

Optimierung der Investitions- und Einsatzplanung dezentraler Energiesysteme unter Unsicherheit

Zur Erlangung des akademischen Grades eines
Doktors der Ingenieurwissenschaften
(Dr.-Ing.)

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

genehmigte

DISSERTATION

von

Diplom-Wirtschaftsingenieur Hannes Schwarz

Tag der mündlichen Prüfung: 11. Januar 2019

Referent: Prof. Dr. Wolf Fichtner

Korreferent: Prof. Dr. Valentin Bertsch

*Von George Dantzig, einem der
Begründer der mathematischen
Optimierung, ist Folgendes überliefert.
Fachsimpelnd mit einem
seiner Doktoranden meinte er beim
Schneiden der Rosenhecke in seinem
Garten: „Weißt du, das eigentliche
Problem in der Optimierung ist
doch die Unsicherheit.“*

Rüdiger Schultz (2012), Übers. d. Verf.

Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Lehrstuhl für Energiewirtschaft des Instituts für Industriebetriebslehre und Industrielle Produktion (IIP) am Karlsruher Institut für Technologie (KIT).

Ich danke meinem Doktorvater Herrn Prof. Dr. Wolf Fichtner für die wegweisende und gleichzeitig schrankenlose Betreuung meiner Arbeit sowie für das in mich gesetzte fachliche und persönliche Vertrauen. Zugleich danke ich Herrn Prof. Dr. Valentin Bertsch für die Übernahme des Korreferats, der durch zahlreiche Ideen, Diskussionen und Anregungen einen wesentlichen Anteil zum Entstehen dieser Arbeit beigetragen hat. Dafür und für das hervorragende Arbeitsklima möchte ich beiden aus tiefstem Herzen danken.

Allen derzeitigen und ehemaligen Kollegen möchte ich für die angenehme und konstruktive Zusammenarbeit danken, insbesondere der Arbeitsgruppe „Dezentrale Energiesysteme und Netze“: Die wunderbaren letzten sechs Jahre haben mein Leben mit Wissen, positiven Energien und Freundschaften bereichert. Ich wünsche Euch maximalen Erfolg und genauso viel Freude bei Euren zukünftigen Vorhaben. An dieser Stelle sei auch jenen Studenten gedankt, die als Abschlussarbeiter oder Hilfwissenschaftler eine wichtige Rolle für meine Arbeit am Lehrstuhl gespielt haben.

Ferner danke ich Herrn Prof. Dr. Holger Hoos und Herrn Prof. Dr. Lars Kothoff, die mir während meines Gastaufenthalts an der University of British Columbia (UBC) die nötigen Finessen zur Problemlösung meiner Arbeit und darüber hinaus für meinen weiteren Lebensweg mitgegeben haben. Mein besonderer Dank gilt Herrn Prof. Dr. Wolfgang Popp der Martin-Luther-Universität Halle-Wittenberg, der mich seit meinem Studium fördert und unterstützt und überhaupt der Ursprung meines Promotionsvorhabens ist.

Nicht zuletzt gilt mein innigster Dank meiner Familie für ihre bedingungslose Unterstützung und Liebe. Mehr als dankbar bin ich für die hinzugekommene Leuchtkraft in meinem Leben – Natalie, ohne dich hätte ich es nicht geschafft.

Hannes Schwarz
Halle (Saale), im Januar 2019

Kurzfassung

Die Energieversorgung verschiebt sich kontinuierlich von einer zentralisierten zu einer dezentralen Versorgung mit deutlichem Ausbau fluktuierender erneuerbarer Energien. Bei der grundlegenden, strukturellen Neuordnung der Energieversorgung unterliegen die Investitions- und Einsatzplanung dezentraler Energiesysteme vielfältigen Unsicherheiten. Motiviert durch diese Entwicklung, wurde für die Investitions- und Einsatzplanungsoptimierung ein ganzheitliches, modulbasiertes Framework entwickelt, um diese Unsicherheiten und deren gegenseitige Abhängigkeiten konsistent modellieren und berücksichtigen zu können.

Zunächst werden meteorologische Eingangsdaten über Markov-Prozesse bereitgestellt und dann in die erforderlichen Daten für die Optimierung umgewandelt. Schließlich werden Investitions- und Einsatzplanung des dezentralen Energiesystems durch ein zweistufiges stochastisches gemischt-ganzzahliges lineares Programm optimiert. Zu diesem Zweck wird dieses komplexe Programm durch Fixierung verknüpfender Variablen in Subprogramme entkoppelt und auf High-Performance-Computing-Systemen parallel ausgeführt. Der Rechenaufwand wird durch eine vorgelagerte Szenarioreduktion und eine optimierte Solver-Einstellung mittels automatischer Algorithmuskonfiguration um bis zu 75 % reduziert. Die fixierten Variablen werden im Masterprogramm durch einen ableitungsfreien Bergsteigeralgorithmus optimiert, der robust und zuverlässig das (lokale) Optimum in wenigen Iterationen findet. Mit einer übergeordneten Regret-Minimierung wird für den privaten Entscheider die Investition bestimmt, die er im schlimmsten Fall am wenigsten bereuen würde.

In einer Fallstudie wird endogen die kostenminimale Investitions- und Einsatzplanung des Energiesystems eines Wohnquartiers in Karlsruhe ermittelt. Zu den möglichen Systemkomponenten gehören eine PV-Anlage, Wärmepumpen als Power-to-Heat-Anwendung sowie thermische und elektrische Speicher. Die Ergebnisse zeigen, dass die PV-Anlage als dezentrales Energieangebot in solch einem System generell wirtschaftlich ist. Wärmespeicher sind in der Regel größer, wenn Unsicherheiten berücksichtigt werden. Stochastische Programmierung kann mithin helfen, insuffiziente Investitionsplanung zu vermeiden. Bei getrenntem Heizsystem sind Speicher für Warmwasser rentabler als für Raumwärme, deren Wert mehr in der Minimierung des Risikos liegt, den Heizbedarf in kalten Wintern nicht decken zu können. Elektrische Speicher spielen aufgrund ihres höheren Investitionsbedarfs im Vergleich zu thermischen Speichern kaum eine Rolle und werden nur zwingend benötigt, um vollständige Autarkie zur Überbrückung bestimmter Wochen im Jahr zu erreichen.

Die Analyse der Skalierbarkeit und der Vergleich mit einer modernen dualen Dekompositionsmethode mittels angepasster Lagrange-Relaxierung zeigen eine gute Performance des entwickelten Ansatzes für den betrachteten Problemtyp. Der Mehrwert, der sich aus der Berücksichtigung der Unsicherheiten in der Optimierung einschließlich des daraus resultierenden Rechenaufwands ergibt, wird aufgezeigt und rechtfertigt den gewählten Ansatz.

Abstract

Energy supply is continuously moving from a centralized to a decentralized supply, with significant expansion occurring in fluctuating renewable energy. In the fundamental, structural rearrangement of the energy supply, the investment and operational planning of decentralized energy systems is subject to a variety of uncertainties. Motivated by this development, a comprehensive, module-based framework is developed for investment and operation planning optimization in order to consistently model and take account of those uncertainties and their interdependencies.

Beginning with the generation of meteorological input data using Markov processes, these are then transformed into the required data for the optimization. Finally, a two-stage stochastic mixed-integer linear program optimizes the investment decision and operational management of the decentralized energy system. To this purpose, the large-scale program is decoupled by fixing connecting variables into sub programs and performed in parallel on high-performance computing systems. The computational effort is reduced by up to 75 % through an upstream scenario reduction and an optimized solver setting using automatic algorithm configuration. The fixed variables in the master program are optimized by a derivative-free hill-climbing algorithm, which robustly and reliably finds the (local) optimum in a few iterations.

In a case study, the optimal investment and operation for the energy system of a residential quarter in Karlsruhe is determined endogenously. Possible system components include a PV system, heat pumps as power-to-heat applications as well as thermal and electrical storage units. The results indicate that the PV system is generally economical as a decentralized energy supply in such a system. Heat storage units are generally larger when uncertainties are taken into account, i. e. stochastic optimization can help to avoid insufficient investment planning. With a separated heating system, hot water storage units are more profitable than space storage units, the value of which is rather in reducing the risk of not covering heat demand in cold winters. Due to their higher investment needs, electrical storage units play a marginal role in comparison to thermal storage units and are only essentially required in the case of complete self-sufficiency bridging certain weeks in the year.

The scalability analysis and the comparison with a state-of-the-art dual decomposition method reflect a good performance in the developed approach for the considered problem type. The added value of taking uncertainties into account in optimization, including the resulting computational effort, is shown and justifies the approach.

Inhaltsverzeichnis

Vorwort.....	V
Kurzfassung / Abstract.....	VII
Inhaltsverzeichnis.....	IX
1 Einleitung.....	1
1.1 Motivation und Problemstellung.....	1
1.2 Forschungsfrage und Zielsetzung.....	4
1.3 Struktur der Arbeit.....	5
2 Energiewirtschaftlicher Rahmen.....	9
2.1 Strukturwandel in der deutschen Energiewirtschaft.....	9
2.1.1 Dezentralisierung der Stromversorgung.....	9
2.1.2 Integration erneuerbarer Energien.....	11
2.1.3 Relevanz des Wohngebäudesektors.....	14
2.1.4 Strompreise für dezentrale Energiesysteme.....	16
2.2 Politische und rechtliche Rahmenbedingungen.....	22
2.2.1 Erneuerbare-Energien-Gesetz.....	22
2.2.2 Energieeinsparverordnung.....	23
2.2.3 Erneuerbare-Energien-Wärmegesetze.....	25
2.2.4 Kraft-Wärme-Kopplungsgesetz.....	26
2.2.5 Spezifische regulatorische Bedingungen für Wohnquartiere.....	27
3 Grundlagen dezentraler Energiesysteme.....	29
3.1 Lokales Energieangebot.....	29
3.1.1 Photovoltaikanlage zur Bereitstellung elektrischer Energie.....	30
3.1.2 Wärmepumpe zur Bereitstellung thermischer Energie.....	32
3.2 Lokale Energienachfrage.....	34
3.2.1 Nachfrage nach elektrischer Energie.....	35
3.2.2 Nachfrage nach thermischer Energie.....	36
3.3 Lokale Energiespeicherung.....	37
3.3.1 Lithium-Ionen-Batterie für die Speicherung elektrischer Energie.....	38
3.3.2 Wasserspeicher für die Speicherung thermischer Energie.....	39
3.4 Investitionsrechnung für dezentrale Energiesysteme.....	40
4 Einordnung in die Optimierung.....	43
4.1 Optimierungsziel der Investitions- und Einsatzplanung.....	43
4.2 Programmklassen der Optimierung.....	46

4.3	Unsicherheiten in der Optimierung.....	48
4.3.1	Risiko, Ungewissheit und Unwissen.....	49
4.3.2	Unsicherheiten in der Optimierung von Wohnquartieren.....	50
4.4	Verfahren zur Berücksichtigung von Unsicherheiten	51
4.4.1	Sensitivitäts- und Szenarioanalyse	52
4.4.2	Stochastische Programmierung	55
4.4.3	Robuste Optimierung.....	59
4.4.4	Regret-Minimierung.....	60
5	Stand der Wissenschaft	61
5.1	Forschungsstand der Investitions- und Einsatzplanungsoptimierung.....	61
5.2	Optimierungsverfahren zur Berücksichtigung von Unsicherheiten.....	66
5.3	Verwendete Optimierungsverfahren zur Berücksichtigung von Unsicherheiten und deren rechentechnische Herausforderungen	70
6	Methodik zur Berücksichtigung von Unsicherheiten	73
6.1	Inputebene mit Wettersimulations-Modul	74
6.2	Transformationsebene	77
6.2.1	Photovoltaik-Generations-Modul	78
6.2.2	Energiebedarfs-Modul	79
6.2.3	Strompreis-Modul	80
6.3	Optimierungsebene Θ -DES	81
6.3.1	Allgemeine Zielfunktion und Restriktionen des Programms.....	82
6.3.2	Investitions- und Einsatzplanung eines Wohnquartiers	83
7	Methodik zur Bewältigung der rechentechnischen Herausforderungen.....	89
7.1	Verteilte Optimierung.....	90
7.1.1	Entkopplung des Optimierungsprogramms.....	91
7.1.2	Parallele Ausführung der Subprogramme auf HPC-Systemen mit CPLEX.....	92
7.1.3	Ableitungsfreie Optimierung des Masterprogramms	93
7.2	Verwendete Methoden zur Reduktion des Rechenaufwands	95
7.2.1	Szenarioreduktion.....	95
7.2.2	Sequenzielle modellbasierte Algorithmuskonfiguration von CPLEX.....	98
8	Fallstudie zur Optimierung eines Wohnquartiers unter Unsicherheiten.....	101
8.1	Wohnquartier als Fallstudie.....	102
8.2	Allgemeine Annahmen	104
8.3	Referenzfall	109

8.4	Alternativfälle	114
8.4.1	Erhöhter Arbeitspreis oder PV-Eigenverbrauchsabgabe.....	114
8.4.2	Dynamischer Arbeitspreis oder Leistungspreis	115
8.4.3	Abweichender Kalkulationszins	116
8.4.4	Rechenergebnisse der Alternativfälle	117
8.5	Optimale Investitions- und Einsatzplanung mit minimalem Risiko und Regret.....	119
8.6	Sonderfälle.....	122
8.6.1	Niedriger Arbeitspreis.....	122
8.6.2	Vollständige Autarkie	123
8.6.3	Rechenergebnisse der Sonderfälle	124
8.7	Vergleich zur deterministischen Lösung.....	127
9	Diskussion der Rechenergebnisse und Methodik	131
9.1	Diskussion der Rechenergebnisse	131
9.1.1	Diskussion des Referenzfalls und der Alternativfälle mit minimalem Regret.....	131
9.1.2	Diskussion der Sonderfälle	134
9.2	Kritische Würdigung der entwickelten Methodik	135
9.2.1	Qualitative Bewertung der angewandten Datengenerierung.....	136
9.2.2	Stärken und Schwächen des Optimierungsverfahrens	138
9.2.3	Rechenaufwand des Optimierungsverfahrens.....	142
9.2.4	Skalierbarkeit des Optimierungsverfahrens	146
10	Schlussbetrachtung.....	149
10.1	Zusammenfassung der Forschungsarbeit	149
10.2	Erkenntnisse der Arbeit.....	151
10.3	Beitrag der Arbeit und Ausblick.....	153
	Anhänge.....	157
A	Validierung der Input- und Transformations-Module.....	159
B	Nomenklatur des Optimierungsprogramms.....	163
C	Überblick über ableitungsfreie Optimierungsverfahren	165
	Verzeichnisse.....	171
I	Literaturverzeichnis.....	173
II	Abkürzungsverzeichnis.....	199
III	Abbildungsverzeichnis	203
IV	Tabellenverzeichnis.....	207

1 Einleitung

Die Energieversorgung verschiebt sich kontinuierlich von einer zentralisierten hin zu einer dezentralen Struktur. Zudem wird der Anteil erneuerbarer Energien deutlich ausgebaut. Diese grundlegende, strukturelle Neuordnung des Energiesystems führt zu einer erhöhten, wetterbedingten Fluktuation und bringt erhebliche Unsicherheiten auf der Angebotsseite mit sich. Eine der daraus resultierenden Herausforderungen besteht darin, den Übergangsprozess in den verschiedenen, miteinander gekoppelten Energiesektoren technisch und wirtschaftlich umzusetzen. Eine weitere Herausforderung lautet, solche Energiesysteme unter Berücksichtigung ihrer Unsicherheiten zu modellieren, um einen zuverlässigen, kosteneffizienten und technisch machbaren Übergang zu unterstützen. Diese neuen Probleme erfordern maßgeschneiderte quantitative Lösungen, um Energiesysteme analysieren und optimieren zu können (Hurink et al. 2016; Owens 2014; Kobayakawa und Kandpal 2016; Yazdanie et al. 2016). Energiesysteme mit dezentraler Energiebereitstellung und Lastverschiebungspotenzialen durch Energiespeicher gewinnen zunehmend an Bedeutung. Der Forschungsbedarf umfasst die Entwicklung von Ansätzen, die dazu dienen zu bestimmen, wie die Komponenten des dezentralen Energiesystems optimal zu dimensionieren und zu nutzen sind. So sollen langfristige Investitions- und kurzfristige Betriebsentscheidungen unter unsicheren Bedingungen unterstützt werden.

1.1 Motivation und Problemstellung

In Deutschland ist der Übergang zu einem stärker dezentralisierten Energiesystem vor allem durch den regulatorischen Rahmen getrieben, der sich auf erneuerbare Energien konzentriert. Bis 2050 sollen 80 % des deutschen Strombedarfs mit erneuerbaren Energien gedeckt (BRD 2012a) und gleichzeitig der Kohlenstoffdioxid-Ausstoß reduziert werden. Entsprechend dieser Zielsetzung ist Deutschland über mehrere Jahre der weltweit führende Photovoltaik(PV)-Installateur gewesen (Rodrigues et al. 2016). Insbesondere das Erneuerbare-Energien-Gesetz (EEG) katalysiert den Ausbau dezentraler Energiesysteme mit erneuerbaren Energiequellen wie PV, indem es die Abnahme mit einer festen Vergütung für die ins lokale Netz eingespeiste Energie garantiert. Abb. 1.1 zeigt die Relevanz für Systeme mit PV-Anlagen anhand der historischen Entwicklung der installierten Kapazität kleiner 100 kW_p in Deutschland unter der Annahme, dass Energiesysteme mit dieser PV-Anlagengröße als dezentral gelten.




Abb. 1.1: Entwicklung der installierten PV-Anlagen (< 100 kW_p) in Deutschland (laut Anlagenregister der BNetzA 2017).

Um das Ziel zu erreichen, die Energieversorgung nachhaltig zu entwickeln, wurde aufbauend auf dem Stromeinspeisungsgesetz (StrEG) das EEG geschaffen. Dieses fördert die Integration erneuerbarer Energien fortwährend und entwickelt diese Integration stetig weiter. Dementsprechend wurden seit Inkrafttreten des Gesetzes PV-Kapazitäten kontinuierlich dezentral hinzugebaut. Gemäß Anlagenregister der Bundesnetzagentur sind 2016 ca. 23 GW_p zugebaut worden (PV-Anlagen < 100 kW_p), die ca. 4 % von 525 TWh_{el} Gesamt-Nettostrombedarf decken (BDEW 2018). Für diesen Zubau sind Investitionen in Höhe von ca. 64 Mrd. € getätigt worden, knapp ein Drittel der gesamten kumulierten Investitionen in erneuerbare Energien bis dato (BMWi 2017b).¹ Diese Entwicklung ist nicht zuletzt auch der Energie-Forschungsförderung zu verdanken. Alleine die Bundesregierung hat im Jahr 2016 rund 860 Mio. € für Forschungen zu erneuerbaren Energien und Energieeffizienz zur Verfügung gestellt (BMWi 2017a). Laut dem Energieatlas (2018) der Heinrich-Böll-Stiftung wurde in Europa knapp das Dreifache dafür ausgegeben, in dem vor allem die Sektorenkopplung zwischen Strom, Wärme und Verkehr als wichtigster Teil für die Integration schwankender erneuerbarer Energien gesehen wird. Das aus dieser Entwicklung entstandene EU-Forschungsprojekt

¹ Die Investitionssumme für PV-Anlagen kleiner 100 kW_p ergibt sich aus der kumulativen installierten PV-Leistung je Jahr, multipliziert mit dem entsprechenden durchschnittlichen System-Endkundenpreis für installierte Dachanlagen laut Bundesverband Solarwirtschaft e. V. (Wirth 2018).

Energy Supply Cooperative (ESC) für Wohnquartiere bildet einen Grundstein der vorliegenden Arbeit, bei dem möglichst minimale Gesamtenergiekosten durch PV in Kombination mit Wärmepumpen und Speichern sowie optimaler Lastverschiebung erreicht werden sollen (ausführliche Informationen unter https://www.iip.kit.edu/86_2055.php).

Die Entwicklung für PV zeigt auch, dass Investitionen stark durch politische Entscheidungen und wirtschaftliche Rahmenbedingungen beeinflusst werden, auch im negativen Sinne: Entgegen der Entwicklung wurde der geförderte PV-Zubau ab dem Jahr 2012 durch verschiedene Ausbaukorridore von 2,5 bis 3,5 GW_p pro Jahr begrenzt (BRD 2012c); (BRD 2014) und insgesamt auf 52 GW_p gedeckelt. Trotz dieser politisch gewollten Dämpfung der Zubauraten ist PV weiterhin wirtschaftlich attraktiv. Neben solchen eher langfristigen unsicheren Bedingungen hängt die Vorteilhaftigkeit dezentraler Energiesysteme auch maßgeblich von lang-, aber auch kurzfristigen wetterbedingten Unsicherheiten ab. So können sich etwa Globalstrahlung und Temperatur auf das lokale Energieangebot, z. B. die PV, aber auch auf die Energienachfrage, z. B. den Heizwärmebedarf, und somit auf die optimale Investitions- und Einsatzplanung auswirken. Abb. 1.2 verdeutlicht die erheblichen täglichen, saisonalen und jährlichen Schwankungen der Globalstrahlung und Temperatur nur für den Ort Karlsruhe.

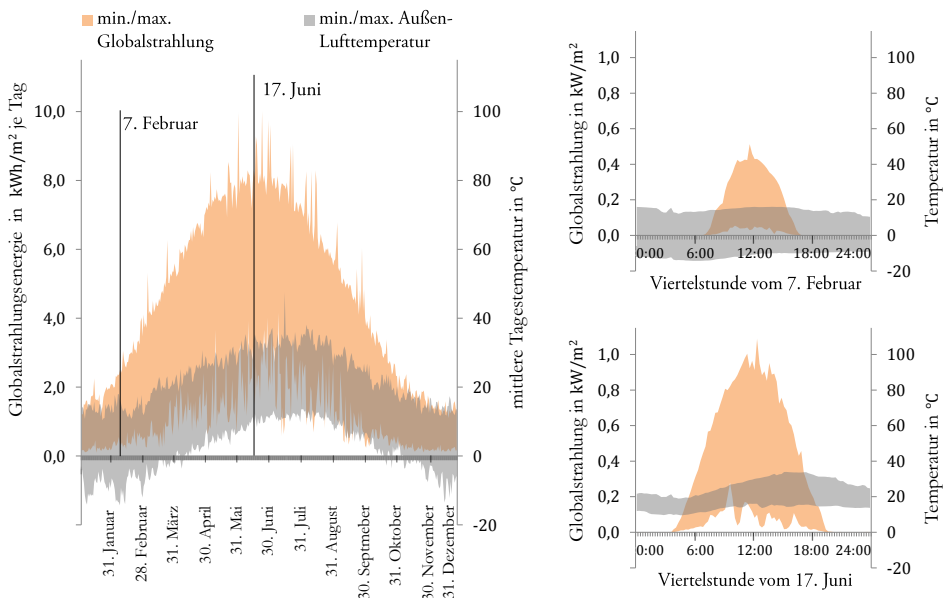


Abb. 1.2: Streuung der Globalstrahlung und Temperatur in Karlsruhe von 2000 bis 2016 (IMK 2018): min./max. tägliche Globalstrahlungsenergie und mittlere Lufttemperatur (links) sowie min./max. Globalstrahlung und Lufttemperatur vom 7. Februar (oben, rechts) und 17. Juni (unten, links).

Durch die geschilderte Entwicklung dezentraler Energiesysteme und das ESC-Forschungsprojekt entstand die Motivation, ein Optimierungsverfahren für Investition und Betrieb mit kostenminimalem Ergebnis zu entwickeln, wobei die entscheidungsrelevanten Unsicherheiten berücksichtigt werden. Denn deterministische Optimierungen mit verschiedenen Wetterjahren können zu deutlich abweichenden „optimalen“ Investitionen führen. Derzeit existieren keine dezentralen Energiesystemmodelle in der benötigten Detailtiefe, die simultan Unsicherheiten und deren Abhängigkeiten direkt bei der Investitions- und Einsatzplanungsoptimierung mitberücksichtigen. Das Problem besteht darin, dass dezentrale Energiesysteme aufgrund kurzfristiger Fluktuationen, beispielsweise durch Wetter oder dynamische Strompreise bedingt, bereits für die deterministische Modellierung rechenaufwendige Programme mit adäquater Abbildungsgenauigkeit und hoher zeitlicher Auflösung erfordern. Bekannte Optimierungsverfahren wie die Stochastische Programmierung werden in der Regel aufgrund der resultierenden Programmgröße ausgeschlossen. Das stochastische Optimierungsprogramm eines schweizerischen Bürogebäudes von Mavromatidis et al. (2017) bildet die Ausnahme. Jedoch werden dabei Korrelationen zwischen den unsicheren Daten nur teilweise abgebildet. Darüber hinaus werden mit einer zeitlichen Auflösung von 60 min und weiteren Vereinfachungen entscheidungsrelevante Details vernachlässigt. Weitere, nicht probabilistische Unsicherheiten können erst gar nicht berücksichtigt werden. Die hohe Anzahl von Entscheidungsvariablen und Restriktionen des stochastischen Programms würden Rechenknoten mit bisher nicht verfügbarer Rechenleistung erfordern. Aber selbst wenn die erforderlichen Rechenressourcen verfügbar wären, sind solche Programme nicht in angemessener Zeit und Genauigkeit durchführbar; insbesondere wenn Energiekomponenten mit stufenweisem Betrieb involviert sind und die Konvexitätsbedingung nicht mehr allgemeingültig ist.

1.2 Forschungsfrage und Zielsetzung

Motiviert durch die beschriebene Entwicklung dezentraler Energiesysteme und die dabei wirkenden Unsicherheiten, entstand der Forschungsansatz eines Optimierungsverfahrens für die Investitions- und Einsatzplanung aus Sicht des privaten Entscheiders. Die dabei aufgekommene Forschungsfrage lautet:

Wie können Investitions- und Einsatzplanung dezentraler Energiesystemen optimal bestimmt werden, dabei Unsicherheiten suffizient Berücksichtigung finden und gleichzeitig die anfallenden rechentechnischen Herausforderungen bewältigt werden?

Diese Frage schließt den Aspekt ein, welchen Unterschied und Mehrwert die Einbindung der Unsicherheiten in die Optimierung für den privaten Entscheider bringt. In diesem Zusammenhang soll auch der Einfluss unsicherer, regulatorischer Rahmenbedingungen auf das Energiesystem untersucht werden.

Für die Beantwortung der Forschungsfrage wurde das Ziel formuliert:

Ableitung eines Verfahrens zur langfristigen Investitions- und kurzfristigen Einsatzplanungsoptimierung eines dezentralen Energiesystems anhand eines Wohnquartiers unter Berücksichtigung plausibel erfassbarer Unsicherheiten aus Sicht des privaten Entscheiders.

Es sollen generelle Aussagen für dezentrale Energiesysteme getroffen und Auswirkungen auf zukünftige Entwicklungen in der deutschen Energieversorgung diskutiert werden. Dabei liegt der Schwerpunkt auf der thermischen und elektrischen Energieversorgung von Wohnquartieren. Allgemein soll dafür ein ganzheitliches, modulbasiertes Framework entwickelt werden, mit dem sichere und unsichere Eingangsdaten sowie deren gegenseitige Abhängigkeiten konsistent modelliert und bei der Optimierung berücksichtigt werden können. Mit plausibel erfassbaren Unsicherheiten sind solche Unsicherheiten gemeint, die gewissen Risiken (probabilistisch) oder Ungewissheiten (nicht probabilistisch) unterliegen, sich jedoch nicht vollständig dem rationalen Wissensstand entziehen. Bei der Umsetzung sollen rechentechnische Limitationen möglichst durch passende Methoden umgangen werden, um nicht a priori bestimmte Optimierungsverfahren zur Berücksichtigung von Unsicherheiten ausschließen zu müssen. Das Ziel impliziert, den Mehrwert des entwickelten Optimierungsverfahrens im Vergleich zum deterministischen Ergebnis aufzuzeigen.

1.3 Struktur der Arbeit

Grundsätzlich ist die Arbeit in einen theoriebezogenen und einen methodisch-anwendungsorientierten Teil gegliedert. Im ersten Teil in den Kapiteln 2–5 werden die Rahmenbedingungen der Thematik dargelegt und grundlegende Methoden vorgestellt, die für die Bearbeitung und das Verständnis der Arbeit benötigt werden. Im zweiten Teil in den Kapiteln 6–9 wird das für die Problem- und Fragestellung entwickelte Optimierungsverfahren beschrieben, das anhand einer Fallstudie angewendet und diskutiert wird.

Nachdem im 1. Kapitel einleitend Motivation und Problemstellung vorgestellt sowie Forschungsfrage und Zielsetzung der Arbeit definiert wurden, folgt ein Einblick in den energiewirtschaftlichen Rahmen in Kapitel 2, der politische und rechtliche Rahmenbe-

dingungen anspricht. Dabei werden der Strukturwandel in der deutschen Energiewirtschaft und die Dezentralisierung der Stromversorgung mit Integration erneuerbarer Energien dargelegt. Bedeutende Gesetze für dezentrale Energiesysteme werden vorgestellt.

In Kapitel 3 werden dezentrale Energiesysteme definiert und deren genereller Aufbau beschrieben, wobei die verwendete Fallstudie der Arbeit in den Blick rückt: ein Wohnquartier mit Elektrizitäts-, Raumwärme- und Warmwasserbedarf sowie PV-Anlage und Wärmepumpe als elektrisches bzw. thermisches Energieangebot mit entsprechender Speicheroption. Darauf aufbauend werden die Investitionsrechnung für dezentrale Energiesysteme vorgestellt und das Optimierungsziel konkret formuliert.

Kapitel 4 gibt zu Beginn einen kompakten Einblick in die Grundlagen von Optimierungsprogrammen. Hierauf sind Unsicherheiten in der Optimierung zu definieren und unterschiedliche Kategorien klar voneinander abzugrenzen. Darauf aufbauend werden die in vorliegender Arbeit verwendeten oder für sie grundlegenden Verfahren vorgestellt, die dazu dienen, diese Unsicherheiten zu berücksichtigen.

In Kapitel 5 wird der Stand der Wissenschaft dargelegt. Dazu ist der aktuelle Forschungsstand der Investitions- und Einsatzplanungsoptimierung dezentraler Energiesysteme wiederzugeben. Hierbei wird die vorliegende Arbeit von anderen Arbeiten abgegrenzt. So kann die Forschungslücke herausgearbeitet werden, die mit der vorliegenden Arbeit geschlossen werden soll. In diesem Zusammenhang werden Optimierungsverfahren zur Berücksichtigung von Unsicherheiten sowie die rechentechnischen Herausforderungen der verwendeten Verfahren aufgezeigt.

Im 6. Kapitel wird der entwickelte konzeptionelle Rahmen zur Berücksichtigung von Unsicherheiten beschrieben. Er unterteilt sich in drei Ebenen, um bei der Datengenerierung die Unsicherheiten und deren Abhängigkeiten untereinander adäquat abzubilden und einen möglichst hohen Konsens zu erlangen. Insbesondere meteorologische Parameter beeinflussen Angebot und Nachfrage dezentraler Energiesysteme stark. Deshalb wird mit der ersten Inputebene dargelegt, wie die benötigten meteorologischen Daten mit einem Wettersimulations-Modul generiert werden. Mit dem Schwerpunkt auf der Fallstudie der Arbeit wird anschließend der Transformationsprozess der zweiten Ebene in die für die dritte Optimierungsebene erforderlichen Daten beschrieben. Die Optimierungsebene, bestehend aus stochastischem Programm und Regret-Minimierung, wird allgemein dargelegt und explizit für die Fallstudie ausformuliert.

Das 7. Kapitel beinhaltet die entwickelte Methodik zur Bewältigung der rechentechnischen Herausforderungen der Optimierungsebene. Darin sind die Entkopplung des Optimierungsprogramms und die verteilte Optimierung auf High-Performance-

Computing-Systemen enthalten, wodurch das Rechenproblem überhaupt erst lösbar wird. Des Weiteren werden die Methoden dargelegt, die genutzt wurden, um den Rechenaufwand zu senken.

Im 8. Kapitel ist das Wohnquartier als Fallstudie für ein dezentrales Energiesystem beschrieben, an der das entwickelte Optimierungsverfahren demonstriert wird. Für die Fallstudie werden Referenzfall und Alternativfälle berechnet und deren Ergebnisse illustriert. Wie die optimale Investitions- und Einsatzplanung unter Unsicherheit mit minimalem Risiko und Regret berechnet wird, wird final aufgezeigt. Separat davon werden zwei Sonderfälle betrachtet, die nicht als Unsicherheit aufgefasst werden, aber deren Ergebnisse für zukünftige Wohnquartiere und politische Entscheidungen nützlich sind. Anhand der beiden Sonderfälle und des Referenzfalls wird der Mehrwert des entwickelten Optimierungsverfahrens, das Unsicherheiten berücksichtigt, gegenüber deterministischen Ansätzen herausgestellt.

Das 9. Kapitel diskutiert die Rechenergebnisse und würdigt die Methodik kritisch. Dabei werden die methodischen Stärken und Schwächen erörtert. Auf Rechenaufwand und Skalierbarkeit des entwickelten Optimierungsverfahrens wird im Zuge dessen gesondert eingegangen.

Das letzte Kapitel 10 schließt mit einer Schlussbetrachtung der Arbeit, in der die Dissertationstätigkeiten zusammengefasst werden. Die wichtigsten Erkenntnisse werden separat hervorgehoben und final der wesentliche Beitrag der Arbeit mit Ausblick verdeutlicht.

2 Energiewirtschaftlicher Rahmen

Kapitel 2 widmet sich den energiewirtschaftlichen Rahmenbedingungen in Deutschland und konzentriert sich dabei auf die zentrale Fallstudie der Arbeit: ein Wohnquartier mit PV-Anlagen, Wärmepumpen und Speichermöglichkeiten. Der Strukturwandel in der deutschen Energiewirtschaft ist in Abschnitt 2.1 beschrieben, der maßgeblich durch Klimaschutzbemühungen motiviert ist. Da der Übergang zu einem stärker dezentralisierten Energiesystem mit Schwerpunkt erneuerbarer Energien vor allem durch den regulatorischen Rahmen getrieben ist, werden in Abschnitt 2.2 entscheidende politische und rechtliche Rahmenbedingungen vorgestellt.

2.1 Strukturwandel in der deutschen Energiewirtschaft

Der Strukturwandel der Energiewirtschaft in Deutschland wird in Abschnitt 2.1.1 einleitend mit der Beschreibung der Dezentralisierung der Stromversorgung skizziert. Daran schließt sich in Abschnitt 2.1.2 eine Zusammenfassung der Integration erneuerbarer Energien bis zum heutigen Stand an. Mit Bezug zur Fallstudie der Arbeit wird in Abschnitt 2.1.3 die Relevanz des Wohngebäudesektors in dem Dezentralisierungsprozess hervorgehoben. Die mit dem Strukturwandel verbundene historische Entwicklung der Strompreise für dezentrale Energiesysteme mit Fokus auf Haushaltsebene wird in Abschnitt 2.1.4 dargelegt.

2.1.1 Dezentralisierung der Stromversorgung

Bedingt durch politische Zielsetzungen und die entsprechende Gestaltung rechtlicher Rahmenbedingungen, durchläuft das deutsche Energiesystem seit mehreren Dekaden einen tiefgreifenden strukturellen Wandel. Dieser äußert sich zunächst auf der Angebotsseite, insbesondere hinsichtlich der Bereitstellung elektrischer Energie.

Die konventionelle Elektrizitätsversorgung von Haushalten und großen Teilen der Industrie mit elektrischer Energie erfolgt heute immer noch größtenteils über ein zentralisiertes System. Der Hauptteil der Elektrizitätsnachfrage wird durch große Kraftwerke gedeckt, deren Standorte wesentlich durch die Brennstoffverfügbarkeit und die Möglichkeit zur Kühlung determiniert sind.

Die Dezentralisierung geht mit der Installation kleinerer Energieanlagen, nahe oder direkt beim Verbraucher, einher (siehe Kapitel 3). Das zuvor gültige Versorgungsschema des zentralen Elektrizitätsangebots der Großkraftwerke und die damit verbundenen Skaleneffekte stellen weiterhin einen großen Teil des Energiesystems, doch steigt der Anteil dezentraler Erzeugung stetig an (BMU 2013). Die Gründe für die zunehmende Dezentralisierung sind vielfältig. Neben der zunehmenden Integration erneuerbarer Energien mit Anlagen in allen Leistungsklassen findet auch ein Umdenken auf der Nachfrageseite statt. Forschung und Entwicklung konzentrieren sich auf die Flexibilisierung der Nachfrage in Industrie und Haushalt, insbesondere auf Lastverschiebungsmaßnahmen. Dadurch soll die Koinzidenz von Energieangebot und -nachfrage erhöht werden. Auch wenn in Zukunft zentral gelegene Großkraftwerke einen großen Anteil an der Energieversorgung bei der Leistungs- und Energiebereitstellung haben werden, steigt die Nutzung verteilter erneuerbarer Energiequellen von Jahr zu Jahr.

Fortwährend werden kleinere, dezentrale PV-Anlagen installiert, insbesondere auf Hausdächern, die einzelne Wohneinheiten bis hin zu ganzen Wohnquartieren und -siedlungen anteilig mit Strom versorgen. Die vorwiegend ungenutzten Dachflächen der Gebäude sind aus technischer und wirtschaftlicher Sicht häufig gut für die Installation geeignet. Bedingt durch das EEG (siehe Abschnitt 2.2.1), wurde der Zubau von PV-Anlagen in der Vergangenheit stark gefördert und ist auch heute noch in den meisten Fällen rentabel. Für die Wirtschaftlichkeit ist neben der optimalen Dimensionierung und Ausrichtung der Anlage auch die Eigenverbrauchsquote des lokal erzeugten Stroms entscheidend, der durch Power-to-Heat-Applikationen, geschicktes DemandSide-Management² oder Speicher erhöht werden kann. Mit PV-Anlagen versorgte Gebäude sind weiterhin an das elektrische Netz angeschlossen, um Einspeisungen ins deutsche Netz zu ermöglichen und die zeitlich stark variierende Energienachfrage von Haushalten (auch in sonnenschwachen Zeiten) stets decken zu können. Kontrovers wird die effiziente Einbindung von PV-Anlagen in Deutschland diskutiert, da meteorologisch bedingt nur vergleichsweise niedrige Volllaststundenzahlen im Jahr erreicht werden können.

Weitere räumlich verteilte erneuerbare Energiequellen werden vor allem mit Windenergieanlagen im Megawatt-Bereich genutzt und stellen den größten Teil der erneuerbaren Energien dar, sowohl in der Leistungs- als auch der Energiebereitstellung (BMWi 2017b). Sogenannte Mikro-Windenergieanlagen für Haushalte haben sich aufgrund der Wirtschaftlichkeit, ästhetischer Vorbehalte und ihres Lärmemissionsverhaltens noch nicht durchgesetzt (Wosnitza und Hilgers 2012).

² Unter Demand-Side-Management ist die aktive, zielgerichtete Beeinflussung der Energienachfrage gemeint.

Neben der Nutzung von Sonne und Wind kommen zunehmend immer mehr steuerbare Mikro- oder kleine Kraft-Wärme-Kopplungs(KWK)-Anlagen in dezentralen Energiesystemen zum Einsatz. Für einen tief gehenden Einblick sei auf die Arbeit von Schönfelder (2013) verwiesen. Andere dezentrale Erzeugungsanlagen wie beispielsweise Brennstoffzellenanlagen spielen derzeit eine untergeordnete Rolle.

Dezentrale Anlagen mit dargebotsabhängigen erneuerbaren Energien ohne Pufferspeicher sind aufgrund der hohen Gleichzeitigkeit, insbesondere bei PV-Anlagen, aus Netzsicht eher kritisch zu betrachten (Kerber 2011). Bei hohem Durchdringungsgrad in einem Netzabschnitt können sich Situationen einer Lastflussumkehr einstellen. Anhand der Studien dena (2010) und dena (2014) wird deutlich, dass dezentrale Windenergie- und PV-Anlagen (gesicherte Leistung³ von 5 bis 10 % bzw. ca. 1 % der Nennleistung) ohne Speichertechnologien oder Lastverschiebungsmaßnahmen, wie Demand-Side-Management, nur einen geringen Beitrag zur Versorgungssicherheit leisten können.

Zusammenfassend wird die Dezentralisierung der Stromversorgung weiter vorangetrieben, insbesondere durch den Ausbau erneuerbarer Energiequellen. Kritisch werden die Versorgungssicherheit und die Wirkungen auf das deutsche elektrische Netz gesehen. Steuerbare dezentrale Anlagen sollten, soweit möglich, auch netzdienlich betrieben werden. Wirtschaftliche Anreize könnten hierbei über adäquate Stromtarife gesetzt werden.

2.1.2 Integration erneuerbarer Energien

Mit dem Ziel einer nachhaltigen Entwicklung der Energieversorgung wurde die Integration erneuerbarer Energien mit dem StrEG im Jahr 1991 initiiert und durch das zur Jahrtausendwende eingeführte EEG fortwährend gefördert. Im Jahr 2010 verabschiedete die Bundesregierung im Zuge des Kyoto-Protokolls das Energiekonzept mit der Vorgabe, den CO₂-Ausstoß in Deutschland bis 2050 um 80 bis 95 % gegenüber dem Basisjahr 1990 zu reduzieren (BMW i und BMU 2010). Erneuerbare Energien sollen dann 80 % der Stromerzeugung stellen.⁴ Hierfür werden intelligente Netze und der Ausbau von Speicherkapazitäten als notwendige Systemänderungen aufgeführt. Die gesetzlich geregelte Stilllegung aller deutschen Kernkraftwerke bis 2022 erschwert dabei die Erreichung der gesetzten Ziele.

³ Die gesicherte Leistung ist die Mindestleistung von Kraftwerken, die mit extrem hoher Sicherheit ständig verfügbar ist.

⁴ Der (aus physikalischer Sicht ungenaue) Begriff „Stromerzeugung“ (o. Ä.) wird aufgrund seiner weiten Verbreitung in der vorliegenden Arbeit verwendet. Damit ist die Bereitstellung elektrischer Energie gemeint.

Der gesetzlich forcierte Ausbau erneuerbarer Energien hat zu einem starken Kapazitätszuwachs in den vergangenen Jahren geführt (BMWi 2017b). Insbesondere das EEG katalysiert den Ausbau im dezentralen Bereich, indem es die Abnahme zu einer festen Vergütung für die ins lokale Netz eingespeiste Energie garantiert. Der Kapazitätszubau wird von Windenergie- und PV-Anlagen dominiert, auch die Nutzung biogener Brennstoffe steigt stetig an. Im Jahr 2016 sind etwas mehr als 100 GW_{el} Leistung erneuerbarer Energien installiert, die knapp 13 % des gesamten deutschen Primärenergieverbrauch decken. Der Anteil an der Bruttostromerzeugung liegt im Jahr 2016 bei knapp einem Drittel, vergleichsweise fallen die Anteile im Wärmesektor mit 13 % und im Kraftstoffsektor mit 5 % niedriger aus. Bezugnehmend auf die Fallstudie der Arbeit, ist im Jahr 2016 neben einem starken PV-Zubau auf 42 GW_{el} (38 TWh_{el}) der Wärmepumpenbestand auf knapp eine Million Anlagen mit 10 GW_{th} Leistung angestiegen (ca. 2,7 GW_{el} bei einer mittleren Leistungszahl von 3,71, so Appelhans et al. 2014).

Die Effizienz der gesetzlichen Regelungen wird kontrovers diskutiert (Erdmann et al. 2010; Mennel 2012; Weber und Hey 2012). Nach Meinung einiger Kritiker wäre insbesondere der im Jahr 2005 eingeführte Emissionshandel bei adäquater Anwendung, z. B. mit hohen CO₂-Zertifikatspreisen, bereits ein ausreichendes Förderungsinstrument für die Integration erneuerbare Energien, so dass weitere Anreize grundlegend überarbeitet oder abgeschafft werden sollten (Frondel et al. 2011).

Neben der ökonomisch und ökologisch geführten Diskussion werden auch der Kapazitätsbestand und -ausbau im technischen Bereich des Energiesystems kritisch betrachtet. Gesetzliche Vorrangregelungen, fluktuierende Einspeisung unabhängig von der aktuellen Nachfrage und fehlerbehaftete Einspeiseprognosen erneuerbarer Energien erfordern einen tiefgreifenden Wandel des konventionellen Kraftwerksparks. Neben der temporären Über- und Unterdeckung führt die Einspeisung der dominierenden erneuerbaren Windenergie- und PV-Anlagen zu hohen Leistungsgradienten, die sich im schlimmsten Fall additiv verknüpfen. Hinzu kommen langanhaltende Perioden ohne Wind und Sonne (Agora 2013). Die verbleibende Energienachfrage nach Abzug der erneuerbaren Energien, die sogenannte Residuallast, muss durch konventionelle Kraftwerke oder Stromimporte aus dem Ausland gedeckt werden. Einspeisespitzen erneuerbarer Energien zu Zeiten niedriger Elektrizitätsnachfrage sollen durch das im EEG verankerte Einspeisemanagement teilweise abgeregelt werden können. Trotzdem ereigneten sich mit dem aktuellen Marktdesign und der mangelnden Flexibilität des konventionellen Kraftwerksparks sowie der Verbraucherseite weiterhin negative Strompreise in den vergangenen Jahren (siehe EPEX SPOT 2017).

Die steigende Durchdringung der erneuerbaren Energien erfordert auch eine Anpassung des elektrischen Netzes. Dies ist vor allem auf deren regional stark unterschiedlich verteilte Potenziale zurückzuführen. Für Windenergie bestehen die größten Potenziale im Norden, während die höchste Energienachfrage im Süden und Westen in Deutschland liegt, so dass immer mehr elektrische Energie über große Entfernungen transportiert werden muss. Dadurch treten in Zeiten niedriger Nachfrage und hoher Windeinspeisung temporäre Engpässe, vor allem in Nord-Süd-Richtung, auf. Um zukünftig strukturelle Engpässe zu vermeiden, werden mehrere Netz-Ausbauprojekte der Übertragungsnetzbetreiber in Milliardenhöhe unter der Aufsicht der Bundesnetzagentur forciert (2015; BNetzA 2016b).

Auch auf Ebene der Verteilungsnetze besteht die Notwendigkeit tiefgreifender Veränderungen. Neben der wachsenden Dezentralisierung der Energiebereitstellung werden aufkommende elektrische Lasten, die gleichzeitig anfallen, z. B. durch Wärmepumpen oder Elektrofahrzeuge, Auswirkungen auf den Betrieb der Verteilungsnetze haben (Klobasa et al. 2013; Kaschub 2017). Dadurch können zukünftig Extremsituationen im Verteilungsnetz auftreten, für die Teile der Netzbetriebsmittel nicht ausgelegt sind (Kerber 2011): hohe Lastflussumkehrflüsse in Richtung höhergelagerter Netzabschnitte durch gleichzeitig hohe Einspeisung, bspw. vieler PV-Anlagen, sowie extreme Lastspitzen, bspw. durch unkontrolliertes Heizen vieler Wärmepumpen ohne Anreiz zur Lastsenkung.

Alles in allem werden thermische Großkraftwerke und auch dezentrale Kleinanlagen eine tragende Rolle im zukünftigen Energiesystem mit ausgeprägten Fluktuationen spielen. Ein wichtiger Beitrag zur Flexibilisierung des Energiesystems stellt die Sektorenkopplung zwischen Strom, Wärme und Verkehr dar, unter anderem anhand der KWK- oder sogenannter Power-to-X-Technologien.⁵ Daneben sind Ausbaumaßnahmen weiterer Speichermöglichkeiten und des elektrischen Netzes gefordert. Ebenso ist die Flexibilisierung der Erzeugungs- und Verbrauchsseite notwendig, um einen weitersteigenden Anteil erneuerbarer Energien an der Stromerzeugung zu beherrschen, ohne die Versorgungssicherheit zu gefährden. Eine unmittelbare Folge für den Endkunden im Haushaltsbereich könnten vermehrt zeitvariable Tarife für Stromkauf und -verkauf sein, mit deren Hilfe Energieversorger Anreize zur Lastverschiebung dezentraler Energiesystem schaffen könnten.

⁵ Power-to-X-Technologien dienen insbesondere zur Vernetzung der Strom-, Wärme- und Mobilitätssektoren und wandeln temporäre Stromüberschüsse (in der Regel der erneuerbaren Energien) in andere Energieformen um (Power-to-Gas, -Heat oder -Liquids). Eine weiterführende Diskussion über Strategien zur Sektorenkopplung bietet die Meta-Studie von enervis (2018).

2.1.3 Relevanz des Wohngebäudesektors

Im Jahr 2016 betrug der Nettostrombedarf in Deutschland 525,1 TWh_{el} (BDEW 2018). Die Anteile der einzelnen Verbrauchergruppen blieben in den vergangenen zehn Jahren weitgehend stabil. Gut zwei Drittel des Stroms wurden für Produktionsprozesse in der Industrie (≈ 250 TWh_{el}) sowie für Gewerbe, Handel und Dienstleistungen (GHD ≈ 140 TWh_{el}) genutzt. Die rund 40 Mio. Haushalte nutzten ca. 130 TWh_{el} (25 %) des Stroms. Davon wird der größte Teil durch Prozesswärme wie Kochen, Trocknen und Bügeln (29 %) sowie Prozesskälte von Kühl- und Gefriergeräten (23 %) verursacht, gefolgt von Informations- und Kommunikationstechnik (IKT) (17 %) sowie Beleuchtung (8 %). Für Raumwärme (auch als Heizwärme bezeichnet) mit 7 % und Warmwasserbereitung mit 12 % wird eher wenig elektrische Energie verwendet (AGEB 2016).

Im Hinblick auf den gesamten Haushaltsendenergiebedarf von 665 TWh fällt der größte Teil durch die Bereitstellung von Wärmeenergie an: 70 % für Raumwärme und 14 % für Warmwasser sowie 6 % sonstige Wärme für Kochen, Wäschetrocknen oder Wassererwärmung in Wasch- und Spülmaschinen im Jahr 2016 (AGEB 2017a; AGEB 2017b). Der restliche Verbrauch für Kälte zum Kühlen und Gefrieren von Lebensmitteln, für IKT-Dienste, Beleuchtung und mechanische Energie (bspw. zum Antrieb von Wasch- und Spülmaschinen) nimmt eine untergeordnete Rolle ein. Zur Erreichung der energie- und klimapolitischen Zielsetzungen der Bundesregierung stehen im Wohngebäudebereich vor allem Maßnahmen im Vordergrund, die den Endenergiebedarf der thermischen Anwendungen zur Bereitstellung von Raumwärme und Warmwasser sowie den damit verbundenen Hilfsenergieeinsatz reduzieren bzw. den Nutzungsanteil erneuerbarer Energien in diesem Bereich erhöhen (Kunze 2016). Denn vor allem die Beheizungsstruktur ist durch fossile Energieträger geprägt: Im Jahr 2005 wurden noch beinahe 90 % der Wohngebäude durch Gas und Öl beheizt. Seitdem hat sich der Anlagenbestand von Wärmepumpen für Raumwärme und Warmwasser um mehr als verdoppelt. Von den derzeit etwa eine Million Wärmepumpen befinden sich über 95 % im Wohngebäudebereich. Dabei sind vor allem geothermische (Sole-Wasser- oder Wasser-Wasser-) und aerothermische Luft-Wasser-Wärmepumpen ungefähr zu gleichen Teilen im Einsatz. Jedes dritte neugebaute Wohngebäude ist mit einer Wärmepumpe ausgestattet (BMW i 2015).

Etwa zehn Jahre später, im Jahre 2016, wurde der Wärmebedarf für Raumwärme und Warmwasser zu ca. zwei Dritteln mit Gas und Öl gedeckt, erneuerbare Energien trugen mit 15 % zu deren Deckung bei. Der restliche Wärmebedarf wurde durch Fernwärme und Strom gedeckt (AGEB 2017b). Die genannten Zahlen zur Struktur des

Endenergiebedarfs der deutschen Haushalte einschließlich des Energieträgereinsatzes nach Anwendungsbereichen sind in Abb. 2.1 veranschaulicht. Die verfügbare Wohnfläche aller deutschen Haushalte von ca. 3,5 Mrd. m² im Verhältnis zum Energiebedarf für Raumwärme und Warmwasser ergibt einen durchschnittlichen wohnflächenspezifischen Wärmebedarf i. H. v. 160 kWh/m².

Von den rund 40 Mio. Haushalten befinden sich nach Diefenbach (2013) etwas mehr als die Hälfte in Mehrfamilienhäusern, knapp ein Drittel in Einfamilienhäusern und der restliche Bestand in Reihenhäusern. Der Großteil davon liegt im Besitz von Privatpersonen, gefolgt von Wohnungseigentümergeinschaften (87 % privat und 8 % gemeinschaftlich im Jahr 2016, Cischinsky und Diefenbach 2018). Durch den Zusammenschluss mehrerer Wohngebäude (ggf. auch nur durch ein großes Mehrfamilienhaus) lassen sich Wohnquartiere bzw. -siedlungen bilden. Herter (2011) bricht die knapp 20 Millionen deutschen Wohngebäude auf ca. 90 000 Wohnquartiere mit durchschnittlich 425 Wohneinheiten herunter. Bezugnehmend auf das Wohnquartier in Kapitel 8 als relevante Fallstudie eines dezentralen Energiesystems, kann neben der Wärmepumpe eine PV-Dachanlage $\leq 100 \text{ kW}_p$ für die dezentrale Bereitstellung elektrischer Energie installiert werden. Diese Anlagengröße umfasst 98 % aller deutschen Dachanlagen bzw. 73 %, bezogen auf die Gesamtleistung der Dachanlagen (Stand 2013, BMWi 2014).




Abb. 2.1: Struktur des Endenergiebedarfs in Deutschland und in deutschen Haushalten einschließlich des Energieträgereinsatzes nach Anwendungsbereichen im Jahr 2016 (in Anlehnung an Kunze 2016, Daten aus AGEB 2017a; AGEB 2017b entnommen).

2.1.4 Strompreise für dezentrale Energiesysteme

Heute und zukünftig werden dezentrale Energiesysteme elektrische Energie in der Regel mit dem externen Energiesystem mithilfe des vorhandenen Elektrizitätsnetzes austauschen, in das sie integriert sind. Für den Handel ist vor allem der Strompreis entscheidend, mit dem Energie bezogen, aber auch eingespeist werden kann. Zudem ist für die Investitions- und Einsatzplanung die Eigenverbrauchabgabe zu berücksichtigen. Bezugnehmend auf das in der Arbeit verwendete Wohnquartier mit PV-Anlage als Fallstudie,

zeigt Abb. 2.2 die historische Entwicklung der Endkunden-Strompreise auf Haushaltsebene, die Einspeisevergütung für eine 100-kW_p-PV-Dachanlage sowie die Eigenverbrauchsabgabe, die für lokal erzeugten und selbst verbrauchten Solarstrom als anteilige Abgabe der EEG-Umlage entrichtet werden muss (siehe auch Abschnitt 2.2.1).

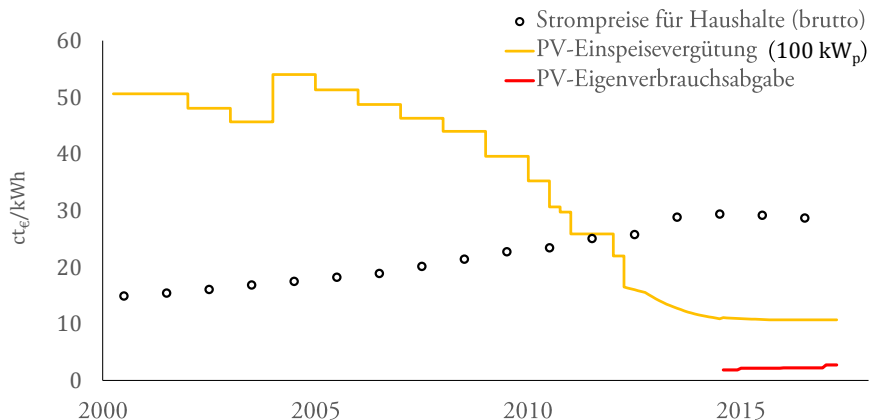


Abb. 2.2: Historische Entwicklung der PV-Einspeisevergütung und -Eigenverbrauchsabgabe sowie der Endkunden-Strompreise in Deutschland (basierend auf Daten von Wirth 2018).

Seit der Einführung des EEG im Jahr 2000 sind die Endkundenpreise für Strom auf Haushaltsebene bis heute um durchschnittlich 5 % pro Jahr gestiegen. Gleichzeitig sind die durchschnittlichen Kosten von PV-Anlagen um durchschnittlich 9 % pro Jahr gesunken (BSW 2015). Diese Kostenreduzierung ging einher mit einer kontinuierlichen Senkung der PV-Einspeisevergütung, die den PV-Eigenverbrauch rentabler und die Flexibilität durch Lastverschiebung, z. B. durch Speicher, attraktiver gestaltet. Im Jahr 2012 konnte die sogenannte Netzparität erreicht werden: Die PV-Einspeisevergütung ist seitdem niedriger als der Bruttopreis von Haushaltsstrom. Seit dem 1. Januar 2016 kann die elektrische Energie von PV-Dachanlagen bis zu 100 kW_p (Stand: 2.6.2018) zu einer festen Einspeisevergütung ins deutsche Netz gespeist werden, die im Jahr 2016 mit 11 ct€/kWh_{el} vergütet wurde. Diese Vergütung wird für 20 Jahre (zzgl. des Jahres der Inbetriebnahme) garantiert. Ab dem Jahr 2020 werden die ersten PV-Anlagen nach und nach aus der 20-jährigen Garantiefrist der EEG-Vergütung ausscheiden.

Für Haushalte gilt üblicherweise ein Endverbraucher-Strompreis, der sich aus einem fixen Arbeitspreis (€ je kWh) mit bestimmten Steuer- und Abgabepflichtanteilen und einer geringen monatlichen oder jährlichen Grundgebühr zusammensetzt. Die genaue

Zusammensetzung des durchschnittlichen Haushalts-Strompreises (Arbeitspreis) ist mit den absoluten und relativen Anteilen in der folgenden Abb. 2.3 dargestellt. Der Strompreis bezieht sich auf das Jahr 2015, der auch als Referenz im Fallbeispiel (siehe Kapitel 8) verwendet wird.




Abb. 2.3: Durchschnittlicher Strompreis (Arbeitspreis) für Endverbraucher auf Haushaltsebene in Deutschland und dessen einzelne absolute und relative Bestandteile für 2015 (BDEW 2015).

Von den insgesamt 28,11 ct_€/kWh_{el} entfallen die größten Anteile am Strompreis auf Beschaffung und Vertrieb (≈ 25 %), Netzentgelte (≈ 24 %), EEG-Umlage (≈ 21 %) und Mehrwertsteuer (≈ 16 %). Während die Mehrwertsteuer vorerst wohl keine Änderung erfährt und für die nächsten 20 Jahre der gleiche relative Anteil veranschlagt wird, sind die Unsicherheiten der anderen drei Parameter deutlich höher. Dies wird in Abb. 2.4 verdeutlicht, in der bis zum Jahr 2035 mögliche Entwicklungen des Strompreises (Arbeitspreises) für Endverbraucher auf Haushaltsebene, der EEG-Umlage und des Großhandels(GH)-Preises verschiedener Studien dargestellt sind. Zusätzlich sind die am Markt zu beobachteten durchschnittlichen Preise für 2016 und 2017 eingetragen. Annahmen zu Brennstoff- und CO₂-Preisen werden nicht gezeigt, da der Studienvergleich primär die Streuung der zukünftigen Strompreispfade und die damit verbundenen Unsicherheiten für den Endverbraucher aufzeigen soll.




Abb. 2.4: Entwicklung des Strompreises (Arbeitspreises) für Endverbraucher auf Haushaltsebene, der EEG-Umlage und des Großhandelspreises von 2016 bis 2035 gemäß verschiedenen Studien (Fahl et al. 2010; Lienert et al. 2010; Nitsch und Wenzel 2010; Herrmann und Hilmes 2011; Knopf et al. 2011; Traber et al. 2011; TU Berlin 2011; Fichtner et al. 2012; Schlesinger et al. 2014; Oei et al. 2015; Öko-Institut 2015).⁶

⁶ Bei der Studie vom Öko-Institut (2015) wurden die Strompreise (Arbeitspreise) für Endverbraucher auf Haushaltsebene auf Basis der EEG-Umlagen und Großhandelspreise abgeleitet.

Die Arbeitspreise zeigen in den aufgeführten Studien eine ähnliche Tendenz: Bis 2025 wird von einem Anstieg ausgegangen, der dann in Richtung 2035 wieder fällt, teilweise unter den Ausgangswert. Im Unterschied zu jüngeren Studien (Schlesinger et al. 2014; Öko-Institut 2015) zeigen ältere Studien deutlich niedrigere Arbeitspreise von bis zu 7 ct_€/kWh_{el}. Der höchste Arbeitspreis aller Studien wird von Schlesinger et al. (2014) erwartet: 31,2 ct_€/kWh_{el} im Jahr 2025 und 28 ct_€/kWh_{el} im Jahr 2035.

Bei der EEG-Umlage sind ebenfalls deutliche absolute Unterschiede von bis zu 6 ct_€/kWh_{el} zu erkennen. Relativ gesehen, liegt eine ähnliche Entwicklung vor: Für 2025 wird eher von einer steigenden Umlage ausgegangen, die in Richtung 2035 wieder fällt. Das bedeutet, dass alle Studien von steigenden Kosten für die Integration erneuerbarer Energien ausgehen, die erst 2025 ihren Scheitel erreicht haben werden. Nur die Leitstudien von Nitsch und Wenzel (2010) gehen bereits ab 2016 von einer kontinuierlichen Senkung der EEG-Umlage auf 0,7 bzw. 0,3 ct_€/kWh_{el} bis 2030 aus. Die jüngste aufgeführte Studie vom Öko-Institut (2015) zeigt die höchsten EEG-Umlagen über alle Jahre hinweg: beginnend mit 6,3 ct_€/kWh_{el} in 2016, über 7,6 ct_€/kWh_{el} im Jahr 2025 und endend mit 4,4 ct_€/kWh_{el} im Jahr 2035.

Die GH-Preise zeigen einen konträren Verlauf. Die Studien von Lienert et al. (2010), Nitsch und Wenzel (2010), Herrmann und Hilmes (2011), Fichtner et al. (2012) sowie Schlesinger et al. (2014) zeigen deutliche Anstiege der GH-Preise: bis zu 9,4 ct_€/kWh_{el} im Jahr 2030 (Leitstudie „Deutlich“ von Nitsch und Wenzel 2010) und 7,5 ct_€/kWh_{el} im Jahr 2035 (Schlesinger et al. 2014). Konträr nehmen Fahl et al. (2010), Knopf et al. (2011), Oei et al. (2015) und das Öko-Institut (2015) einen gleichbleibenden bis fallenden GH-Preis an, der 2035 bei knapp 3 ct_€/kWh_{el} liegen würde.

Der Vergleich der verschiedenen Strompreispfade wird zusätzlich durch unterschiedliche Inflationsraten erschwert, die von 1,5 bis 2,3 % reichen oder nicht angegeben (n. a.) sind. Dies zeigt aber generell die große Unsicherheit und Streuung in positiver und negativer Richtung über die Annahme der Entwicklung der Arbeits- und GH-Preise sowie der EEG-Umlage, welche auch maßgebend für die PV-Eigenverbrauchsabgabe ist (35 % im Jahr 2016 und 40 % ab 2017, siehe Abschnitt 2.2.1).

In Zukunft könnten auch die derzeit vereinzelt angebotenen Tarife mit dynamischen Strompreisen verstärkt im Haushaltsbereich Anwendung finden, einhergehend mit dem gesetzlich auferlegten Smart-Meter-Rollout. Dabei besteht die Möglichkeit, Elektrizität zum GH-Preis plus diverse Steuern und Abgaben zu beziehen. Umgekehrt ist auch der Verkauf zu ähnlichen Preisen möglich, z. B. von eingespeicherter elektrischer Energie oder auch von PV-Energie, die nicht zum festen Einspeisetarif veräußert wird. Während Steuern und Abgaben einen festen Anteil am Gesamtstrompreis haben, welche in der

Regel nur langfristig administrativ angepasst werden, ist der GH-Preis gewissen kurzfristigen Schwankungen ausgesetzt.

Die GH-Preise bilden sich an den Energiebörsen, z. B. an der europäischen Strombörse *European Power Exchange* (EPEX) SPOT SE in Paris, alle 15 min durch das Zusammentreffen von elektrischem Energieangebot und elektrischer Energienachfrage zu verschiedenen Mengen und Preisen der Marktteilnehmer: Der GH-Preis wird durch den Gleichgewichtspreis (*Market-Clearing-Preis*) gebildet, bei dem die Angebotsmenge gleich der Nachfragemenge ist. Unter idealen Marktbedingungen wird dieser Preis theoretisch durch das Kraftwerk mit den höchsten Grenzkosten (Grenzkraftwerk) bestimmt, das noch zur Deckung der Energienachfrage nötig ist (Wirth 2016). Ein wesentlicher Einflussfaktor ist hierbei die Energiebereitstellung aus wetterabhängigen erneuerbaren Quellen innerhalb des deutschen Strommarkts.⁷ Daher werden für die vorliegende Arbeit dynamische Preise als Funktion von den simulierten meteorologischen Daten abgeleitet. Hierfür werden historische Day-ahead-Preise des *Physical-Electricity-Index*(PHELIX)-Spotmarkts der EPEX verwendet, der den primären Marktplatz für Elektrizitätshandel in Deutschland darstellt (siehe Abschnitt 6.2.3).

Des Weiteren existieren auch Tarife mit Leistungspreisen, bei dem neben einem gewissen Arbeitspreis auch die maximale Bezugslast vom Netz bepreist wird (€ je kW^{\max}).⁸ Derzeit werden arbeits- und leistungspreisbasierte Tarife vorwiegend im Industriesektor angeboten (Kaschub 2017). Für kleinere dezentrale Energiesysteme, etwa Wohnquartiere, bilden sie eher die Ausnahme.

⁷ Einspeisungen von erneuerbaren Energien mit Grenzkosten gegen null senken die Preise, jedoch wird diese Preissenkung, wenn überhaupt, nur indirekt über Endkundenpreise langfristig weitergegeben. Kurzfristig erhöht sich sogar der Arbeitspreis für Haushalte, da die anfallenden Kosten für die Einspeisevergütung über die EEG-Umlage umgewälzt werden.

⁸ Beispielsweise könnte der Arbeitspreis um die enthaltenen Netzentgelte (derzeit $7 \text{ ct}_{\text{€}}/\text{kWh}_{\text{el}}$) reduziert werden und ein gesonderter Leistungspreis für den maximalen Netzbezug vom externen Energieversorger innerhalb einer bestimmten Periode (z. B. Monat oder Jahr) bepreist werden. Ebenso wäre die gesonderte Bepreisung der max. Einspeiselast in kritischen Netzabschnitten denkbar.

2.2 Politische und rechtliche Rahmenbedingungen

Ambitionierte Klimaschutzziele der Deutschen Bundesregierung und der Europäischen Union spiegeln sich in Politik und einer Vielzahl von Gesetzen und Verordnungen wider. Aufgrund ständiger Anpassungen der Gesetzeslage unterliegt die Investitions- und Einsatzplanung des privaten Entscheiders gewissen Unsicherheiten. Im Folgenden werden die wichtigsten gesetzlichen Rahmenbedingungen beschrieben, die einen Einfluss auf die Investitions- und Einsatzplanung von dezentralen Energiesystemen haben (Abschnitt 2.2.1 bis 2.2.4). Weitere regulatorische Bedingungen speziell für Wohnquartiere werden in Abschnitt 2.2.5 vorgestellt.

2.2.1 Erneuerbare-Energien-Gesetz

Als weltweit erstes Ökostrom-Einspeisegesetz galt das seit 1991 geltende StrEG (Lüdeke-Freund und Opel 2014). Das Gesetz verpflichtete die Netzbetreiber zur Abnahme des Stroms erneuerbarer Energien mit einer gesicherten Mindestvergütung. Im Jahr 2000 wurde dieses Gesetz vom EEG mit den beiden zentralen Grundprinzipien eines gesetzlich gesicherten Einspeisevorrangs sowie einer technologie- und einsatzartenabhängigen Einspeisevergütung abgelöst (Ergen 2015). Die Vergütung wird für die gesamte Förderdauer von 20 Kalenderjahren (zzgl. des verbleibenden Zeitraums im Jahr der Inbetriebnahme) garantiert und über die bundesweite EEG-Umlage finanziert, die Bestandteil des Endnutzerpreises beim Strombezug von einem Lieferanten ist. Ein drittes Grundprinzip, der vorrangige Anschluss von Anlagen mit erneuerbaren Energien, wurde mit der ersten Novelle des EEG 2004 eingeführt (BRD 2004).

Die aktuellen Mindestziele hinsichtlich des Anteils erneuerbarer Energien an der Stromversorgung betragen 35 % im Jahr 2020 und 80 % im Jahr 2050 (BRD 2012a). Für einen planbaren Wachstumspfad und bessere Synchronisation mit dem Netzausbau wurde ein Ausbaukorridor für verschiedene erneuerbare Energien festgelegt.⁹ Außerdem müssen Anlagen mit erneuerbaren Energien vom Betreiber der Bundesnetzagentur gemeldet werden, um sich die Einspeisevergütung in Höhe des EEG vom Netzbetreiber auszahlen zu lassen. Für den Eigenverbrauch ist seit 2015 eine anteilige EEG-Umlage als Abgabe fällig. Diese beträgt 30 % des jeweils gültigen Umlagebetrags im Jahr 2015,

⁹ Für die konstanten Vergütungsraten wurde eine gleitende Degression in Abhängigkeit vom PV-Zubau eingeführt. Das Gesamtausbauziel für die geförderte PV ist in Deutschland auf 52 GW_p gedeckelt, der Ausbaukorridor beträgt derzeit 2,5 GW_p pro Jahr (BRD 2012c; BRD 2014).

35 % in 2016 und 40 % ab dem Jahr 2017. Vom öffentlichen Netz vollständig abgetrennte Inselanlagen sowie 10 MWh_{el} eigenverbraucher Strom von Anlagen mit einer Leistung kleiner 10 kW_{el} sind von dieser Abgabe befreit. Zu beachten gilt auch, wenn der Anlagen-Eigentümer nicht auch Verbraucher ist (z. B. bei Mietwohnungen), fällt die volle EEG-Umlage auf den eigenverbrauchten Strom an. Im Fall einer Wohnungseigentümergeinschaft wird für den Gemeinschaftsstrom die anteilige EEG-Umlage angerechnet. Für den individuellen Stromverbrauch der Wohnungseigentümer muss die EEG-Umlage vollständig abgeführt werden (BNetzA 2016a).

