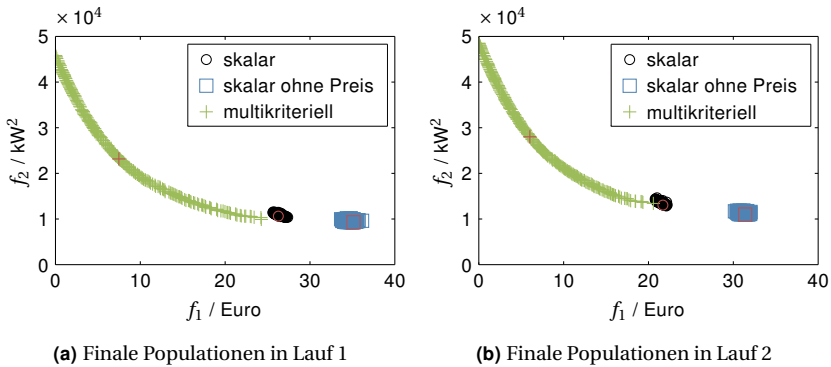


Abbildung 7.16 – Szenario 9: Finale Populationen der genetischen Algorithmen \mathcal{A}_{SO} bzw. \mathcal{A}_{MO} für die skalare bzw. die multikriterielle Optimierung. Zielfunktion f_1 beschreibt die Kosten einer Lösung und f_2 die Summe der quadratischen Abweichungen zwischen erzeugtem Leistungsprofil und Zielprofil. Blaue Quadrate stellen Lösungen der skalaren Optimierung ohne Berücksichtigung der Kosten dar. Die besten Lösungen der skalaren Probleme und das mittels TOPSIS ausgewählte Element der nicht-dominierten Menge sind Rot abgebildet.


In Szenario 7 befanden sich die Lösungen der skalaren Optimierung unter Berücksichtigung der Kosten im Inneren der Front der Lösungen des multikriteriellen Problems. Im Unterschied dazu lagen die Lösungen des skalaren Problems in Szenario 9 am Rand. Weiter außerhalb der Front lagen die Lösungen der skalaren Optimierung ohne Berücksichtigung des Preises, d. h. der Minimierung der Funktion f_2 . Diese Lösungen führten zu einer geringfügigen Reduzierung der Zielabweichung, jedoch zu einer deutlichen Zunahme der Kosten. In diesem Bereich des Zielraums fand der multikriterielle Algorithmus keine Lösungen und konnte somit nicht das vollständige Spektrum an Entscheidungsmöglichkeiten aufzeigen. Sofern a priori die Präferenz, dass die Zielabweichung egal zu welchem Preis zu minimieren ist, eindeutig bekannt gewesen wäre, hätten durch eine skalare Optimierung bessere Ergebnisse erzielt werden können.

Wie in Abbildung 7.16 zu erkennen ist, liegt die durch TOPSIS ausgewählte Lösung des multikriteriellen Problems in einem Bereich der Lösungsfront, der eine hohe Steigung aufweist. Durch Akzeptieren einer kleinen Kostensteigerung könnte dort eine verhältnismäßig starke Senkung der Zielabweichung erzielt werden.


weichung erreicht werden. Solche Trade-offs können in Algorithmus \mathcal{A}_{PMO} (siehe Kapitel 6.6.3) durch den Parameter M beschränkt werden. Entsprechend Ungleichung (6.2) auf Seite 104 wird dadurch die Verschlechterung begrenzt, die für eines der Teilziele akzeptiert wird entgegen einer Verbesserung in einem anderen Teilziel. Es ist zu beachten, dass hierfür die normierten Zielfunktionen herangezogen werden.

Abbildung 7.17 zeigt die Geoffrion- M -eigentlich Pareto-optimalen Lösungen für die Parameterwerte $M = 1,5$ und $M = 2,5$. Hierbei wurden die Probleminstanzen optimiert, deren Ergebnisse in Abbildung 7.16 dargestellt sind. Die grünen Fronten der korrespondierenden Simulationsläufe sind somit identisch. In den Abbildungen 7.17a und 7.17b werden die Ergebnisse im ursprünglichen dimensionsbehafteten Zielraum gezeigt. Es ist erkennbar, dass die Lösungen von Algorithmus \mathcal{A}_{PMO} mit kleiner werdendem M -Wert die Front weiter eingrenzten. Dieser M -Wert beschränkt in Ungleichung (6.2) den Betrag des Differenzenquotienten, der geometrisch die Steigung der Sekante durch zwei Punkte der Lösungsfront darstellt. Falls eine Sekante durch zwei Punkte einer Front existiert, deren Steigung vom Betrag größer ist als M , ist mindestens einer der beiden Punkte nicht Geoffrion- M -eigentlich Pareto-optimal. Anschaulich muss in zweidimensionalen Zielräumen diese Aussage laut Definition der Geoffrion- M -eigentlichen Pareto-Optimalität unabhängig davon gelten, welches Teilziel auf der Abszissenachse und welches auf der Ordinatenachse aufgetragen wird. Insbesondere gilt die Beschränkung der Steigung also bei Vertauschen der Achsen.


Da die Teilziele normalisiert werden müssen, um Trade-offs zu berechnen, werden die Ergebnisse der zwei Simulationsläufe in den Abbildungen 7.17c und 7.17d in normalisierten Koordinatensystemen dargestellt. Darin ist besser zu erkennen, dass die Lösungen von Algorithmus \mathcal{A}_{PMO} tatsächlich in dem Bereich der Front liegen, in dem die Sekantensteigungen am geringsten sind. Für die Normalisierung der Kosten wurde 0 Euro als Minimum gesetzt, welches bei Ablehnung aller Angebote auftritt. Das entsprechende Maximum bildete die Summe der Preise aller Angebote. Für die Ermittlung der minimalen und maximalen Werte der Zielabweichung wurde Algorithmus \mathcal{A}_{SO} genutzt, wobei in der Zielfunktion ausschließlich die Abweichung berücksichtigt wurde und die Netzrestriktionen unbeachtet blieben. Bei einer Populationsgröße von 200 Individuen wurde der Algorithmus nach 220 000 Funktionsevaluationen beendet.




(a) Finale Populationen in Lauf 1



(b) Finale Populationen in Lauf 2



(c) Normalisierte Werte in Lauf 1



(d) Normalisierte Werte in Lauf 1

Abbildung 7.17 – Szenario 9: Finale Populationen der genetischen Algorithmen \mathcal{A}_{MO} bzw. \mathcal{A}_{PMO} für die multi-kriterielle bzw. die präferenzbasierte multi-kriterielle Optimierung. In den Teilabbildungen (a) und (b) werden die Lösungen von 2 Simulationsläufen im ursprünglichen Koordinatensystem gezeigt. In (c) und (d) sind die entsprechenden Lösungen im normalisierten, dimensionslosen Koordinatensystem abgebildet. Die Zielfunktion f_1 beschreibt die Kosten einer Lösung und f_2 die Summe der quadratischen Abweichungen zwischen erzeugtem Leistungsprofil und Zielprofil. Die mittels TOPSIS ausgewählten Elemente der nicht-dominierten Mengen sind Rot dargestellt.

Tabelle 7.9 – Simulationsergebnisse für Szenario 9 für die TOPSIS-Lösungen der Algorithmen \mathcal{A}_{MO} und \mathcal{A}_{PMO} . Die Prozentangaben beziehen sich auf die Energie, welche abzüglich Eigenverbrauch im unoptimierten Betrieb insgesamt umgesetzt wurde.

Merkmal	Mittelwert	Std.abw.	Minimum	Maximum
\mathcal{A}_{MO} und \mathcal{A}_{PMO}				
Zielabw. unopt. (MAPE)	115,07	24,86	76,64	156,90
Flexible Energie (%)	45,42	3,55	39,48	51,75
\mathcal{A}_{MO}				
Zielabw. opt. (MAPE)	87,35	18,56	58,60	117,75
Verlagerter Verbrauch (%)	5,39	0,78	4,10	6,61
Gedrosselte Erzeugung (%)	0,27	0,25	0,00	0,71
Kosten (Euro/Tag)	5,67	1,13	3,91	7,85
$\mathcal{A}_{PMO}, M = 2,5$				
Zielabw. opt. (MAPE)	64,36	15,84	38,61	90,91
Verlagerter Verbrauch (%)	7,12	0,50	6,40	8,34
Gedrosselte Erzeugung (%)	6,24	1,33	3,69	8,26
Kosten (Euro/Tag)	15,78	2,23	12,36	19,24
$\mathcal{A}_{PMO}, M = 1,5$				
Zielabw. opt. (MAPE)	63,14	15,44	38,15	89,28
Verlagerter Verbrauch (%)	7,13	0,44	6,52	8,13
Gedrosselte Erzeugung (%)	6,91	1,51	3,88	9,79
Kosten (Euro/Tag)	16,78	2,41	12,90	20,80

Abbildung 7.17 zeigt, dass die Lösungen von Algorithmus \mathcal{A}_{PMO} für die betrachteten M -Werte in anderen Bereichen der Front angesiedelt sind als die durch das TOPSIS-Verfahren selektierte Lösung von Algorithmus \mathcal{A}_{MO} . Dieser Bereich wird für größere M erreicht. Die Lösungen von \mathcal{A}_{PMO} , die durch TOPSIS ausgewählt wurden, wiesen eine geringere Zielabweichung und höhere Kosten auf. Die entsprechenden Werte sind in Tabelle 7.9 zu finden. Da nach Beenden der multikriteriellen Optimierung eine Menge von nicht-dominierten Lösungen zur Verfügung stand, repräsentieren die Ergebnisse in der Tabelle nur eine der möglichen Lösungen.

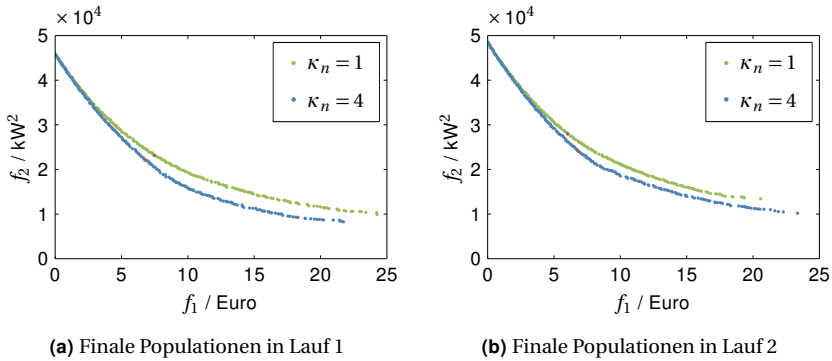


Abbildung 7.18 – Szenario 10: Finale Populationen des Algorithmus \mathcal{A}_{MO} für zwei Simulationsläufe mit jeweils zwei Werten der Parameter κ_n , welche die Anzahl konkurrierender Angebote je Haushalt bestimmen. Die Zielfunktion f_1 beschreibt die Kosten einer Lösung und f_2 die Summe der quadratischen Abweichungen zwischen erzeugtem Leistungsprofil und Zielprofil. Mittels TOPSIS ausgewählte Elemente der nicht-dominierten Mengen sind Rot dargestellt.

7.2.3 Szenario 10: Multikriterielle Optimierung bei erhöhter Lastflexibilität

In Anknüpfung an die Betrachtungen zur erhöhten Lastflexibilität in Szenario 6 und das multikriterielle Energiemanagement in Szenario 9 wurden in Szenario 10 beide Aspekte zusammen untersucht. Hierzu wurde erneut eine multikriterielle Optimierung von Problem (P6) mit Algorithmus \mathcal{A}_{MO} durchgeführt. Dabei wurden zwei verschiedene Werte für die Parameter κ_n ($n = 1, \dots, N$) betrachtet, welche die Anzahl der konkurrierenden Angebote je Entität bestimmen.

Die finalen Populationen des Algorithmus sind für zwei Simulationsläufe in Abbildung 7.18 für $\kappa_n = 1$ und $\kappa_n = 4$ gegenübergestellt. Da die gleiche Belegung der Simulationsparameter wie in Szenario 9 gewählt wurde, entsprechen die Lösungen für $\kappa_n = 1$ denen in Szenario 9. Die Abbildung zeigt die beiden gleichen Läufe wie in Szenario 9. Die Ergebnisse – auch für alle anderen Simulationsläufe – bestätigen, dass höhere Lastflexibilität auch in Verbindung mit Erzeugungsmanagement nutzbar ist. Ersichtlich ist dies daran, dass die Lösungen für $\kappa_n = 4$ die Lösungen für $\kappa_n = 1$ dominieren. Daher ist es möglich, bei gleicher Zielabweichung günstigere Lösungen zu finden. Umgekehrt kann für denselben Preis eine geringere Zielabweichung

erreicht werden, wenn eine höhere Lastflexibilität zur Verfügung steht. Ferner waren durch Steigerung der Anzahl von Verlagerungsangeboten geringere Zielabweichungen umsetzbar. Zu erkennen ist dies daran, dass bei einer Projektion auf die f_2 -Achse das minimale Element der blauen Lösungsmenge einen kleineren Wert aufweist als das minimale Element der grünen Menge.

7.3 Diskussion

Im Folgenden werden die Grundgedanken der verschiedenen Szenarien aufgegriffen und in einen gemeinsamen Zusammenhang gebracht. Hierbei werden die wichtigsten Ergebnisse zusammengefasst.

7.3.1 Flexibilität

In den vorgestellten Szenarien wurde eine fahrplanbasierte flexible Leistungsführung in zwei Schritten untersucht. Im ersten Schritt wurde die Zielleistungskurve mit Hilfe des zur Verfügung stehenden flexiblen Verbrauchs angenähert. Als Verbraucher wurden einzelne Haushalte simuliert. Wie in Abschnitt 2.2.2 erörtert, besitzt deren Lastflexibilität einen diskreten Charakter [49]. Es kann daher nicht vorausgesetzt werden, dass Haushalte, die weder Speicher noch Erzeugungsanlagen besitzen, kontinuierliche Verlagerungen anbieten. Aus diesem Grund wurden Verlagerungsangebote, wie in Abschnitt 3.1.1 beschrieben, als Menge diskreter Leistungsänderungen über einem Planungshorizont modelliert. In den kombinatorischen Optimierungsproblemen, die in Kapitel 6 formuliert wurden, gehen die Verlagerungsangebote der Haushalte durch binäre Entscheidungsvariablen ein. Demzufolge kann ein Angebot entweder als Ganzes angenommen oder abgelehnt werden.