Der Abbau der Überförderung und damit eine Kostenreduktion mittels zukünftiger Ermittlung der Förderhöhe erfolgen über Ausschreibungen.¹⁰ Generell sind Wasserkraft-, Geothermie-, Deponiegas-, Klärgas- und Grubengasanlagen sowie Anlagen bis 750 kW_{el} vom Ausschreibungsverfahren ausgenommen und werden nach dem bisherigen Förderungssystem vergütet. Für Anlagen mit erneuerbaren Energien zwischen 100 und 750 kW_{el}, die ab dem 1. Januar 2016 in Betrieb genommen wurden, besteht eine Pflicht zur Direktvermarktung des erzeugten Stroms (BRD 2016). Erzeugungsspitzen neuer Anlagen können vom Netzbetreiber oder Direktvermarkter unter bestimmten Bedingungen unentgeltlich abgegelt werden.

2.2.2 Energieeinsparverordnung

Bereits Jahrzehnte vor der Einführung des StrEG und EEG sollte der Energiebedarf von Haushalten durch bauliche Maßnahmen gesenkt werden, um den steigenden Energiepreisen nach der Ölkrise 1973 und den aufkommenden Klimaschutzanforderungen zu begegnen. Aufbauend auf dem im Jahr 1976 verabschiedeten Energieeinsparungsgesetz (EnEG) wurde ein Jahr später die erste Wärmeschutzverordnung mit vorgegebenen Dämmstandards für Neubauten verabschiedet (BRD 1976; BRD 1997). Über mehrere Novellierungen wurde später der Wärmebedarfsausweis mit Grenzwerten für den Heizwärmebedarf eingeführt. Im Jahr 2002 wurde das Gesetz in die Energieeinsparverordnung (EnEV) überführt (BRD 2002a). Während der Fokus zuvor auf qualitativen Einzelbauteilanforderungen lag, werden durch die EnEV Anforderungen auf der Grundlage einer energetischen Bilanzierung des gesamten Gebäudes definiert sowie neben der erforderlichen Nutzenergie auch der Energieverlust und -aufwand für die gebäudeinterne Wärmeerzeugung und -verteilung mit in die Betrachtung einbezogen (Kunze 2016).

¹⁰ Für Ausschreibungsanlagen gilt ein Eigenversorgungsverbot Valentin (2018).

Dabei werden im Wesentlichen einzuhaltende energetische Kenngrößen, zu verwendende Geräte und Anlagen und die Pflicht des Energieausweises für Neubauten, Gebäudeerweiterungen und Sanierungen geregelt.

Für Neubauten gelten die Bauanforderungen des mit der EnEV 2009 eingeführten Referenzgebäudeverfahrens (BRD 2009): Basierend auf einem virtuellen Referenzgebäude mit entsprechender Geometrie, Gebäudenutzfläche und Ausrichtung, werden zulässiger Jahresprimärenergiebedarf des Gebäudes, Transmissionswärmeverluste der thermischen Gebäudehülle sowie Anforderungen an den sommerlichen Wärmeschutz berechnet. Mit der neuesten EnEV-Fassung von 2014 wurden die maximal zulässigen Werte weitergesenkt. Außerdem kann seitdem das Referenzgebäudeverfahren zur Ermittlung des Jahresprimärenergiebedarfs entweder nach DIN V 18599 oder für Wohngebäude ohne technische Ausstattungen zur Kühlung nach DIN V 4108-6 in Verbindung mit DIN V 4701-10 erfolgen (Kunze 2016).

Bei Gebäudeerweiterungen und Sanierungen von Bestandsgebäuden beschränkt sich die EnEV weiterhin auf die Vorgabe einzuhaltender Wärmedurchgangskoeffizienten für Bauteile der wärmeübertragenden Umfassungsfläche. Die EnEV gilt nur bei Änderungen der Baufläche > 10 % und bei Überschreitung des Jahresprimärenergiebedarfs oder des spezifischen Transmissionswärmeverlusts > 40 % in Relation zu einem vergleichbaren Neubau. Daneben gelten Ersatzvorschriften für bestimmte Heiz- und Kühlanlagen sowie bauspezifische Dämmvorgaben (BRD 2013; Schönfelder 2013).

Im Fall der Errichtung oder Änderung des Gebäudes ist der Bauherr verpflichtet, dass der Eigentümer einen Energieausweis einschließlich Modernisierungsempfehlungen gemäß EnEV-Vorschriften erhält. Die aktuelle EnEV 2014 teilt Häuser anhand ihres Endenergie- und gesamten Jahresprimärenergiebedarfs in Energieeffizienzklassen von A+ (< 30 kWh/(m² · a)) bis H (> 250 kWh/(m² · a)) ein. Außerdem gelten für Neu- sowie große Umbauten parallel zur bundesweiten EnEV auch Erneuerbare-Energien-Wärmegesetze, die im folgenden Abschnitt 2.2.3 beschrieben werden: Bei Neubauten muss der spezifische Jahresprimärenergiebedarf seit 2016 unter 57,3 kWh/(m² · a) (zuvor noch 79,2 kWh/(m² · a)) liegen, der spezifische Transmissionswärmeverlust unter 0,4 W/(m² · K) (nach DIN V 4701-10, ASUE 2014). Bei Nichtumsetzung oder -einhaltung können Bußgelder von bis zu 50.000 € drohen.

2.2.3 Erneuerbare-Energien-WärmeGesetze

Mit Inkrafttreten des *Gesetzes zur Förderung Erneuerbarer Energien im Wärmebereich* (des Erneuerbare-Energien-WärmeGesetzes, EEWärmeG) sollen 14 % des Endenergiebedarfs für Wärme und Kälte durch erneuerbare Energien bis 2020 gedeckt werden (BRD 2011). Hierfür gelten bundeseinheitliche Regelungen prinzipiell für Neubauten im Wohnbereich und bestimmte Nichtwohngebäude, um einen gewissen Anteil durch die Nutzung erneuerbarer Energien zu decken oder den Wärmebedarf signifikant zu senken.

In dem Gesetz werden mit der sogenannten Nutzungspflicht Ziele hinsichtlich des Deckungsanteils erneuerbarer Energien am Wärme- und Kältebedarf des Gebäudes festgelegt. Dabei sind verschiedene Technologie- bzw. energieträgerspezifische Mindestdeckungsanteile vorgegeben: für solare Strahlungsenergie, Biomasse, Geothermie und Umweltwärme. Zur Erfüllung der Nutzungspflicht kann die Form der erneuerbaren Energie vom Eigentümer gewählt werden. Beispielsweise kann die Vorgabe mit Wärmepumpen mit der Deckung des Wärmebedarfs > 50 % erreicht werden.¹¹ Alternativ kann den Anforderungen auch durch definierte Ersatzmaßnahmen nachgekommen werden (z. B. durch verstärkten Einsatz von KWK oder Übererfüllung der EnEV-Vorgaben). Erneuerbare Energien und Ersatzmaßnahmen können zur Erfüllung der Nutzungspflicht kombiniert werden. Alternativ ist auch eine pauschale Größenauslegung der Solaranlage in Abhängigkeit von der Gebäudenutzfläche möglich (ASUE 2014).

Bundesländer haben das Recht, die Nutzungspflicht für erneuerbare Energien mit landesspezifischen Regelungen auch auf Bestandswohngebäude auszuweiten. Bislang wurden nur in Baden-Württemberg mit dem *Gesetz zur Nutzung erneuerbarer Wärmeenergie in Baden-Württemberg* (Erneuerbare-Wärme-Gesetz, EWärmeG) ergänzende Vorgaben für Bestandswohngebäude im Jahr 2008 verabschiedet (LBW 2007). Mit der letzten Novellierung sind die Eigentümer von Bestandswohngebäuden beim Austausch wesentlicher Komponenten der Heizanlage verpflichtet, mindestens 15 % des Wärmebedarfs durch erneuerbare Energien zu decken (UMBW 2013). Ähnlich wie im EEWärmeG des Bundes enthält das EWärmeG die Möglichkeit, den Anforderungen durch Ersatzmaßnahmen und Kombinationen aus teilweise erfüllten Einzelbedingungen gerecht zu werden. Hier führt eine PV-Anlage, welche die Installation einer solarthermischen Anlage verhindert, zur Befreiung von der Nutzungspflicht.

¹¹ Darüber hinaus definiert das Gesetz Mindestwerte für die Jahresarbeitszahl (3,5 für Luft-Wasser- und Luft-Luft-Wärmepumpen sowie 4 für alle anderen Wärmepumpen) sowie die Notwendigkeit von Strom-, Brennstoff- und Wärmemengenzählern.

2.2.4 Kraft-Wärme-Kopplungsgesetz

Seit 2002 regelt das *Gesetz für die Erhaltung, die Modernisierung und den Ausbau der Kraft-Wärme-Kopplung* (das Kraft-Wärme-Kopplungsgesetz, KWKG) Einspeisung und Vergütung des Stroms aus KWK-Anlagen in Deutschland (BRD 2002b). Mit dem KWKG sollen Modernisierung und Neubau von KWK-Anlagen und Wärmenetzen gefördert werden. Seit der Novellierung im Jahr 2012 sind auch Kraft-Wärme-Kälte-Kopplung (KWKK), Wärme- und Kältespeicher sowie Kältenetze förderfähig (BRD 2012b). Durch die gekoppelte Erzeugung von Strom und Wärme (oder Kälte) soll ein Beitrag zur Primärenergieeinsparung und zur Verminderung von CO₂-Emissionen erreicht werden. Ziel des Gesetzes ist die Erhöhung der Nettostromerzeugung aus KWK-Anlagen im Interesse der Energieeinsparung sowie des Umwelt- und Klimaschutzes auf 110 TWh_{el}/a bis zum Jahr 2020 sowie auf 120 TWh_{el}/a bis zum Jahr 2025 (BRD 2015). Im Jahr 2016 ist mit 110 TWh_{el} Nettostromerzeugung aus KWK-Anlagen das Ziel für 2020 bereits erreicht worden (Baten et al. 2017).

Als KWK-Anlagen gelten laut Gesetz der BRD (2015) Anlagen, die Strom und Nutzwärme auf Basis von Abfall, Abwärme, Biomasse, gasförmigen oder flüssigen Brennstoffen bereitstellen (ASUE 2017).¹² Die Förderung erfolgt über Zuschlagszahlungen zwischen 1 bis 8 ct_{€/kWh_{el}} für erzeugten KWK-Strom (Stand: 10.12.2018) und richtet sich nach der elektrischen Nennleistung der Anlage sowie der eigenverbrauchten oder eingespeisten elektrischen Energie. Es gelten separate Förderregelungen für nachgerüstete, modernisierte oder neue Anlagen. Bei neuen und modernisierten KWK-Anlagen von 1 bis 50 MW_{el} oder „innovativen KWK-Systemen“ (z. B. mit Wärmepumpe) sind die Zuschlagzahlungen über Ausschreibungen zu ermitteln. Es werden keine Zuschlagzahlungen in Stunden mit negativen Börsenstrompreisen oder bei Anlagen mit Kohle-Feuerung gewährt. Hingegen erfolgen zusätzliche Bonuszahlungen für die Ersetzung bestehender Kohle-gefeuerter KWK-Anlagen i. H. v. 0,6 ct_{€/kWh_{el}} oder für Anlagen im Anwendungsbereich des Treibhausgas-Emissionshandelsgesetzes (TEHG) i. H. v. 0,3 ct_{€/kWh_{el}}. Zusätzlich zu den Zuschlagzahlungen erhalten Betreiber von KWK-Anlagen bis zu einer Größe von 100 kW_{el} den durchschnittlichen Preis des an der Strombörse *European Energy Exchange* gehandelten Grundlaststroms des vorangegange-

¹² Darüber hinaus gelten folgende Förderungsvoraussetzungen: Aufnahme des Dauerbetriebs bis 31.12.2022, keine Verdrängung bestehender Fernwärmeversorgung aus KWK-Anlagen sowie Ausstattung von Anlagen über 100 kW_{el} mit einer Einheit zur Fernsteuerbarkeit zum Zweck der Leistungsreduzierung oder -abrufung entsprechend EEG § 9.

nen Quartals. Für Anlagen, die größer als $100 \text{ kW}_{\text{el}}$ sind, gilt die Direktvermarktungspflicht.¹³

Die Förderdauer hängt von der Leistungsklasse ab und kann bis zu 60 000 vbh betragen.¹⁴ Mikro-KWK-Anlagen ($\leq 2 \text{ kW}_{\text{el}}$) können optional eine pauschale Vorabauszahlung der Zuschläge erhalten. Ähnlich wie beim EEG wird die Förderung, die Betreiber von KWK-Anlagen erhalten, auf den gesamten Strombedarf umgelegt. Die Kostenumlage erfolgt über einen KWK-Aufschlag (siehe Strompreiszusammensetzung in Abschnitt 2.1.4) vom Netzbetreiber auf die im Strompreis enthaltenen Netzentgelte. Die Umlage der Förderkosten ist auf 1,5 Mrd. €/a begrenzt (ASUE 2017).

2.2.5 Spezifische regulatorische Bedingungen für Wohnquartiere

Das im Fallbeispiel in Kapitel 8 untersuchte Wohnquartier unterliegt einer Reihe weiterer regulatorischer Rahmenbedingungen. Beispielsweise muss bei sehr großen dezentralen Energieerzeugungsanlagen ($> 2 \text{ MW}_{\text{el}}$) beachtet werden, dass auf die objektintern erzeugten und verbrauchten Strommengen eine Stromsteuer gemäß *Stromsteuergesetz* (StromStG) i. H. v. $2,05 \text{ ct}_{\text{e}}/\text{kWh}_{\text{el}}$ erhoben wird (BRD 1999). Generell fällt keine Stromsteuer für Strom aus erneuerbaren Energieträgern an, wenn dieser aus einem Netz entnommen wird, in dem ausschließlich Strom aus erneuerbaren Energieträgern eingespeist wird. Außerdem sind Anlagen von der Stromsteuer befreit, wenn der Strom in einem „räumlichen Zusammenhang“ zur Anlage verbraucht wird.

Gemäß Rechtsleitfaden für Wohnquartiere von Jacobshagen et al. (2017) wird das Quartier definiert als „ein räumlich abgrenzbarer Bereich, der über eine energetische Infrastruktur verfügt, die an ein vorgelagertes Netz der allgemeinen Versorgung angeschlossen ist. Insellösungen werden insoweit nicht betrachtet. Das Quartier verfügt über mindestens eine Erzeugungsanlage und mehrere Letztverbraucher und ggf. auch über einen Speicher.“ Kritisch ist die Definition eines „räumlichen Zusammenhangs“ nach dem *Gesetz über die Elektrizitäts- und Gasversorgung* (EnWG), die neben weiteren Kriterien ausschlaggebend ist, ob ein Verteil- oder Transportnetz oder eine Kundenanlage im Quartier vorliegt (siehe § 3 Nr. 24a EnWG). Die Einstufung in Kundenanlage oder

¹³ Zusätzlich wird ein ortsabhängig vermiedenes Netznutzungsentgelt zwischen $0,5$ und $2 \text{ ct}_{\text{e}}/\text{kWh}_{\text{el}}$ vergütet. Diese Vergütung entfällt nach dem Netzentgeltmodernisierungsgesetz für KWK-Neuanlagen ab 2023.

¹⁴ Die Vollbenutzungsstunden (vbh) sind definiert als der Quotient aus der jährlichen zuschlagberechtigten KWK-Nettostromerzeugung und der Nennleistung (BRD 2015).

Netz ist entscheidend für die Wirtschaftlichkeit des Geschäftsmodells des Quartiersbetreibers. Im Fall einer Kundenanlage fallen keine netzregulatorischen Anforderungen an den Betreiber an und keine netznutzungsbezogenen Abgaben oder Umlagen für innerhalb der Kundenanlage erzeugten und gelieferten Strom. Nach Valentin (2018) ist diese Kategorisierung für Wohnquartiere nicht immer eindeutig. Es gibt gegensätzliche Gerichtsentscheidungen über das Vorhandensein eines „räumliche[n] Zusammenhangs“ vergleichbarer Wohnquartiere. Insofern stehen Wohnungseigentümer, insbesondere beim Neubau, nicht nur vor ökonomischen, sondern auch vor juristischen Fragestellungen. In dem Rechtsleitfaden Jacobshagen et al. (2017) wurden die verschiedenen rechtlichen Entwicklungen seit Mai 2016 berücksichtigt und dargestellt.

Mit Inkrafttreten des *Gesetzes zur Förderung von Mieterstrom und zur Änderung weiterer Vorschriften des Erneuerbare-Energien-Gesetzes* (Mieterstromgesetz) im Jahr 2017 besteht ein Anspruch des Anlagenbetreibers einer PV-Dachanlage ($\leq 100 \text{ kW}_p$) auf eine Zuschlagszahlung für den lokal verbrauchten Mieterstrom (BRD 2017). Mieterstrom ist der von PV-Dachanlagen eines Wohngebäudes erzeugte Strom, der direkt ohne Netzdurchleitung an Letztverbraucher in diesem Gebäude oder in Nebenanlagen und -wohngebäuden im unmittelbaren räumlichen Zusammenhang geliefert und verbraucht wird. Der Mieterstromzuschlag orientiert sich an den EEG-Einspeisevergütungen für PV-Strom abzüglich eines Abschlags von $8,5 \text{ ct}_e/\text{kWh}_{el}$. Der durch den Mieterstromzuschlag förderfähige Zubau von Solaranlagen ist auf $500 \text{ MW}_p/\text{a}$ begrenzt. Anspruchsberechtigt ist der Anlagenbetreiber, also im Regelfall der Quartiersversorger. Der Mieter muss seinen Stromanbieter weiterhin frei wählen können und Miet- und Stromlieferungsvertrag dürfen nicht gekoppelt werden. Zum Schutz des Mieters ist eine Höchstgrenze von 90 % des Grundversorgertarifs für den Mieterstrom angesetzt.

Verschiedene Programme fördern die Anschaffung oder Modernisierung bestimmter Energiesystemkomponenten im Wohngebäudesektor. Beispielsweise fördert die Kreditanstalt für Wiederaufbau (KfW) die Anschaffung von PV-Anlagen und stationären Batteriespeichersystemen mittels zinsgünstigen Darlehen und Tilgungszuschüssen. Die Anschaffung der Wärmepumpe kann ggf. durch Basis-, Innovations- und Zusatzförderungen vom Bundesamt für Wirtschaft und Ausfuhrkontrolle zwischen 1.300 bis maximal 11.800 € zusätzlich bezuschusst werden (BAFA 2018).

3 Grundlagen dezentraler Energiesysteme

Generell gilt für dezentrale Energiesysteme, dass ein Teil der Energie zur Bedarfsdeckung unmittelbar vor Ort (lokal), entweder innerhalb von Gebäuden, Communities oder Bauungen oder bedarfsnah mit direkter Verbindung, umgewandelt und angeboten wird (Wolfe 2008). Ein schematischer Aufbau eines dezentralen Energiesystems ist in Abb. 3.1 dargestellt, bestehend aus lokalem Energieangebot und lokaler Energienachfrage sowie der Option, Energie lokal zu speichern oder extern einzuspeisen oder zu beziehen.

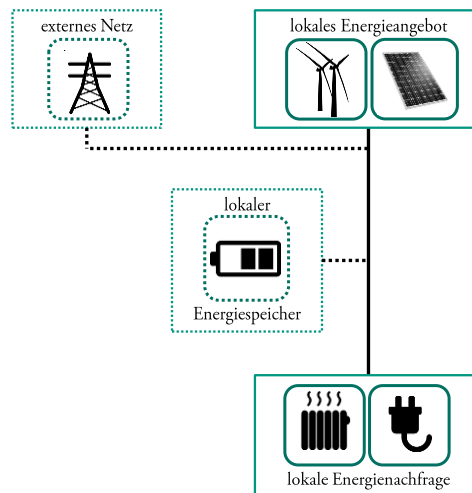


Abb. 3.1: Schema eines dezentralen Energiesystems.

In den folgenden Abschnitten 3.1, 3.2 und 3.3 werden Energieangebot und -nachfrage sowie Möglichkeiten zur Energiespeicherung beschrieben. Dabei wird primär auf die Energiesystemkomponenten des verwendeten Wohnquartiers der Fallstudie in Kapitel 8 eingegangen.

3.1 Lokales Energieangebot

In dezentralen Energiesystemen kommen vor allem Wind-, PV-, vereinzelt auch Wasserkraft-Anlagen und Brennstoffzellen für die Bereitstellung elektrischer Energie zum Einsatz. Daneben sind thermische Kleinkraftwerke, z. B. Gasturbinen, Diesel- oder

Benzinmotoren weit verbreitet. Oftmals sind elektrische Erzeugungsanlagen auch zur Bereitstellung thermischer Energie in Form von KWK-Anlagen gekoppelt oder mit Power-to-Heat-Applikationen kombiniert. In den folgenden Abschnitten 3.1.1 und 3.1.2 werden die lokalen Erzeugungsanlagen der Fallstudie vorliegender Arbeit vorgestellt: eine PV-Anlage und Wärmepumpen.

3.1.1 Photovoltaikanlage zur Bereitstellung elektrischer Energie

Der elektrische Ertrag hängt primär vom einfallenden Licht, der PV-Moduleffizienz sowie der Ausrichtung und Kapazität (Nennleistung) der PV-Anlage ab. Die Jahressumme der mittleren (horizontalen) Globalstrahlungsenergie liegt in Deutschland bei $1\,053\text{ kWh/m}^2$ und beträgt in Karlsruhe ca. $1\,150\text{ kWh/m}^2$ (Zeitraum: 1981-2010, Riecke 2011). Für einen maximalen Ertrag sind die Kollektorflächen in Deutschland approximativ gen Süden mit einem Neigungswinkel von 30° ausgerichtet (Wirth 2018). Der gelieferte Gleichstrom wird üblicherweise von Wechselrichtern für die Netzeinspeisung angepasst.

Die PV-Moduleffizienz hängt grundsätzlich vom verwendeten Material und der Kristallstruktur der PV-Zellen ab. Am häufigsten werden amorphe Dünnschicht- oder mono- und polykristalline Dickschichtmodule aus Silizium verbaut. Bei Verwendung von Silizium ist der Wirkungsgrad aufgrund bestimmter physikalischer Eigenschaften auf 33 % für unfokussiertes Licht auf der Erde begrenzt (Würfel 2000; Würfel und Trupke 2003). Laut Wirth (2018) erreichen sehr gute, kommerziell erhältliche monokristalline Silizium-Dickschichtmodule ca. 20 % unter Standardtestbedingungen.¹⁵ Daneben entscheiden im Betrieb auch Schwachlicht- und Temperaturverhalten, Wirkungsgradverluste durch Verschmutzung und Modul-Mismatch sowie Wechselrichter- und Leitungsverluste über die Effizienz. Der resultierende Gesamtwirkungsgrad der PV-Anlage wird in der sogenannten Performance-Ratio zusammengefasst. Übliche Jahreswerte liegen zwischen 80 und 90 %. Demnach werden in Deutschland je nach Einstrahlung und Performance-Ratio spezifische Erträge um $900\text{ kWh}_{\text{el}}/\text{kW}_{\text{p}}$, in sonnigen Gegenden $1000\text{ kWh}_{\text{el}}/\text{kW}_{\text{p}}$ erzielt. Bei guten Modulen mit 20%-Wirkungsgrad entspricht dies ca. $200\text{ kWh}_{\text{el}}$ pro Quadratmeter Modulfläche. Hierbei gilt zu beachten, dass die Module ungefähr das zwei- bis zweieinhalbfache ihrer eigenen Fläche auf flachen Dächern und

¹⁵ Die Leistungsmessung erfolgt nach DIN EN 61215 bei einer Einstrahlungsstärke von 1000 W/m^2 und einem Strahlungsspektrum nach DIN EN 60904 senkrecht zur Modulebene bei 25°C .

im Freiland belegen, um gegenseitige Verschattung und damit eine Ertragsminderung der Anlage zu vermeiden. Die Beabstandung kann durch Installationen mit niedrigeren Neigungswinkeln verringert werden. Häufig wird hier die Ost-West-Ausrichtung gewählt. Abb. 3.2 zeigt die mittleren PV-Ertragsprofile mit ertragsmaximaler Süd-Ausrichtung im Vergleich zu einer Ost-West-Ausrichtung für das Jahr 2016 in Karlsruhe.




Abb. 3.2: Mittlere PV-Ertragsprofile bei ertragsmaximaler Süd-Ausrichtung (durchgezogene Linie) sowie Ost-West-Ausrichtung (gepunktete Linie) für 2016 in Karlsruhe; berechnet mit PV-Generations-Modul (siehe Abschnitt 6.2.1) und Einstrahlungsdaten vom KIT-Physikhochhaus (IMK 2018).

Zwar sinkt der spezifische Jahresertrag um ca. 20 % (212 kWh_{el}/kW_p) im Vergleich zur Süd-Ausrichtung, aber die Koinzidenz von PV-Energie und Haushaltsstrombedarf steigt und damit der Eigenverbrauch. Letzteres lohnt sich umso mehr, je größer die Differenz zwischen Strombezugs- und Stromgestehungskosten ist. Haushalte ohne Speichermöglichkeiten erreichen in Abhängigkeit der Anlagenkapazität in der Regel Eigenverbrauchsquoten von 20 bis 40 % des erzeugten PV-Stroms (Weniger et al. 2012).

Die durchschnittlichen Nettopreise für PV-Anlagen kleiner 100 kW_p belaufen sich im Jahr 2018 auf ca. 1.200 €/kW_p (Wirth 2018). Darin sind alle Kosten für Installation und Anlagenteile enthalten, wovon etwa 50 % auf die Solarmodule entfallen. Die darüber hinaus anfallenden Instandhaltungskosten können mit 1 bis 1,5 % der

Anschaffungskosten¹⁶ geschätzt werden (Kaschub 2017; Wirth 2018). Von Herstellern wird üblicherweise eine Lebensdauer von 20 bis 25 Jahren mit 80 % der Nennleistung am Ende garantiert. Dies entspricht einer mittleren Degradation von 0,8 bis 1 % p. a.

3.1.2 Wärmepumpe zur Bereitstellung thermischer Energie

Wärmepumpen nehmen thermische Energie aus einer Umgebung (Wärmequelle) auf niedrigem Temperaturniveau auf und geben sie als Nutzwärme für ein zu beheizendes System auf höherem Temperaturniveau ab. Hauptbestandteil der Wärmepumpe ist ein Verdichter bzw. Kompressor, der auf der Wärmequellenseite ein Kältemittel im gasförmigen Zustand (Dampf) bei niedriger Temperatur und niedrigem Druck ansaugt und nahezu adiabat verdichtet. Im Kondensator sinkt infolge des Heizwärmebedarfes die Temperatur auf die Kondensationstemperatur ab. Der Dampf beginnt zu kondensieren und gibt dabei die Kondensationswärme wieder ab. Der Wirkungsgrad wird mit der Leistungszahl beschrieben (*Coefficient of Performance*, COP), die das Verhältnis von Nutzwärme und elektrisch benötigter Energie angibt ($\text{kWh}_{\text{th}}/\text{kWh}_{\text{el}}$). Die übers Jahr gemittelte Leistungszahl wird als Jahresarbeitszahl bezeichnet (Häfner et al. 2015). Wärmepumpen können anhand verschiedener Kriterien charakterisiert werden. Verbreitet ist die Einteilung nach Art der Wärmequelle und -senke, vorwiegend mit Wasser als Wärmesenke: Luft-Wasser-Wärmepumpen, Sole-Wasser-Wärmepumpen (auch als Erdwärmepumpen bezeichnet) und Wasser-Wasser-Wärmepumpen (Häfner et al. 2015).

Luft-Wasser-Wärmepumpen nutzen als Wärmequelle die Umgebungsluft und sind in der Anschaffung und Inbetriebnahme mit dem niedrigsten Investitionsbedarf verbunden. Allerdings arbeiten sie bei niedrigen Lufttemperaturen im Winter nur wenig effizient (Jahresarbeitszahl üblicherweise < 3). Aufgrund der geringeren Wärmekapazität der Luft im Vergleich zu Wasser oder zum Erdreich, müssen große Luftmengen bewegt werden, was zu einer als störend empfundenen Geräuschentwicklung führen kann.

Sole-Wasser-Wärmepumpen beziehen die Wärme mithilfe der Sole, einem Frostschutzmittel-Wasser-Gemisch, aus dem Erdreich. Dabei stammt die Erdwärme entweder aus horizontal im Erdreich verlaufenden Kollektoren, die unterhalb der Frostschutzgrenze ($> 0,5$ m) verlegt werden, oder aus einer senkrechten, im Untergrund verlegten Sonde

¹⁶ Der (aus wirtschaftswissenschaftlicher Sicht ungenaue) Begriff „Anschaffungskosten“ wird aufgrund seiner weiten Verbreitung in der vorliegenden Arbeit verwendet. Damit sind Kapitalkosten gemeint, die durch Investitionsauszahlungen verursacht werden, um einen Vermögensgegenstand zu erwerben und ihn in einen betriebsbereiten Zustand zu versetzen.

mit einer Bohrungstiefe von üblicherweise 50 bis 100 m. Die Sonde benötigt zwar eine geringere Grundstücksfläche. Oftmals sind aber behördliche Genehmigungen erforderlich. Zusätzlich fallen, anders als bei Erdkollektoren, höhere Erschließungskosten für die Sondenbohrungen an. Die Wärmequellentemperatur schwankt in Abhängigkeit von der Dimensionierung, meistens zwischen -5 bis $+12$ °C. Dadurch werden übers ganze Jahr hinweg gute Leistungszahlen erreicht (Jahresarbeitszahl ≈ 4). Sole-Wasser- und auch Wasser-Wasser-Wärmepumpen, die ihre Wärme über Erdsonden oder Grundwasser beziehen, sind vor allem aufgrund der Erschließungskosten in der Anschaffung mit dem höchsten Investitionsbedarf verbunden: Die nötigen Aushub- und Bohrarbeiten müssen von Spezialunternehmen durchgeführt werden.

Wasser-Wasser-Wärmepumpen beziehen die Wärme des Grundwassers, zumeist über Saug- und Schluckbrunnen in unterschiedlichen Bohrtiefen. Aus Gründen des Gewässerschutzes werden auch hier behördliche Genehmigungen benötigt. Neben der Grundwasserwärme ist die Wärme von Abwässern technisch nutzbar. Diese Möglichkeit kommt bisher noch vergleichsweise selten zum Einsatz. Der Vorteil von Wasser-Wasser-Wärmepumpen besteht darin, dass die Wärmequelle eine nahezu konstante Temperatur von ca. 10 °C aufweist. Dadurch können Jahresarbeitszahlen von vier und größer erreicht werden.

Heizleistung und Leistungszahl hängen neben der Wärmequelleneintritts- auch von der Wasseraustrittstemperatur ab. Für Warmwasser (Trinkwasser) empfiehlt der Deutsche Verein des Gas- und Wasserfaches (DVGW) Warmwassertemperaturen von mindestens 50 °C (Arbeitsblatt W 551, DVGW 2004). Technisch erfolgt die Regelung der Temperatur anhand der Differenz zwischen Ein- und Ausschalttemperaturen (Hysterese) der Wärmepumpe. In Bezug auf den Heizkreis für Raumwärme kann die Leistungszahl mit niedrigeren Wasseraustrittstemperaturen durch geminderte Wärmeverluste deutlich erhöht werden: In Kombination mit Fußbodenheizungen können Vorlauftemperaturen zwischen 25 und 35 °C angefahren werden.¹⁷ Gängige Werte für Vorlauf-/Rücklauftemperaturen sind $45/35$ °C.

Die Heizleistung kann mit sogenannten On-Off-Wärmepumpen oder Wärmepumpen mit mehreren Leistungsstufen nur stufenweise abgerufen werden. Inverter-Wärmepumpen können die Heizleistung in beliebiger Höhe kleiner der maximalen Leistung bereitstellen.

¹⁷ Die Vorlauftemperatur wirkt sich auf Energieeffizienz und Behaglichkeit aus und richtet sich grundsätzlich nach der Heizleistung, die erforderlich ist, um einen Raum auch bei Außenlufttemperaturen von -15 oder -20 °C angenehm warm zu heizen (weitere Faktoren sind neben geplanter Raumtemperatur, Differenz zwischen Vor- und Rücklauftemperatur, Verlegeabstand der Rohrleitungen sowie Aufbau des Fußbodens).

Die Leistungszahl der Wärmepumpe wird durch Anfahrverluste gemindert, die durch Druck- und Temperatenausgleich mit der Umgebung nach Stillstand entstehen und beim Anfahren wieder aufgebaut werden müssen. Laut Hersteller betragen diese Verluste 5 % der angefahrenen Heizleistung. Die Anzahl der Anfahrzyklen kann sich ggf. auf die Lebensdauer auswirken, die größtenteils von der verwendeten Technologie des Verdichters abhängt: am gängigsten sind Scroll-, Kolben- und Schraubenkompressoren. Scrollkompressoren weisen die höchste Lebensdauer auf. Die Angabe der maximalen Zyklen schwankt von Hersteller zu Hersteller zwischen ca. 100 000 und 150 000. Manche Hersteller geben lediglich maximale Laufzeiten, z. B. 20 Jahre, ohne Bezug zum Takten an. Häufig wird auch eine minimale Lauf- oder Stillstandszeit von 10 bis 20 min vorgegeben.

3.2 Lokale Energienachfrage

Für die Investitions- und Einsatzplanung können historische Lastprofile oder Referenzlastprofile verwendet werden. Referenzlastprofile geben den durchschnittlichen zeitlichen Verlauf des Verbrauchs (Lastgang) des betrachteten Gebäudes oder Segments wieder und werden an den geschätzten Tages- oder Jahresbedarf angepasst. Hierzu gehören die H0-Referenzlastprofile des Verbands der Elektrizitätswirtschaft e. V. (VDEW, Meier et al. 1999) für die Stromnachfrage vieler Haushalte und die VDI-Richtlinie 4655 (VDI 2008), die neben elektrischen auch thermische Lastprofile für Ein- und Mehrfamilienhäuser anbietet.

Während die H0-Referenzlastprofile des VDEW auf 332 gemessenen elektrischen Haushaltlastgängen (von 1981 bis 1998) basieren, werden für die VDI-Richtlinie Wärme-, Strom- und Warmwasserverbräuche von fünf Ein- und drei Mehrfamilienhäusern verwendet. Um die Verbrauchsscharakteristika grundsätzlich zu erhalten, wird in beiden Fällen ein gemessenes Profil aus einer Menge von Profilen eines definierten Typ-tags ausgewählt, welches dem typischen Verlauf aller gemessenen Tage am nächsten kommt. Die genaue Vorgehensweise ist in Meier et al. (1999) bzw. Dubielzig (2007) beschrieben.

3.2.1 Nachfrage nach elektrischer Energie

Die H0-Referenzlastprofile des VDEW basieren auf neun verschiedenen Typtagen, die sich in Werktag, Samstag und Sonntag sowie in Winter (01.11. bis 20.03.), Sommer (15.05. bis 14.09.) und Übergang (21.03. bis 14.05. und 15.09. bis 31.10.) unterscheiden. Für die Berechnung werden die Referenzprofile auf einen geschätzten Jahresbedarf skaliert. Zur Vermeidung von Sprüngen an den Grenzen der Jahreszeiten werden die Profile zusätzlich mit einer empirisch ermittelten, polynomischen Gleichung dynamisiert.

Die Referenzlastprofile der VDI-Richtlinie 4655 basieren, ähnlich wie die VDEW-Lastprofile, auf Typtagen, mit dem Unterschied, dass nur in Werk- und Sonntag differenziert wird. Außerdem wird die Saison von der durchschnittlichen Tagestemperatur abgeleitet ($< 5\text{ °C}$ Winter, $> 15\text{ °C}$ Sommer, andernfalls Übergang). Hinzu kommt, dass in bewölkte und sonnige Typtage unterschieden wird, wobei im Sommer die bewölkten zu den sonnigen Typtagen zusammengefasst werden. Demnach finden sich in der VDI-Richtlinie zehn verschiedene Typtage. Bei der VDI-Richtlinie hängen die Jahresenergieverbräuche vom Gebäudetyp (Ein-/Mehrfamilienhäuser), der Anzahl der Personen (im Einfamilienhaus) bzw. Wohneinheiten (im Mehrfamilienhaus) und vom Standort des Gebäudes (anhand von Testreferenzjahren des Deutschen Wetterdienstes, DWD) ab.

Abb. 3.3 zeigt exemplarisch die unterschiedlichen VDEW- und VDI-Referenzlastprofile mit 15-min-Auflösung für die Werktage der verschiedenen Jahreszeiten.

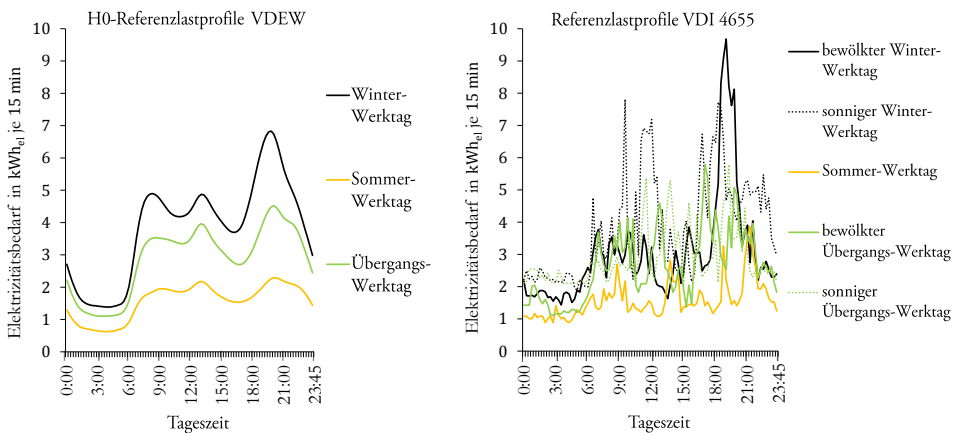


Abb. 3.3: Referenzlastprofile des VDEW und der VDI-Richtlinie 4655 für Werktage. Daten aus Meier et al. (1999) sowie VDI (2008) entnommen und entsprechend der VDI-Richtlinie für Karlsruhe auf die elektrischen Tagesverbräuche eines Mehrfamilienhauses mit 28 Wohneinheiten und 2 000 m² Wohnfläche skaliert (Tagesverbräuche zwischen 146 und 370 kWh_d).

In der vorliegenden Arbeit wird der tägliche Elektrizitätsbedarf mit monatlichen Skalierungsfaktoren auf bewohnerspezifische, gemessene Verbräuche von Wohneinheiten der Fallstudie skaliert. Zusätzlich werden die Verbräuche, statt an Testreferenzjahre des DWD, an das lokale Wetter genauer angepasst. Der Einfluss des Strompreises auf den Elektrizitätsbedarf wird in der Arbeit nicht berücksichtigt.

Die Verwendung der VDEW- oder der VDI-Referenzlastprofile hängt wesentlich von der Anzahl der Haushalte ab. VDI-Referenzlastprofile werden eher zur Abbildung des volatilen Lastverlaufs weniger Haushalte genutzt. Die VDEW-Referenzlastprofile eignen sich zur Wiedergabe von Lastverläufen größerer Haushaltsgruppierungen, die aufgrund des Gleichzeitigkeitseffekts einen „ruhigeren“ Verlauf mit geringeren Gradienten aufweisen.¹⁸ Bei der Optimierung dezentraler Energiesysteme führen volatilere Verbrauchsprofile in der Regel zu erhöhten Kosten. Einerseits kann die Bedarfsdeckung häufiger und hoher Gradienten den effizienten Betrieb bestimmter Energiesystemkomponenten verschlechtern. Andererseits kann, etwa durch (größere) Speicher zur Deckung des volatilen Verlaufs, höherer Investitionsbedarf entstehen.

3.2.2 Nachfrage nach thermischer Energie

Die Nachfrage nach thermischer Energie besteht prinzipiell aus dem Heizwärmebedarf für Raumwärme und der Erwärmung für Warmwasser (Trinkwasser). Der Jahresheizwärmebedarf für Raumwärme berechnet sich gemäß VDI-Richtlinie 4655 nach dem Energiebilanzverfahren der DIN EN 832 aus Wärmeverlusten und -gewinnen für eine Heizperiode. Zur Ermittlung des Energiebedarfs für die Warmwassererwärmung setzt die Richtlinie im Einfamilienhaus $500 \text{ kWh}_{\text{th}}$ je Person und im Mehrfamilienhaus $1\,000 \text{ kWh}_{\text{th}}$ je Wohneinheit an (alternativ verweist die Richtlinie auf die EnEV). Abb. 3.3 zeigt exemplarisch die unterschiedlichen Referenzlastprofile mit 15-min-Auflösung für die Werktage der verschiedenen Jahreszeiten, die entsprechend der VDI-Richtlinie auf den Raum- und Warmwasserbedarf eines Mehrfamilienhauses skaliert sind.

Ähnlich wie der Elektrizitätsbedarf wird der Wärmebedarf für Raumwärme und Warmwasser mittels monatlicher Skalierungsfaktoren auf typische, gemessene Verbräuche von Wohneinheiten der Fallstudie skaliert. Auch die genaue Anpassung an das lokale Wetter wird in vorliegender Arbeit vorgenommen. Der Einfluss des Strompreises auf den Wärmebedarf wird nicht berücksichtigt.

¹⁸ Ein Vergleich der VDEW-Referenzlastprofile mit der gemessenen Elektrizitätsnachfrage von 28 Haushalten eines Wohnquartiers befindet sich in Anhang A.

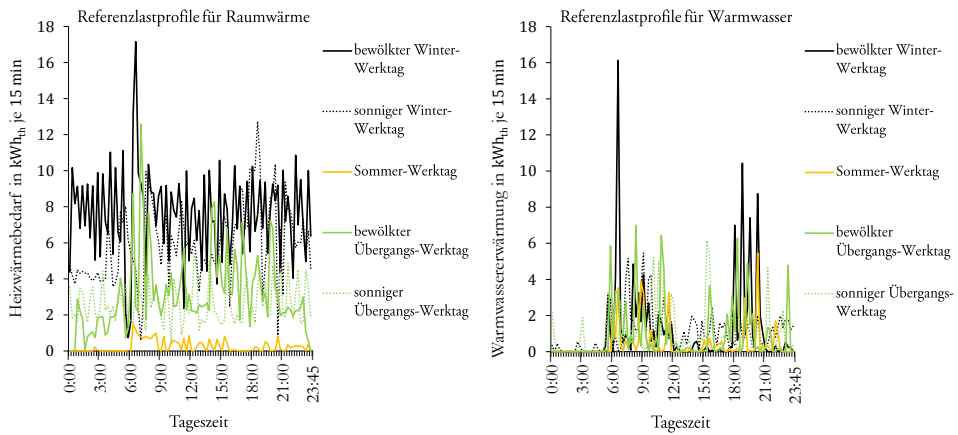


Abb. 3.4: Referenzlastprofile der VDI-Richtlinie 4655 für Werktage: Bedarf für Raumwärme (links) und für Warmwasser (rechts). Daten aus Meier et al. (1999) sowie VDI (2008) entnommen und entsprechend der Richtlinie für Karlsruhe auf den thermischen Tagesbedarf eines Mehrfamilienhauses mit 28 Wohneinheiten, 2 000 m² Wohnfläche und einem Jahresheizwärmebedarf von 50 kWh_{th}/m² skaliert (zwischen 23 und 723 kWh_{th} für Raumwärme und 40 und 106 kWh_{th} für Warmwasser).

3.3 Lokale Energiespeicherung

Energetische Speicher sind Energiesystemkomponenten zur temporären Speicherung von Energie. Dafür sind die Prozessschritte Laden, Speichern und Entladen nötig, die mit Verlusten behaftet sein können (Sterner und Stadler 2014). Die Speicherung kann entweder ohne oder mit Zwischenumwandlung in andere Energieformen erfolgen. Demnach lassen sich Speichertechnologien nach den zugrundeliegenden physikalischen Prinzipien der Energiespeicherung strukturieren (siehe Abb. 3.5). Außerdem kann nach Anwendungsgebiet in Energie- oder Leistungsspeicher unterschieden werden. Leistungsspeicher haben eine geringere speicherbare Energiemenge im Verhältnis zur Lade- und Entladeleistung. In den folgenden Abschnitten 3.3.1 und 3.3.2 werden die lokalen Energiespeicher der Fallstudie der vorliegenden Arbeit vorgestellt: eine Lithium-Ionen-Batterie und ein Warmwasserspeicher.

thermisch / thermochemisch	mechanisch	chemisch / elektrochemisch	elektrisch
sensible Wärmespeicher (Feststoff, Fluid, Erdsonde, Aquifer)	Pumpspeicher	Redox-Flussbatterie	Kondensator
Latentwärmespeicher (Dampf, Eis, Salzhydrat, Paraffin)	Druckluftspeicher	Hochtemp. Akkumulator (NaS, Na ₂ NiCl)	Supraleitende Spule
Sorptionspeicher (Metallhydrid, Silikagel, Zeolith)	Schwungradspeicher	Akkumulator (Blei, NiCd, NiMH, Li-Ion)	<div style="display: flex; justify-content: space-between;"> ■ Energieanwendung ■ Leistungsanwendung </div>

Abb. 3.5: Physikalische Einteilung von Speichertechnologien nach Anwendungsgebiet, nach Schossig et al. (2005), Oertel (2008), Hannig et al. (2009), Schabbach et al. (2010), Hauer et al. (2013) und Leonhard (2016) in Anlehnung an Kaschub (2017).

3.3.1 Lithium-Ionen-Batterie für die Speicherung elektrischer Energie

Die Lithium-Ionen-Batterie zählt generell zu den Akkumulatoren und kann als elektrischer Energie- und Leistungsspeicher eingesetzt werden. Die enthaltenen Zellen, in der Regel ein galvanisches Element, wandeln chemische in elektrische Energie um und umgekehrt. Die Zellen werden für die gewünschte Energiedichte und Ladeleistung zu einem Batteriepack zusammengeschaltet. Dieses erfordert ein zusätzliches Batteriemanagement-System (Kaschub 2017).

Für die Lithium-Ionen-Batterie einschließlich aller weiteren Systemkomponenten (Batteriezellenpackung mit Steuerungssystem und Inverter) wird gemäß Kaschub (2017) ein Preis von 600 €/kWh_{el} angenommen. Im Betrieb setzen Kaschub et al. (2016) jährliche Instandhaltungskosten von 1 % des Investitionsbetrags an. Es wird eine Ladeeffizienz von je 94 % für Be- und Entladung sowie eine Selbstentladung von 2 % pro Monat angenommen. Die Ladeleistung für die Beladung nimmt in Abhängigkeit des Speicherstands (*State of Charge*, SoC) bei einem Speicherstand zwischen 75 % und 100 % linear ab. Schnelles Entladen stellt bei hohen SoC > 75 % kein Problem dar.

Allgemein unterliegen Lithium-Ionen-Batterien nutzungsabhängigen und kalendarischen Alterungsprozessen. Kaschub et al. (2016) vertreten eine additive Verknüpfung dieser Prozesse, die auch in dieser Arbeit bei der Modellierung aufgegriffen wird. Gemäß Schmiegel und Kleine (2014) sowie Weniger et al. (2014) wird von einer kalendarischen Lebensdauer von 20 Jahren und einer nutzbaren Kapazität am Ende der Lebensdauer von 80 % ausgegangen. Darüber hinaus verringert sich die Kapazität gemäß Kaschub et al. (2016) sowie Lutz et al. (2012) um eine reduzierte kalendarische Lebensdauer für hohe Ladungszustände. Ferner wird zur Sicherstellung des funktionierenden Betriebs

vom Hersteller in der Regel eine maximale Zyklenzahl vorgegeben. Ein Zyklus entspricht einer kompletten Ladung und Entladung. Wird der Speicher nicht komplett entladen, kann eine höhere Anzahl äquivalenter Vollzyklen erreicht werden. Je geringer der Lade- und Entladehub, desto höher die Anzahl dieser Zyklen. Im Extremfall können über 100 000 äquivalente Vollzyklen gefahren werden (Kaschub 2017).

3.3.2 Wasserspeicher für die Speicherung thermischer Energie

Im Niedertemperaturbereich der Trinkwassererwärmung und Raumheizung wird der größte Teil des Markts für Wärmespeicher durch klassische sensible Wasserspeicher abgedeckt (Schossig et al. 2005). Diese können als Einzel- oder Kombispeicher (auch als Kaskade) entweder direkt oder indirekt über innere Wärmeüberträger be- und entladen werden (Leonhard 2016). Wasserspeicher sind in der Regel aufgrund der höheren Anforderungen an Material, z. B. Edelstahl für Trinkwasser, und Dämmung mit einem höheren Investitionsbedarf verbunden. Für thermische Nachfragespitzen können zusätzlich Heizelemente eingebaut werden. Beim Trinkwasser dienen die Heizelemente auch der thermischen, periodischen Desinfektion (sogenannte Legionellen-Schaltung).

In der Fallstudie vorliegender Arbeit werden ausschließlich einzelne Wasserspeicher von Hoval (2013) mit elektrischen Heizelementen für die Raum- und Warmwassererwärmung eingesetzt. Für die Raumwärme wird der Wasserspeicher (auch Pufferspeicher genannt) in einem geschlossenen Heizkreislauf unter Annahme perfekter Durchmischung durch die Wärmepumpe beladen. Technisch erfolgt die Hysterese der Wärmepumpe (An- und Abschaltungstemperaturen) mit ± 5 K bei 40 °C. Demnach ist der Speicher energetisch bei maximalem Temperaturniveau (45 °C) voll und bei niedrigstem Temperaturniveau (35 °C) leer. Der Temperaturunterschied von 10 K und die spezifische Wärmekapazität für Wasser ergibt eine Speicherkapazität des Heizspeichers von 1,16 kWh_{th} je 100 l Volumen.

Für Warmwasser (Trinkwasser) kommt ein sogenannter Wasserschichtspeicher in einem offenen Kreislauf zum Einsatz. In diesem Speicher wird Frischwasser von ca. 15 auf 55 °C erwärmt (Speicherkapazität beträgt 4,65 kWh_{th} je 100 l). Eine gute Temperaturschichtung erlaubt die Entnahme von möglichst viel Wasser mit einer konstant hohen Temperatur. Temperaturschichtungen stellen sich grundsätzlich aufgrund der temperaturabhängigen Dichte von Wasser in gut gedämmten Speichern ein. Durch bauliche Maßnahmen kann die Vermischung reduziert werden, z. B. durch ein Prallblech zur Beruhigung des eintretenden kalten Wasserstrahls. Außerdem kann die Vermischung (als Schichtladespeicher) durch einen vorgelagerten Plattenwärmeüberträger weiter ge-

senkt werden. Nach längeren Verweilzeiten baut sich die Temperaturschichtung durch Wärmeleitungseffekte in Wasser und Behälterwand sowie auftretende Konvektionsströmungen ab. Die Bereitschaftswärmeverluste über die Manteloberflächen beider Speicher werden mithilfe einer vereinfachten zeitlichen linearen Funktion in Abhängigkeit vom Speicherfüllstand abgebildet (Modellierungsdetails siehe Abschnitt 6.3.2).

3.4 Investitionsrechnung für dezentrale Energiesysteme

Investitionsrechnungen dienen dazu, die Vorteilhaftigkeit von Investitionsentscheidungen unter Berücksichtigung (zukünftiger) Zahlungen bzw. Ereignisse zu bewerten (Olfert und Reichel 2009). Es wird grundsätzlich in statische und dynamische Rechnungen unterschieden. Statische Investitionsrechnungen sollten nur für kurzfristige oder überschlägige Betrachtungen herangezogen werden, da keine Zinseszinsseffekte berücksichtigt werden (Zantow und Dinauer 2011). Dynamische Investitionsrechnungen sind Mehrperiodenmodelle, die die Zeitpunkte der Ein- und Auszahlungen mit einbeziehen und sich somit für langfristige Betrachtungen besser eignen. Der Betrachtungshorizont wird in der Regel so gewählt, dass er der Nutzungsdauer der Investition entspricht (Konstantin 2009). Zu den dynamischen Verfahren gehören die Kapitalwert-, Annuitäten- und Interne-Zinsfuß-Methode. Grundsätzlich gehen alle drei Methoden von der Annahme eines vollkommenen Kapitalmarkts aus. Hierunter fällt auch die Prämisse, dass für Finanzanlagen und Kredite ein einheitlicher Kapitalmarktzinssatz besteht, zu dem jederzeit und in beliebiger Höhe Finanzinvestitionen angelegt und Kredite aufgenommen werden können. Die individuelle Berücksichtigung unterschiedlicher Soll- und Habenzinssätze je Periode ist mit der Endwertmethode möglich.

Entscheidend für jede Investition ist der Kalkulationszins, der die Verzinsung des Kapitals einer alternativen Investition darstellt. Jedoch muss der Kalkulationszins nicht zwangsläufig vom Markt abgeleitet werden, sondern obliegt vielmehr einer gewünschten Mindestverzinsung des Investors; sie entspricht den Kapitalkosten (Wöhe et al. 2016). Eine Möglichkeit des Entscheiders, seine Investition zu benchmarken, stellt der Aktienmarkt dar. Der bedeutendste deutsche Aktienindex ist der Deutsche Aktienindex (DAX), der die Wertentwicklung der 30 größten und liquidesten Unternehmen des deutschen Aktienmarkts repräsentiert und einen Marktkapitalisierungsanteil von ca. 80 % aller börsennotierten Aktiengesellschaften in Deutschland aufweist (Deutsche Börse 2016).

In den letzten 50 Jahren hat der DAX jährliche Renditen von bis zu 84,1 % (im Jahr 1995) erzielt, aber auch negative Renditen bis zu -43,9 % (im Jahr 2002). Die Anlage in den DAX für nur ein Jahr erscheint aufgrund der erheblichen Schwankungen und Unsicherheiten weniger geeignet als Benchmark für die Investition des privaten Entscheiders. Dies gestaltet sich anders, wenn die Lebensdauer der geplanten Investition mit dem Anlagehorizont der Investitionsalternative übereinstimmt. Abb. 3.6 zeigt die nominalen DAX-Renditen p. a. für verschiedene Haltedauern (basierend auf den letzten 50 Jahren).




Abb. 3.6: Durchschnittliche und max./min. nominale DAX-Rendite sowie max./min. Inflationsrate in Deutschland p. a. (im geom. Mittel) in Abhängigkeit des Betrachtungs- bzw. Anlagehorizonts von 1967 bis 2016 (DAI 2017; Destatis 2018, basierend auf Stehle et al. 1996).

Es ist ersichtlich, dass eine Anlage in den DAX mit einer Haltedauer von beispielsweise 20 Jahren eine Rendite von 9,2 % p. a. (im geom. Mittel) erzielte, im schlechtesten Fall eine Mindestrendite von 6 % p. a. (im geom. Mittel). Der private Entscheider könnte die Mindestverzinsung von 6 % als Investitionsalternative ansetzen. Ausgehend von den letzten 50 Jahren und mit der Prämisse, dass sich der DAX im zukünftigen Betrachtungshorizont gleichartig verhält, erscheint der DAX als risikoäquivalente Anlagealternative zur Investition in dezentrale Energiesysteme.

Neben der Rendite als Nominalzins sollte auch die Inflationsrate, die einen merklichen Einfluss auf die Gesamrendite hat, in die Optimierung mit gleichem Betrachtungshorizont einfließen. Für den Betrachtungshorizont von 20 Jahren zeigt Abb. 3.6 eine Inflationsrate von 1,4 bis 3,9 % p. a. (im geom. Mittel). Mathematisch lässt sich die Inflationsrate i im Kalkulationszins k vereinfacht durch die Subtraktion vom Nominalzins k_{nominal} berücksichtigen. Für eine exakte Berechnung gilt:

$$k = \frac{(1 + k_{\text{nominal}})}{(1 + i)} - 1. \quad (3.1)$$

4 Einordnung in die Optimierung

Grundsätzlich liegt immer dann ein Entscheidungsproblem vor, wenn mindestens eine Entscheidungsalternative, demnach mindestens zwei Entscheidungsvarianten, zur Erreichung eines bestimmten Ziels vorhanden ist. Mithilfe von Optimierungsverfahren wird die optimale Auswahl aus den Entscheidungsvarianten unter Berücksichtigung der gegebenen Beschränkungen gesucht. Es können hierbei exakte Verfahren zum Einsatz kommen, die ein globales Optimum bei der Lösungsfindung garantieren, oder heuristische Verfahren, die mit auf Erfahrung beruhenden Algorithmen nach guten, aber nicht notwendigerweise optimalen Lösungen suchen (Pearl 1984).¹⁹

Entscheidungsprobleme können durch mathematische Optimierungsmodelle bzw. -programme abgebildet werden, die prinzipiell aus einer Zielfunktion f (Optimierungsziel) sowie einschränkenden Gleichungen oder Ungleichungen (Restriktionen) bestehen. Zielfunktion und Restriktionen sind mit gegebenen Parametern und den zu optimierenden Entscheidungsvariablen x (im Folgenden **fett** hervorgehoben) formuliert. Anhand der Verknüpfungen der enthaltenen Entscheidungsvariablen lassen sich die Optimierungsprogramme in bestimmte Klassen unterteilen, einhergehend mit besonderen Merkmalen und dementsprechend speziellen Lösungstechniken. Darüber hinaus wird generell in deterministische Optimierungsprogramme oder in Programme unterschieden, bei denen gewisse Modellparameter als unbestimmt bzw. unsicher gelten.

4.1 Optimierungsziel der Investitions- und Einsatzplanung

Allgemein wird mit der Optimierung dezentraler Energiesysteme vorwiegend eine Gewinnmaximierung oder Kostenminimierung angestrebt. Die durch Investition bedingten Kapitalkosten werden prinzipiell durch das gebundene Kapital für Anschaffung von Energiesystemkomponenten (ggf. Ersatz oder abzgl. Restwert) und einem zugrundeliegenden Kapitalzins bzw. Kalkulationszins verursacht. Die Betriebsführung dezentraler Energiesysteme führt gewöhnlich zu Energiebezugskosten (ggf. auch zu Einspeisungsgewinnen) sowie weiteren Betriebskosten, wie Wartungs- oder Instandhaltungskosten.

¹⁹ Das globale Optimum ist der bestmögliche, mit den Entscheidungsvariablen x erreichbare Wert einer Zielfunktion, unter Einhaltung aller Restriktionen. Hingegen sind lokale Optima nur bestmögliche, mit den Entscheidungsvariablen x erreichbare Werte, in einer gewissen Umgebung von x (Ellinger et al. 2001).

Größere Investitionen mindern in der Regel die Betriebskosten bei der Bereitstellung, Speicherung oder beim Bedarf von Energie. Gleichzeitig erhöht sich das gebundene Kapital, das auch am Markt eine gewisse Rendite erzielt hätte. Der private Entscheider sucht nun die Investition, die den Trade-Off zwischen gebundenen Kapitalkosten der Energiesystemkomponenten und Betriebskosten unter Erfüllung der Nachfrage-Restriktionen ergeben und zu den minimalen Gesamtenergiekosten führen. Für langfristige Investitionsrechnungen für dezentrale Energiesysteme haben sich die Kapitalwertmethode (siehe z. B. Kunze 2016; Eggers 2018; McKenna et al. 2018) und die Annuitätenmethode (siehe z. B. Hawkes et al. 2006; Beck et al. 2017; Mavromatidis et al. 2017) bewährt.

Bei der Kapitalwertmethode (auch Nettobarwert- bzw. Diskontierungsmethode genannt) werden alle Ein- und Auszahlungen einer Investition über den gesamten Betrachtungshorizont L auf den Barwert diskontiert und aufsummiert. Die zu minimierenden Gesamtenergiekosten $cost^{NPV}$ ergeben sich im einfachsten Fall aus der Auszahlung Inv für die Investition und den über alle Perioden $l = \{1, \dots, L\}$ abgezinsten Nettozahlungen:

$$cost^{NPV} = Inv + \sum_{l=1}^L e_l^{\text{grid}} \cdot \frac{p_l^{\text{grid}}}{(1+k)^l}, \quad (4.1)$$

mit dem Energiebezug e_l^{grid} vom externen Energieversorger einer Periode zum festen Arbeitspreis p_l^{grid} für elektrische Energie. Dabei wird mit dem Kalkulationszins (auch Kalkulationszinsfuß) k abgezinst.

Bei der Annuitätenmethode werden Investitionen anhand von periodisch gleichbleibenden Zahlungen (Annuitäten) bewertet, so dass der Kapitalwert einer Investition auf den gesamten Betrachtungshorizont gleich verteilt wird. Die Gesamtenergiekosten werden über den Annuitätenfaktor ANF , mit dem Kalkulationszins k und dem Betrachtungshorizont L , auf eine Periode, z. B. ein Jahr, aufgeschlüsselt:

$$ANF = \frac{(1+k)^L \cdot k}{(1+k)^L - 1}. \quad (4.2)$$

Bei gleichem Energiebezug für alle Perioden gilt für den annualisierte Kapitalwert der Gesamtenergiekosten in Gleichung (4.1):

$$\begin{aligned} cost^{\text{EAC}} &= ANF \cdot \left(Inv + \sum_{l=1}^L e_l^{\text{grid}} \cdot \frac{p_l^{\text{grid}}}{(1+k)^l} \right) \\ &= ANF \cdot Inv + e^{\text{grid}} \cdot ANF \sum_{l=1}^L \frac{p_l^{\text{grid}}}{(1+k)^l}. \end{aligned} \quad (4.3)$$

Mit der zusätzlichen Annahme, dass sich der Arbeitspreis $p_t^{\text{grid}} = p_0^{\text{grid}}$ über den Betrachtungshorizont nicht ändert, ergibt sich mittels geometrischer Reihe:

$$\sum_{l=1}^L p_0^{\text{grid}} \cdot q^l = p_0^{\text{grid}} \cdot q \frac{q^L - 1}{q - 1} \quad \text{mit } q = \frac{1}{(1+k)}, \quad (4.4)$$

eine vereinfachte Annuität der Gesamtenergiekosten:

$$\begin{aligned} \text{cost}^{\text{EAC}} &= ANF \cdot Inv + e^{\text{grid}} \cdot \frac{(1+k)^L \cdot k}{(1+k)^L - 1} p_0^{\text{grid}} \frac{1}{(1+k)} \frac{\frac{1}{(1+k)^L} - 1}{\frac{1}{(1+k)} - 1} \\ &= ANF \cdot Inv + e^{\text{grid}} \cdot p_0^{\text{grid}}. \end{aligned} \quad (4.5)$$

Analog dazu führt auch die Implementierung von Stromeinspeisung ins externe Netz, z. B. einer PV-Anlage oder eines elektrischen Speichers, mit einer Einspeisevergütung bzw. einem Einspeise-Arbeitspreis, zum gleichen Resultat. Demzufolge entspricht die in vorliegender Arbeit verwendete Annuitätenmethode, bei der vereinfachten Annahme eines gleichen Energiebezugs in allen Perioden des Betrachtungshorizonts L , der in Kaschub (2017) verwendeten Kapitalwertmethode. Diese Aussage ist auch bei unterschiedlichen, sich über die Periode verändernden Arbeitspreisen gültig (siehe auch Gleichung 4.3).

In der vorliegenden Arbeit wird für die Optimierung dezentraler Energiesysteme die Annuitätenmethode verwendet: eine Minimierung der annualisierten Gesamtenergiekosten anhand der Investitions- und Einsatzplanung, unter Einhaltung vorgegebener Restriktionen. Zu den Restriktionen gehört, dass die elektrische und thermische Nachfrage des dezentralen Energiesystems zzgl. der Systemverluste durch das elektrische und thermische Angebot zu jedem Zeitpunkt gedeckt ist. Außerdem unterliegt das von Investition und Einsatz abhängige Energieangebot weiteren Restriktionen. Häufig ist dieses auf ein maximales Limit begrenzt, z. B. auf die Heizleistung der Wärmepumpe oder auf maximale Speicherstände. Ebenso kann auch die Änderung des energetischen Angebots limitiert sein.

Kritisch bei der Optimierung dezentraler Energiesysteme sind die für die Entscheidung verwendeten zukünftigen Parameter, wie elektrischer und thermischer Energiebedarf, Stromtarife und -preise und das Dargebot erneuerbarer Energien, die nicht mit Sicherheit vorausgesagt werden können. In dezentralen Energiesystemen sind viele dieser Parameter mit wetterbedingten Unsicherheiten verknüpft und korrelieren stark mit der vorliegenden Wetterlage. Unter der Prämisse, dass sich die Stochastik des Wetters im Betrachtungshorizont von 20 bis 30 Jahren im Vergleich zu den zurückliegenden Dekaden nicht ändern wird, können vor allem wetterbedingte Unsicherheiten über histori-

sche Wahrscheinlichkeitsverteilungen adäquat erfasst werden. Für jene wahrscheinlichkeitsbedingten Unsicherheiten (Risiken) wird die Stochastische Programmierung als Optimierung verwendet (siehe Abschnitt 4.4.2). Ungewisse Unsicherheiten, die sich nicht mit Wahrscheinlichkeiten abbilden lassen, werden durch die Regret-Minimierung in der Optimierung berücksichtigt (siehe Abschnitt 4.4.4). Das gesamte Optimierungsprogramm mit der Kombination aus Stochastischer Programmierung und Regret-Minimierung wird in Abschnitt 6.3.1 allgemeingültig für dezentrale Energiesysteme beschrieben und in Abschnitt 6.3.2 spezifisch für ein Wohnquartier ausformuliert. Einzelne Zwischenergebnisse der Stochastischen Programmierung und Regret-Minimierung lassen sich als Form der Szenarioanalyse verstehen und werden im Ergebnisteil der Fallstudie des Wohnquartiers in Kapitel 8 dargelegt.

4.2 Programmklassen der Optimierung

Generell werden mathematische Optimierungsprogramme in lineare Programme (*Linear Program*, LP), ganzzahlige lineare Programme (*Integer Linear Program*, ILP), gemischt-ganzzahlige lineare Programme (*Mixed-Integer Linear Program*, MILP) und nicht lineare Programme (*Non-Linear Program*, NLP) klassiert.²⁰ Das LP als einfachste Programmklasse entspricht der Form:

$$\begin{aligned} f(\mathbf{x}) &= \min_{\mathbf{x}} c^T \mathbf{x} \\ \text{s. t. } \underline{A}\mathbf{x} &= \mathbf{b}, \\ \mathbf{x} &\geq 0, \end{aligned} \tag{4.6}$$

mit der linearen Zielfunktion $f(\mathbf{x})$, dem Entscheidungsvariablen-Vektor $\mathbf{x} \in \mathbb{R}^I$ und dem Kosten-Vektor $c \in \mathbb{R}^I$ mit jeweils I Elementen. Die Entscheidungsvariablen in Verbindung mit der Restriktionskoeffizienten-Matrix $\underline{A} \in \mathbb{R}^{I \times J}$ werden durch J lineare Restriktionen gemäß dem Rechte-Hand-Seiten-Vektor $\mathbf{b} \in \mathbb{R}^I$ beschränkt.

Grundsätzlich sind LP konvexe Optimierungsprogramme, bei denen sowohl die Zielfunktionen als auch der durch die Restriktionen gebildete Lösungsraum konvex sind. Aufgrund der Konvexitätsbedingungen handelt es sich bei einem gefundenen, lokalen Optimum auch um das globale Optimum. Diese Programmklasse, für die eine

²⁰ Gemischt-ganzzahlige Programme werden allgemein als MIP bezeichnet. Dabei kann das Programm sowohl linear (MILP) als auch nicht linear (MINLP) sein.

ganze Reihe von Optimierungsverfahren zur (exakten) Lösungsfindung existiert, gilt als am besten untersucht und verstanden. Grundsätzlich sind alle LP in polynomieller Zeit durchführbar.²¹

In vielen Fällen können Entscheidungen nur auf der Grundlage einer diskreten Auswahl getroffen werden. Ist der Wertebereich der Entscheidungsvariablen des LP vollständig auf ganze Zahlen beschränkt ($x \in \mathbb{Z}$), handelt es sich um ein ILP. Im Fall des MILP können sowohl kontinuierliche als auch ganzzahlige Entscheidungsvariablen vorkommen ($x \in \mathbb{R}^{I-Z_1} \times \mathbb{Z}^{Z_1}$). Aus komplexitätstheoretischer Sicht sind Optimierungsprobleme, die ganzzahlige Entscheidungsvariablen enthalten, im Allgemeinen nicht polynomiell(NP)-schwer lösbar.²² Durch Relaxierung der Ganzzahligkeitsbedingung und Optimierung des resultierenden LP kann (bei Minimierungsproblemen) eine untere (duale) Schranke des ILP und MILP bestimmt werden. Somit kann mit jeder zulässigen ganzzahligen Lösung des Programms als obere Schranke ein maximaler relativer Abstand zum optimalen Zielfunktionswert, der sogenannte (Optimalitäts-)Gap, angegeben werden, ohne das Optimum genau zu kennen. Durch schrittweise Verschärfung des relaxierten LP wird die duale Schranke angehoben. Gleichzeitig wird nach einer besseren zulässigen Lösung gesucht, um die obere Schranke zu verringern. Ein 1%iger MIP-Gap bedeutet, dass eine gültige ganzzahlige Lösung mit einer maximalen Abweichung von 1 % von der dualen Schranke vorliegt. Die Lösung von MIP-Problemen stellt in der Praxis immer noch eine schwere Aufgabe dar: Mit der aktuell verfügbaren Rechentechnik können viele MIP-Probleme nicht oder nur ungenügend genau gelöst werden. Daher existieren neben (aufwendigen) exakten Lösungsverfahren, speziell entwickelte bzw. angepasste Algorithmen, eine Vielzahl von Heuristiken oder eine Kombination aus beidem (Bertsimas und Tsitsiklis 1997).

Sind Zielfunktion oder Restriktionen nicht linear, handelt es sich um ein NLP. Als weiterführende Literatur sei auf Stein (2018) und mit verstärkt praktischer Anwendung auf Reinhardt et al. (2013) verwiesen.

²¹ Ein Programm ist in polynomieller Zeit deterministisch durchführbar, wenn die Rechenzeit $\tau(n)$ (Anzahl der benötigten Elementaroperationen) höchstens polynomiell k -ten Grades mit der Größe der Eingabe n des Programms wächst: $\tau(n) \in O(n^k)$ für $k \in \mathbb{N}$. D.h., $\tau(n)$ steigt in einem Verhältnis zu n , das sich durch ein Polynom des Grades k ausdrücken lässt (τ steigt um das 2^k -Fache, wenn sich n verdoppelt). Ein Problem ist in exponentieller Zeit lösbar, wenn: $\tau(n) \in O(2^{n^k})$ für $k \in \mathbb{N}$ (τ steigt bei $k = 1$ ungefähr um das Doppelte, wenn n um eins zunimmt) (Sipser 2013).