Die kombinatorischen Eigenschaften beeinflussen die Qualität der Approximation einer Zielfunktion. Zwar wurde in allen untersuchten Szenarien im Vergleich zum unoptimierten Betrieb eine deutliche Annäherung an die Zielvorgabe umgesetzt, jedoch war ein exaktes Nachfahren des Zielprofils nicht möglich. Hierfür war die Angebotsstruktur nicht ausreichend flexibel. Daher wurden zwei Möglichkeiten der Flexibilitätssteigerung untersucht. Zum einen wurde die Anzahl der Zeitschritte erhöht, in denen

Verlagerungsangebote eine Leistungsänderung beinhalteten. Dies führte zu einer Erhöhung der Menge verlagerbarer Energie sowie zu einer Verbesserung der Zielapproximation. Gleichzeitig stiegen die Kosten für die Umsetzung, da mehr Energie verlagert wurde. Eine solche Art von Angeboten kann von Haushalten generiert werden, die Verbraucher mit einem thermischen Speicher aufweisen. Dieser muss, wie beispielsweise bei Gefrierschränken, Klimaanlage oder Wärmepumpen, permanent innerhalb eines spezifischen Temperaturintervalls gehalten werden, sodass über einen längeren Zeitraum Energieverlagerungen möglich sind. Zum anderen wurde es jeder Entität ermöglicht, mehrere konkurrierende Angebote abzugeben. Solche Angebote können von Haushalten erstellt werden, die alternative Einplanungen von Geräten vornehmen. Aufgrund des gleichbleibenden Energieumfangs der Angebote blieb die insgesamt verlagerbare Energiemenge im Vergleich zum Basisszenario konstant. Diese konnte jedoch flexibler eingesetzt werden, sodass die Zielabweichung unter geringen Mehrkosten reduziert wurde.

Im zweiten Schritt wurden neben Verbrauchern auch Erzeuger im Energiemanagement eingesetzt. In den betrachteten Szenarien wurden hierfür Photovoltaik-Anlagen simuliert. Deren Flexibilität weist eine andere Struktur auf als die kombinatorischen Angebote der Haushalte. Zum einen nehmen die zugehörigen Entscheidungsvariablen des Optimierungsproblems kontinuierliche Werte an und zum anderen kann die Einspeisung adaptiert werden. Aus diesen Gründen war in den Zeitschritten, für die solche Angebote zur Verfügung standen, eine genauere Approximation des Zielprofils möglich. Die Optimierungsprobleme wurden so allgemein formuliert, dass auch andere Erzeuger, wie beispielsweise Blockheizkraftwerke, erfasst werden können.

7.3.2 Optimierung

Eine zentrale Rolle bei der Betrachtung der flexiblen Leistungsführung spielen die Optimierungskriterien. In dieser Arbeit wurden dafür die Kosten für die in Anspruch genommenen Angebote einerseits und die Abweichung von der Zielvorgabe andererseits gewählt. In den vorgestellten Szenarien lag das Hauptaugenmerk auf einer Minimierung beider Teilziele. Da eine Reduzierung der Zielabweichung normalerweise mit einer Erhöhung der

Leistungsänderungen und damit einer Erhöhung der Kosten verbunden ist, widersprechen sich die Kriterien. Daher stellt eine Lösung des Optimierungsproblems einen Kompromiss zwischen den beiden Teilzielen dar. Neben der gleichzeitigen Optimierung der Teilziele ist es mit dem vorgestellten Energiemanagement-Ansatz auch möglich, nur die Zielabweichung zu minimieren, falls dies im Anwendungsfall gefordert ist.

Um zu einer Lösung oder einer Menge von Lösungen zu gelangen, wurden zwei alternative Vorgehensweisen untersucht. Eine dieser Vorgehensweisen bestand aus dem Zusammenfassen der Teilziele in einer skalaren Zielfunktion, wobei eine Gewichtung vorgegeben werden konnte. Die andere Vorgehensweise umfasste eine multikriterielle Optimierung. Während Lösungen eines skalaren Problems anhand der eindimensionalen Zielfunktion geordnet werden können, ist dies für mehrdimensionale Zielräume nicht mehr möglich. In diesem Fall existieren Lösungen, die nicht miteinander vergleichbar sind.

Die Optimierung wurde mittels verschiedener genetischer Algorithmen durchgeführt. Diese gehören der Klasse der stochastischen Metaheuristiken an. Eine wichtige Eigenschaft dieser Algorithmen ist das populationsbasierte Vorgehen. Dies bedeutet, dass die Algorithmen auf einer Menge von Lösungen operieren und demzufolge eine Lösungsmenge ausgeben. Obwohl genetische Algorithmen zur skalaren Optimierung mehrere Lösungen ermitteln, kann daraus die Lösung mit dem minimalen Zielfunktionswert bestimmt werden. Dies ist für die Ausgabe der multikriteriellen Algorithmen nicht möglich. In der Regel bilden diese Lösungen eine nicht-dominierte Menge, die ein Spektrum an Kompromissen wiedergibt. Diese Information geht bei der Skalarisierung verloren. In Abhängigkeit der Gewichtung der Teilziele werden punktuelle Kompromisse gefunden. Ein einziger Optimierungslauf erlaubt keine Rekonstruktion des gesamten Spektrums. Um einen breiteren Überblick zu erhalten, müsste die Optimierung unter Einsatz verschiedener Gewichtungen mehrfach durchlaufen werden.

In der Evaluation wurde festgestellt, dass die Qualität der Lösungen, welche im Rahmen der skalaren und der multikriteriellen Optimierung gefunden wurden, vergleichbar war. Die skalaren Lösungen reihten sich in die nicht-dominierte Menge der multikriteriellen Lösungen ein. Wie bereits dargelegt, wurde dabei allerdings nur ein kleiner Teil der Front nicht-dominierter Lösungen erfasst.

Es liegt in der Natur der Optimierung mehrerer Teilziele, dass zwischen verschiedenen Lösungen Trade-offs bestehen. Dabei hängt es von den Präferenzen des Anwenders ab, welche Verschlechterung in einem Teilziel er bereit ist, in Kauf zu nehmen für eine Verbesserung in einem anderen Teilziel. Übertragen auf das Energiemanagement bedeutet dies beispielsweise, dass für eine geringfügige Reduzierung der Zielabweichung nicht ein unverhältnismäßig hoher Preis bezahlt werden soll. Um die Trade-offs bei der Optimierung zu limitieren, wurde ein multikriterieller Algorithmus entwickelt. Dieser berücksichtigt die Beschränkungen bereits bei der Suche, sodass sich diese auf die präferierten Bereiche konzentriert. Bei der in den Szenarien betrachteten Preisspanne und der relativ kleinen Zahl von Entitäten erscheinen die Kosten zunächst vernachlässigbar. Wird das Energiemanagement jedoch auf eine hohe Zahl von Teilnehmern skaliert, so steigen die Kosten um mehrere Größenordnungen. Sofern die Preise börsenähnlichen Schwankungen unterliegen und Spitzen aufweisen, gewinnen die Trade-offs ebenfalls an Bedeutung.

Sowohl die Beschränkungen der Trade-offs bei der multikriteriellen Optimierung als auch die Gewichte der einzelnen Teilziele bei der skalaren Optimierung stellen Vorgaben dar, welche vor der Optimierung festgelegt werden. Diese Vorgaben sind im skalaren Fall insofern restriktiver, als dass genau eine Lösung optimal ist – wenn man davon absieht, dass mehrere Lösungen denselben minimalen Zielfunktionswert besitzen können. Die obere Schranke für Trade-offs im multikriteriellen Fall lässt hingegen eine Menge von Kompromisslösungen zu. Von diesem Standpunkt aus betrachtet, ist es ohne Kenntnis des Ergebnisses und der Entscheidungsmöglichkeiten vorab praktikabler, die Trade-offs zu beschränken als eine Gewichtung der Teilziele vorzunehmen.

7.3.3 Netzrestriktionen

Die flexible Leistungsführung erfolgte in allen Szenarien unter Berücksichtigung von physikalischen Netzrestriktionen bezüglich der Spannungshöhe und der thermischen Belastbarkeit der Stromkabel. Hierzu wurde für jeden Zeitschritt der AC-Leistungsfluss berechnet. Abschnitt 3.3 beschreibt das modellierte 106-Knoten-Niederspannungsnetz. In den Szenarien wurde dieses vermascht betrieben, wie es häufig bei hohen Leistungsdichten der

Fall ist. Ein Vergleich zwischen der vermaschten und einer radialen Topologie dieses Netzes wurde in der Studie [163] vorgenommen.

Die Netzrestriktionen fanden im Rahmen der Bewertungs- und Selektionsschritte der genetischen Algorithmen Beachtung. Der Darstellung in Abschnitt 6.6 folgend, wurde eine Lösung ohne Restriktionsverletzung stets einer Lösung vorgezogen, welche eine Verletzung der Nebenbedingungen nach sich zog. Beim Vergleich zweier unzulässiger Lösungen wurde die Lösung mit der geringeren Restriktionsverletzung präferiert. Dieses Vorgehen sorgte dafür, dass auch unter hoher Netzbelastung umsetzbare Lösungen gefunden wurden. Wo dies nicht möglich war, wurde die Restriktionsverletzung zumindest deutlich reduziert. Auf diese Weise ermittelte Lösungen wiesen im Vergleich zu den Lösungen, die ohne Berücksichtigung der Netzrestriktionen bestimmt worden waren, eine höhere Zielabweichung auf bei gleichzeitig umfangreicheren Leistungsverschiebungen. Obwohl die restriktionsbehafteten Lösungen demnach dominiert wurden, fand die Suche in dem zulässigen Raum statt. Das Minimieren der Abweichung von einer Zielvorgabe bezüglich der Leistung führte zusammen mit der Beachtung von Netzrestriktionen dazu, dass Rebound-Effekte vermieden wurden.

7.3.4 Hierarchisches Energiemanagement

Das vorgestellte Energiemanagement verfolgt einen hierarchischen Ansatz, welcher die Autonomie der teilnehmenden Entitäten gewährleistet. Eine Leistungsänderung wird lediglich im Rahmen der übermittelten Angebote durch eine übergeordnete Instanz ausgewählt. Da sich die Struktur der Angebote grundlegend unterscheidet, wurden die Photovoltaik-Anlagen als separate Entitäten aufgefasst, obwohl diese physikalisch zu den entsprechenden Haushalten gehörten.

Basierend auf deren Autonomie kann eine Abstraktion der Entitäten erfolgen. Aus Sicht des Energiemanagers stellt jede Entität eine Blackbox dar, welche durch ihr Leistungsprofil und ihre Änderungsangebote charakterisiert wird. Die Abstraktion stellt zum einen ein Mittel zur Komplexitätsreduktion dar, da auf einer höheren Ebene keine Interna der untergeordneten Entitäten bekannt sein müssen. Zum anderen wurde damit ein universeller Ansatz geschaffen, der in vielfältigen Situationen nutzbar ist. In dieser Arbeit wurden beispielsweise verschiedene Zielprofile und Planungs-

horizonte betrachtet, wobei die Art der Optimierung modular wählbar war. Ferner ist der Energiemanagement-Ansatz weder auf die dargestellten Entitäten noch auf die Niederspannungsebene beschränkt. Obgleich die Ergebnisse von Szenario 4 das Berücksichtigen von Netzrestriktionen nahelegen, kann eine Optimierung „auf der Kupferplatte“ erfolgen, beispielsweise wenn die Entitäten in verschiedenen Netzbereichen liegen.

Zusammenfassung und Ausblick

Motiviert durch die Flexibilisierung von Erzeugung und Verbrauch in Smart Grids wurde in dieser Arbeit ein fahrplanbasiertes Energiemanagement vorgestellt. Dieses Kapitel fasst die wichtigsten Ergebnisse zusammen und zeigt mögliche Anknüpfungspunkte für künftige Arbeiten auf.

8.1 Zusammenfassung

Smart Grids sind durch informationstechnische Vernetzung und Steuerung der Komponenten und Akteure geprägt. Die Koordination zahlreicher heterogener Systeme erfordert intelligente Koordinationsmethoden und geeignete Systemarchitekturen. Beide Aspekte wurden in der Arbeit betrachtet.

8.1.1 Fahrplanbasiertes Energiemanagement

Im Fokus dieser Arbeit stand die Entwicklung einer Methode für flexible Leistungsführung. Diese approximiert definierte Leistungsprofile mit Hilfe der Flexibilität einer Aggregation von autonomen Energieverbrauchern und -erzeugern. Hierzu wurden Optimierungsprobleme formuliert, die sowohl Last- als auch Erzeugungsmanagement – zusammenfassend als Energiemanagement bezeichnet – umfassen. Das Energiemanagement basiert auf zeitdiskreten, prognostizierten Leistungsprofilen, den sogenannten Fahrplänen. Diese ermöglichen die Planung aggregierter Leistungsprofile für mehrstündige Zeithorizonte. Um realisierbare Pläne zu erstellen, werden Netzrestriktionen berücksichtigt. Neben der Energiemanagement-Architektur bilden daher folgende Aspekte Schwerpunkte dieser Arbeit: Problemformalisierung, Optimierung mit Netzrestriktionen sowie Fahrplanprognose.

Formalisierung

Um Zielprofile mittels Algorithmen zu approximieren, wurde zunächst eine Problemformalisierung durchgeführt. Diese umfasst die mathematische Modellierung der Erzeuger, Verbraucher und Flexibilitäten sowie darauf aufbauend die Formulierung von Optimierungsproblemen. Erzeuger und Verbraucher werden durch Leistungsprofile repräsentiert, welche aus mathematischer Sicht Zeitreihen sind. Diese Darstellung ist unabhängig von der Art der Erzeugungsanlagen und Verbraucher. Aus diesem Grund wurde der Überbegriff der Entität für einen beliebigen Erzeuger oder Verbraucher eingeführt.

Flexibilitätpotenziale bezüglich Erzeugung und Verbrauch werden ebenfalls generisch als Leistungsprofile modelliert, um eine Vielzahl von Entitäten einheitlich abzubilden. Diese Zeitreihen werden als Differenz-Leistungsprofile interpretiert, die eine Änderung der zugehörigen Fahrpläne bewirken. Hierbei werden zwei Flexibilitätsgrade unterschieden. Zum einen werden starre Differenzprofile genutzt, welche in den einzelnen Zeitschritten feste Leistungsänderungen vorgeben. Diese Profile können durch den Energiemanager entweder akzeptiert oder abgelehnt werden. Zum anderen werden anpassbare Differenzprofile eingesetzt. Diese geben für die einzelnen Zeitschritte Intervalle vor, innerhalb deren der Energiemanager einen Wert für die Leistungsänderung festlegen kann. Starre Differenzprofile sind typisch für Haushalte. Diese können zwar die Startzeiten von Geräten wie beispielsweise Geschirrspülern verschieben, nicht jedoch deren Verbrauchsprofile ändern. Adaptierbare Differenzprofile hingegen sind typisch für Energieerzeuger. So können beispielsweise Blockheizkraftwerke die Erzeugung in bestimmten Grenzen verändern oder Photovoltaik-Anlagen die Einspeisung drosseln.