²² Ein NP-Problem ist nicht deterministisch in Polynomialzeit lösbar. Für NP-schwere Probleme existiert kein Algorithmus, der eine Lösung in polynomieller Zeit garantiert.

4.3 Unsicherheiten in der Optimierung

Allgemein wird hinsichtlich der (Zukunfts-)Erwartungen eines Entscheiders in sichere und unsichere Zustände unterschieden. Bei Sicherheit können (zukünftige) Zustände der Umwelt eindeutig vom Entscheider bestimmt werden, bei Unsicherheit gibt es mehrere mögliche, nicht eindeutig zuvor bestimmbare Zustände. In der Realität sind die Ausprägungen der entscheidungsrelevanten, in der Zukunft liegenden Zustände grundsätzlich unsicher (Laux et al. 2014). Damit gilt für alle realen Entscheidungsprobleme, dass die mit den ausgewählten Handlungsalternativen realisierte Zielerreichung nicht mit Sicherheit bestimmt werden kann.

Es gibt unterschiedliche Ansätze, Unsicherheiten zu definieren und zu klassifizieren. Prinzipiell lassen sich Unsicherheiten in aleatorisch oder epistemisch unterteilen (Bedford und Cooke 2001; French 1995; Goldstein 2012; Morgan und Henrion 1992; Mustajoki et al. 2006).²³ Eine sehr gute Zusammenfassung geben Svetlova und van Elst (2013). In Bezug auf die Problemstellung der vorliegenden Arbeit unterliegen die Ergebnisse des Optimierungsprogramms drei verschiedenen Unsicherheitsquellen:

- (unverarbeitete) Inputdaten,
- für die Optimierung vorbereitende Transformation der Inputdaten sowie
- Modellierung bzw. Programmierung des dezentralen Energiesystems.

In vielen Fällen werden Optimierungsprogramme mit vollständiger Information unter Sicherheit ausgeführt. Diese deterministischen Optimierungsprogramme stehen stets unter dem Vorbehalt, ob die angenommenen Parameterausprägungen mit hinreichender Genauigkeit eintreten werden. Insbesondere bei weit in die Zukunft reichenden Entscheidungsproblemen sind nicht immer alle Zustände bekannt: Sie unterliegen gewissen Unsicherheiten. Bereits in den frühen 1920er Jahren haben Knight (1921) und Keynes (1921) zwischen messbarem Risiko und der Unsicherheit unterschieden, bei der sich das Ereignis nicht anhand einer Wahrscheinlichkeitsverteilung vorhersehen oder anderweitig kalkulieren lässt (Knight'sche Unsicherheit). Svetlova und van Elst (2013) bezeichnen diese Art der Unsicherheit als Ungewissheit und führen daneben noch das Unwissen als weitere Unsicherheitskategorie an. Demnach lässt sich Unsicherheit in die drei Bestandteile Risiko, Ungewissheit und Unwissen gliedern.

²³ Unsicherheiten werden als epistemisch bezeichnet, wenn sie sich reduzieren lassen, etwa durch Erfassung von mehr Daten oder durch Verbesserung des Modells. Sie sind aleatorisch, wenn dem Modellierer keine weitere Möglichkeit zu ihrer Reduzierung bekannt ist (Kiureghian und Ditlevsen 2009).

4.3.1 Risiko, Ungewissheit und Unwissen

Der Begriff "Risiko" umfasst eine Vielzahl von Bedeutungen (Stier 2017). Oft wird Risiko nur als Gefahr des Mislingens einer Handlung verstanden. Aus ökonomischer Sicht kann Risiko ein Ereignis sowohl mit möglicher negativer (Gefahr) als auch positiver (Chance) Auswirkung sein. Demgemäß definiert Gleißner (2017) Risiko wie folgt: „Risiko ist die aus einer nicht sicher vorhersehbaren Zukunft resultierende, durch ‚zufällige‘ Störungen verursachte Möglichkeit, von geplanten Zielen abzuweichen.“ Unter der Prämisse, dass jene „zufälligen“ Möglichkeiten bzw. Ereignisse mit einer bestimmten Wahrscheinlichkeit eintreten, soll diese Definition auch für die vorliegende Arbeit gelten.²⁴ Bezugnehmend auf mathematische Optimierungsprogramme, besteht also bei der Entscheidung das Risiko darin, dass der geplante Zielfunktionswert, z. B. die minimalen Kosten, aufgrund von risikobehafteten Unsicherheiten im positiven und negativen Sinne abweichen kann. Risikobehaftete Unsicherheiten sind bestimmte probabilistische Ereignisse mit bekannter oder adäquat abschätzbarer Eintrittswahrscheinlichkeit. Das Ausmaß dieser Unsicherheiten ist neben ihrer Streuung auch von der Abweichungswirkung auf die Zielfunktion abhängig, die sich nur selten trivial ableiten lässt.

Es gibt zahlreiche Ansätze, Risiko in weitere Subkategorien zu unterteilen. Neben der Differenzierung von leistungswirtschaftlichen und finanzwirtschaftlichen Risiken ist vor allem die Einteilung in systematisches und unsystematisches Risiko in der Kapitalmarkttheorie verbreitet. Leistungs- und Finanzrisiken sind mit der (leistungswirtschaftlichen) Güter- und Dienstleistungserstellung durch Unternehmen und deren Absatzmärkte verbunden sowie mit den (finanzwirtschaftlichen) Marktpreis-, Kredit- und Liquiditätsrisiken. Die Kapitalmarkttheorie befasst sich mit der Reduzierung von (unsystematischem) Risiko durch Diversifizierung von Wertpapierportfolios und (systematischem) Restrisiko, das nicht weiter reduziert werden kann (Stier 2017).

Darüber hinaus hängt das angestrebte Ziel des Entscheiders (die Zielfunktion) von dessen Risikopräferenzen ab. Der Entscheider kann risikoaffin (höherer Nutzen bei höherem Risiko zweier Handlungsalternativen mit gleichem Erwartungswert), risikoavers (höherer Nutzen bei geringerem Risiko zweier Handlungsalternativen mit gleichem Erwartungswert) und risikoneutral (ausschließliche Orientierung am Erwartungswert) sein. Zudem ist nicht zwingend vorausgesetzt, dass Risikoneigung oder -grad über alle Perioden hinweg beim Entscheider unverändert bleiben (Breuer et al. 2010).

²⁴ Risiko wird auch als zufälliges/stochastisches/probabilistisches Ereignis bezeichnet, das sich wiederholt, so dass sich Statistiken von Beobachtungen der Vergangenheit ableiten lassen (Buygi et al. 2006).

Eine Entscheidung unter Ungewissheit (*ambiguity*) liegt vor, wenn dem Entscheider die möglichen Zustände bekannt, nicht jedoch die entsprechenden Eintrittswahrscheinlichkeiten bekannt sind. Der Eintritt eines ungewissen Zustands ist exogen gegeben und kann vom Entscheider nicht aktiv beeinflusst werden. Für eine Optimierung auf Basis eines bestimmten Wahrscheinlichkeitsmaßes, wie dem Erwartungswert, könnten die Eintrittswahrscheinlichkeit a priori subjektiv vom Entscheider festgelegt werden (Svetlova und van Elst 2013). So führt beispielsweise die Anwendung des Indifferenzprinzips (auch als Laplace-Regel bezeichnet) dazu, dass allen möglichen Zustandereignissen die gleiche Eintrittswahrscheinlichkeit zugeordnet wird. Auf der Basis derartiger Wahrscheinlichkeitsbewertungen kann auch unter Ungewissheit eine Entscheidung hinsichtlich eines (subjektiven) Erwartungswertes vorgenommen werden. Der Nutzen der Umwandlung von Ungewissheit in (subjektives) Risiko ist fraglich und hängt stark von der Fähigkeit des Entscheiders ab, den Eintritt ungewisser Zustände a priori (vor der Entscheidung) bestimmen zu können.

Buygi et al. (2006) teilen Ungewissheit weiter in nicht zufällige und unscharfe (*vague*) Parameter ein. Nicht zufällige Parameter wiederholen sich nicht und lassen sich nicht von Beobachtungen der Vergangenheit ableiten, wie die Ausbauplanung der Energieerzeugung. Vage Daten sind unscharfe Parameter, die nicht eindeutig ausgedrückt werden können, wie der Stellenwert der Stakeholder bei der Entscheidungsfindung.

Unwissen (*unawareness* oder auch *ignorance*) liegt vor, wenn dem Entscheider weder die von seiner Entscheidung abhängigen Eintrittswahrscheinlichkeiten der Zustände noch die möglichen Zustände selbst bekannt sind (Svetlova und van Elst 2013). In dem entwickelten Optimierungsverfahren der vorliegenden Arbeit wird Unwissen nicht berücksichtigt.

4.3.2 Unsicherheiten in der Optimierung von Wohnquartieren

Bei der Investitions- und Einsatzplanungsoptimierung von Wohnquartieren als dezentrales Energiesystem können verschiedene Unsicherheiten Einfluss auf die optimale Lösung nehmen. Tab. 4.1 gibt eine Zusammenfassung möglicher Einflussgrößen einschließlich der jeweiligen von diesen Größen abhängenden Einflussfaktoren. Zusätzlich sind, mit Blick auf die vorangegangenen Abschnitte Risiko, Ungewissheit und Unwissen, entsprechende Unsicherheitskategorien zugeordnet. Falls mehrere Unsicherheitskategorien zutreffen, sind die treffendsten Kategorien fett hervorgehoben.

Tab. 4.1: Entscheidungsrelevante Einflussgrößen bei der Optimierung von Wohnquartieren aus Sicht des privaten Entscheiders und ihre Unsicherheitskategorien (in Anlehnung an Urschel 2010).

Einflussgröße	Einflussfaktoren	Unsicherheitskategorie
Energierrechtliche Anlagen- und Komponentenanforderungen	Politische/rechtliche Rahmenbedingungen	Ungewissheit/Unwissen
Komponentenwirkungsgrad und -leistung (Speicherverluste, Heizleistung, Ausfälle etc.)	Technische Unsicherheiten, Umwelt (Wetter)	Risiko/ Ungewissheit/Unwissen
Technische Nutzungsdauer	Technische Unsicherheiten	Risiko/Ungewissheit
Verfügbarkeit erneuerbarer Energien (fluktuierend)	Umwelt (Wetter)	Risiko/Ungewissheit/Unwissen
Erw. Aufwand für Wartung/ Instandhaltung von Anlagenteilen	Technische Unsicherheiten, wirtschaftliche Entwicklung	Ungewissheit/ Unwissen
Kapitalzins (Kreditzins, Alternativrendite, Inflation)	Wirtschaftliche Entwicklung	Risiko/ Ungewissheit
Preise für Energiebezug und -lieferung (Netzspeisung)	Wirtschaftliche Entwicklung, polit. Rahmenbedingungen	Risiko/Ungewissheit/Unwissen
Erwarteter Energieverbrauch	Umwelt (Wetter), Nutzerverhalten (u.a. Leerstandzeiten), technische Unsicherheiten	Risiko/Ungewissheit/Unwissen
Umlagen/Abgaben/Zuschläge für bestimmte Bereiche	Politische/rechtliche Rahmenbedingungen	Ungewissheit/Unwissen

4.4 Verfahren zur Berücksichtigung von Unsicherheiten

Zu den am häufigsten und am ältesten eingesetzten Verfahren zur Abschätzung der Auswirkung von Unsicherheiten auf die optimale Lösung zählen Sensitivitäts- und Szenarioanalysen. Erst als Unsicherheiten bei Entscheidungsproblemen in den 1920er Jahren stärker in den Fokus rückten und in Risiko und Unwissen unterteilt wurden, folgten in den nächsten Dekaden mit Wald (1945), Dantzig (1955) und Beale (1955) erstmals

Optimierungsverfahren mit direkter Berücksichtigung von Unsicherheiten. Für die direkte Einbindung unsicherer Parameter, deren Wahrscheinlichkeitsverteilungen bekannt oder auch adäquat abbildbar sind, eignet sich die Stochastische Programmierung. Bei unsicheren Parametern, deren Wahrscheinlichkeitsverteilungen unbekannt sind, ist vor allem die Robuste Optimierung verbreitet. Daneben eignet sich im Sinne des ökonomischen Entscheiders die sogenannte Regret-Minimierung, die konträr zur Robusten Optimierung neben dem schlimmsten auch Bezug auf den bestmöglichen Fall nimmt.

Die genannten Verfahren zur Berücksichtigung von Unsicherheiten werden auch in der vorliegenden Arbeit verwendet und in den folgenden Abschnitten einzeln vorgestellt. Auch wenn die Robuste Optimierung in vorliegender Arbeit keine direkte Anwendung findet, wird sie als Grundlage der Regret-Minimierung beschrieben. Die rechentechnischen Herausforderungen dieser Verfahren und weitere Optimierungsverfahren für dezentrale Energiesysteme unter Unsicherheit werden in einem Forschungsüberblick in Kapitel 5 aufgezeigt.

4.4.1 Sensitivitäts- und Szenarioanalyse

Eine sehr verbreite und klassische Form, um die Auswirkungen von Unsicherheiten abschätzen zu können, ist die Untersuchung der Rechenergebnisse bei Variation der Inputdaten oder auch, im weiteren Sinne, des Optimierungsprogramms: die Sensitivitäts- und Szenarioanalyse.

In der Literatur wurde die Sensitivitätsanalyse erstmals von Dinkelbach (1969) aus entscheidungstheoretischer Sicht systematisch untersucht und aufgeführt. Dinkelbach (1969) bemängelt oftmals die wenig klare, widersprüchliche Definition. Aus seiner Literaturrecherche geht hervor, dass die Sensitivitätsanalyse generell als eine Postoptimalitätsanalyse aufgefasst wird, die das Entscheidungsproblem nach der Bestimmung der optimalen Lösung in Bezug auf die in die Rechnung eingegangenen Koeffizienten untersucht. Er unterscheidet in direkte Sensitivitätsanalysen, die angeben, in welchen Grenzen sich die in das Optimierungsprogramm eingehenden Daten bewegen können, ohne dass dabei die Optimalität der bestehenden Lösung verletzt wird. Daneben differenziert er in zielfunktionale und parametrische Sensitivitätsanalysen.

Bei der zielfunktionalen Sensitivitätsanalyse werden Entscheidungsmodelle mit mehreren Zielsetzungen mit der Fragestellung untersucht: Wie ändert sich der Wert einer Zielsetzung, wenn die andere Zielsetzung von ihrem individuellen Optimum abweicht?

Bei der parametrischen Sensitivitätsanalyse wird die Abhängigkeit genau eines Koeffizienten von einem Parameter betrachtet.²⁵ Diese Form der Stabilitätsprüfung von Rechenergebnissen bei Variation des Daten-Inputs unter der Ceteris-Paribus-Bedingung werden häufig bei Berechnungen von Kapitalwerten, des internen Zinsfußes oder der Amortisationsdauer von Investitionen eingesetzt (Lüder 1977; Blohm et al. 2012). Schreier (2012) erweitert die parametrische Sensitivitätsanalyse um einen zusätzlichen Untersuchungsgegenstand: Neben der Analyse des Einflusses von Schwankungen einzelner Koeffizienten auf die optimale Lösung werden Auswirkungen von Modelländerungen durch Hinzufügen weiterer Variablen (neuer Aktivitäten) und Restriktionen untersucht. Diese Auffassung der Sensitivitätsanalyse entspricht teilweise auch der Szenarioanalyse.

Die Szenarioanalyse als Form der Zukunftsforschung²⁶ umfasst den Prozess der Erstellung, des Vergleichs und der Bewertung von Szenarien (Alcamo 2008). Wenn auch vermutlich im Militärwesen seit vielen Jahrhunderten eingesetzt, findet sich eine Systematisierung der Analyse erst in den 1950er Jahren. Eine umfangreiche Auflistung der Entwicklungsschritte der Szenarioanalyse bis zum Anfang des 21. Jahrhunderts ist in Mietzner (2009) zu finden. Aus heutiger Sicht ist die Szenarioanalyse eine Methode, mit deren Hilfe systematisch alternative Zukunftsbilder von Entscheidungsproblemen entworfen und in ihrer jeweiligen Entstehung für andere nachvollziehbar gemacht werden können (Götze 2013). Ausgehend von der gegenwärtigen Problemlage, wird bei der Szenario-Erzeugung versucht, alle erwägbaren Entwicklungen und deren Interdependenzen zu berücksichtigen. Gemäß Götze (2013) wird die Szenarioanalyse vor allem zur langfristigen Strategieplanung eingesetzt und dient zur Gewinnung konkreter Handlungsoptionen. Kosow et al. (2008) fassen die Einsatzmöglichkeiten der Szenarioanalyse wie folgt zusammen:

- **Explorative Funktion:** Systematisierung und Vertiefung des bestehenden Verständnisses über heutige und zukünftige Entwicklungen, Zustände und Einflüsse einschließlich der Spannweite möglicher Ausprägungen sowie Bewusstseinerweiterung des konventionellen Denkmusters,
- **Kommunikationsfunktion:** Förderung des gemeinsam geteilten Verständnisses eines Entscheidungsproblems sowie des Austauschs und der Integration verschiedener Perspektiven,

²⁵ Poppenborg (1996) bezeichnet die parametrische Sensitivitätsanalyse auch als parametrische Programmierung und ordnet die direkte Sensitivitätsanalyse als Sonderfall ein.

²⁶ Die Zukunftsforschung (Futurologie) ist ein Problemfeld mehrerer wissenschaftlicher Disziplinen, das sich kritisch und systematisch mit der Zukunft beschäftigt (Flechtheim 1971).

- **Zielbildungsfunktion:** Entwicklung oder Konkretisierung von Zielvorstellungen sowie Machbarkeits- und Plausibilitätsprüfung,
- **Entscheidungsfindungs- und Strategiebildungsfunktion:** Entwicklung von Handlungsoptionen und Indikatoren als Orientierungspunkte sowie Bewertung von Entscheidungen, Maßnahmen, und Strategien (z. B. als Test der Tragfähigkeit, Robust- Robustheit und Effizienz).

Kosow et al. (2008) beschreiben das Szenario als Idee einer möglichen Zukunft. Somit sind implizit immer mehrere alternative Zukünfte möglich. Szenarien dienen dazu, den Raum möglicher Zukünfte aufzuspannen. Als Veranschaulichung dieser Offenheit und Multiplizität der Zukunft dient häufig der in Abb. 4.1 dargestellte Szenariotrichter.

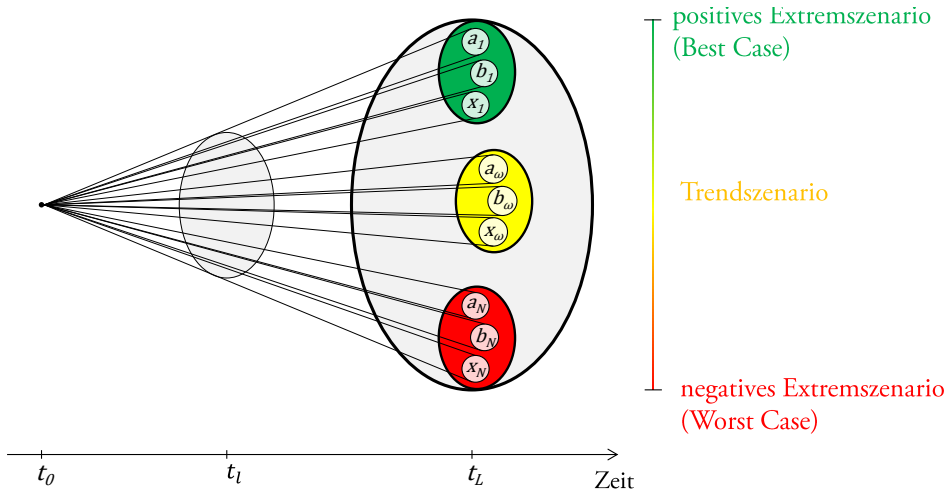


Abb. 4.1: Szenariotrichter (in Anlehnung an Kosow et al. 2008; Reibnitz 1992).

Der Szenariotrichter verdeutlicht, dass die Zahl möglicher Entwicklungen ansteigt und sich der Raum möglicher Zukunftsbilder trichterförmig auf die Zukunft hin öffnet, je weiter von einem gewählten Zeitpunkt (t_0) aus in die Zukunft geschaut wird (t_l und t_L). Unterschiedliche Szenarien (in Abb. 4.1 angedeutet durch die Indizes $1, \dots, \omega, \dots, N$) dienen dazu, den Raum möglicher Entwicklungen abzubilden und führen zu einem Bündel alternativer Zukünfte, die sich im Zeitablauf auseinanderbewegen (siehe auch Kaiser et al. 1999). Dazu werden für jedes Szenario mögliche Verläufe der unterschiedlichen Einflussfaktoren (in Abb. 4.1 angedeutet durch a, b, \dots, x) ausgewählt und zu den Szenarien verdichtet, die für jeden einzelnen Zeitpunkt (t_{0+i}) einen Trichter verschie-

dener denkbarer Ausprägungen aufspannen. Der Bereich außerhalb des Szenariotrichters symbolisiert zukünftige Entwicklungen, die nicht betrachtet werden, z. B. weil sie als unmöglich angesehen werden (Kosow et al. 2008).

Um die Spannweite des Zukunftsbilds möglichst gut zu erfassen, werden die Einflussfaktoren aus dem breiten Raum möglicher Entwicklungen häufig zu Extremszenarien verdichtet. Dabei wird versucht ein positives Extremszenario als bestmögliche Zukunftsentwicklung (Best Case) und ein negatives Extremszenario als denkbar schlechteste Zukunftsentwicklung (Worst Case) zu erstellen: minimaler und maximaler Ziel-funktionswert der Optimierung.²⁷ Daneben wird bei Fortschreibung der Gegenwart in die Zukunft ein Trendszenario erstellt, von dem angenommen wird, dass es dem wahrscheinlichsten Zukunftsfall entspricht. Die entwickelten Szenarien können generell mit bestimmten Eintrittswahrscheinlichkeiten spezifiziert werden (siehe Godet 1994). Durch die differenzierte Vorhersagbarkeit der Zukunft unterliegt jedes Szenario gleichzeitig einer gewissen Unsicherheit.

4.4.2 Stochastische Programmierung

Die Ursprünge der Stochastischen Programmierung liegen in den 1950er Jahren in den Arbeiten von Dantzig (1955) und Beale (1955), in denen bestimmte Modelparameter erstmals als nicht exakt bekannt betrachtet werden und anhand ihrer Wahrscheinlichkeitsverteilungen Berücksichtigung finden. Die Abbildung unsicherer Inputdaten mit Zufallsvariablen ermöglicht eine Modellierung vieler wirtschaftlicher Fragestellungen, in denen beispielsweise Preise, Produktnachfragen, Ressourcen, oder Kapazitäten zum Zeitpunkt der Entscheidungsfindung oft nicht genau bekannt sind (Koberstein 2016). Zu den einführenden Standardwerken zur Stochastischen Programmierung zählen die Monografien von Birge (1982) und Kall und Wallace (1997).

Allgemein wird bei der Stochastischen Programmierung in „Here-and-Now“-Entscheidungen differenziert, die zum jetzigen Zeitpunkt getroffen werden müssen, und „Wait-and-See“-Entscheidungen, die erst zukünftig getroffen werden und gewissen Unsicherheiten unterliegen (Kall und Wallace 1997). Die einstufige Stochastische Programmierung beinhaltet ausschließlich „Here-and-Now“-Entscheidungsprobleme. Bei der zwei- oder mehrstufigen Stochastischen Programmierung müssen generell „Here-and-Now“-Entscheidungen zum Zeitpunkt $t = 0$ und „Wait-and-See“-Entscheidungen

²⁷ Positive (Extrem-)Szenarien werden von Steinmüller und Schulz-Montag (2004) auch als Wunsch-szenarien deklariert.

zu zukünftigen Zeitpunkten $t = 0, \dots, T$ getroffen werden. Hierbei werden die zeitlich späteren Entscheidungen durch die vorangegangenen Entscheidungen beeinflusst sowie durch die unsicheren Parameter, deren Realisation noch zu beobachten ist.

Bei der zweistufigen Stochastischen Programmierung wird die Erststufen- und Zweitstufen-Entscheidung gesucht, die zum erwarteten Optimum bei unsicherer Zukunft führt (Heitsch et al. 2009). Während die Erststufen-Entscheidung \mathbf{x} deterministisch ist, hängt die Zweitstufen-Entscheidung $\mathbf{y} = (\mathbf{y}_1, \dots, \mathbf{y}_T)$ und jede ihrer Komponenten von den zukünftigen Realisationen der unsicheren Parameter ab. Soll die Entscheidung \mathbf{x}_t zum Zeitpunkt t nur von der bis dahin vorhandenen Information abhängen, kann dies mit der mehrstufigen Stochastischen Programmierung abgebildet werden (Heitsch et al. 2009). Es findet eine Erweiterung der Interaktion zwischen Entscheidung und Beobachtung bei dem rekursiven Entscheidungsprozess statt, der zu jedem neuen Zeitpunkt auf der Basis neuer Information erfolgt (Heinze 2008). Dadurch wird das mehrstufige Modell aus struktureller und algorithmischer Sicht zu einem wesentlich komplexeren Programm. Jedoch weisen Szenarien, die aus historischen Daten oder durch auf angepasste Zeitreihen- oder Regressionsmodellen basierende Simulationen erzeugt werden, generell keine Baumstruktur auf, die für die mehrstufige Stochastische Programmierung benötigt wird (Heitsch et al. 2009). Es müsste aus diesen Szenarien ein geeigneter Szenariobaum approximiert werden und der dabei resultierende Approximationsfehler akzeptiert werden, um die Generalität des entwickelten Konzepts in Kapitel 6 zu erhalten. Überdies wäre bei einem mehrstufigen stochastischen Programm nur ein geringerer Parallelisierungsgrad bei der verteilten Ausführung des Optimierungsprogramms (siehe Abschnitt 7.1) realisierbar. Aus diesen beiden Gründen wird in der vorliegenden Arbeit die zweistufige Stochastische Programmierung verwendet.

Für zweistufige lineare stochastische Programme mit Rekurs (Kompensation), als Sonderform der mehrstufigen Stochastischen Programmierung, gilt (Ahmed 2010):

$$\begin{aligned} \min_{\mathbf{x}} \quad & c^T \mathbf{x} + E_{\omega} Q_{\omega}(\mathbf{x}) \\ \text{s. t.} \quad & \underline{A} \mathbf{x} \leq \underline{b}, \\ & \mathbf{x} \geq 0, \end{aligned} \tag{4.7}$$

mit $\omega = 1, \dots, N$ unabhängigen Szenarien sowie:

$$\begin{aligned} Q_{\omega}(\mathbf{x}) := \quad & \min_{\mathbf{y}} p_{\omega}^T \mathbf{y} \\ \text{s. t.} \quad & \underline{T}_{\omega} \mathbf{x} + \underline{W}_{\omega} \mathbf{y} \leq \underline{h}_{\omega} \quad \forall \omega = 1, \dots, N, \\ & \mathbf{y} \geq 0. \end{aligned} \tag{4.8}$$

Die erste Stufe in Gleichung (4.7) enthält die Erststufen-Entscheidung \mathbf{x} sowie die Zielfunktionskoeffizienten-Matrix (Kosten-Matrix) c^T , die Restriktionskoeffizienten-Matrix \underline{A} und die Rechte-Hand-Seite b , die mit Sicherheit allesamt bekannt sind. In der zweiten Stufe in Gleichung (4.8) wird die Erwartung E der Rekurs-Zielfunktion Q minimiert, einem Produkt der Zweitstufen-Entscheidungsvariablen \mathbf{y} und der Rekurs-Kosten p . Die Rekurs-Zielfunktion Q wird durch die Transitions-Matrix \underline{T} (auch als Technologie-Matrix bezeichnet), die Variablen x , die Rekurs-Matrix \underline{W} und die Rechte-Hand-Seite h beschränkt. Der Index ω kennzeichnet ein mit der Eintrittswahrscheinlichkeit π mögliches Szenario des Wahrscheinlichkeitsraums (N, P) und weist darauf hin, dass \underline{T} , \underline{W} , h und p nicht mit Sicherheit bekannt sind. Fester Rekurs liegt vor, wenn $\underline{W}_\omega = \underline{W}$, also keine Unsicherheiten im Rekurs auftreten (Schade 2012). Der Rekurs heißt „vollständig“, wenn zu jeder Erststufenentscheidung eine zulässige Zweitstufenentscheidung existiert. Er heißt „relativ vollständig“, wenn für jede zulässige Entscheidung in der ersten Stufe und für jedes Szenario eine zulässige Entscheidung in der zweiten Stufe existiert.

Die analytische Lösung zweistufig stochastischer Programme ist nur in wenigen, einfachen Fällen bekannt. Alternativ kann das Programm als sogenanntes deterministisches Äquivalent formuliert werden, um es numerisch lösen zu können (Infanger 2011):

$$\min_{\mathbf{x}, \mathbf{y}_\omega} c^T \mathbf{x} + \pi_1 p_1^T \mathbf{y}_1 + \dots + \pi_\omega p_\omega^T \mathbf{y}_\omega + \dots + \pi_N p_N^T \mathbf{y}_N \quad (4.9)$$

$$\text{s. t. } \underline{A} \mathbf{x} \leq b, \quad (4.10)$$

$$\begin{array}{rcl} \underline{T}_1 \mathbf{x} + \underline{W}_1 \mathbf{y}_1 & & \leq h_1, \\ \vdots & \ddots & \vdots \\ \underline{T}_\omega \mathbf{x} & + \underline{W}_\omega \mathbf{y}_\omega & \leq h_\omega, \end{array} \quad (4.11)$$

$$\begin{array}{rcl} \vdots & \ddots & \vdots \\ \underline{T}_N \mathbf{x} & + \underline{W}_N \mathbf{y}_N & \leq h_\omega, \\ \mathbf{x}, & \mathbf{y}_1 \quad \dots \quad \mathbf{y}_\omega, \quad \dots \quad \mathbf{y}_N & \geq 0. \end{array} \quad (4.12)$$

Hierbei tritt jedes Szenario ω als Element des Szenario-Sets $\Omega = \{1, 2, \dots, N\}$ mit jeweils der Wahrscheinlichkeit π_1, \dots, π_N ein.²⁸ Im Fall gemischt-ganzzahliger Entscheidungsvariablen sind \mathbf{x} und \mathbf{y} definiert als:

$$\mathbf{x} \in \mathbb{R}_+^{I-Z_1} \times \mathbb{Z}_+^{Z_1}, \mathbf{y}_\omega \in \mathbb{R}_+^{R-Z_2} \times \mathbb{Z}_+^{Z_2}. \quad (4.13)$$

Dabei sind I, R, Z_1 und Z_2 nicht negative ganze Zahlen mit $Z_1 \leq I$ und $Z_2 \leq R$.

²⁸ In praktischen Anwendungen sind \underline{W} und p^T meist unabhängig von ω , also sicher bekannt.

Die Szenario-Erzeugung sollte adäquat in Abhängigkeit von den Wahrscheinlichkeitsverteilungen der unsicheren Parameter erfolgen. Für lineare stochastische Programme konnte Schultz (1995) aufzeigen, dass kontinuierliche Verteilungen unter milden Bedingungen effektiv durch diskrete Verteilungen mit beliebiger Genauigkeit approximiert werden können. Bei gleicher Eintrittswahrscheinlichkeit der Szenarien kann Gleichung (4.9) als sogenannte Sample-Average-Approximation des stochastischen Programms zusammengefasst werden zu (Shapiro et al. 2009):²⁹

$$\min_{x, y_\omega} c^T x + \frac{1}{N} \sum_{\omega=1}^N p_\omega^T y_\omega. \quad (4.14)$$

Gemäß dem Gesetz der großen Zahlen konvergiert die angenäherte Erwartung E mit $N \rightarrow \infty$ punktweise zum exakten Wert, unter der Annahme, dass die Szenarien unabhängig voneinander sind.

Der Vorteil der Modellierung des Problems als stochastisches Programm wird üblicherweise durch den Wert der stochastischen Lösung (*Value of Stochastic Solution*, VSS) ausgedrückt (Birge 1982). Für die Berechnung werden die Erststufen-Variablen des Programms für nur ein Szenario deterministisch optimiert, welches die Erwartungswerte der unsicheren Parameter enthält. Diese optimalen Erststufen-Variablen der Erwartungswerte werden dem gesamten stochastischen Programm für alle Szenarien explizit vorgegeben. Die resultierende Lösung wird mit der stochastischen Lösung verglichen.

Häufig wird bei stochastischen Programmen auch der Erwartungswert für perfekte Information (*Expected Value of Perfect Information*, EVPI) angegeben. Er liefert einen ökonomischen Wert für den Bezug perfekter Informationen über die Zukunft, und ist demzufolge ein Maß für den Wert genauer Prognosen der unsicheren Parameter. Allgemein wird der EVPI aus der Differenz zwischen den minimalen erwarteten Kosten der stochastischen Lösung und den im besten Fall minimalen erwarteten Kosten berechnet. Im „besten Fall“ bedeutet, dass perfekte Informationen über zukünftige Szenarien zur Verfügung stehen und die Erststufen-Variablen für jedes auftretende Szenario individuell angepasst werden können. Mathematisch gesehen resultiert der Erwartungswert der individuell optimierten Szenarien aus der Relaxation der Nichtantizipativitäts-Restriktion.

²⁹ Das Handeln nach dem Erwartungswertprinzip wird auch als Bayes-Regel (μ -Regel) bezeichnet und entspricht risikoneutralen Entscheidern. Risikopräferenzen können bspw. unter Hinzunahme der Standardabweichung (μ - σ -Regel) berücksichtigt werden. Die Annahme, dass die Eintrittswahrscheinlichkeiten aller Szenarien gleich sind (Indifferenzprinzip), wird als Laplace-Regel bezeichnet (Bardmann 2014).

4.4.3 Robuste Optimierung

Historisch gesehen wurde die Minimax-Regel als Grundidee der Robusten Optimierung etwa eine Dekade vor der Stochastischen Programmierung von Wald (1945) vorgestellt. Der Gedanke, auf den Erwartungswert hin zu optimieren, wurde mit der Begründung verworfen, dass in den meisten Anwendungsfällen die Eintrittswahrscheinlichkeiten unsicherer Parameter nicht vorliegen oder a priori unbekannt sind. Im Gegensatz besteht der Vorteil der Robusten Optimierung darin, die maximale Gefahr des Entscheiders (Worst Case) zu minimieren, ohne Informationen über die Wahrscheinlichkeitsverteilungen der unsicheren Parameter zu benötigen. Nachteilig ist hier die hohe Sensitivität gegenüber Extremfällen.

Die grundlegende Minimax-Regel wurde im Laufe der Zeit immer weiter verfeinert (Mulvey et al. 1995; Bertsimas und Sim 2006; Bertsimas und Sim 2004) und vor allem durch Ben-Tal und Nemirovskii (1997) geprägt. Heute gibt es verschiedene Varianten zur Bestimmung des unsicheren Sets U eines Parameters. Durch die Möglichkeit zur Aufweichung der ursprünglich harten Restriktionen lässt sich das robuste Programm in ein stochastisches Programm überführen und umgekehrt. Ben-Tal et al. (2009) bieten hierzu einen sehr guten Einblick und definieren das robuste Programm allgemein:

$$\begin{aligned} \min_x \quad & \sup_{c \in U^c} c^T x \\ \text{s. t.} \quad & \sup_{(\underline{A}, b) \in U^a \times U^b} (\underline{A}x - b) \leq 0, \\ & x \geq 0, \end{aligned} \tag{4.15}$$

wobei $(\underline{A}, b, c) \in U = U^a \times U^b \times U^c$ und $x \in \mathbb{R}^I$. $\underline{A} \in \mathbb{R}^{I \times J}$, $b \in \mathbb{R}^J$ und $c \in \mathbb{R}^I$ sind unsichere Parameter in einem konvexen Unsicherheits-Set U , das in $\mathbb{R}^{I \times J} \times \mathbb{R}^J \times \mathbb{R}^I$ als kartesisches Produkt jedes unsicheren Parameter-Sets definiert ist.

Die Robuste Optimierung unter Anwendung der Minimax-Regel ist eine extrem pessimistische Entscheidungsregel, bei der jede Handlungsalternative nur anhand des Ergebnisses beurteilt wird, das beim schlechtesten Umweltzustand (Handlungskonsequenz) eintreten kann. Ein extrem optimistischer Entscheider würde die Maximax-Regel verwenden, bei der nur der beste Umweltzustand je Handlungsalternative betrachtet wird. Aus den so ermittelten, jeweils besten Handlungskonsequenzen wird die Handlungsalternative mit dem maximalen Ergebniswert ausgewählt (Bardmann 2014).

4.4.4 Regret-Minimierung

Das Prinzip der Regret-Minimierung wurde erstmals von Savage (1951) in Anlehnung an die Minimax-Regel von Wald (1945) exemplarisch formuliert und damals noch als minimaler Verlust bezeichnet.³⁰ Der Begriff „Regret“ (Reue) wurde von Bell (1982) sowie Loomes und Sugden (1982) eingeführt und fortan unter Anwendung der Regret-Minimierung weiter gefestigt (Engelbrecht-Wiggans 1989; De La Torre, T. et al. 1999; Fang und Hill 2003; Maghouli et al. 2011; Eldar et al. 2004).

Mit Regret ist die Reue (Opportunitätskosten) des Entscheiders gemeint, die in einem bestimmten Fall nach getroffener Entscheidung entsteht.³¹ Mathematisch formuliert empfindet der Entscheider bei der Umsetzung der Entscheidung \mathbf{x} unter Fall $\boldsymbol{\theta}$:

$$\text{regret}(\mathbf{x}, \boldsymbol{\theta}) = f(\mathbf{x}, \boldsymbol{\theta}) - f(\mathbf{x}^*, \boldsymbol{\theta}), \quad (4.16)$$

wobei $f(\cdot)$ generell für ein Kriterium steht, das es zu minimieren gilt (z. B. Kosten) und \mathbf{x}^* die optimale Lösung für Fall $\boldsymbol{\theta}$ ist (Mejia-Giraldo 2013). Die Minimierung des Regrets führt zu einer robusten Lösung im Sinne eines Regret-aversen Entscheiders:

$$\min_{\mathbf{x}} \max_{\boldsymbol{\theta}} \text{regret}(\mathbf{x}, \boldsymbol{\theta}). \quad (4.17)$$

Eine vollständig robuste Lösung $\mathbf{x}^{\text{robust}}$ liegt vor, wenn $\text{regret}(\mathbf{x}^{\text{robust}}, \boldsymbol{\theta}) = 0 \quad \forall \boldsymbol{\theta}$. Demnach kann die Regret-Minimierung mit der von Wald (1945) eingeführten Minimax-Regel auch als erweiterte Form der Robusten Optimierung verstanden werden (Mejia-Giraldo 2013). Im Unterschied zur Robusten Optimierung wird bei der Regret-Minimierung neben dem Worst Case auch ein absoluter Bezug zum Best Case hergestellt. Es erfolgt die Minimierung des Regrets, so dass der Entscheider im schlimmsten Fall am wenigsten Reue empfinden würde.

Der Vorteil der Regret-Minimierung, ähnlich wie bei der Robusten Optimierung, besteht darin, dass keine Informationen über die Wahrscheinlichkeitsverteilungen der unsicheren Parameter benötigt werden. Nachteilig ist die hohe Sensitivität gegenüber der Auswahl an möglichen Fällen (Higle und Wallace 2002).

³⁰ Die Regret-Minimierung ist auch als Savage-Niehans-Regel bekannt, aufgestellt durch den amerikanischen Statistiker Leonard Jimmie Savage und den schweizer Nationalökonom Jürg Niehans (Bardmann 2014).

³¹ Bei der Regret-Minimierung wird in der Regel der Begriff „Szenario“ genutzt. Um eine Verwechslung zur Stochastischen Programmierung zu vermeiden, wird auf den folgenden Seiten stets der Begriff „Fall“ zur Verdeutlichung einer möglichen, ungewissen Realisation der Regret-Minimierung verwendet.

5 Stand der Wissenschaft

In Abschnitt 5.1 wird der aktuelle Forschungsstand der Optimierung dezentraler Energiesysteme wiedergegeben. In diesem Zusammenhang werden im folgenden Abschnitt 5.2 Optimierungsverfahren vorgestellt, die Unsicherheiten direkt bei der Optimierung mit berücksichtigen. Verfahren wie die Sensitivitäts- oder Szenarioanalyse, die Unsicherheiten erst nach dem Optimierungsprozess bewerten, werden hier nicht betrachtet. In Abschnitt 5.3 wird explizit auf die in der Arbeit verwendeten Verfahren mit Bezug auf deren rechentechnische Herausforderungen eingegangen.

5.1 Forschungsstand der Investitions- und Einsatzplanungsoptimierung

In der Literatur beschäftigen sich zahlreiche Arbeiten mit der Investitions- und Einsatzplanungsoptimierung dezentraler Energiesysteme, meist unter der Prämisse sicherer Bedingungen. Je nach Anwendungszweck werden nur Investitionsentscheidungen unter regelbasiertem Betriebsverhalten oder nur der kurz- oder langfristige Betrieb bei Vorgabe der Investitionsentscheidung optimiert. Grund für die alleinige Optimierung der Investitionsplanung oder der Einsatzplanung sind oftmals höhere Anforderungen an das Modell, etwa bedingt durch Realtime-Applikationen oder eine höhere Komplexität bzw. Detailtiefe des Modells. Der Forschungsstand der Optimierung dezentraler Energiesysteme ist mit Quellenangaben und Modellnamen in der folgenden Tab. 5.1 aufgeführt. Neben der Unterscheidung in Investitions- und Einsatzplanungsoptimierung sind die enthaltenen Energiesystemkomponenten, die betrachtete Energieform sowie die zeitliche Auflösung und der Betrachtungshorizont gelistet. Auf Modellen mit reiner Investitionsplanungsoptimierung folgen Modelle mit reiner Einsatzplanungsoptimierung sowie Modelle mit Investitions- und Einsatzplanungsoptimierung; eine gesonderte Spalte erfasst die Berücksichtigung von Unsicherheiten. Eine weitere Sortierung erfolgt ggf. anhand der zeitlichen Auflösung in absteigender Reihenfolge (beginnend mit der größten) und nachrangig anhand des Betrachtungshorizonts in aufsteigender Reihenfolge (beginnend mit dem kürzesten). Die vorliegende Arbeit ist zum Vergleich am Tabellenende aufgeführt.

Tab. 5.1: Forschungsstand der Investitions- und Einsatzplanungsoptimierung dezentraler Energiesysteme (Seite 1 von 2).

Quelle	Modellname ¹	Optimierung ²		Energiesystemkomponenten ³	Betrachtete Energieform		Programm- art ⁵	zeitl. Auflösung	zeitl. Horizont
		Inv.	Eins.		el.	th.			
Xu et al. (2005)	n. a.	x		PV+S+W	x		MINLP	1 h	1 y
Bernal-Agustín et al. (2006)	n. a.	x		DG+S	x		NLP	1 h	25 y
Dufo-López u. Bernal-Agustín (2015)	n. a.	x		BZ+DG+P2G+S	x		NLP	1 h	25 y
Katsigiannis et al. (2010)	SAHPS	x		BZ+DG+P2G+S+W	x		NLP	10 min	20 y
Merai et al. (2013)	n. a.	x		DG+PV+S+W	x		NLP	10 min	20 y
Hawkes et al. (2006)	n. a.	x		KWK+S	x	x	NLP	1 min	10 y
Shang et al. (2017)	n. a.		x	KWK+S	x	x	MILP	1 h	1 d
Suk-Kim u. Edgar (2014)	n. a.		x	KWK	x	x	MINLP	1 h	1 d
Moghaddam et al. (2016)	Energy Hub		x	KWK+N+P2H+S	x	x	MINLP	1 h	1 d
Wei et al. (2015)	n. a.		x	P2H		x	NLP	1 h	< 1 w
Wille-Haussmann et al. (2010)	n. a.		x	KWK+N+S	(x)	x	MILP	1 h	1 w
ElNozahy et al. (2015)	n. a.		x	EF+N+PV+S	x		NLP	1 h	20 y
Oh et al. (2012)	n. a.		x	KWK	x	x	LP	1 h	1 y
Shirazi u. Jaidid (2017)	n. a.		x	DSM+KWK+PV+P2H+S+W	x	x	MILP	30 min	1 d
Erdinc (2014)	n. a.		x	EF+S	x		MILP	15 min	2 d
Schönefelder (2013)	P-OPT		x	KWK	x	x	MILP	15 min	14 d
Fischer (2015)	n. a.		x	PV+P2H+S		x	NLP	15 min	1 y

Tab. 5.1: Forschungsstand der Investitions- und Einsatzplanungsoptimierung dezentraler Energiesysteme (Seite 2 von 2).

Quelle	Modellname ¹	Optimierung ²		Energiesystemkomponenten ³	Betrachtete Energieform		Programm-art ⁵	zeitl. Auflösung	zeitl. Horizont
		Inv.	Betr.		el.	th.			
Kunze (2016)	BRIAMO	x	x	E+KWK+ST+PV+S	x	x	MILP	ZS	20 y
McKenna et al. (2018)	RE ³ ASON	x	x	B+E+HK+KWK+N+PV+P2H+S+W	x	x	MILP	ZS	35 y
Lorenzi u. Silva (2016)	n. a.	x	x	PV+S	x	x	LP	1 h	10 y
Eggers (2018)	KomMod	x	x	KWK+ST+PV+P2H+S+W	x	x	LP	1 h	1 y
Kaschub (2017)	SpeicherOpt	x	x	EF+PV+S	x	x	MILP	15 min	20 y
Burkhard (2015)	n. a.	x	x	DG+PV+S	x	x	LP	15 min	20 y
Beck et al. (2017)	n. a.	x	x	PV+P2H+S	x	x	MILP	15/60 min	20 y
Kia et al. (2017)	n. a.	x	x	KWK+N+S	x	x	SMILP	1 h	1 d
Moradi et al. (2013)	n. a.	x	x	HK+KWK	x	x	MILP +F	1 h	1 y
Müller (2017)	OSH	x	x	HK+KWK+PV+P2H+S	x	x	SMILP	1 min	1 d
Mavromatidis et al. (2017)	n. a.	x	x	HK+KWK+PV+P2H+S	x	x	SMILP	60 min	n. a.
(vorliegende Arbeit)	Θ-DES	x	x	PV+P2H+S	x	x	R-SMILP	15 min	20 y

¹ Modellname: n. a.= nicht angegeben.
² Optimierung: Inv.= Investitionsplanung, Eins.= Einsatzplanung, u. U.= unter Unsicherheit.
³ Komponente: B= Biomasseanlage, BZ= Brennstoffzelle, DSM= Demand-Side-Management, DG= Dieselgenerator, E= Effizienzmaßnahme, EF= Elektrofahrzeug, HK= Heizkessel (Biomasse/Gas/Öl), KWK= Kraft-Wärmekopplungsanlage, N= Netz, ST= Solarthermieanlage, PV= Photovoltaikanlage, P2H/P2G= Power-to-Heat-/Power-to-Gas-Applikation, S= Speicher, W= Windenergieanlage.
⁴ Energieforn: el.= elektrisch, th.= thermisch.
⁵ Programmart: LP= lineares Programm, MILP= gemischt-ganzzahliges lineares Programm, MINLP= gemischt-ganzzahliges nicht lineares Programm, NLP= nicht lineares Programm, SMILP= stochastisches gemischt-ganzzahliges lineares Programm, F= Fuzzy Programmierung, R= Regret-Minimierung.
⁶ Programmart: ZS= Zeitscheiben (Zusammenfassung mehrerer Stunden).

Als Energiesystemkomponenten zur Bereitstellung elektrischer Energie stehen überwiegend PV- und KWK-Anlagen im Fokus. Daneben werden auch Biomasseanlagen (B), Brennstoffzellen (BZ), Dieselgeneratoren (DG), Heizkessel (HK) sowie Solarthermie(ST)- und Windenergieanlagen (W) betrachtet. Häufig werden diese Erzeugungskomponenten mit Speichern (S) oder Optionen zur Sektorenkopplung wie Elektrofahrzeugen (EF) sowie Power-to-Heat- und Power-to-Gas-Applikationen (P2H bzw. P2G) kombiniert. Neben der Energieangebotsseite werden auch Demand-Side-Management (DSM) und Effizienzmaßnahmen (E) auf der Nachfrageseite bei der Optimierung mitberücksichtigt (z. B. Kunze 2016; Shirazi und Jadid 2017). Vereinzelt werden auch Netze (N) zwischen Angebots- und Nachfrageseite miteinbezogen (z. B. ElNozahy et al. 2015; Moghaddam et al. 2016).

Im Hinblick auf die betrachteten Energieformen wird oft nur die elektrische (el.) Angebots- und Nachfrageseite betrachtet (z. B. Xu et al. 2005; Bernal-Agustín et al. 2006; Katsigiannis et al. 2010; Merei et al. 2013; Erdinc 2014; Dufo-López und Bernal-Agustín 2015; Kaschub 2017). Andere Arbeiten legen den Fokus auf das thermische (th.) Management (z. B. Wille-Hausmann et al. 2010; Fischer et al. 2014; Wei et al. 2015). Daneben betrachten diverse Arbeiten die elektrische und die thermische Seite, aber nur wenige umfassen zudem eine Investitions- und Einsatzplanungsoptimierung (z. B. Lorenzi und Silva 2016). Zum Teil liegt der Schwerpunkt hierbei auf dem Heizsystem der thermischen Seite (z. B. Beck et al. 2017; Eggers 2018), einige Optimierungsmodelle berücksichtigen noch verschiedene Maßnahmen auf der Energienachfrageseite (z. B. Kunze 2016; McKenna et al. 2018).

Für die Optimierung sind die Modelle je nach Anforderung und Zweck meist als gemischt-ganzzahlige lineare Programme (MILP) und nicht lineare Programme (NLP) umgesetzt. Außerdem gibt es einige lineare Programme (LP) und gemischt-ganzzahlige nicht lineare Programme (MINLP). Die Mehrheit der Programme basiert aufgrund fluktuierender Eigenschaften auf der Angebots- und Nachfrageseite auf einer zeitlich hohen Auflösung von 15 min bis 1 h mit einem zeitlichen Horizont von weniger als einem Tag bis hin zu 25 Jahren. Je nach Anwendung werden sehr hohe, minütliche Auflösungen (z. B. Hawkes et al. 2006) oder gegenteilig gröbere Auflösungen durch Zusammenfassen mehrerer Stunden in Zeitscheiben genutzt (z. B. Kunze 2016).

In fast allen aufgeführten Arbeiten werden trotz der verschiedenen Unsicherheiten, welche die Modellergebnisse beeinflussen, deterministische Programme mit vollständiger Information verwendet. Unsichere Parameter werden dann häufig mit Mittelwerten oder Sensitivitäts- und Szenarioanalysen beurteilt. Jedoch können mit solchen Verfahren

die Effekte auf die Optimierungsergebnisse lediglich abgeschätzt werden – die komplexen Auswirkungen können dabei nicht komplett erfasst werden.

Die von Beck et al. (2017) dargelegte Investitions- und Einsatzplanungsoptimierung im Wohngebäudebereich mit PV, Wärmepumpen und Speichern in Stuttgart gleicht dem Fallbeispiel der vorliegenden Arbeit. Mit einem Betrachtungshorizont von 20 Jahren wird bei der Optimierung neben dem Elektrizitätsbedarf auch der thermische Bedarf für Raum- und Warmwasser in hoher 15-min-Auflösung miteinbezogen. Die Minimierung der Gesamtenergiekosten basiert auf der Annuitätenmethode. Im Unterschied zur vorliegenden Arbeit führen Beck et al. (2017) die Untersuchung von Unsicherheiten mittels Szenarioanalyse durch. Darüber hinaus enthält das Modell vorwiegend kontinuierliche Variablen und nur wenige binäre Variablen für Investitionsentscheidungen. Weiter vereinfacht wird das Modell durch die Zusammenfassung der Entscheidungsvariablen für Raumwärme zu stündlichen Zeitschritten. Begründet wird diese Vereinfachung mit der Trägheit des Gebäudes und des Wärmeübertragungssystems. Die Wärmepumpenflexibilität, die einen Einfluss auf die Speicherauslegung hat, geht hierdurch verloren (siehe auch Diskussionskapitel, Abschnitt 9.2.3).

Zwar existieren einige Arbeiten, die Unsicherheiten bei der Betriebsoptimierung dezentraler Energiesysteme direkt einbinden (z. B. Moradi et al. 2013; Kia et al. 2017; Müller 2017), jedoch berücksichtigen Mavromatidis et al. (2017) als einzige Unsicherheiten bei der Optimierung der Investitionsentscheidung und der Betriebsführung. Deren Modell kommt dem der vorliegenden Arbeit am nächsten: Mithilfe eines stochastischen gemischt-ganzzahligen linearen Programms (SMILP) werden Investitions- und Einsatzplanung für das Energiesystem eines Bürogebäudes in der Schweiz optimiert. Die Kostenminimierung basiert ebenfalls auf der Annuitätenmethode. Im Untersuchungsfokus steht die Autarkiefähigkeit des Gebäudes. Zu den Energiesystemkomponenten zählen eine PV-Anlage, Wärmepumpen sowie elektrische und thermische Speicher. Darüber hinaus bestehen die Optionen für eine KWK-Anlage und für verschiedene Heizkesseltypen (Gas, Öl und Biomasse). Die Ergebnisse zeigen, dass mit der kostengünstigsten Lösung eine elektrische Autonomie von 20 % erreicht wird, wenn nur PV-Strom lokal zur Verfügung steht. Höhere Autarkiegrade bis zu 100 % erfordern zusätzliche elektrische Energie von einer KWK-Anlage sowie sehr große thermische und elektrische Speicher. Schließlich zeigen Mavromatidis et al. (2017) signifikante Unterschiede zu deterministischen Lösungen auf und verdeutlichen die Bedeutung von Unsicherheitsüberlegungen bei der Gestaltung (autonomer) dezentraler Energiesysteme. Das stochastische Optimierungsprogramm unterscheidet sich zur vorliegenden Arbeit vor allem im Detail- und Komplexitätsgrad: Risikobehaftete Unsicherheiten werden mit 20

Szenarien abgebildet. Dabei umfasst jedes Szenario jeweils 270 000 Entscheidungsvariablen und 340 000 Restriktionen (in der vorliegenden Arbeit sind es 100 Szenarien mit jeweils 670 000 Entscheidungsvariablen und 1 200 000 Restriktionen). Statt mit 15 min wird mit einer zeitlichen Auflösung von 60 min gerechnet. Dadurch werden kurzfristige Schwankungen der PV-Anlage und der Energienachfrage verstärkt geglättet. Verluste der Speicher und der Wärmepumpe werden dabei nicht betrachtet. Der Betrieb der Wärmepumpen ist linearisiert. Obwohl, ähnlich wie bei Beck et al. (2017), nur wenige binäre Variablen für Investitionsentscheidungen verwendet werden, ist eine genauere Modellierung, insbesondere ganzzahlige Variablen in der zweiten Stufe, laut Mavromatidis (2018) nicht möglich. Darüber hinaus bleiben mit dem stochastischen Programm Ungewissheiten in der Optimierung unberücksichtigt.

Die vorliegende Arbeit zeichnet sich durch die Berücksichtigung von Unsicherheiten in der Optimierung aus. Dabei werden risikobehaftete PV-Erträge, elektrische und thermische Energienachfragen, Strompreise sowie deren Korrelationen untereinander, basierend auf derselben Meteorologie, konsistent abgebildet. Besonders hervorzuheben ist das stochastische gemischt-ganzzahlige lineare Programm mit übergeordneter Regret-Minimierung, das neben risikobehafteten auch ungewisse Parameter berücksichtigen kann. Rechentechnisch wird das Programm mittels Entkopplung, Szenarioreduktion, optimierten Solver-Einstellungen und intensiver Parallelisierung auf HPC-Clustern ausgeführt.

5.2 Optimierungsverfahren zur Berücksichtigung von Unsicherheiten

Die klassischen Verfahren zur Optimierung von Entscheidungsproblemen unter unsicheren Bedingungen sind probabilistische Methoden wie die Stochastische Programmierung oder Techniken der Robusten Optimierung. Die folgende Tab. 5.2 enthält weitere Optimierungsverfahren, die sich grundsätzlich für die Investitions- und Einsatzplanungsoptimierung unter Unsicherheiten eignen würden. Die Grundidee jedes Verfahrens ist mitaufgeführt. Daneben sind Anwendungsbeispiele im energiewirtschaftlichen Kontext sowie die dabei berücksichtigten unsicheren Parameter aufgeführt.

Für die Berücksichtigung risikobehafteter Unsicherheiten eignen sich probabilistische Methoden wie die Stochastische Programmierung (Buygi et al. 2006). Die Vor- und Nachteile des stochastischen Programms gegenüber dem deterministischen Programm werden in Birge (1982) umfassend diskutiert. Weitere stochastische Optimie-

rungsverfahren stellen die Stochastische Dynamische Programmierung (SDP) und die Approximative Dynamische Programmierung (ADP) dar.

Für ungewisse Parameter lässt sich die Robuste Optimierung prinzipiell verwenden. Neben der Ausrichtung auf den Worst Case können auch andere Optimierungskriterien berücksichtigt werden: Mit der Regret-Minimierung wird das nachträgliche Bedauern einer Entscheidung mit ungewissen Parametern minimiert. Alternativ kann (unscharfe) Fuzzy Programmierung bei ungewissen Parametern angewendet werden, wenn bestimmte Restriktionen nur zu einem gewissen Grad erfüllt werden müssen.

Im Bereich dezentraler Energiesysteme lassen sich kaum Programme finden, die tatsächlich Investitions- und Einsatzplanung unter Unsicherheiten optimieren. Die Arbeit von Mavromatidis et al. (2017) bildet mit dem stochastischen Programm eines Schweizer Bürogebäudes die Ausnahme. Dort wird die Relevanz der Berücksichtigung von Unsicherheiten bei der Gestaltung dezentraler Energiesysteme hervorgehoben. Gleichzeitig werden die rechentechnischen Herausforderungen der Optimierung eines dezentralen Energiesystems unter Unsicherheiten deutlich.

Tab. 5.2: Optimierungsverfahren zur Investitions- und Einsatzplanung unter Berücksichtigung von Unsicherheiten (Seite 1 von 2).

Optimierungsverfahren	Grundidee	Anwendungsbeispiele in der Energiewirtschaft Quelle	unsichere Daten
1) Stochastische Programmierung (siehe Abschnitt 4.3.2)	Optimierung der erwarteten Kosten unter Verwendung von Wahrscheinlichkeitsverteilungen unsicherer Parameter (in einem einstufigen, zwei- oder mehrstufigen Programm)	Göbelts (2001), Fichtner (2005)	Nachfrageentwicklung, Primärenergieträgerpreise, umweltspezif. Restriktionen (Emissionsvorgaben)
2) Robuste stochastische Programmierung (Mulvey et al. 1995)	Optimierung der erwarteten Kosten unter Verwendung von Wahrscheinlichkeitsverteilungen unsicherer Parameter und Risikopräferenzen des Entscheiders durch ein gewichtetes Streumaß	Fügenschuh(2014), MINLP für Netzplanungsprobleme in Koch et al. (2015) entbündelten liberalisierten Gasmärkten Mavromatidis (2017) Optimale Auslegung und Betriebsführung eines Bürogebäudes mit PV, Speicher sowie KWK- und Power-to-Heat-Applikation	reservierte Kapazitäten im Gasnetz Energienachfrage, PV-Angebot
3) Stochastische Dynamische Programmierung (Putermann 2005)	Stufenweise Zerlegung mehrstufiger stochastischer Programme nach dem Bellmann-Prinzip und rekursive Berechnung einer Wertfunktion (Wert eines Zustands zzgl. erw. Folgekosten/-gewinne) für jede Stufe unter Verwendung der Lösung aller nachfolgenden Teilprobleme, bis das gesamte Problem gelöst ist	Malcolm u. Zenios (1994) Ausbauplanung eines Energiesystems Epe et al. (2009) Kostenminderung der Stromversorgung durch Entkopplung von Angebot und Nachfrage mittels Energiespeicher Xi et al. (2012) Ko-Optimierung des Betriebs verteilter, elektrischer Energiespeicher Keles (2013) Investitionsbewertung eines Druckluftspeichers und Pumpspeicherkraftwerks in Kombination mit einer Windenergieanlage am Energiemarkt	Energienachfrage Strompreise, Windenergie
4) Approximative Dynamische Programmierung (Powell 2009; Bertsekas 2012)	Ähnlich wie Stochastische Dynamische Programmierung, jedoch mit reduzierten Rechenzeiten durch Approximation der Wertfunktionen anhand lernender Verfahren	Gönsch u. Hassler (2016) optimaler Betrieb zur Vermarktung erneuerbarer Energien eines Energieversorgers	Energienachfrage, Preise für Regelleist./-energie, Stromausfall Strompreise, Windenergie
4) Chance-Constrained Programming (Shapiro et al. 2009)	Optimierung der erw. Kosten unter Verwendung von Wahrscheinlichkeitsverteilungen unsicherer Parameter und dem Zulassen von Restriktionsverletzungen (Konfidenzniveau) mit einem Strafterm	Mazadi et al. (2009) Investitions- und Produktionsprogrammplanung von Energieversorgungsunternehmen	PV-Angebot und Windenergie Energienachfrage

Berücksichtigung von Risiko

Tab. 5.2: Optimierungsverfahren zur Investitions- und Einsatzplanung unter Berücksichtigung von Unsicherheiten (Seite 1 von 2).

Optimierungsverfahren	Grundidee	Anwendungsbeispiel in der Energiewirtschaft Quelle	unsichere Daten
5) Robuste Optimierung (siehe Abschnitt 4.3.3)	Lösung gesucht, die für alle unsicheren Daten realisierbar ist und im schlechtesten Fall (Worst Case) optimal ist (Kompromisse zwischen Worst und Best Case durch Hurwicz-Regel möglich)	Hajimiriagha et al. (2011) Integration von Plug-in-Hybrid-Elektrofahrzeugen in das Stromnetz in Ontario bis 2025	Strompreise, Wachstumsrate des PKW-Kraftstoffverbrauchs
Angepasste Robuste Optimierung (Ben-Tal et al. 2009)	Worst-Case-Optimierung, aber wie bei der Stochastischen Programmierung werden "Here-and-Now"- und „Wait-and-See“-Entscheidungen getroffen, so dass die Betriebsoptimierung individuell erfolgt	Jiang et al. (2012) Robuste Einsatzplanung von thermischen Kraftwerken, Windenergieanlagen und Pumpspeichern	Windenergie
Regret-Minimierung (siehe Abschnitt 4.3.4)	Lösung gesucht, die den maximalen Regret (Reue) des Entscheiders minimiert	Mejia-Giraldo (2013) Ausbauplanung der Erzeugungskapazität von Energiesystemen	Anschaffungskosten, Energienachfrage, Primärenergie-trägerpreise, Übertragungs-kapazität, umweltpolit. Restriktionen, Volllaststunden
(unscharfe) Fuzzy Programmierung (Lodwick u. Kacprzyk 2010; Tang et al. 2004)	unsichere Parameter und Restriktionen werden als Fuzzy-Zahlen bzw. -Sets behandelt. Restriktionen müssen nur zu einem gewissen Grad erfüllt werden (definiert über die Zugehörigkeitsfunktion)	Dong et al. (2011) Ausbau- und Einsatzplanung eines Energiesystems	Anschaffungskosten, Wirkungs-grad, Stromerzeugung fossiler und erneuerbarer Kraftwerke
Stochastische Programmierung mit übergeordneter Regret-Minimierung (siehe Kapitel 5) und Risiko	Stochastische Programmierung von risikobehafteten Parameter mit einer übergeordneten Regret-Minimierung zur Berücksichtigung von ungewissen Parametern	Yan u. Luh (1997) Einsatzplanung von thermischen Kraftwerken eines Energieversorgers mit Kauftransaktionen Urbina u. Li (2006) Betrieb einer PV-Anlage mit elektrischem Speicher (vorliegende Arbeit) Optimale Auslegung und Betriebsführung eines Wohnquartiers mit einer PV-Anlage, Speichern und Wärmepumpen als Power-to-Heat-Applikation	Energienachfrage, Reservebedarf, Preise zukünftiger Kauftransaktionen PV-Angebot ungewiss: Kapitalzinsen, Strompreise und -tarife; risikobehaftet: Energienachfrage, PV-Angebot sowie Wärmepumpen-leistung u. -wirkungsgrad (unter Berücksichtigung der Korrelationen)

5.3 Verwendete Optimierungsverfahren zur Berücksichtigung von Unsicherheiten und deren rechentechnische Herausforderungen

Zur Berücksichtigung von Risiken (Unsicherheiten, die sich mit Wahrscheinlichkeitsverteilungen abbilden lassen) in der Investitions- und Einsatzplanungsoptimierung dezentraler Energiesysteme wird ein zweistufiges stochastisches lineares Programm verwendet. Ohne Ganzzahligkeitsbedingungen sind solche konvexen Programme gut erforscht und eine Reihe von Lösungsalgorithmen vorhanden (siehe Ruszczynski 1999; Schultz 2003). Die meisten dieser Algorithmen verwenden eine Form der Benders-Dekomposition. Dieses Verfahren wurde erstmals in stochastischen Programmen von van Slyke und Wets (1969) als sogenannte L-Shaped-Methode angewendet.³²

In der Realität basieren viele Entscheidungen auf einer nicht kontinuierlichen Handlungsauswahl. Deren Abbildung mittels ganzer Zahlen führt zu der Herausforderung, dass Konvexitätsbedingungen nicht mehr allgemeingültig gegeben sind (Schultz 2003). Für bedeutende Ergebnisse auf diesem Gebiet sei auch auf Haneveld und van der Vlerk (1999) verwiesen.

Birge und Louveaux (1997) haben ein Branch-and-Cut-Verfahren mit der L-Shaped-Methode für die einfachste Form des zweistufigen SMILP vorgestellt: reine binäre Erststufen- und kontinuierliche Zweitstufen-Variablen. Für die herausforderndste Klasse, mit ganzzahligen und kontinuierlichen Variablen in beiden Stufen sowie unsicheren Parametern im gesamten Programm können nur wenige Algorithmen in der Literatur gefunden werden. Denn wenn ganzzahlige Variablen in der zweiten Stufe involviert sind, kann die L-Shaped-Methode, die konvexe Subprobleme voraussetzt, nicht direkt angewendet werden. Einen umfassenden Einblick hierzu geben Escudero et al. (2010).

Carøe und Tind (1998) und Carøe und Schultz (1999) stellten eine generalisierte L-Shaped-Methode für Modelle vor, die ganzzahlige Variablen in der zweiten Stufe und nur wenige kontinuierliche oder diskrete Erststufen-Variablen enthalten. Die Dual-Dekompositionsmethode verwendet die Lagrange-Relaxierung, um passende Schranken für die Zielfunktion zu erhalten. Für eine sehr große Anzahl gemischt-ganzzahliger Variablen in beiden Stufen haben Nürnberg und Römisch (2002) SDP verwendet. Serali und Fraticelli (2002), Sen und Serali (2006) und Zhu (2006) haben eine Branch-and-Cut-Dekomposition mit einer modifizierten L-Shaped-Methode entwickelt, bei der eine

³² Die L-Shaped-Methode ist eine spezielle Anwendung der Benders-Dekomposition in stochastischen Programmen. Die Hauptidee besteht in der Approximation der Rekursfunktion in der Zielfunktion, sprich der Lösung aller Programme der zweiten Stufe mit Rekurs.

Kombination aus Relaxierung und einem speziellen Konvexifikationsschema (*Reformulation Linearization Technique*) Anwendung findet. Das Verfahren wurde durch eine Benders-Dekomposition in der ersten Stufe und einen stochastischen Branch-and-Cut-Algorithmus in der zweiten Stufe von Yuan und Sen (2009) und Sherali und Smith (2009) weiterentwickelt. Parallel dazu haben Alonso-Ayuso et al. (2003) eine Branch-and-Fix-Koordinationsmethodik eingeführt. Der Hauptunterschied zum üblichen Branch-and-Bound ist die Bewertung vieler Subprobleme im Suchbaum: Die Entscheidung zur Verzweigung, Beschneidung oder Beschränkung hängt in jedem Suchschritt von allen Subproblemen ab. Dieses Verfahren wurde kontinuierlich verbessert und verwendet derzeit ein Twin-Node-Family-Konzept in Kombination mit Benders-Dekomposition und paralleler Berechnung für kontinuierliche und binäre Variablen in beiden Stufen (Alonso-Ayuso et al. 2005; Escudero et al. 2007; Escudero et al. 2010; Pagès-Bernaus et al. 2015).

Neben diesen exakten Algorithmen für SMILP existieren mehrere heuristische Verfahren. Beispielsweise schlagen Till et al. (2007) einen hybriden Algorithmus vor, der zweistufige SMILP mit ganzzahligen und kontinuierlichen Variablen in beiden Stufen löst. Basierend auf einer Stufen-Dekomposition werden Subprobleme der zweiten Stufe mithilfe eines kommerziellen MILP-Solvers gelöst. Die Suche der Erststufen-Variablen wird durch einen evolutionären Algorithmus realisiert. Dieses heuristische Verfahren ist, ebenso wie die aufgeführten Verfahren, bei komplexen Programmen mit extrem hohem Rechenaufwand je Iterationsschritt praktisch nicht anwendbar, insbesondere wenn ganze Zahlen in der zweiten Stufe involviert sind.

Zur Berücksichtigung von Ungewissheiten (Unsicherheiten, bei denen die möglichen Ereignisse, nicht aber deren Eintrittswahrscheinlichkeiten bekannt sind) wird die Regret-Minimierung als eine erweiterte Form der Robusten Optimierung verwendet. Generell hat die Robuste Optimierung den Vorteil, dass Wahrscheinlichkeitsverteilungen nicht bekannt sein müssen und sich Ungewissheiten somit berücksichtigen lassen. Aus optimierungstechnischer Sicht kommt hinzu, dass das Programm im Vergleich zu mehrstufigen stochastischen Programmen nur eine robuste Lösung für alle Stufen besitzt (Bent et al. 2009). Da es für jede Stufe nur eine mögliche Ausführung der verschiedenen Entscheidungsvariablen gibt, sind die Rechenanforderungen für das Programme geringer. Des Weiteren lässt sich der Rechenaufwand durch spezielle Verfahren erheblich reduzieren (siehe z. B. Wittmann-Hohlbein und Pistikopoulos 2011). Einen aktuellen, gesammelten Überblick in die Robuste Optimierung und deren Anwendungen bieten Delage und Iancu (2016).

Nachteil der Robusten Optimierung des Worst Case ist die extrem pessimistische Sicht, die für den ökonomisch motivierten Anwender in vielen Fällen unbefriedigend sein kann. Diesen Nachteil der Minimierung des maximalen Risikos haben auch Haskell et al. (2016) in ihrer Arbeit „*Ambiguity in risk preferences in robust stochastic optimization*“ bemängelt und schlagen vor, die Risikopräferenz des Entscheiders bei der Optimierung zu berücksichtigen. Alternativ kann die Robuste Optimierung durch die Regret-Minimierung erweitert werden. Hier wird neben dem Worst Case auch ein Bezug zum Best Case hergestellt (siehe Abschnitt 4.4.4). In vorliegender Arbeit wird die Regret-Minimierung nach Savage (1951) genutzt. Sie wird häufig in anderen Arbeiten zur Berücksichtigung von Unsicherheiten verwendet (Mejia-Giraldo 2013; Pereira et al. 2000).

Die Betrachtung der stochastischen Programmierung und der Regret-Minimierung zur Berücksichtigung von Risiken und Ungewissheiten ist in der Literatur, von wenigen Ausnahmen abgesehen, nicht auffindbar. Philpott et al. (2010) haben sowohl das Prinzip der Stochastischen Programmierung als auch der Regret-Minimierung dargelegt, jedoch die Kombination beider Techniken nicht erwähnt. Für die Problemstellung der vorliegenden Arbeit wird ein stochastisches Programm verwendet, wenn die Wahrscheinlichkeitsverteilungen unsicherer Parameter bekannt sind bzw. sich adäquat abbilden lassen. Ungewisse Parameter werden mit einer übergeordneten Regret-Minimierung berücksichtigt, um im Sinne des privaten Entscheiders auf den Worst und Best Case Bezug zu nehmen. Das gesamte Konzept zur Berücksichtigung der Unsicherheiten sowie die Methodik zur Bewältigung der rechentechnischen Herausforderungen werden in den folgenden Kapiteln 6 und 7 dargelegt.

6 Methodik zur Berücksichtigung von Unsicherheiten

Grundsätzlich lassen sich die für die Optimierung dezentraler Energiesysteme benötigten Daten nicht immer exakt vorhersagen. Bei der Bereitstellung einzelner Daten ist es nicht nur wichtig, deren Unsicherheiten mit abzubilden, sondern zur Erlangung einer möglichst hohen Konsistenz bei der Datengenerierung auch die Abhängigkeiten untereinander adäquat zu erfassen. Insbesondere haben meteorologische Parameter einen großen Einfluss auf die Energieangebot und -nachfrage dezentraler Energiesysteme. Deswegen wird ein umfassendes Konzept verwendet, in dem mit Risiko behaftete, wetterabhängige Unsicherheiten konsistent durch die Modellierungskette erfasst und bis zur Optimierung übergeben werden. Das Konzept besteht aus den drei Ebenen (Abb. 6.1):

- a) Input,
- b) Transformation und
- c) Optimierung.

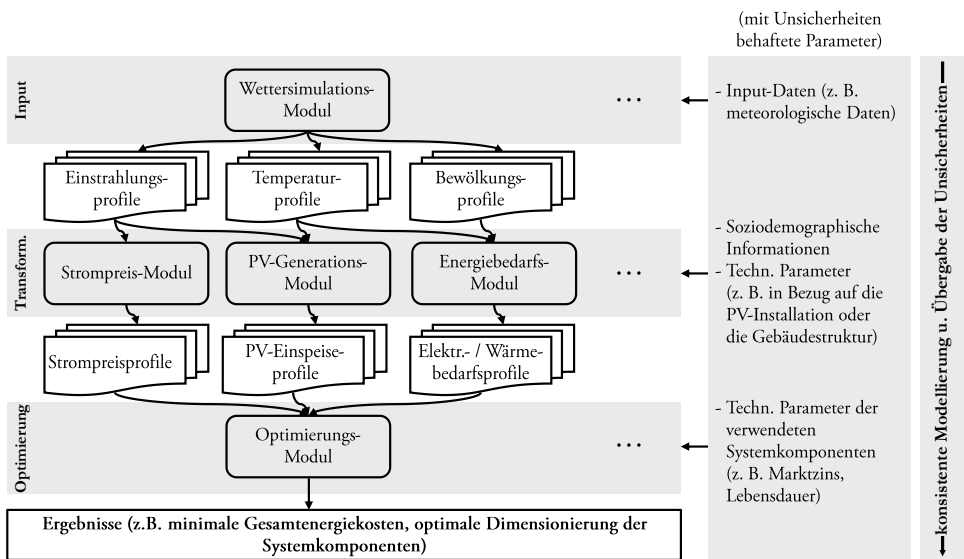


Abb. 6.1: Konzept zur Generierung der Inputdaten für die Optimierung unter Berücksichtigung von Unsicherheiten (in Anlehnung an Bertsch et al. 2014; Schwarz et al. 2018a).

Das Konzept basiert im Wesentlichen auf Bertsch et al. (2014) und wurde in Schwarz et al. (2018b) um ein Strompreis-Modul sowie die Option eines elektrischen Speichers erweitert. Beginnend mit der Generierung konsistenter Profile meteorologischer Inputparameter werden die assoziierten Unsicherheiten unter Beachtung ihrer probabilistischen Eigenschaften (Abschnitt 6.1) berücksichtigt. Diese Profile werden in der Transformationsebene in Energieangebot und -nachfrage sowie Preisprofile weiterverarbeitet (Abschnitt 6.2), die für die Optimierungsebene benötigt werden (Abschnitt 6.3).

6.1 Inputebene mit Wettersimulations-Modul

Ziel der Datenbereitstellung ist es, entscheidungsrelevante Parameter für die Optimierung möglichst gut abzubilden. Dabei sollen die fluktuierenden und stochastischen Eigenschaften sowie deren Wechselwirkungen untereinander mit einbezogen werden. Die Investitions- und Einsatzplanungsoptimierung dezentraler Energiesysteme erfordert die Berücksichtigung sowohl kurzfristiger als auch langfristiger Schwankungen und Unsicherheiten bei der Simulation der Inputprofile.

Beispielsweise können "gute" und "schlechte" Sonnenjahre die optimale Wahl geeigneter Kapazitäten der Energiesystemkomponenten beeinflussen. Neben dem Angebot dezentraler Energiesysteme wird auch die Nachfrageseite durch das Wetter bedingt. Daher müssen Abhängigkeiten zwischen meteorologischen Daten sowie Angebots- und Nachfrageprofilen mit berücksichtigt werden. Eine unabhängige stochastische Simulation der Profile wäre nicht sinnvoll. So hängt die Stromerzeugung aus Photovoltaikmodulen nicht nur von der Globalstrahlung, sondern auch von der Temperatur ab, die den Wirkungsgrad der Module beeinflusst. Außerdem wird der Wärmebedarf durch Temperatur und Bewölkung bedingt.

Für die Fallstudie der vorliegenden Arbeit werden Bewölkungsgrad, (horizontale) Globalstrahlung und die (Außenluft-)Temperatur unter Berücksichtigung deren Wechselwirkungen untereinander generiert. Hierbei werden kurzfristige und langfristige Variationen, z. B. einstrahlungsreiche und -arme Solarjahre, eingebunden, die einen Einfluss auf die optimale Dimensionierung der Systemkomponenten und deren optimale Betriebsführung haben.

Die stochastische Charakterisierung der Globalstrahlung und anderer meteorologischer Parameter wurde in der Literatur intensiv untersucht. Generell können bestehende Verfahren zur stochastischen Simulation von meteorologischen Parametern in zwei Gruppen unterteilt werden. Die erste Gruppe beinhaltet Regressionsmodelle, bei denen

Wahrscheinlichkeitsverteilungsfunktionen auf Basis von Beobachtungen geschätzt werden (siehe z. B. Diagne et al. 2013). Die zweite Gruppe umfasst Markov-Prozesse, bei denen die Wahrscheinlichkeiten zukünftiger Zustände, die von vergangenen Realisationen abhängen, mittels Übergangswahrscheinlichkeits-Matrizen abgebildet werden. So verwenden Amato et al. (1986) einen Markov-Prozess, um langzeitige Variationen der täglichen Globalstrahlung zu simulieren. Ehnberg und Bollen (2005) verwenden Beobachtungen der Bewölkung in Drei-Stunden-Intervallen. Morf (1998) hingegen legt einen stärkeren Fokus auf kurzzeitige Variationen und nutzt einen Markov-Prozess zur Simulation dynamischer Verläufe der Globalstrahlung. Markov-Prozesse eignen sich grundsätzlich sehr gut, Wechselwirkungen zwischen Bewölkung, Temperatur und Solarstrahlung mitzuberechnen und genügen somit der oben genannten Anforderung an die Datengenerierung (Schwarz et al. 2018a).

Die Simulation der benötigten meteorologischen Inputdaten basiert auf Ehnberg und Bollen (2005) mit einer Erweiterung des Markov-Prozesses um saisonalen Informationen: Für jeden Monat werden eigene Übergangswahrscheinlichkeits-Matrizen gebildet. Neben Bewölkungsgrad und Globalstrahlung werden dazu konsistent passende Temperaturprofile simuliert. Mit dem Ziel, lang- und kurzzeitige Variationen zu berücksichtigen, erfolgt die Simulation der Wetterdaten in *zwei Schritten*.

Im ersten Schritt wird mithilfe eines Markov-Prozesses der tägliche Bewölkungsgrad in Oktas $\zeta \in \{0, \dots, 8\}$ modelliert, um langzeitige Variationen zu berücksichtigen. Die Maßeinheit Okta beschreibt den Bedeckungsgrad des Himmel, wobei ein vollständig klarer Himmel $\zeta = 0$ und eine vollständig bewölkter Himmel $\zeta = 8$ entspricht (Jones 1992). Die Übergangswahrscheinlichkeits-Matrix $\underline{\theta}_\zeta^m$ für den Bewölkungsgrad ζ und den Monat m des Markov-Prozesses ist:

$$\underline{\theta}_\zeta^m = \begin{pmatrix} \pi_{00}^{\zeta,m} & \dots & \pi_{08}^{\zeta,m} \\ \vdots & \ddots & \vdots \\ \pi_{80}^{\zeta,m} & \dots & \pi_{88}^{\zeta,m} \end{pmatrix}. \quad (6.1)$$

Die Übergangswahrscheinlichkeiten $\pi_{ij}^{\zeta,m}$ in Gleichung (6.1) sind von öffentlich erhältlichen Wetterdaten des DWD abgeleitet, welche für viele deutsche Standorte über mehrere Dekaden, in der Regel 50 Jahre oder mehr, verfügbar sind.³³ Für die Übergangswahrscheinlichkeit $\pi_{ij}^{\zeta,m}$ des Monats m gilt die bedingte Wahrscheinlichkeit, dass der Bewölkungsgrad ζ_δ am Tag δ gleich j ist, mit der Kenntnis, dass der Bewölkungsgrad $\zeta_{\delta-1}$ am Tag $\delta - 1$ gleich i war:

³³ In vorliegender Arbeit werden die Daten der DWD-Wetterstation in Karlsruhe mit der Stations-ID 2522 und den entsprechenden Koordinaten *Breitengrad* = 49.0382 und *Längengrad* = 8.3641 verwendet.

$$\pi_{ij}^{\zeta,m} = P(\zeta_\delta = j \mid \zeta_{\delta-1} = i); \sum_j \pi_{ij}^{\zeta,m} = 1 \quad \forall m \forall i. \quad (6.2)$$

Der auf den Übergangswahrscheinlichkeiten basierende Markov-Prozess für den Bewölkungsgrad ist dann:

$$\zeta_\delta = f(\zeta_{\delta-1}, \varepsilon), \quad (6.3)$$

wobei ε eine gleichverteilte Zufallsvariable im Bereich $[0,1]$ ist. Der Markov-Prozess wird gemäß folgender Gleichung operationalisiert, indem der Bewölkungsgrad ζ_δ durch die Realisation ξ von ε ermittelt wird:

$$\zeta_\delta = \begin{cases} 0 & \text{für } \xi \in [0, \pi_{\zeta_{\delta-1}0}^{\zeta,m}[, \\ 1 & \text{für } \xi \in [\pi_{\zeta_{\delta-1}0}^{\zeta,m}, \sum_{j=0}^1 \pi_{\zeta_{\delta-1}j}^{\zeta,m}[, \\ \vdots \\ 8 & \text{für } \xi \in [\sum_{j=0}^7 \pi_{\zeta_{\delta-1}j}^{\zeta,m}, 1]. \end{cases} \quad (6.4)$$

Höhere (niedrigere) Übergangswahrscheinlichkeiten $\pi_{ij}^{\zeta,m}$ vergrößern das betreffende Intervall; so ist z. B. die Wahrscheinlichkeit eines klaren Himmels am Tag δ bei klarem Himmel am vorherigen Tag $\delta - 1$ im Juni relativ hoch, jedoch im Dezember gering. Gemäß der Realisation ξ einer gleichverteilten Zufallsvariable folgt eine höhere (niedrigere) Wahrscheinlichkeit der entsprechenden Bewölkung am Tag δ .

Für die Simulation der täglichen Globalstrahlung wird ein zusätzlicher Markov-Prozess auf Basis des Bewölkungsgrads verwendet. Die Übergangswahrscheinlichkeiten der zugehörigen Übergangswahrscheinlichkeitsmatrix $\underline{\theta}_\rho^{m,\zeta}$ mit der Globalstrahlung ρ_δ am Tag δ ist eine Funktion von Monat m , Bewölkungsgrad ζ_δ am Tag δ und Globalstrahlung $\rho_{\delta-1}$ am Tag $\delta - 1$:

$$\pi_{kl}^{\rho,m,j} = P(\rho_\delta = l \mid \rho_{\delta-1} = k \cap \zeta_\delta = j); \sum_l \pi_{kl}^{\rho,m,j} = 1 \quad \forall m \forall j \forall k. \quad (6.5)$$

Auf die gleiche Weise werden die Werte für durchschnittliche Tagestemperaturen ermittelt. Die Ausgangswerte der Markov-Prozesse können beliebig gewählt werden, da der Einfluss langfristig vernachlässigbar ist. Insgesamt zeigen die Übergangswahrscheinlichkeiten auf monatlicher statt auf jährlicher Basis eine höhere Genauigkeit.

Im zweiten Schritt werden Profile mit einer 15-min-Auflösung basierend auf den simulierten täglichen Werten (von Schritt 1) mithilfe eines separaten stochastischen Prozesses erzeugt. Dieser zweite Schritt trägt den kurzfristigen stochastischen Schwankungen

Rechnung, die vom Zustand der Atmosphäre, z. B. der Bewölkung, abhängen. Sie werden durch einen empirisch ermittelten, statistisch variierenden Term unter der Bedingung generiert, die vorgegebene tägliche Globalstrahlung (ermittelt in Schritt 1) zu erreichen.³⁴ Der im Wettersimulations-Modul implementierte Markov-Prozess erzeugt Zeitreihen der erforderlichen Inputparameter (Globalstrahlung, Temperatur und Bewölkungsgrad) für die folgende Ebene und wird solange wiederholt, bis eine vordefinierte Anzahl an Szenarien $\omega \in \{1, \dots, N\}$ generiert ist ($N = 100$ in der Fallstudie in Kapitel 8).

Zur Validierung des Simulationsansatzes wurden die Ergebnisse mit den historischen Wetterdaten des Deutschen Wetterdienstes anhand von kurz- und langfristigen Leistungsindikatoren verglichen. Für die Zeitreihen des Strahlungsangebots umfasst die Validierung beispielsweise einen Vergleich der gesamten jährlichen Strahlungsenergie sowie eine Reihe weiterer Indikatoren auf Basis von Schermeyer et al. (2015). Weitere Einzelheiten finden sich in Anhang A.

6.2 Transformationsebene

In der Transformationsebene wird die Ausgabe der Inputebene (ein Bündel simulierter Globalstrahlungs-, Temperatur- und Bewölkungsprofile) in die für die Optimierung benötigten Daten umgewandelt. Für die Investitions- und Einsatzplanungsoptimierung des Wohnquartiers werden elektrischer und thermischer Bedarf, PV-Angebot und Elektrizitätspreise benötigt, die anhand der meteorologischen Daten der Inputebene abgeleitet werden. Der gesamte Generierungsprozess der für die Optimierung benötigten Daten ist in Abb. 6.2 zusammengefasst dargestellt. Zur Erzeugung der benötigten PV-Einspeiseprofile, Elektrizitäts- und Wärmebedarfsprofile sowie Strompreisprofile in 15-min-Auflösung wurden spezielle Module entwickelt, die in den folgenden Abschnitten einzeln vorgestellt werden.

³⁴ Für den separaten stochastischen Prozess mit 15-min-Auflösung werden Messreihen der Wetterstation des Physikhochhauses am Campus-Süd des KIT verwendet (IMK (2018)).

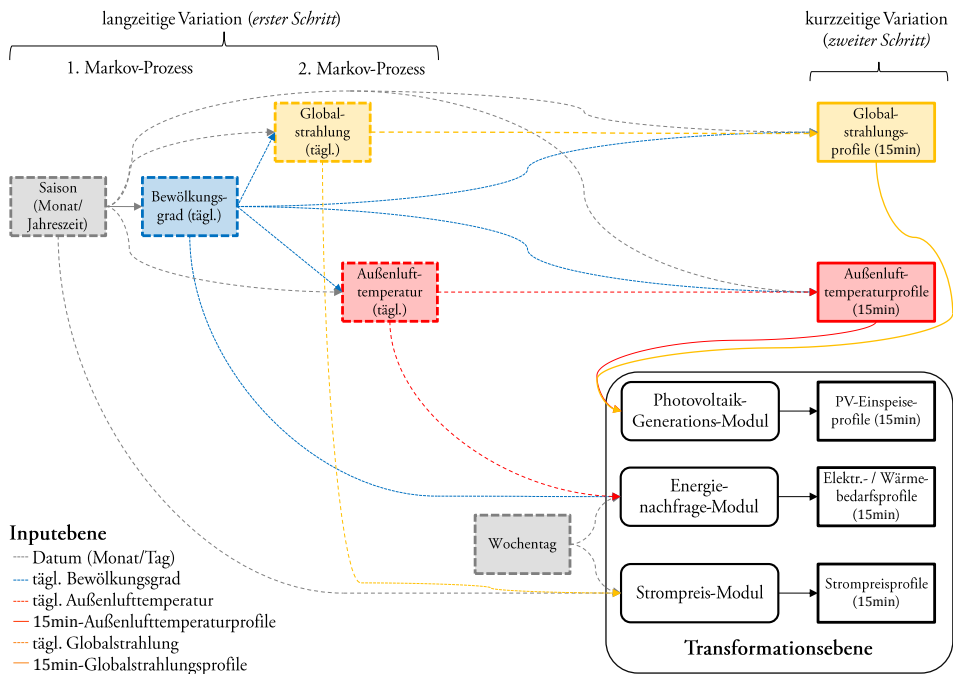


Abb. 6.2: Generierungsprozess der Inputdaten für die Optimierung eines Wohnquartiers (in Kapitel 8).

6.2.1 Photovoltaik-Generations-Modul

Die Transformation meteorologischer Daten in PV-Einspeisepprofile erfolgt mithilfe des physikalischen Modells nach Ritzenhoff (2006). Es beschreibt die Abhängigkeiten des elektrischen Ertrags vom einfallenden Licht, der PV-Moduleffizienz sowie der Ausrichtung und Kapazität (Nennleistung) der PV-Anlage. Dabei sind Schwachlichtverhalten, Temperaturabhängigkeiten und ein genereller Wirkungsgradverlust durch Modul-Mismatch sowie Wechselrichter- und Leitungsverluste integriert. Die von der Inputebene bereitgestellten (horizontalen) Globalstrahlungsprofile werden auf der Basis von Liu und Jordan (1960) in direkte und diffuse Einstrahlung aufgeteilt und auf die geneigte Fläche der PV-Anlage umgerechnet. In Verbindung mit der Temperatur werden akkurate PV-Einspeisepprofile für die Optimierungsebene bestimmt. Die spezifischen Anlagenparameter entsprechen der in Abschnitt 3.1.1 vorgestellten PV-Anlage.

6.2.2 Energiebedarfs-Modul

Das Energiebedarfs-Modul stellt Elektrizitätsbedarfsprofile sowie Wärmebedarfsprofile für Raumwärme (RM) und Warmwasser (WW) bereit. Hierfür ist ein Referenzlastprofil-Verfahren implementiert, das die Temperatur und die Bewölkung der Inputebene sowie Parameter wie Wochentag, Jahreszeit, Dämmung und Anzahl der Bewohner (bei Einfamilienhäusern) bzw. Wohneinheiten (bei Mehrfamilienhäusern) berücksichtigt. Das Verfahren basiert auf der VDI-Richtlinie 4655 (VDI 2008). Als Anwendungsbereich werden Einfamilienhäuser mit bis zu zwölf Personen und Mehrfamilienhäuser mit bis zu 40 Wohneinheiten empfohlen. Für einen genaueren, anwendungsfallbezogenen Elektrizitäts- und Wärmebedarf werden die Referenzlastprofile mit einem monatlichen Skalierungsfaktor auf Messreihen einer vergleichbaren Bewohnergruppe angepasst.³⁵ Um die Interdependenzen von Temperatur und Bewölkung bei der Transformation zu Energielastprofilen adäquat einzubinden, werden zudem für die Typtage-Bestimmung statt der Testreferenzjahre des DWD die generierten meteorologischen Daten der Inputebene verwendet. Abb. 6.3 zeigt beispielhaft die 15-min-PV-Angebots- und Energienachfrageprofile eines Wohnquartiers für einen typischen, sonnigen Sonntag im Herbst. Neben dem PV-Angebot kann zusätzlich elektrische Energie von einem externen Energieversorger bezogen werden. Der thermische Energiebedarf für Raum- und Warmwasser wird hingegen ausschließlich durch die Wärmepumpen und Heizelemente in Verbindung mit den Wärmespeichern gedeckt.




Abb. 6.3: PV-Angebot und Energienachfrage eines Wohnquartiers an einem typischen sonnigen Sonntag im Spätherbst (Schwarz et al. 2018a).

³⁵ Die monatlichen Energieverbräuche sind auf Messreihen von Bewohnern skaliert, die zu Kunden der *evohaus GmbH* gehören und die merklich weniger Energie als in den Richtlinien angegeben verbrauchen.

Speziell für die Modellierung des Elektrizitätsbedarfs werden H0-Referenzlastprofile verwendet. Diese weisen, auch bei einer relativ geringen Anzahl von Haushalten, eine starke Konvergenz gegenüber aggregierten Haushaltslasten auf (ausführliche Informationen siehe Anhang A, u.a. Tab. A.3). Die H0-Referenzlastprofile mit 15-min-Auflösung werden nach Meier et al. (1999) in Abhängigkeit von Wochentag und Jahreszeit erstellt und auf den temperatur- und bewölkungsgradabhängigen täglichen Elektrizitätsbedarf gemäß VDI 4655 skaliert.

6.2.3 Strompreis-Modul

In Deutschland werden für Wohnquartiere vereinzelt Tarife mit dynamischen Strompreisen eingeführt. Dabei besteht die Möglichkeit, Elektrizität zum GH-Preis plus diverser Steuern und Abgaben zu beziehen. Umgekehrt ist auch der Verkauf zum GH-Preis möglich, z. B. von eingespeicherter elektrischer Energie oder auch von PV-Energie, die nicht zum festen Einspeisetarif veräußert wird. Während Steuern und Abgaben einen festen Anteil am Gesamtpreis haben und in der Regel nur langfristig durch den Gesetzgeber angepasst werden, unterliegt der GH-Preis gewissen kurzfristigen Schwankungen. Ein wesentlicher Einfluss auf den Marktpreis ist unter anderem die wetterabhängige Energiebereitstellung erneuerbarer Energien innerhalb des deutschen Strommarkts. Für die vorliegende Arbeit werden daher dynamische GH-Preise als Funktion der simulierten meteorologischen Daten gemäß Schwarz et al. (2018b) abgeleitet. Hierzu werden historische Day-ahead-Preise des PHELIX-Spotmarkts der EPEX, dem primären Marktplatz für Elektrizitätshandel in Deutschland, der Jahre 2012-2015 sowie aggregierte tägliche Globalstrahlungswerte von Anemos (2016) derselben Jahre verwendet.³⁶ Mithilfe der täglichen Preisprofile und der kongruenten täglichen Globalstrahlung erfolgt eine Unterteilung der Preisprofile in 60 Klassen anhand der folgenden drei Dimensionen:

- tägliche Globalstrahlung in Wh/m²: Die Beobachtungen über die vier Jahre sind in fünf Klassen eingeteilt, so dass die Anzahl der Beobachtungen je Klasse gleich groß ist (≤ 2050 Wh/m², ≤ 3736 Wh/m², ≤ 9056 Wh/m², ≤ 5424 Wh/m² und ≤ 6959 Wh/m²),

³⁶ Die Globalstrahlungswerte basieren auf dem NASA-Programm *Modern-Era Retrospective Analysis for Research and Applications* unter Anwendung des Mesoscale-Modells *MM5* (PSU/NCAR 2003). Es ist der nächste Standort zur Messstation in Karlsruhe ausgewählt, die auch für die Generierung der Globalstrahlungsprofile in der Inputebene verwendet wird. Mithilfe eines Korrekturfaktors wird die von Schermeyer et al. (2015) gefundene, systematische Überschätzung der Globalstrahlungswerte von Anemos (2016) berichtigt.

- Jahreszeit: Die beobachteten Preisprofile sind anhand der vier Jahreszeiten separiert, um saisonale Einflüsse auf den Strompreis zu berücksichtigen (z. B. die von Temperatur und Tageslichtlänge abhängige Elektrizitätsnachfrage),
- Typtag: Zur Berücksichtigung systematischer Unterschiede der Elektrizitätsnachfrage und -preise werden die Preisprofile nach Wochentag, Samstag und Sonntag differenziert.

Für die finale Generierung werden die erzeugten Wetterszenarien der Inputebene den 60 verschiedenen Klassen zugeordnet. Entsprechend der Klasse wird ein Preisprofil durch eine gleichverteilte Zufallsvariable ausgewählt. Ein Vergleich der simulierten GH-Preise vier zufällig ausgewählter Jahre mit historischen Preisen von 2012 bis 2015 zeigt eine sehr gute Übereinstimmung (siehe Anhang A).

Für die Erstellung dynamischer Arbeitspreise für den Elektrizitätsbezug werden alle Steuern und Abgaben einschließlich der Mehrwertsteuer sowie die Vertriebsprovisionen des Energieversorgers zu den GH-Preisen addiert (siehe Abschnitt 2.1.4). Als Vertriebsprovision wird der Mittelwert von 2015 verwendet: Die im Arbeitspreis enthaltenen Kosten für Beschaffung und Vertrieb i. H. v. 7,12 ct_€/kWh_{el} abzüglich eines durchschnittlichen GH-Preises von 3,2 ct_€/kWh_{el} ergeben eine gemittelte Vertriebsprovision von 3,92 ct_€/kWh_{el}.

6.3 Optimierungsebene Θ -DES

Allgemein lässt sich die Optimierung dezentraler Energiesysteme als zweistufiges Programm darstellen, das aus der Optimierung der Investitions- und Einsatzplanung besteht. Es wird die in Abschnitt 4.1 vorgestellte Annuitätenmethode verwendet. Nach Gleichung (4.5) gilt für die Gesamtenergiekosten: $cost = ANF \cdot Inv + p_0^{grid} \cdot e_t^{grid}$. Für den Fall, dass Energie extern gehandelt werden kann, z. B. an einer Strombörse, ist die Minimierung von Energiebezug und -verkauf abhängig. Der Strompreis kann dabei auch von t abhängig sein. Es können risikobehaftete und ungewisse Unsicherheiten in der Optimierungsebene für dezentrale Energiesysteme (Θ -DES) berücksichtigt werden: Die Stochastische Programmierung wird mit einer übergeordneten Regret-Minimierung kombiniert, mit der das nachträgliche (erwartete) Bedauern einer Entscheidung minimiert wird. Das Optimierungsprogramm wird im folgenden Abschnitt 6.3.1 für dezentrale Energiesysteme allgemeingültig beschrieben und in Abschnitt 6.3.2 speziell für das Wohnquartier der Fallstudie mathematisch ausformuliert.

Das innere stochastische Programm wird nicht als stochastisch dynamisches Programm umgesetzt, da nur ein geringer Parallelisierungsgrad des stufenweisen Optimierungsprozesses möglich wäre. Alternativ könnte das innere Programm auch mit einer approximativen dynamischen Programmieretechnik umgesetzt werden, mit der gute Lösungen in verkürzten Zeiten erreicht werden können (eine ausführliche Einführung geben Powell 2009; Bertsekas 2012). Die Lösungen sind jedoch in der Regel nicht optimal und geben keinen Hinweis darauf, wie weit sie vom Optimum entfernt sind. Für ungewisse Parameter lässt sich die Robuste Optimierung prinzipiell verwenden. Jedoch erscheint die alleinige Ausrichtung auf den Worst Case nicht im Sinne des ökonomischen Entscheiders.

6.3.1 Allgemeine Zielfunktion und Restriktionen des Programms

Gemäß der Stochastischen Programmierung aus Abschnitt 4.4.2 ergeben sich die minimalen erwarteten Energiegesamtkosten $cost_\theta^*$ in Abhängigkeit von \mathbf{Inv}_θ und des Betriebs $\mathbf{B}_{t,u,\omega,\theta}$ für einen bestimmten Fall θ wie folgt:

$$\begin{aligned} \min_{\mathbf{Inv}_\theta, \mathbf{B}_{t,u,\omega,\theta}} \quad & ANF_\theta \cdot \mathbf{Inv}_\theta + \text{Wartung}_\theta(\mathbf{Inv}_\theta) + \text{Degradation}_\theta(\mathbf{Inv}_\theta) \\ & + \frac{1}{N} \sum_{\omega=1}^N \text{Betriebskosten}_{\omega,\theta}(\mathbf{B}_{t,u,\omega,\theta}), \end{aligned} \quad (6.6)$$

unter folgenden Restriktionen:

$$\begin{aligned} \text{Energieangebot}_{t,u,\omega,\theta}(\mathbf{Inv}_\theta, \mathbf{B}_{t,u,\omega,\theta}) \\ - \text{Energieeinspeisung}_{t,u,\omega,\theta}(\mathbf{Inv}_\theta, \mathbf{B}_{t,u,\omega,\theta}) = \text{Energienachfrage}_{t,u,\omega,\theta}(\mathbf{B}_{t,u,\omega,\theta}) \\ + \Delta \text{Speicher}_{t,u,\omega,\theta}(\mathbf{B}_{t,u,\omega,\theta}) \\ + \text{Systemverluste}_{t,u,\omega,\theta}(\mathbf{B}_{t,u,\omega,\theta}) \end{aligned} \quad (6.7)$$

$\forall t, \forall u, \forall \omega, \forall \theta,$

mit $t = \{0, \dots, T\}$ Zeitschritten, $u = \{\text{Elektrizität}, RW, WW, \dots\}$ Energieanwendungen, $\omega = \{1, \dots, N\}$ gleichwahrscheinlichen Szenarien und $\theta = \{1, \dots, \Theta\}$ Fällen. Für Speicher gilt:

$$\text{Speicherstand}_{t,u,\omega,\theta}(\mathbf{Inv}_\theta, \mathbf{B}_{t,u,\omega,\theta}) \leq \max. \text{Speicherstand}_{u,\theta}(\mathbf{Inv}_\theta) \quad \forall t, \forall u, \forall \omega, \forall \theta \quad (6.8)$$

$$\text{Speicherstand}_{t,u,\omega,\theta}(\mathbf{Inv}_\theta, \mathbf{B}_{t,u,\omega,\theta}) \geq \min. \text{Speicherstand}_{u,\theta}(\mathbf{Inv}_\theta) \quad \forall t, \forall u, \forall \omega, \forall \theta. \quad (6.9)$$

Für die Betrachtung einer geschlossenen Periode sollten alle Speicherstände des ersten und letzten Zeitschritts ($t = 0$ und $t = T$) auf Gleichheit beschränkt sein. Das Energieangebot der Speicher und anderer Energiesystemkomponenten kann limitiert sein mit:

$$\begin{aligned} & \text{Energieangebot}_{t,u,\omega,\theta}(\mathbf{Inv}_\theta, \mathbf{B}_{t,u,\omega,\theta}) \\ & \leq \max. \text{Energieangebot}_{t,u,\omega,\theta}(\mathbf{Inv}_\theta, \mathbf{B}_{t,u,\omega,\theta}) \quad \forall t, \forall u, \forall \omega, \forall \theta, \end{aligned} \quad (6.10)$$

und ggf.:

$$\begin{aligned} & \Delta \text{Energieangebot}_{t,u,\omega,\theta}(\mathbf{Inv}_\theta, \mathbf{B}_{t,u,\omega,\theta}) \\ & \leq \min./\max. \Delta \text{Energieangebot}_{t,u,\omega,\theta}(\mathbf{Inv}_\theta, \mathbf{B}_{t,u,\omega,\theta}) \quad \forall t, \forall u, \forall \omega, \forall \theta. \end{aligned} \quad (6.11)$$

Analog dazu kann auch der Speicher limitiert sein. Die (harten) Nebenbedingungen (6.7)–(6.11) können durch Hilfsvariablen auf der rechten Seite „aufgeweicht“ werden (weiche Nebenbedingungen). Diese fließen in die Zielfunktion in Form eines Bestrafungsterms ein.

Die Regret-Minimierung aller Fälle ergibt sich in Abhängigkeit von den fallspezifischen optimalen Investitionen \mathbf{Inv}_θ^* und θ (gemäß Abschnitt 4.4.4):

$$\min_{\mathbf{Inv}_\theta^*} \max_{\theta} (\text{regret} = \text{cost}_{\mathbf{Inv}_\theta, \theta} - \text{cost}_\theta^*), \quad (6.12)$$

wobei $\text{cost}_{\mathbf{Inv}_\theta, \theta}$ ist nach Gleichung (6.6):

$$\begin{aligned} \min_{\mathbf{B}_{t,u,\omega,\theta}} & \text{ANF}_\theta \cdot \mathbf{Inv}_\theta + \text{Wartung}_\theta(\mathbf{Inv}_\theta) + \text{Degradation}_\theta(\mathbf{Inv}_\theta) \\ & + \frac{1}{N} \sum_{\omega=1}^N \text{Betriebskosten}_{\omega,\theta}(\mathbf{B}_{t,u,\omega,\theta}). \end{aligned} \quad (6.13)$$

Die Lösung der Regret-Minimierung führt zu der Investition, die vom Entscheider im schlechtesten Fall θ am wenigsten bereit werden würde.

6.3.2 Investitions- und Einsatzplanung eines Wohnquartiers

In der folgenden Abb. 6.4 ist der Energiefluss des Wohnquartiers schematisch skizziert, das in der Fallstudie in Kapitel 8 betrachtet wird. Zur Bestimmung der minimalen Gesamtenergiekosten unter unsicheren Bedingungen ist das Wohnquartier als zweistufig stochastisches Programm mit Rekurs modelliert. Mit dem Modell, das im Wesentlichen auf Schwarz et al. (2018a) beruht, können Risiken (Unsicherheiten, die sich mittels Wahrscheinlichkeitsverteilungen realitätsnah abbilden lassen) adäquat berücksichtigt werden. Für die Berücksichtigung von Ungewissheiten (Unsicherheiten, deren Eintrittsereignisse, jedoch nicht deren Eintrittswahrscheinlichkeiten, bekannt bzw. vorstellbar sind) wird die Regret-Minimierung als äußeres, umhüllendes Programm eingesetzt.

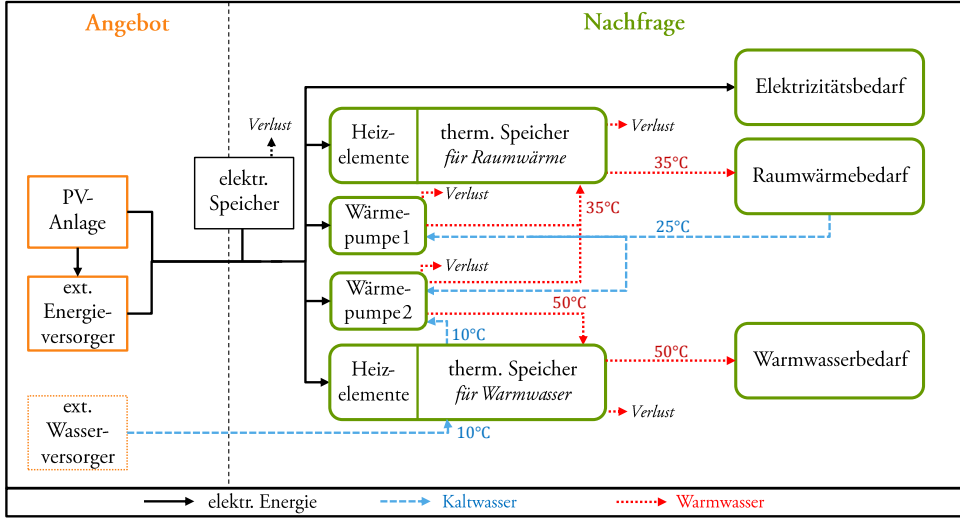


Abb. 6.4: Schematisches Energieflussdiagramm des Wohnquartiers (in Anlehnung an Schwarz et al. 2019).

Das innere *zweistufige* stochastische Programm mit minimalen erwarteten Gesamtenergiekosten $cost_{\theta}^*$ der Investitions- und Einsatzplanung im Fall θ ist:³⁷

$$\begin{aligned}
 cost_{\theta}^* = & \min_{x_{i,\theta}, \hat{e}_{\omega}^{grid}, e_{t,\omega,\theta}^{grid}, e_{t,\omega,\theta}^{grid,fi}, e_{t,\omega,\theta}^{PV,fi}} (ANF_{\theta} + MF_i) \sum_{i=1}^I \left(c_i^{fix} + \frac{c_i^{var}}{(1 - DF_i)} \cdot x_{i,\theta} \right) \\
 & + \frac{1}{N} \sum_{\omega=1}^N \left(\hat{p}_{\theta}^{grid} \cdot \hat{e}_{\omega,\theta}^{grid} + \sum_{t=1}^T \left(p_{t,\omega,\theta}^{grid} \cdot e_{t,\omega,\theta}^{grid} - p_{t,\omega,\theta}^{grid,fi} \cdot e_{t,\omega,\theta}^{grid,fi} - p_{t,\omega,\theta}^{PV,fi} \cdot e_{t,\omega,\theta}^{PV,fi} \right) \right). \quad (6.14)
 \end{aligned}$$

In der *ersten Stufe* wird die Auszahlung für Investition $i \in I$ in äquivalente Zahlungen pro Periode umgewandelt; dabei umfasst I die Menge möglicher Investitionsoptionen (z. B. PV-System, Wärmepumpe, Speicher etc.). Die Lebensdauer L der Investition und eine Investitionsalternative für das gebundene Kapital zu einem bestimmten Zins r werden durch den Annuitätenfaktor ANF_{θ} (siehe Gl. 4.2) berücksichtigt. Zusätzlich sind Instandhaltungskosten wie in Kaschub et al. (2016) mit dem Maintenance-Faktor $MF_{i,\theta}$ integriert. Darüber hinaus ist die Reduktion der initialen Kapazität $x_{i,\theta}$ der Investition i durch einen Degradationsfaktor $DF_{i,\theta}$ berücksichtigt. Die Kapazität des elektrischen Speichers und der thermischen Speicher $x_{i=ES,\theta}$ bzw. $x_{i=U,\theta}$ sowie die Anzahl der Wärmepumpen und Heizelemente $x_{i=HP_u,\theta}$ bzw. $x_{i=HE_u,\theta}$ sind auf Ganzzahligkeit beschränkt.

³⁷ Das Programm ist für die Fallstudie in Kapitel 8 ausgelegt, jedoch ohne PV-Eigenverbrauchsabgabe. Weitere Komponenten mit spezifischen Preisen, etwa für lokal verbrauchten PV-Strom, müssen ggf. mit weiteren Entscheidungsvariablen integriert werden.

In der zweiten Stufe ergeben sich die Betriebskosten je Szenario $\omega = \{1, \dots, N\}$ und Zeitschritt $t = \{0, \dots, T\}$ für die vom externen Netz bezogene elektrische Energie $e_{t,\omega,\theta}^{\text{grid}}$ zum Preis $p_{t,\omega,\theta}^{\text{grid}}$. Im Fall eines leistungspreisspezifischen Stromtarifs wird der maximale Netzbezug $\hat{e}_{\omega,\theta}^{\text{grid}}$ mit einem Leistungspreis $\hat{p}_{\theta}^{\text{grid}}$ kostenseitig verrechnet. Die Betriebskosten mindern sich durch die ins externe Netz eingespeiste elektrische Energie $e_{\omega,\theta}^{\text{grid,fi}}$ zum Preis $p_{t,\omega,\theta}^{\text{grid,fi}}$ sowie eingespeiste PV-Energie $e_{t,\omega,\theta}^{\text{PV,fi}}$ zur Vergütung $p_{t,\omega,\theta}^{\text{PV,fi}}$.

Eine wesentliche Nebenbedingung des Systems besteht darin, dass die elektrische Nachfrage zu jedem Zeitpunkt gleich dem Angebot ist, einschließlich der eingespeisten oder entnommenen Energie des elektrischen Speichers $\Delta s_{t,\omega,\theta}^{\text{ES}}$:

$$\begin{aligned} e_{t,\omega,\theta}^{\text{grid}} + (e_{t,\omega,\theta}^{\text{PV}} - e_{t,\omega,\theta}^{\text{fi}}) + \Delta s_{t,\omega,\theta}^{\text{ES}} \\ = d_{t,\omega,\theta}^{\text{ee}} + \sum_{u=1}^2 (d_{t,u,\omega,\theta}^{\text{HP}} + d_{t,u,\omega,\theta}^{\text{HE}}) \quad \forall t, \forall \omega, \forall \theta. \end{aligned} \quad (6.15)$$

Das Elektrizitätsangebot setzt sich aus der Energie aus dem externen Netz $e_{t,\omega,\theta}^{\text{grid}}$ und der PV-Energie $e_{t,\omega,\theta}^{\text{PV}}$ zusammen, abzüglich der ins externe Netz eingespeisten PV-Energie $e_{t,\omega,\theta}^{\text{fi}}$. Dabei hängt die angebotene PV-Energie von der Anlagengröße ab: $e_{t,\omega,\theta}^{\text{PV}} = x_{t=\text{PV},\theta} \cdot e_{t,\omega,\theta}^{\text{PV,kWp}}$. Die Elektrizitätsnachfrage besteht aus dem elektrischen Energiebedarf der Haushalte $d_{t,\omega,\theta}^{\text{ee}}$, der Wärmepumpen $d_{t,u,\omega,\theta}^{\text{HP}}$ und der Heizelemente $d_{t,u,\omega,\theta}^{\text{HE}}$.

Die eingespeiste oder entnommene Energie des elektrischen Speichers entspricht der Differenz des Speicherzustands zum Zeitpunkt t und $t+1$ abzüglich des Speicherverlusts: $\Delta s_{t,\omega,\theta}^{\text{ES}} = s_{t,\omega,\theta}^{\text{ES}} - s_{t+1,\omega,\theta}^{\text{ES}} - L_{t,\omega,\theta}^{\text{ES}}$. Der Verlust $L_{t,\omega,\theta}^{\text{ES}}$ ist vom Speicherstand zum Zeitpunkt t , der Ladeeffizienz $\eta_{\theta}^{\text{ES}}$, der Selbstentladung l_{θ}^{ES} und von der Be- bzw. Entladeleistung abhängig:

$$L_{t,\omega,\theta}^{\text{ES}} = l_{\theta}^{\text{ES}} \cdot s_{t,\omega,\theta}^{\text{ES}} + \left(\frac{1}{\eta_{\theta}^{\text{ES}}} - 1 \right) \cdot \text{pos}_{t,\omega,\theta}^{\text{ES}} + (1 - \eta_{\theta}^{\text{ES}}) \cdot \text{neg}_{t,\omega,\theta}^{\text{ES}} \quad \forall t, \forall \omega, \forall \theta, \quad (6.16)$$

wobei Beladung und Entladung mittels positiver Hilfsvariablen implementiert sind:

$$s_{t+1,\omega,\theta}^{\text{ES}} - s_{t,\omega,\theta}^{\text{ES}} = \text{pos}_{t,\omega,\theta}^{\text{ES}} - \text{neg}_{t,\omega,\theta}^{\text{ES}} \quad \forall t, \forall \omega, \forall \theta. \quad (6.17)$$

Analog dazu muss die thermische Nachfrage (der thermische Energiebedarf der Haushalte $d_{t,u,\omega,\theta}^{\text{th}}$) dem thermischen Angebot der Wärmepumpen ($\text{COP}_{t,u,\omega,\theta} \cdot d_{t,u,\omega,\theta}^{\text{HP}}$ abzgl. deren Verlust $L_{t,u,\omega,\theta}^{\text{HP}}$) und Heizelemente ($\eta_{\theta}^{\text{HE}} \cdot d_{t,u,\omega,\theta}^{\text{HE}}$) zu jedem Zeitpunkt entsprechen, einschließlich der Be- bzw. Entladung des thermischen Speichers $\Delta s_{\Delta t,u,\omega,\theta}^{\text{TS}}$:

$$\text{COP}_{t,u,\omega,\theta} \cdot d_{t,u,\omega,\theta}^{\text{HP}} - L_{t,u,\omega,\theta}^{\text{HP}} + \eta_{\theta}^{\text{HE}} \cdot d_{t,u,\omega,\theta}^{\text{HE}} + \Delta s_{t,u,\omega,\theta}^{\text{TS}} \quad \forall t, \forall u, \forall \omega, \forall \theta. \quad (6.18)$$

Der Index u steht für die verschiedenen Anwendungen für Raumwärme (RW) oder Warmwasser (WW) des Heizsystems. Die thermischen und mechanischen Verluste der Wärmepumpen $L_{t,u,\omega,\theta}^{\text{HP}}$ während positiver Lastveränderungen werden mit einem Verlustfaktor $l_{u,\theta}^{\text{HP}}$ und einer positiven Hilfsvariable $\mathit{pos}_{t,u,\omega,\theta}^{\text{HP}}$ abgebildet:

$$L_{t,u,\omega,\theta}^{\text{HP}} = l_{u,\theta}^{\text{HP}} \cdot \mathit{pos}_{t,u,\omega,\theta}^{\text{HP}} \quad \forall t, \forall u, \forall \omega, \forall \theta, \quad (6.19)$$

wobei:

$$d_{t+1,u,\omega,\theta}^{\text{HP}} - d_{t,u,\omega,\theta}^{\text{HP}} = \mathit{pos}_{t,u,\omega,\theta}^{\text{HP}} - \mathit{neg}_{t,u,\omega,\theta}^{\text{HP}} \quad \forall t, \forall u, \forall \omega, \forall \theta. \quad (6.20)$$

Der Verlustfaktor bildet die Anfahrverluste der Wärmepumpen als prozentualen thermischen Verlust der positiven Laständerung ab. Dadurch wird auch ein ständiger Lastwechsel der Wärmepumpe (Penny-Switching) verhindert. Die Be- bzw. Entladung der thermischen Speicher entspricht der Differenz des Speicherzustands zum Zeitpunkt t und $t+1$ abzüglich des Speicherverlusts: $\Delta s_{t,u,\omega,\theta}^{\text{TS}} = s_{t,u,\omega,\theta}^{\text{TS}} - s_{t+1,u,\omega,\theta}^{\text{TS}} - L_{t,u,\omega,\theta}^{\text{TS}}$. Der Verlust $L_{t,u,\omega,\theta}^{\text{TS}}$ ist vom Speicherstand zum Zeitpunkt t abhängig:

$$L_{t,u,\omega,\theta}^{\text{TS}} = l_{u,\theta}^{\text{TS}} \cdot s_{t,u,\omega,\theta}^{\text{TS}} \quad \forall t, \forall u, \forall \omega, \forall \theta. \quad (6.21)$$

Des Weiteren kann das elektrische und thermische Angebot durch technische oder andere Restriktionen limitiert sein. So ist das thermische Angebot der Wärmepumpen und Heizelemente durch deren Anzahl $x_{i=\text{HP}_u,\theta}$ bzw. $x_{i=\text{HE}_u}$ sowie deren maximale Heizleistung $\hat{d}_{t,\omega,\theta}^{\text{hp}}$ bzw. $\hat{d}_{\theta}^{\text{he}}$ begrenzt:

$$\text{COP}_{t,u,\omega,\theta} \cdot d_{t,u,\omega,\theta}^{\text{HP}} = \frac{1}{m_{\theta}} \cdot \hat{d}_{t,\omega,\theta}^{\text{hp}} \cdot z_{t,u,\omega,\theta} \quad \forall t, \forall u, \forall \omega, \forall \theta, \quad (6.22)$$

$$z_{t,u=\text{WW},\omega,\theta} \leq m_{\theta} \cdot x_{i=\text{HP}_u=\text{WW},\theta} \quad \forall t, \forall u, \forall \omega, \forall \theta, \quad (6.23)$$

$$\sum_{u=1}^2 z_{t,u,\omega,\theta} \leq m \cdot \sum_{u=1}^2 x_{i=\text{HP}_u,\theta} \quad \forall t, \forall u, \forall \omega, \forall \theta, \quad (6.24)$$

$$\eta_{\theta} \cdot d_{t,u,\omega,\theta}^{\text{HE}} \leq \hat{d}_{\theta}^{\text{he}} \cdot x_{i=\text{HE}_u} \quad \forall t, \forall u, \forall \omega, \forall \theta, \quad (6.25)$$

mit $z_{t,u,\omega,\theta} \in \mathbb{Z}_+$, wobei m die möglichen Heizstufen je Wärmepumpe (abzgl. des Leerlauf-Zustands) wiedergibt. Werden Inverter-Wärmepumpen mit beliebiger Heizleistung kleiner der maximalen Leistung eingesetzt, ist $z_{t,u,\omega,\theta}$ eine kontinuierliche Variable und $m = 1$. Die Nebenbedingungen (6.22)–(6.24) stellen sicher, dass die Wärmepumpe für Warmwasser auch zur Deckung des Raumwärmebedarfs verwendet werden kann. Umgekehrt (Deckung des Warmwasserbedarfs mit der Wärmepumpe für Raumwärme) funktioniert dies jedoch nicht. Diese spezifische Konfiguration ist dadurch begründet,

dass Nachfragespitzen für Raumwärme höher sind als Nachfragespitzen für Warmwasser (an Wintertagen bis zu 10 Mal höher).

Die elektrischen und thermischen Speicherstände sind durch einen minimalen und maximalen Speicherstand limitiert:

$$\xi_{t,\omega,\theta}^{\text{ES}} \leq s_{t,\omega,\theta}^{\text{ES}} \leq x'_{i=\text{ES},\theta} \quad \forall t, \forall \omega, \forall \theta, \quad (6.26)$$

$$\xi_{t,u,\omega,\theta}^{\text{TS}} \leq s_{t,u,\omega,\theta}^{\text{TS}} \leq x_{i=u,\theta} \quad \forall t, \forall u, \forall \omega, \forall \theta. \quad (6.27)$$

Der minimale Speicherstand wird häufig vom Betreiber zur Sicherheit vorgegeben. Der maximale Speicherstand ist durch die endogen gesuchte Speicherkapazität begrenzt. Als weitere Restriktion kommt hinzu, dass die thermischen Speichergrößen $x_{i=u,\theta}$ wirtschaftlich nur als diskrete sinnvolle Investitionseinheiten auf dem Markt verfügbar sind. Sie werden daher mit ganzzahligen Entscheidungsvariablen $z_{i=u,\theta}$ und der kleinsten verfügbaren Speichergröße (die in Abschnitt 3.3.2 berechnet ist) restringiert:

$$x_{i=\text{RW},\theta} = z_{i=\text{RW},\theta} \cdot 1,16 \text{ kWh}_{\text{th}}, \quad (6.28)$$

$$x_{i=\text{WW},\theta} = z_{i=\text{WW},\theta} \cdot 4,65 \text{ kWh}_{\text{th}}. \quad (6.29)$$

Bei Verwendung einer Lithium-Ionen-Batterie als Speicher gilt gemäß Kaschub (2017) zusätzlich für dessen Kapazität $x_{i=\text{ES}}$:

$$x_{i=\text{ES},\theta} = x'_{i=\text{ES},\theta} + \frac{0,3}{T} \cdot \sum_{t=1}^T s_{t,\omega,\theta}^{\text{ES}} \quad (6.30)$$

Damit wird die reduzierte kalendarische Lebensdauer für hohe Ladungszustände eingerechnet (Kaschub et al. 2016; Lutz et al. 2012). Dieser vereinfachte lineare Zusammenhang führt dazu, dass sich die Lebensdauer eines immer vollständig geladenen Speichers ca. um ein Drittel reduziert und folglich ein höherer Investitionsbedarf notwendig ist. Darüber hinaus ist die Ladeleistung der Lithium-Ionen-Batterie limitiert: $\Delta s_{t,\omega,\theta}^{\text{ES}} \leq \Delta \hat{s}_{t,\omega,\theta}^{\text{ES}}$. Die maximale Ladeleistung $\Delta \hat{s}_{t,\omega,\theta}^{\text{ES}}$ hängt generell von der Speicherkapazität $x'_{i=\text{ES},\theta}$ und der maximalen C-Rate C_{θ}^{max} ab:

$$\Delta \hat{s}_{t,\omega,\theta}^{\text{ES}} = C_{\theta}^{\text{max}} \cdot x'_{i=\text{ES},\theta} - \Delta \hat{s}_{t,\omega,\theta}^{\text{ES,red}} \quad \forall t, \forall \omega, \forall \theta. \quad (6.31)$$

Zusätzlich reduziert sich die Ladeleistung bei hohem SoC gemäß Kaschub et al. (2013) und Kaschub et al. (2016) um $\Delta \hat{s}_{t,\omega,\theta}^{\text{ES,red}}$:

$$\Delta \hat{s}_{t,\omega,\theta}^{\text{ES,red}} \geq C_{\theta}^{\text{max}} \cdot (4s_{t,\omega,\theta}^{\text{ES}} - 3x'_{i=\text{ES},\theta}) \quad \forall t, \forall \omega, \forall \theta. \quad (6.32)$$

Die maximale Ladeleistung nimmt bei einem SoC über 75 % linear ab und ist bei einem SoC von 100 % gleich null (wenn $C_{\theta}^{\text{max}} \cdot x'_{i=\text{ES},\theta} = \Delta \hat{s}_{t,\omega,\theta}^{\text{ES,red}}$). Diese lineare Reduzierung

der Ladeleistung hängt von Ladeenergie $s_{t,\omega,\theta}^{\text{ES}}$, Speicherkapazität $x'_{i=\text{ES},\theta}$ und maximaler C-Rate C_{θ}^{max} ab. Hingegen wird die Entladeleistung der Lithium-Ionen-Batterie nicht reduziert und kann SoC-unabhängig stets vollständig abgerufen werden.

Da in die Speicher und Wärmepumpen nur diskret investiert werden kann (1. Stufe) und die eingesetzten Luft-Wasser-Wärmepumpen nur stufenweise (im Leerlauf, unter Halb- oder Volllast) betrieben werden können (2. Stufe), enthalten beide Stufen gemischt-ganzzahlige Entscheidungsvariablen. Die Speicher im Energiesystem verknüpfen die Zustände der Zeitschritte t und $t + 1$ miteinander und führen zu einem komplexen, komplizierten SMILP. Damit das Programm stets ausführbar ist, wird die linke Seite der Randbedingung (6.15) und (6.18) durch weitere Hilfsenergievariablen $e_{t,\omega,\theta}^{\text{aux}}$ bzw. $a_{t,u,\omega,\theta}^{\text{aux}}$ relaxiert. Somit können Nachfrage-Restriktionen auch gedeckt werden, wenn das lokal verfügbare Energieangebot nicht ausreicht. Diese Hilfsenergievariablen in multiplikativer Verbindung mit einem Kompensationsfaktor sind als Strafterm zur Zielfunktion additiv hinzugefügt.

Alle Speicherstands-Variablen sind im ersten und letzten Zeitschritt eines Jahrs ($t = 0$ und $t = T$) auf Gleichheit beschränkt. Des Weiteren gilt für alle Entscheidungsvariablen die Nichtnegativitätsbedingung. Außerdem sind alle Entscheidungsvariablen kontinuierlich, wenn nicht anders angegeben. Die vollständige Nomenklatur des gesamten inneren stochastischen Programms findet sich tabellarisch in Anhang B.

Das äußere Programm minimiert den Regret der erwarteten Gesamtenergiekosten:

$$\min_{x_{\theta}^*} \max_{\theta} (\text{regret} = \text{cost}_{x_{\theta},\theta} - \text{cost}_{\theta}^*). \quad (6.33)$$

Dabei sind cost_{θ}^* die minimalen erwarteten Gesamtenergiekosten und $\text{cost}_{x_{\theta}^*,\theta}$ die minimierten erwarteten Gesamtenergiekosten (mit minimalen Betriebskosten) für die optimale Investition x_{θ}^* des Falls θ . Die resultierende Investition in das Energiesystem des Wohnquartiers ist die Lösung, die vom Entscheider im schlechtesten Fall θ am wenigsten bereut werden würden.

7 Methodik zur Bewältigung der rechtechnischen Herausforderungen

Das in Abschnitt 6.3.2 vorgestellte Optimierungsprogramm für Wohnquartiere, angepasst an die Fallstudie in Kapitel 8 beinhaltet ein SMILP mit übergeordneter Regret-Minimierung. Das SMILP der Fallstudie ist aufgrund seiner Größe mit gegenwärtig verfügbarer Hard- und Software nicht ohne Weiteres in vertretbarer Zeit und zufriedenstellender Genauigkeit durchführbar. Zur Vermittlung eines Eindrucks der rechtechnischen Herausforderungen des Programms enthält Tab. 7.1 die Anzahl der Entscheidungsvariablen und Restriktionen sowie die gesamte Rechenzeit. Die Berechnung eines einzigen Szenarios benötigt auf einem Rechner bereits drei Rechentage, um eine Lösung mit einem einigermaßen genauen MIP-Gap unterhalb von 5 % zu erhalten.

Tab. 7.1: Programmdimension des SMILP mit Regret-Minimierung der Fallstudie in Kapitel 8.

	Entscheidungsvariablen (davon ganzzahlig)	Restriktionen	gesamte Rechenzeit auf einem Rechner ³⁸
$N = 1$ Szenario	630 727 (70 084)	1 191 372	3 Rechentage (≈ 5 % MIP-Gap)
$N = 100$ Szenarien	63 072 106 (7 008 004)	119 136 606	\emptyset
$\theta = 7$ Fälle mit jeweils $N = 100$ Szenarien	$63\,072\,106 \cdot \theta$ $(7\,008\,004 \cdot \theta)$	$119\,136\,606 \cdot \theta$	\emptyset

Zur Lösung des komplexen SMILP erfolgt eine Dekomposition in kleinere Subprogramme einschließlich einer parallelen Ausführung auf mehreren Rechenrechnern und einer ableitungsfreien Optimierung des Masterprogramms (siehe Abschnitt 7.1). Um den Rechenaufwand möglichst gering zu halten, wird zuvor eine Szenarioreduktion und eine automatische Algorithmuskonfiguration des verwendeten CPLEX-Solvers durchge-

³⁸ Das Programm wird mit CPLEX auf einem Rechner mit bis zu 1 TB RAM und 32 Prozessoren (@ 2,4– 2,6 GHz) bei einer maximalen Laufzeit von 72 Stunden sowie einem relativen MIP-Gap von 5 % als Abbruchkriterium berechnet.

führt (siehe Abschnitt 7.2). Der gesamte parallele Optimierungsprozess ist in Abb. 7.1 dargestellt und wird im Folgenden näher erläutert.

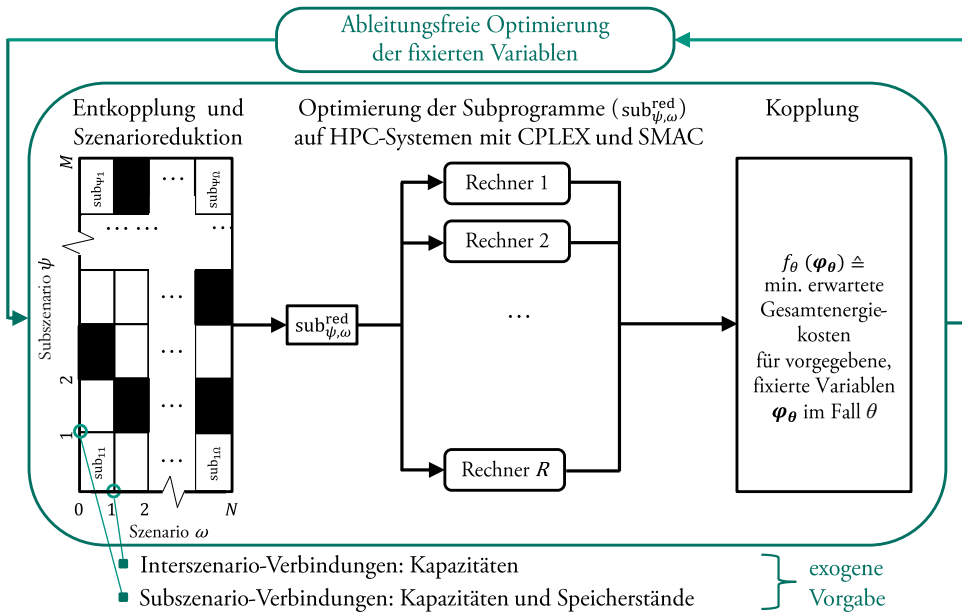


Abb. 7.1: Methodik zur Bewältigung rechentechnischer Herausforderungen des komplexen SMILP (in Anlehnung an Schwarz et al. 2018a; Schwarz et al. 2019).

7.1 Verteilte Optimierung

Rechentechnisch wird das stochastische Programm durch Entkopplung in Kombination mit verteilter Optimierung auf High-Performance-Computing(HPC)-Systemen ausgeführt. Hierfür werden Subszenario- und Interszenario-Verbindungen explizit vorgegeben (siehe Abschnitt 7.1.1). Dadurch kann das Programm in viele Subprogramme entkoppelt werden, welche mithilfe eines kommerziellen MILP-Solvers auf R Rechenknoten ausgeführt werden (siehe Abschnitt 7.1.2). Anschließend werden die Lösungen der Subprogramme zur Berechnung der minimalen Energiekosten mit den gegebenen Variablen wieder zusammengeführt. Die Optimierung der fixierten Variablen leistet eine ableitungsfreie Optimierung (siehe Abschnitt 7.1.3).

7.1.1 Entkopplung des Optimierungsprogramms

Grundsätzlich kann jedes stochastische Programm durch die Relaxierung von Subszenario- und Interszenario-Verbindungen entkoppelt werden. Für die Entkopplung des zweistufigen stochastischen Programms ist Gleichung (4.14) in impliziter Form als Funktion der Erststufen-Variablen für den Fall θ als Masterprogramm formuliert:³⁹

$$\begin{aligned} \min_{\mathbf{x}_\theta} f_\theta(\mathbf{x}) &= \mathbf{c}_\theta^T \mathbf{x}_\theta + \frac{1}{N} \sum_{\omega=1}^N Q_{\omega,\theta}(\mathbf{x}_\theta) \\ \text{s. t. } \underline{A}_\theta \mathbf{x}_\theta &\leq \mathbf{b}_\theta. \end{aligned} \quad (7.1)$$

Die Evaluation der impliziten Zweitstufen-Funktion $Q_{\omega,\theta}(\mathbf{x}_\theta)$ für ein vorgegebenes \mathbf{x}_θ erfordert die Lösung von N unabhängigen (gleichwahrscheinlichen) Subprogrammen:

$$\begin{aligned} Q_{\omega,\theta}(\mathbf{x}_\theta) &= \min_{\mathbf{y}_{\omega,\theta}} \mathbf{p}_{\omega,\theta}^T \mathbf{y}_{\omega,\theta} \\ \text{s. t. } \underline{T}_{\omega,\theta} \mathbf{x}_\theta + \underline{W}_{\omega,\theta} \mathbf{y}_{\omega,\theta} &\leq \mathbf{h}_{\omega,\theta} \quad \forall \omega = 1, \dots, N. \end{aligned} \quad (7.2)$$

Interszenario-verbundene Variablen sind durch Nichtantizipativitäts-Restriktionen verknüpft: Die Entscheidungen, z. B. die Investition in Speicher oder PV-Anlage, müssen in der ersten Stufe getroffen werden, ohne die tatsächliche Realisation der zweiten Stufe antizipieren zu können.⁴⁰

Falls erforderlich, kann auch eine Entkopplung der zweiten Stufe in $M \times N$ Subprogramme erfolgen, indem Subszenario-verbundene Variablen fixiert werden. In Energiesystemen sind diese in der Regel Investitionsentscheidungen (Erststufen-Entscheidungen) und über Zeitschritte verknüpfte Variablen, wie Speicherstand oder -verluste (Zweitstufen-Entscheidungen). Es gilt dann, die Zielfunktion $f_\theta(\boldsymbol{\varphi}_\theta = (\mathbf{x}_\theta, \mathbf{y}_{\omega,\theta}^{\text{fixiert}}))$ zu minimieren, wobei \mathbf{x}_θ die fixierten Erststufen-Variablen und $\mathbf{y}_{\omega,\theta}^{\text{fixiert}}$ die fixierten Zweitstufen-Variablen darstellen. Im Fall eines zweistufigen stochastischen Programms stellen die fixierten Erst- und Zweitstufen-Variablen \mathbf{x}_θ und $\mathbf{y}_{\omega,\theta}^{\text{fixiert}}$ Subszenario- bzw. Interszenario-Verbindungen dar.

³⁹ In der Arbeit wird der Begriff „Entkopplung“ als spezielle Form der Dekomposition verwendet, bei der die Subprogramme je Iteration des Masterprogramms unabhängig voneinander ausgeführt werden können.

⁴⁰ Bei Transformation der Stufen-Variablenschreibweise der Gleichungen (4.9) in die Szenario-Variablenschreibweise mit den Entscheidungsvektoren $\mathbf{x}_{1,\theta}, \dots, \mathbf{x}_{\omega,\theta}$ wird die Nichtantizipativitäts-Restriktion $\mathbf{x}_{1,\theta} = \dots = \mathbf{x}_{\omega,\theta}$ ersichtlich.

Das Masterprogramm der in Abschnitt 6.3.2 beschriebenen Investitions- und Einsatzplanung eines Wohnquartiers führt zu den minimalen Gesamtenergiekosten $costs_\theta^*$ für Fall θ :⁴¹

$$\begin{aligned} \min_{\mathbf{x}_{i,\theta}, \mathbf{y}_{\omega,\theta}^{\text{fixiert}}} f_\theta(\mathbf{x}_{i,\theta}, \mathbf{y}_{\omega,\theta}^{\text{fixiert}}) \\ = (ANF_{i,\theta} + MF_{i,\theta}) \sum_{i=1}^I \left(c_{i,\theta}^{\text{fix}} + \frac{c_{i,\theta}^{\text{var}}}{(1 - DF_{i,\theta})} \cdot \mathbf{x}_{i,\theta} \right) \\ + \frac{1}{N} \sum_{\omega=1}^N Q_{\omega,\theta}(\mathbf{x}_{i,\theta}, \mathbf{y}_{\omega,\theta}^{\text{fixiert}}) \end{aligned} \quad (7.3)$$

$$s. t. \mathbf{x}_{i=\text{PV},\theta}, \mathbf{y}_{\omega,\theta}^{\text{fixiert}} \in \mathbb{R}_+ \text{ und } \mathbf{x}_{i=\text{ES},\theta}, \mathbf{x}_{i=\text{u},\theta}, \mathbf{x}_{i=\text{HPu},\theta} \in \mathbb{Z}_+,$$

mit $\omega = \{1, \dots, N\}$, $\theta = \{1, \dots, \theta\}$ und dem Subprogramm:

$$\begin{aligned} Q_{\omega,\theta}(\mathbf{x}_{i,\theta}, \mathbf{y}_{\omega,\theta}^{\text{fixiert}}) \\ = \min_{\hat{p}_{\omega,\theta}^{\text{grid}}, \mathbf{e}_{t,\omega,\theta}^{\text{grid}}, \mathbf{e}_{t,\omega,\theta}^{\text{grid,fi}}, \mathbf{e}_{t,\omega,\theta}^{\text{PV,fi}}} \hat{p}_{\omega,\theta}^{\text{grid}} \cdot \mathbf{e}_{\omega,\theta}^{\text{grid}} \\ + \sum_{t=1}^T (p_{t,\omega,\theta}^{\text{grid}} \cdot \mathbf{e}_{t,\omega,\theta}^{\text{grid}} - p_{t,\omega,\theta}^{\text{grid,fi}} \cdot \mathbf{e}_{t,\omega,\theta}^{\text{grid,fi}} - p_{t,\omega,\theta}^{\text{PV,fi}} \cdot \mathbf{e}_{t,\omega,\theta}^{\text{PV,fi}}) \end{aligned} \quad (7.4)$$

$$s. t. \text{ equations (6.30) – (6.31) mit } t = \{0, \dots, T\}.$$

Gemäß Abb. 7.1 werden im Subprogramm Quartiers die minimalen Betriebskosten für eine vorgegebene Investition \mathbf{x}_θ (in PV-Anlage, Wärmepumpen, Raumwärme- und Warmwasserspeicher sowie elektr. Speicher) und vorgegebene, fixierte Speicherstände $\mathbf{y}_{\omega,\theta}^{\text{fixiert}}$ (Anfangs- und Endspeicherstände je Subprogramm) für Fall θ bestimmt. Durch die Fixierung kann Gleichung (7.4) in $M \times N$ (mit $M = |\mathbf{y}_{\omega,\theta}^{\text{fixiert}}| + 1$) Subprogramme zerlegt und parallel mit der benötigten, höheren Genauigkeit berechnet werden.

7.1.2 Parallele Ausführung der Subprogramme auf HPC-Systemen mit CPLEX

Die in Gleichung (7.4) entkoppelten Subprogramme $sub_{\psi,\omega}$ sind bei einer großen Anzahl von Szenarien und Entkopplungen auf gängigen Rechnern nicht mehr in einem akzeptablen Zeitrahmen rechen-technisch ausführbar. Deshalb erfolgt die Optimierung parallel: Nach Zerlegung des gesamten stochastischen Programms für Fall θ in $M \times N$ gemischt-zahlige Subprogramme und einer anschließenden Szenarioreduktion werden die

⁴¹ Das Masterprogramm ist durch diskrete Kapazitäten des elektrischen Speichers und der thermischen Speicher sowie die Anzahl der Wärmepumpen und Heizelemente restringiert.

verbleibenden Subprogramme $sub_{\psi,\omega}^{\text{red}}$ (siehe Abschnitt 7.2.1) mithilfe des kommerziellen MILP-Solvers CPLEX (Ver. 12.6.3) ausgeführt. Zur Reduzierung der Rechenzeit erfolgt die innere Optimierung parallel auf R Rechenknoten eines HPC-Systems. Der Prozess ist darauf ausgelegt, die Subprogramme auch auf Rechenknoten verschiedener HPC-Systeme ausführen zu können. Nach der Optimierung der Subprogramme wird deren Lösung zusammengesetzt, um den Minimalwert von $f_{\theta}(\varphi_{\theta})$ für die vom Masterprogramm exogen vorgegebenen Variablen zu berechnen. Aufgrund von Ganzzahligkeitsanforderungen in Bezug auf diese Variablen wird ein ableitungsfreies Optimierungsverfahren für das Masterprogramm eingesetzt (siehe Abschnitt 7.1.3).