Die Repräsentation mittels Leistungsprofilen beruht auf der Autonomie der Entitäten. Diese können ausschließlich im Rahmen der angebotenen Flexibilitäten beeinflusst werden. Auf diese Weise wird ein hierarchisches Koordinationskonzept umgesetzt, welches zu einer Komplexitätsreduktion beiträgt. Wenn beispielshalber Haushalte als Entitäten auftreten, werden dadurch alle Geräte und Anlagen auf Haushaltsebene aggregiert. Das Energiemanagement auf Netzebene erfordert dann eine Koordination von Haushalten und nicht von einer höheren Zahl von Haushaltskomponenten.

Optimierung

Die formulierten Optimierungsprobleme basieren auf der Grundidee, dass Entitäten ihre Flexibilität gegen Bezahlung anbieten. Aus diesen Angeboten muss eine Auswahl getroffen werden, welche zu einem bestmöglichen Kompromiss zwischen Approximationsgüte und Kosten führt. Da beide Teilziele gegenläufig sind, wird das Optimierungsziel durch zwei Funktionen ausgedrückt. Darüber hinaus werden auch skalarisierte Varianten betrachtet. Die Entscheidungsvariablen sind binär für die Auswahl starrer Differenzprofile und reell für die anpassbaren Differenzprofile. Aufgrund nichtlinearer Zielfunktionen und Nebenbedingungen sind im Rahmen des Energiemanagements nichtlineare, gemischt-ganzzahlige Optimierungsprobleme zu lösen. Physikalische Netzrestriktionen hinsichtlich Spannung und Strom werden als Nebenbedingungen berücksichtigt.

Für die Optimierung wurden drei genetische Algorithmen implementiert, die verschiedene Ansätze verfolgen. Einer dieser Algorithmen führt eine skalare Optimierung durch, wobei die beiden Teilziele Approximationsgüte und Kosten durch eine gewichtete Summierung in einer Zielfunktion zusammengefasst werden. Die beiden anderen Algorithmen optimieren multikriteriell. Im Unterschied zu skalaren Problemen existieren bei multikriteriellen Problemen Pareto-optimale Lösungen, die nicht miteinander vergleichbar sind. Damit ist keine vollständige Ordnung der Lösungen hinsichtlich deren Güte gegeben. Bei der skalaren Optimierung muss a priori eine Gewichtung der Teilziele vorgenommen werden. Die resultierende Lösung stellt einen Kompromiss zwischen diesen Teilzielen dar, welcher die Gewichtung widerspiegelt. Die multikriterielle Optimierung liefert hingegen ein Spektrum an Kompromisslösungen, welche diversen Präferenzen bezüglich der Teilziele entsprechen. Damit kann a posteriori eine Lösung unter Kenntnis des Entscheidungsspektrums gewählt werden. Diese Entscheidungsfindung kann durch Anwender oder automatisiert erfolgen.

Bei multikriteriellen Betrachtungen existieren potenziell unerwünschte Trade-offs zwischen Lösungen. Für das Energiemanagement bedeutet dies beispielsweise, dass für eine geringfügige Reduzierung der Zielabweichung im Vergleich zu einer anderen Lösung ein unverhältnismäßig hoher Preis bezahlt werden muss. Diese unerwünschten Lösungen können in der Lösungsmenge zwar identifiziert werden, jedoch kann es vorteilhaft sein, die

Suche auf die bevorzugten Bereiche zu konzentrieren. Dadurch ist es möglich, bei begrenzter Rechenzeit eine höhere Zahl bevorzugter Lösungen zu finden, auch wenn dadurch das Entscheidungsspektrum eingeschränkt wird. Aus diesem Grund limitiert einer der multikriteriellen Algorithmen die akzeptierten Trade-offs. Auf diese Weise können Lösungen entfernt werden, welche zu unverhältnismäßig hohen Preisen oder Abweichungen führen.

Lastprognose

Bei der Optimierung werden physikalische Netzrestriktionen zur Vermeidung von Überlastungen berücksichtigt. Dazu werden Entitäten auf Knoten eines Stromnetzes abgebildet, sodass für den Planungshorizont Leistungsflüsse basierend auf Fahrplänen der Entitäten berechnet werden können.

Neben intelligenten Entitäten, die selbstständig Fahrplanprognosen vornehmen, umfasst das Stromnetz auch konventionelle Verbraucher in Form von Haushalten, die weder Lastflexibilität noch Prognosefähigkeit aufweisen. Daher wurden diverse Prädiktionsverfahren gegenübergestellt und zur Lastprognose von Einzelhaushalten auf Basis der Messdaten intelligenter Stromzähler genutzt. Zu den untersuchten Verfahren gehören saisonale ARIMA-Modelle, künstliche neuronale Netze, Vergleichstageverfahren sowie ein synthetisches Lastprofilverfahren. Es wurde gezeigt, dass mit ARIMA-Modellen und künstlichen neuronalen Netzen genauere Lastprognosen möglich sind als mit den in der Energiewirtschaft etablierten Verfahren.

Fazit

Modellierung und Optimierung verfolgen einen generischen Ansatz, sodass ein Energiemanagement mit diversen Entitäten umsetzbar ist. Um den fahrplanbasierten Energiemanagement-Ansatz zu evaluieren, wurden Photovoltaik-Anlagen sowie intelligente und konventionelle Gebäude auf ein 106-Knoten-Niederspannungsnetz abgebildet und simuliert. Hierfür wurden Szenarien definiert, die verschiedene Aspekte des Last- und des Erzeugungsmanagements beleuchten. Dabei wurde gezeigt, dass der entwickelte Energiemanagement-Ansatz geeignet ist, eine flexible Leistungsführung umzusetzen. Das Berücksichtigen von Netzrestriktionen erwies sich als notwendig, um realisierbare Lösungen unter hoher Netzlast zu finden.

8.1.2 Energiemanagement-Architektur

In dieser Arbeit wurde eine generische, hierarchische Architektur für Energiemanagement-Systeme präsentiert. Diese basiert auf der Observer/Controller-Architektur des Organic Computing und integriert diverse zeitliche, räumliche und strukturelle Ebenen der Koordination. Um die Heterogenität der Subsysteme auf der Managementebene zu verbergen, wird eine Abstraktionsschicht eingesetzt, welche mittels Treibern die untergeordneten Systeme kapselt. Die Treiber bieten auf der Managementebene eine definierte Schnittstelle an, welche zum einen die unterliegenden Kommunikationsprotokolle verbirgt und zum anderen die Art der kommunizierten Daten für Klassen von Subsystemen vereinheitlicht. Durch die Abstraktion wird es möglich, Systeme zu aggregieren und diese wiederum als Subsysteme auf einer höheren Koordinierungsebene zu verwenden. Auf diese Weise können sowohl hierarchische als auch dezentrale Kontrollstrukturen umgesetzt werden, welche eine Komplexitätsreduktion im Vergleich zu zentralen Ansätzen bewirken. Darüber hinaus erlaubt die Abstraktion das Einbinden neuer oder veränderter Subsysteme, ohne Anpassungen auf der Managementebene durchführen zu müssen, sofern ein Treiber bereitgestellt wird.

Die vorgestellte generische Architektur kann diverse Anwendungsfälle im Kontext von Smart Grids abbilden. In dieser Arbeit wurde die Architektur für das fahrplanbasierte Energiemanagement instanziiert. Hierbei wurde die generische Darstellung der Entitäten und Flexibilitäten für die Abstraktion mittels Treibern genutzt. Die Lastprognose sowie die Optimierung mit Netzrestriktionen wurden durch Komponenten des Observers und des Controllers wahrgenommen.

8.2 Ausblick

Besonderes Augenmerk wurde in dieser Arbeit der Formalisierung und der Optimierung gewidmet. Die Modellierung wurde insbesondere für Erzeuger und Verbraucher diskutiert. Indes können Fahrpläne und Differenzprofile auch Speicher abbilden, wobei jedoch nicht das volle Flexibilitätspotenzial gehoben werden kann. Um das gesamte Potenzial auszuschöpfen, müsste der Ladezustand der Speicher durch Nebenbedingungen einbezogen werden. In diesem Fall ist es möglich, die Flexibilität durch anpassbare

Differenzprofile auszudrücken. Dabei bilden die maximale Lade- und Entladeleistung die obere und untere Grenze der erlaubten Leistungsänderungen in einem Zeitschritt.

Das Stromnetz wurde als passiv betrachtet und ausschließlich in den Nebenbedingungen berücksichtigt. Durch moderne Betriebsmittel sowie deren Vernetzung entsteht die Möglichkeit, das Netz im Rahmen der Optimierung aktiv einzubinden. Statt die Erzeugung zu drosseln, um eine Verletzung des Spannungsbands zu vermeiden, könnte so beispielsweise das Übersetzungsverhältnis eines regelbaren Ortsnetztransformators adaptiert werden. Es bleibt zu untersuchen, wie sich eine derartige Erweiterung des Entscheidungsraums auf die Lösungsgüte auswirkt.

In den Leistungsflussberechnungen, und damit in den Netzrestriktionen, wurde die Blindleistung berücksichtigt. Diese hatte jedoch keinen Einfluss auf die Zielvorgaben, welche nur die Wirkleistung einbezogen. Um eine Optimierung hinsichtlich der Blindleistung durchzuführen, kann eine weitere Zielfunktion eingeführt werden. In Kombination mit der dezentralen Blindleistungsbereitstellung, beispielsweise durch die Wechselrichter von Photovoltaik-Anlagen, entsteht so zusätzliches Optimierungspotenzial.

Für die Optimierung wurden drei genetische Algorithmen eingesetzt. Dabei wurden grundlegende Herangehensweisen gegenübergestellt und die Umsetzbarkeit des Energiemanagement-Ansatzes demonstriert. In einem nächsten Schritt können weitere Optimierungsalgorithmen für die skalare und multikriterielle Optimierung evaluiert werden, wie beispielsweise Partikelschwarm-Optimierung oder Evolutionsstrategien. Hierdurch können Aussagen hinsichtlich der Lösungsqualität getroffen werden. Diese Verfahren können um eine lokale Suche erweitert werden.

Die Koordination der Entitäten basiert auf Fahrplänen, welche stochastischen Fehlern unterliegen. Lösungen, die im Rahmen der Optimierung gefunden werden, können daher nicht genau umgesetzt werden. Damit bei der Abwicklung der Fahrpläne die Abweichung von der ermittelten Lösung möglichst gering bleibt, kann bei der Optimierung die Robustheit von Lösungen berücksichtigt werden.

Für die Evaluation wurden diverse Szenarien mittels Simulationen betrachtet. Um die Evaluation auf reale Systeme auszudehnen, können in einem nächsten Schritt Hardware-in-the-Loop-Szenarien analysiert werden. Hierfür eignet sich das Organic Smart Home, welches über Mechanismen

verfügt, mit einem übergeordneten Energiemanagement-System zu kommunizieren. Ein weiterer Vorteil der Einbindung des Organic Smart Home ist die Möglichkeit, im Rahmen des Gebäude-Energiemanagements feingranulare Betrachtungen bezüglich Flexibilitäten auf Geräteebene vorzunehmen.

Literaturverzeichnis

- [1] H. Aalami, M. P. Moghadam und G. R. Yousefi. Optimum time of use program proposal for Iranian power systems. In *International Conference on Electric Power and Energy Conversion Systems (EPECS)*. IEEE, 2009.
- [2] J. Aghaei und M.-I. Alizadeh. Demand response in smart electricity grids equipped with renewable energy sources: A review. *Renewable and Sustainable Energy Reviews*, 18:64–72, 2013.
- [3] H. M. Al-Hamadi und S. A. Soliman. Short-term electric load forecasting based on Kalman filtering algorithm with moving window weather and load model. *Electric Power Systems Research*, 68(1):47–59, 2004.
- [4] M. H. Albadi und E. F. El-Saadany. Demand response in electricity markets: An overview. In *Power and Engineering Society General Meeting (PES GM)*. IEEE, 2007.
- [5] H. K. Alfares und M. Nazeeruddin. Electric load forecasting: Literature survey and classification of methods. *International Journal of Systems Science*, 33(1):23–34, 2002.
- [6] M. Alizadeh, A. Scaglione und R. J. Thomas. From packet to power switching: Digital direct load scheduling. *IEEE Journal on Selected Areas in Communications*, 30(6):1027–1036, 2012.
- [7] M. Alizadeh, Z. Wang und A. Scaglione. Demand side management trends in the power grid. In *International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP)*, S. 141–144. IEEE, 2011.

- [8] K. Allemand, K. Fukuda, T. M. Liebling und E. Steiner. A polynomial case of unconstrained zero-one quadratic optimization. *Mathematical Programming*, 91(1):49–52, 2001.
- [9] F. Allerding. *Organic Smart Home – Energiemanagement für intelligente Gebäude*. Dissertation, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2013.
- [10] F. Allerding, B. Becker und H. Schmeck. Decentralised energy management for smart homes. In C. Müller-Schloer, H. Schmeck und T. Ungerer (Hrsg.), *Organic Computing — A Paradigm Shift for Complex Systems*, Autonomic Systems, S. 605–607. Springer Basel, 2011.
- [11] F. Allerding, I. Mauser und H. Schmeck. Customizable energy management in smart buildings using evolutionary algorithms. In A. I. Esparcia-Alcázar und A. M. Mora (Hrsg.), *Applications of Evolutionary Computation: 17th European Conference, EvoApplications 2014, Granada, Spain, April 23–25, 2014, Revised Selected Papers*, Band 8602 von LNCS, S. 153–164. Springer Berlin Heidelberg, 2014.
- [12] F. Allerding, M. Premm, P. K. Shukla und H. Schmeck. Electrical load management in smart homes using evolutionary algorithms. In J.-K. Hao und M. Middendorf (Hrsg.), *Evolutionary Computation in Combinatorial Optimization: 12th European Conference, EvoCOP 2012, Málaga, Spain, April 11–13, 2012. Proceedings*, Band 7245 von LNCS, S. 99–110. Springer Berlin Heidelberg, 2012.
- [13] F. Allerding und H. Schmeck. Organic Smart Home: Architecture for energy management in intelligent buildings. In *Workshop on Organic Computing (OC)*, S. 67–76. ACM, 2011.
- [14] M. J. Alves und J. Clímaco. A review of interactive methods for multi-objective integer and mixed-integer programming. *European Journal of Operational Research*, 180(1):99–115, 2007.
- [15] F. Aminifar, M. Fotuhi-Firuzabad und M. Shahidehpour. Unit commitment with probabilistic spinning reserve and interruptible load considerations. *IEEE Transactions on Power Systems*, 24(1):388–397, 2009.