Die Umsetzung der parallelen Optimierung erfolgt gemäß Schwarz (2017). Die Entkopplung in Kombination mit der ableitungsfreien Optimierung sowie die Verteilung der Subprogramme auf verschiedene HPC-Systeme wird durch eine *Visual Basic Application* (VBA) auf einem Windows-Masterrechner realisiert. Neben der einfachen Implementierung und Handhabung der Dateneingabe und -ausgabe können sowohl Windows- als auch Linux-basierte Rechner verschiedener HPC-Systeme (über das Tool *PuTTY* bzw. *PsExec*) eingebunden werden. Für die Optimierung des Wohnquartiers wurden Linux-basierte Rechenknoten des *bwUniClusters* und des *bwForClusters* sowie einige Windows-basierte Rechner des *Instituts für Industriebetriebslehre und Industrielle Produktion* (IIP) verwendet. Dedizierte Rechenknoten mit maximal 16 GB RAM und zwei CPU-Kernen werden für bis zu 30min angefordert, um eine Lösung der Subprogramme mit einer für die ableitungsfreie Optimierung erforderlichen Qualität (MIP-Gap < 1 %) zu gewährleisten.

7.1.3 Ableitungsfreie Optimierung des Masterprogramms

Allgemein gibt es globale und lokale ableitungsfreie Suchalgorithmen, die nur die Werte der Zielfunktion benötigen und keine Informationen über deren Ableitung erfordern (Rios und Sahinidis 2013). Eine globale Lösung ist grundsätzlich wünschenswert. Angesichts der sehr rechenaufwendigen Evaluationen aller Subprogramme ist es jedoch wichtiger, nur wenige Iterationen zu benötigen, um überhaupt eine lokale optimale Lösung zu finden. Außerdem ist ein zuverlässiger und robuster Lösungsprozess, insbesondere mit hoher Toleranz gegenüber Lösungsungenauigkeiten der Subprogramme, gefordert. Verschiedene ableitungsfreie Optimierungsverfahren sind im Hinblick auf die genannten Anforderungen im Anhang C in Tab. C.1 zusammengefasst. In der vorliegenden Arbeit wird das Masterprogramm in einer äußeren Schleife mit einem Bergsteigeralgorithmus (*Hill-Climbing Algorithm*) ausgeführt.

Ein Bergsteigeralgorithmus ist ein lokaler Suchalgorithmus, bei dem versucht wird, eine gegebene Ausgangslösung eines Problem durch inkrementelle Änderung der lösungsabhängigen Variablen zu verbessern (Taborda und Zdravkovic 2012). In der vorliegenden Arbeit wird für die Minimierung der Zielfunktion $f_\theta(\boldsymbol{\varphi}_\theta)$ ein Algorithmus des steilsten Abstiegs (*Steepest Ascent Hill-Climbing*, SAHC) verwendet. Jedes einzelne Element k von $\boldsymbol{\varphi}_\theta$, das einen kontinuierlichen oder diskreten Wert der fixierten Erst- und Zweitstufen-Variablen $\boldsymbol{\varphi}_{\theta,k}$ darstellt, wird verändert. Bei jedem Iterationsschritt werden alle Elemente von $\boldsymbol{\varphi}_\theta$ sequenziell in jene Richtung verändert, die zur Verbesserung des Werts von $f_\theta(\boldsymbol{\varphi}_\theta)$ führt. Die Veränderung mit der größten Verbesserung wird akzeptiert (siehe z. B. Forrest und Mitchell 1993).

Für die Optimierung des Masterprogramms wurde der SAHC-Algorithmus leicht modifiziert. Die Abstiegsrichtungen für jede fixierte Variable $\boldsymbol{\varphi}_{\theta,k}$, die den Zielwert $f_\theta(\boldsymbol{\varphi}_\theta)$ verbessert, wird in einer initialen Prozedur bestimmt. Dabei wird zu jeder fixierten Variable $\boldsymbol{\varphi}_{\theta,k}$ eine bestimmte Schrittweite s_k addiert und der minimale Zielwert von f_θ durch den parallelen Optimierungsprozess berechnet. Analog wird von jeder fixierten Variable die gleiche Schrittweite s_k subtrahiert und der minimale Zielwert von f_θ berechnet. Die Abstiegsrichtung für jedes $\boldsymbol{\varphi}_{\theta,k}$ wird festgelegt. Der Schritt mit der größten Verbesserung wird akzeptiert und die Suche des steilsten Abstiegs wird anschließend immer nur für die festgelegte Abstiegsrichtung wiederholt. Gibt es keine Verbesserung, wird die Schrittweite halbiert und der Prozess beginnt erneut mit der initialen Prozedur. Der Prozess wird solange fortgesetzt, bis die relative Änderung von f_θ kleiner als ein vorgegebenes Stoppkriterium $a \in R_+$ ist. Die vollständige Prozedur des steilsten Abstiegs wird in Anhang C beschrieben. Die Optimierung wird für jeden Fall θ individuell durchgeführt. Im Folgenden wird die lokal optimale Lösung des Bergsteigeralgorithmus, die global optimal sein könnte, als optimale Lösung oder Optimum bezeichnet.

Der SAHC wird in vielen Fällen in der Performance von anderen Algorithmen übertroffen. Die Auswahl lässt sich jedoch damit begründen, dass er auch ohne exakte Lösung der Subprogramme robust zum (lokalen) Optimum voranschreitet: Die Rechenzeit kann durch größere MIP-Gaps als Abbruchkriterium erheblich reduziert werden. Erst in der Nähe des Optimums steigt die Anforderung an die Lösungsgenauigkeit der Subprogramme. Darüber hinaus wird ein (lokales) Optimum bei wenigen fixierten Variablen und einem guten Startpunkt in wenigen Iterationen erreicht. Abschnitt 9.2.4 enthält in Tab. 9.2 einen Vergleich des Bergsteigeralgorithmus mit dem von Carøe und Schultz (1999) entwickelten *Dual Dekomposition in Stochastic Integer Programmierung* (DDSIP)-Algorithmus. DDSIP wurde stetig weiterentwickelt und repräsentiert den aktuellen Stand der Forschung zur Lösung zweistufiger stochastischer Probleme.

7.2 Verwendete Methoden zur Reduktion des Rechenaufwands

Zur Reduktion des Rechenaufwands der Optimierungsebene (Abschnitt 6.3) werden eine Szenarioreduktionstechnik (siehe Abschnitt 7.2.1) und eine sequenzielle modelbasierte Algorithmuskonfiguration (*Sequential Model-based Algorithm Configuration*, SMAC) für den verwendeten CPLEX-Solver (siehe Abschnitt 7.2.2) angewendet.

7.2.1 Szenarioreduktion

Auch wenn die Dekomposition eine extensive Berechnung auf mehreren Rechnern gleichzeitig zulässt, hängt der rechentechnische Aufwand entscheidend von der Anzahl der Szenarien ab. So ist auch deren Reduktion zur Aufwandsbegrenzung naheliegend. Einen kompakten Einblick in die Szenarioreduktion mit weiterführender Literatur geben Heitsch und Römisich (2011). Nach Maßgabe der zuvor beschriebenen Szenario-Erzeugung und -Entkopplung (Abschnitt 6.1 und 7.1) eignet sich eine Reduktion auf Basis von Moment-Matching oder Wahrscheinlichkeitsmetriken (Arpón et al. 2018).

Momente sind Kenngrößen der Verteilungsfunktion einer Zufallsvariablen. Das Moment-Matching zielt darauf ab, Wahrscheinlichkeitsverteilungen stochastischer Parameter möglichst genau wiederzugeben, indem die Differenz zwischen geeigneten Momenten des originalen und des reduzierten Szenariofächers minimiert wird. Auch wenn diese Heuristik unter Praktikern akzeptiert ist, garantieren ähnliche Momente im Allgemeinen keine Ähnlichkeit zweier Verteilungen. Ferner fehlt es an theoretischen Grundlagen. Es ist ungewiss, wie sich passende Momente in Bezug auf die Approximationsqualität verhalten (Kovacevic und Pichler 2015).

Szenarioreduktionstechniken auf Basis von Wahrscheinlichkeitsmetriken umfassen die Minimierung eines bestimmten Distanzmaßes zwischen originalem und reduziertem Szenario-Set. Typischerweise basieren diese Ansätze auf Stabilitätseigenschaften, die sicherstellen, dass die Differenz zwischen den optimalen Werten der ursprünglichen und approximativen Szenario-Sets durch eine vorgegebene Distanz beschränkt ist (Arpón et al. 2018). Ähnlich wie Dupačová et al. (2003) wird in der Regel eine Funktion gemäß der Kantorovich-Metrik (auch als Wasserstein-Metrik bezeichnet) als Distanzmaß zwischen zwei Wahrscheinlichkeitsverteilungen verwendet. Dabei werden einem Szenario-Subset mit gewünschter Kardinalität oder relativer Genauigkeit neue Wahrscheinlichkeiten zugeordnet. Das entsprechend reduzierte Wahrscheinlichkeitsmaß \tilde{P} soll dem originalen Maß P möglichst nahe kommen. Hierbei dient das Distanzmaß zur Quantifizierung

des Abstands zwischen P und \tilde{P} (Distanz zwischen Werten der Szenarien). In der vorliegenden Arbeit wird diese Methode verwendet und im Folgenden im Detail beschrieben.

Die Wahrscheinlichkeitsverteilung P eines K -dimensionalen, zeitabhängigen stochastischen Prozesses $\xi \in \mathbb{R}^{KT}$ sei approximativ gegeben durch:

$$\xi^\omega = \{\xi_{1,1}^\omega, \dots, \xi_{K,1}^\omega, \xi_{1,2}^\omega, \dots, \xi_{K,2}^\omega, \dots, \xi_{1,T}^\omega, \dots, \xi_{K,T}^\omega\}, \quad (7.5)$$

mit $k = 1, \dots, K$ Komponenten und $t = 0, \dots, T$ Zeitschritten für eine finite Anzahl an Szenarien $\omega = 1, \dots, N$ und deren Wahrscheinlichkeiten p_ω mit $\sum_{\omega=1}^N p_\omega = 1$. Nun sei \tilde{P} die Wahrscheinlichkeitsverteilung eines anderen K -dimensionalen zeitabhängigen stochastischen Prozesses $\tilde{\xi}$ mit $\tilde{\xi}^{\tilde{\omega}} \in \mathbb{R}^{KT}$ für die Szenarien $\tilde{\omega} = 1, \dots, \tilde{N}$ und deren Wahrscheinlichkeiten $q_{\tilde{\omega}}$.

Als Distanzmaß dient das Monge-Kantorovich-Funktional, das gemäß Heitsch (2007) im diskreten Fall die Form annimmt:

$$D_k(P, \tilde{P}) = \inf \sum_{\omega=1}^N \sum_{\tilde{\omega}=1}^{\tilde{N}} c_T(\xi^\omega, \tilde{\xi}^{\tilde{\omega}}) g_{\omega\tilde{\omega}} \quad (7.6)$$

$$s. t. \quad g_{\omega\tilde{\omega}} \geq 0, \quad \sum_{\omega=1}^N g_{\omega\tilde{\omega}} = q_{\tilde{\omega}}, \quad \sum_{\tilde{\omega}=1}^{\tilde{N}} g_{\omega\tilde{\omega}} = p_\omega \quad \forall \omega, \forall \tilde{\omega},$$

wobei $c_T(\xi^\omega, \tilde{\xi}^{\tilde{\omega}}) := \|\xi^\omega - \tilde{\xi}^{\tilde{\omega}}\|^r$ und $\|\cdot\|^r$ die sogenannte L_r -Norm mit $r \geq 1$ bezeichnet.⁴² Für die Kostenfunktion $c_T(\xi^\omega, \tilde{\xi}^{\tilde{\omega}})$ wird die euklidische Distanz als L_2 -Norm angewandt und über Heitsch (2007) hinaus eine Wichtung w_k eingeführt.⁴³ Die Distanz über den gesamten Zeitraum T und alle Komponenten K zweier Szenarien ist:

$$c_T(\xi^\omega, \tilde{\xi}^{\tilde{\omega}}) := \sqrt{\sum_{k=1}^K w_k \sum_{t=1}^T (\xi_{k,t}^\omega - \tilde{\xi}_{k,t}^{\tilde{\omega}})^2}, \quad (7.7)$$

mit der komponentenbezogenen Standardabweichung $w_k = 1/\sigma_k$. Ohne Wichtung würden Komponenten gleich gewertet, obwohl die Komponenten mit verschiedenen Wertebereichen eines Szenarios unterschiedliche Auswirkungen auf das Optimierungser-

⁴² Die sogenannten L_r -minimalen Metriken werden auch als Wasserstein-Metriken der Ordnung r bezeichnet.

⁴³ Für zweistufige SMILP gilt: $r = 1$ wenn entweder nur Kosten-Vektor c oder Rechte-Hand-Seiten-Vektor h und/oder Technologiematrix \underline{T} stochastisch sind (zweistufige SMILP mit festem Rekurs); $r = 2$ wenn c oder h und \underline{T} stochastisch sind; $r > 2$ tritt nur auf, wenn die Rekurs-Matrix \underline{W} auch stochastisch ist. Bei ganzzahligen Entscheidungsvariablen würden die verursachten Unstetigkeiten in der Zielfunktion mittels Rechtecksdiskrepanz besser approximiert werden (Heitsch et al. 2009). Jedoch würde die Verwendung in Gleichung (7.7) für größere K bzw. T zu unverhältnismäßig langen Rechenzeiten führen.

gebnis haben. Die Normierung der Szenariokomponenten auf die Standardabweichung führt dazu, dass alle Summanden etwa in der gleichen Größenordnung berücksichtigt werden, ohne dass spezifische Kenntnisse über die Daten erforderlich sind.

Das in Gleichung (7.6) eingeführte Monge-Kantorovich-Funktional $D_k(P, \tilde{P})$ entspricht mit der Kostenfunktion aus Gleichung (7.7) dem Optimum eines klassischen linearen (Massen-)Transportproblems zwei diskreter Wahrscheinlichkeitsverteilungen (Heitsch 2007). Das Transportproblem besteht in der Bestimmung eines kostenminimalen Wegs für die Wahrscheinlichkeitsgewichte g_{ij} des Szenario-Sets mit der Verteilung P zum Szenario-Set mit der Verteilung \tilde{P} , wobei nur direkte Verbindungen zwischen den Sets erlaubt sind.

\tilde{P}^{red} sei die reduzierte Wahrscheinlichkeitsverteilung von P , also $\text{supp}(\tilde{P}^{\text{red}}) = \{\xi^\omega : \omega \in \{1, \dots, N\} \setminus \tilde{N}\}$ und \tilde{N} bezeichnet die Indexmenge der gelöschten Szenarien $\tilde{N} \subset \{1, \dots, N\}$. Das Szenario-Set mit der Verteilung \tilde{P}^{red} und den Szenarien $\{\xi^{\tilde{\omega}}\}_{\tilde{\omega} \in \tilde{N}}$ mit der minimalen D_k -Distanz zu P ist:

$$D_k(P, \tilde{P}^{\text{red}}) = \sum_{\omega \in \tilde{N}} p_\omega \min_{\tilde{\omega} \in \tilde{N}} c_T(\xi^\omega, \xi^{\tilde{\omega}}). \quad (7.8)$$

Die Wahrscheinlichkeiten $q_{\tilde{\omega}}$ der erhaltenen Szenarien $\xi^{\tilde{\omega}}$ mit $\tilde{\omega} \in \tilde{N}$ von \tilde{P}^{red} ergeben sich nach der Regel:

$$q_{\tilde{\omega}} := p_{\tilde{\omega}} + \sum_{\omega \in \tilde{N}(\tilde{\omega})} p_\omega, \quad (7.9)$$

wobei $\tilde{N}(\tilde{\omega}) := \{\omega \in \tilde{N} : \tilde{\omega} = \tilde{\omega}(\omega)\}$ mit $\tilde{\omega}(\omega) \in \arg \min c_T(\xi^\omega, \xi^{\tilde{\omega}})$ für $\forall \omega \in \tilde{N}$.

Das Prinzip der Szenarioreduktion besteht nun aus der optimalen Auswahl der Indexmenge \tilde{N} mit einer vorgegebenen Kardinalität $\#\tilde{N}$ der reduzierten Anzahl an Szenarien $n \in \mathbb{N}$ mit $n < N$:

$$\min \left\{ \sum_{\omega \in \tilde{N}} p_\omega \min_{\tilde{\omega} \in \tilde{N}} c_T(\xi^\omega, \xi^{\tilde{\omega}}) : \tilde{N} \subset \{1, \dots, N\}, \#\tilde{N} = N - n \right\}. \quad (7.10)$$

Probleme dieser Art sind aufgrund ihrer kombinatorischen Struktur im Allgemeinen NP-schwer (siehe auch Gröwe-Kuska et al. 2003; Heitsch 2007). Dadurch ist die Reduzierung an sich ein Optimierungsproblem, das unter Umständen rechenaufwendiger als das zu optimierende stochastische Programm selbst ausfallen kann. Aus diesem Grund existieren konzeptionell heuristische Vorwärts- oder Rückwärts-Reduktions-Algorithmen. In der vorliegenden Arbeit wird der von Gröwe-Kuska et al. (2003) entwickelte Rückwärts-Reduktions-Algorithmus verwendet: Die Idee besteht darin, Szenarien nacheinander zu löschen, so dass die Kantorovich-Distanz zwischen originalem und reduziertem Szenario-Set $D_k(P, \tilde{P}^{\text{red}})$ immer minimal ist. Die Eintrittswahrscheinlichkeit

des gelöschten Szenarios wird zu dem Szenario hinzugefügt, das die minimale Kantorovich-Distanz zum gelöschten Szenario aufweist. Dieser Löschvorgang wird so häufig wiederholt, bis entweder eine gewünschte Szenarienzahl n erreicht ist oder alternativ, solange eine geforderte relative Genauigkeit $\varepsilon_{rel} \leq \frac{D_K}{D_{K,1}}$ eingehalten wird. Dabei stellt $D_{k,1}$ die minimal mögliche Kantorovich-Distanz zwischen originalem Set und einem einzigen Szenario $D_k(P; \bar{P}_1^{\text{red}})$ dar. Der heuristische Rückwärts-Reduktions-Algorithmus zeigt für eine große Anzahl an Szenarien eine Reduktion nahe dem Optimum innerhalb kurzer Rechenzeiten (Heitsch 2007). Aufgrund der dimensionsunabhängigen Reduktion sind keine besonderen Kenntnisse über die verwendeten Daten erforderlich.

7.2.2 Sequenzielle modellbasierte Algorithmuskonfiguration von CPLEX

Für die operative Lösungsfindung von MILP und SMILP werden in der Regel leistungsfähige Solver-Softwaresysteme eingesetzt. Der in dieser Arbeit verwendete CPLEX-Solver stellt einen der besten, kommerziell erhältlichen Solver für verschiedene Arten von MILP-Problemen dar (Koch et al. 2011; Meindl und Templ 2012).

Die meisten modernen Solver-Softwaresysteme, wie auch der CPLEX-Solver, stellen dem Anwender eine Vielzahl von Parametereinstellungen zur Verfügung. Die Standardwerte dieser Parameter bieten in der Regel keine optimale Performance (Atamtürk und Savelsbergh 2005). Für ein schnelles und effizientes Lösen der Optimierungsprobleme ist eine programmspezifische Konfiguration des Solvers unerlässlich (Hutter et al. 2010). Leider ist der Raum der möglichen Parametereinstellungen sehr groß und es gibt in der Literatur kaum Verfahren zur Ableitung optimaler Einstellungen für ein spezifisches Problem. Daher werden in den meisten Anwendungen von CPLEX und ähnlichen hochparametrischen Solvern entweder Standardwerte verwendet oder spezifische Parametereinstellungen ad hoc in aufwendigen Experimenten ermittelt. Die automatische Algorithmuskonfiguration (*automated algorithm configuration*) mittels künstlicher Intelligenz bieten einen effektiven Weg, dieser Herausforderung zu begegnen (siehe z. B. Hutter et al. 2007; Hutter et al. 2011). Zur Reduktion des Rechenaufwands des stochastischen Programms wird daher die in Schwarz et al. (2019) beschriebene automatisierte Algorithmuskonfiguration am CPLEX-Solver angewendet.

Anstatt manuell mit verschiedenen Parametereinstellungen zu experimentieren, definiert der Anwender hier nur den Zielalgorithmus (d.h. den Algorithmus, dessen Performance optimiert werden soll), den Parameterraum (definiert durch die Parameternamen sowie deren zulässige Werte und Standardwerte), eine Reihe von repräsentativen Prob-

leminstanzen und eine Performance-Metrik. Das automatisierte Verfahren erledigt den Rest: Es wählt und bewertet intelligent und effizient vielversprechende Parametereinstellungen mit dem Ziel, die vorgegebene Performance-Kennzahl zu optimieren. Das allgemeine Verfahren ist in Abb. 7.2 dargestellt.

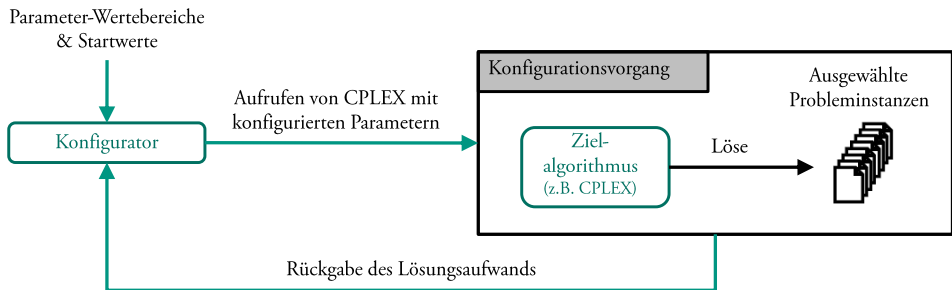


Abb. 7.2: Automatisierte Algorithmuskonfiguration (in Anlehnung an Hutter et al. 2010).

Bei den Verfahren zur automatischen Algorithmuskonfiguration wird der Zielalgorithmus wie eine Blackbox behandelt. Dabei werden keine Kenntnisse über das Innenleben vorausgesetzt, sondern deren Performance wird durch empirische Beobachtungen bewertet. Die so gewonnenen Informationen werden genutzt, um Performance-steigernde Parametereinstellungen für den Zielalgorithmus zu finden.

Ein einfacher Ansatz zur Algorithmuskonfiguration besteht darin, eine sehr große Anzahl verschiedener Konfigurationen zu bewerten, die entweder systematisch ausgewählt werden, um den gegebenen Parameterraum abzudecken, oder nach dem Zufallsprinzip getestet werden. Für Zielalgorithmen mit sehr großen Parameterräumen (z. B. CPLEX) ist dies aufgrund von Restriktionen der rechen-technischen Ressourcen nicht möglich.⁴⁴ Modellbasierte Methoden zur Algorithmuskonfiguration hingegen approximieren den Parameter-Performance-Lösungsraum mit einem Ersatzmodell, als Surrogat-Modell bezeichnet (siehe z. B. Hutter et al. 2011). Das Surrogat-Modell ist aus rechen-technischer Sicht sehr einfach zu lösen und liefert Vorhersagen über die Performance des Zielalgorithmus mit noch nicht getesteten Parametereinstellungen. Zur Bestimmung der nächsten Testkonfiguration des Zielalgorithmus werden diese Vorhersagen, verbunden mit einer gewissen Unsicherheit, durch eine Evaluationsfunktion bewertet. Es wird die Konfiguration mit dem höchsten Potenzial zur Performance-Steigerung gewählt. Hierbei

⁴⁴ CPLEX (Ver. 12.6.2) enthält 7 boolesche, 45 kategorische, 18 ganzzahlige und 7 kontinuierliche Parameter.

wird sowohl die Leistung vergangener Konfigurationen als auch die Unsicherheit, die mit unerforschten Konfigurationen verbunden ist, berücksichtigt. Auf diese Weise werden zu Beginn, bei noch hoher Unsicherheit des Lösungsraums, tendenziell Konfigurationen mit hoher Diversität erforscht; mit zunehmenden Informationen und abnehmender Unsicherheit des Lösungsraums wird verstärkt auf die vielversprechendsten Bereiche des Parameterraums fokussiert. Der Prozess stoppt, wenn ein benutzerdefiniertes Konfigurationsbudget erschöpft ist. Das Verfahren bietet jederzeit eine Lösung: Die bestehende Konfiguration kann in jedem Schritt des Prozesses abgerufen werden.

Die bei solchen sequenziellen modellbasierten Optimierungsverfahren (SMBO) verwendeten Surrogat-Modelle werden durch maschinelle Lernmethoden generiert, die verhältnismäßig wenige Datenpunkte des Parameter-Performance-Lösungsraums für dessen ausreichende Approximation benötigen. Diese Verfahrensweise ist aktueller Stand der Forschung und bietet eine generelle Möglichkeit, große Parameterräume intelligent und effizient zu erforschen. Weitere Informationen finden sich beispielsweise in Jones et al. (1998), Hutter et al. (2009), Ansótegui et al. (2009) oder Mascia et al. (2014).

Die automatisierte Konfiguration kann von Anwendern ohne Hintergrundwissen der verwendeten KI-Techniken eingesetzt werden. Demzufolge ist damit ein leistungsstarkes, domänenunabhängiges Verfahren verfügbar, das allen potenziellen Anwendern, unabhängig von ihrem Hintergrund, die Möglichkeit bietet, die Performance des Solvers zu verbessern. Der in vorliegender Arbeit verwendete automatische Algorithmuskonfigurator SMAC wurde an der *University of British Columbia* (UBC) entwickelt und stetig weiterentwickelt (siehe auch Hutter et al. 2011). Das Programm SMAC ist als Open-Source-Software verfügbar, relativ einfach zu bedienen und erzielt bei einer Vielzahl von Aufgaben zur Algorithmuskonfiguration sehr gute Ergebnisse. Alternative SMBO-basierte Verfahren sind der *Tree-based Parzen Estimator* (TPE) (Bergstra et al. 2011) und *Spearmint* (Snoek et al. 2012). Es hat sich jedoch nicht gezeigt, dass diese die Leistungsfähigkeit von SMAC bei der Konfiguration von CPLEX erreichen oder übertreffen würden (Eggersperger et al.).

8 Fallstudie zur Optimierung eines Wohnquartiers unter Unsicherheiten

Als Fallstudie für die Investitions- und Einsatzplanungsoptimierung wird das dezentrale Energiesystem eines Wohnquartiers bezüglich der Gesamtenergiekosten mit dem entwickelten Optimierungsverfahren unter Unsicherheit minimiert. Das Energiesystem des Wohnquartiers wird in Abschnitt 8.1 vorgestellt. In Abschnitt 8.2 sind die rahmengebenden Modellparameter und allgemeine Annahmen aller betrachteten Fälle zusammengefasst. Als Ausgangspunkt wird ein Referenzfall θ_{Ref} in Abschnitt 8.3 vorgestellt, bei dem davon ausgegangen wird, dass die Modellparameter über den Betrachtungshorizont von 20 Jahren gleich bleiben. Um die risikobehafteten Unsicherheiten mit bekannter Eintrittswahrscheinlichkeit zu berücksichtigen, werden insgesamt 100 verschiedene Szenarien mit dem in Kapitel 6 vorgestellten Konzept erzeugt. Diese erzeugten Szenarien werden für alle Fälle verwendet.

Um ungewisse Unsicherheiten zu berücksichtigen, werden in Abschnitt 8.4 sechs weitere Alternativfälle präsentiert, bei denen weder deren Eintrittswahrscheinlichkeit bekannt ist noch sinnvoll abgeschätzt werden kann. Die Alternativfälle treten exogen mit der gleichen Ungewissheit wie der Referenzfall ein und können vom Entscheider nicht beeinflusst werden. Für jeden Fall θ wird die individuell optimale Investition in die Systemkomponenten k bestimmt, die zu den fallspezifischen minimalen erwarteten Gesamtenergiekosten des Wohnquartiers (mit minimalen erwarteten Betriebskosten) führen. Final werden in Abschnitt 8.5 der Referenzfall und alle Alternativfälle für die Regret-Minimierung genutzt, um die Investitions- und Einsatzplanung mit den minimalen erwarteten Gesamtenergiekosten zu bestimmen, die vom Entscheider im schlechtesten Fall θ am wenigsten bereut werden würde.

Neben der Regret-Minimierung werden in Abschnitt 8.6 zwei Sonderfälle mit niedrigem Arbeitspreis und vollständiger Autarkie betrachtet, die (aus Sicht des Autors) in den nächsten 20 Jahren für das betrachtete Wohnquartier in Deutschland nicht (als ungewisse Fälle) eintreten werden, deren Untersuchung jedoch einen Mehrwert für zukünftige dezentrale Energiesysteme bietet.

Um den Vorteil der Stochastischen Programmierung aufzuzeigen, werden in Abschnitt 8.7 die deterministische und stochastische Lösung des Referenzfalls sowie der Sonderfälle verglichen. Die Diskussion über die Ergebnisse und das Optimierungsverfahren sowie die Schlussfolgerungen daraus sind in Kapitel 9 enthalten.

8.1 Wohnquartier als Fallstudie

In dieser Arbeit wird ein Wohnquartier in Karlsruhe als dezentrales Energiesystem exemplarisch modelliert und optimiert. Das Quartier vereint 28 Wohneinheiten auf 2 000 m² Wohnfläche in Reihen- und Mehrfamilienhäusern zu einer Energiegemeinschaft. Der Bedarf an thermischer und elektrischer Energie kann mit PV-Anlage, elektrischen Wärmepumpen und Heizelementen gedeckt werden. Es besteht zu jedem Zeitpunkt die Möglichkeit, elektrische Energie von einem externen Energieversorger zu beziehen. Flexible elektrische und thermische Speicher können ebenso zugebaut werden. In Abb. 8.1 ist der Aufbau des Energiesystems des Wohnquartiers abgebildet. Mit der Fallstudie kann eine Antwort auf die Forschungsfrage der vorliegenden Arbeit gegeben werden: eine Optimierung unter Berücksichtigung von Unsicherheiten zur Bestimmung der optimale Investition (mit kostenminimalen Einsatzkosten) in PV-Anlage, Wärmepumpenanzahl sowie thermische und elektrische Speicher. In diesem Zusammenhang soll auch der Einfluss von verschiedenen Stromtarifen aufgezeigt werden. Darüber hinaus wird der Mehrwert der entwickelten Methodik anhand eines Vergleichs mit einer deterministischen Optimierung des Wohnquartiers demonstriert.

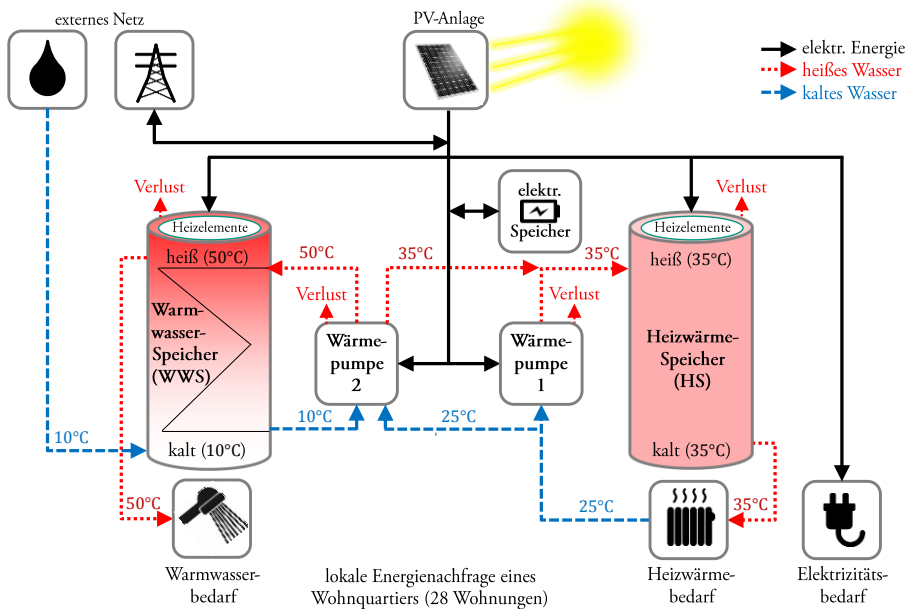


Abb. 8.1: Aufbau des Energiesystems des Wohnquartiers (in Anlehnung an Schwarz et al. 2018b).

Die PV-Anlage des Quartiers soll hälftig nach Osten und Westen ausgerichtet sein. Dadurch steht dem Quartier mehr PV-Energie in den Morgen- und Abendstunden zur Verfügung. Bei dieser Ausrichtung ermöglicht die Dachfläche des Quartiers eine maximale Anlagenkapazität von 75 kW_p. PV-Überschüsse können entweder ins externe Netz eingespeist werden oder im thermischen Speicher (über Wärmepumpen und Heizelemente) oder elektrischen Speicher gespeichert werden, abhängig von der entsprechenden Investitionsentscheidung. Als elektrischer Speicher kommt eine generische Lithium-Ionen-Batterie zum Einsatz (siehe Abschnitt 6.3.2).

Das Heizsystem ist in zwei Kreisläufe separiert. Jedes besitzt seinen eigenen Wasserspeicher in Kombination mit Luft-Wasser-Wärmepumpen, die in Abhängigkeit von der Außenlufttemperatur im zweistufigen Betrieb unter Halb- oder Volllast betrieben werden können (bei 15 °C Lufttemperatur: 60 bzw. 120 kW_{th}). Im Warmwasser(WW)-Kreislauf wird Frischwasser von einem externen Wasserversorger bezogen und von 10 auf 50 °C aufgeheizt. Der Kreislauf für Raumwärme (RW) wird bei einer niedrigeren Temperatur von 35 °C mit einem Temperaturhub von 10 K betrieben, wodurch sich eine bessere Jahresarbeitszahl der Wärmepumpen für RW und ein geringerer Wärmeverlust im Speicher ergeben. Durch den geringeren Temperaturhub im Vergleich zum WW-Speicher ergibt sich bei gleichem Speichervolumen ein geringerer Speicherinhalt. Bei sehr kalten Außenlufttemperaturen und hoher RW-Nachfrage können zusätzlich die Wärmepumpen des WW-Kreislaufs zur RW-Deckung eingesetzt werden. Heizelemente in den thermischen Speichern sichern die thermische Deckung in Spitzennachfragezeiten sowie die gesetzlich geforderte Desinfektionsfunktion im WW-Speicher. Für RW und WW kann jeweils eine Leistung von bis zu 24 kW_{th} bei einem Wirkungsgrad von 95 % angesetzt werden. Die Heizelemente können modular betrieben werden: Deren bereitgestellte Wärmeenergie kann beliebige Werte bis zur maximalen Heizleistung annehmen.

Die Optimierungsaufgabe besteht in der Minimierung der Gesamtenergiekosten des Quartiers unter Unsicherheit und beinhaltet Investitions- und Betriebsentscheidungen. Bei der Investitionsplanung werden die optimalen Größen der verschiedenen Systemkomponenten gesucht. Bei der Betriebsoptimierung kann Wärmebedarf zu Zeiten im Sinne der Kostenminimierung (bei PV-Überschüssen, ggf. bei niedrigen Strompreisen oder zur Bezugslastsenkung) mittels Wärmepumpe und -speicher verschoben werden. Nicht eingespeister PV-Überschuss und Elektrizitätsbedarf des Quartiers können durch einen elektrischen Speicher zeitlich zusammengebracht werden. Daneben kann der elektrische Speicher zum Handel mit dem externen Energieversorger genutzt werden. Die Energiekosten können darüber hinaus durch Minimierung der Speicher- und Anfahrverluste der Wärmepumpen sowie durch Vermeidung der Nutzung der ineffizienten Heizelemente weitergesenkt werden.

8.2 Allgemeine Annahmen

In allen betrachteten Fällen gilt es, die minimalen erwarteten Gesamtenergiekosten der Investitions- und Einsatzplanung des Wohnquartiers aus Sicht des privaten Entscheiders zu finden, mit dem Startdatum am 1. Januar 2016 und einem Betrachtungshorizont von 20 Jahren. Für alle Energiesystemkomponenten wird eine Lebensdauer von 20 Jahren angenommen. Als Input für die Investitions- und Einsatzplanungsoptimierung werden mit Markov-Prozessen 100 Wetterszenarien für ein Jahr mit 15-min-Auflösung generiert, welche die unsichere Globalstrahlung, Temperatur und Bewölkung abbilden (siehe Abschnitt 6.1). Diese Profile werden in PV-Angebotsprofile und Energienachfrageprofile für Strom, RW und WW transformiert (siehe Abschnitt 6.2) und für den gesamten Betrachtungshorizont verwendet. Es werden monokristalline Silizium-Module von Sunpower (2015) modelliert und deren Schwachlicht- und Temperaturverhalten nachgebildet (Modulleistung und Wirkungsgrad nominell: 333 W bzw. 20,4 %). Es kommen zweistufige Luft-Wasser-Wärmepumpen der Firma Dimplex zum Einsatz. Die Anschaffungskosten liegen gemäß eingeholtem Angebot bei 25.500 € je Stück, wovon geschätzte 1,5 % p. a. als Instandhaltungskosten anfallen (Dimplex 2014). Laut Hersteller betragen die Verluste beim Anfahren 5 % des Lastwechsels. Die Wärmepumpen können nur im Leerlauf, bei Halb- oder Volllast betrieben werden ($\mathbf{z}_{t,u,\omega,\theta} \in \mathbb{Z}_+$ und $m = 2$ mögliche Heizleistungsstufen je Wärmepumpe). Auf Basis des Datenblatts von Dimplex (2013) werden temperaturabhängige Heizleistung und Leistungszahl abgeleitet. Die Leistungszahl wird bei Halb- und Volllast vereinfacht als gleichwertig angenommen. Für die zweistufige Heizleistung d^{hp} der Wärmepumpe wird eine lineare Abhängigkeit von der Außenlufttemperatur T^{amb} in °C abgeleitet:

$$d^{\text{hp}} = (49,2 + 1,36 \cdot T^{\text{amb}})/2 \cdot z \quad \text{mit } z \in \{0,1,2\}, \quad (8.1)$$

sowie für die Leistungszahl für Raumwärme (35 °C)

$$\text{COP}^{\text{RW}} = 3,467 + 0,0733 \cdot T^{\text{amb}}, \quad (8.2)$$

und für die Leistungszahl für Warmwasser (55 °C)

$$\text{COP}^{\text{WW}} = 2,587 + 0,0543 \cdot T^{\text{amb}}. \quad (8.3)$$

Die Anzahl der Heizelemente ist aufgrund der ausgewählten thermischen Speicher mit $\mathbf{x}_{i=\text{HE}_u} = 2$ vorgegeben. Der Wirkungsgrad der Heizelemente liegt bei $\eta_{\theta}^{\text{HE}} = 95\%$. Für den elektrischen Speicher wird eine maximale C-Rate von eins, eine Ladeeffizienz $\eta_{\theta}^{\text{ES}}$ von 94 % und eine Selbstentladung von 2 % pro Monat angenommen. Der minimale thermische und elektrische Speicherstand wird auf null gesetzt ($\check{\mathbf{s}}_{t,u,\omega,\theta}^{\text{TS}} = 0, \check{\mathbf{s}}_{t,\omega,\theta}^{\text{ES}} = 0$).

Weitere allgemeine Modellannahmen für die Energiesystemkomponenten des Wohnquartiers sind in Tab. 8.1 gelistet.

Tab. 8.1: Allgemeine Modellannahmen der Energiesystemkomponenten des Wohnquartiers für alle betrachteten Fälle (Dimplex 2014; Schwarz und Bertsch 2014; Kaschub et al. 2016; Wirth 2016).

	PV-Anlage	Wärmepumpe	RW-Speicher	WW-Speicher	Elektr. Speicher
Anschaffungskosten (netto)					
fix c_i^{fix}	1.000 €	0 €	436 €	610 €	0 €
variabel c_i^{var}	1.300 €/kW _p	25.500 €/St.	91,8 €/kWh _{th}	70,7 €/kWh _{th}	600 €/kWh _{el}
Maintenance-Faktor MF_i	1,5 %	1,5 %	1,5 %	1,5 %	1 %
Degradationsfaktor DF_i	16 %	0 %	0 %	0 %	20 %
Lebensdauer L_i	20 Jahre	20 Jahre	20 Jahre	20 Jahre	20 Jahre
Verluste	(siehe Abschnitt 6.2.1)	5 % des Lastwechsels beim Anfahren	0,3 % des Speicherstands je 15 min	0,6 % des Speicherstands je 15 min	0,0007 % des Speicherstands je 15 min 6 % bei Be-/Entladung
Allgemeine Restriktionen	≤ 75 kW _p	Heizangebot ≤ Lufttemperaturbedingte max. Heizleistung	Speicherlevel ≤ max. Kapazität	Speicherlevel ≤ max. Kapazität	Speicherlevel ≤ max. Kapazität Be-/Entladen ≤ max. Be-/Entladeleistung

Die fixen und variablen Anschaffungskosten aller Energiesystemkomponenten sind zum Zeitpunkt der Entscheidung bekannt, ebenso die gesetzlich garantierte PV-Einspeisevergütung i. H. v. 11 ct€/kWh. Des Weiteren wird unterstellt, dass Lebensdauer, Degradation und Instandhaltungskosten aller Komponenten sicher bekannt sind. Als Strafkosten für jede nicht gedeckte Kilowattstunde werden 10.000 €/kWh_{th} für thermische Hilfsenergie und 100.000 €/kWh_{el} für elektrische Hilfsenergie angesetzt. Hilfsenergie wird benötigt, wenn das lokal verfügbare Energieangebot zur Deckung der Nachfrage-Restriktionen nicht ausreicht. Die Kompensationsfaktoren entsprechen dem Preis, der vom Entscheider bei Nichtdeckung einer Kilowattstunde in Kauf genommen

wird. Die hohen Kompensationsfaktoren führen bei Verwendung von Hilfsenergie zu einer hohen monetären Bestrafung, um generell Investitionen zu ermitteln, die grundsätzlich alle Restriktionen des Quartiers erfüllen können.

Die mit Risiko behafteten Parameter für jeden Fall θ sind:

- PV-Angebot (abhängig von 15-min-Globalstrahlung und Außenlufttemperatur),
- thermisches Angebot und Leistungszahl der Luft-Wasser-Wärmepumpen (abhängig von 15-min-Außenlufttemperatur),
- elektrische und thermische Nachfrage des Wohnquartiers (abhängig von Wochentag, Monat, Jahreszeit sowie Tagesstemperatur und tägl. Bewölkungsgrad),
- GH-Preise für den Kauf und Verkauf elektrischer Energie (abhängig von Wochentag, Monat, Jahreszeit und tägl. Globalstrahlung).

Für die Berücksichtigung ungewisser Unsicherheiten werden zum Referenzfall θ_{Ref} sechs weitere Alternativfälle gebildet, welche mit der gleichen Ungewissheit wie der Referenzfall eintreten, ohne deren genaue Eintrittswahrscheinlichkeiten zu kennen. Das Eintreten des Referenzfalls oder der Alternativfälle ist exogen gegeben: Der Entscheider hat keine Möglichkeit, den Eintritt eines (ungewissen) Falls aktiv zu beeinflussen. Die Anzahl der Alternativfälle der Regret-Minimierung ist aufgrund des Rechenaufwands des stochastischen Programms auf sechs beschränkt. Mit Bezug zum energiewirtschaftlichen Rahmen in Kapitel 2 und 3 wurden auf Basis verschiedener Studien die plausibelsten Fälle ausgewählt. Dazu gehören die in Abschnitt 2.1.4 vorgestellten Studien zur langfristigen Entwicklungen der Strompreise und -tarife einschließlich der gesetzlichen Eigenverbrauchsabgabe (EVA) für PV-Strom sowie der in Abschnitt 3.4 beschriebene individuelle, inflationsabhängige Kalkulationszins:

Fall 1: Referenz (Ref) mit gleichbleibenden Marktbedingungen von 2016,

Fall 2: hoher Arbeitspreis (H-AP) gemäß der Studie von Schlesinger et al. (2014),

Fall 3: hohe Eigenverbrauchsabgabe (H-EVA) gemäß der Studie vom Öko-Institut (2015),

Fall 4: dynamischer Preis (DP) gemäß Schwarz et al. (2018b),

Fall 5: Leistungspreis (CP) gemäß Kaschub (2017) und Schwarz et al. (2018b),

Fall 6: hoher Kalkulationszins (H-Zins), mittlere 20-Jahre-Dax-Rendite gemäß Abschnitt 3.4,

Fall 7: niedriger Kalkulationszins (N-Zins), min. 20-Jahre-Dax-Rendite gemäß Abschnitt 3.4.

In Tab. 8.2 sind die ungewissen Parameter Arbeits-, Leistungs- und GH-Preis sowie PV-EVA und Kalkulationszins für alle betrachteten Fälle aufgeführt. Daneben sind die zwei Sonderfälle niedriger Arbeitspreis (I: N-AP) und vollständige Autarkie ohne externen Netzanschluss (II: Autark) enthalten, die nicht in die Regret-Minimierung einfließen.

Tab. 8.2: Fallbeschreibung für ungewisse Parameter (nur Parameteränderungen im Vergleich zum Referenzfall sind eingetragen, bei leeren Zellen entspricht der Parameterwert dem des Referenzfalls).

Ungewisse Parameter	Fall 1	Fall 2	Fall 3	Fall 4	Fall 5	Fall 6	Fall 7	I N-AP	II Autark
	Ref	H-AP	H-EVA	DP	CP	H-Zins	N-Zins		
Arbeitspreis in ct_{ϵ}/kWh_{el}	29	39,5	33,5	\emptyset 29 [-2;49,5]	22,8			8,7	∞
Leistungspreis in ϵ/kW_{el}	0				18			48	
GH-Preis in ct_{ϵ}/kWh_{el}	\emptyset 3,2 [-22,7;20,6]	\emptyset 7,5 [-18,4;24,9]	\emptyset 4 [-21,9;21,4]						∞ (0 bei Verk.)
PV-EVA in ct_{ϵ}/kWh_{el}	2,5	2,9	6,9						0
Kalkulationszins	4,5 %					7,7 %	2 %		

Bei den Alternativ- und Sonderfällen sind nur Parameteränderungen im Vergleich zum Referenzfall eingetragen. Eine leere Zelle bedeutet keine Veränderung des Parameters gegenüber dem Referenzfall. Alle Fälle und deren Rechenergebnisse werden in den folgenden Abschnitten einzeln im Detail vorgestellt.

Für alle betrachteten Fälle gilt der Hinweis, dass die verwendete Annuitätenmethode, auch unter der Annahme gleicher jährlicher Energiebezüge und -veräußerungen für alle Perioden gemäß Gleichung (4.3), bereits einen inflationären Preisverlauf im Betrachtungshorizont berücksichtigt. Die angegebenen Strompreise sowie die PV-EVA entsprechen in allen Fällen einem realen Verlauf über den Betrachtungshorizont von 20 Jahren. Dabei wird die durchschnittliche Inflationsrate der letzten 20 Jahre (1996–2015) von 1,4 % p. a. angewendet. Abb. 8.2 zeigt den nominalen (nicht inflationsbereinigten) und realen (inflationsbereinigten) Verlauf des jährlichen Arbeitspreises, der PV-EVA und des GH-Preises für die Fälle 1–3 (Ref, H-AP und H-EVA) bis zum Ende des Betrachtungshorizonts.




Abb. 8.2: Jährlicher Arbeitspreis (links), PV-Eigenverbrauchsabgabe (mittig) und Großhandelspreis (rechts) für die Fälle 1–3 (Ref, H-AP und H-EVA): nominal (durchgehende Linie) und inflationsbereinigt mit 1,4 % p. a. (gepunktete Linie) für den Betrachtungshorizont von 20 Jahren.

Für die Ausführung des gesamten Programms (aus Abschnitt 6.3) werden die 100 Szenarien durch die Fixierung der Erststufen-Variablen (Investition in PV-Anlage, Wärmepumpen sowie RW-, WW- und elektr. Speicher) entkoppelt (siehe Abschnitt 7.1.1). Aufgrund der extremen Problemgröße eines Szenarios ist zusätzlich die einjährige Periode T jedes Szenarios in 52 einwöchige Subszenarien durch Fixierung der Speicherinhalte beim Wochenwechsel zerlegt (52 fixierte Speicherstände pro Speicher und Szenario).⁴⁵ Die daraus resultierenden 5 200 Subprogramme werden reduziert⁴⁶ und parallel mit der in Kapitel 7 entwickelten Methodik zur Optimierung dezentraler Energiesysteme für jeden Fall θ seriell ausgeführt. Die fixierten Erststufen-Variablen der Investition werden im Masterprogramm durch den SAHC-Algorithmus optimiert. Die fixierten Speicherstände pro Speicher und Szenario der zweiten Stufe werden mit Werten vorgegeben, um Rechenzeit einzusparen: Für RW werden sie auf null gesetzt, da in etwa fünf von zwölf Monaten keine RW-Nachfrage vorliegt, für WW wird der Speicherstand auf 50 % der

⁴⁵ Der gewählte Zeitraum von einer Woche für die Subprogramme führt zu einer effizienten Nutzung der HPC-Systeme hinsichtlich Genauigkeit, Rechenbedarf und Gesamtrechenzeit.

⁴⁶ Im Referenzfall können mithilfe der Szenarioreduktion die Subprogramme auf 1 865 reduziert werden, ohne die optimale Investition zu verändern oder den optimalen Zielwert wesentlich zu beeinflussen; diese werden auch für die Optimierung der Alternativ- und Sonderfälle verwendet.

maximalen Speicherkapazität eingestellt, da eine gute Schätzung nicht möglich ist. Die entstandene Fehlerabweichung des optimalen Zielwerts im Referenzfall liegt unter 0,2 %.

Zu Beginn des SAHC wird jedes Subprogramm mit geringerer Genauigkeit (MIP-Gap < 2 %) innerhalb weniger Minuten ausgeführt. Nur für die letzten Iterationen des SAHC ist die Rechenzeit auf eine halbe Stunde begrenzt, um die Genauigkeit zu erreichen, die der SAHC-Algorithmus benötigt, um das Optimum zu finden (MIP-Gap < 1 %).⁴⁷ Für einen guten Ausgangspunkt wurde jeder Fall initial mit einem repräsentativen Szenario optimiert. Anschließend sind weniger als 20 Schritte für die Optimierung des Masterprogramms je Fall θ notwendig, um die optimale Investition zu finden.

8.3 Referenzfall

Im Referenzfall θ_{Ref} sind die optimalen Entscheidungen für Investition und Betrieb des Wohnquartiers gesucht – unter den vorliegenden Bedingungen im Jahr 2016, die sich über den Betrachtungshorizont von 20 Jahren nicht ändern. Der Fall tritt mit der gleichen Ungewissheit wie die im folgenden Abschnitt 8.4 beschriebenen Alternativfälle ein. Es werden ein unveränderter Strompreis des externen Energieversorgers von 29 ct_€/kWh_{el} angenommen sowie die Option, elektrisch gespeicherte Energie zum GH-Preis zu verkaufen. Der GH-Preis liegt im Durchschnitt bei 3,2 ct_€/kWh_{el} und kann von –22,7 bis 20,6 ct_€/kWh_{el} schwanken.⁴⁸ Die PV-Einspeisevergütung liegt bei 11 ct_€/kWh_{el}, die PV-Eigenverbrauchsabgabe bei 2,5 ct_€/kWh_{el}.⁴⁹ Des Weiteren wird für die Bewertung der Investition von einer Verzinsung i. H. v. 6 % ausgegangen (min. nominale DAX-Rendite mit 20-jähriger Haltedauer, siehe Abschnitt 3.4). Mit einer Inflationsrate i. H. v. 1,4 % p. a. (geom. Mittel der letzten 20 Jahre) ergibt sich nach Gleichung (3.1) ein Kalkulationszins von 4,5 %. Ungewisse Modellparameter, bei denen die Eintrittswahrscheinlichkeiten nicht bekannt sind, etwa langfristige Strompreise oder der Kalkulationszins, werden im Referenzfall als unverändert angenommen.

⁴⁷ Es ist zu beachten, dass mit dem verwendeten SAHC-Algorithmus eine lokale, jedoch keine globale Optimalität garantiert werden kann.

⁴⁸ Die GH-Preise basieren auf EPEX-Preisen von 2012 bis 2016 (siehe Anhang A); es sind keine Mehrwertsteuer sowie andere staatliche Steuern und Abgaben oder Vertriebsprovisionen enthalten.

⁴⁹ Die 2,5 ct_€/kWh_{el} ergeben sich nach Gleichung (4.3) aus der annualisierten, um den Kalkulationszins diskontierten Summe: 35 % der EEG-Umlage im Jahr 2016 (2,22 ct_€/kWh_{el}) und der bereits in 2016 feststehenden 40 % der EEG-Umlage ab 2017 (2,54 ct_€/kWh_{el}) bis 2035.

Die minimalen erwarteten Gesamtenergiekosten für den Referenzfall θ_{Ref} liegen bei 29.978 €. Die optimalen Kapazitäten für die Energiesystemkomponenten sind:

Wärmepumpen: $x_{i=\text{WP},\theta=\text{Ref}} = 2$ Stück,

PV-Anlage: $x_{i=\text{PV},\theta=\text{Ref}} = 59,8$ kW_p,

RW-Speicher: $x_{i=\text{RW},\theta=\text{Ref}} = 18,6$ kWh_{th},

WW-Speicher: $x_{i=\text{WWS},\theta=\text{Ref}} = 60,4$ kWh_{th},

Elektrischer Speicher: $x_{i=\text{ES},\theta=\text{Ref}} = 0$ kWh_{el}.

Insgesamt werden durch Auszahlungen für die Investition 43 % der erwarteten Gesamtenergiekosten verursacht (PV-Anlage: 24 %, Wärmepumpen: 16 %, therm. Speicher: < 3 %). Der elektrische Speicher wird im Referenzfall nicht ausgebaut. Der größte Teil der erwarteten Gesamtenergiekosten wird durch die erwarteten Betriebskosten (57 %) verursacht. Abb. 8.3 zeigt die Kostenaufteilung der Investitions- und Einsatzplanung in einem Kreisdiagramm.

Um einen Überblick über die jährlichen Energieflüsse des Wohnquartiers zu vermitteln, sind diese in folgender Abb. 8.4 als Energieflussdiagramm dargestellt (in Anlehnung an Abb. 6.4). Repräsentativ für die Energieflüsse der 100 Szenarien werden nur deren Mediane angegeben.

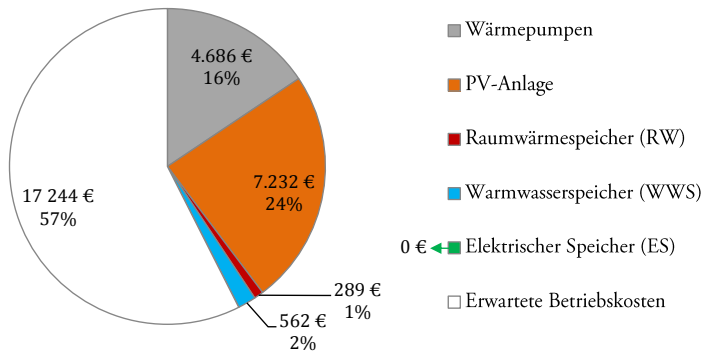


Abb. 8.3: Kostenaufteilung der Investitions- und Einsatzplanung im Referenzfall θ_{Ref} .

2. Energy setup of one heating cluster

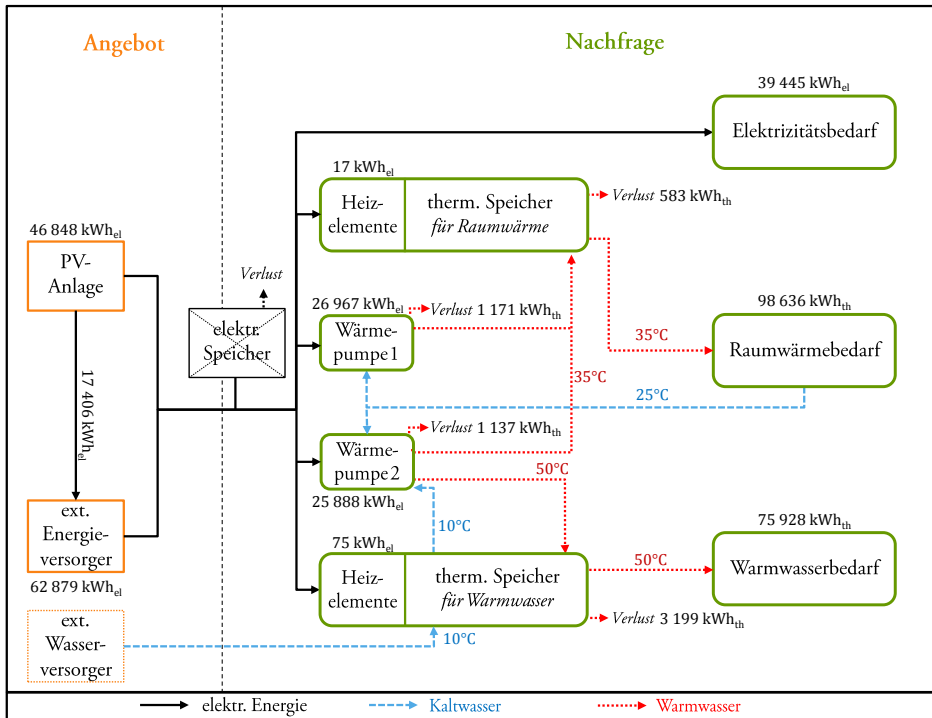


Abb. 8.4: Energieflussdiagramm des Wohnquartiers für 100 Szenarien des Referenzfalls (Jahreswerte). Aufgrund der verwendeten Mediane stimmt die Bilanz zwischen Energieangebot und -nachfrage nur näherungsweise überein.

Die Variation der wichtigsten Energieflüsse und weiterer charakteristischer Werte enthält Abb. 8.5 anhand verschiedener Streumaße der 100 Szenarien: Minimum, 25%-Quantil, Median, 75%-Quantil und Maximum. Daneben werden die Werte als um 90° gedrehte Box-and-Whisker-Plots dargestellt. Die dargestellten Streumaße weisen bei gegebener optimaler Investitionsentscheidung (1. Stufe) auf die Abweichungen im Betrieb (2. Stufe) hin.

Fallstudie zur Optimierung eines Wohnquartiers unter Unsicherheiten

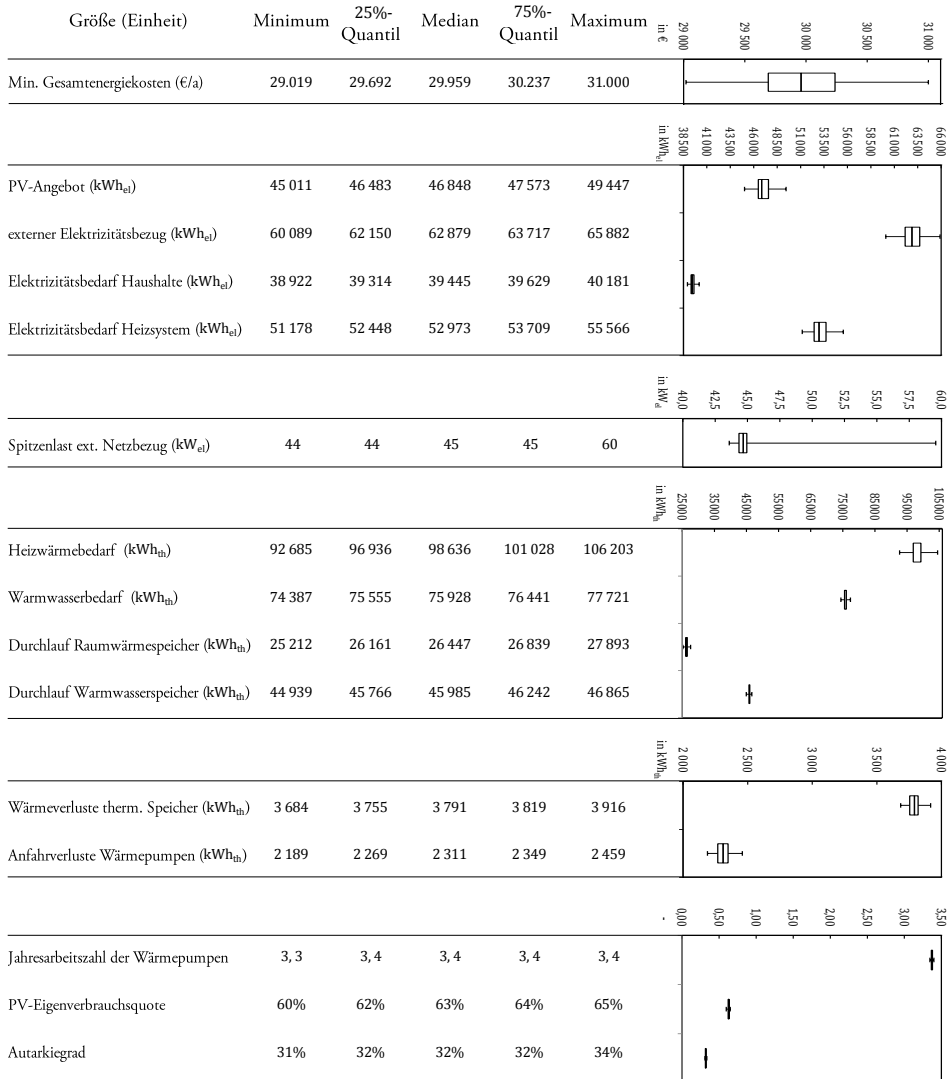


Abb. 8.5: Charakteristische Werte und deren Streuung von 100 Szenarien für die opt. Lösung des Referenzfalls, rechts als Box-and-Whisker-Plot gezeigt (Whiskers stellen min. und max. Werte dar).

Die minimalen Gesamtenergiekosten für die berechnete optimale Investitionsplanung, bei kostenminimaler Einsatzplanung je Szenario, betragen mindestens 29.019 € und maximal 31.000 €. Die jährliche PV-Versorgung variiert zwischen 45 011 kWh_{el} und 49 447 kWh_{el} aufgrund der wetterbedingten Unsicherheiten. Dabei variiert der spezifische PV-Ertrag um ca. 10 % pro Jahr (753 bis 827 kWh_{el}/kW_p). Das entspricht der

jährlichen Schwankung der Globalstrahlung in Karlsruhe (IMK 2018: 2000–2016). Der Elektrizitätsbedarf der Haushalte schwankt zwischen 38 922 und 40 181 kWh_{el} und des Heizsystems (Wärmepumpen u. Heizelemente) zwischen 51 178 und 55 566 kWh_{el}. Dabei durchlaufen insgesamt 25 212 bis 27 893 kWh_{th} den RW-Speicher (Ø Speicherstand: 29 %) und 44 939 bis 46 865 kWh_{th} den WW-Speicher (Ø Speicherstand: 25 %).

Der unterschiedliche Elektrizitätsbedarf des Heizsystems resultiert aus unterschiedlichen RW- und WW-Bedarfen der 100 Szenarien sowie der damit verbundenen thermischen Speicherverluste (3 684 bis 3 916 kWh_{th}) und Anfahrverluste der Wärmepumpen (2 189 bis 2 459 kWh_{th}). Die Jahresarbeitszahl liegt zwischen 3,3 und 3,4, welche sich auf das gesamte Wärmeangebot und den gesamten elektrischen Bedarf beider Wärmepumpen bezieht.

Insgesamt können 60 bis 65 % der PV-Energie zur Deckung des Elektrizitätsbedarfs genutzt werden. Die restliche elektrische Energie muss vom externen Netz (60 089 bis 65 882 kWh_{el}) bezogen werden. Daraus folgt ein Autarkiegrad von 31 bis 34%.⁵⁰ Der rein bilanzielle Autarkiegrad liegt bei 48 bis 53%. Die vom Netz bezogene Spitzenlast liegt zwischen 44 und 60 kW_{el}. Abb. 8.6 zeigt den maximalen und minimalen Bereich der Lastdauerlinie für Netzbezug und PV-Einspeisung.




Abb. 8.6: Lastdauerlinienbereich von 100 Szenarien des Referenzfalls (ext. Netzbezug und PV-Einspeisung).

⁵⁰ Der Autarkiegrad ergibt sich aus dem Verhältnis des gesamten PV-Eigenverbrauchs zum gesamten Elektrizitätsbedarf des Quartiers über das ganze Jahr. Vollständige Autarkie liegt vor, wenn der gesamte Elektrizitätsbedarf des Quartiers durch die Energie der PV-Anlage gedeckt wird. Der bilanzielle Autarkiegrad ist das Verhältnis der gesamten PV-Energie zum gesamten Elektrizitätsbedarf des Quartiers.

8.4 Alternativfälle

Neben dem oben beschriebenen Referenzfall werden in der vorliegenden Arbeit noch sechs Alternativfälle mit ungewissen Parametern optimiert: mit abweichendem Arbeitspreis oder PV-Eigenverbrauchsabgabe (Abschnitt 8.4.1), dynamischem Arbeitspreis oder Leistungspreis (Abschnitt 8.4.2) oder abweichendem Kalkulationszins (Abschnitt 8.4.3). Da die Eintrittswahrscheinlichkeiten weder beim Referenzfall noch bei den Alternativfällen bekannt sind, sind alle Fälle gleich ungewiss. Es wird angenommen, dass der Entscheider das Eintreten eines bestimmten Falls nicht beeinflussen kann. Die spezifischen Annahmen der Alternativfälle werden in den folgenden Unterabschnitten im Detail vorgestellt. Die Ergebnisse sind im letzten Unterabschnitt 8.4.4 zusammengefasst dargestellt.

8.4.1 Erhöhter Arbeitspreis oder PV-Eigenverbrauchsabgabe

Als zweifellos sicher gilt der Strompreis nur im ersten Zeitschritt des Betrachtungshorizonts. Die Annahme eines unveränderten Strompreises über 20 Jahre ist ungewiss. Dies zeigen auch die in Abschnitt 2.1.4 aufgeführten Studien zur Strompreisentwicklung bis 2035: Sowohl Preiserhöhungen und -senkungen in verschiedensten Variationen über die Zeit sind denkbar, jedoch lassen sich keine Eintrittswahrscheinlichkeiten hierfür erfassen. Ältere Studien haben dabei den Nachteil, dass sie absolute Preise nennen, die von denen des aktuellen Basisjahrs erheblich abweichen. Des Weiteren hängen Arbeits- und GH-Preis sowie die an die EEG-Umlage gebundene PV-Eigenverbrauchsabgabe voneinander ab. Daher wird eine geschlossene Betrachtung dieser Preise über den gesamten Betrachtungshorizont als am sinnvollsten erachtet. Aus diesem Grund werden die jüngsten vorliegenden Studien von Schlesinger et al. (2014) und dem Öko-Institut (2015) als Fälle für die Regret-Minimierung berücksichtigt, die die Entwicklung von Arbeits- und GH-Preis sowie EEG-Umlage von 2015 bis 2035 gesamtheitlich abbilden.

Die Studie von Schlesinger et al. (2014) wird als hoher Arbeitspreis(H-AP)-Fall bezeichnet, weil hier die höchsten Arbeitspreise im Vergleich zu allen anderen Studien erwartet werden: nominal gesehen bis nahezu $50 \text{ ct}_e/\text{kWh}_{el}$ im Jahr 2035, real mit einer Inflationsrate von $1,4\% \text{ p. a.}$ immerhin noch $37 \text{ ct}_{e,2016}/\text{kWh}_{el}$ (siehe Abb. 8.2). Der Verlauf des Arbeitspreises der Studie entspricht einem durchschlichen nominalen Preisanstieg von $3,5\% \text{ p. a.}$ bis 2035. Der annualisierte, aufsummierte und abgezinste Arbeitspreis beträgt nach Gleichung (4.3) (mit $k = 4,5\%$ und $L = 20$) $39,5 \text{ ct}_e/\text{kWh}_{el}$, der in die entwickelte Optimierungsebene Θ -DES (Abschnitt 6.3) als Parameter eingeht.

Entsprechend ergeben sich für den GH-Preis $7,5 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$. Kurzfristige Preisschwankungen des 15-min-GH-Preises können $-18,4$ bis $24,9 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$ innerhalb eines Jahres erreichen (basierend auf EPEX-Preisen von 2012 bis 2015, siehe Anhang A). Für die PV-Eigenverbrauchsabgabe ergeben sich $2,9 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$, mit 35 % der EEG-Umlage im Jahr 2016 und 40 % der Umlage ab 2017 bis 2035.

Der Fall mit hoher Eigenverbrauchsabgabe (H-EVA) basiert auf der Studie des Öko-Institut (2015) mit den höchsten EEG-Umlagen im Vergleich zu allen anderen Studien (nominal bis zu $8,6 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$), die ja maßgebend für die Abgaben des PV-Eigenverbrauchs sind. Damit ist die Studie auch am nächsten an den bereits bekannten EEG-Umlagen von 2016 und 2017. Um den ungewissen Fall einer hohen PV-Eigenverbrauchsabgabe zu berücksichtigen, werden 35 % im Jahr 2016, 40 % im Jahr 2017 und 100 % von 2018 bis 2035 der EEG-Umlage angesetzt.⁵¹ Dadurch ergeben sich PV-Eigenverbrauchsabgaben nominal von bis zu $8,6 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$ im Jahr 2023, die 2035 auf $5,9 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$ zurückgehen (real $7,7$ bzw. $4,5 \text{ ct}_{\epsilon 2016}/\text{kWh}_{\text{el}}$ mit einer Inflationsrate von $1,4 \%$ p. a.). Aufgrund des hohen Anteils von 100 % der EEG-Umlage entspricht der Verlauf bis 2035 einem durchschnittlichen nominalen Anstieg von $6,1 \%$ p. a. Für die Optimierungsebene Θ -DES ergibt sich, (annualisiert, aufsummiert und abgezinst nach Gleichung (4.3) mit $k = 4,5 \%$ und $L = 20$), eine PV-Eigenverbrauchsabgabe von $6,9 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$. Entsprechend ergibt sich ein Arbeitspreis von $33,5 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$. Für den GH-Preis ergeben sich $4 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$, die innerhalb eines Jahres zwischen $-21,9$ und $21,4 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$ schwanken können.

8.4.2 Dynamischer Arbeitspreis oder Leistungspreis

Einhergehend mit dem gesetzlich auferlegten Smart-Meter-Rollout können zukünftig verschiedene Stromtarife für Haushalte eingeführt werden. Deshalb werden die Fälle mit dynamischem Arbeitspreis (DP) und mit Leistungspreis (CP) in der Regret-Minimierung des privaten Entscheiders berücksichtigt. Annahmen über den GH-Preis, die PV-Eigenverbrauchsabgabe und den Kalkulationszins sind unverändert gegenüber dem Referenzfall.

Im DP-Fall werden dynamische Endverbraucher- und GH-Preise angesetzt, die im Durchschnitt 29 bzw. $3,2 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$ betragen (beide Preise werden, wie im Abschnitt

⁵¹ Der Sprung von 40 auf 100 % entspricht einer pessimistischen Haltung gegenüber der PV-Eigenverbrauchsabgabe aus Sicht des privaten Entscheiders.

6.2.3 beschrieben, erzeugt). Die dynamischen 15-min-Arbeitspreise liegen zwischen -2 und $49,5 \text{ ct}_\text{€}/\text{kWh}_{\text{el}}$ (basierend auf EPEX-Preisschwankungen von 2012 bis 2015), der GH-Preis zwischen $-22,7$ und $20,4 \text{ ct}_\text{€}/\text{kWh}_{\text{el}}$ (wie im Referenzfall).

Der CP-Fall entspricht der Möglichkeit, dass der externe Energieversorger auf einen arbeits- und leistungspreisbasierten Tarif umsteigt. Der abgerufene maximale Netzbezug vom externen Energieversorger (Spitzenlast) wird über einen Leistungspreis in $\text{€}/\text{kWh}_{\text{el}}$ verrechnet. Wie bei Kaschub (2017) und Schwarz et al. (2018b) werden im CP-Fall die im Arbeitspreis enthaltenen Netzentgelte i. H. v. $7 \text{ ct}_\text{€}/\text{kWh}_{\text{el}}$ (2015) vom Arbeitspreis abgezogen und die Spitzenlast mit $18 \text{ €}/\text{kWh}_{\text{el}}$ bepreist.⁵² Damit verringert sich der Arbeitspreis im Vergleich zum Referenzfall auf $22,5 \text{ ct}_\text{€}/\text{kWh}_{\text{el}}$. Es wird davon ausgegangen, dass der GH-Preis unberührt bei durchschnittlich $3,2 \text{ ct}_\text{€}/\text{kWh}_{\text{el}}$ bleibt.

8.4.3 Abweichender Kalkulationszins

Die Entwicklung des Kapitalzins, die ja einen erheblichen Einfluss auf die Investitionsentscheidung hat (gemäß Gl. 3.1), ist ungewiss. Für die Berücksichtigung dieser Ungewissheit werden die Fälle mit hohem Kalkulationszins (H-Zins) und niedrigem Kalkulationszins (N-Zins) in der Regret-Minimierung berücksichtigt. Alle anderen Annahmen gleichen dem Referenzfall.

Für den H-Zins-Fall wird für die Bewertung der Investition im Vergleich zum Referenzfall nicht von der minimalen, sondern der durchschnittlichen nominalen Dax-Rendite mit 20-jähriger Haltedauer i. H. v. $9,2 \%$ p. a. als Verzinsung ausgegangen (statt 6% , siehe Abschnitt 3.4). Mit der Inflationsrate i. H. v. $1,4 \%$ p. a. ergibt sich nach Gleichung (3.1) ein Kalkulationszins von $7,4 \%$.

Im N-Zins-Fall wird für die Bewertung der Investition von der gleichen Verzinsung wie im Referenzfall i. H. v. 6% p. a. ausgegangen, jedoch die höchste mittlere Inflationsrate über 20 Jahre angesetzt, die in den letzten 50 Jahren aufgetreten ist: $3,9 \%$ p. a. Damit ergibt sich ein Kalkulationszins von 2% . Es sei angemerkt, dass mit dem H-Zins- und N-Zins-Fall verschiedene Kombinationen aus möglicher Kapitalverzinsung und Inflationsrate abgedeckt werden, die zum gleichen Kalkulationszins führen.

⁵² Gemäß Kaschub (2017) entsprechen $18 \text{ €}/\text{kWh}_{\text{el}}$ den Netzentgelten von 208 € , die jeder Haushalt mit einer mittleren Last von ca. $11,5 \text{ €}/\text{kWh}_{\text{el}}$ pro Jahr durchschnittlich mit dem Endverbraucherpreis zahlt. Die Kosten je Haushalt i. H. v. 208 € ergeben sich aus einem mittleren Elektrizitätsbedarf von $3\,200 \text{ kWh}_{\text{el}}$ (der 40 Millionen deutschen Haushalte), multipliziert mit den Netzentgelten von $0,065 \text{ €}/\text{kWh}_{\text{el}}$ im Jahr 2014.

8.4.4 Rechenergebnisse der Alternativfälle

Die optimalen, berechneten Kapazitäten der Energiesystemkomponenten des Wohnquartiers für diese sechs Alternativfälle im Vergleich zum Referenzfall werden in Abb. 8.7 gezeigt.




Abb. 8.7: Optimale Kapazitäten der Energiesystemkomponenten der Fallstudie für den Referenzfall (Ref) und die sechs Alternativfälle: hoher Arbeitspreis (H-AP), hohe Eigenverbrauchsabgabe (H-EVA), dynamischer Preis (DP), Leistungspreis (CP) sowie hoher und niedriger Kalkulationszins (H-Zins bzw. N-Zins). Daneben ist im rechten Diagramm die jeweils maximal aus dem externen Netz bezogene elektrische Energie (Spitzenlast) aufgetragen und der rechten Ordinate zugeordnet.

Die genauen Zahlenwerte sind in Tab. 8.3 enthalten, die zusätzlich weitere Berechnungsergebnisse enthält. Die Auswertung der Rechenergebnisse des Referenzfalls und der Alternativfälle und die Diskussion der verwendeten Methodik erfolgen in Kapitel 9.

Aus Sicht des privaten Entscheiders lässt sich allgemein festhalten, dass die PV-Anlage für Wohnquartiere wirtschaftlich vorteilhaft ist. Dieses Ergebnis gilt unter allen betrachteten Preisbildungsmechanismen. Dynamische Preise erhöhen nur leicht die PV-Attraktivität im Vergleich zum Referenzfall. Nur in den Fällen eines hohen Arbeitspreises und eines niedrigen Kalkulationszinses wird die maximal mögliche PV-Kapazität auf der Dachfläche ($\leq 75 \text{ kW}_p$) vollständig ausgenutzt. Im Fall eines Leistungspreises mit verringertem Arbeitspreis und im Fall eines hohen Kalkulationszinses fällt die optimale PV-Anlage nur halb so groß aus.

Tab. 8.3: Berechnungsergebnisse der Fallstudie des Referenzfalls und der sechs Alternativfälle.

Größen (Einheiten)	Fall 1 Ref	Fall 2 H-AP	Fall 3 H-EVA	Fall 4 DP	Fall 5 CP	Fall 6 H-Zins	Fall 7 N-Zins
Investition in...							
PV-Anlage (kW_p)	59,8	75	69,2	61,4	34,6	34,0	75
Wärmepumpen (St.)	2	2	2	2	2	2	2
RW-Speicher (kWh_{th})	18,6	20,9	18,6	18,6	18,6	18,6	18,6
WW-Speicher (kWh_{th})	60,4	92,9	69,7	69,7	27,9	27,9	74,3
Elektr. Speicher (kWh_{el})	–	2,5	–	–	–	–	1,3
PV-Angebot (kWh_{el})	45 011 –49 447	55 306 –63 519	50 698 –58 226	44 936 –51 609	25 349 –29 113	24 909 –28 608	55 306 –63 519
Externer Elektrizitäts- bezug (kWh_{el})	60 089 –67 164	55 068 –62 100	58 057 –64 863	59920 –66737	69 609 –75 591	69 468 –75 454	56 237 –63 159
Spitzenlast (kW_{el})	44 – 60	44 – 46	44 – 60	44 – 87	35 – 39	44 – 61	43 – 58
Durchlauf RW- Speicher (kWh_{th})	25 212 –27 893	25 147 –28 574	25 014 –28 679	25 740 –29 177	24 997 –28 663	24 506 –28 165	25 030 –28 281
Durchlauf WW- Speicher (kWh_{th})	44 939 –46 865	47 950 –49 974	46 012 –47 933	51 307 –53 405	41 736 –43 427	40 786 –42 132	46 195 –48 290
Durchlauf elektr. Spei- cher (kWh_{el})	–	772 –885	–	–	–	–	410 –461
Verluste...							
Wärmepumpen (kWh_{th})	2 189 –2 459	1 875 –2 231	2 109 –2 458	2 363 –2 903	2 387 –2 857	2 315 –2 678	2 067 –2 397
therm. Speicher (kWh_{th})	3 684 –3 916	5 053 –5 531	3 936 –4 319	4 523 –4 962	2 392 –2 605	2 358 –2 590	4 088 –4493
elektr. Speicher (kWh_{el})	–	93 – 106	–	–	–	–	49 – 55
PV-Eigenverbrauchsquote	60–65%	55–62%	55–61%	59–65%	72–78%	72–79%	53–59%
Autarkiegrad	31–34%	35–40%	32–37%	30–35%	21–24%	21–24%	34–39%
Minimale erwartete Gesamtenergiekosten (€/a)	29.978	36.379	33.543	30.130	25.607	32.418	27.506

In allen Fällen werden stets zwei Wärmepumpen zugebaut, die mindestens benötigt werden, um den RW- und WW-Bedarf in Kombination mit Speichern zu decken. Dadurch

können die Einsatzzeiten der elektrischen Heizelemente auf ein Minimum reduziert werden. Diese kommen nur in Spitzennachfragezeiten oder bei kalten Außenlufttemperaturen zum Einsatz. Eine weitere Wärmepumpe würde sich hierfür nicht rentieren.

Thermische Speicher werden gegenüber elektrischen Speichern eindeutig bevorzugt. Ähnlich wie bei der PV-Anlage werden größere thermische Speicher bei höheren Arbeitspreisen oder niedrigem Kalkulationszins zugebaut. Dabei verringern sich betriebsbedingt die Anfahrverluste der Wärmepumpen. Insgesamt fallen die Verluste aufgrund der größeren thermischen Speicherverluste höher aus.

Elektrische Speicher spielen im Wohnquartier unter den aktuellen Annahmen eine untergeordnete Rolle und werden nur im Fall eines hohen Arbeitspreises oder eines niedrigen Kalkulationszins marginal zugebaut. Der Verkauf gespeicherter elektrischer Energie an den externen Energieversorger zu GH-Preisen ist nahezu nicht vorhanden und nur im H-AP-Fall mit $87 \text{ kWh}_{\text{el}}$ im Jahr nennenswert.

Im Referenzfall und in den Alternativfällen variieren die PV-Eigenverbrauchsquote zwischen 53 bis 79 % und der Autarkiegrad zwischen 21 bis 40 % hauptsächlich mit der Kapazität der PV-Anlage. Die minimalen erwarteten Gesamtenergiekosten liegen zwischen 25.607 € (CP-Fall) und 36.379 € (H-AP-Fall). Dynamische Preise führen zu leicht erhöhten Gesamtenergiekosten im Vergleich zum Referenzfall (Begründung siehe Diskussion in Abschnitt 9.1.1).

8.5 Optimale Investitions- und Einsatzplanung mit minimalem Risiko und Regret

Die zuvor vorgestellten stochastischen Lösungen sind jeweils nur optimal für den entsprechenden ungewissen Fall θ und weisen demnach auch nur die minimalen erwarteten Gesamtenergiekosten cost_{θ}^* des Falls θ aus. Bei der Regret-Minimierung wird der für den Entscheider exogen gegebene Fall θ selbst zur Entscheidungsvariable (und ist demzufolge fett hervorgehoben). Für die Minimierung werden nur Referenzfall und Alternativfälle berücksichtigt, jedoch nicht die Sonderfälle. Die Minimierung erfolgt gemäß Gleichung (6.33) in einem ersten Schritt durch die Berechnung der minimierten erwarteten Gesamtenergiekosten $\text{cost}_{x_{\theta}, \theta}$ aller Fälle unter Vorgabe der fallspezifischen optimalen Investition x_{θ}^* . Demnach werden minimierte erwartete Gesamtenergiekosten für jedes x_{θ}^* in einer Matrix berechnet, die sich in allen anderen (sechs abweichenden) Fällen ergeben würden (siehe Tab. 8.4).

Tab. 8.4: Matrix der minimierten erwarteten Gesamtenergiekosten $cost_{x_{\theta},\theta}$ für Investition x_{θ}^* in Fall θ . (Die Matrix-Diagonale zeigt die minimalen erwarteten Gesamtenergiekosten des Falls θ mit der optimalen Investition x_{θ}^*).

		Minimierte erw. Gesamtenergiekosten $cost_{x_{\theta},\theta}$ in € im Fall $\theta \dots$							Maximum der erw. Gesamtenergiekosten in € für Investition x_{θ}^* (Worst Case)
		1 Ref	2 H-AP	3 H-EVA	4 DP	5 CP	6 H-Zins	7 N-Zins	
Anwendung der opt. Investition x_{θ}^* des Falls $\theta \dots$	1 Ref	29.978	36.775	33.567	30.134	25.924	32.910	27.790	36.775
	2 H-AP	30.095	36.379	33.600	30.227	26.347	33.556	27.534	36.379
	3 H-EVA	29.998	36.569	33.543	30.142	26.096	33.200	27.607	36.569
	4 DP	29.982	36.704	33.557	30.130	25.971	32.969	27.750	36.704
	5 CP	30.235	37.882	33.985	30.470	25.607	32.429	28.594	37.882
	6 H-Zins	30.238	37.899	33.990	30.474	25.614	32.418	28.606	37.899
	7 N-Zins	30.034	36.427	33.558	30.175	26.232	33.445	27.506	36.427
Minimum der erw. Gesamtenergiekosten für Fall θ (Best Case)		29.978	36.379	33.543	30.130	25.607	32.418	27.506	

Tab. 8.4 enthält in der letzten Spalte die maximalen minimierten erwarteten Gesamtenergiekosten für die Investition x_{θ}^* (Worst Case). In der letzten Zeile sind die minimalen minimierten erwarteten Gesamtenergiekosten für Fall θ aufgeführt (Best Case). Das Maximum der erwarteten Gesamtenergiekosten aller Investitionen x_{θ}^* beträgt (im Sinne der Robusten Optimierung) 37.899€, das Minimum der erwarteten Gesamtenergiekosten aller Fälle θ beträgt 27.506 €.

Für die Regret-Minimierung wird der Regret in Bezug zum Best Case für jeden Fall θ bestimmt: die Differenz der minimierten erwarteten Gesamtenergiekosten $cost_{x_{\theta},\theta}$ und des Minimums im Fall θ (siehe Tab. 8.5).

Tab. 8.5: Matrix des Regrets ($regret_{x_\theta, \theta}$) für die Investition x_θ^* im Fall θ (unter jedem absoluten Regret steht der relative Regret in Bezug zum Best Case des Falls θ in Klammern).

		Regret ($regret_{x_\theta, \theta}$) für Investition x_θ^* in € im Fall $\theta \dots$							Max. Regret in € für Investition x_θ^* (Worst Regret)
		1	2	3	4	5	6	7	
		Ref	H-AP	H-EVA	DP	CP	H-Zins	N-Zins	
Anwendung der opt. Investition x_θ^* des Falls $\theta \dots$	1 Ref	0 (0,0 %)	395 (1,1 %)	24 (0,1 %)	4 (0 %)	317 (1,2 %)	492 (1,5 %)	284 (1 %)	492
	2 H-AP	116 (0,4 %)	0	57 (0,2 %)	97 (0,3 %)	740 (2,9 %)	1.138 (3,5 %)	28 (0,1 %)	1.138
	3 H-EVA	20 (0,1 %)	190 (0,5 %)	0	12 (0 %)	489 (1,9 %)	782 (2,4 %)	101 (0,4 %)	782
	4 DP	3 (0 %)	324 (0,9 %)	14 (0 %)	0	364 (1,4 %)	551 (1,7 %)	244 (0,9 %)	551
	5 CP	257 (0,9 %)	1.502 (4,1 %)	442 (1,3 %)	340 (1,1 %)	0	11 (0 %)	1.087 (4 %)	1.502
	6 H-Zins	260 (0,9 %)	1.519 (4,2 %)	447 (1,3 %)	344 (1,1 %)	7 (0 %)	0	1.099 (4 %)	1.519
	7 N-Zins	56 (0,2 %)	47 (0,1 %)	14 (0 %)	45 (0,2 %)	625 (2,4 %)	1.027 (3,2 %)	0	1.027

$$\text{Minimaler Regret: } \min_{x_\theta^*} \max_{\theta} regret_{x_\theta, \theta} = 492$$

Der minimale Regret ist das Minimum des maximalen Regrets aller Investitionen x_θ^* (letzte Spalte in Tab. 8.5): 492 €. Demnach führt die optimale Investition des Referenzfalls $x_{\theta=Ref}^*$ ins Energiesystem des Wohnquartiers zur Lösung, die vom Entscheider im schlechtesten Fall θ am wenigsten bereit werden würde.

Ohne Regret-Minimierung könnte der Entscheider einen dreifach höheren, maximalen Regret von 1.519 € erleiden, wenn er sich für die optimale Investition des H-Zins-Falls entscheiden würde. Im Übrigen ist die Lösung des H-Zins-Falls im Sinne der Robusten Optimierung optimal (Maximum der letzten Spalte der Tab. 8.4), in dem der Entscheider möglichst wenig ins Energiesystem investiert. Denn der hohe Kalkulationszins stellt den schlechtesten Fall dar, dessen Kosten minimiert werden würden (Minimax-Regel).

8.6 Sonderfälle

Die Fälle I und II mit niedrigem Arbeitspreis und vollständiger Autarkie werden als gesonderte Fälle betrachtet. Diese fließen nicht in die Regret-Minimierung ein, unter der Prämisse, dass beide Sonderfälle in den nächsten 20 Jahren nicht (als ungewisse Fälle) für das betrachtete Wohnquartier in Karlsruhe eintreten werden und auch nicht aktiv vom Entscheider ausgewählt werden können. Unabhängig davon lassen sich diese Ergebnisse nutzen, um (optimale) Investitions- und Betriebsentscheidungen zukünftiger Wohnquartiere oder anderer dezentraler Energiesysteme besser abschätzen zu können.

8.6.1 Niedriger Arbeitspreis

Im Fall I mit niedrigem Arbeitspreis (N-AP) wird der Strombedarf des Wohnquartiers primär durch eine Gasturbine gedeckt. Das Wohnquartier und die Gasturbine stehen im räumlichen Zusammenhang und bilden eine sogenannte Kundenanlage (siehe EnWG in Abschnitt 2.2.5). Als Brennstoff der Gasturbine wird Erdgas genutzt und über das externe Gasnetz bezogen. Daneben besteht weiterhin ein Anschluss ans externe Stromnetz zur Notstromversorgung.

Für den vom Wohnquartier eigenverbrauchten Strom der Gasturbine wird ein Arbeitspreis von $8,7 \text{ ct}_e/\text{kWh}_{el}$ angenommen (bestehend aus $6,2 \text{ ct}_e/\text{kWh}_{el}$ Brennstoffkosten und $2,5 \text{ ct}_e/\text{kWh}_{el}$ Eigenverbrauchsabgabe).⁵³ Die Anschaffungskosten der Gasturbine belaufen sich gemäß Studienvergleich der AEE (2012) auf ca. 400 €/kW_{el} . Mit dem Annuitätenfaktor des Referenzfalls (Laufzeit: 20 Jahre, Kalkulationszins: 4,5 %) ergeben sich Kapitalkosten i. H. v. 30 €/kW_{el} , die als Leistungspreis der Gasturbine angesetzt werden. Zusätzlich wird für den Anschluss des Quartiers ans externe Stromnetz ein Anschlusspreis i. H. v. 18 €/kW_{el} (wie im CP-Fall in Abschnitt 8.4.2) angesetzt. Der Anschlusspreis wird damit begründet, dass die entgangenen Stromnetzentgelte des externen Netzbetreibers bzw. Energieversorgers (bei Notstrommengen gegen Null) auf den abgerufenen maximalen Stromnetzbezug umgelegt werden. Insgesamt ergibt sich ein Leistungspreis für das Wohnquartier i. H. v. 48 €/kW_{el} .

⁵³ Die Brennstoffkosten ergeben sich aus einem Gaspreis von $2,1 \text{ ct}_e/\text{kWh}_{th}$ und einem elektrischen Wirkungsgrad von 34 % (basierend auf Siemens AG 2013; ÜBN 2018). Gemäß EEG fällt auf den eigenverbrauchten (Gemeinschafts-)Strom des Wohnquartiers eine anteilige EEG-Umlage von 40 % an.

8.6.2 Vollständige Autarkie

Im Fall II mit vollständiger Autarkie (mit einem Autarkiegrad von 100 %) besteht keine Verbindung mit dem externen Elektrizitäts- und Gasnetz und damit auch keine Möglichkeit, Strom oder Gas extern zu beziehen oder zu veräußern (abgebildet in Tab. 8.2 mit unendlich hohem Arbeits- und GH-Preis beim Bezug sowie mit $0 \text{ €/kWh}_{\text{el}}$ beim Veräußern elektrischer Energie). Dadurch entfällt auch die Option, den Elektrizitätsbedarf mit einer Gasturbine zu decken. Die benötigte elektrische Energie muss vollständig mit PV-Energie gedeckt werden, eine Eigenverbrauchsabgabe fällt aufgrund des isolierten Energiesystems nicht an ($0 \text{ €/kWh}_{\text{el}}$).

Damit der Fall überhaupt lösbar ist, wird die restriktive Obergrenze für die PV-Dachanlage von 75 kWp aufgehoben. Andernfalls könnte der gesamte Energiebedarf des Wohnquartiers rein bilanziell nur ungefähr zur Hälfte gedeckt werden.

Des Weiteren sind die Speicherstände bei der Entkopplung zwischen den Subprogrammen für die Minimierung der Gesamtenergiekosten entscheidend, um auch saisonale Lastverschiebungen zu ermöglichen. Die Berechnung eines gesamten Jahres ist nur mit relaxierter Ganzzahligkeits-Restriktion (für die Wärmepumpen) mit vertretbarem Aufwand möglich. Mithilfe dieser Relaxierung werden die wöchentlichen optimalen relativen Speicherstände aller 100 Szenarien zuvor bestimmt. Anschließend werden diese für die Ausführung der originalen Subprogramme mit Ganzzahligkeits-Restriktion vorgegeben. Die folgende Abb. 8.8 zeigt die wöchentlichen optimalen Speicherstände des RW-, WW- und elektrischen Speichers der 100 Szenarien (relative Minimal-, Maximal- und Mittelwerte). Der MIP-Gap zum relaxierten linearen Programm ist kleiner 1 %.




Abb. 8.8: Relative Minimal-, Maximal- und Mittelwerte der wöchentlichen optimalen Speicherstände des Raumwärme(RW)-, Warmwasser(WW)- und elektr. Speichers von 100 Szenarien (optimiert als stochastisches Programm mit relaxierter Ganzzahligkeits-Restriktion der Wärmepumpen).

8.6.3 Rechenergebnisse der Sonderfälle

Die Kostenaufteilung der Investitions- und Einsatzplanung für die beiden Sonderfälle I (N-AP) und II (Autark) sind in der folgenden Abb. 8.9 in einem Kreisdiagramm dargestellt.

Im Sonderfall I (N-AP) sinken die erwarteten Gesamtenergiekosten im Vergleich zum Referenzfall um 50 % auf 14.691 €, wovon ca. 2/3 durch die erwarteten Betriebskosten verursacht werden. Der sehr niedrige Arbeitspreis von 8,7 ct_€/kWh_{el} führt dazu, dass sich die Investitionen in die Energiesystemkomponenten des Wohnquartiers kaum noch rentieren. Es findet keine Investition mehr in die PV-Anlage statt. In die thermischen Speicher wird nur das Nötigste investiert, um in Verbindung mit den Wärmepumpen die thermische Nachfrage decken zu können. Der elektrische Speicher wird trotz des hohen Leistungspreises von 48 €/kWh_{el} nicht zugebaut.

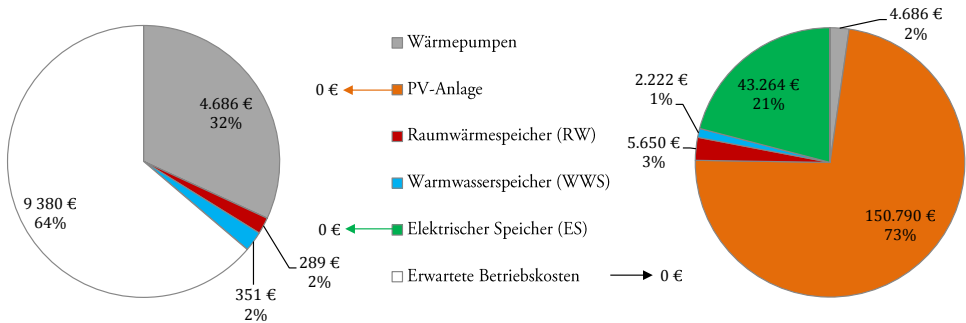


Abb. 8.9: Kostenaufteilung der Investitions- und Einsatzplanung für Sonderfall I (links) und II (rechts).⁵⁴

Im Sonderfall II (Autark) führen die totale Trennung vom externen Netz und die Anforderung vollständiger Autarkie genau zum Gegenteil: Die erwarteten Gesamtenergiekosten steigen im Vergleich zum Referenzfall um knapp den Faktor sieben auf 206.046 € (MIP-Gap < 1 %). Grund für den immensen Kostenanstieg ist der hohe Investitionsbedarf in eine extrem großdimensionierte PV-Anlage: Es werden knapp 1,3 MW_p für eine vollständig autarke Versorgung zugebaut, die 73 % (150.790 €) der erwarteten Gesamtenergiekosten ausmachen. Davon können aufgrund der Inkoinzidenz zwischen Elektrizitätsnachfrage und PV-Angebot nur ca. 15 % genutzt werden. Die restliche potenzielle Energiemenge bleibt beim Abschalten der PV-Anlage ungenutzt. Die optimalen Speichergrößen sind nicht dafür ausgelegt, den saisonalen PV-Überschuss auf sonnenschwache Monate zu verschieben. Sowohl die thermischen Speicher mit 654,2 kWh_{th} für RW und 316 kWh_{th} für WW als auch der elektrische Speicher mit 830 kWh_{el} dienen mehr dazu, tägliche bis maximal wöchentliche Koinzidenz zwischen Energieangebot und -nachfrage herzustellen. Neben den optimalen Kapazitäten aller Energiekomponenten für die Sonderfälle I und II sind in Tab. 8.6 weitere wichtige Kenngrößen im Vergleich zum Referenzfall gelistet.

⁵⁴ Im Fall der vollständigen Autarkie fallen keine Betriebskosten an. Wartungskosten der Energiesystemkomponente werden in der Arbeit durch den Maintenance-Faktor der Investitionsauszahlung zugeordnet.

Tab. 8.6: Berechnungsergebnisse der Sonderfälle I und II im Vergleich zum Referenzfall.

Größen (Einheiten)	Fall 1: Ref	Sonderfall I: N-AP	Sonderfall II: Autark
Investition in ...			
PV-Anlage (kW _p)	59,8	–	1 261,7
Wärmepumpen (St.)	2	2	2
RW-Speicher (kWh _{th})	18,6	18,6	654,2
WW-Speicher (kWh _{th})	60,4	27,9	316
Elektr. Speicher (kWh _{el})	–	–	830
PV-Angebot (kWh _{el})	45 011 – 49 447	0	924 077 – 1 061 303
Externer Elektrizitäts- bezug (kWh _{el})	60 089 – 67 164	90 593 – 95 567	0
Spitzenlast (kW _{el})	44 – 60	34 – 38	–
Durchlauf RW- Speicher (kWh _{th})	25 212 – 27 893	24 767 – 28 406	62 617 – 79 920
Durchlauf WW- Speicher (kWh _{th})	44 939 – 46 865	39 804 – 41 498	51 139 – 56 123
Durchlauf elektr. Spei- cher (kWh _{el})	–	–	21 261 – 29 156
Verluste ...			
Wärmepumpen (kWh _{th})	2 189 – 2 459	2 119 – 2 488	5 996 – 10 189
therm. Speicher (kWh _{th})	3 684 – 3 916	2 208 – 2 387	16 835 – 22 680
elektr. Speicher (kWh _{el})	–	–	2500 – 3440
PV-Eigenverbrauchsquote	60 – 65 %	–	14 – 16 %
Autarkiegrad	31 – 34 %	0%	100 %
Minimale erwartete Gesamtenergiekosten (€/a)	29.978	14.691	206.046

8.7 Vergleich zur deterministischen Lösung

Ein Vergleich der optimalen stochastischen Lösungen (*Stochastic Solution, SS*) und der individuellen deterministischen Lösungen für jeweils 100 Szenarien des Referenzfalls ist in den folgenden Abbildungen (Abb. 8.10, Abb. 8.11 und Abb. 8.12) gezeigt. Auf der linken Seite ist jeweils ein bivariates Histogramm der minimalen Gesamtenergiekosten und optimalen Kapazität der Systemkomponente abgebildet. Die SS ist rot eingetragen. Auf der rechten Seite enthalten die Abbildungen jeweils ein univariates Histogramm der optimalen Kapazität der Systemkomponente, in dem neben der SS die deterministische Lösung für ein ausgewähltes Szenario eingetragen ist: für das Szenario mit Erwartungswerten (*Expected Values, EV*) der unsicheren Parameter und für ein Szenario, das mit der in Abschnitt 7.2.1 vorgestellten Szenarioreduktion von den 100 Szenarien mit insgesamt 5 200 Wochenteilen auf ein Szenario mit 52 Teilen reduziert wurde (S1-Lösung).




Abb. 8.10: Links: bivariates Histogramm der min. Gesamtenergiekosten und opt. PV-Anlage (200-€- bzw. 3- kW_p -Klassenbreite) sowie stoch. Lösung (SS); rechts: Histogramm der opt. PV-Anlage (3- kW_p -Klassenbreite) sowie stoch. und determ. Lösung (SS, EV, S1); für 100 Szenarien des Referenzfalls.

Bezugnehmend auf die Histogramme auf der linken Seite, werden die optimalen Kapazitäten der PV-Anlage sowie der RW- und WW-Speicher der individuell (deterministisch) optimierten Szenarien auf der Abszisse (seitliche Längsachse) gegenüber minimalen Gesamtenergiekosten auf der Ordinate (seitliche Tiefenachse) dargestellt. Die Applikate

(vertikale Höhenachse) zeigt die Häufigkeitsverteilung in den Klassenbreiten: 1 kW_p für PV, 1,16 kWh_{th} für RW-Speicher und 4,65 kWh_{th} für WW-Speicher sowie deren zugehörige minimale Gesamtenergiekosten in Klassenbreiten von 200 €. ⁵⁵

Wird jedes Szenario individuell optimiert, variiert die optimale Kapazität für PV zwischen 30 und 75 kW_p und die Häufigkeitsspitze liegt zwischen 57 und 63 kW_p. Die optimale Kapazität für RW-Speicher variiert zwischen 9,3 und 22,1 kWh_{th} (800–1 900 l) und für WW-Speicher zwischen 37,2 und 88,3 kWh_{th} (800–1 900 l); die Häufigkeitsspitze liegt zwischen 14 und 15,1 kWh_{th} (1 200–1 300 l) bzw. 60,4 und 65,1 kWh_{th} (1300–1 400 l). Für den elektrischen Speicher ist kein Histogramm abgebildet, da dieser nur in sechs Szenarien mit der kleinsten vordefinierten Schrittgröße (1 kWh_{el}/DF_{i=ES} = 1,3 kWh_{el}) zugebaut wird. Demnach liegt die optimale elektrische Speicherkapazität und deren Häufigkeitsspitze der 100 Szenarien in der Klasse von 0 bis 1,3 kWh_{el}.

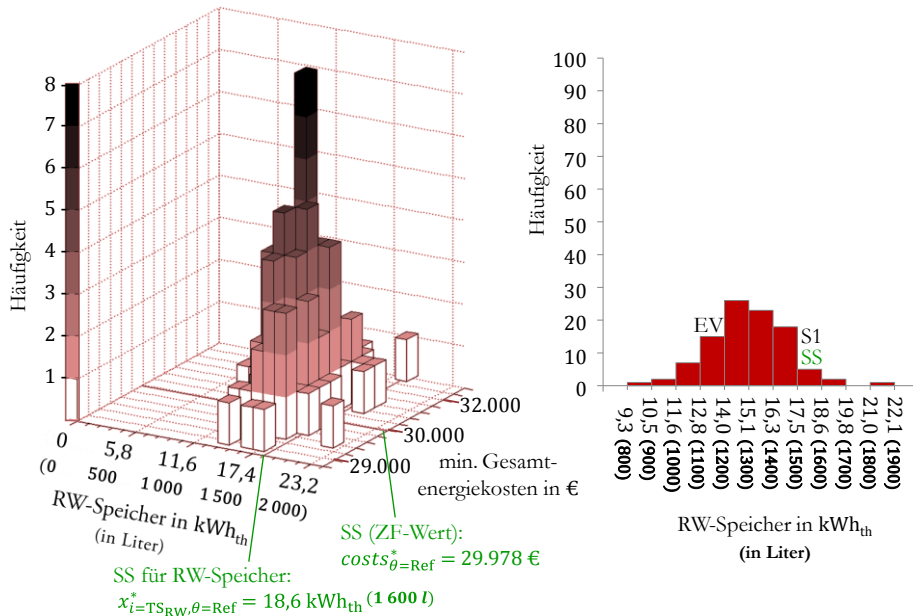


Abb. 8.11: Links: bivariates Histogramm der min. Gesamtenergiekosten und opt. RW-Speicher (200-€- u. 100-l-Klassenbreite) sowie stoch. Lösung (SS); rechts: Histogramm der opt. RW-Speicher (100-l-Klassenbreite) sowie stoch. und determ. Lösung (SS, EV, S1); für 100 Szenarien des Referenzfalls.

⁵⁵ Die Abszisse in Abb. 8.11 und Abb. 8.12 ist gemäß thermischer Speicherfähigkeit skaliert: 1,16 kWh_{th} und 4,65 kWh_{th} entsprechen dabei dem kleinstmöglichen Wasserspeicher von 100 l für RW bzw. WW.

Schwache Korrelationen bestehen nur zwischen der PV-Kapazität und dem wetterabhängigen Jahresertrag sowie dem WW-Speicher.⁵⁶ Daneben hängen die Größen generell vom Lastwechselfpotenzial ab, das durch die komplexe Kombination aus zeitabhängiger PV-Versorgung und elektrischem und thermischem Energiebedarf bedingt wird. Darüber hinaus beeinflussen Speicherverluste und Anfahrverluste der Wärmepumpen die Wirtschaftlichkeit der Lastverschiebung.

Die Gesamtenergiekosten betragen 28.957 bis 31.288 €. Die Kostenschwankungen werden hauptsächlich durch das PV-Angebot und den thermischen Bedarf getrieben, beide abhängig von unsicheren, stochastischen Wetterbedingungen: Je höher die durchschnittliche Sonneneinstrahlung und Temperatur eines Jahres, desto niedriger sind die minimalen Kosten aufgrund eines höheren PV-Angebots und eines niedrigeren thermischen Bedarfs. Der Erwartungswert der individuell (deterministisch) optimierten 100 Szenarien beträgt 29.852 € im Referenzfall. In Relation zur stochastischen Lösung ergibt sich damit ein EVPI (siehe Abschnitt 4.4.2) kleiner 1 %.

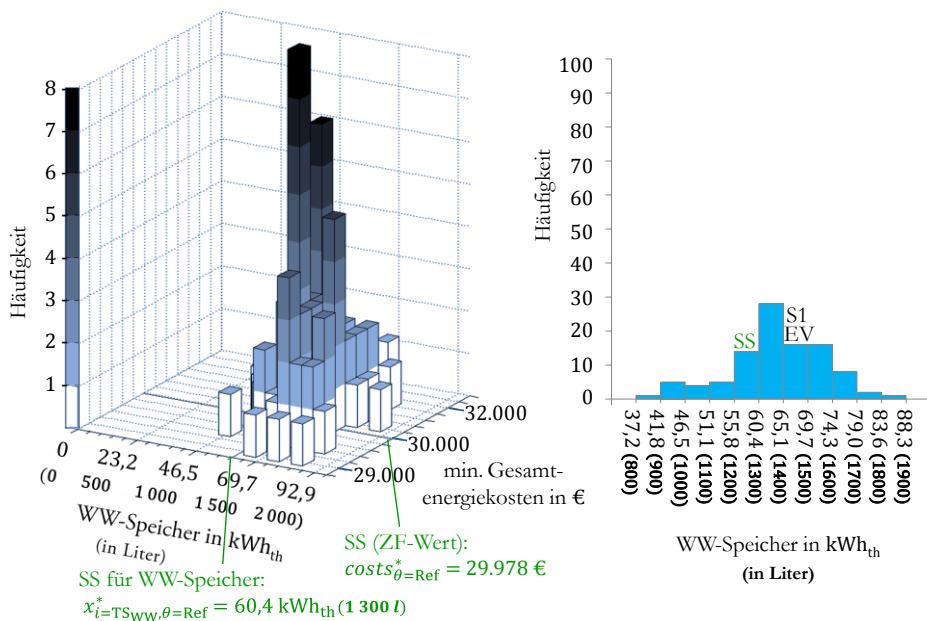


Abb. 8.12:Links: bivariates Histogramm der min. Gesamtenergiekosten und opt. WW-Speicher (200-€- u. 100-l-Klassenbreite) sowie stoch. Lösung (SS); rechts: Histogramm der opt. WW-Speicher (100-l-Klassenbreite) sowie stoch. und determ. Lösung (SS, EV, S1); für 100 Szenarien des Referenzfalls.

⁵⁶ Der lineare Korrelationskoeffizient zwischen PV-Kapazität und spezifischem PV-Jahresertrag liegt bei 0,4; zwischen PV-Kapazität und WW-Speicher bei 0,3.

Bezugnehmend auf die Histogramme auf der rechten Seite der Abb. 8.10, Abb. 8.11 und Abb. 8.12, fallen die optimalen deterministischen Lösungen der EV-Lösung und der S1-Lösung nicht mit den Kapazitäten der SS zusammen.

Die EV-Lösung des Referenzfalls nach Optimierung mit Erwartungswerten hat im Vergleich zur stochastischen Lösung eine um 10 % (6 kW_p) größere PV-Anlage. Der RW-Speicher ist um 25 % ($-4,6 \text{ kWh}_{th}$) kleiner und der WW-Speicher um 15 % ($9,3 \text{ kWh}_{th}$) größer. Der elektrische Speicher wird mit $1,3 \text{ kWh}_{el}$ zugebaut. Diese Kapazitäten, eingesetzt in das gesamte stochastische Programm mit 100 Szenarien des Referenzfalls, führen zu erwarteten Gesamtenergiekosten i. H. v. 33.478 € und einem VSS (Differenz zur stochastischen Lösung) von 3.500 € (10,5 %).

Die S1-Lösung mit einem Szenario, das von insgesamt 5 200 Teilen auf 52 Teile reduziert ist, bietet im Vergleich zur stochastischen Lösung die gleiche Kapazität der PV-Anlage und des RW-Speichers. Der WW-Speicher ist um 15 % ($9,3 \text{ kWh}_{th}$) größer und der elektrische Speicher wird mit $1,3 \text{ kWh}_{el}$ zugebaut. Diese Kapazitäten, eingesetzt in das gesamte stochastische Programm, führen zu erwarteten Gesamtenergiekosten i. H. v. 30.336 € und einem VSS von nur 358 € (1,2 %).

Die folgende Tab. 8.7 zeigt die eben genannten Unterschiede der stochastischen, EV- und S1-Lösung für den Referenzfall, zusätzlich auch für den Sonderfall I und II.

Tab. 8.7: Gesamtenergiekosten mit optimaler Investition der stochastischen, EV- und S1-Lösung.

Fall θ	Lösung	Optimale Investition in ...					Min. erw. Gesamtenergiekosten	Kostendifferenz zur stochastischen Lösung (SS)
		PV [kW_p]	WP [St.]	RWS [kWh_{th}]	WWS [kWh_{th}]	ES [kWh_{el}]		
Referenzfall	SS	59,8	2	18,6	60,4	0	29.978 €	–
	EV	66,1	2	13,9	69,7	1,3	33.478 €	3.500 € (10,5 %)
	S1	59,8	2	18,6	69,7	1,3	30.336 €	358 € (1,2 %)
Sonderfall I	SS	0	2	18,6	27,9	0	14.786 €	–
	EV	0	2	13,9	18,6	0	62.667 €	47.881 € (324,8 %)
	S1	0	2	16,3	27,9	0	30.336 €	1.241 € (8,2 %)
Sonderfall II	SS	1 261,7	2	654	316	867,5	206.046 €	–
	EV	1 069,8	2	294	130,1	280	110,7 Mio. €	110,5 Mio. € (53 318 %)
	S1	1 238,1	2	646,1	292,7	817,5	337.277 €	131.231 € (63,7 %)

*Wärmepumpe (WP) | Raumwärmespeicher (RWS) | Warmwasserspeicher (WWS) | elektr. Speicher (ES)

9 Diskussion der Rechenergebnisse und Methodik

Im folgenden Abschnitt 9.1 werden die im vorangegangenen Kapitel 8 vorgestellten Optimierungsergebnisse der Fallstudie eines Wohnquartiers als dezentrales Energiesystem diskutiert. Die entwickelte Methodik wird in Abschnitt 9.2 gesondert kritisch gewürdigt.

9.1 Diskussion der Rechenergebnisse

Der Referenzfall und die Alternativfälle sowie der minimale Regret werden in Abschnitt 9.1.1 diskutiert, die Sonderfälle in Abschnitt 9.1.2.

9.1.1 Diskussion des Referenzfalls und der Alternativfälle mit minimalem Regret

Die maximal mögliche PV-Kapazität auf der Dachfläche ($\leq 75 \text{ kW}_p$) wird nur in den Fällen mit hohem Arbeitspreis (H-AP) und niedrigem Zins (N-Zins) vollständig ausgenutzt. In den anderen Fällen wird die maximal mögliche Kapazität nicht erreicht. Einige Jahre zuvor hatten noch hohe Einspeisevergütungen sichere ertragsreiche Kapitalrenditen garantiert und meist den Anreiz geschaffen, die vorhandene Dachfläche vollständig zu nutzen. Dennoch bleiben PV-Anlagen im Haushaltsbereich mit den aktuellen Vergütungs- und Strompreisen attraktiv. Hauptsächlich Arbeitspreis und Kalkulationszins entscheiden über die Wirtschaftlichkeit der PV-Anlage und damit deren Ausbaugröße. Es lohnt sich grundsätzlich, selbst bei hohem Zins (H-Zins) im verringerten Maße, in eine PV-Anlage mit Wärmepumpen und Speichern zu investieren.

Dynamische Preise erhöhen nur leicht die PV-Attraktivität fürs Quartier, aber nicht deshalb, weil mehr PV-Strom an der Börse gewinnsteigernd veräußert werden würde (elektrischer Speicher wird nicht zugebaut). Vielmehr steigen die erwarteten minimalen Gesamtenergiekosten im Vergleich zum Referenzfall geringfügig an. Grund dafür ist, dass der Arbeitspreis negativ mit dem eigenen PV-Angebot korreliert ist. Dies führt zu durchschnittlich höheren Arbeitspreisen. Demzufolge lohnt es sich, in eine etwas größere PV-Anlage zu investieren und damit das eigene PV-Angebot zu erhöhen, das positiv mit der residualen Nachfrage des Quartiers korreliert ist. Im Gegensatz dazu ist die PV-Anlage im Fall eines Leistungspreises (CP) nur halb so groß. In diesem Fall werden die Netzentgelte nach der Spitzenlast des Wohnquartiers berechnet. Die Kosten für den

Elektrizitätsbezug vom externen Energieversorger vermindern sich mit dem um Netzentgelte reduzierten Arbeitspreis. Generell profitieren dezentrale Energiesysteme wie Wohnquartiere von solchen Leistungspreistarifen. Denn die Lastspitzen der Wohneinheiten nivellieren sich aufgrund des Gleichzeitigkeitseffekts innerhalb des Quartiers gegenseitig. Zusätzlich ist der Anreiz für einen netzdienlichen Betrieb der Wärmepumpen gegeben. Das Ergebnis ist eine niedrige Spitzenlast von maximal $1,4 \text{ kW}_{\text{el}}$ pro Wohneinheit und damit verbundene um 15 % reduzierte Energiekosten. Hätte der Entscheider die aktive Tarifwahl zwischen Referenzfall mit festem Arbeitspreis, DP- und CP-Fall (und wären die Fälle nicht exogen gegeben), wären Kapazitätspreise für das Quartier kostenminimal.

Thermische Speicher werden gegenüber elektrischen Speichern eindeutig bevorzugt. Der Hauptgrund dafür ist, dass die spezifischen Anschaffungskosten nur 10 bis 15 % im Vergleich zu denen elektrischer Speicher betragen. Außerdem ist die Verschiebung von $1 \text{ kWh}_{\text{el}}$ anstelle von $1 \text{ kWh}_{\text{th}}$ nicht konkurrenzfähig gegenüber dem geringeren Investitionsbedarf der Wärmespeicher in Kombination mit Wärmepumpen. Im Schnitt liefern Letztere mit $1 \text{ kWh}_{\text{el}}$ Elektrizität zwischen $3,1 \text{ kWh}_{\text{th}}$ für RW und $3,8 \text{ kWh}_{\text{th}}$ für WW.

Die Speicherkapazität für WW ist größer als für RW, da der Energietagesbedarf für WW über das Jahr annähernd konstant ist. Damit verteilt sich auch die Lastflexibilität von WW-Speichern gleichmäßiger über das Jahr im Vergleich zu RW-Speichern. Die hohe Lastflexibilität der WW-Speicher wird mittels Schichtspeichern erreicht. Solche Speicher unterstützen die Integration von PV-Anlagen und erhöhen den kosteneffizienten Eigenverbrauch. Deshalb erhöhen sich auch die Kapazitäten von WW-Speichern bei größeren PV-Anlagen und umgekehrt. Der Wert des RW-Speichers liegt weniger in der Lastverschiebung, sondern eher in der Reduktion der Anfahrvorgänge der Wärmepumpe und in der Deckung von Lastspitzen für RW im Winter, wenn die Luft-Wasser-Wärmepumpen aufgrund kalter Außenlufttemperaturen wenig Wärme liefern können. Dies erfordert RW-Speicher von mindestens $18,6 \text{ kWh}_{\text{th}}$ in allen betrachteten Fällen, die für die Nachfragedeckung sehr kalter Winter notwendig sind.

Elektrische Speicher spielen im Wohnquartier unter aktuellen (Kosten-)Annahmen eine untergeordnete Rolle. Im Vergleich zum Leistungspreis sind die Kapitalkosten zu hoch. Die Spitzenlast wird bereits durch den lastausgleichenden Betrieb der Wärmepumpen um bis zu 50 % reduziert. Selbst für die Fälle mit hohem Arbeitspreis (H-AP) und niedrigem Zins (N-Zins) wird der Speicher nur um bis zu $2,5 \text{ kWh}_{\text{el}}$ zugebaut.

Die aufgezeigten Fälle gehen von aktuellen Marktpreisen und -bedingungen aus und beschreiben keine in ferner Zukunft liegenden, sondern bevorstehende mögliche Entwicklungen. Insgesamt bringen dezentrale Energiesysteme in der deutschen Energiever-

sorgung Veränderungen und Herausforderungen mit sich. Diese gelten sowohl für Elektrizitätsversorgungsunternehmen als auch für Träger politischer Entscheidungen. Der Rückgang der in der Vergangenheit gelieferten Energiemengen würde das Geschäft der Energieversorger ernsthaft beeinträchtigen. Für die Träger politischer Entscheidungen besteht die größte Herausforderung darin, dass bei abnehmendem Strombedarf die Verbraucher für die Kosten der Energiesysteminfrastruktur aufkommen müssen. Im derzeitigen System werden diese Kosten über den Arbeitspreis vom Verbraucher bezahlt. Wenn dem Netz immer weniger Strom entnommen wird, würden die Systemgebühren pro kWh_{el} mit der Zeit steigen, um die Gesamtkosten einschließlich der Netzkosten tragen zu können. Dies kann zu Schwierigkeiten bei der Verteilung der Kosten führen, ist aber auch wegen der möglichen Ineffizienz des Gesamtsystems kritisch. Je mehr dezentrale Energiesysteme sich zunehmend selbst versorgen, desto weniger gleichen sich Angebot und Nachfrage über verschiedene Netzgebiete (unter Nutzung der vorhandenen Netzinfrastuktur) aus. Leistungsbasierte Preiskomponenten können dazu beitragen, solche Effekte zu vermeiden. Im CP-Fall ist die maximale Netzlast um bis zu 35 % im Vergleich zum Referenzfall gesunken. Jedoch wird eine leistungsbasierte Preisgestaltung auch wegen ihrer Wirkung auf die Verteilung der Kosten kritisiert: kleine Haushalte, die einen niedrigen Gesamtbedarf und wenige Nachfragespitzen im Jahr aufweisen, würden negativ beeinflusst werden. Verbraucher im Verbund, etwa Wohnquartiere, die ihre Spitzenlasten schon innerhalb des Systems ausgleichen, würden von solch einem Tarif profitieren.

Aus Sicht des Entscheiders steht vor der Investitionsentscheidung nicht fest, welcher Fall genau eintreten wird. Unter der Prämisse, dass der Entscheider das Eintreten des Referenzfalls und der Alternativfälle nicht beeinflussen kann, sind alle Fälle gleich ungewiss (die Sonderfälle werden nicht als ungewisse Fälle betrachtet). Mit der Regret-Minimierung wird die Investition des Referenzfalls $x_{\theta=\text{Ref}}^*$ als optimale Lösung bestimmt, die vom Entscheider im schlechtesten Fall θ am wenigsten bereut werden würde. Ohne Regret-Minimierung könnte der Entscheider im schlechtesten Fall (opt. Investition des H-Zins-Falls) einen dreifach höheren, maximalen Regret erleiden.

In die Regret-Minimierung wurden Ungewissheiten über Lebensdauer, Degradation und Instandhaltungskosten der Energiesystemkomponenten nicht berücksichtigt. Eine kürzere oder längere Lebensdauer würde den Kalkulationszins ändern. Wenn die Lebensdauer für alle Komponenten gleichermaßen steigen oder fallen sollte, wäre dies teilweise über die Fälle mit hohem und niedrigem Kalkulationszins (H-Zins und N-Zins) abgebildet. Änderte sich die Lebensdauer nur einer Energiesystemkomponente, würde deren Wirtschaftlichkeit mit erhöhter Lebensdauer steigen (niedrigerer Annuitä-

tenfaktor) und mit verringerter fallen (höherer Annuitätenfaktor). Ähnlich würden erhöhte Degradation oder Instandhaltungskosten die wirtschaftliche Attraktivität der Energiesystemkomponente senken (vice versa).

9.1.2 Diskussion der Sonderfälle

Im Sonderfall I mit extrem niedrigem Arbeitspreis von $8,7 \text{ ct}_\epsilon/\text{kWh}_{\text{el}}$ wird keine PV-Anlage zugebaut. Denn, wie oben geschildert, ist vor allem der Arbeitspreis für die Wirtschaftlichkeit und damit deren Ausbaugröße entscheidend. Trotz des extrem hohen Leistungspreises wird der elektrische Speicher nicht hinzugebaut. Weil der Speicher fast ausschließlich dazu dienen würde, die Spitzenlast zu reduzieren, reicht das Einsparungspotenzial nicht aus: Selbst mit der hohen angenommen C-Rate von eins können mit $1 \text{ kWh}_{\text{el}}$ Speicher nur $1 \text{ kWh}_{\text{el}}$ reduziert werden. Die Einsparungen per Leistungspreis i. H. v. $48 \text{ €/kWh}_{\text{el}}$ sind zu gering, um die annualisierten Kapitalkosten des elektrischen Speichers ($\approx 52 \text{ €/kWh}_{\text{el}}$) zu erwirtschaften. Die beiden thermischen Speicher werden nur noch mit der Mindestkapazität zugebaut, die notwendig ist, um den Energiebedarf für RW und WW zu decken. Ähnlich wie im CP-Fall profitieren dezentrale Energiesysteme wie Wohnquartiere generell von Tarifen mit hohem Leistungspreis und dafür gemindertem Arbeitspreis. Grund dafür ist der Ausgleichseffekt, der bei Lastspitzen der Wohneinheiten innerhalb des Quartiers im Vergleich zu Einzelhaushalten auftritt. Durch den hohen Leistungspreis werden durch Lastverschiebung der Wärmepumpen und thermischen Speicher die niedrigsten Lastspitzen aller betrachteten Fälle erreicht: 34 bis $38 \text{ kWh}_{\text{el}}$, durchschnittlich $1 \text{ kWh}_{\text{el}}$ weniger als im CP-Fall mit niedrigerem Leistungspreis ($18 \text{ €/kWh}_{\text{el}}$).

Im Sonderfall II werden beinahe $1,3 \text{ MW}_p$ PV-Kapazität für eine vollständig autarke Versorgung von 28 Wohneinheiten zugebaut (die max. PV-Kapazitätsrestriktion $\leq 75 \text{ kW}_p$ wurde hierfür aufgehoben). Je Wohneinheit sind das 45 kW_p , damit deren Elektrizitäts- und Wärmenachfrage mit PV-Anlage, Wärmepumpen und Speichern übers gesamte Jahr gedeckt werden kann. Rein bilanziell würde weniger als $1/7$ der PV-Kapazität ausreichen, um den gesamten Energiebedarf decken zu können. Jedoch sind die Speicher nicht wirtschaftlich genug, um saisonale PV-Überschüsse (intersaisonal) auf sonnenschwache Monate zu verschieben. Bei den modellierten thermischen Kurzzeitspeichern sind vor allem die Verluste zu hoch, die bei saisonalen Langzeitspeichern deutlich geringer wären. Beim elektrischen Speicher sind neben den energetischen Verlusten die Kapitalkosten im Vergleich zur PV-Anlage zu hoch. Die Speicher dienen hier vielmehr zum Ausgleich der Last weniger Tage bis maximal Wochen.

Die Festlegung des relativen wöchentlichen Speicherstands zwischen den Subprogrammen eines Szenarios anhand des relaxierten CP-Falls führt tendenziell dazu, den elektrischen Speicher leicht zu überschätzen. Für den Entscheider ist diese Abweichung jedoch vernachlässigbar klein. Denn sie hat einen marginalen Anteil an den erwarteten Gesamtenergiekosten. Hauptkostenfaktoren sind die bereits im relaxierten Fall benötigten elektrischen Speichergrößen und die immense PV-Anlage. Die Kosten für eine vollständige Autarkie würden noch höher ausfallen, wenn die tatsächlichen Kosten des Flächenbedarfs für die PV-Anlage berücksichtigt werden würden. Denn ohne Netzananschluss und Einrichtungen zur Frequenzhaltung des externen Netzes wäre der Betrieb nur mit Wechselrichtern der PV-Anlage und des elektrischen Speichers sehr anspruchsvoll: Ohne perfekte Voraussicht und ohne Trägheit der rotierenden Massen des externen Netzes müssten Leistungsanpassungen aufgrund von Laständerungen innerhalb extrem kurzer Reaktionszeiten erfolgen. So wären Investitionen in frequenzstabilisierende Komponenten erforderlich. Daneben würde die Übersteigerung der maximal möglichen Kapazität auf der Dachfläche ($\leq 75 \text{ kW}_p$) in den meisten Fällen in hohen Grundflächenpreisen (abhängig von lokalen Grundstückspreisen etc.) resultieren. Abgesehen davon müsste bei der zuständigen Gemeinde eine Baugenehmigung für eine Freiflächenanlage beantragt werden.

9.2 Kritische Würdigung der entwickelten Methodik

Das in der Arbeit entwickelte Optimierungsverfahren dient dazu, die optimale Investitions- und Einsatzplanung unter Unsicherheit aus Sicht des privaten Entscheiders zu finden. Dabei werden risikobehaftete Parameter durch die Stochastische Programmierung und ungewisse Parameter durch die Regret-Minimierung berücksichtigt. Um das Optimierungsprogramm mit den aktuell zur Verfügung stehenden Rechenressourcen lösen zu können, erfolgt eine Dekomposition mit anschließender Szenarioreduktion und paralleler Ausführung auf HPC-Systemen. Im Folgenden wird zunächst die Datengenerierung qualitativ bewertet (Abschnitt 9.2.1) sowie die Stärken und Schwächen des Optimierungsverfahrens erörtert (Abschnitt 9.2.2). Rechenaufwand (Abschnitt 9.2.3) und Skalierbarkeit (Abschnitt 9.2.4) werden im Anschluss gesondert diskutiert.

9.2.1 Qualitative Bewertung der angewandten Datengenerierung

Das in Kapitel 6 entwickelte Konzept zur Berücksichtigung von Unsicherheiten in der Optimierung ist in drei Ebenen unterteilt. Damit sollen bei der Datengenerierung risikobehaftete Unsicherheiten und deren Abhängigkeiten untereinander adäquat abgebildet und ein möglichst hoher Konsens erreicht werden. Insbesondere meteorologische Parameter beeinflussen Erzeugung und Verbrauch dezentraler Energiesystemen stark. Daher werden als Ausgangspunkt die benötigten meteorologischen Daten in der ersten Inputebene mittels Wettersimulations-Modul generiert. Um diese Daten zu generieren, wird ein zweistufiger Markov-Prozess erster Ordnung verwendet, der auf DWD-Wetterdaten der letzten 50 Jahre beruht. Insgesamt haben sich Markov-Prozesse als geeignet erwiesen, die Anforderungen der Problemstellung vorliegender Arbeit zu erfüllen und die Wechselwirkungen zwischen den benötigten Wetterdaten (Bewölkung, Temperatur und Globalstrahlung) zu berücksichtigen. Die erzeugten Wetterdaten zeigen im Vergleich zu historischen Daten des DWD ein zufriedenstellendes Ergebnis (siehe Anhang A). Von historischen Daten abweichende Ereignisse oder Trends, z. B. zukünftige Klimaentwicklungen, müssten durch modellgestützte Prognosen oder, falls verfügbar, durch Experteneinschätzungen berücksichtigt werden. Gegebenenfalls ist auch eine Anpassung des Optimierungsprogramms (Berücksichtigung verschiedener Perioden) erforderlich.

Die meteorologischen Daten werden in PV-Erzeugungsdaten transformiert. Dies gelingt anhand eines physikalischen Modells, das auf eine reale PV-Anlage in Karlsruhe mit den gleichen PV-Modulen der Fallstudie kalibriert ist. Eigene Untersuchungen haben ergeben, dass Sommerprofile akkurat nachgebildet werden und Winterprofile leicht überschätzt werden. Grund dafür ist die von Liu und Jordan (1960) empirisch ermittelte polynomische Gleichung zur Aufteilung der Globalstrahlung in direkte und diffuse Einstrahlung. Dabei wird die direkte Einstrahlung leicht überschätzt. Eine Verbesserung könnte durch andere (ortsspezifische) empirische Gleichungen zur Aufteilung in direkte und diffuse Einstrahlung erreicht werden.

Um die meteorologischen Daten in Elektrizitäts- und Wärmebedarfsprofile von 28 Wohneinheiten zu transformieren, wird ein Referenzlastprofil-Verfahren eingesetzt, das im Wesentlichen auf der VDI-Richtlinie 4655 (VDI 2008) basiert. In Lütke (2015) spricht der Vergleich mit einem physikalischen Modell des gleichen Gebäudes der Fallstudie in TRNSYS (professionelle Gebäude-Simulationssoftware) für das Referenzlastprofil-Verfahren, da mit deutlich weniger Aufwand gleichwertige Ergebnisse erzielt werden. Genauere Heizprofile ließen sich durch spezifische Referenzlastprofile ersetzen, die das Verhalten der zukünftigen Bewohner noch besser abbilden, z. B. mit Profilen

gleicher bzw. ähnlicher Bewohnergruppen. Damit könnten auch Informationen über das Heiz- und Lüftungsverhalten bestimmter Bewohner besser erfasst werden. Ein anderer Ansatz bindet künstliche neuronale Netze zur wetter- und bewohnerspezifischen Lastgenerierung ein. Huber (2016) konnte eine geringe Genauigkeitsverbesserung im Vergleich zu gemessenen WW-Bedarfsprofilen aufzeigen, zumindest für kurzfristige Lastprognosen (≤ 72 h). Speziell die elektrischen Lastprofile der VDI-Richtlinie sind für die Fallstudie mit H0-Profilen ersetzt worden. Denn diese zeigen eine starke Konvergenz gegenüber aggregierten Haushaltslasten auf, auch bei einer relativ geringen Anzahl von Haushalten (siehe Anhang A, u. a. Tab. A.3).

Das Strompreis-Modul bildet die historischen Spotmarktpreise mit dem statistischen Verfahren exakt und passend zu den generierten Wetterdaten der Inputebene ab (siehe Abb. A.1 sowie Tab. A.1 und Tab. A.2 im Anhang A). Jedoch werden Veränderungen im Energiemarkt, die sich auf die Preise auswirken, nicht berücksichtigt. So werden etwa der Ausbau erneuerbarer Energien oder der Ausstieg aus der Kernenergie in Deutschland bis 2022 nicht beachtet. Dafür wäre es nötig, ein Fundamentalmodell einzubinden. Auch der Einfluss des Strompreises auf den Verbrauch wird in der Transformationsebene außer Acht gelassen, weil nur wenige Daten zur Preiselastizität bekannt sind und diese nicht ohne Weiteres übertragbar sind. Bei bekannter, zuverlässiger Preiselastizität ließe sich diese im einfachen Fall in die Bedarfs-Datengenerierung integrieren. Im Fall einer endogenen zu bestimmenden Lastverschiebung der Nachfrage wären weitere binäre Variablen für die Integration in das Optimierungsprogramm nötig, was die Durchführbarkeit erheblich erschweren würde (siehe z. B. Burkhard 2015). Im schwierigsten Fall sind sowohl Strompreise als auch Nachfrage Entscheidungsvariablen, die aufgrund multiplikativer Verknüpfung zu einem NLP führen.

Mit der Input- und Transformationsebene sind zur Abbildung des Risikos 100 Szenarien für die Fallstudie generiert worden, um die Stochastik zu erfassen. Eine erneute Erstellung von 100 Szenarien des Referenzfalls mithilfe des Markov-Prozesses und deren Optimierung resultieren in einer nahezu identischen Lösung. Das spricht zumindest für eine gute Wiedergabe der stochastischen Eigenschaften der risikobehafteten Parameter. Grundsätzlich ist es nur ein Indiz, jedoch kein Beweis dafür.

Für die Berechnung wurden diese 100 Szenarien nach der Transformationsebene in jeweils 52 Teile entkoppelt und auf 1 865 Subprogramme reduziert, ohne die optimale Lösung wesentlich zu beeinflussen (gleichbleibende Investitionsplanung im Referenzfall und den Alternativfällen mit dynamischem Arbeitspreis und Leistungspreis; Änderung der optimalen Zielfunktionswerte $< 1\%$). Der Vorteil der angewandten Szenarioreduktionstechnik gemäß Gröwe-Kuska et al. (2003) besteht darin, dass mit Datenkomponen-

ten unterschiedlicher Dimensionen problemlos umgegangen werden kann – ohne dass Vorkenntnisse über die Daten erforderlich wären. Problematisch ist es, alle Komponenten gleich zu gewichten, obwohl beispielsweise Strompreise völlig anderes als der thermische Bedarf das optimale Ergebnis beeinflussen. Dieser Problematik wurde mit der Normierung auf die jeweilige Standardabweichung der Komponenten begegnet. Eine höhere Reduktion könnte erreicht werden, indem komponentenspezifische Wichtungen mittels Voruntersuchung des Parametereinflusses auf das Optimierungsergebnis bestimmt werden würden (siehe z. B. Dong et al. 2011 oder Burkhard 2015). Mit solch einer Sensitivitätsanalyse ließe sich auch eine Priorisierung der risikobehafteten Parameter erstellen. Je nach Parametereinfluss und den zur Verfügung stehenden Rechenressourcen könnten ausgewählte Parameter vernachlässigt werden. Ungeachtet dessen bestünde weiterhin bei der Szenarioreduktionstechnik das Problem, dass eine (In-)Koinzidenz der Komponenten nicht berücksichtigt werden würde. So ergibt sich z. B. für zwei Szenarien mit identischen PV-Profilen mit geringem zeitlichen Versatz eine merkliche Distanz zueinander, obwohl der Einfluss bei Speicheroptionen auf die optimale Lösung nahezu null ist. Abhilfe könnte schaffen, die Komponenten vorgelagert zu transformieren, z. B. indem Verbrauch und PV-Erzeugung zur Residualast zusammengefasst oder zu täglichen bzw. wöchentlichen Dauerlastlinien sortiert werden würden.

9.2.2 Stärken und Schwächen des Optimierungsverfahrens

Mit dem entwickelten Optimierungsverfahren können sowohl risikobehaftete als auch ungewisse Parameter berücksichtigt werden. Bestehend aus Stochastischer Programmierung und übergeordneter Regret-Minimierung, ist das Optimierungsprogramm aufgrund der hohen Anzahl von über 100 Millionen Entscheidungsvariablen und Restriktion extrem komplex. Erschwerend kommt hinzu, dass mehrere Millionen Entscheidungsvariablen ganzzahlig sind. Um das stochastische Programm mit derzeit verfügbarer Rechentechnik dennoch lösen zu können, wird eine Dekomposition angewandt. Hierfür werden Entkopplung und anschließender Optimierung der Subprogramme mit CPLEX (mit SMAC-optimierten Einstellungen) auf HPC-Systemen kombiniert. Das Masterprogramm wird durch einen ableitungsfreien Bergsteigeralgorithmus optimiert. Andere typische Dekompositionstechniken sind die Lagrange- oder Benders-Dekomposition. Diese genauen Algorithmen auf das Programm anzuwenden, würde zu einem nicht durchführbaren Rechenaufwand führen, der die derzeit allgemein verfügbaren Rechenressourcen übersteigt. Der Vergleich mit dem State-of-the-Art-Verfahren, DDSIP, das auf einer Lagrange-Dekomposition basiert (Abschnitt 9.2.4), bestätigt diese Behauptung.

tung. Es sei angemerkt, dass der verwendete Bergsteigeralgorithmus in der Fallstudie zuverlässig, robust und effizient innerhalb weniger Iterationen das Optimum findet. Trotzdem kann dieses heuristische Verfahren maximal lokale Optimalität garantieren. Der Algorithmus kann durch jedes beliebige ableitungsfreie Optimierungsverfahren ersetzt werden, auch durch globale Suchverfahren, wenn genügend Rechenkapazität zur Verfügung steht (siehe auch Abschnitt 9.2.3).

Trotz des entwickelten Optimierungsverfahrens bleibt die Investitions- und Einsatzplanung aus Sicht des privaten Entscheiders mit gewissen Unsicherheiten behaftet. Unvorhersehbare politische oder energiewirtschaftliche Entwicklungen lassen sich nur schwer modellieren, können aber jederzeit die Vorteilhaftigkeit von getroffenen Investitionsentscheidungen negieren.

Die Regret-Minimierung als äußeres Optimierungsprogramm hat prinzipiell den Nachteil, hochgradig sensitiv gegenüber der Auswahl an möglichen Fällen zu sein. Für Higle und Wallace (2002) trägt die Anwendung solcher Techniken in sich selbst ein hohes Risiko. Fälle, die vom Entscheider bewusst als Handlungsalternative gewählt werden können, sollten nicht in der Regret-Minimierung berücksichtigt und gesondert betrachtet werden.

Mit der Stochastischen Programmierung als inneres Optimierungsprogramm wird gezeigt, dass das Risiko unzureichender oder gar nicht realisierbarer Investitionsentscheidungen unter unsicheren zukünftigen Bedingungen reduziert wird. Sowohl im Referenzfall als auch in den Sonderfällen wäre es unzulässig, die deterministische Lösung mit Erwartungswerten der risikobehafteten Parameter zu verwenden. Zwar ist die PV-Anlage im Referenzfall um ca. 10 % überdimensioniert. Allerdings sind die thermischen Speicher im Vergleich zur stochastischen Lösung eher zu klein. Dies führt dazu, dass thermische Spitzenlasten in kalten Wintern nicht gedeckt werden können. Die Nichtdeckung der Energienachfrage spitzt sich im extremen Sonderfall vollständiger Autarkie zu, bei dem die Kapazität der PV-Anlage um deutliche 15 % unterschätzt wird, dazu mit viel zu kleinen Speichern. In der Realität müssten in allen Szenarien Stromausfälle in Kauf genommen werden. Mit der optimalen Investitionsplanung für Erwartungswerte, eingesetzt in das stochastische Programm, fällt der VSS mit erwarteten Gesamtenergiekosten um über 110 Mio. € höher aus (mit hohen Strafkosten für Hilfsenergiekosten i. H. v. $10.000 \text{ €/kWh}_{\text{th}}$ und $100.000 \text{ €/kWh}_{\text{el}}$).

Auch wenn der VSS in der Literatur unter Nutzung der Erwartungswerte der risikobehafteten Parameter bestimmt wird, zeigt der Vergleich vor allem, dass die Gradienten der Inputdaten ausgemittelt und dadurch deutlich unterschätzt werden können. Um den Wert der stochastischen Lösung besser einschätzen zu können, aber auch für deter-

ministische Optimierungen mit beschränkten Rechenressourcen, erscheint die Wahl eines tatsächlich möglichen Szenarios als geeigneteres Mittel.⁵⁷ Damit werden im Referenzfall nahezu optimale Investitionsplanungen erreicht. In den Sonderfällen werden bessere Ergebnisse berechnet. Diese zeigen aber mit immer noch 64 % höheren erwarteten Gesamtenergiekosten, dass die Stochastische Programmierung unentbehrlich ist, um risikobehaftete Unsicherheiten in extremen Fällen adäquat erfassen zu können. Hingegen ist der Wert einer guten Prognose der risikobehafteten Parameter sehr gering, angesichts des EXPI im Referenzfall kleiner als 1 %.