- [16] N. Amjady. Short-term hourly load forecasting using time-series modeling with peak load estimation capability. *IEEE Transactions on Power Systems*, 16(3):498–505, 2001.
- [17] J. M. Arroyo und A. J. Conejo. Multiperiod auction for a pool-based electricity market. *IEEE Transactions on Power Systems*, 17(4):1225–1231, 2002.
- [18] D. Axehill. *Integer quadratic programming for control and communication*. Dissertation, Universität Linköping, Linköping, Schweden, 2008.
- [19] M. Babar, T. P. I. Ahamed, E. A. Al-Ammar und A. Shah. A novel algorithm for demand reduction bid based incentive program in direct load control. *Energy Procedia*, 42:607–613, 2013.
- [20] R. Badawy, A. Yassine, A. Heßler, B. Hirsch und S. Albayrak. A novel multi-agent system utilizing quantum-inspired evolution for demand side management in the future smart grid. *Integrated Computer-Aided Engineering*, 20(2):127–141, 2013.
- [21] C. Ballester und D. Furió. Effects of renewables on the stylized facts of electricity prices. *Renewable and Sustainable Energy Reviews*, 52:1596–1609, 2015.
- [22] K. Bao, F. Allerdig und H. Schmeck. User behavior prediction for energy management in smart homes. In *International Conference on Fuzzy Systems and Knowledge Discovery (FSKD)*, Band 2, S. 1335–1339. IEEE, 2011.
- [23] F. Barahona. A solvable case of quadratic 0–1 programming. *Discrete Applied Mathematics*, 13(1):23–26, 1986.
- [24] N. C. Batista, R. Melício und V. M. F. Mendes. Layered smart grid architecture approach and field tests by ZigBee technology. *Energy Conversion and Management*, 88:49–59, 2014.
- [25] J. E. Beasley. *Heuristic algorithms for the unconstrained binary quadratic programming problem*. Technischer Bericht, The Imperial College of Science, Technology and Medicine, London, UK, 1998.

- [26] B. Becker. *Interaktives Gebäude-Energiemanagement*. Dissertation, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2014.
- [27] G. T. Bellarmine. Load management techniques. In *Southeastcon*. IEEE, 2000.
- [28] T. Berthold. *Primal heuristics for mixed integer programs*. Diplomarbeit, TU Berlin, Berlin, Deutschland, 2006.
- [29] K. Bhattacharyya und M. L. Crow. A fuzzy logic based approach to direct load control. *IEEE Transactions on Power Systems*, 11(2):708–714, 1996.
- [30] C. Block, D. Neumann und C. Weinhardt. A market mechanism for energy allocation in micro-CHP grids. In *Hawaii International Conference on System Sciences (HICSS)*, S. 172–180. IEEE, 2008.
- [31] C. Blum, J. Puchinger, G. R. Raidl und A. Roli. Hybrid metaheuristics in combinatorial optimization: A survey. *Applied Soft Computing*, 11(6):4135–4151, 2011.
- [32] C. Blum und A. Roli. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. *ACM Computing Surveys*, 35(3):268–308, 2003.
- [33] I. Boussaïd, J. Lepagnot und P. Siarry. A survey on optimization metaheuristics. *Information Sciences*, 237:82–117, 2013.
- [34] G. E. P. Box, G. C. Reinsel und G. M. Jenkins. *Time series analysis: Forecasting and control*. Prentice Hall, 3. Auflage, 1994.
- [35] J. Branke, K. Deb, H. Dierolf und M. Osswald. Finding knees in multi-objective optimization. In X. Yao, E. Burke, J. A. Lozano, J. Smith, J. J. Merelo-Guervós, J. A. Bullinaria, J. Rowe, P. Tino, A. Kabán und H.-P. Schwefel (Hrsg.), *Parallel Problem Solving from Nature – PPSN VIII: 8th International Conference, Birmingham, UK, September 18–22, 2004. Proceedings*, Band 3242 von LNCS, S. 722–731. Springer Berlin Heidelberg, 2004.

- [36] J. Branke, M. Mnif, C. Müller-Schloer, H. Prothmann, U. Richter, F. Rochner und H. Schmeck. Organic Computing – Addressing complexity by controlled self-organization. In *International Symposium on Leveraging Applications of Formal Methods, Verification and Validation (ISoLA)*, S. 185–191. IEEE, 2006.
- [37] Bundesministerium für Wirtschaft und Energie (BMWi). *Die Energie der Zukunft – Erster Fortschrittsbericht zur Energiewende*. Technischer Bericht, Bundesministerium für Wirtschaft und Energie (BMWi), Berlin, Deutschland, 2014.
- [38] Bundesministerium für Wirtschaft und Energie (BMWi). *Ein Strommarkt für die Energiewende. Ergebnisrapport des Bundesministeriums für Wirtschaft und Energie (Weißbuch)*. Technischer Bericht, Bundesministerium für Wirtschaft und Energie (BMWi), Berlin, Deutschland, 2015.
- [39] Bundesverband der Energie- und Wasserwirtschaft e.V. (BDEW). *Stromverbrauch im Haushalt*. Berlin, Deutschland, 2013.
- [40] Bundesverband der Energie- und Wasserwirtschaft e.V. (BDEW). *Erneuerbare Energien und das EEG: Zahlen, Fakten, Grafiken (2014)*. Berlin, Deutschland, 2014.
- [41] B. Burmeister, A. Haddadi und G. Matylis. Application of multi-agent systems in traffic and transportation. *IEE Proceedings – Software Engineering*, 144(1):51–60, 1997.
- [42] L. Buşoni, R. Babuška und B. De Schutter. A comprehensive survey of multiagent reinforcement learning. *IEEE Transactions on Systems, Man, and Cybernetics – Part C: Applications and Reviews*, 38(2):156–172, 2008.
- [43] N. Cai und J. Mitra. A multi-level control architecture for master-slave organized microgrids with power electronic interfaces. *Electric Power Systems Research*, 109:8–19, 2014.
- [44] D. S. Callaway und I. A. Hiskens. Achieving controllability of electric loads. *Proceedings of the IEEE*, 99(1):184–199, 2011.

- [45] E. Carpaneto und G. Chicco. Probability distributions of the aggregated residential load. In *International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*. IEEE, 2006.
- [46] V. M. Catterson, E. M. Davidson und S. D. J. McArthur. Agents for active network management and condition monitoring in the smart grid. In *International Conference on Autonomous Agents and Multi-agent Systems (AAMAS)*. 2010.
- [47] V. M. Catterson, E. M. Davidson und S. D. J. McArthur. Practical applications of multi-agent systems in electric power systems. *European Transactions on Electrical Power*, 22(2):235–252, 2012.
- [48] E. Çelebi und J. D. Fuller. A model for efficient consumer pricing schemes in electricity markets. *IEEE Transactions on Power Systems*, 22(1):60–67, 2007.
- [49] A. C. Chapman, G. Verbič und D. J. Hill. A healthy dose of reality for game-theoretic approaches to residential demand response. In *Bulk Power System Dynamics and Control Conference*. 2013.
- [50] Charles River Associates. *Primer on demand-side management – With an emphasis on price-responsive programs*. Technischer Bericht, The World Bank, Washington, DC, USA, 2005.
- [51] B.-J. Chen, M.-W. Chang und C.-J. Lin. Load forecasting using support vector machines: A study on EUNITE competition 2001. *IEEE Transactions on Power Systems*, 19(4):1821–1830, 2004.
- [52] C. Chen, J. Wang und S. Kishore. A distributed direct load control approach for large-scale residential demand response. *IEEE Transactions on Power Systems*, 29(5):2219–2228, 2014.
- [53] C. S. Chen und J. T. Leu. Interruptible load control for Taiwan Power Company. *IEEE Transactions on Power Systems*, 5(2):460–465, 1990.
- [54] J. Chen, F. N. Lee, A. M. Breipohl und R. Adapa. Scheduling direct load control to minimize system operation cost. *IEEE Transactions on Power Systems*, 10(4):1994–2001, 1995.

- [55] L. Chen, N. Li, S. H. Low und J. C. Doyle. Two market models for demand response in power networks. In *International Conference on Smart Grid Communications (SmartGridComm)*, S. 397–402. IEEE, 2010.
- [56] C.-M. Chu und T.-L. Jong. A novel direct air-conditioning load control method. *IEEE Transactions on Power Systems*, 23(3):1356–1363, 2008.
- [57] C. M. Colson und M. H. Nehrir. Comprehensive real-time microgrid power management and control with distributed agents. *IEEE Transactions on Smart Grid*, 4(1):617–627, 2013.
- [58] A. J. Conejo, F. Milano und R. García-Bertrand. Congestion management ensuring voltage stability. *IEEE Transactions on Power Systems*, 21(1):357–364, 2006.
- [59] V. Crastan. *Elektrische Energieversorgung 1*. Springer Berlin Heidelberg, 2. Auflage, 2007.
- [60] V. Crastan und D. Westermann. *Elektrische Energieversorgung 3*. Springer Berlin Heidelberg, 3. Auflage, 2012.
- [61] C. D’Ambrosio und A. Lodi. Mixed integer nonlinear programming tools: A practical overview. *4OR – A Quarterly Journal of Operations Research*, 9(4):329–349, 2011.
- [62] S. Datchanamoorthy, S. Kumar, Y. Ozturk und G. Lee. Optimal time-of-use pricing for residential load control. In *International Conference on Smart Grid Communications (SmartGridComm)*, S. 375–380. IEEE, IEEE, 2011.
- [63] E. M. Davidson, S. D. J. McArthur, J. R. McDonald, T. Cumming und I. Watt. Applying multi-agent system technology in practice: Automated management and analysis of SCADA and digital fault recorder data. *IEEE Transactions on Power Systems*, 21(2):559–567, 2006.
- [64] K. Deb. An efficient constraint handling method for genetic algorithms. *Computer Methods in Applied Mechanics and Engineering*, 186(2–4):311–338, 2000.

- [65] K. Deb. *Multi-objective optimization using evolutionary algorithms*. John Wiley & Sons, 2001.
- [66] K. Deb und R. B. Agrawal. Simulated binary crossover for continuous search space. *Complex Systems*, 9(2):115–148, 1995.
- [67] K. Deb, S. Agrawal, A. Pratap und T. Meyarivan. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II. In M. Schoenauer, K. Deb, G. Rudolph, X. Yao, E. Lutton und J. J. Merelo (Hrsg.), *Parallel Problem Solving from Nature – PPSN VI: 6th International Conference Paris, France, September 18–20, 2000. Proceedings*, Band 1917 von LNCS, S. 849–858. Springer Berlin, 2000.
- [68] K. Deb und M. Goyal. A combined genetic adaptive search (GeneAS) for engineering design. *Computer Science and Informatics*, 26(4):30–45, 1996.
- [69] K. Deb und A. Kumar. Real-coded genetic algorithms with simulated binary crossover: Studies on multimodal and multiobjective problems. *Complex Systems*, 9(6):431–454, 1995.
- [70] K. Deb, A. Pratap, S. Agrawal und T. Meyarivan. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2):182–197, 2002.
- [71] Y. del Valle, G. K. Venayagamoorthy, S. Mohagheghi, J.-C. Hernandez und R. G. Harley. Particle swarm optimization: Basic concepts, variants and applications in power systems. *IEEE Transactions On Evolutionary Computation*, 12(2):171–195, 2008.
- [72] Deutsches Institut für Normung e. V. (DIN). Merkmale der Spannung in öffentlichen Elektrizitätsversorgungsnetzen; Deutsche Fassung EN 50160:2010 + Cor. :2010. Beuth Verlag GmbH, 2011. DIN EN 50160.
- [73] G. Di Marzo Serugendo, N. Foukia, S. Hassas, A. Karageorgos, S. Kouadri Mostéfaoui, O. F. Rana, M. Ulieru, P. Valckenaers und C. Van Aart. Self-organisation: Paradigms and applications. In G. Di Marzo Serugendo, A. Karageorgos, O. F. Rana und F. Zambonelli (Hrsg.), *Engineering Self-Organising Systems: Nature-Inspired Approaches to Software*

- Engineering*, Band 2977 von *LNAI*, S. 1–19. Springer Berlin Heidelberg, 2004.
- [74] K. Dietrich, F. Leuthold und H. Weigt. Will the market get it right? The placing of new power plants in Germany. *Zeitschrift für Energiewirtschaft*, 34(4):255–265, 2010.
- [75] J. J. Durillo und A. J. Nebro. jMetal: A Java framework for multi-objective optimization. *Advances in Engineering Software*, 42(10):760–771, 2011.
- [76] F. Y. Edgeworth. *Mathematical psychics. An essay on the application of mathematics to the moral sciences*. C. Kegan Paul & Co., London, UK, 1881.
- [77] M. Ehrgott. *Multicriteria optimization*. Springer Berlin Heidelberg, 2. Auflage, 2005.
- [78] M. Ehrgott und X. Gandibleux. A survey and annotated bibliography of multiobjective combinatorial optimization. *OR-Spektrum*, 22(4):425–460, 2000.
- [79] M. Ehrgott und X. Gandibleux. Approximative solution methods for multiobjective combinatorial optimization. *TOP: An Official Journal of the Spanish Society of Statistics and Operations Research*, 12(1):1–63, 2004.
- [80] M. Ehrgott und X. Gandibleux. Hybrid metaheuristics for multi-objective combinatorial optimization. In C. Blum, M. J. B. Aguilera, A. Roli und M. Sampels (Hrsg.), *Hybrid Metaheuristics: An Emerging Approach to Optimization*, Band 114 von *Studies in Computational Intelligence*, S. 221–259. Springer Berlin Heidelberg, 2008.
- [81] G. Eichfelder. *Adaptive scalarization methods in multiobjective optimization*. Springer Berlin Heidelberg, 2008.
- [82] T. Ericson. Direct load control of residential water heaters. *Energy Policy*, 37(9):3502–3512, 2009.