Generell kritisch bei der Stochastischen Programmierung ist, dass die Berücksichtigung risikobehafteter Unsicherheiten stark von der Abbildungsqualität der tatsächlichen Wahrscheinlichkeitsverteilungen abhängt (siehe dazu 9.2.1). Neben den Wahrscheinlichkeitsverteilungen sind die suffiziente Anzahl der generierten Szenarien und deren Reduktion, die die Verteilung ausreichend gut darstellen, nur schwierig zu bestimmen. Darüber hinaus kann die optimale Entscheidung unter Unsicherheiten von den Risikopräferenzen des Entscheidungsträgers abhängen (Pflug und Römisch 2007).⁵⁸ Die Ergebnisse vorliegender Arbeit basieren auf rein ökonomischen Überlegungen, ohne solche subjektiven Kriterien zu berücksichtigen.

Mit der verwendeten Annuitätenmethode wird ein annualisierter Kapitalwert der (erwarteten) Gesamtenergiekosten berechnet, unter der Annahme, dass Elektrizitätsbezug und -einspeisung ins externe Netz für alle Perioden gleich sind (siehe Abschnitt 4.1). Durch diese Annahme wird der tatsächliche optimale Energieaustausch mit dem externen Netz im Vergleich zum errechneten in den ersten Jahren des Betrachtungshorizonts überschätzt und in den letzten Jahren unterschätzt. Grund dafür ist, dass die nominalen Strompreise am Anfang des Betrachtungshorizonts real höher sind als am Ende (bei positivem Kalkulationszins). Dieser Effekt ist umso größer, je höher der Kalkulationszins gewählt wird und je größer die Änderung der Strompreise (oder anderer Parameter, z. B. die Globalstrahlung) über die Jahre des Betrachtungshorizonts ausfällt. Würden Ein- und Auszahlungen aller Perioden mit entsprechender Verzinsung berücksichtigt werden,

⁵⁷ Die Szenariowahl sollte für eine generelle Vergleichbarkeit nach einem einheitlichen Standard erfolgen: Neben der verwendeten Szenarioreduktion auf ein Szenario wäre auch denkbar, das Szenario mit der kleinsten Distanz zu den Mittel- oder Medianwerten aller Szenarien zu wählen. Die Distanz könnte bspw., ähnlich wie bei der verwendeten Szenarioreduktionstechnik, mittels euklidischer Distanz mit Normierung auf die Standardabweichung bestimmt werden.

⁵⁸ Die Einbindung der Risikopräferenzen in das bestehende Optimierungsprogramm wäre z. B. mit Risikonutzenfunktionen nach dem Bernoulli-Prinzip (Laux et al. 2014) oder Unsicherheitspräferenzfunktionen nach der Krelle-Regel (Obermaier und Saliger 2013) möglich.

dann könnten auch zeitlich versetzte Investitionsentscheidungen und damit verbundene Unsicherheiten in die Optimierung einbezogen werden. Jedoch würden sich alle Entscheidungsvariablen und Restriktionen des Optimierungsprogramms nahezu proportional mit jeder Periode verdoppeln (außer Erststufen-Variablen und -Restriktionen) – eine Durchführung des Programms wäre mit der verfügbaren Rechentechnik nicht möglich. Sollen alle Ein- und Auszahlungen unter realen Bedingungen berücksichtigt werden, ohne einen vollkommenen Kapitalmarkt anzunehmen (wie bei der Kapital- und Annuitätenmethode), erscheint bei unlimitierten Rechenressourcen die Endwertmethode am besten geeignet.

Aufgrund der verwendeten vereinfachten Annuitätenmethode kann auch nur eine Art mittlerer Degradation für eine Periode einkalkuliert werden, die für alle Perioden gleich ist. Mit der derzeitigen Implementierung wird jede Investition so behandelt, als wenn vom ersten Tag an nur die Kapazität zur Verfügung stünde, die am Ende des Betrachtungshorizonts vorhanden wäre. Diese recht konventionelle Annahme wurde gewählt, um stets die Erfüllung aller Restriktionen zu gewährleisten. Bei jeder anderen Einbindung, beispielsweise der degradierten Kapazität nach der halben Betrachtungsdauer, könnten Szenarien auftreten, deren Restriktionen in der Realität nicht erfüllt werden würden.

Eine weitere Vereinfachung des Modells besteht darin, die Anzahl der Zyklen bei der Lebensdauer zu vernachlässigen, die bei manchen Energiesystemkomponenten limitiert sind. Beispielsweise kann eine Einschränkung für das Anfahren der Wärmepumpen vom Hersteller gelten. Die in der Fallstudie erreichten Zyklen von weniger als 90 000 überschreiten nie die Grenze von 100 000 bis 150 000 Zyklen (Dimplex 2014). Ähnliches gilt für die durch die Lade- und Entladezyklen begrenzte elektrische Speicherung. Kaschub et al. (2016) rechnen mit 7 000 äquivalenten Vollzyklen für die maximale Zyklenzahl der Lithium-Ionen-Batterie. Diese Restriktion, die den Rechenaufwand deutlich erhöhen würde, wurde für die vorliegende Arbeit relaxiert, da nur in wenigen Szenarien die Zyklenzahl überschritten werden (stets $< 7\,400$). Daneben ist der zeitliche lineare Speicherungsverlust eine Vereinfachung, die grundsätzlich der Methodik der linearen Programmierung geschuldet ist. Insbesondere bei den thermischen Speichern werden dadurch temperaturbedingte Ausgleichsprozesse im Speicher selbst nicht berücksichtigt, die den zeitlichen Wärmeverlust an die Umgebung mitbeeinflussen.

9.2.3 Rechenaufwand des Optimierungsverfahrens

Das gesamte Optimierungsprogramm des Wohnquartiers mit 100 Szenarien ist geschlossen auf einem Rechner nicht durchführbar. Schon ein einzelnes Szenario zu berechnen, stellt eine Herausforderung dar und erreicht nach drei Rechentagen keine Lösung mit benötigter Lösungsqualität (MIP-Gaps $> 5\%$). Für die Bewältigung dieser rechentechnischen Herausforderung des Optimierungsprogramms bieten sich verschiedene Methoden an. Naheliegender ist die Reduzierung der zeitlichen Auflösung des Programms. Jedoch haben Schwarz et al. (2018a) gezeigt, dass eine Reduzierung von 15 auf beispielsweise 60 min die optimale Lösung entscheidend beeinflusst. Abb. 9.1 vergleicht exemplarisch 15-min-PV- und Stundenprofile auf der Angebotsseite.

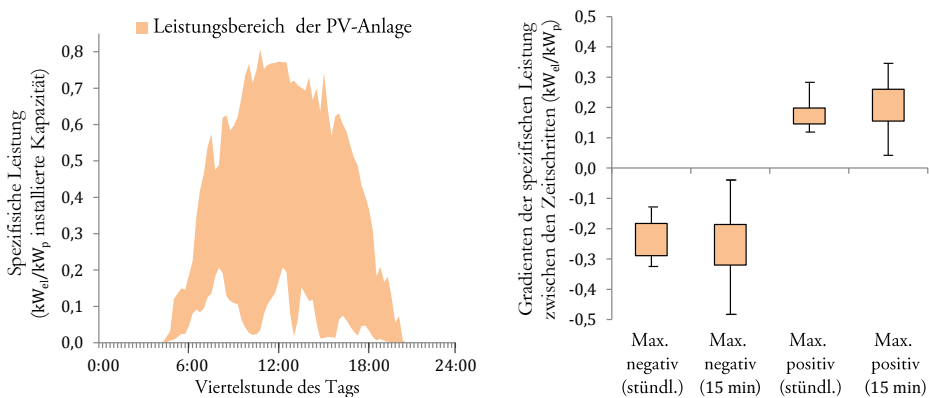


Abb. 9.1: Variabilität der PV-Erzeugung von 100 Szenarien (links) und der max. Gradienten (rechts) für einen exemplarischen Juni-Tag (Schwarz et al. 2018a).

Das linke Diagramm in Abb. 9.1 zeigt die Variabilität der PV-Leistung von 100 betrachteten Szenarien allgemein für einen Tag im Juni. Erzeugungsspitzen, teilweise auch Erzeugungseinbrüche, treten nur während kurzer Zeiträume auf (15-min-Intervalle statt Stunden). Maximale und minimale Ausschläge der PV-Strahlungszufuhr würden bei stündlichen Profilen ausgemittelt und unterschätzt werden.

Darüber hinaus sind bei der Auswahl der optimalen Kapazitäten der Energiesystemkomponenten die Gradienten der Leistungsabgabe zwischen den Zeitschritten sehr wichtig, insbesondere für Speicher. Das rechte Diagramm in Abb. 9.1 verdeutlicht, dass die maximalen positiven und negativen Gradienten bei einer stündlichen Auflösung im Gegensatz zu einer 15-min-Auflösung stark unterschätzt werden. Auch bestimmte Zeitabschnitte zu Blöcken zusammenzufassen, ist schwierig, wenn bedacht wird, dass sich

neben der Variation der PV-Anlage am Tag auch die Strompreise an der Börse alle 15 min ändern. Hinzu kommt, dass relativ kleine thermische Speicher durch die verwendeten Luft-Wasser-Wärmepumpen ($60 \text{ kW}_{\text{th}}$ Nennleistung) innerhalb kürzester Zeit befüllt sind (bei höheren Außenlufttemperaturen im Sommer und Übergang).

Abb. 9.2 zeigt für den Referenzfall (mit leicht abweichenden Strompreisen) die optimalen Speichergrößen für RW und WW für verschiedene zeitliche Auflösungen.




Abb. 9.2: Einfluss der zeitl. Auflösung auf die optimalen Kapazitäten für den Raumwärmespeicher (RWS) und den Warmwasserspeicher (WWS) (Schwarz et al. 2018a).

Bei Zeitschritten von 60 statt 15 min unterscheiden sich die optimalen Speichergrößen um bis zu 50 %. Grundsätzlich reduziert die geringere zeitliche Auflösung das Lastverschiebungspotenzial und mindert den wirtschaftlichen Nutzen von Speichern. Jedoch wird auch die graduelle Flexibilität der Wärmepumpen (Leerlauf, Halb- oder Volllast) reduziert, was die Wirtschaftlichkeit von Speichern erhöht. Dieser Effekt ist größer als das reduzierte Lastverschiebungspotenzial und resultiert in größeren Speicherkapazitäten bei größeren zeitlichen Auflösungen.⁵⁹

Die Entkopplung des Programms ermöglicht dessen Durchführung. Jedoch würde diese, sequenziell auf einem Rechner und mit Standard-CPLEX-Einstellungen, bis zu 26 Jahre dauern. Mit der Szenarioreduktion müssen nur 1 865 statt 5 200 Subprogramme ausgeführt werden, ohne die optimale Investitionsplanung zu verändern oder den optimalen Zielwert wesentlich zu beeinflussen. Mit den von SMAC gefundenen CPLEX-

⁵⁹ Für die vollständige Erfassung des gesamten Lastverschiebungspotenzials könnten Auflösungen von unter 15 min erforderlich sein. Mit 15-min-Zeitschritten könnten Speichergrößen, insb. elektrische, sowie Spitzenlasten vom oder ins Netz unterschätzt werden. Prinzipiell kann das entwickelte Optimierungsverfahren mit kleineren Zeitschritten umgehen. Doch neben dem Problem des erhöhten Rechenaufwands gibt es kaum konsistente Daten in höherer zeitlicher Auflösung.

Konfigurationen werden bis zu 50 % Rechenzeit bei der Optimierung eingespart (siehe Schwarz et al. 2019). Durch die parallele Optimierung auf HPC-Clustern, die CPLEX-optimierte Einstellungen mithilfe von SMAC und die Szenarioreduktion kann das gesamte stochastische Programm der Fallstudie mit Regret-Minimierung in weniger als einer Woche ausgeführt werden (siehe Tab. 9.1).

Tab. 9.1: Gesamte Rechenzeit für das stochastische Programm der Fallstudie mit Regret-Minimierung.

Gesamte Rechenzeit ...	1 Rechner & CPLEX (Default)	1 Rechner & CPLEX (Default) & Entkopplung	512 Rechner & CPLEX (SMAC) & Entkopplung & Szenarioreduktion
$N = 1$ Szenario	3 Rechentage ⁶⁰ (≈ 5 % MIP-Gap)	≈ 6 Rechentage (< 1 % MIP-Gap)	≈ 6 Rechenstunden ⁶¹ (< 1 % MIP-Gap)
$N = 100$ Szenarien	\emptyset	≈ 3 Rechenjahre	≈ 15 Stunden
$\theta = 7$ Fälle mit jeweils $N = 100$ Szenarien	\emptyset	≈ 26 Rechenjahre	≈ 5 Rechentage

Schwarz et al. (2018a) sehen den Vorteil des ableitungsfreien SAHC-Algorithmus zur Optimierung des Masterprogramms in der Robustheit gegenüber Lösungsungenauigkeiten der Subprogramme und in der zuverlässigen Lösungsfindung. Bei gutem Startpunkt und wenigen fixierten Variablen sind nur wenige Iterationen der rechenaufwendigen Subprogramme erforderlich. Nachteilig ist, dass keine Garantie auf globale Optimalität vorliegt, wenn der Lösungsraum nicht konvex ist. Ein globales Optimum kann entweder durch vollständige Enumeration oder exakte Algorithmen, wie die in Abschnitt 5.3 erwähnten Ansätze, gefunden werden. Jedoch erscheint die Anwendung wegen der Größe des Problems unmöglich. Beispielsweise wenden Pagès-Bernaus et al. (2015) ihre entwickelten Branch-and-Fix-Koordinationsmethodik auf zwei reale Instanzen mit 447 771 Variablen (davon 13 338 binär) und 56 700 Variablen (davon 34 479 binär) an. Einen dieser genauen Algorithmen auf die Fallstudie dieser Arbeit mit mehr als 100

⁶⁰ Die Berechnung mit CPLEX auf einem Rechner mit bis zu 1TB RAM und 32 Prozessoren (@ 2,4 bis 2,6 GHz) führt nach einer Laufzeit von 72 h zu einem MIP-Gap von ca. 5 %.

⁶¹ Die entkoppelten Subprogramme werden innerhalb von 15 min unter 1 % MIP-Gap ausgeführt. Dabei werden die fixierten Speicherstände mit plausiblen Werten vorgegeben (Fehlerabweichung $< 0,2$ %).

Millionen Variablen je Fall anzuwenden, würde zu einem Rechenaufwand führen, der die derzeit allgemein verfügbaren Rechenressourcen überstiege. Der Vergleich mit dem DDSIP im folgenden Abschnitt 9.2.4 bestätigt diese Behauptung.

Bei dem entwickelten, verhältnismäßig aufwendigen Optimierungsverfahren für dezentrale Energiesysteme stellt sich die Frage, wie sich dessen Effizienz in Abhängigkeit von den verfügbaren Rechenknoten verhält und ob überhaupt der gesamte Rechenaufwand wirtschaftlich gerechtfertigt ist. In Schwarz et al. (2019) wird die gesamte Rechenzeit des Referenzfalls (Abschnitt 8.3) in Abhängigkeit von der Anzahl der verwendeten CPU-Kerne analysiert. Dabei wird die benötigte Rechenzeit des Optimierungsverfahrens mit der Standardkonfiguration und den mit SMAC optimierten Konfigurationen für CPLEX verglichen. In Abb. 9.3 sind Gesamt-Rechenzeit in Sekunden und Rechenaufwand in Euro in Abhängigkeit von der Anzahl der CPU-Kerne dargestellt. Zudem wird der Aufwand für die SMAC-Konfiguration mit abgebildet.




Abb. 9.3: Gesamte Rechenzeit in Sekunden (durchgezogene Linien, linke logarithmisch skalierte Ordinatenachse) und gesamter Rechenaufwand in Euro (gepunktete Linien, rechte Ordinatenachse) in Abhängigkeit von den verwendeten CPU-Kernen (logarithmisch skalierte Abszissenachse) unter Verwendung der Standard-CPLEX-Konfiguration (schwarz) und der mit SMAC optimierten CPLEX-Konfiguration inklusive des Konfigurationsaufwands (rot) (Schwarz et al. 2019).⁶²

⁶² Die Rechnungen erfolgen mit einer vorgegebenen PV-Anlage von 75 kW_p und mit vom Referenzfall leicht abweichendem Kapitalzins und Strompreis. Der Rechenaufwand in Euro basiert auf sogenannten Amazon-EC2-Instanzen (<https://aws.amazon.com/ec2/pricing>): 0,215 € pro volle Stunde und Knoten mit zwei CPU-Kernen und 16 GB RAM, die für die CPLEX-Optimierung der Subprogramme benötigt werden.

Auf einem CPU-Kern reduziert sich die gesamte Rechenzeit mit der optimierten Konfiguration für CPLEX, anstelle der Standardkonfiguration, von 592 Tagen (51 149 983 s) auf 308 Tage (26 629 672 s). Infolgedessen sinken die gesamten Rechenkosten um ca. 50 % im Vergleich zur Optimierung mit der Standardkonfiguration (ca. 30 %, wenn die Suchzeit für die optimierten Konfigurationen berücksichtigt wird). Dieses Verhältnis von Rechenzeit und -kosten bleibt bei der Verwendung von bis zu ca. 100 CPU-Kernen unverändert. Über 100 CPU-Kerne hinaus steigen die Kosten, weil sich dann einige CPU-Kerne im Leerlauf befinden, während andere CPU-Kerne noch Subprogramme ausführen, deren Lösungen ebenso erforderlich sind, um das Masterprogramm zu optimieren. Ab ca. 6 000 CPU-Kernen negiert dieser Effekt die individuelle Rechenzeitverkürzung der Subprogramme durch die optimierte CPLEX-Konfiguration, sodass auch keine weitere Zeit- und Kostenersparnis erzielt werden kann.

Für die Berechnungen in Schwarz et al. (2019) werden bis zu 512 CPU-Kerne eines HPC-Clusters verwendet. Die reduzierte Rechenzeit beträgt ca. 15 h mit Rechenkosten i. H. v. 1.856 €, insgesamt 20 h und 2.414 € bei Berücksichtigung der Konfigurationszeit. Dem stehen Einsparungen der erwarteten Gesamtenergiekosten von 358 bis 3.500 € im Referenzfall gegenüber, abhängig vom gewählten Szenario der deterministischen Optimierung als Benchmark. Dabei ist hervorzuheben, dass der Aufwand für das Auffinden der optimierten Konfiguration für den CPLEX-Solver nur einmalig anfällt. Hingegen kann die gefundene Konfiguration verwendet werden, um die Subprogramme für verschiedene Fälle effizienter zu lösen. Daher konnte für die betrachteten Fälle in Summe mehr Rechenzeit und -kosten eingespart werden, als in Abb. 9.3 dargestellt ist.

9.2.4 Skalierbarkeit des Optimierungsverfahrens

Die Skalierbarkeit des Optimierungsverfahrens wird durch Schwarz et al. (2018a) bewertet. Hierfür wird die Fallstudie in unterschiedlicher Komplexität getestet. Zusätzlich wird das Verfahren mit dem – dem State of the Art entsprechenden – DDSIP-Algorithmus für zweistufige stochastische Programme verglichen. DDSIP wurde von Carøe und Schultz (1999) speziell für die Dekomposition und Optimierung zweistufiger SMILP entwickelt und bis heute kontinuierlich verbessert.⁶³ Die Hauptidee der Dekomposition besteht in der Lagrange-Relaxierung der Nichtantizipativitäts-Restriktion und einem Branch-and-Bound-Algorithmus zur Wiederherstellung der Nichtantizipati-

⁶³ Die Linux-Version kann unter <https://www.uni-due.de/~hn215go/ddsip.shtml> heruntergeladen werden.

vität. Die Lösungen der gemischt-ganzzahligen Subprogramme im Branch-and-Bound-Baum werden mit dem CPLEX-Solver ermittelt. Um die Dualvariablen zu optimieren, nutzt DDSIP das ConicBundle-Verfahren nach C. Helmberg.⁶⁴

Sowohl SAHC als auch DDSIP benötigen die Lösung der zweiten Stufe, um entweder den steilsten Abstieg der fixierten Variablen oder den Abstiegschritt des dualen Problems durchzuführen. Die Optimierung der Subprogramme in der zweiten Stufe ist identisch. Wird angenommen, dass immer genügend Knoten zur Verfügung stehen, um alle Subprogramme gleichzeitig auszuführen, so sind nur die Iterationen des Masterprogramms zeitentscheidend für die Berechnung und den Vergleich beider Algorithmen.

Es wird nur der schwierigere Fall betrachtet, wenn in beiden Stufen ganze Zahlen beteiligt sind: diskrete Speichergrößen in der ersten Stufe und Heizleistungsstufen der Wärmepumpen (Leerlauf, Halb- oder Volllast) in der zweiten Stufe. Die Optimierung erfolgt bei Programmen mit zwei, vier und acht Erststufen-Variablen, um die Anzahl der fixierten Variablen zu variieren.⁶⁵ Weil DDSIP die Subprogramme derzeit nur sequenziell ausführt, werden die Szenarien auf zweitägige Subprogramme vereinfacht und auf eins, zwei, fünf und zehn Szenarien reduziert. Die Ergebnisse sind in Tab. 9.2 zusammengefasst. Dabei ist zu beachten, dass nur die Anzahl der Iterationen der Optimierung des Masterprogramms verglichen wird.

DDSIP übertrifft die Performance des SAHC-Algorithmus, wenn nur ein Szenario optimiert wird, weil hier keine Nichtantizipativitäts-Restriktion vorhanden ist (Erststufen-Variablen müssen keinem anderen Szenario gleichen). Es ist zu erkennen, dass DDSIP eine Zunahme der Erststufen-Variablen besser verarbeiten kann als eine Zunahme der Szenarien. Die Anzahl der Iterationen steigt leicht an, wenn weitere Erststufen-Variablen hinzugefügt werden. Jedoch nehmen die Iterationen mit der Anzahl der Szenarien stark zu, die DDSIP benötigt, um eine gültige optimale Lösung zu finden.

⁶⁴ Für die Berechnung werden die Standardkonfigurationen von DDSIP mit ConicBundle verwendet. ConicBundle erfordert keine Anpassung der Schrittzahl oder -weite bei der Minimierung der Summe der konvexen Funktionen, die sich aus der Lagrange-Relaxierung ergeben. Unterstützt wird das Finden optimaler dualer Multiplikatoren durch Generierung der primalen optimalen Lösungen sowie durch Hinzufügen und Löschen von Dualvariablen (siehe Märkert und Gollmer 2016).

⁶⁵ In Schwarz et al. (2018a) werden nur die thermischen Speicher optimiert und die Anzahl der fixierten Variablen durch Hinzunahme weiterer, thermisch unabhängiger Gebäudegruppen variiert.

Tab. 9.2: Anzahl der Iterationen der Optimierung des Masterprogramms: DDSIP im Vergleich zum SAHC-Algorithmus (die Lösung je betrachtete Instanz ist für beide Methoden identisch). Die Suche wird immer mit einem 800-l-Wassertank für den RW- und WW-Speicher mit einer Anfangsschrittweite von 400 l initialisiert (in Anlehnung an Schwarz et al. 2018a).

	1 Szenario	2 Szenarien	5 Szenarien	10 Szenarien
Fixierte Variablen	DDSIP SAHC	DDSIP SAHC	DDSIP SAHC	DDSIP SAHC
2 Erstst.-Variablen	1 8	14 8	> 71 7	>139 7
4 Erstst.-Variablen	1 7	16 10	>109 16	>150 9
8 Erstst.-Variablen	1 8	22 14	>150 13	>150 14

Im Gegensatz dazu benötigt der SAHC-Algorithmus immer eine ähnliche Anzahl von Iterationen für wenige oder viele Szenarien. Die Iterationen nehmen nur mit mehr Erststufen-Variablen zu, die optimiert werden sollen. Wenn die Anzahl der fixierten Variablen jedoch gering bleibt, benötigt SAHC nur wenige Iterationen. Zu beachten ist, dass die lokal optimalen Lösungen des SAHC-Algorithmus mit den global optimalen Lösungen des DDSIP-Algorithmus identisch sind. Die Analyse von Schwarz et al. (2018a) berücksichtigt nicht das hohe Potenzial an Rechenzeitverkürzung der Subprogramme. Dieses ergibt sich aufgrund einer hohen Toleranz des SAHC-Algorithmus (in den meisten Iterationen) gegenüber der Lösung der Subprogramme.

Bei vielen fixierten Variablen sollte eine andere ableitungsfreie Optimierung (z. B. ein Surrogat-Modellansatz wie SMAC) gewählt werden. Eine stochastische dynamische Programmieretechnik wird nicht angewendet, da durch den stufenweisen Optimierungsprozess die parallele Ausführung aller Subprogramme unabhängig voneinander nicht mehr möglich wäre. Approximative dynamische Programmierungstechniken werden nicht eingesetzt, weil deren Lösungen in der Regel nicht optimal sind.

10 Schlussbetrachtung

Als finale Betrachtung wird in Abschnitt 10.1 die Forschungsarbeit zur Beantwortung der Forschungsfrage wiederholend zusammengefasst. In Abschnitt 10.2 werden die wichtigsten Erkenntnisse der Arbeit hervorgehoben und in Abschnitt 10.3 der wesentliche Beitrag mit einem Ausblick für die Zukunft ausformuliert.

10.1 Zusammenfassung der Forschungsarbeit

Die Arbeit wird motiviert durch die zunehmende Dezentralisierung der Energieversorgung mit einem deutlichen Ausbau der erneuerbaren Energien. Diese Restrukturierung des Energiesystems führt zu erhöhten Fluktuationen und nicht unerheblichen Unsicherheiten. Deswegen soll mit dieser Arbeit eine Antwort darauf gefunden werden, wie dezentrale Energiesysteme unter Berücksichtigung von Unsicherheiten optimiert und gleichzeitig die anfallenden rechentechnischen Herausforderungen adäquater Optimierungsverfahren bewältigt werden können. Ziel der Arbeit ist es, ein Verfahren aus Sicht des privaten Entscheiders zu entwickeln, das dazu dient, Investitionsplanungen eines dezentralen Energiesystems langfristig und die Einsatzplanung desselben kurzfristig zu optimieren. Dabei sollen plausibel erfassbare Unsicherheiten berücksichtigt und der Mehrwert der Einbindung von Unsicherheiten aufgezeigt werden.

Zunächst wird ein Einblick in den energiewirtschaftlichen Gesamtrahmen einschließlich politischer Rahmenbedingungen für dezentrale Energiesysteme gegeben. Sodann folgt ein theoretischer Teil über dezentrale Energiesysteme und über optimale Investitions- und Einsatzplanung der Energiesystemkomponenten. Neben gängigen Optimierungsverfahren werden vor allem die eingesetzten Verfahren zur Berücksichtigung von Unsicherheiten vorgestellt und mit anderen Arbeiten in der Literatur verglichen.

Für die Investitions- und Einsatzplanungsoptimierung dezentraler Energiesysteme wird ein ganzheitliches, modulbasiertes Framework entwickelt. Dies dient dazu, unsichere Parameter dezentraler Energiesysteme und ihre Abhängigkeiten konsistent über die Modellkette zu modellieren und weiterzugeben. Zu Beginn werden meteorologische Eingangsdatenszenarien mithilfe von Markov-Prozessen erstellt. In einem anschließenden Transformationsprozess werden die erforderlichen Daten für das Optimierungsmodul bereitgestellt: PV-Ertragsdaten durch ein physikalisches Modell, Elektrizitäts-, Raumwärme- und Warmwasserenergiebedarf mittels Referenzlastprofil-Verfahren sowie

dynamische Preise der EPEX mittels statistischer Verfahren. Schließlich werden die Energiesystemkomponenten des dezentralen Energiesystems in einem zweistufigen stochastischen gemischt-ganzzahligen linearen Programm mit einer übergeordneten Regret-Minimierung bewertet und optimiert, um sowohl risikobehaftete als auch ungewisse Unsicherheiten zu berücksichtigen. Für die Berechnung wird das komplexe Programm durch Fixierung Szenario-verbindender Variablen in Subprogramme entkoppelt und parallel auf High-Performance-Computing-Systemen ausgeführt. Des Weiteren wird der Rechenaufwand mittels Szenarioreduktion und automatischer Optimierung der CPLEX-Einstellungen erreicht. Die fixierten Variablen werden durch einen einfachen, robusten Bergsteigeralgorithmus optimiert.

In einer Fallstudie wird die optimale Investitionsplanung mit kostenminimalem Betrieb der Energiesystemkomponenten für ein Wohnquartier in Karlsruhe endogen ermittelt, und zwar für einen Betrachtungshorizont von 20 Jahren (Startdatum: 1.1.2016). Für die Investitionsplanung stehen eine PV-Anlage, Wärmepumpen mit thermischen Speichern für Raumwärme sowie für Warmwasser und ein elektrischer Speicher zur Auswahl. Risikobehaftete Parameter sind PV-Angebot, thermisches Angebot und Wirkungsgrad der Luft-Wasser-Wärmepumpen, elektrische und thermische Nachfrage der Haushalte sowie Großhandels- und Arbeitspreise für den Handel elektrischer Energie. Diese Parameter werden durch Szenarien für ein Jahr mit 15-min-Auflösung im zweistufigen stochastischen Programm berücksichtigt. Ungewisse Parameter sind die langfristige Entwicklung der Strompreise einschließlich der Bepreisungsform des externen Energieversorgers, die gesetzliche Eigenverbrauchsabgabe für PV-Strom sowie der individuelle, inflationsabhängige Kalkulationszins. Diese Parameter werden über verschiedene Alternativfälle in der Regret-Minimierung berücksichtigt.

Es ist zu bestimmen, welchen Mehrwert das entwickelte Optimierungsverfahren unter Einbindung risikobehafteter und ungewisser Unsicherheiten bietet. Dazu werden die stochastischen Lösungen des Referenzfalls und zweier Sonderfälle mit niedrigem Arbeitspreis oder vollständiger Autarkie separat betrachtet und mit deterministischen Lösungen verglichen. Daneben bringen die zwei Sonderfälle nützliche Erkenntnisse über die Investitions- und Einsatzplanung zukünftiger Wohnquartiere oder anderer dezentraler Energiesysteme. Sie fließen jedoch nicht als ungewisse Fälle in die Regret-Minimierung ein, da angenommen wird, dass sie in den nächsten 20 Jahren für das betrachtete Wohnquartier in Deutschland nicht eintreten werden.

10.2 Erkenntnisse der Arbeit

Als wesentliche Erkenntnis lässt sich festhalten, dass PV-Anlagen in solchen Wohnquartieren unter allen betrachteten Fällen und Tarifen wirtschaftlich vorteilhaft sind, außer im Fall eines extrem niedrigen Arbeitspreises für den Quartiersstrombedarf i. H. v. $8,7 \text{ ct}_{\text{€}}/\text{kWh}_{\text{el}}$. Die PV-Eigenverbrauchsquoten und Autarkiegrade variieren in erster Linie mit der Kapazität der PV-Anlage. Was die nachfrageseitigen Flexibilitätsoptionen für eine verbesserte PV-Integration betrifft, so sind vor allem thermische Speicher in Kombination mit Wärmepumpen vorteilhafter als elektrische Speicher. Bei einem getrennten Heizkreislauf sind insbesondere Schichtspeicher für Warmwasser aufgrund ihres geringen Kapitalbedarfs und der ganzjährigen konstanten Auslastung rentabel und vorteilhaft. Speicher für Raumwärme dienen eher dazu, das Risiko zu verringern, den Heizbedarf in kalten Wintern nicht decken zu können.

Eine Marktdurchdringung dezentraler Energiesysteme mit erneuerbaren Energien kann entweder durch vorteilhafte Zinsbedingungen als Investitionsanreiz erreicht werden oder durch hohe Arbeitspreise, die einen Anreiz für eine gesteigerte Eigenversorgung geben. Dynamische Preise erhöhen die Wirtschaftlichkeit in der Fallstudie nur leicht, jedoch kann die Spitzenlast ohne Anreiz zur Reduktion stark ansteigen. Hingegen wirken Leistungspreise mit dem aktuellen, um Netzentgelte geminderten Arbeitspreis dem Ausbau der PV-Anlagen stark entgegen. Dabei sinkt die Spitzenlast um bis zu 35 % und deren Variationsbreite von 16 auf 4 kW_{el} infolge des angepassten, optimalen Betriebs der Wärmepumpen und Speicher. Energiegemeinschaften wie Wohnquartiere würden von einer solchen Tarifoption finanziell profitieren. Dagegen wären Einzelhaushalte mit hohen Spitzenlasten im Verhältnis zum niedrigen Energieverbrauch benachteiligt.

Mit der Stochastischen Programmierung als inneres Optimierungsprogramm wird gezeigt, dass das Risiko unzureichender oder nicht realisierbarer Investitionsentscheidungen unter unsicheren zukünftigen Bedingungen reduziert werden kann. Würde das Problem mit Erwartungswerten der risikobehafteten Parameter deterministisch optimiert werden, würden insuffiziente Investitionsplanungen getroffen werden. Diese wiederum würden zur Nichtdeckung der Energienachfrage bzw. zu hohen Strafkosten führen. Besonders verheerend sind die Auswirkungen im betrachteten Sonderfall vollständiger Autarkie, bei dem die benötigten Kapazitäten von PV-Anlage und Speichern deutlich unterschätzt werden. In der Realität müssten in allen Szenarien Stromausfälle in Kauf genommen werden. Diese Lösung der Erwartungswerte, eingesetzt in das gesamte stochastische Programm, führt aufgrund hoher Strafkosten zu über 110 Mio. € erwarteten Gesamtenergiekosten im Vergleich zur stochastischen Lösung mit etwa 200.000 €.

Um den Wert stochastischer Lösungen zu bewerten, aber auch deterministische Optimierungen bei beschränkten Rechenressourcen durchzuführen, erscheint ein repräsentatives Szenario geeigneter. Damit werden bessere bis nahezu optimale Investitionsplanungen erreicht. In extremen Fällen, beispielsweise bei vollständiger Autarkie und erwarteten Gesamtenergiekosten von weiterhin über 100 Tsd. € zeigt sich, dass die Stochastische Programmierung mit einer Vielzahl an Szenarien unentbehrlich ist, um risikobehaftete Unsicherheiten adäquat erfassen zu können. Die dafür angefallenen Rechenkosten von wenigen Tausend Euro fallen dabei kaum ins Gewicht, mit der Perspektive, dass die aktuellen Kosten für Rechenressourcen im Laufe der Zeit weiterfallen werden.

Ohne die äußere Regret-Minimierung des gesamten Optimierungsprogramms könnte der private Entscheider einen doppelt so hohen Regret erleiden, wenn er sich für die (robuste) Lösung in der Fallstudie mit hohem Kalkulationszins entscheiden würde. Denn die resultierende geringe Investition ins Energiesystem führt beim Eintritt hoher Arbeitspreise zu sehr hohen erwarteten Betriebs- und damit Gesamtenergiekosten, die der Entscheider am meisten bereuen würde. Hingegen führt die Lösung des Referenzfalls zum minimalen (erwarteten) Regret in allen anderen Fällen. Daraus lässt sich aber nicht schließen, dass der Referenzfall mit unveränderten Strompreis- und mäßigen Zinsannahmen stets den minimalen Regret ergäbe. Dieser muss bei jeder Änderung der betrachteten Fälle erneut berechnet werden.

Zum Status quo der Optimierung dezentraler Energiesysteme kann gesagt werden, dass die Literatur in den letzten Jahren stark angewachsen ist. Jedoch berücksichtigt dabei keine der Arbeiten Unsicherheiten mit der erforderlichen hohen zeitlichen Auflösung von mindestens 15 min für die Investitions- und Einsatzplanungsoptimierung. In einem Forschungsüberblick wurden verschiedene Optimierungsverfahren aufgezeigt, mit denen Unsicherheiten und deren rechentechnische Herausforderungen berücksichtigt werden. Die vorliegende Arbeit demonstriert anhand geeigneter Verfahren, dass auch extrem komplexe stochastische Programme mit übergeordneter Regret-Minimierung zerlegbar und in Kombination mit Szenarioreduktion und optimierten Solver-Einstellungen auf High-Performance-Computing-Systemen durchführbar sind.

Um das Masterprogramm zu optimieren, wurde bewusst ein Bergsteigeralgorithmus gewählt. Denn dieser benötigt in der Fallstudie nur wenige Iterationen der rechenintensiven Evaluationen der Subprogramme. Außerdem ist der zuverlässige und robuste Lösungsprozess vorteilhaft. Insbesondere ist hier die hohe Toleranz gegenüber Lösungsungenauigkeiten der Subprogramme zu nennen. Dadurch kann die Rechenzeit beträchtlich verringert werden. Eine höhere Lösungsgenauigkeit der Subprogramme wird erst in der Nähe des Optimums benötigt.

10.3 Beitrag der Arbeit und Ausblick

Mit der Arbeit wurde ein Verfahren für Investitions- und Einsatzplanungsoptimierung dezentraler Energiesysteme unter plausibel erfassbaren Unsicherheiten aus Sicht des privaten Entscheiders abgeleitet und dessen Mehrwert gegenüber der deterministischen Optimierung aufgezeigt. Dafür sind grundlegend dezentrale Energiesysteme definiert sowie Unsicherheiten, die bei der Optimierung des Energiesystems auftreten können. Die Unsicherheiten werden klar in (probabilistisches) Risiko, (nicht probabilistische) Ungewissheit und Unwissen getrennt. Unwissen wird in der Arbeit nicht weiter berücksichtigt, da es nicht als plausibel erfassbar erscheint.

Für die Einordnung in den derzeitigen Wissensstand wird zunächst ein Forschungsüberblick über Investitions- und Einsatzplanungsoptimierung dezentraler Energiesysteme generell gegeben. Gesondert davon beinhaltet die vorliegende Arbeit einen Forschungsüberblick über Optimierungsverfahren unter Unsicherheit und deren rechen-technische Herausforderungen. Die verwendete Stochastische Programmierung und die Regret-Minimierung werden theoretisch beschrieben und in einem neu entwickelten Programm kombiniert, das Risiko und Ungewissheit berücksichtigt. Für dieses Programm wurde ein generelles Framework erarbeitet, um unter anderem risikobehaftete Unsicherheiten und deren Interdependenzen adäquat abzubilden und über eine geschlossene Modellierungskette dem Optimierungsprogramm bereitzustellen. Da insbesondere meteorologische Parameter Energieangebot und -nachfrage dezentraler Energiesysteme stark beeinflussen, werden diese mit Markov-Prozessen in einem Wetter-simulations-Modul generiert. Die Wetterdaten werden anschließend mit physikalischen, statistischen oder Referenzlastprofil-Verfahren in die für die Optimierung erforderlichen Daten transformiert. Das modulare Framework ermöglicht es, die Datengenerierung für jedes beliebige dezentrale Energiesystem individuell anzupassen.

Als wissenschaftlicher Neuwert kann auch die eingesetzte Methodik zur Durchführung des Programms gezählt werden. Erst durch die Entkopplung des Programms mit anschließender angepasster Szenarioreduktionstechnik wird die Optimierung mit aktueller Rechentechnik ermöglicht. Neu bei energiewirtschaftlichen Optimierungsproblemen ist zudem die parallele Berechnung auf High-Performance-Computing-Systemen, um die Lösungen mit akzeptabler Genauigkeit und Rechenzeit zu erhalten. Dabei wird aufgezeigt, dass der Rechenaufwand durch automatische Algorithmuskonfiguration des verwendeten Solvers erheblich reduziert werden kann. Rechenaufwand und Skalierbarkeit des entwickelten Optimierungsprogramms werden diskutiert und mit einem State-of-the-Art-Verfahren für zweistufige stochastische Programme verglichen.

In der vorgestellten Fallstudie eines Wohnquartiers mit PV-Anlage, Wärmepumpen sowie elektrischen und thermischen Speichern ist die kombinierte Optimierung von Wärme- und Elektrizitätsangebot sowie -nachfrage eines dezentralen Energiesystems einzigartig. Damit liefert die Arbeit einen wichtigen Beitrag zur aktuellen Umstrukturierung der Energieversorgung und Integration erneuerbarer Energien. Insbesondere die sektorenübergreifende Untersuchung trägt zur aktuellen Debatte der Dekarbonisierung des Wärmesektors und nötigen Flexibilisierung des Energiesystems bei.

Besonders ist die Berücksichtigung verschiedener Unsicherheiten bei hoher zeitlicher Auflösung mit langfristigem Betrachtungshorizont. Dabei wird gezeigt, dass insuffiziente Investitionsplanungen vermieden werden können, im Extremfall sogar drohende Blackouts des Energiesystems. Außerdem wird die in der Literatur häufig vorgeschlagene Bewertung der stochastischen Lösung mit der deterministischen Lösung der Erwartungswerte risikobehafteter Parameter aufgezeigt. Vergleichend wird die Lösung eines repräsentativen, tatsächlich möglichen Szenarios vorgestellt. Mit diesem Szenario können bessere Ergebnisse mit geringerem Risiko erzielt werden, auch bei Rechenleistungsbeschränkungen. Der Mehrwert der Optimierung unter Berücksichtigung von Risiko sollte künftig nicht mehr anhand von Erwartungswerten der unsicheren Parameter, sondern anhand eines tatsächlich möglichen, repräsentativen Szenarios bestimmt werden. Extreme Fälle wie beispielsweise vollständiger Autarkie zeigen, dass die Stochastische Programmierung mit einer Vielzahl an Szenarien unentbehrlich ist, um risikobehaftete Unsicherheiten adäquat erfassen zu können. Neben der bekannten Stochastischen Programmierung ist mit der übergeordneten Regret-Minimierung eine Investitionsplanung hervorgebracht, die der private Entscheider im schlimmsten Fall am wenigsten bereuen würde. In der Fallstudie kann damit der maximale (erwartete) Regret um 50 % gesenkt werden.

Mit dem entwickelten Gesamtkonzept zur Optimierung dezentraler Energiesysteme unter Unsicherheiten wird dargelegt, dass Detailtiefe der Modellierung und Berücksichtigungsgrad der Unsicherheiten prinzipiell von der verfügbaren Rechentechnik abhängig sind, die stetig voranschreitet und mit jedem Jahr komplexere, rechenintensivere Programme zulässt. Für die zukünftige Optimierung dezentraler Energiesysteme ist ggf. eine höhere zeitliche Auflösung erforderlich. Dies gilt es zu untersuchen. Erstrebenswert wäre auch, die Annuitäten- oder Kapitalmethode ohne Annahmen zur Vereinfachung anzuwenden, damit Ein- und Auszahlungen aller Perioden vollständig berücksichtigt werden können. Dem gesteigerten Rechenaufwand könnte mit verbesserter, programmspezifischer Szenarioreduktion oder Solver-Technik der Subprogramme begegnet werden, letzteres beispielsweise durch Implementation einer speziell erweiterten Benders-

Dekomposition. Daneben könnte ein effizienter ableitungsfreier Algorithmus des Masterprogramms (denkbar wäre z. B. das Programm SMAC) Abhilfe für den hohen Rechenaufwand schaffen. Auch die Einbindung künstlicher Intelligenz in die Optimierung erscheint aussichtsreich und würde neue Wege in der Optimierung eröffnen.

Die nachfolgende Energieforschung sollte sich verstärkt darauf konzentrieren, effiziente Integrationsmöglichkeiten dezentraler Energiesysteme zu analysieren, z. B. über verschiedene Tarifoptionen oder andere Anreize. Um der Integration von erneuerbarem Energien in das Energiesystem besser gerecht zu werden, muss sich in Zukunft der Einsatz dezentraler Anlagen stärker am Energiemarkt orientieren; eine Flexibilisierung der Energienachfrage und des Energieangebots ist dazu unumgänglich. Stärkere Anreize für Investitionen in Speicher oder Demand-Side-Management-Maßnahmen und gleichzeitig Mechanismen zum netzdienlichen Betrieb werden benötigt, um zu einer hohen Versorgungssicherheit beizutragen. Bei immer weniger grundlastfähigen Kern- und Kohlekraftwerken und mehr dezentralen Systemen mit erneuerbaren Energien und niedriger gesicherter Leistung muss das sich langfristig abzeichnende Versorgungsproblem ganzheitlich untersucht werden: sektoren-, technologien-, regionen- und ggf. staatenübergreifend. In diesem Zusammenhang sollten auch die Auswirkungen einer zunehmenden Eigenversorgung auf das Netz und die anderen Teilnehmer im gesamten Energiesystem berücksichtigt werden. Gerade die Ergebnisse der vorliegenden Arbeit zeigen den hohen Bedarf, die zukünftige Verteilungsgerechtigkeit der Energiekosten angesichts sozialer, ökologischer und ökonomischer Restriktionen und Ziele zu erforschen. Zugleich obliegt jedem einzelnen die Verantwortung, dabei mitzuwirken, die energiewirtschaftlichen, politischen und klimatischen Herausforderungen gemeinsam zu bewältigen.

Anhänge

A Validierung der Input- und Transformations-Module

Für die Validierung der erzeugten Wetterdaten werden diese mit historischen Daten des DWD verglichen und dabei kurz- und langzeitige Indikatoren verwendet. Im Folgenden ist die Bewertung der Globalstrahlung aufgezeigt, welche neben der Gesamtjahreseinstrahlung verschiedene Indikatoren gemäß Schermeyer et al. (2015) enthält. Hierfür sind langzeitige, historische Messdaten nur in stündlicher Auflösung verfügbar, weshalb der Modul-Output zweckdienlich von 15 min auf 1 h aggregiert ist.

Sei $\rho_a = (\rho_a^1, \dots, \rho_a^{8760})$ eine stündliche Serie der horizontalen Globalstrahlung im Jahr a , mit $a \in \{1971, \dots, 2011\}$ für die historischen Daten und $a \in \{1, \dots, 100\}$ für den Output des Wettersimulations-Moduls. Es werden für die Validierung vier Indikatoren herangezogen: (i) die Gesamtjahreseinstrahlung $P_a = \sum_{h=1}^{8760} \rho_a^h$ als Langzeit-Indikator im Jahr a , (ii) die stündliche Volatilität $vola_a = \sigma(\rho_a)/\mu(\rho_a)$ als Kurzzeit-Indikator im Jahr a , wobei $\sigma(\rho_a)$ und $\mu(\rho_a)$ die Standardabweichung bzw. das arithmetische Mittel der Globalstrahlung im Jahr a sind, (iii) die maximale Einstrahlungsamplitude MEA_a im Jahr a sowie (iv) der maximale Einstrahlungsgradient MEG_a im Jahr a . Um die langzeitige Performance des Moduls und den entsprechenden Variationsbereich zu bewerten, erfolgt der Vergleich des arithmetischen Mittels $\mu(\cdot)$, des 5%-Quantils $quant_{5\%}(\cdot)$ und des 95%-Quantils $quant_{95\%}(\cdot)$ dieser vier Indikatoren für alle verfügbaren Jahre. Die relativen Abweichungen der Mittelwerte und Quantile der vier Indikatoren (simulierte im Vergleich zu historischen Daten) sind in Tab. A.1 aufgeführt:

Tab. A.1: Vergleich der simulierten und historischen Wetterdaten mittels vier ausgewählter Indikatoren.

Indikatoren	Relative Abweichung von...		
	$\mu(\cdot)$	$quant_{5\%}(\cdot)$	$quant_{95\%}(\cdot)$
P_a	0 %	6 %	-3 %
$vola_a$	-4 %	-3 %	-6 %
MEA_a	7 %	4 %	10 %
MEG_a	8 %	-2 %	5 %

Für die Validierung der erzeugten Day-ahead-Preise des PHELIX-Spotmarkts der EPEX werden vier zufällig ausgewählte Jahre mit historischen Preisen von 2012 bis 2015 als Dauerlinie in Abb. A.1 verglichen. Zusätzlich werden wesentliche Kennzahlen der er-

zeugten Preisszenarien mit historischen Beobachtungen in Tab. A.2 gegenübergestellt. Der Vergleich zeigt, dass die simulierten Preise den historischen Preisverlauf sehr gut abbilden.

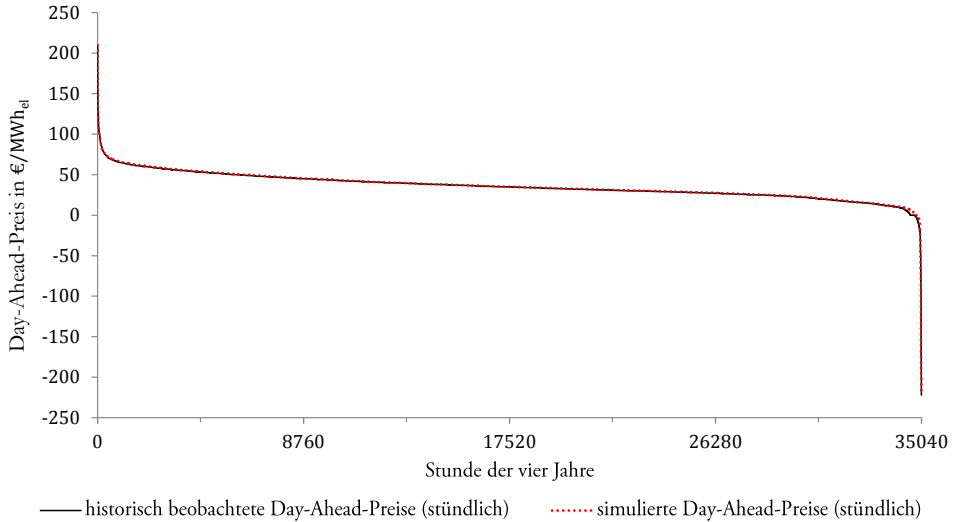


Abb. A.1: Preis-Dauerlinie von historisch beobachteten und simulierten stündlichen Day-ahead-Preisen (PHELIX-Spotmarkt) für vier Jahre.

Tab. A.2: Vergleich statistischer Kennzahlen simulierter und historischer Preise.

Statistische Kennzahlen	Historische Preise (2012 bis 2015) in €/MWh _{el}	Simulierte Preise (100 Szenarien) in €/MWh _{el}
Quantile		
10%-Quantil	18,47	18,29
40%-Quantil	31,96	31,92
70%-Quantil	42,84	42,54
90%-Quantil	55,97	55,54
Mittelwert	36,21	36,39
Minimum	-222,99	-222,99
Maximum	210	210
Standardabweichung	15,95	16,23
Volatilität	44 %	44 %

Für die in Abschnitt 6.2.2 beschriebenen nachfrageseitigen Elektrizitätsprofile der 28 Haushalte des modellierten Wohnquartiers in Karlsruhe werden Referenzlastprofile (sogenannte H0-Profile) verwendet. Dabei wird der gesamte jährliche Elektrizitätsbedarf (ohne Wärmepumpen und Heizelementen) nach der VDI-Richtlinie 4655 berechnet, welche die Haushaltsanzahl und die Nutzfläche berücksichtigt. Mit dem Ziel einer Validierung (ex post) der Annahme, dass 28 Haushalte durch H0-Profile approximiert werden können, werden in Tab. A.3 die H0-Profile mit gemessenen Elektrizitätsbedarfsprofilen von Haushalten eines Wohnquartiers mit ähnlichen Konditionen verglichen.

Tab. A.3 zeigt den linearen Korrelationskoeffizienten zwischen den H0- und den gemessenen Profilen, den mittleren absoluten prozentualen Fehler (*MAPE*), die Wurzel aus dem mittleren quadratischen Fehler (*RMSE*) und die relative Differenz der Nachfragevolatilität:

$$\Delta(vola_a) = (vola_a(H0) - vola_a(\text{measured profiles}) / vola_a(\text{measured profiles}).$$

Der Korrelationskoeffizient von 28 Haushalten und den H0-Profilen beträgt bereits 72 %. Für eine größere Anzahl von Haushalten zeigen Hayn et al. (2016), dass der Korrelationskoeffizient bei 100 Haushalten auf 90 % ansteigt. Daher erscheint der verwendete Ansatz für gleichgroße und größere Quartiere für die Generierung der Elektrizitätsprofile geeignet. In Bezug auf die Nachfragevolatilität $\Delta(vola_a)$ zeigt sich, dass zwischen 30 Haushalten und den H0-Profilen nur ein Unterschied von -12 % besteht (der bei mehr Haushalten weiter abnehmen dürfte).

Tab. A.3: H0-Profile im Vergleich zur gemessenen Elektrizitätsnachfrage von 28 Haushalten eines Wohnquartiers in Köln.

Indikatoren	Anzahl der Haushalte...				
	1	5	10	20	28
Korrelation mit H0-Profilen	25 %	39 %	51 %	64 %	72 %
<i>MAPE</i>	89 %	53 %	43 %	32 %	26 %
<i>RMSE</i>	163 %	74 %	57 %	42 %	36 %
$\Delta(vola_a)$	-78 %	-43 %	-35 %	-18 %	-12 %

B Nomenklatur des Optimierungsprogramms

Tab. B.1: Nomenklatur des zweistufigen stochastischen Optimierungsprogramms Θ -DES mit Regret-Minimierung für das dezentrale Energiesystem eines Wohnquartiers.

Indizes	
i	Komponente $i \in \{PV, HP_{RW}, HP_{WW}, HE_{RW}, HE_{WW}, S_{RW}, S_{WW}, S_{ES}\}$ mit $ i = I = 7$
u	Anwendung $u \in \{RW, WW\}$ für Raumwärme und Warmwasser mit $ u = 2$
t	Zeitschritt $0, \dots, T$ des Jahres in 15-min-Auflösung mit $ T = 35040$
ω	Szenario $1, \dots, N$
θ	Fall $1, \dots, \Theta$
Parameter	
ANF_{θ}	Annuitätenfaktor im Fall θ
$c_i^{\text{fix var}}$	fixe variable Kapazitätskosten von Komponente i
C_{θ}^{max}	Maximale C-Rate des elektr. Speichers im Fall θ
$COP_{t,u,\omega,\theta}$	COP der Wärmepumpe in t für Anwendung u in Szenario ω im Fall θ
$DF_i MF_i L_i$	Maintenance-Faktor Degradationsfaktor Lebensdauer von Komponente i
$\hat{d}_{t,\omega,\theta}^{\text{HP}}$	max. Heizleistung der Wärmepumpe in t für Anwendung u in Szenario ω im Fall θ
$\hat{d}_{\theta}^{\text{HE}}$	max. Heizleistung der Heizelemente im Fall θ
$d_{t,\omega,\theta}^{\text{ee}}$	Elektrizitätsbedarf der Haushalte in t in Szenario ω im Fall θ
$d_{t,u,\omega,\theta}^{\text{th}}$	Wärmebedarf der Haushalte in t für Anwendung u in Szenario ω im Fall θ
$e_{t,\omega,\theta}^{\text{PV,kWP}}$	elektr. Energie je kW _p der PV-Anlage in t in Szenario ω im Fall θ
$e_{t,\omega,\theta}^{\text{PV}}$	elektr. Energie der PV-Anlage in t in Szenario ω im Fall θ
$e^c d^c$	Kompensationsfaktor für nicht gedeckte Elektrizitäts- bzw. Wärmenachfrage
l_{θ}^{ES}	Verlustfaktor des elektr. Speichers im Fall θ
$l_{u,\theta}^{\text{HS}}$	Verlustfaktor des therm. Speichers für Anwendung u im Fall θ
$l_{u,\theta}^{\text{HP}}$	Anfahrverlustfaktor der Wärmepumpe für Anwendung u im Fall θ
m	mögliche Heizleistungsstufen der Wärmepumpe
$p_{t,\omega,\theta}^{\text{grid}}$	Elektrizitäts-Einkaufspreis des externen Netzes in t in Szenario ω im Fall θ
$p_{t,\omega,\theta}^{\text{grid,fi}}$	Elektrizitäts-Verkaufspreis des externen Netzes in t in Szenario ω im Fall θ
$p_{\theta}^{\text{PV,fi}}$	PV-Einspeisevergütung im Fall θ
$\xi_{\theta}^{\text{ES}} \xi_{\theta}^{\text{ES}}$	min./max. elektrischer Speicherstand im Fall θ
$\xi_{u,\theta}^{\text{TS}} \xi_{u,\theta}^{\text{TS}}$	min./max. thermischer Speicherstand für Anwendung u im Fall θ
$\eta_{\theta}^{\text{ES HE}}$	Ladeeffizienz des elektrischen Speichers Wirkungsgrad der Heizelemente im Fall θ

Entscheidungsvariablen

$d_{t,u,\omega,\theta}^{\text{HP}}$	Elektrizitätsbedarf der Wärmepumpe in t für Anwendung u in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$d_{t,u,\omega,\theta}^{\text{HE}}$	Elektrizitätsbedarf der Heizelemente in t für Anwendung u in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$e_{t,\omega}^{\text{grid}}$	Elektrizitätsbezug vom externen Netz in t in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$e_{t,\omega}^{\text{grid,fi}}$	Einspeisung des elektr. Speichers ins externe Netz in t in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$e_{t,\omega}^{\text{fi}}$	PV-Einspeisung ins externe Netz in t in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$L_{t,\omega}^{\text{ES}}$	Verlust des elektr. Speichers in t in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$L_{t,u,\omega,\theta}^{\text{HS}}$	Verlust des therm. Speichers in t für Anwendung u in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$\text{pos neg}_{t,\omega}^{\text{ES}}$	Hilfsvariable für pos./neg. Änderung des elektr. Speicherstands in t in ω im Fall θ ; $\in \mathbb{R}_+$
$\text{pos neg}_{t,u,\omega,\theta}^{\text{TS}}$	Hilfsvariable für pos./neg. Leistungsänderung der Wärmepumpe in t für u in ω in θ ; $\in \mathbb{R}_+$
$e_{t,\omega}^{\text{aux}}$	Hilfsvariable für nicht gedeckten Elektrizitätsbedarf in t in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$d_{t,u,\omega,\theta}^{\text{aux}}$	Hilfsvariable für nicht gedeckten Wärmebedarf in t für u in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$S_{t,\omega}^{\text{ES}}$	Speicherstand des elektr. Speichers in t in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$\Delta S_{t,\omega}^{\text{ES}}$	max. Änderung des elektr. Speichers in Δt und in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$S_{t,u,\omega,\theta}^{\text{HS}}$	Speicherstand des therm. Speichers in t für Anwendung u in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$\Delta S_{t,u,\omega,\theta}^{\text{TS}}$	max. Änderung des therm. Speichers in Δt für Anwendung u in Szenario ω im Fall θ ; $\in \mathbb{R}_+$
$x_{i,\theta}$	Kapazität von Komponente i im Fall θ
$x_{i=\text{PV},\theta}$	installierte PV-Kapazität im Fall θ ; $\in \mathbb{R}_+$ (ggf. $\in \mathbb{Z}_+$)
$x_{i=\text{HP}_{\text{RW}},\theta}$	Anzahl der Wärmepumpen für Raumwärme im Fall θ ; $\in \mathbb{Z}_+$
$x_{i=\text{HP}_{\text{WW}},\theta}$	Anzahl der Wärmepumpen für Warmwasser im Fall θ ; $\in \mathbb{Z}_+$
$x_{i=\text{HE}_{\text{RW}},\theta}$	Anzahl der Heizelemente für Raumwärme im Fall θ ; $\in \mathbb{Z}_+$
$x_{i=\text{HE}_{\text{WW}},\theta}$	Anzahl der Heizelemente für Warmwasser im Fall θ ; $\in \mathbb{Z}_+$
$x_{i=\text{S}_{\text{ES}},\theta}$	max. Kapazität des elektr. Speichers im Fall θ ; $\in \mathbb{Z}_+$
$x'_{i=\text{S}_{\text{ES}},\theta}$	reduzierte max. Kapazität des elektr. Speichers im Fall θ ; $\in \mathbb{Z}_+$
$x_{i=\text{S}_{\text{RW}},\theta}$	max. Kapazität des Raumwärme-Speichers im Fall θ ; $\in \mathbb{Z}_+$
$x_{i=\text{S}_{\text{WW}},\theta}$	max. Kapazität des Warmwasser-Speichers im Fall θ ; $\in \mathbb{Z}_+$
$z_{i,\theta}$	ganzzahlige Kapazität von Komponente i im Fall θ ; \mathbb{Z}_+
$z_{t,u,\omega,\theta}$	Heizleistungsstufe in t für Anwendung u in Szenario ω im Fall θ ; $\in \mathbb{Z}_+$

C Überblick über ableitungsfreie Optimierungsverfahren

Zur Optimierung des Masterprogramms der exogen vorgegebenen gemischt-ganzzahligen Variablen ist eine ableitungsfreie Optimierung implementiert (siehe Abschnitt 7.1.3). Angewendet werden ableitungsfreie Optimierungsalgorithmen bei Problemen, wenn Informationen der Ableitung von f nicht verfügbar, unzuverlässig oder unpraktisch zu erhalten sind. Dazu gehören auch Algorithmen, welche die Berechnung von Ableitungen von anderen Funktionen als f beinhalten (Rios und Sahinidis 2013). In Tab. C.1 sind verschiedene Methoden im Hinblick auf die in Abschnitt 7.1.3 genannten Anforderungen zusammengefasst. Nach der Tabelle folgt die formelle Beschreibung des verwendeten SAHC-Algorithmus.

Tab. C.1: Ableitungsfreie Optimierungsalgorithmen für das in Abschnitt 7.1 vorgestellte Masterprogramm (Schwarz et al. 2018a, basierend auf Rios und Sahinidis 2013; Conn et al. 2009).

Algorithmus	Beschreibung	Such- Methode	Merkmale bzgl. Optimierung des Masterprogramms	Ungenauig- keitstoleranz gegenüber f
Koordinaten- suche / Berg- steiger- algorithmus entlang des steilsten Ab- stiegs (SAHC)	Inkrementelles Ändern lösungsabhängiger Variablen zur Verbesserung der Ausgangslösung; alle zu optimierenden Komponenten von f werden je Iteration sequenziell modifiziert und die größte Verbesserung von f wird akzeptiert	Lokal	Flexibel, robust und einfach; bei gutem Startpunkt und wenigen Variablen sind nur wenige Iterationen zum approx. (lokalem) Optimum nötig; Problem bei geringem Anstieg von f	(Sehr) Hoch / niedrig bei geringem Anstieg von f
Lipschitz- basierte Parti- tionierung	Erstellung und Optimierung einer Funktion, die f unterschätzt (Erweiterung durch DIRECT-Algorithmus oder Branch-and-Bound-Suche)	Global	Die Lipschitz-Konstante ist unbekannt und die Anzahl der Evaluationen von f steigt exponentiell an	–

Algorithmus	Beschreibung	Such- Methode	Merkmale bzgl. Optimierung des Masterprogramms	Ungenauig- keitstoleranz gegenüber f
Modelbasierte Suche	Erstellung eines Ersatz- modells von f , um Such- prozess iterativ zu leiten	Lokal/ global	Anwendbar bei weni- gen und vielen fixier- ten Variablen	Niedrig / hoch (mittelmäßig)
Branch-and- Fit-Optimie- rung	Kombination des Ersatzmo- dells (zur Bestimmung von Evaluationspunkten) und Zufallspunktgenerierung	Global	fixierte Variablen ≤ 10 (vorgeschlagen von Huyer und Neumaier 2008)	(Sehr) Hoch
Implizite Filterung	Erstellung eines Ersatzmo- dells des Gradienten von f , um die Suche iterativ zu unterstützen	Lokal	Geringere Effizienz; gut geeignet, um Rauschen zu filtern	Hoch
Response Surface- Methode	Approximation von f durch \hat{f} ; Variation durch Oberflä- chen-Interpolation mittels Kriging-Funktion, radialer Basisfunktionen, effizienter globaler Optimierung (EGO) oder sequenzielles Design zur Optimierung (SDO)	Global	Annahme, dass Dis- krepanz zwischen f und \hat{f} durch das Modell und nicht durchs Rauschen verursacht wird	Niedrig (mit- telmäßig)
Surrogate- Management- Framework	Mustersuchverfahren, das ein Ersatzmodell verwendet, um potenziell optimale Punkte zu erzeugen und die Genauigkeit des Ersatz- modells zu verbessern	Global	–	–
Trust-Region- Methode	Annahme, dass das Ersatz- modell in einem Vertrau- ensbereich in der aktuellen Iteration genau ist	Lokal	Die Suche wird anhand der Eigen- schaften des Ersatz- modells geleitet	Niedrig

Algorithmus	Beschreibung	Such- Methode	Merkmale bzgl. Optimierung des Masterprogramms	Ungenauig- keitstoleranz gegenüber f
Multilevel-Koordinatensuche (MCS)	Unterteilung des Suchraums in Blöcke mit einer evaluierten Basis; Anwendung einer global-lokalen Suche unter Abgleichung eines mehrstufigen Ansatzes	Global	Ähnlich wie SAHC; erfordert mehr Evaluationen der Subprogramme für die globale Suche	Hoch / niedrig bei geringem Anstieg von f
Nelder-Mead-Simplex-Algorithmus	Bestimmung von Eckpunkten eines Simplex und Ersetzung des schlechtesten Punkts, so dass ein neuer Simplex entsteht	Lokal	Kann stagnieren, wenn Abstieg von f gering ist; wird gewöhnlich bei kontinuierlichen Optimierungsprogrammen verwendet	Hoch / niedrig bei geringem Anstieg von f
Mustersuche	Musterbasierte Bewertung von f	Lokal	Benötigt häufig viele Iterationen und Evaluationen	(Sehr) Hoch
Generalisierte Mustersuche (GPS)	Suche nach Abfrageschritten (explorative Bewegung): Definition einer Punkte-Menge, die ein Muster bildet, das durch Schritt- und Generations-Matrizen bestimmt wird	Lokal	Ähnlich wie SAHC; kann zu Sattelpunkten konvergieren	(Sehr) Hoch
Generalisierte Set-Suche (GSS)	Verbesserung von GPS, indem neben den Abfrageschritten auch Suchschritte verwendet werden (erforderliche Suchrichtungen werden berechnet)	Lokal	Ähnlich wie SAHC	Hoch
Hooke-Jeeves-Direkt-Suche (HJDS)	Verwendung explorativer Bewegungen (f wird durch sukzessive Änderungen in Suchrichtung evaluiert) und Musterbewegungen (in die zugrundeliegende verbesserte Suchrichtung)	Lokal	Ähnlich wie SAHC, jedoch mit geringerem Parallelisierungsgrad	Hoch

Algorithmus	Beschreibung	Such- Methode	Merkmale bzgl. Optimierung des Masterprogramms	Ungenauig- keitstoleranz gegenüber f
Maschen- Adaptive- Direkt-Suche	Modifikation von GPS durch Abfrage in einer asymptotisch dichten Menge von Suchrichtungen (Menge variiert mit Anzahl der Iteration)	Lokal	Ähnlich wie SAHC; nicht stationäre Punkte werden besser im Vergleich zu GPS überwunden	Hoch
Stochastische Suche	Basis bilden nicht deterministische Algorithmen	Global	Generell werden viele Evaluationen der Subprogramme benötigt	Hoch / sehr hoch
Evolutionärer Algorithmus (EA)	Verwendung der Prinzipien der natürlichen Selektion: Eignung, Zuweisung, Rekombination und Mutation	Global	Es werden viele Evaluationen benötigt	Hoch
Hit-and-Run- Algorithmus	Vergleich aktueller Iteration mit einem zufällig generierten Kandidaten	Global	Keine Garantie für gute Lösungen bei begrenzter Anzahl von Iterationen	Sehr hoch
Partikel- Schwarm- Optimierung (Particle Swarm Opti- mization)	Bewegung von Partikeln im Lösungsraum, die von früheren erfolgreichen Lösungen angezogen werden und sich gegenseitig mit stochastischen Veränderungen beeinflussen	Global	Es werden viele Evaluationen benötigt	Hoch
Simulierte Abkühlung (Simulated Annealing)	Vergleich aktueller Iteration mit einem spezifisch generierten Punkt, der im Gegensatz zum Hit-and-Run-Algorithmus mit einer Wahrscheinlichkeitsfunktion akzeptiert wird	Global	Keine Garantie für gute Lösungen bei begrenzter Anzahl von Iterationen	Hoch

Die Hauptaufgabe besteht in der Bestimmung der optimalen Investitionsplanung des Wohnquartiers mit kostenminimaler Betriebsführung. Hierfür wird das Problem durch Fixierung der Erststufen-Variablen (Speicher- und PV-Anlagengröße sowie Anzahl der Wärmepumpen) entkoppelt. Da die Nichtoptimierung der Speicherstände zwischen den entkoppelten Subprogrammen zu einem vernachlässigbaren Fehler führt, müssen nur wenige fixierte Variablen optimiert werden (insgesamt 6). Für diese Aufgabe ist der verwendete SAHC-Algorithmus im Masterprogram suffizient. Die Vorteile der Implementierung des SAHC-Algorithmus liegen in der Einfachheit, Flexibilität und Zuverlässigkeit. Darüber hinaus schreitet der Algorithmus auch bei ungenauen Lösungen der Subprogramme robust zum (lokalen) Optimum hin. Die komplette Prozedur des SAHC-Algorithmus wird im Folgenden vorgestellt.

Prozedur des Bergsteigeralgorithmus entlang des steilsten Abstiegs (SAHC):

Schritt 0: (**Initialisierung**) Berechne $f(\varphi)$ für ein initiales φ (z. B. $\varphi = 0$) und definiere die Schrittweite s_k für jede fixierte Variable φ_k des Vektors φ . Wenn $\varphi_k \in \mathbb{Z}$, dann $s_k \in \mathbb{Z}$. Sei $e_k \in R_+^{I+R-v}$ der k -te Einheitsvektor, wobei I die Anzahl der fixierten Variablen der ersten Stufe ist und $R - v$ die Anzahl der fixierten Variablen der zweiten Stufe ist.

Schritt 1: Addiere s_k zu φ_k und berechne $f(\varphi + s_k e_k)$ sowie subtrahiere s_k von φ_k und berechne $f(\varphi - s_k e_k)$ für jede Fixierung $1 \leq k \leq I + R - v$. Beachte wenn $f(\varphi + s_k e_k) > f(\varphi - s_k e_k)$, dann $step_k^* = +s_k e_k$, sonst $step_k^* = -s_k e_k$.

Schritt 2: Wähle $\varphi^* \in \{\varphi \pm s_k e_k \mid \forall 1 \leq k \leq I + R - v\}$ mit

$$f(\varphi) = \min_k \{f(\varphi \pm s_k e_k)\}.$$

Schritt 3: Definiere $\Delta f(\varphi)_{rel} = (f(\varphi) - f(\varphi^*)) / f(\varphi)$.

Schritt 4: Wenn $\Delta f(\varphi)_{rel} \leq 0$, dann $s_k = \frac{s_k}{2}$; wenn $\varphi_k \in \mathbb{Z}$ und $\frac{s_k}{2} < 1$, dann gehe zu Schritt 6; wenn $\varphi_k \in \mathbb{Z}$ und $\frac{s_k}{2} \notin \mathbb{Z}$, dann runde $\frac{s_k}{2}$ auf die nächstgrößere ganze Zahl. Sonst fahre fort.