- [83] J. Eto. *The past, present, and future of U.S. utility demand-side management programs*. Technischer Bericht, Ernest Orlando Lawrence Berkeley National Laboratory, Berkeley, CA, USA, 1996.
- [84] T. Facchinetti und M. L. Della Vedova. Real-time modeling for direct load control in cyber-physical power systems. *IEEE Transactions on Industrial Informatics*, 7(4):689–698, 2011.
- [85] X. Fang, S. Misra, G. Xue und D. Yang. Smart grid – The new and improved power grid: A survey. *IEEE Communications Surveys & Tutorials*, 14(4):944–980, 2012.
- [86] A. Faruqui und S. George. Quantifying customer response to dynamic pricing. *The Electricity Journal*, 18(4):53–63, 2005.
- [87] A. Faruqui und S. Sergici. Household response to dynamic pricing of electricity: A survey of 15 experiments. *Journal of Regulatory Economics*, 38(2):193–225, 2010.
- [88] E. A. Feinberg und D. Genethliou. Load forecasting. In J. H. Chow, F. F. Wu und J. Momoh (Hrsg.), *Applied Mathematics for Restructured Electric Power Systems: Optimization, Control, and Computational Intelligence*, Power Electronics and Power Systems, Kapitel 12, S. 269–285. Springer US, 2005.
- [89] J.-A. Ferrez, K. Fukuda und T. M. Liebling. Solving the fixed rank convex quadratic maximization in binary variables by a parallel zonotope construction algorithm. *European Journal of Operational Research*, 166(1):35–50, 2005.
- [90] Z. Fikri. *Statistical load analysis for distribution network planning*. Dissertation, Königlich Technische Hochschule, Stockholm, Schweden, 1975.
- [91] J. Fliege. Gap-free computation of Pareto-points by quadratic scalarizations. *Mathematical Methods of Operations Research*, 59(1):69–89, 2004.

- [92] S. Franklin und A. Graesser. Is it an agent, or just a program?: A taxonomy for autonomous agents. In J. P. Müller, M. J. Wooldridge und N. R. Jennings (Hrsg.), *Intelligent Agents III – Agent Theories, Architectures, and Languages*, Band 1193 von LNCS, S. 21–35. Springer Berlin Heidelberg, 1997.
- [93] D. Frey, J. Nimis, H. Wörn und P. Lockemann. Benchmarking and robust multi-agent-based production planning and control. *Engineering Applications of Artificial Intelligence*, 16(4):307–320, 2003.
- [94] S. Frey, A. Diaconescu, D. Menga und I. Demeure. A holonic control architecture for a heterogeneous multi-objective smart micro-grid. In *Self-Adaptive and Self-Organizing Systems (SASO)*, S. 21–30. IEEE, 2013.
- [95] L. Friedrich. *Kurzfristige Lastprognose von Haushalten*. Bachelorarbeit, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2012.
- [96] J. C. Fuller, K. P. Schneider und D. Chassin. Analysis of residential demand response and double-auction markets. In *Power and Energy Society General Meeting (PES GM)*. IEEE, 2011.
- [97] L. Gelazanskas und K. A. A. Gamage. Demand side management in smart grid: A review and proposals for future direction. *Sustainable Cities and Society*, 11:22–30, 2014.
- [98] C. W. Gellings. The concept of demand-side management for electric utilities. *Proceedings of the IEEE*, 73(10):1468–1470, 1985.
- [99] M. Gendreau und J.-Y. Potvin. Metaheuristics in combinatorial optimization. *Annals of Operations Research*, 140(1):189–213, 2005.
- [100] A. M. Geoffrion. Proper efficiency and the theory of vector maximization. *Journal of Mathematical Analysis and Applications*, 22(3):618–630, 1968.
- [101] C. Gerwig. Short term load forecasting for residential buildings—An extensive literature review. In R. Neves-Silva, L. C. Jain und R. J.

- Howlett (Hrsg.), *Intelligent Decision Technologies: Proceedings of the 7th KES International Conference on Intelligent Decision Technologies (KES-IDT 2015)*, Band 39 von *Smart Innovation, Systems and Technologies*, S. 181–193. Springer International Publishing, 2015.
- [102] M. Ghofrani, M. Hassanzadeh, M. Etezadi-Amoli und M. S. Fadali. Smart meter based short-term load forecasting for residential customers. In *North American Power Symposium (NAPS)*. IEEE, 2011.
- [103] A. K. Ghosh, D. L. Lubkeman, M. J. Downey und R. H. Jones. Distribution circuit state estimation using a probabilistic approach. *IEEE Transactions on Power Systems*, 12(1):45–51, 1997.
- [104] I. Giagkiozis, R. C. Purshouse und P. J. Fleming. An overview of population-based algorithms for multi-objective optimisation. *International Journal of Systems Science*, 46(9):1572–1599, 2015.
- [105] F. Glover, B. Alidaee, C. Rego und G. Kochenberger. One-pass heuristics for large-scale unconstrained binary quadratic problems. *European Journal of Operational Research*, 137(2):272–287, 2002.
- [106] L. Goel, Q. Wu und P. Wang. Fuzzy logic-based direct load control of air conditioning loads considering nodal reliability characteristics in restructured power systems. *Electric Power Systems Research*, 80(1):98–107, 2010.
- [107] A. Gomes, C. H. Antunes und A. G. Martins. A multiple objective evolutionary approach for the design and selection of load control strategies. *IEEE Transactions on Power Systems*, 19(2):1173–1180, 2004.
- [108] S. Gottwalt, W. Ketter, C. Block, J. Collins und C. Weinhardt. Demand side management—A simulation of household behavior under variable prices. *Energy Policy*, 39(12):8163–8174, 2011.
- [109] M. Groschke, A. Eßer, D. Möst und W. Fichtner. Neue Anforderungen an optimierende Energiesystemmodelle für die Kraftwerkseinsatz- und Zubauplanung bei begrenzten Netzkapazitäten. *Zeitschrift für Energiewirtschaft*, 33(1):14–22, 2009.

- [110] I. E. Grossmann. Review of nonlinear mixed-integer and disjunctive programming techniques. *Optimization and Engineering*, 3(3):227–252, 2002.
- [111] Y. Guo, R. Li, G. Poulton und A. Zeman. A simulator for self-adaptive energy demand management. In S. Brueckner, P. Robertson und U. Bellur (Hrsg.), *International Conference on Self-Adaptive and Self-Organizing Systems (SASO)*, S. 64–73. IEEE, 2008.
- [112] H. Hahn, S. Meyer-Nieberg und S. Pickl. Electric load forecasting methods: Tools for decision making. *European Journal of Operational Research*, 199(3):902–907, 2009.
- [113] E. Handschin, F. Neise, H. Neumann und R. Schultz. Optimal operation of dispersed generation under uncertainty using mathematical programming. *International Journal of Electrical Power & Energy Systems*, 28(9):618–626, 2006.
- [114] P. Hansen. Methods of nonlinear 0–1 programming. *Annals of Discrete Mathematics*, 5:53–70, 1979.
- [115] T. A. Heberlein und G. K. Warriner. The influence of price and attitude on shifting residential electricity consumption from on- to off-peak periods. *Journal of Economic Psychology*, 4(1-2):107–130, 1983.
- [116] G. C. Heffner und D. A. Kaufman. Distribution substation load impacts of residential air conditioner load control. *IEEE Transactions on Power Apparatus and Systems*, 104(7):1602–1608, 1985.
- [117] R. Herman und C. T. Gaunt. A practical probabilistic design procedure for LV residential distribution systems. *IEEE Transactions on Power Delivery*, 23(4):2247–2254, 2008.
- [118] R. Herman und J. J. Kritzinger. The statistical description of grouped domestic electrical load currents. *Electric Power Systems Research*, 27(1):43–48, 1993.
- [119] K. Herter. Residential implementation of critical-peak pricing of electricity. *Energy Policy*, 35(4):2121–2130, 2007.

- [120] K. Heuck, K. D. Dettmann und D. Schulz. *Elektrische Energieversorgung: Erzeugung, Übertragung und Verteilung elektrischer Energie für Studium und Praxis*. Vieweg+Teubner, 8. Auflage, 2010.
- [121] K. Heussen, S. Koch, A. Ulbig und G. Andersson. Unified system-level modeling of intermittent renewable energy sources and energy storage for power system operation. *IEEE Systems Journal*, 6(1):140–151, 2012.
- [122] L. Hillemacher. *Lastmanagement mittels dynamischer Strompreissignale bei Haushaltskunden*. Dissertation, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2014.
- [123] L. Hillemacher, K. Hufendiek, V. Bertsch, H. Wiechmann, J. Gratenau, P. Jochem und W. Fichtner. Ein Rollenmodell zur Einbindung der Endkunden in eine smarte Energiewelt. *Zeitschrift für Energiewirtschaft*, 37(3):195–210, 2013.
- [124] C. Hinrichs. *Selbstorganisierte Einsatzplanung dezentraler Akteure im Smart Grid*. Dissertation, Carl von Ossietzky Universität Oldenburg, Oldenburg, Deutschland, 2014.
- [125] C. Hinrichs, U. Vogel und M. Sonnenschein. Approaching decentralized demand side management via self-organizing agents. In *International Conference on Autonomous Agents and Multiagent Systems (AAMAS)*. 2011.
- [126] H. S. Hippert und C. E. Pedreira. Estimating temperature profiles for short-term load forecasting: Neural networks compared to linear models. *IEE Proceedings – Generation, Transmission and Distribution*, 151(4):543–547, 2004.
- [127] H. S. Hippert, C. E. Pedreira und R. C. Souza. Neural networks for short-term load forecasting: A review and evaluation. *IEEE Transactions on Power Systems*, 16(1):44–55, 2001.
- [128] C. Hirsch, L. Friedrich und H. Schmeck. Kurzfristige Lastprognose von Einzelhaushalten. In *VDE-Kongress 2014: Smart Cities*. VDE Verlag GmbH, 2014.

- [129] C. Hirsch, L. Hillemacher, C. Block, A. Schuller und D. Möst. Simulations in the smart grid field study MeRegio. *it – Information Technology*, 52(2):100–106, 2010.
- [130] C. Hirsch, P. K. Shukla und H. Schmeck. Variable preference modeling using multi-objective evolutionary algorithms. In R. H. C. Takahashi, K. Deb, E. F. Wanner und S. Greco (Hrsg.), *Evolutionary Multi-criterion Optimization: 6th International Conference, EMO 2011, Ouro Preto, Brazil, April 5–8, 2011. Proceedings*, Band 6576 von LNCS, S. 91–105. Springer Berlin Heidelberg, 2011.
- [131] C. Höft. *Bewertung von Verfahren zur Prognose der elektrischen Last – Eine empirische Analyse*. Diplomarbeit, TU Dresden, Dresden, Deutschland, 2004.
- [132] J. H. Holland. A new kind of turnpike theorem. *Bulletin of the American Mathematical Society*, 75(6):1311–1317, 1969.
- [133] J. H. Holland. Genetic algorithms and the optimal allocation of trials. *SIAM Journal on Computing*, 2(2):88–105, 1973.
- [134] C.-L. Hor, S. J. Watson und S. Majithia. Analyzing the impact of weather variables on monthly electricity demand. *IEEE Transactions on Power Systems*, 20(4):2078–2085, 2005.
- [135] W. Horenkamp, W. Hube, J. Jäger, M. Kleimaier, W. Kühn, D. Nestle, R. Pickhan, M. Pokojski, T. Raphael, J. Scheffler, C. Schulz, C. Schwaegerl, D. Wielsch und R. Witzmann. *VDE-Studie Dezentrale Energieversorgung 2020*. Technischer Bericht, Verband der Elektrotechnik, Elektronik und Informationstechnik e.V. (VDE), Frankfurt am Main, Deutschland, 2007.
- [136] Y.-Y. Hsu und C.-C. Su. Dispatch of direct load control using dynamic programming. *IEEE Transactions on Power Systems*, 6(3):1056–1061, 1991.
- [137] K.-Y. Huang, H.-C. Chin und Y.-C. Huang. A model reference adaptive control strategy for interruptible load management. *IEEE Transactions on Power Systems*, 19(1):683–689, 2004.

- [138] K.-Y. Huang und Y.-C. Huang. Integrating direct load control with interruptible load management to provide instantaneous reserves for ancillary services. *IEEE Transactions on Power Systems*, 19(3):1626–1634, 2004.
- [139] S.-J. Huang und K.-R. Shih. Short-term load forecasting via ARMA model identification including non-Gaussian process considerations. *IEEE Transactions on Power Systems*, 18(2):673–679, 2003.
- [140] V. L. Huang, A. K. Qin, K. Deb, E. Zitzler, P. N. Suganthan, J. J. Liang, M. Preuss und S. Huband. *Problem definitions for performance assessment of multi-objective optimization algorithms*. Technischer Bericht, Nanyang Technological University, Singapur, 2007.
- [141] S. Huband, P. Hingston, L. Barone und L. While. A review of multiobjective test problems and a scalable test problem toolkit. *IEEE Transactions on Evolutionary Computation*, 10(5):477–506, 2006.
- [142] C.-L. Hwang und K. Yoon. *Multiple attribute decision making: Methods and applications*, Band 186 von *Lecture Notes in Economics and Mathematical Systems*. Springer Berlin Heidelberg, 1981.
- [143] C. Ibars, M. Navarro und L. Giupponi. Distributed demand management in smart grid with a congestion game. In *International Conference on Smart Grid Communications (SmartGridComm)*, S. 495–500. IEEE, 2010.
- [144] International Energy Agency. Worldwide survey of network-driven demand-side management projects, 2008. 2. Ausgabe.
- [145] G. C. James. Analytical methods for scientific demand response. In *Australasian Universities Power Engineering Conference (AUPEC)*. IEEE, 2008.
- [146] N. R. Jennings, K. Sycara und M. J. Wooldridge. A roadmap of agent research and development. *Autonomous Agents and Multi-Agent Systems*, 1(1):7–38, 1998.

-
- [147] H. Joumaa, S. Ploix, S. Abras und G. D. Oliveira. A MAS integrated into home automation system, for the resolution of power management problem in smart homes. *Energy Procedia*, 6:786–794, 2011.
- [148] Z. Jun, L. Junfeng, W. Jie und H. W. Ngan. A multi-agent solution to energy management in hybrid renewable energy generation system. *Renewable Energy*, 36(5):1352–1363, 2011.
- [149] J. Kacprzyk und W. Pedrycz (Hrsg.). *Springer handbook of computational intelligence*. Springer Berlin Heidelberg, 2015.
- [150] M. Kahl. *Cooperative predictive control to enhance power system security*. Dissertation, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2014.
- [151] M. Kahl, C. Freye und T. Leibfried. A cooperative multi-area optimization with renewable generation and storage devices. *IEEE Transactions on Power Systems*, PP(99), 2014.
- [152] M. Kahl und T. Leibfried. Decentralized model predictive control of electrical power systems. In *International Conference on Power Systems Transients (IPST)*. 2013.
- [153] M. Kahl, S. Wenig und T. Leibfried. Dezentrale modellprädiktive Optimierungsstrategien zur Einbindung erneuerbarer Erzeugungskapazität und Speichersysteme. In *Konferenz für Nachhaltige Energieversorgung und Integration von Speichern (NEIS)*. 2013.
- [154] A. Kamper. *Dezentrales Lastmanagement zum Ausgleich kurzfristiger Abweichungen im Stromnetz*. Dissertation, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2010.
- [155] A. Kamper und A. Eßer. Strategies for decentralised balancing power. In A. Lewis, S. Mostaghim und M. Randall (Hrsg.), *Biologically-Inspired Optimisation Methods: Parallel Algorithms, Systems and Applications*, Band 210 von *Studies in Computational Intelligence*, S. 261–289. Springer Berlin Heidelberg, 2009.
- [156] A. Kamper und H. Schmeck. Adaptives verteiltes Lastmanagement in Bilanzkreisen. *Informatik-Spektrum*, 35(2):102–111, 2012.

- [157] Z. Kang und H. Wang. A novel approach to allocate cloud resource with different performance traits. In *International Conference on Services Computing (SCC)*, S. 128–135. IEEE, 2013.
- [158] A. Khodaei, M. Shahidehpour und S. Bahramirad. SCUC with hourly demand response considering intertemporal load characteristics. *IEEE Transactions on Smart Grid*, 2(3):564–571, 2011.
- [159] J.-H. Kim und A. Shcherbakova. Common failures of demand response. *Energy*, 36(2):873–880, 2011.
- [160] G. Kirchgässner, J. Wolters und U. Hassler. *Introduction to modern time series analysis*. Springer Texts in Business and Economics. Springer Heidelberg New York Dordrecht London, 2. Auflage, 2013.
- [161] S. Kishore und L. V. Snyder. Control mechanisms for residential electricity demand in smartgrids. In *International Conference on Smart Grid Communications (SmartGridComm)*, S. 443–448. IEEE, 2010.
- [162] L. Klein, J. Kwak, G. Kavulya, F. Jazizadeh, B. Becerik-Gerber, P. Varakantham und M. Tambe. Coordinating occupant behavior for building energy and comfort management using multi-agent systems. *Automation in Construction*, 22:525–536, 2012.
- [163] S. Kochanneck, C. Hirsch, I. Mauser, H. Schmeck und M. Schröder. Bottom-up simulation of suburban power grids. In *International ETG Congress: Die Energiewende*. VDE Verlag GmbH, 2015.
- [164] J. K. Kok, C. J. Warmer und I. G. Kamphuis. PowerMatcher: Multiagent control in the electricity infrastructure. In *International Conference on Autonomous Agents and Multiagent Systems (AAMAS)*, S. 75–82. ACM, 2005.
- [165] K. Kok, B. Roossien, P. MacDougall, O. van Pruissen, G. Venekamp, R. Kamphuis, J. Laarakkers und C. Warmer. Dynamic pricing by scalable energy management systems – Field experiences and simulation results using PowerMatcher. In *Power and Energy Society General Meeting (PES GM)*. IEEE, 2012.

- [166] F. Kupzog. Self-controlled exploitation of energy cost saving potentials by implementing distributed demand side management. In *International Conference on Industrial Informatics (INDIN)*, S. 375–380. IEEE, 2006.
- [167] E. Kyriakides und M. Polycarpou. Short term electric load forecasting: A tutorial. In K. Chen und L. Wang (Hrsg.), *Trends in Neural Computation*, Band 35 von *Studies in Computational Intelligence*, S. 391–418. Springer Berlin Heidelberg, 2007.
- [168] R. H. Lasseter. MicroGrids. In *Power Engineering Society Winter Meeting (PES WM)*, Band 1, S. 305–308. IEEE, 2002.
- [169] Y. W. Law, T. Alpcan, V. C. S. Lee, A. Lo, S. Marusic und M. Palaniswami. Demand response architectures and load management algorithms for energy-efficient power grids: A survey. In *International Conference on Knowledge, Information and Creativity Support Systems (KICSS)*, S. 134–141. IEEE, 2012.
- [170] S. H. Lee und C. L. Wilkins. A practical approach to appliance load control analysis: A water heater case study. *IEEE Transactions on Power Apparatus and Systems*, 102(4):1007–1013, 1983.
- [171] S. Lehnhoff. *Dezentrales vernetztes Energiemanagement. Ein Ansatz auf Basis eines verteilten adaptiven Realzeit-Multiagentensystems*. Vieweg+Teubner, 2010.
- [172] M. LeMay, R. Nelli, G. Gross und C. A. Gunter. An integrated architecture for demand response communications and control. In *Hawaii International Conference on System Sciences (HICSS)*. IEEE, 2008.
- [173] D. Li, S. K. Jayaweera und A. Naseri. Auctioning game based demand response scheduling in smart grid. In *Online Conference on Green Communications (GreenCom)*, S. 58–63. IEEE, 2011.
- [174] J. Li, G. James und G. Poulton. Set-points based optimal multi-agent coordination for controlling distributed energy loads. In *International Conference on Self-Adaptive and Self-Organizing Systems (SASO)*, S. 265–271. IEEE, 2009.

- [175] J. Li, G. Poulton und G. James. Agent-based distributed energy management. In M. A. Orgun und J. Thornton (Hrsg.), *AI 2007: Advances in Artificial Intelligence: 20th Australian Joint Conference on Artificial Intelligence, Gold Coast, Australia, December 2–6, 2007. Proceedings*, Band 4830 von *LNCS*, S. 569–578. Springer Berlin Heidelberg, 2007.
- [176] J. Li, G. Poulton und G. James. Coordination of distributed energy resource agents. *Applied Artificial Intelligence*, 24(5):351–380, 2010.
- [177] N. W. A. Lidula und A. D. Rajapakse. Microgrids research: A review of experimental microgrids and test systems. *Renewable and Sustainable Energy Reviews*, 15(1):186–202, 2011.
- [178] L. Liu. *Organic service-level management in service-oriented environments*. Dissertation, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2011.
- [179] T. Logenthiran, D. Srinivasan und A. M. Khambadkone. Multi-agent system for energy resource scheduling of integrated microgrids in a distributed system. *Electric Power Systems Research*, 81(1):138–148, 2011.
- [180] Z. Lu, J. Zhang, T. Feng und H. Cheng. Distributed agent-based state estimation considering controlled coordination layer. *International Journal of Electrical Power & Energy Systems*, 54:569–575, 2014.
- [181] R. Mamlook, O. Badran und E. Abdulhadi. A fuzzy inference model for short-term load forecasting. *Energy Policy*, 37(4):1239–1248, 2009.
- [182] A. Mas-Colell, M. D. Whinston und J. R. Green. *Microeconomic theory*. Oxford University Press New York, 1995.
- [183] E. Mashhour und S. M. Moghaddas-Tafreshi. Bidding strategy of virtual power plant for participating in energy and spinning reserve markets—Part I: Problem formulation. *IEEE Transactions on Power Systems*, 26(2):949–956, 2011.
- [184] E. Mashhour und S. M. Moghaddas-Tafreshi. Bidding strategy of virtual power plant for participating in energy and spinning reserve

- markets—Part II: Numerical analysis. *IEEE Transactions on Power Systems*, 26(2):957–964, 2011.
- [185] K. Matsumoto, Y. Takamuki, N. Mori und M. Kitayama. An interactive approach to demand side management based on utility functions. In *International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT)*, S. 147–150. IEEE, 2000.
- [186] I. Mauser. *Kurzfristiges Lastmanagement in einem Smart Home und Bereitstellung von Netzdienstleistungen*. Diplomarbeit, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2012.
- [187] I. Mauser, M. Dorscheid, F. Allerding und H. Schmeck. Encodings for evolutionary algorithms in smart buildings with energy management systems. In *Congress on Evolutionary Computation (CEC)*, S. 2361–2366. IEEE, 2014.
- [188] I. Mauser, M. Dorscheid und H. Schmeck. Run-time parameter selection and tuning for energy optimization algorithms. In T. Bartz-Beielstein, J. Branke, B. Filipič und J. Smith (Hrsg.), *Parallel Problem Solving from Nature – PPSN XIII: 13th International Conference, Ljubljana, Slovenia, September 13–17, 2014. Proceedings*, Band 8672 von LNCS, S. 80–89. Springer International Publishing, 2014.
- [189] I. Mauser, J. Feder, J. Müller und H. Schmeck. Evolutionary optimization of smart buildings with interdependent devices. In A. M. Mora und G. Squillero (Hrsg.), *Applications of Evolutionary Computation: 18th European Conference, EvoApplications 2015, Copenhagen, Denmark, April 8–10, 2015, Proceedings*, Band 9028 von LNCS, S. 239–251. Springer International Publishing, 2015.
- [190] I. Mauser, C. Hirsch, S. Kochanneck und H. Schmeck. Organic architecture for energy management and smart grids. In *International Conference on Autonomic Computing (ICAC)*, S. 101–108. IEEE, 2015.
- [191] I. Mauser und H. Schmeck. Tarife zur Flexibilisierung des Stromverbrauchs in Haushalten mit Energiemanagementsystemen. In *VDE-Kongress 2014: Smart Cities*. VDE Verlag GmbH, 2014.

- [192] S. D. J. McArthur, C. D. Booth, J. R. McDonald und I. T. McFadyen. An agent-based anomaly detection architecture for condition monitoring. *IEEE Transactions on Power Systems*, 20(4):1675–1682, 2005.
- [193] S. D. J. McArthur, E. M. Davidson, V. M. Catterson, A. L. Dimeas, N. D. Hatziargyriou, F. Ponci und T. Funabashi. Multi-agent systems for power engineering applications—Part I: Concepts, approaches, and technical challenges. *IEEE Transactions on Power Systems*, 22(4):1743–1752, 2007.
- [194] S. D. J. McArthur, E. M. Davidson, V. M. Catterson, A. L. Dimeas, N. D. Hatziargyriou, F. Ponci und T. Funabashi. Multi-agent systems for power engineering applications—Part II: Technologies, standards, and tools for building multi-agent systems. *IEEE Transactions on Power Systems*, 22(4):1753–1759, 2007.
- [195] J. Medina, N. Muller und I. Roytelman. Demand response and distribution grid operations: Opportunities and challenges. *IEEE Transactions on Smart Grid*, 1(2):193–198, 2010.
- [196] H. Meier, C. Fünfgeld und B. Schieferdecker. Repräsentative VDEW-Lastprofile. VDEW-Materialien M-28/99, 1999.
- [197] M. Merdan, W. Lepuschitz, T. Strasser und F. Andren. Multi-agent system for self-optimizing power distribution grids. In *International Conference on Automation, Robotics and Applications (ICARA)*, S. 312–317. IEEE, 2011.
- [198] R. Merris. *Combinatorics*. John Wiley & Sons, 2003.
- [199] P. Merz und K. Katayama. Memetic algorithms for the unconstrained binary quadratic programming problem. *Biosystems*, 78(1):99–118, 2004.
- [200] S. Mhanna, G. Verbič und A. C. Chapman. Guidelines for realistic grounding of mechanism design in demand response. In *Australasian Universities Power Engineering Conference (AUPEC)*. IEEE, 2014.

-
- [201] F. Milano, C. A. Canizares und M. Invernizzi. Multiobjective optimization for pricing system security in electricity markets. *IEEE Transactions on Power Systems*, 18(2):596–604, 2003.
- [202] M. P. Moghaddam, A. Abdollahi und M. Rashidinejad. Flexible demand response programs modeling in competitive electricity markets. *Applied Energy*, 88(9):3257–3269, 2011.
- [203] A. Molderink, V. Bakker, J. L. Hurink und G. J. M. Smit. Comparing demand side management approaches. In *International Conference and Exhibition on Innovative Smart Grid Technologies Europe (ISGT Europe)*. IEEE, 2012.
- [204] J. Morren, S. W. H. de Haan und J. A. Ferreira. Contribution of DG units to primary frequency control. *European Transactions on Electrical Power*, 16(5):507–521, 2006.
- [205] F. Mösch, M. Litza, A. El Sayed Auf, E. Maehle, K. E. Großpietsch und W. Brockmann. ORCA – Towards an organic robotic control architecture. In H. de Meer und J. P. G. Sterbenz (Hrsg.), *Self-Organizing Systems: First International Workshop, IWSOS 2006, and Third International Workshop on New Trends in Network Architectures and Services, EuroNGI 2006, Passau, Germany, September 18–20, 2006 Proceedings*, Band 4124 von LNCS, S. 251–253. Springer Berlin Heidelberg, 2006.
- [206] A. L. Motto, F. D. Galiana, A. J. Conejo und J. M. Arroyo. Network-constrained multiperiod auction for a pool-based electricity market. *IEEE Transactions on Power Systems*, 17(3):646–653, 2002.
- [207] C. Müller-Schloer. Organic Computing – On the feasibility of controlled emergence. In *International Conference on Hardware/Software Codesign and System Synthesis (CODES+ISSS)*. ACM, 2004.
- [208] C. Müller-Schloer und H. Schmeck. Organic Computing: A grand challenge for mastering complex systems. *it – Information Technology*, 52(3):135–141, 2010.
- [209] C. Müller-Schloer, H. Schmeck und T. Ungerer (Hrsg.). *Organic Computing – A paradigm shift for complex systems*. Autonomic Systems. Springer Basel, 2011.

- [210] C. Müller-Schloer, C. von der Malsburg und R. P. Würtz. Organic Computing. *Informatik Spektrum*, 27(4):332–336, 2004.
- [211] M. Mültin. *Das Elektrofahrzeug als flexibler Verbraucher und Energiespeicher im Smart Home*. Dissertation, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2014.
- [212] D. Nestle. *Energiemanagement in der Niederspannungsversorgung mittels dezentraler Entscheidung. – Konzept, Algorithmen, Kommunikation und Simulation –*. Dissertation, Universität Kassel, Kassel, Deutschland, 2008.
- [213] D. G. Neumann. *Market engineering. A structured design process for electronic markets*. Dissertation, Universität Karlsruhe, Karlsruhe, Deutschland, 2007.
- [214] G. R. Newsham und B. G. Bowker. The effect of utility time-varying pricing and load control strategies on residential summer peak electricity use: A review. *Energy Policy*, 38(7):3289–3296, 2010.
- [215] K.-H. Ng und G. B. Sheblé. Direct load control - A profit-based load management using linear programming. *IEEE Transactions on Power Systems*, 13(2):688–694, 1998.
- [216] D. T. Nguyen, M. Negnevitsky und M. de Groot. Pool-based demand response exchange—Concept and modeling. *IEEE Transactions on Power Systems*, 26(3):1677–1685, 2011.
- [217] D. T. Nguyen, M. Negnevitsky und M. de Groot. Walrasian market clearing for demand response exchange. *IEEE Transactions on Power Systems*, 27(1):535–544, 2012.
- [218] H. Nilsson. The many faces of demand-side management. *Power Engineering Journal*, 8(5):207–210, 1994.
- [219] D. Niu, H. Shi und D. D. Wu. Short-term load forecasting using bayesian neural networks learned by hybrid monte carlo algorithm. *Applied Soft Computing*, 12(6):1822–1827, 2012.

-
- [220] D. Niu, Y. Wang und D. D. Wu. Power load forecasting using support vector machine and ant colony optimization. *Expert Systems with Applications*, 37(3):2531–2539, 2010.
- [221] A. Nourai, V. I. Kogan und C. M. Schafer. Load leveling reduces T&D line losses. *IEEE Transactions on Power Delivery*, 23(4):2168–2173, 2008.
- [222] G. Ochoa. Setting the mutation rate: Scope and limitations of the $1/L$ heuristic. In *Genetic and Evolutionary Computation Conference (GECCO)*, S. 495–502. Morgan Kaufmann Publishers, 2002.
- [223] F. Oldewurtel, A. Ulbig, A. Parisio, G. Andersson und M. Morari. Reducing peak electricity demand in building climate control using real-time pricing and model predictive control. In *Conference on Decision and Control (CDC)*, S. 1927–1932. IEEE, 2010.
- [224] M. A. Olson, S. J. Rassenti, V. L. Smith, M. L. Rigdon und M. J. Ziegler. Market design and motivated human trading behavior in electricity markets. In *Hawaii International Conference on System Sciences (HICSS)*. IEEE, 1999.
- [225] I. H. Osman und J. P. Kelly. Meta-heuristics: An overview. In I. H. Osman und J. P. Kelly (Hrsg.), *Meta-Heuristics: Theory and Applications*, Kapitel 1, S. 1–21. Springer US, 1996.
- [226] I. H. Osman und G. Laporte. Metaheuristics: A bibliography. *Annals of Operations Research*, 63(5):511–623, 1996.
- [227] N. P. Padhy. Unit commitment—A bibliographical survey. *IEEE Transactions on Power Systems*, 19(2):1196–1205, 2004.
- [228] P. Palensky und D. Dietrich. Demand side management: Demand response, intelligent energy systems, and smart loads. *IEEE Transactions on Industrial Informatics*, 7(3):381–388, 2011.
- [229] L. Panait und S. Luke. Cooperative multi-agent learning: The state of the art. *Autonomous Agents and Multi-Agent Systems*, 11(3):387–434, 2005.

- [230] S. C. Pandian, K. Duraiswamy, C. C. A. Rajan und N. Kanagaraj. Fuzzy approach for short term load forecasting. *Electric Power Systems Research*, 76(6–7):541–548, 2006.
- [231] H. Pandžić, I. Kuzle und T. Capuder. Virtual power plant mid-term dispatch optimization. *Applied Energy*, 101:134–141, 2013.
- [232] A. Pankratz. *Forecasting with univariate Box-Jenkins models: Concepts and cases*. John Wiley & Sons, 1983.
- [233] S. S. Pappas, L. Ekonomou, D. C. Karamousantas, G. E. Chatzarakis, S. K. Katsikas und P. Liatsis. Electricity demand loads modeling using autoregressive moving average (ARMA) models. *Energy*, 33(9):1353–1360, 2008.
- [234] Z. J. Paracha und P. Doulai. Load management: Techniques and methods in electric power system. In *International Conference on Energy Management and Power Delivery (EMPD)*, S. 213–217. IEEE, 1998.
- [235] P. M. Pardalos und S. Jha. Graph separation techniques for quadratic zero-one programming. *Computers & Mathematics with Applications*, 21(6–7):107–113, 1991.
- [236] P. M. Pardalos und N. Koor. An algorithm for a singly constrained class of quadratic programs subject to upper and lower bounds. *Mathematical Programming*, 46(3):321–328, 1990.
- [237] V. Pareto. *Manuale di economia politica*. Società Editrice Libreria, Mailand, Italien, 1906.
- [238] V. Pareto. *Manual of political economy*. Augustus M. Kelley Publishers, New York, USA, 1971.
- [239] S.-J. Park und J.-T. Lim. Modelling and control of agent-based power protection systems using supervisors. *IEE Proceedings on Control Theory and Applications*, 153(1):92–98, 2006.
- [240] J. A. Peças Lopes, N. Hatziargyriou, J. Mutale, P. Djapic und N. Jenkins. Integrating distributed generation into electric power systems: A review of drivers, challenges and opportunities. *Electric power systems research*, 77(9):1189–1203, 2007.

- [241] M. Peik-Herfeh, H. Seifi und M. K. Sheikh-El-Eslami. Decision making of a virtual power plant under uncertainties for bidding in a day-ahead market using point estimate method. *International Journal of Electrical Power & Energy Systems*, 44(1):88–98, 2013.
- [242] L. Phillips, H. Link, R. Smith und L. Weiland. *Agent-based control of distributed infrastructure resources*. Technischer Bericht, Sand National Laboratories, Albuquerque, NM und Livermore, CA, USA, 2006.
- [243] J. C. Picard und H. D. Ratliff. Minimum cuts and related problems. *Networks*, 5(4):357–370, 1975.
- [244] N. M. Pindoriya, S. N. Singh und K. Y. Lee. A comprehensive survey on multi-objective evolutionary optimization in power system applications. In *Power and Energy Society General Meeting (PES GM)*. IEEE, 2010.
- [245] M. Pipattanasomporn, H. Feroze und S. Rahman. Multi-agent systems in a distributed smart grid: Design and implementation. In *Power Systems Conference and Exposition (PSCE)*. IEEE, 2009.
- [246] E. Pournaras, M. Warnier und F. M. T. Brazier. Local agent-based self-stabilisation in global resource utilisation. *International Journal of Autonomic Computing*, 1(4):350–373, 2010.
- [247] A. Probst, M. Braun und S. Tenbohlen. Erstellung und Simulation probabilistischer Lastmodelle von Haushalten und Elektrofahrzeugen zur Spannungsbandanalyse. In *Internationaler ETG-Kongress: Umsetzungskonzepte nachhaltiger Energiesysteme*. VDE Verlag GmbH, 2011.
- [248] H. Prothmann. *Organic traffic control*. Dissertation, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2011.
- [249] H. Prothmann, J. Branke, H. Schmeck, S. Tomforde, F. Rochner, J. Hähner und C. Müller-Schloer. Organic traffic light control for urban road networks. *International Journal of Autonomous and Adaptive Communications Systems*, 2(3):203–225, 2009.

- [250] A. Prügel-Bennett. Benefits of a population: Five mechanisms that advantage population-based algorithms. *IEEE Transactions on Evolutionary Computation*, 14(4):500–517, 2010.
- [251] D. Pudjianto, C. Ramsay und G. Strbac. Virtual power plant and system integration of distributed energy resources. *IET Renewable Power Generation*, 1(1):10–16, 2007.
- [252] V. Quaschnig und R. Hanitsch. Lastmanagement einer zukünftigen Energieversorgung. *Brennstoff Wärme Kraft*, 51(10):64–67, 1999.
- [253] G. Rabensteiner. Ein Modell zur kombinierten Kraftwerks- und Netzausbauplanung elektroenergetischer Systeme unter Anwendung der gemischt-ganzzahligen Programmierung. *Zeitschrift für Operations Research*, 27(1):B73–B89, 1983.
- [254] S. Rahman und O. Hazim. Load forecasting for multiple sites: Development of an expert system-based technique. *Electric Power Systems Research*, 39(3):161–169, 1996.
- [255] B. Ramanathan und V. Vittal. A framework for evaluation of advanced direct load control with minimum disruption. *IEEE Transactions on Power Systems*, 23(4):1681–1688, 2008.
- [256] S. D. Ramchurn, P. Vytelingum, A. Rogers und N. R. Jennings. Agent-based homeostatic control for green energy in the smart grid. *ACM Transactions on Intelligent Systems and Technology*, 2(4):35:1–35:28, 2011.
- [257] S. D. Ramchurn, P. Vytelingum, A. Rogers und N. R. Jennings. Putting the ‘smarts’ into the smart grid: A grand challenge for artificial intelligence. *Communications of the ACM*, 55(4):86–97, 2012.
- [258] M. S. S. Rao, S. A. Soman, B. L. Menezes, P. Chawande, P. Dipti und T. Ghanshyam. An expert system approach to short-term load forecasting for Reliance Energy Limited, Mumbai. In *Power India Conference*. IEEE, 2006.

- [259] F. Ren, M. Zhang, D. Soetanto und X. Su. Conceptual design of a multi-agent system for interconnected power systems restoration. *IEEE Transactions on Power Systems*, 27(2):732–740, 2012.
- [260] U. Richter. *Controlled self-organisation using learning classifier systems*. Dissertation, Karlsruher Institut für Technologie, Karlsruhe, Deutschland, 2009.
- [261] F. Rigoll, C. Hirsch, S. Kochanneck, H. Schmeck und I. Mauser. A privacy-aware architecture for energy management systems in smart grids. In B. O. Apduhan, Y. Zheng, Y. Nakamoto, P. Thulasiraman, H. Ning und Y. Sun (Hrsg.), *International Conference on Autonomic & Trusted Computing (ATC)*, S. 449–455. IEEE, 2014.
- [262] D. E. Rumelhart, G. E. Hinton und R. J. Williams. Learning representations by back-propagating errors. *Nature*, 323:533–536, 1986.
- [263] S. J. Russell und P. Norvig. *Artificial intelligence: A modern approach*. Prentice Hall, 3. Auflage, 2009.
- [264] S. Ruthe, C. Rehtanz und S. Lehnhoff. A market-oriented stochastic optimization framework and its application in the energy domain. In *Conference of the IEEE Industrial Electronics Society (IECON)*, S. 4721–4726. IEEE, 2013.
- [265] S. Ruthe, C. Rehtanz und S. Lehnhoff. On the problem of controlling shiftable prosumer devices with price signals. In *Power Systems Computation Conference (PSCC)*. 2014.
- [266] W. Saad, Z. Han, H. V. Poor und T. Basar. Game-theoretic methods for the smart grid: An overview of microgrid systems, demand-side management, and smart grid communications. *IEEE Signal Processing Magazine*, 29(5):86–105, 2012.
- [267] P. Samadi, H. Mohsenian-Rad, R. Schober und V. W. S. Wong. Advanced demand side management for the future smart grid using mechanism design. *IEEE Transactions on Smart Grid*, 3(3):1170–1180, 2012.

- [268] S. Sargunaraaj, D. Sen Gupta und S. Devi. Short-term load forecasting for demand side management. *IEE Proceedings – Generation, Transmission and Distribution*, 144(1):68–74, 1997.
- [269] H. Schmeck. Organic Computing – A new vision for distributed embedded systems. In *International Symposium on Object-Oriented Real-Time Distributed Computing (ISORC)*, S. 201–203. IEEE, 2005.
- [270] A. J. Schwab. *Elektroenergiesysteme: Erzeugung, Transport, Übertragung und Verteilung elektrischer Energie*. Springer Berlin Heidelberg, 3. Auflage, 2012.
- [271] H. Seebach, F. Ortmeier und W. Reif. Design and construction of organic computing systems. In *Congress on Evolutionary Computation (CEC)*, S. 4215–4221. IEEE, 2007.
- [272] T. Senjyu, H. Takara, K. Uezato und T. Funabashi. One-hour-ahead load forecasting using neural network. *IEEE Transactions on Power Systems*, 17(1):113–118, 2002.
- [273] A. Seppälä. Statistical distribution of customer load profiles. In *International Conference on Energy Management and Power Delivery (EMPD)*, Band 2, S. 696–701. IEEE, 1995.
- [274] A. Seppälä. *Load research and load estimation in electricity distribution*. Dissertation, Helsinki University of Technology, Espoo, Finnland, 1996.
- [275] F. Shariatzadeh, P. Mandal und A. K. Srivastava. Demand response for sustainable energy systems: A review, application and implementation strategy. *Renewable and Sustainable Energy Reviews*, 45:343–350, 2015.
- [276] W. Shen und D. H. Norrie. Agent-based systems for intelligent manufacturing: A state-of-the-art survey. *Knowledge and Information Systems*, 1(2):129–156, 1999.
- [277] L. Sheng, K. K. Li, W. L. Chan, X. Zeng, D. Shi und X. Duan. Adaptive agent-based wide-area current differential protection system. *IEEE Transactions on Industry Applications*, 46(5):2111–2117, 2010.

- [278] P. K. Shukla. In search of proper pareto-optimal solutions using multi-objective evolutionary algorithms. In Y. Shi, G. D. van Albada, J. Dongarra und P. M. A. Sloot (Hrsg.), *Computational Science – ICCS 2007: 7th International Conference, Beijing, China, May 27–30, 2007, Proceedings, Part IV*, Band 4490 von LNCS, S. 1013–1020. Springer Berlin Heidelberg, 2007.
- [279] P. K. Shukla und K. Deb. On finding multiple Pareto-optimal solutions using classical and evolutionary generating methods. *European Journal of Operational Research*, 181(3):1630–1652, 2007.
- [280] P. K. Shukla, M. Emmerich und A. Deutz. A theoretical analysis of curvature based preference models. In R. C. Purshouse, P. J. Fleming, C. M. Fonseca, S. Greco und J. Shaw (Hrsg.), *Evolutionary Multi-Criterion Optimization: 7th International Conference, EMO 2013, Sheffield, UK, March 19–22, 2013. Proceedings*, Band 7811 von LNCS, S. 367–382. Springer Berlin Heidelberg, 2013.
- [281] P. K. Shukla, C. Hirsch und H. Schmeck. A framework for incorporating trade-off information using multi-objective evolutionary algorithms. In R. Schaefer, C. Cotta, J. Kołodziej und G. Rudolph (Hrsg.), *Parallel Problem Solving from Nature – PPSN XI: 11th International Conference, Kraków, Poland, September 11–15, 2010, Proceedings, Part I*, Band 6239 von LNCS, S. 131–140. Springer Berlin Heidelberg, 2010.
- [282] P. K. Shukla, C. Hirsch und H. Schmeck. In search of equitable solutions using multi-objective evolutionary algorithms. In R. Schaefer, C. Cotta, J. Kołodziej und G. Rudolph (Hrsg.), *Parallel Problem Solving from Nature – PPSN XI: 11th International Conference, Kraków, Poland, September 11–15, 2010, Proceedings, Part I*, Band 6238 von LNCS, S. 687–696. Springer Berlin Heidelberg, 2010.
- [283] P. K. Shukla, C. Hirsch und H. Schmeck. Towards a deeper understanding of trade-offs using multi-objective evolutionary algorithms. In C. Di Chio, A. Agapitos, S. Cagnoni, C. Cotta, F. F. de Vega, G. A. Di Caro, R. Drechsler, A. Ekárt, A. I. Esparcia-Alcázar, M. Farooq, W. B. Langdon, J. J. Merelo-Guervós, M. Preuss, H. Richter, S. Silva, A. Simões, G. Squillero, E. Tarantino, A. G. B. Tettamanzi, J. Togelius, N. Urquhart,

- A. S. Uyar und G. N. Yannakaki (Hrsg.), *Applications of Evolutionary Computation – EvoApplications 2012: EvoCOMNET, EvoCOMPLEX, EvoFIN, EvoGAMES, EvoHOT, EvoIASP, EvoNUM, EvoPAR, EvoRISK, EvoSTIM, and EvoSTOC, Málaga, Spain, April 11–13, 2012. Proceedings*, Band 7248 von LNCS, S. 396–405. Springer Berlin Heidelberg, 2012.
- [284] P. Siano. Demand response and smart grids—A survey. *Renewable and Sustainable Energy Reviews*, 30:461–478, 2014.
- [285] Smart Grid Coordination Group. *Smart grid reference architecture*. Technischer Bericht, CEN-CENELEC-ETSI, Brüssel, Belgien, 2012.
- [286] L. J. Soares und M. C. Medeiros. Modeling and forecasting short-term electricity load: A comparison of methods with an application to Brazilian data. *International Journal of Forecasting*, 24(4):630–644, 2008. Energy Forecasting.
- [287] J. M. Solanki, S. Khushalani und N. N. Schulz. A multi-agent solution to distribution systems restoration. *IEEE Transactions on Power Systems*, 22(3):1026–1034, 2007.
- [288] S. A.-H. Soliman und A.-A. H. Mantawy. *Modern optimization techniques with applications in electric power systems*. Energy Systems. Springer New York, 2012.
- [289] J. C. Sousa, L. P. Neves und H. M. Jorge. Load forecasting based on neural networks and load profiling. In *PowerTech*. IEEE, 2009.
- [290] K. Spees und L. B. Lave. Demand response and electricity market efficiency. *The Electricity Journal*, 20(3):69–85, 2007.
- [291] Statistisches Bundesamt. Bevölkerung und Erwerbstätigkeit. Haushalte und Familien. Ergebnisse des Mikrozensus, 2014. <https://www.destatis.de/DE/ZahlenFakten/GesellschaftStaat/Bevoelkerung/Haushaltsvorausberechnung/Tabelle/VorausberechnungHaushalte.html>, zuletzt abgerufen: 18.09.2015.

- [292] Statistisches Bundesamt. Preise – Daten zur Energiepreisentwicklung, 2015. https://www.destatis.de/DE/Publikationen/Thematisch/Preise/Energiepreise/EnergiepreisentwicklungPDF_5619001.pdf, zuletzt abgerufen: 18.09.2015.
- [293] P. Stone und M. Veloso. Multiagent systems: A survey from a machine learning perspective. *Autonomous Robots*, 8(3):345–383, 2000.
- [294] G. Strbac. Demand side management: Benefits and challenges. *Energy Policy*, 36(12):4419–4426, 2008.
- [295] G. Strbac und D. Kirschen. Assessing the competitiveness of demand-side bidding. *IEEE Transactions on Power Systems*, 14(1):120–125, 1999.
- [296] C. L. Su. *Optimal demand-side participation in day-ahead electricity markets*. Dissertation, Universität Manchester, Manchester, UK, 2007.
- [297] C.-L. Su und D. Kirschen. Quantifying the effect of demand response on electricity markets. *IEEE Transactions on Power Systems*, 24(3):1199–1207, 2009.
- [298] J. Taft und P. De Martini. Ultra-large scale control architecture. In *Innovative Smart Grid Technologies (ISGT)*. IEEE, 2013.
- [299] E.-G. Talbi, M. Basseur, A. J. Nebro und E. Alba. Multi-objective optimization using metaheuristics: Non-standard algorithms. *International Transactions in Operational Research*, 19(1-2):283–305, 2012.
- [300] J. W. Taylor. Short-term electricity demand forecasting using double seasonal exponential smoothing. *The Journal of the Operational Research Society*, 54(8):799–805, 2003.
- [301] J. W. Taylor und P. E. McSharry. Short-term load forecasting methods: An evaluation based on european data. *IEEE Transactions on Power Systems*, 22(4):2213–2219, 2007.
- [302] G. Theraulaz und E. Bonabeau. A brief history of stigmergy. *Artificial Life*, 5(2):97–116, 1999.

- [303] A. Tidemann, B. A. Høverstad, H. Langseth und P. Öztürk. Effects of scale on load prediction algorithms. In *International Conference and Exhibition on Electricity Distribution (CIRED)*. IET, 2013.
- [304] J. Torriti, M. G. Hassan und M. Leach. Demand response experience in Europe: Policies, programmes and implementation. *Energy*, 35(4):1575–1583, 2010.
- [305] M. Tröschel. *Aktive Einsatzplanung in holonischen Virtuellen Kraftwerken*. Dissertation, Carl von Ossietzky Universität Oldenburg, Oldenburg, Deutschland, 2010.
- [306] L. A. Tuan und K. Bhattacharya. Competitive framework for procurement of interruptible load services. *IEEE Transactions on Power Systems*, 18(2):889–897, 2003.
- [307] H. Van Dyke Parunak, S. Brueckner, M. Fleischer und J. Odell. A design taxonomy of multi-agent interactions. In P. Giorgini, J. P. Müller und J. Odell (Hrsg.), *Agent-Oriented Software Engineering IV: 4th International Workshop, AOSE 2003, Melbourne, Australia, July 15, 2003. Revised Papers*, Band 2935 von LNCS, S. 123–137. Springer Berlin Heidelberg, 2004.
- [308] D. A. Van Veldhuizen. *Multiobjective evolutionary algorithms: Classifications, analyses, and new innovations*. Dissertation, Air Force Institute of Technology, Ohio, USA, 1999.
- [309] M. Vasirani, R. Kota, R. L. G. Cavalcante, S. Ossowski und N. R. Jennings. An agent-based approach to virtual power plants of wind power generators and electric vehicles. *IEEE Transactions on Smart Grid*, 4(3):1314–1322, 2013.
- [310] A. Veit, C. Goebel, R. Tidke, C. Doblander und H.-A. Jacobsen. Household electricity demand forecasting – Benchmarking state-of-the-art methods. *ArXiv e-prints 1404.0200*, 2014.
- [311] C. Vivekananthan, Y. Mishra, G. Ledwich und F. Li. Demand response for residential appliances via customer reward scheme. *IEEE Transactions on Smart Grid*, 5(2):809–820, 2014.

-
- [312] E. Vrettos, S. Koch und G. Andersson. Load frequency control by aggregations of thermally stratified electric water heaters. In *International Conference and Exhibition on Innovative Smart Grid Technologies Europe (ISGT Europe)*. IEEE, 2012.
- [313] C. J. Wallace, G. M. West, S. D. J. McArthur und D. Towle. Distributed data and information fusion for nuclear reactor condition monitoring. *IEEE Transactions on Nuclear Science*, 59(1):182–189, 2012.
- [314] R. A. Walling, R. Saint, R. C. Dugan, J. Burke und L. A. Kojovic. Summary of distributed resources impact on power delivery systems. *IEEE Transactions on Power Delivery*, 23(3):1636–1644, 2008.
- [315] J. Wang, S. Kennedy und J. Kirtley. A new wholesale bidding mechanism for enhanced demand response in smart grids. In *Innovative Smart Grid Technologies (ISGT)*. IEEE, 2010.
- [316] Z. Wang, R. Yang und L. Wang. Intelligent multi-agent control for integrated building and micro-grid systems. In *Innovative Smart Grid Technologies (ISGT)*. IEEE, 2011.
- [317] P. Warren. A review of demand-side management policy in the UK. *Renewable and Sustainable Energy Reviews*, 29:941–951, 2014.
- [318] W. W. Weaver und P. T. Krein. Game-theoretic control of small-scale power systems. *IEEE Transactions on Power Delivery*, 24(3):1560–1567, 2009.
- [319] L. A. Wehinger, G. Hug-Glanzmann, M. D. Galus und G. Andersson. Modeling electricity wholesale markets with model predictive and profit maximizing agents. *IEEE Transactions on Power Systems*, 28(2):868–876, 2013.
- [320] D.-C. Wei und N. Chen. Air conditioner direct load control by multi-pass dynamic programming. *IEEE Transactions on Power Systems*, 10(1):307–313, 1995.
- [321] K. Weicker. *Evolutionäre Algorithmen*. Springer Science+Business Media, 2. Auflage, 2007.

- [322] A. Weidlich und D. Veit. A critical survey of agent-based wholesale electricity market models. *Energy Economics*, 30(4):1728–1759, 2008.
- [323] R. Weihmayer und H. Velthuijsen. Intelligent agents in telecommunications. In N. R. Jennings und M. J. Wooldridge (Hrsg.), *Agent Technology: Foundations, Applications, and Markets*, S. 203–217. Springer Berlin Heidelberg, 1998.
- [324] R. Weron. *Modeling and forecasting electricity loads and prices: A statistical approach*. John Wiley & Sons, 2007.
- [325] B. Wille-Haussmann, T. Erge und C. Wittwer. Decentralised optimisation of cogeneration in virtual power plants. *Solar Energy*, 84(4):604–611, 2010.
- [326] T. Wolf und T. Holvoet. Emergence versus self-organisation: Different concepts but promising when combined. In S. A. Brueckner, G. Di Marzo Serugendo, A. Karageorgos und R. Nagpal (Hrsg.), *Engineering Self-Organising Systems: Methodologies and Applications*, Band 3464 von *LNAI*, S. 1–15. Springer Berlin Heidelberg, 2005.
- [327] M. J. Wooldridge und N. R. Jennings. Agent theories, architectures, and languages: A survey. In M. J. Wooldridge und N. R. Jennings (Hrsg.), *Intelligent Agents: ECAI-94 Workshop on Agent Theories, Architectures, and Languages, Amsterdam, The Netherlands August 8–9, 1994. Proceedings*, Band 890 von *LNCS*, S. 1–39. Springer Berlin Heidelberg, 1995.
- [328] H. Wu, M. Shahidehpour und M. E. Khodayar. Hourly demand response in day-ahead scheduling considering generating unit ramping cost. *IEEE Transactions on Power Systems*, 28(3):2446–2454, 2013.
- [329] M. Wünsche, S. Mostaghim, H. Schmeck, T. Kautzmann und M. Geimer. Organic Computing in off-highway machines. In *International Workshop on Self-Organizing Architectures (SOAR)*, S. 51–58. ACM, 2010.


-
- [330] Y. Xin, I. Baldine, J. Chase, T. Beyene, B. Parkhurst und A. Chakraborty. Virtual smart grid architecture and control framework. In *International Conference on Smart Grid Communications (SmartGridComm)*. IEEE, 2011.
- [331] F. Ygge und H. Akkermans. Power load management as a computational market. In *International Conference on Multi-Agent Systems (ICMAS)*. AAAI Press, 1996.
- [332] S. Ying. *Auswirkungen auf die Niederspannungsnetze bei hoher Penetration von innerstädtischen Photovoltaikanlagen und Elektrofahrzeugen*. Dissertation, TU Cottbus, Cottbus, Deutschland, 2011.
- [333] K. Yoon und C.-L. Hwang. Manufacturing plant location analysis by multiple attribute decision making: Part I—Single-plant strategy. *International Journal of Production Research*, 23(2):345–359, 1985.
- [334] A. Zaballos, A. Vallejo und J. M. Selga. Heterogeneous communication architecture for the smart grid. *IEEE Network*, 25(5):30–37, 2011.
- [335] S. H. Zanakis, A. Solomon, N. Wishart und S. Dublish. Multi-attribute decision making: A simulation comparison of select methods. *European Journal of Operational Research*, 107(3):507–529, 1998.
- [336] A. Zeman, M. Prokopenko, Y. Guo und R. Li. Adaptive control of distributed energy management: A comparative study. In S. Brueckner, P. Robertson und U. Bellur (Hrsg.), *International Conference on Self-Adaptive and Self-Organizing Systems (SASO)*, S. 84–93. IEEE, 2008.
- [337] G. Zhabelova und V. Vyatkin. Multiagent smart grid automation architecture based on IEC 61850/61499 intelligent logical nodes. *IEEE Transactions on Industrial Electronics*, 59(5):2351–2362, 2012.
- [338] F. Zhang und R. de Dear. Thermal environments and thermal comfort impacts of direct load control air-conditioning strategies in university lecture theatres. *Energy and Buildings*, 86:233–242, 2015.
- [339] Q. Zhang und J. Li. Demand response in electricity markets: A review. In *International Conference on the European Energy Market (EEM)*. IEEE, 2012.

- [340] P. Zhao, S. Suryanarayanan und M. G. Simões. An energy management system for building structures using a multi-agent decision-making control methodology. *IEEE Transactions on Industry Applications*, 49(1):322–330, 2013.
- [341] J. Zhu. *Optimization of power system operation*. IEEE Press Series on Power Engineering. John Wiley & Sons, 2009.
- [342] Q. Zhu, J. Zhang, P. W. Sauer, A. Domínguez-García und T. Başar. A game-theoretic framework for control of distributed renewable-based energy resources in smart grids. In *American Control Conference (ACC)*, S. 3623–3628. IEEE, 2012.
- [343] E. Zitzler, K. Deb und L. Thiele. Comparison of multiobjective evolutionary algorithms: Empirical results. *Evolutionary Computation*, 8(2):173–195, 2000.
- [344] R. Zivanovic. Local regression-based short-term load forecasting. *Journal of Intelligent and Robotic Systems*, 31(1–3):115–127, 2001.
- [345] B. Zwaenepoel, J. I. Laveyne, L. Vandeveldel, T. L. Vandoorn, B. Meersman und G. Van Eetvelde. Solar commercial virtual power plant. In *Power and Energy Society General Meeting (PES GM)*. IEEE, 2013.

ISBN 978-3-7315-0551-8



9 783731 505518 >



Der Trend hin zu dezentraler, volatiler Erzeugung führt zu Engpässen in Stromnetzen. Eine Lösung verspricht die informationstechnische Vernetzung und Koordination von Verbrauchern, Erzeugern und Speichern in Smart Grids. Neue Energiemanagement-Ansätze erfordern geeignete Systemarchitekturen sowie intelligente Koordinationsmethoden. Daher wird eine generische Architektur für Energiemanagement-Systeme vorgestellt und für ein fahrplanbasiertes Last- und Erzeugungsmanagement instanziiert. Dabei werden vorgegebene Leistungsprofile durch die Aggregation flexibler Verbraucher und Erzeuger approximiert. Die Nutzung der definierten Flexibilitäten wird unter Berücksichtigung von Netzrestriktionen mittels skalarer sowie multikriterieller Optimierung geplant. Im Rahmen der Fahrplanerstellung werden diverse Verfahren zur Prädiktion der Lastprofile von einzelnen Haushalten angewandt.