Schritt 5: Wenn $\Delta f(\varphi)_{rel} > \text{Abbruchkriterium } a \in \mathbb{R}_+$, dann akzeptiere $f(\varphi) = f(\varphi^*)$ und $\varphi = \varphi^*$, berechne $f(\varphi + step_k^*)$ für jede Fixierung $f(\varphi + step_k^*)$ und gehe zu Schritt 2. Sonst fahre fort.

Schritt 6: (**Ende**) Stopp. Der lokale optimale Zielfunktionswert ist $f(\varphi^*)$ mit dem Vektor φ^* .

Verzeichnisse

I Literaturverzeichnis

- AEE (2012): *Studienvergleich: Entwicklung der Investitionskosten neuer Kraftwerke*. Agentur für Erneuerbare Energien (AEE).
- AGEB (2016): *Stromverbrauch der Haushalte. Struktur des Stromverbrauchs nach Anwendungsbereichen*. Arbeitsgemeinschaft Energiebilanzen e.V. (AGEB), Berlin.
- AGEB (2017a): *Auswertungstabellen zur Energiebilanz Deutschland 1990 bis 2016, Stand: September 2017*. Arbeitsgemeinschaft Energiebilanzen e.V. (AGEB), Berlin.
- AGEB (2017b): *Anwendungsbilanzen für die Endenergiesektoren in Deutschland in den Jahren 2013 bis 2016. Studie beauftragt vom Bundesministerium für Wirtschaft und Energie Projektnummer: 072/15*. Arbeitsgemeinschaft Energiebilanzen e.V. (AGEB), Berlin.
- Agora (2013): *Kapazitätsmarkt oder strategische Reserve: Was ist der nächste Schritt?* Agora Energiewende, Berlin.
- Ahmed, S. (2010): „Two-stage stochastic integer programming: a brief introduction“ in *Wiley Encyclopedia of Operations Research and Management Science*, Hrsg. J. J. Cochran; L. A. Cox; P. Keskinocak; J. P. Kharoufeh & J. C. Smith. John Wiley & Sons, Inc, Hoboken, N.J.
- Alcamo, J. (2008): „Chapter One Introduction: the Case for Scenarios of the Environment“ in *Environmental Futures – The Practice of Environmental Scenario Analysis*. Elsevier, S. 1–11.
- Alonso-Ayuso, A.; Escudero, L. F.; Garín, A.; Ortuño, M. T. & Pérez, G. (2005): „On the product selection and plant dimensioning problem under uncertainty“. *Omega*, Vol. 33, Heft 4, S. 307–318.
- Alonso-Ayuso, A.; Escudero, L. F. & Teresa Ortuño, M. (2003): „BFC, A branch-and-fix coordination algorithmic framework for solving some types of stochastic pure and mixed 0–1 programs“. *European Journal of Operational Research*, Vol. 151, Heft 3, S. 503–519.
- Amato, U.; Andretta, A.; Bartoli, B.; Coluzzi, B.; Cuomo, V.; Fontana, F. & Serio, C. (1986): „Markov processes and Fourier analysis as a tool to describe and simulate daily solar irradiance“. *Sol Energ*, Vol. 37, Heft 3, S. 179–194.
- Anemos (2016): *Wind Atlas and Production Index Europe*. Kommerzieller Anbieter von Wetterdaten für Windenergieanwendungen. Abrufbar unter: <http://www.anemos.de/en/windatlases.php> [geprüft am 10.01.2017].

- Ansótegui, C.; Sellmann, M. & Tierney, K. (2009): „A gender-based genetic algorithm for the automatic configuration of algorithms“ in *Principles and Practice of Constraint Programming – CP 2009*, Hrsg. D. Hutchison; T. Kanade; J. Kittler; J. M. Kleinberg; F. Mattern; J. C. Mitchell; M. Naor; O. Nierstrasz; C. Pandu Rangan; B. Steffen; M. Sudan; D. Terzopoulos; D. Tygar; M. Y. Vardi; G. Weikum & I. P. Gent. Springer, Berlin, Heidelberg, S. 142–157.
- Appelhans, K.; Exner, S. & Bracke, R. (2014): *Analyse des deutschen Wärmepumpenmarktes. – Bestandsaufnahme und Trends*. Internationales GeothermieZentrum Bochum, Bochum.
- Arpón, S.; Homem-de-Mello, T. & Pagnoncelli, B. (2018): „Scenario reduction for stochastic programs with Conditional Value-at-Risk“. *Mathematical Programming*, Vol. 170, Heft 1, S. 327–356.
- ASUE (2014): *EnEV 2014 für Wohngebäude*. Arbeitsgemeinschaft für sparsamen und umweltfreundlichen Energieverbrauch e.V. (ASUE), Berlin, Essen.
- ASUE (2017): *Das KWK-Gesetz 2017 – zur weiteren Förderung der Kraft-Wärme-Kopplung*. Arbeitsgemeinschaft für sparsamen und umweltfreundlichen Energieverbrauch e.V. (ASUE), Bonn. Abrufbar unter: https://www.asue.de/sites/default/files/asue/themen/blockheizkraftwerke/2017/broschueren/asue_kwk_gesetz2017_309860.pdf [geprüft am 08.12.2018].
- Atamtürk, A. & Savelsbergh, M. W. P. (2005): „Integer-Programming Software Systems“. *Annals of Operations Research*, Vol. 140, Heft 1, S. 67–124.
- BAFA (2018): *Förderübersicht Wärmepumpe (Basis-, Innovations- und Zusatzförderung)*. Bundesamt für Wirtschaft und Ausfuhrkontrolle (BAFA). Abrufbar unter: https://www.bafa.de/SharedDocs/Downloads/DE/Energie/ew_waermepumpen_foerderung/foerdersicht.pdf?__blob=publicationFile&v=5 [geprüft am 11.12.2018].
- Bardmann, M. (2014): *Grundlagen der Allgemeinen Betriebswirtschaftslehre*. Springer Gabler, Wiesbaden.
- Baten, T.; Buttermann, H.-G. & Nieder, T. (2017): „Kraft-Wärme-Kopplung 2008 bis 2016 – Einfluss der Bilanzgrenze“. *Energiewirtschaftliche Tagesfragen*, Vol. 67, Heft 12 [geprüft am 09.12.2018].
- BDEW (2015): *Strompreis für Haushalte*. Bundesverband der Energie- und Wasserwirtschaft e.V. (BDEW). Abrufbar unter: https://www.vewsaar.de/fileadmin/dokumente/Aktuell/Presse/2015/Anlage_Stromrechnung_Haushalte.pdf [geprüft am 08.06.2018].

- BDEW (2018): *Strompreis für Haushalte – Durchschnittlicher Strompreis für einen Haushalt in ct/kWh, 2006 bis 2017, Jahresverbrauch von 3.500 kWh*. Bundesverband der Energie- und Wasserwirtschaft e.V. (BDEW). Abrufbar unter: <https://www.bdew.de/service/daten-und-grafiken/strompreis-fuer-haushalte/> [geprüft am 01.11.2018].
- Beale, E. M. L. (1955): „On Minimizing A Convex Function Subject to Linear Inequalities“. *Journal of the Royal Statistical Society: Series B*, Vol. 17, Heft 2, S. 173–184.
- Beck, T.; Kondziella, H.; Huard, G. & Bruckner, T. (2017): „Optimal operation, configuration and sizing of generation and storage technologies for residential heat pump systems in the spotlight of self-consumption of photovoltaic electricity“. *Applied Energy*, Vol. 188, S. 604–619.
- Bedford, T. & Cooke, R. M. (2001): *Probabilistic risk analysis – Foundations and methods*. Cambridge University Press, Cambridge, UK, New York, USA.
- Bell, D. E. (1982): „Regret in Decision Making under Uncertainty“. *Operations Research*, Vol. 30, Heft 5, S. 961–981.
- Ben-Tal, A.; El Ghaoui, L. & Nemirovskii, A. S. (2009): *Robust optimization*. Princeton University Press, Princeton.
- Ben-Tal, A. & Nemirovskii, A. S. (1997): „Robust Truss Topology Design via Semidefinite Programming“. *SIAM Journal on Optimization*, Vol. 7, Heft 4, S. 991–1016.
- Bergstra, J. S.; Bardenet, R.; Bengio, Y. & Kégl, B. (2011): „Algorithms for Hyperparameter Optimization“ in *Advances in Neural Information Processing Systems 24*, Hrsg. J. Shawe-Taylor; R. S. Zemel; P. L. Bartlett; F. Pereira & K. Q. Weinberger. Curran Associates, Inc, S. 2546–2554. Abrufbar unter: <http://papers.nips.cc/paper/4443-algorithms-for-hyper-parameter-optimization.pdf>.
- Bernal-Agustín, J. L.; Dufo-López, R. & Rivas-Ascaso, D. M. (2006): „Design of isolated hybrid systems minimizing costs and pollutant emissions“. *Renewable Energy*, Vol. 31, Heft 14, S. 2227–2244.
- Bertsch, V.; Schwarz, H. & Fichtner, W. (2014): „Layout Optimisation of Decentralised Energy Systems Under Uncertainty“ in *Operations Research Proceedings 2013: Selected Papers of the International Conference on Operations Research, OR2013, organized by the German Operations Research Society (GOR), the Dutch Society of Operations Research (NGB) and Erasmus University Rotterdam, September 3–6, 2013*, Hrsg. D. Huisman; I. Louwse & A. P. Wagelmans. Springer International Publishing, Cham, S. 29–35.
- Bertsekas, D. P. (2012): *Dynamic programming and optimal control*. Athena Scientific, Belmont, Mass.
- Bertsimas, D. & Sim, M. (2004): „The Price of Robustness“. *Operations Research*, Vol. 52, Heft 1, S. 35–53.

- Bertsimas, D. & Sim, M. (2006): „Tractable Approximations to Robust Conic Optimization Problems“. *Mathematical Programming*, Vol. 107, 1-2, S. 5–36.
- Bertsimas, D. & Tsitsiklis, J. N. (1997): *Introduction to linear optimization*. Athena Scientific, Belmont, Mass.
- Birge, J. R. (1982): „The value of the stochastic solution in stochastic linear programs with fixed recourse“. *Mathematical Programming*, Vol. 24, Heft 1, S. 314–325.
- Birge, J. R. & Louveaux, F. (1997): *Introduction to stochastic programming*. Springer, New York.
- Blohm, H.; Lüder, K. & Schaefer, C. (2012): *Investition – Schwachstellenanalyse des Investitionsbereichs und Investitionsrechnung*. Vahlen, München. Abrufbar unter: <http://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=678744>.
- BMU (2013): *Zeitreihen zur Entwicklung der erneuerbaren Energien in Deutschland*. Daten der Arbeitsgruppe Erneuerbare Energien-Statistik (AGEE-Stat) / Bundesministerium für Umwelt, Naturschutz und Reaktorsicherheit (BMU).
- BMWi (2014): *Vorbereitung und Begleitung der Erstellung des Erfahrungsberichts 2014 gemäß § 65 EEG – Vorhaben IIc Solare Strahlungsenergie*. Bundesministerium für Wirtschaft und Energie (BMWi), Stuttgart.
- BMWi (2015): *Zweiter Erfahrungsbericht zum Erneuerbare-Energien-Wärmegesetz*. Bundesministerium für Wirtschaft und Energie (BMWi). Bundesanzeiger Verlag.
- BMWi (2017a): *Bundesbericht Energieforschung 2017 – Forschungsförderung für die Energiewende*. Bundesministerium für Wirtschaft und Energie (BMWi), Frankfurt.
- BMWi (2017b): *Erneuerbare Energien in Zahlen – Nationale und internationale Entwicklung im Jahr 2016*. Bundesministerium für Wirtschaft und Energie (BMWi), Frankfurt.
- BMWi & BMU (2010): *Energiekonzept für eine umweltschonende, zuverlässige und bezahlbare Energieversorgung*. Bundesministerium für Wirtschaft und Technologie (BMWi) und Bundesministerium für Umwelt, Naturschutz und Reaktorsicherheit (BMU).
- BNetzA (2016a): *Leitfaden zur Eigenversorgung*. Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen sowie Bundeskartellamt (BNetzA).
- BNetzA (2016b): *Monitoringbericht 2016*. Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen sowie Bundeskartellamt (BNetzA). Abrufbar unter: https://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/Sachgebiete/Energie/Unternehmen_Institutionen/DatenaustauschUndMonitoring/Monitoring/Monitoringbericht2016.pdf?__blob=publicationFile&cv=2 [geprüft am 12.06.2018].

- BNetzA (2017): *Anlagenregister*. Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen sowie Bundeskartellamt (BNetzA). Abrufbar unter: https://www.bundesnetzagentur.de/DE/Sachgebiete/ElektrizitaetundGas/Unternehmen_Institutionen/ErneuerbareEnergien/Anlagenregister/Anlagenregister_node.html [geprüft am 16.06.2017].
- BRD (1976): *Gesetz zur Einsparung von Energie in Gebäuden – Energieeinsparungsgesetz (EnEG)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (1997): *1. Verordnung über einen energiesparenden Wärmeschutz bei Gebäuden – Wärmeschutzverordnung (WärmeschutzV)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (1999): *Stromsteuergesetz (StromStG)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (2002a): *Energieeinsparverordnung (EnEV) 2002 – Verordnung über energiesparenden Wärmeschutz und energiesparende Anlagentechnik bei Gebäuden*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (2002b): *Gesetz für die Erhaltung, die Modernisierung und den Ausbau der Kraft-Wärme-Kopplung (KWKG)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (2004): *Gesetz zur Neuregelung des Rechts der Erneuerbaren Energien im Strombereich – Erneuerbare Energien Gesetz (EEG)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (2009): *Energieeinsparverordnung (EnEV) 2009 – Verordnung über energiesparenden Wärmeschutz und energiesparende Anlagentechnik bei Gebäuden*. Bundesrepublik Deutschland (BRD). Bundesministeriums der Justiz.
- BRD (2011): *Gesetz zur Förderung Erneuerbarer Energien im Wärmebereich – Erneuerbare-Energien-Wärmegesetz (EEWärmeG)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (2012a): *Gesetz für den Vorrang Erneuerbarer Energien – Erneuerbare Energien Gesetz (EEG)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (2012b): *Gesetz zur Änderung des Kraft-Wärme-Kopplungsgesetzes (KWKG)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (2012c): *Gesetz zur Änderung des Rechtsrahmens für Strom aus solarer Strahlungsenergie und zu weiteren Änderungen im Recht der erneuerbaren Energien*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.

- BRD (2013): *Novelle der Energieeinsparverordnung (EnEV)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (2014): *Gesetz zur grundlegenden Reform des Erneuerbare-Energien-Gesetzes und zur Änderung weiterer Bestimmung des Energiewirtschaftsrechts*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (2015): *Gesetz zur Neuregelung des Kraft-Wärme-Kopplungsgesetzes (KWKG)*. Bundesrepublik Deutschland (BRD), Bundesanzeiger Verlag.
- BRD (2016): *Gesetz zur Einführung von Ausschreibungen für Strom aus erneuerbaren Energien und zu weiteren Änderungen des Rechts der erneuerbaren Energien (EEG 2017)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- BRD (2017): *Gesetzes zur Förderung von Mieterstrom Gesetz zur Förderung von Mieterstrom und zur Änderung weiterer Vorschriften des Erneuerbare-Energien-Gesetzes (Mieterstromgesetz)*. Bundesrepublik Deutschland (BRD). Bundesanzeiger Verlag.
- Breuer, W.; Gürtler, M. & Schuhmacher, F. (2010): *Portfoliomanagement I*. Gabler, Wiesbaden.
- BSW (2015): *Statistische Zahlen der deutschen Solarstrombranche (Photovoltaik)*. Bundesverband Solarwirtschaft. Abrufbar unter: https://www.solarwirtschaft.de/fileadmin/media/pdf/2015_2_BSW_Solar_Faktenblatt_Photovoltaik.pdf [geprüft am 06.04.2017].
- Burkhard, M. (2015): *Optimal integration of flexible loads and PV power generation in an isolated grid*. Masterthesis, Karlsruhe.
- Buygi, M. O.; Shanechi, H. M.; Balzer, G.; Shahidehpour, M. & Pariz, N. (2006): „Network Planning in Unbundled Power Systems“. *IEEE Transactions on Power Systems*, Vol. 21, Heft 3, S. 1379–1387.
- Carøe, C. C. & Schultz, R. (1999): „Dual decomposition in stochastic integer programming“. *Operations Research Letters*, Vol. 24, 1-2, S. 37–45.
- Carøe, C. C. & Tind, J. (1998): „L-shaped decomposition of two-stage stochastic programs with integer recourse“. *Mathematical Programming*, Vol. 83, 1-3, S. 451–464.
- Cischinsky, H. & Diefenbach, N. (2018): *Datenerhebung Wohngebäudebestand 2016 – Datenerhebung zu den energetischen Merkmalen und Modernisierungsraten im deutschen und hessischen Wohngebäudebestand*. Institut Wohnen und Umwelt GmbH, Darmstadt.
- Conn, A. R.; Scheinberg, K. & Vicente, L. N. (2009): *Introduction to Derivative-Free Optimization*. Society for Industrial and Applied Mathematics.

- DAI (2017): *50 Jahre Aktien-Renditen: Das DAX-Rendite-Dreieck des Deutschen Aktieninstituts (Dezember 2017)*. Deutsche Aktieninstitut e. V. (DAI). Abrufbar unter: https://www.dai.de/files/dai_usercontent/dokumente/renditedreieck/2017-12-31%20DAX-Rendite-Dreieck%2050%20Jahre%20Web.pdf [geprüft am 04.06.2018].
- Dantzig, G. B. (1955): „Linear programming under uncertainty“. *Management Science*, Vol. 1, S. 197–206.
- De La Torre, T.; Feltes, J. W.; Gomez San Roman, T. & Merrill, H. M. (1999): „Deregulation, privatization, and competition – Transmission planning under uncertainty“. *IEEE Transactions on Power Systems*, Vol. 14, Heft 2, S. 460–465.
- Delage, E. & Iancu, D. A. (Hrsg.) (2016): *Special issue on "Robust optimization and applications"*. Springer, Berlin, Heidelberg.
- dena (2010): *Kurzanalyse der Kraftwerksplanung in Deutschland bis 2020 (aktualisierte Fassung)*. Deutsche Energie-Agentur GmbH (dena), Berlin.
- dena (2014): *Systemdienstleistungen 2030 – Sicherheit und Zuverlässigkeit einer Stromversorgung mit hohem Anteil erneuerbarer Energien*. Deutsche Energie-Agentur GmbH (dena), Berlin.
- Destatis (2018): *Preise: Verbraucherpreisindizes für Deutschland, lange Reihen ab 1948*. Statistisches Bundesamt (Destatis). Abrufbar unter: https://www.destatis.de/DE/Publikationen/Thematisch/Preise/Verbraucherpreise/Verbraucherpreisindex/LangeReihenPDF_5611103.pdf?__blob=publicationFile [geprüft am 04.06.2018].
- Deutsche Börse (2016): *Deutsche Börse startet neuen XDAXDAX-Index. Index deckt gesamte Handelszeit des Derivatemarktes ab*. Deutsche Börse AG. Abrufbar unter: <http://deutsche-boerse.com/dbg-de/presse/pressemitteilungen/Deutsche-Boerse-startet-neuen-XDAXDAX-Index/2386400> [geprüft am 20.07.2017].
- Diagne, M.; David, M.; Lauret, P.; Boland, J. & Schmutz, N. (2013): „Review of solar irradiance forecasting methods and a proposition for small-scale insular grids“. *Renewable and Sustainable Energy Reviews*, Vol. 27, S. 65–76.
- Diefenbach, N. (2013): *Basisdaten für Hochrechnungen mit der Deutschen Gebäudetypologie des IWU: Neufassung Oktober 2013*. Institut Wohnen und Umwelt GmbH (Hrsg.), Darmstadt.
- Dimplex (2013): *Technische Daten LA 60TU*. Glen Dimplex Group (Dimplex). Abrufbar unter: https://www.dimplex.de/pdf/de/produktattribute/produkt_1726829_extern_egd.pdf [geprüft am 29.06.2018].
- Dimplex (2014): *mündliche Mitteilung der Firma Dimplex über Anschaffungs- und Installationskosten, Anfahrverluste und maximale Zyklenzahl der Wärmepumpe LA 60TU*, Karlsruhe.

- Dinkelbach, W. (1969): *Sensitivitätsanalysen und parametrische Programmierung*. Habilitationsschrift, Köln. Springer, Berlin, Heidelberg, New York.
- Dong, C.; Huang, G. H.; Cai, Y. P. & Xu, Y. (2011): „An interval-parameter minimax regret programming approach for power management systems planning under uncertainty“. *Applied Energy*, Vol. 88, Heft 8, S. 2835–2845.
- Dubielzig, G. (2007): *Referenzlastprofile von Ein- und Mehrfamilienhäusern für den Einsatz von KWK-Anlagen*. VDI Verlag, Düsseldorf.
- Dufo-López, R. & Bernal-Agustín, J. L. (2015): „Techno-economic analysis of grid-connected battery storage“. *Energy Conversion and Management*, Vol. 91, S. 394–404.
- Dupačová, J.; Gröwe-Kuska, N. & Römisches, W. (2003): „Scenario reduction in stochastic programming“. *Mathematical Programming*, Vol. 95, Heft 3, S. 493–511.
- DVGW (2004): *Technische Regel Arbeitsblatt W551 2004-04 – Trinkwassererwärmungs- und Trinkwasserleitungsanlagen; Technische Maßnahmen zur Verminderung des Legionellenwachstums; Planung, Errichtung, Betrieb und Sanierung von Trinkwasser-Installationen*. Deutscher Verein des Gas- und Wasserfaches (DVGW), Bonn.
- Eggensperger, K.; Feurer, M.; Hutter, F.; Bergstra, J.; Snoek, J.; Hoos, H. & Leyton-Brown, K. : „Towards an Empirical Foundation for Assessing Bayesian Optimization of Hyperparameters“ in *NIPS 2013 Workshop*. Abrufbar unter: https://ml.informatik.uni-freiburg.de/papers/13-BayesOpt_EmpiricalFoundation.pdf [geprüft am 08.12.2018].
- Eggers, J.-B. (2018): *Das kommunale Energiesystemmodell KomMod – Konzeption, Implementierung und Anwendung an den Praxisbeispielen Frankfurt am Main und Freiburg-Haslach*. Fraunhofer Verlag, Stuttgart.
- Ehnberg, J. S. & Bollen, M. H. (2005): „Simulation of global solar radiation based on cloud observations“. *ISES Solar World Congress 2003*, Vol. 78, Heft 2, S. 157–162.
- Eldar, Y. C.; Ben-Tal, A. & Nemirovskii, A. S. (2004): „Linear Minimax Regret Estimation of Deterministic Parameters with Bounded Data Uncertainties“. *IEEE Transactions on Signal Processing*, Vol. 52, Heft 8, S. 2177–2188.
- Ellinger, T.; Beuermann, G. & Leisten, R. (2001): *Operations Research*. Springer Berlin Heidelberg, Berlin, Heidelberg.
- ElNozahy, M. S.; Abdel-Galil, T. K. & Salama, M. (2015): „Probabilistic ESS sizing and scheduling for improved integration of PHEVs and PV systems in residential distribution systems“. *Electric Power Systems Research*, Vol. 125, S. 55–66.

- Energieatlas (2018): *Daten und Fakten über die Erneuerbaren in Europa*. Kooperationsprojekt von Heinrich-Böll-Stiftung, Green European Foundation, European Renewable Energies Federation und Le Monde diplomatique. Bonifatius GmbH Druck, Paderborn. Abrufbar unter: <https://www.boell.de/sites/default/files/energieatlas2018.pdf> [geprüft am 30.09.2018].
- enervis (2018): *META-Studie Sektorenkopplung: Analyse einer komplexen Diskussion*. Eine META-Studie der enervis energy advisors GmbH im Auftrag der VNGGRUPPE, Berlin. Abrufbar unter: https://vng.de/sites/default/files/vng_meta_studie_sektorenkopplung_enervis.pdf [geprüft am 01.11.2018].
- Engelbrecht-Wiggans, R. (1989): „The effect of regret on optimal bidding in auctions“. *Management Science*, Vol. 35, Heft 6, S. 685–692.
- Epe, A.; Küchler, C.; Römisch, W.; Vigerske, S.; Wagner, H.-J.; Weber, C. & Woll, O. (2009): „Optimization of Dispersed Energy Supply – Stochastic Programming with Recombining Scenario Trees“ in *Optimization in the Energy Industry*, Hrsg. J. Kallrath; P. M. Pardalos; S. Rebennack & M. Scheidt. Springer Berlin Heidelberg, Berlin, Heidelberg, S. 347–364.
- EPEX SPOT (2017): *DAY-AHEAD ACTION – DE/AT*. European Power Exchange. Abrufbar unter: <https://www.epexspot.com/en/market-data/dayaheadaction>.
- Erdinc, O. (2014): „Economic impacts of small-scale own generating and storage units, and electric vehicles under different demand response strategies for smart households“. *Applied Energy*, Vol. 126, S. 142–150.
- Erdmann, G.; Fishedick, M.; Hirschhausen, C. v.; Hohmeyer, O.; Jochem, E.; Kemfert, C.; Matthes, F.; Pehnt, M.; Ragwitz, M. & Schmid, J. (2010): *Dringender Appell zur Rettung des Erneuerbare-Energien-Gesetzes seitens deutscher Energiewissenschaftler*. Abrufbar unter: <https://www.oeko.de/oekodoc/1107/2010-150-de.pdf> [geprüft am 13.07.2015].
- Ergen, T. (2015): *Grosse Hoffnungen und brüchige Koalitionen – Industrie, Politik und die schwierige Durchsetzung der Photovoltaik*. Campus Verlag, Frankfurt.
- Escudero, L. F.; Garín, A.; Merino, M. & Pérez, G. (2007): „A two-stage stochastic integer programming approach as a mixture of Branch-and-Fix Coordination and Benders Decomposition schemes“. *Annals of Operations Research*, Vol. 152, Heft 1, S. 395–420.
- Escudero, L. F.; Garín, M. A.; Merino, M. & Pérez, G. (2010): „An exact algorithm for solving large-scale two-stage stochastic mixed-integer problems: Some theoretical and experimental aspects“. *European Journal of Operational Research*, Vol. 204, Heft 1, S. 105–116.

- Fahl, U.; Blesl, M.; Frondel, M.; Grösche, P.; Löschel, A.; Mennel, T. & Wölfling, N. (2010): *Die Entwicklung der Energiemärkte bis 2030, Energieprognose 2009*. Untersuchung im Auftrag des Bundesministeriums für Wirtschaft und Technologie, Berlin [geprüft am 08.06.2016].
- Fang, R. & Hill, D. J. (2003): „A new strategy for transmission expansion in competitive electricity markets“. *IEEE Transactions on Power Systems*, Vol. 18, Heft 1, S. 374–380.
- Fichtner, W. (2005): *Emissionsrechte, Energie und Produktion – Verknappung der Umweltnutzung und produktionswirtschaftliche Planung*. Erich Schmidt, Berlin.
- Fichtner, W.; Genoese, M.; McKenna, R.; Schäfer, S.; Büchelmaier, A.; Ringler, P.; Cail, S. & Ziegahn, F. (2012): *Die Weiterentwicklung der Energiewirtschaft in Baden-Württemberg bis 2025 unter Berücksichtigung der Liefer- und Preissicherheit*. Studie im Auftrag des Baden-Württembergischen Industrie- und Handelskammertags, Karlsruhe.
- Fischer, D.; Toral, T. R.; Lindberg, K. B.; Wille-Hausmann, B. & Madani, H. (2014): „Investigation of Thermal Storage Operation Strategies with Heat Pumps in German Multi Family Houses“. *Energy Procedia*, Vol. 58, S. 137–144.
- Flechthelm, O. K. (1971): *Futurologie – Der Kampf um die Zukunft*. Verl. Wissenschaft u. Politik, Köln.
- Forrest, S. & Mitchell, M. (1993): „Relative Building-Block Fitness and the Building-Block Hypothesis“. *Foundations of Genetic Algorithms*, Vol. 2, S. 109–126.
- French, S. (1995): „Uncertainty and Imprecision – Modelling and Analysis“. *Journal of the Operational Research Society*, Vol. 46, Heft 1, S. 70.
- Frondel, M.; Ritter, N. & Schmidt, C. M. (2011): „Teure Grünstrom-Euphorie: Die Kosten der Energiewende“. *Energiewirtschaftliche Tagesfragen*, Vol. 61, Heft 12, S. 20–25.
- Fügenschuh, A.; Geißler, B.; Gollmer, R.; Hayn, C.; Henrion, R.; Hiller, B.; Humpola, J.; Koch, T.; Lehmann, T.; Martin, A.; Mirkov, R.; Morsi, A.; Rövekamp, J.; Schewe, L.; Schmidt, M.; Schultz, R.; Schwarz, R.; Schweiger, J.; Stangl, C.; Steinbach, M. C. & Willert, B. M. (2014): „Mathematical optimization for challenging network planning problems in unbundled liberalized gas markets“. *Energy Systems*, Vol. 5, Heft 3, S. 449–473.
- Gleißner, W. (2017): *Grundlagen des Risikomanagements im Unternehmen*. Vahlen, München.
- Godet, M. (1994): *From anticipation to action – A handbook of strategic prospective*. Unesco Publishing, Paris.

- Goldstein, M. (2012): „Bayes Linear Analysis for Complex Physical Systems Modeled by Computer Simulators“ in *Uncertainty quantification in scientific computing – 10th IFIP WG 2.5 Working Conference, WoCoUQ 2011, Boulder, CO, USA, August 1-4, 2011, Revised selected papers*, Hrsg. A. M. Dienstfrey & R. F. Boisvert. Springer, Berlin, New York, S. 78–94.
- Gönsch, J. & Hassler, M. (2016): „Sell or store? – An ADP approach to marketing renewable energy“. *OR Spectrum*, Vol. 38, Heft 3, S. 633–660.
- Götze, U. (2013): *Szenario-Technik in der strategischen Unternehmensplanung*. Zugl.: Göttingen, Univ., Diss., 1990. Springer Fachmedien, Wiesbaden.
- Gröwe-Kuska, N.; Heitsch, H. & Römisch, W. (2003): „Scenario reduction and scenario tree construction for power management problems“ in *2003 IEEE Bologna Power-Tech. Conference Proceedings: June 23-26, 2003, Faculty of Engineering, University of Bologna, Bologna, Italy*. IEEE, Piscataway, N.J., S. 152–158.
- Häfner, F.; Wagner, R.-M. & Meusel, L. (2015): *Bau und Berechnung von Erdwärmeeinlagen*. Springer Berlin Heidelberg, Berlin, Heidelberg.
- Hajimiragha, A. H.; Canizares, C. A.; Fowler, M. W.; Moazeni, S. & Elkamel, A. (2011): „A Robust Optimization Approach for Planning the Transition to Plug-in Hybrid Electric Vehicles“. *IEEE Transactions on Power Systems*, Vol. 26, Heft 4, S. 2264–2274.
- Haneveld, W. K. & van der Vlerk, M. H. (1999): „Stochastic integer programming: general models and algorithms“. *Annals of Operations Research*, Vol. 85, S. 39–57.
- Hannig, F.; Smolinka, T.; Bretschneider, P.; Nicolai, S.; Krüger, S.; Meißner, F. & Voigt, M. (2009): *Stand und Entwicklungspotenzial der Speichertechniken für Elektroenergie – Ableitung von Anforderungen an und Auswirkungen auf die Investitionsgüterindustrie*. Abschlussbericht, Fraunhofer ISI, Fraunhofer AST, VKPartner.
- Haskell, W. B.; Fu, L. & Dessouky, M. (2016): „Ambiguity in risk preferences in robust stochastic optimization“. *European Journal of Operational Research*, Vol. 254, Heft 1, S. 214–225.
- Hauer, A.; Hiebler, S. & Reuß, M. (2013): *Wärmespeicher*. Fraunhofer IRB Verlag, Stuttgart.
- Hawkes, A. D.; Aguiar, P.; Hernandez-Aramburo, C. A.; Leach, M. A.; Brandon, N. P.; Green, T. C. & Adjiman, C. S. (2006): „Techno-economic modelling of a solid oxide fuel cell stack for micro combined heat and power“. *Journal of Power Sources*, Vol. 156, Heft 2, S. 321–333.

- Hayn, M.; Bertsch, V.; Zander, A.; Nickel, S. & Fichtner, W. (2016): *The impact of electricity tariffs on residential demand side flexibility – Working Paper Series in Production and Energy*. KIT, Karlsruhe.
- Heinze, T. (2008): *Ein Verfahren zur Dekomposition mehrstufiger stochastischer Optimierungsprobleme mit Ganzzahligkeit und Risikoaversion*. Dissertation, Duisburg, Essen.
- Heitsch, H. (2007): *Stabilität und Approximation stochastischer Optimierungsprobleme*. Dissertation. Logos-Verl., Berlin.
- Heitsch, H.; Henrion, R.; Küchler, C. & Römisch, W. (2009): „Generierung von Szenariobäumen und Szenarioreduktion für stochastische Optimierungsprobleme in der Energiewirtschaft“ in *Innovative Modellierung und Optimierung von Energiesystemen*, Hrsg. R. Schultz & H.-J. Wagner. LIT, Berlin, S. 227–254.
- Heitsch, H. & Römisch, W. (2011): „Scenario Tree Generation for Multi-stage Stochastic Programs“ in *Stochastic optimization methods in finance and energy – New financial products and energy market strategies*, Hrsg. M. Bertocchi; G. Consigli & M. A. H. Dempster. Springer, New York, S. 313–341.
- Herrmann, N. & Hilmes, U. (2011): *Atomausstieg bis zum Jahr 2020: Auswirkungen auf Investitionen und Wettbewerb in der Stromerzeugung*, Berlin [geprüft am 08.06.2018].
- Herter, M. (2011): *Statistische Daten im Geomarketing. Referat im Forum 1 "Geodaten, Georeferenzierung und Datenschutz" der 5. Konferenz für Sozial und Wirtschaftsdaten 2011*, Bonn. Abrufbar unter: <https://www.ddgi.de/downloads-topmenu-8/interessante-dokumente/ratswd-rat-fuer-sozial-und-wirtschaftsdaten/389-statistische-daten-im-geomarketing/file> [geprüft am 19.07.2013].
- Higle, J. L. & Wallace, S. W. (2002): „Managing risk in the new power business – A sequel“. *IEEE Computer Applications in Power*, Vol. 15, Heft 2, S. 12–19.
- Hoval (2013): *Speicher / Trinkwassererwärmung*. Hoval GmbH. Abrufbar unter: https://www.hoval.de/de/Heiztechnik/Speicher-Trinkwassererw%C3%A4rmung/cl_G_storage-tank-domestic-water-heating [geprüft am 28.12.2018].
- Huber, J. (2016): *Kurzfristige Prognose des Warmwasserbedarfs eines Wohnquartiers – Kurzfristige Prognose des Warmwasserbedarfs eines Wohnquartiers mittels künstlicher neuronaler Netzeers mittels künstlicher neuronaler Netze*. Masterthesis, Karlsruhe.
- Hurink, J.; Schultz, R. & Wozabal, D. (2016): „Quantitative solutions for future energy systems and markets“. *OR Spectrum*, Vol. 38, Heft 3, S. 541–543.
- Hutter, F.; Babic, D.; Hoos, H. H. & Hu, A. J. (2007): „Boosting verification by automatic tuning of decision procedures“ in *Formal Methods in Computer Aided Design (FMCAD'07)*, S. 27–34.

- Hutter, F.; Hoos, H. H. & Leyton-Brown, K. (2010): „Automated configuration of mixed integer programming solvers“ in *Integration of AI and OR Techniques in Constraint Programming for Combinatorial Optimization Problems*, Hrsg. D. Hutchison; T. Kanade; J. Kittler; J. M. Kleinberg; F. Mattern; J. C. Mitchell; M. Naor; O. Nierstrasz; C. Pandu Rangan; B. Steffen; M. Sudan; D. Terzopoulos; D. Tygar; M. Y. Vardi; G. Weikum; A. Lodi; M. Milano & P. Toth. Springer Berlin Heidelberg, Berlin, Heidelberg, S. 186–202.
- Hutter, F.; Hoos, H. H. & Leyton-Brown, K. (2011): „Sequential model-based optimization for general algorithm configuration“ in *Learning and Intelligent Optimization*, Hrsg. D. Hutchison; T. Kanade; J. Kittler; J. M. Kleinberg; F. Mattern; J. C. Mitchell; M. Naor; O. Nierstrasz; C. Pandu Rangan; B. Steffen; M. Sudan; D. Terzopoulos; D. Tygar; M. Y. Vardi; G. Weikum & C. A. C. Coello. Springer, Berlin, Heidelberg, S. 507–523.
- Hutter, F.; Hoos, H. H.; Leyton-Brown, K. & Stützle, T. (2009): „ParamILS: an automatic algorithm configuration framework“. *Journal of Artificial Intelligence Research*, Vol. 36, S. 267–306.
- Huyer, W. & Neumaier, A. (2008): „SNOBFIT -- Stable Noisy Optimization by Branch and Fit“. *ACM Transactions on Mathematical Software*, Vol. 35, Heft 2, S. 1–25.
- IMK (2018): *Messwerte der Globalstrahlung und Temperatur von 2000 bis 2016 des Physikhochhaus am KIT, Campus-Süd*. Institut für Meteorologie und Klimaforschung (IMK), Karlsruher Institut für Technologie (KIT), Karlsruhe.
- Infanger, G. (Hrsg.) (2011): *Stochastic programming – The State of the Art – In Honor of George B. Dantzig*. Springer, New York.
- Jacobshagen, U.; Weise, M.; Hartmann, T. C.; Große, A.; Kachel, M. & Ahlers, M. (2017): *Rechtsleitfaden – Quartiersversorgung*. Im Auftrag von Smart Grids-Plattform Baden-Württemberg e.V.
- Jiang, R.; Wang, J. & Guan, Y. (2012): „Robust Unit Commitment With Wind Power and Pumped Storage Hydro“. *IEEE Transactions on Power Systems*, Vol. 27, Heft 2, S. 800–810.
- Jones, D. R.; Schonlau, M. & Welch, W. J. (1998): „Efficient global optimization of expensive black-box functions“. *Journal of Global Optimization*, Vol. 13, Heft 4, S. 455–492.
- Jones, P. A. (1992): „Cloud-Cover Distributions and Correlations“. *Journal of Applied Meteorology and Climatology*, Vol. 31, Heft 7, S. 732–741.

- Kaiser, F.-J.; Kaminski, H.; Hübner, M. & Brettschneider, V. (1999): *Methodik des Ökonomie-Unterrichts – Grundlagen eines handlungsorientierten Lernkonzepts mit Beispielen*. Julius Klinkhardt, Bad Heilbrunn.
- Kall, P. & Wallace, S. W. (1997): *Stochastic programming*. Wiley, Chichester.
- Kaschub, T. (2017): *Batteriespeicher in Haushalten unter Berücksichtigung von Photovoltaik, Elektrofahrzeugen und Nachfragesteuerung*. Dissertation, Karlsruhe.
- Kaschub, T.; Heinrichs, H.; Jochem, P. & Fichtner, W. (2013): *Modeling load shifting potentials of electric vehicles*. IAEE European Conference, Düsseldorf.
- Kaschub, T.; Jochem, P. & Fichtner, W. (2016): „Solar energy storage in German households – Profitability, load changes and flexibility“. *Energy Policy*, Vol. 98, S. 520–532.
- Katsigiannis, Y. A.; Georgilakis, P. S. & Karapidakis, E. S. (2010): „Multiobjective genetic algorithm solution to the optimum economic and environmental performance problem of small autonomous hybrid power systems with renewables“. *IET Renewable Power Generation*, Vol. 4, Heft 5, S. 404.
- Keles, D. (2013): *Uncertainties in energy markets and their consideration in energy storage evaluation*. Dissertation. KIT Scientific Publishing, Karlsruhe.
- Kerber, G. (2011): *Aufnahmefähigkeit von Niederspannungsverteilsnetzen für die Einspeisung aus Photovoltaikkleinanlagen*. Dissertation, München. Abrufbar unter: <https://mediatum.ub.tum.de/doc/998003/998003.pdf> [geprüft am 15.07.2016].
- Keynes, J. M. (1921): *A treatise on probability*. Macmillan, London.
- Kia, M.; Nazar, M. S.; Sepasian, M. S.; Heidari, A. & Siano, P. (2017): „Optimal day ahead scheduling of combined heat and power units with electrical and thermal storage considering security constraint of power system“. *Energy*, Vol. 120, S. 241–252.
- Kiureghian, A. D. & Ditlevsen, O. (2009): „Aleatory or epistemic? Does it matter?“. *Risk Acceptance and Risk Communication*, Vol. 31, Heft 2, S. 105–112.
- Klobasa, M.; Angerer, G.; Lüllmann, A.; Schleich, J.; Buber, T.; Gruber, Anna, Hünecke, Maria & Roon, S. v. (2013): *Lastmanagement als Beitrag zur Deckung des Spitzenlastbedarfs in Süddeutschland*. Endbericht einer Studie von Fraunhofer ISI und der Forschungsgesellschaft für Energiewirtschaft. Agora Energiewende, Berlin.
- Knight, F. H. (1921): „Risk, uncertainty and profit“. *Hart, Schaffner, and Marx Prize Essays*, Vol. 31.

- Knopf, B.; Kondziella, H.; Pahle, M.; Götz, M.; Bruckner, T. & Edenhofer, O. (2011): *Der Einstieg in den Ausstieg: Energiepolitische Szenarien für einen Atomausstieg in Deutschland*. Studie im Auftrag der Abteilung Wirtschafts- und Sozialpolitik der Friedrich-Ebert-Stiftung, Bonn.
- Kobayakawa, T. & Kandpal, T. C. (2016): „Optimal resource integration in a decentralized renewable energy system – Assessment of the existing system and simulation for its expansion“. *Energy for Sustainable Development*, Vol. 34, S. 20–29.
- Koberstein, A. (2016): „Stochastische Optimierung“ in *Enzyklopädie der Wirtschaftsinformatik – Online-Lexikon*, Hrsg. N. Gronau; J. Becker; J. E. Sinz; L. Suhl & J. M. Leimeister. GITO Verlag, Berlin.
- Koch, T.; Achterberg, T.; Andersen, E.; Bastert, O.; Berthold, T.; Bixby, R. E.; Danna, E.; Gamrath, G.; Gleixner, A. M.; Heinz, S.; Lodi, A.; Mittelman, H.; Ralphs, T.; Salvagnin, D.; Steffy, D. E. & Wolter, K. (2011): „MIPLIB 2010“. *Mathematical Programming Computation*, Vol. 3, Heft 2, S. 103–163.
- Koch, T.; Hiller, B.; Pfetsch, M. E. & Schewe, L. (2015): *Evaluating gas network capacities*. Society for Industrial and Applied Mathematics (SIAM), Philadelphia, Pennsylvania.
- Konstantin, P. (2009): *Praxisbuch Energiewirtschaft*. Springer Berlin Heidelberg, Berlin, Heidelberg.
- Kosow, H.; Erdmann, L.; Gaßner, R. & Luber, B.-J. (2008): *Methoden der Zukunfts- und Szenarioanalyse – Überblick, Bewertung und Auswahlkriterien*. IZT, Berlin.
- Kovacevic, R. M. & Pichler, A. (2015): „Tree approximation for discrete time stochastic processes – A process distance approach“. *Annals of Operations Research*, Vol. 235, Heft 1, S. 395–421.
- Kunze, R. (2016): *Techno-ökonomische Planung energetischer Wohngebäudemodernisierungen – Ein gemischt-ganzzahliges lineares Optimierungsmodell auf Basis einer vollständigen Finanzplanung*. Dissertation. KIT Scientific Publishing, Karlsruhe.
- Laux, H.; Gillenkirch, R. M. & Schenk-Mathes, H. Y. (2014): *Entscheidungstheorie*. Springer Berlin Heidelberg, Berlin, Heidelberg.
- LBW (2007): *Gesetz zur Nutzung erneuerbarer Wärmeenergie in Baden-Württemberg (EWärmeG)*. Land Baden-Württemberg (LBW).
- Leonhard, C. (2016): *Thermische Speicher mit Phasenwechselmaterialien im Heizsystem*. Dissertation, Aachen.

- Lienert, M.; Buttermann, H.-G.; Müsgens, F.; Hillebrand, E.; Peek, M. & Wissen, R. (2010): *Ökonomische Auswirkungen einer Laufzeitverlängerung deutscher Kernkraftwerke: Endbericht*. Im Auftrag des Bundesverbands der deutschen Industrie e.V. (BDI), Köln [geprüft am 08.06.2018].
- Liu, B. Y. & Jordan, R. C. (1960): „The interrelationship and characteristic distribution of direct, diffuse and total solar radiation“. *Solar Energy*, Vol. 4, Heft 3, S. 1–19.
- Liu, M. L. & Sahinidis, N. V. (1996): „Optimization in Process Planning under Uncertainty“. *Industrial & Engineering Chemistry Research*, Vol. 35, Heft 11, S. 4154–4165.
- Lodwick, W. A. & Kacprzyk, J. (Hrsg.) (2010): *Fuzzy Optimization – Recent Advances and Applications*. Springer-Verlag Berlin Heidelberg, Berlin, Heidelberg. Abrufbar unter: <http://site.ebrary.com/lib/alltitles/docDetail.action?docID=10404581>.
- Loomes, G. & Sugden, R. (1982): „Regret Theory – An Alternative Theory of Rational Choice Under Uncertainty“. *The Economic Journal*, Vol. 92, Heft 368, S. 805.
- Lorenzi, G. & Silva, C. A. S. (2016): „Comparing demand response and battery storage to optimize self-consumption in PV systems“. *Applied Energy*, Vol. 180, S. 524–535.
- Lüdeke-Freund, F. & Opel, O. (2014): „Energie“ in *Nachhaltigkeitswissenschaften*, Hrsg. H. Heinrichs & G. Michelsen. Springer Berlin Heidelberg, Berlin, Heidelberg, S. 429–453.
- Lüder, K. (1977): *Investitionsplanung*. Vahlen, München.
- Lunz, B.; Yan, Z.; Gerschler, J. B. & Sauer, D. U. (2012): „Influence of plug-in hybrid electric vehicle charging strategies on charging and battery degradation costs“. *Energy Policy*, Vol. 46, S. 511–519.
- Lüthke, J. (2015): *Entwicklung eines Modells zur Heizwärmebedarfsprognose eines Wohnquartiers und ein Vergleich mit TRNSYS*. Masterthesis, Karlsruhe.
- Maghouli, P.; Hosseini, S. H.; Oloomi Buygi, M. & Shahidehpour, M. (2011): „A Scenario-Based Multi-Objective Model for Multi-Stage Transmission Expansion Planning“. *IEEE Transactions on Power Systems*, Vol. 26, Heft 1, S. 470–478.
- Malcolm, S. A. & Zenios, S. A. (1994): „Robust Optimization for Power Systems Capacity Expansion under Uncertainty“. *The Journal of the Operational Research Society*, Vol. 45, Heft 9, S. 1040.
- Märkert, A. & Gollmer, R. (2016): *User’s Guide to ddsip–AC Package for the Dual Decomposition of Two-Stage Stochastic Programs with Mixed-Integer Recourse*. Department of Mathematics, University of Duisburg-Essen, Duisburg. Abrufbar unter: <https://github.com/RalfGollmer/ddsip/ddsip-man.pdf> [geprüft am 01.05.2016].

- Mascia, F.; López-Ibáñez, M.; Dubois-Lacoste, J. & Stützle, T. (2014): „Grammar-based generation of stochastic local search heuristics through automatic algorithm configuration tools“. *Computers & Operations Research*, Vol. 51, S. 190–199.
- Mavromatidis, G. (2018): *Schriftliche Mitteilung vom 12.09.2018*.
- Mavromatidis, G.; Orehounig, K. & Carmeliet, J. (2017): „Designing electrically self-sufficient distributed energy systems under energy demand and solar radiation uncertainty“. *Energy Procedia*, Vol. 122, S. 1027–1032.
- Mazadi, M.; Rosehart, W. D.; Malik, O. P. & Aguado, J. A. (2009): „Modified Chance-Constrained Optimization Applied to the Generation Expansion Problem“. *IEEE Transactions on Power Systems*, Vol. 24, Heft 3, S. 1635–1636.
- McKenna, R.; Bertsch, V.; Mainzer, K. & Fichtner, W. (2018): „Combining local preferences with multi-criteria decision analysis and linear optimization to develop feasible energy concepts in small communities“. *European Journal of Operational Research*, Vol. 268, Heft 3, S. 1092–1110.
- Meier, H.; Fünfgeld, C.; Adam, T. & Schieferdecker, B. (1999). Repräsentative VDEW-Lastprofile. Im Auftrag des Verbands der Elektrizitätswirtschaft e. V. (VDEW). VDEW, Frankfurt am Main.
- Meindl, B. & Templ, M. (2012): *Analysis of commercial and free and open source solvers for linear optimization problems*. Forschungsbericht CS-2012-1, Technische Universität Wien.
- Mejia-Giraldo, D. (2013): *Robust and flexible planning of power system generation capacity*. Dissertation, Ames. Abrufbar unter: <http://lib.dr.iastate.edu/etd/13225> [geprüft am 02.12.2016].
- Mennel, T. (2012): „Das Erneuerbare-Energien-Gesetz – Erfolgsgeschichte oder Kostenfalle?“. *Wirtschaftsdienst*, Vol. 92, Heft 1, S. 17–22.
- Merei, G.; Berger, C. & Sauer, D. U. (2013): „Optimization of an off-grid hybrid PV–Wind–Diesel system with different battery technologies using genetic algorithm“. *Solar Energy*, Vol. 97, S. 460–473.
- Mietzner, D. (2009): *Strategische Vorausschau und Szenarioanalysen – Methodenevaluati-on und neue Ansätze*. Gabler Verlag / GWV Fachverlage, Wiesbaden.
- Moghaddam, I. G.; Saniei, M. & Mashhour, E. (2016): „A comprehensive model for self-scheduling an energy hub to supply cooling, heating and electrical demands of a building“. *Energy*, Vol. 94, S. 157–170.

- (2015): *Monitoringbericht 2015*. Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen sowie Bundeskartellamt (BNetzA). Abrufbar unter: https://www.bundesnetzagentur.de/SharedDocs/Downloads/DE/Allgemeines/Bundesnetzagentur/Publikationen/Berichte/2015/Monitoringbericht_2015_BA.pdf?jsessionid=068BF0CF3251A2D908B0AD6B89796A13?__blob=publicationFile&v=4 [geprüft am 06.04.2017].
- Moradi, M. H.; Hajinazari, M.; Jamasb, S. & Paripour, M. (2013): „An energy management system (EMS) strategy for combined heat and power (CHP) systems based on a hybrid optimization method employing fuzzy programming“. *Energy*, Vol. 49, S. 86–101.
- Morf, H. (1998): „The Stochastic two-state solar irradiance model (STSIM)“. *Solar Energy*, Vol. 62, Heft 2, S. 101–112.
- Morgan, M. G. & Henrion, M. (1992): *Uncertainty – A guide to dealing with uncertainty in quantitative risk and policy analysis*. Cambridge University Press, Cambridge.
- Müller, J. (2017): „Evolutionary optimization under uncertainty in energy management systems“. *Information Technology*, Vol. 59, Heft 1, S. 464.
- Mulvey, J. M.; Vanderbei, R. J. & Zenios, S. A. (1995): „Robust Optimization of Large-Scale Systems“. *Operations Research*, Vol. 43, Heft 2, S. 264–281.
- Mustajoki, J.; Hämäläinen, R. P. & Lindstedt, M. R. (2006): „Using intervals for global sensitivity and worst-case analyses in multiattribute value trees“. *European Journal of Operational Research*, Vol. 174, Heft 1, S. 278–292.
- Nitsch, J. & Wenzel, B. (2010): *Langfristszenarien und Strategien für den Ausbau der erneuerbaren Energien in Deutschland bei Berücksichtigung der Entwicklung in Europa und global*. Bericht FKZ 03MAP146, Stuttgart [geprüft am 08.06.2018].
- Nürnberg, R. & Römisch, W. (2002): „A two-stage planning model for power scheduling in a hydro-thermal system under uncertainty“. *Optimization and Engineering*, Vol. 3, Heft 4, S. 355–378.
- Obermaier, R. & Saliger, E. (2013): *Betriebswirtschaftliche Entscheidungstheorie – Einführung in die Logik individueller und kollektiver Entscheidungen*. Oldenbourg Wissenschaftsverlag, München.
- Oei, P.-Y.; Gerbaulet, C.; Kemfert, C.; Kunz, F.; Reitz, F. & Hirschhausen, C. v. (2015): *Effektive CO₂-Minderung im Stromsektor: Klima-, Preis- und Beschäftigungseffekte des Klimabeitrags und alternativer Instrumente*. Deutsches Institut für Wirtschaftsforschung, Berlin.

- Oertel, D. (2008): *Energiespeicher – Stand und Perspektiven*. Sachstandsbericht zum Monitoring Nachhaltige Energieversorgung, Arbeitsbericht Nr. 123, Berlin.
- Oh, S.-D.; Kim, K.-Y.; Oh, S.-B. & Kwak, H.-Y. (2012): „Optimal operation of a 1-kW PEMFC-based CHP system for residential applications“. *Applied Energy*, Vol. 95, S. 93–101.
- Öko-Institut (2015): *Die Entwicklung der EEG-Kosten bis 2035*. Studie im Auftrag von Agora Energiewende, Berlin.
- Olfert, K. & Reichel, C. (2009): *Investition*. Kiehl, Ludwigshafen (Rhein).
- Owens, B. (2014): *The rise of distributed power*. General Electric (ecomagination).
Abrufbar unter: <https://www.ge.com/sites/default/files/2014%2002%20Rise%20of%20Distributed%20Power.pdf> [geprüft am 30.09.2016].
- Pagès-Bernaus, A.; Pérez-Valdés, G. & Tomsgard, A. (2015): „A parallelised distributed implementation of a Branch and Fix Coordination algorithm“. *European Journal of Operational Research*, Vol. 244, Heft 1, S. 77–85.
- Pearl, J. (1984): *Heuristics – Intelligent search strategies for computer problem solving*. Addison-Wesley, Reading, Mass.
- Pereira, M.; McCoy, M. F. & Merrill, H. M. (2000): „Managing risk in the new power business“. *IEEE Computer Applications in Power*, Vol. 13, Heft 2, S. 18–24.
- Pflug, G. C. & Römisch, W. (2007): *Modeling, measuring and managing risk*. World Scientific, Hackensack, N.J.
- Philpott, A.; Cochran, J. J.; Cox, L. A.; Keskinocak, P.; Kharoufeh, J. P. & Smith, J. C. (2010): „Modeling Uncertainty in Optimization Problems“ in *Wiley Encyclopedia of Operations Research and Management Science*. John Wiley & Sons, Inc.
- Poppenborg, C. (1996): *Standortplanung für Locally Unwanted Land Uses*. Deutscher Universitätsverlag, Wiesbaden.
- Powell, W. B. (2009): „What you should know about approximate dynamic programming“. *Naval Research Logistics*, Vol. 56, Heft 3, S. 239–249.
- PSU/NCAR (2003): *MM5 Community Model Homepage – MM5 Modeling System Overview*. Pennsylvania State University / National Center for Atmospheric Research.
Abrufbar unter: <http://www.mmm.ucar.edu/mm5/overview.html>
[geprüft am 30.05.2014].
- Puterman, M. L. (2005): *Markov Decision Processes: Discrete Stochastic Dynamic Programming*. Wiley, Hoboken, N.J.

- Reibnitz (1992): *Szenario-Technik – Instrumente für die unternehmerische und persönliche Erfolgsplanung*. Gabler Verlag, Wiesbaden.
- Reinhardt, R.; Hoffmann, A. & Gerlach, T. (2013): *Nichtlineare Optimierung – Theorie, Numerik und Experimente*. Springer Berlin Heidelberg, Berlin, Heidelberg.
- Riecke, W. (2011): *Bereitstellung von historischen Globalstrahlungsdaten für die Photovoltaik*. Fachtagung Energiemeteorologie. Abrufbar unter: https://www.uni-oldenburg.de/fileadmin/user_upload/physik/ag/ehf/enmet/download/procl/G01_riecke_globalstrahlungsdaten.pdf [geprüft am 08.06.2016].
- Rios, L. M. & Sahinidis, N. V. (2013): „Derivative-free optimization – A review of algorithms and comparison of software implementations“. *Journal of Global Optimization*, Vol. 56, Heft 3, S. 1247–1293.
- Ritzenhoff, P. (2006): *Erstellung eines Modells zur Simulation der Solarstrahlung auf beliebig orientierte Flächen und deren Trennung in Diffus- und Direktanteil*. Forschungszentrum Jülich, Zentralbibliothek, Jülich.
- Rodrigues, S.; Torabikalaki, R.; Faria, F.; Cafôfo, N.; Chen, X.; Ivaki, A. R.; Mata-Lima, H. & Morgado-Dias, F. (2016): „Economic feasibility analysis of small scale PV systems in different countries“. *Solar Energy*, Vol. 131, S. 81–95.
- Ruszczynski, A. (1999): „Some advances in decomposition methods for stochastic linear programming“. *Annals of Operations Research*, Vol. 85, S. 153–172.
- Savage, L. J. (1951): „The theory of statistical decision“. *Journal of the American Statistical Association : JASA*, Vol. 46, Heft 253, S. 55–67.
- Schabbach, T.; Wesselak, V. & Steiner, P. (2010): *Thermische Speichertechnologien zur effizienten Nutzung Erneuerbarer Energien/Überschusswärme und ihre Umsetzung in Thüringen*. Im Auftrag der Landesentwicklungsgesellschaft Thüringen mbH, Nordhausen.
- Schade, K. (2012): *Stochastische Optimierung – Bestandsoptimierung in mehrstufigen Lagernetzwerken*. Vieweg+Teubner Verlag, Wiesbaden.
- Schermeyer, H.; Bertsch, V. & Fichtner, W. (2015): „Review and Extension of Suitability Assessment Indicators of Weather Model Output for Analyzing Decentralized Energy Systems“. *Atmosphere*, Vol. 6, Heft 12, S. 1871–1888.
- Schlesinger, M.; Knaut, A.; Lutz, C.; Hofer, P.; Malischek, R.; Lehr, U.; Kemmler, A.; Nick, S.; Ulrich, P.; Kirchner, A.; Panke, T.; Koziel, S.; Paulus, S.; Ley, A.; Tode, C.; Piégsa, A.; Wagner, J.; Seefeldt, F.; Straßburg, S. & Weinert, K. (2014): *Entwicklung der Energiemärkte: Energiereferenzprognose*. Projekt Nr. 57/12: Studie im Auftrag des

- Bundesministeriums für Wirtschaft und Technologie, Basel, Köln, Osnabrück [geprüft am 08.06.2018].
- Schmiegel, A. U. & Kleine, A. (2014): „Optimized Operation Strategies for PV Storages Systems Yield Limitations, Optimized Battery Configuration and the Benefit of a Perfect Forecast“. *Energy Procedia*, Vol. 46, S. 104–113.
- Schönfelder, M. (2013): *Optimierung des Einsatzes brennstoffzellenbasierter Mikro-KWK-Anlagen unter Berücksichtigung des gesteuerten Ladens von Elektrofahrzeugen*. Dissertation. Cuvillier Verlag, Göttingen.
- Schossig, P.; Dötsch, C.; Drück, H.; Götsche, J.; Huenges, E.; Kabus, F. & Tamme, R. (2005): „Thermische Speicher. Wärmespeicher für die Hausenergieversorgung, Speicherung für Hochtemperaturwärme“ in *Wärme und Kälte – Energie aus Sonne und Erde. Beiträge zur FVEE-Jahrestagung 2005*, Hrsg. ForschungsVerbund Erneuerbare Energien (FVEE). Bonifatius GmbH, Berlin, S. 119–130.
- Schreier, H. (2012): *Parametrische Optimierung*. Vorlesungsskript, Institut für Numerische Mathematik und Optimierung, Technische Universität Bergakademie Freiberg [geprüft am 21.03.2017].
- Schultz, R. (1995): „On structure and stability in stochastic programs with random technology matrix and complete integer recourse“. *Mathematical Programming*, Vol. 70, 1-3, S. 73–89.
- Schultz, R. (2003): „Stochastic programming with integer variables“. *Mathematical Programming*, Vol. 97, Heft 1, S. 285–309. Abrufbar unter: <http://dx.doi.org/10.1007/s10107-003-0445-z>.
- Schultz, R. (2012): „... the Real Problem“: Optimization under Uncertainty“ in *Book of Abstracts – European meetings of cybernetics and systems research (EMCSR)*, Hrsg. R. M. Bichler; S. Blachfellner & W. Hofkirchner. Bertalanffy Center for the Study of Systems Science, Wien, S. 217–220.
- Schwarz, H. (2017): „Distributed optimisation of decentralised energy systems under uncertainty on HPC systems“ in *Proceedings of the 3rd bwHPC-Symposium – Heidelberg 2016*, Hrsg. S. Richling; M. Baumann & V. Heuveline. Universitätsbibliothek Heidelberg, Heidelberg, S. 49–54.
- Schwarz, H. & Bertsch, V. (2014): *ESC Touch Meeting – Layout Optimisation Model*. Projekttreffen der Energy Supply Cooperative (ESC), Köln.
- Schwarz, H.; Bertsch, V. & Fichtner, W. (2018a): „Two-stage stochastic, large-scale optimization of a decentralized energy system – A case study focusing on solar PV, heat pumps and storage in a residential quarter“. *OR Spectrum*, Vol. 40, Heft 1, S. 265–310.

- Schwarz, H.; Kotthoff, L.; Hoos, H. H.; Fichtner, W. & Bertsch, V. (2019): „Improving the computational efficiency of stochastic programs using automated algorithm configuration – An application to decentralized energy systems“. *Annals of Operations Research*, Vol. 66, S. 225.
- Schwarz, H.; Schermeyer, H.; Bertsch, V. & Fichtner, W. (2018b): „Self-consumption through power-to-heat and storage for enhanced PV integration in decentralised energy systems“. *Solar Energy*, Vol. 163, S. 150–161.
- Sen, S. & Sherali, H. D. (2006): „Decomposition with branch-and-cut approaches for two-stage stochastic mixed-integer programming“. *Mathematical Programming*, Vol. 106, Heft 2, S. 203–223.
- Shang, C.; Srinivasan, D. & Reindl, T. (2017): „Generation and storage scheduling of combined heat and power“. *Energy*, Vol. 124, S. 693–705.
- Shapiro, A.; Dentcheva, D. & Ruszczyński, A. P. (2009): *Lectures on stochastic programming – modeling and theory*. SIAM, Philadelphia Pa.
- Sherali, H. D. & Fraticelli, B. M. (2002): „A modification of Benders decomposition algorithm for discrete subproblems: An approach for stochastic programs with integer recourse“. *Journal of Global Optimization*, Vol. 22, Heft 1-4, S. 319–342.
- Sherali, H. D. & Smith, J. C. (2009): „Two-stage stochastic hierarchical multiple risk problems – Models and algorithms“. *Mathematical Programming*, Vol. 120, Heft 2, S. 403–427.
- Shirazi, E. & Jadid, S. (2017): „Cost reduction and peak shaving through domestic load shifting and DERs“. *Energy*, Vol. 124, S. 146–159.
- Siemens AG (2013): *Industriegasturbinen – Gasturbinen im Leistungsbereich von 5 bis 50 Megawatt*, Erlangen. Abrufbar unter: https://www.energy.siemens.com/co/pool/hq/power-generation/gas-turbines/downloads/Industrial%20Gas%20Turbines/Industrial_Gas_Turbines_DE.pdf [geprüft am 12.12.2018].
- Sipser, M. (2013): *Introduction to the theory of computation*. Cengage Learning, Delhi, India.
- Snoek, J.; Larochelle, H. & Adams, R. P. (2012): „Practical Bayesian Optimization of Machine Learning Algorithms“ in *Advances in Neural Information Processing Systems 25*, Hrsg. F. Pereira; C. J. C. Burges; L. Bottou & K. Q. Weinberger. Curran Associates, Inc, S. 2951–2959. Abrufbar unter: <http://papers.nips.cc/paper/4522-practical-bayesian-optimization-of-machine-learning-algorithms.pdf>.

- Stehle, R.; Maier, J. & Huber, R. (1996): *Rückberechnung des DAX für die Jahre 1955 bis 1987*. Humboldt-Universität, Berlin. Abrufbar unter:
<http://hdl.handle.net/10419/66277>.
- Stein, O. (2018): *Grundzüge der Nichtlinearen Optimierung*. Springer Berlin Heidelberg, Berlin, Heidelberg.
- Steinmüller, K. & Schulz-Montag, B. (2004): „Szenarien – Instrumente für Innovation und Strategiebildung“. *Wirtschaftspsychologie*, Heft 1, S. 63–66.
- Sterner, M. & Stadler, I. (2014): *Energiespeicher – Bedarf, Technologien, Integration*. Springer Berlin Heidelberg, Berlin, Heidelberg.
- Stier, C. (2017): *Risikomanagement und wertorientierte Unternehmensführung – Effizienz- und Monopoleffekte*. Springer Gabler, Wiesbaden.
- Sunpower (2015): *Datenblatt Solarmodule E20/333 und E20/327 – Dokument Nr. 001-65483 Rev**/A4_DE*. SunPower Corp. Abrufbar unter:
<http://www.mysuntec.com/fileadmin/Datenblaetter/sunpower-e20-327.pdf>.
- Svetlova, E. & van Elst, H. (2013): „How is non-knowledge represented in economic theory?“ in *Ungewissheit als Herausforderung für die ökonomische Theorie: Nichtwissen, Ambivalenz und Entscheidung*, Hrsg. B. Priddat & A. Kaballak. Metropolis-Verl., Marburg, S. 41–72.
- Taborda, D. & Zdravkovic, L. (2012): „Application of a hill-climbing technique to the formulation of a new cyclic nonlinear elastic constitutive model“. *Computers and Geotechnics*, Vol. 43, S. 80–91.
- Tang, J. F.; Wang, D. W.; Fung, R. Y. K. & Yung, K.-L. (2004): „Understanding of fuzzy optimization: theories and methods“. *Journal of Systems Science and Complexity*, Vol. 17, Heft 1, S. 117–136.
- Till, J.; Sand, G.; Urselmann, M. & Engell, S. (2007): „A hybrid evolutionary algorithm for solving two-stage stochastic integer programs in chemical batch scheduling“. *Computers & Chemical Engineering*, Vol. 31, 5-6, S. 630–647.
- Traber, T.; Kemfert, C. & Diekmann, J. (2011): *Strompreise: Künftig nur noch geringe Erhöhung durch erneuerbare Energien*. Wochenbericht des DIW Berlin Nr. 6/2011, Berlin. Abrufbar unter: http://www.diw.de/sixcms/detail.php?id=diw_01.c.368298.de [geprüft am 08.06.2018].

- TU Berlin (2011): *Kosten des Ausbaus der erneuerbaren Energien*. Auftraggeber: Vereinigung der Bayerischen Wirtschaft e. V. (vbw), Bayerische Chemieverbände, Bayerische Papierverbände und Verband der Bayerischen Energie- und Wasserwirtschaft e. V., München, Berlin. Abrufbar unter: http://www.baypapier.com/fileadmin/user_upload/Downloads/Standpunkte/Studie_Kosten_Erneuerbare_Energien.pdf [geprüft am 08.06.2018].
- ÜBN (2018): *Szenariorahmen für die Netzentwicklungspläne Strom 2030 (Version 2019)*. Entwurf der Übertragungsnetzbetreiber (ÜNB): 50Hertz Transmission GmbH; Amprion GmbH; TenneT TSO GmbH; TransnetBW GmbH.
- UMBW (2013): *Eckpunkte für eine Novellierung des EWärmeG nach Kabinettsbeschluss vom 11. Juni 2013*. Ministerium für Umwelt, Klima und Energiewirtschaft Baden-Württemberg (UMBW). Abrufbar unter: https://beteiligungportal.baden-wuerttemberg.de/fileadmin/redaktion/beteiligungportal/UM/EWaermeG/Eckpunkte_EWaermeG.pdf.
- Urbina, M. & Li, Z. (2006): „A Fuzzy Optimization Approach to PV/Battery Scheduling with Uncertainty in PV Generation“ in *2006 38th North American Power Symposium*, S. 561–566.
- Valentin, F. (2018): *StoREgio e.V. 4. Vereinstreffen 2018*. Workshop zu Fragen der Regulierung, Kaiserslautern.
- van Slyke, R. M. & Wets, R. (1969): „L-Shaped Linear Programs with Applications to Optimal Control and Stochastic Programming“. *SIAM Journal on Applied Mathematics*, Vol. 17, Heft 4, S. 638–663.
- VDI (2008): *Referenzlastprofile von Ein- und Mehrfamilienhäusern für den Einsatz von KWK-Anlagen*. Verein Deutscher Ingenieure (VDI). Verein Deutscher Ingenieure (VDI), Düsseldorf. Abrufbar unter: https://www.vdi.de/richtlinie/vdi_4655-referenzlastprofile_von_ein_und_mehrfamilienhaeusern_fuer_den_einsatz_von_kwk_anlagen/.
- Wald, A. (1945): „Statistical Decision Functions Which Minimize the Maximum Risk“. *The Annals of Mathematics*, Vol. 46, Heft 2, S. 265.
- Weber, M. & Hey, C. (2012): „Effektive und effiziente Klimapolitik – Instrumentenmix, EEG und Subsidiarität“. *Wirtschaftsdienst*, Vol. 92, Heft 1, S. 43–51.
- Wei, X.; Kusiak, A.; Li, M.; Tang, F. & Zeng, Y. (2015): „Multi-objective optimization of the HVAC (heating, ventilation, and air conditioning) system performance“. *Energy*, Vol. 83, S. 294–306.

- Weniger, J.; Tjaden, T. & Quaschnig, V. (2012): „Solare Unabhängigkeitserklärung“. *Photovoltaik*, Heft 10, S. 50–54.
- Weniger, J.; Tjaden, T. & Quaschnig, V. (2014): „Sizing of Residential PV Battery Systems“. *Energy Procedia*, Vol. 46, S. 78–87.
- Wille-Hausmann, B.; Erge, T. & Wittwer, C. (2010): „Decentralised optimisation of cogeneration in virtual power plants“. *Solar Energy*, Vol. 84, Heft 4, S. 604–611.
- Wirth, H. (2016): *Aktuelle Fakten zur Photovoltaik in Deutschland*. Fraunhofer Bericht, Fraunhofer-Institut für Solar Energiesysteme (ISE). Abrufbar unter: https://www.hannover.ihk.de/fileadmin/data/Dokumente/Themen/Energie/160422_Fakten_zur_PV.pdf [geprüft am 16.07.2017]
- Wirth, H. (2018): *Aktuelle Fakten zur Photovoltaik in Deutschland*. Fraunhofer Bericht, Fraunhofer-Institut für Solar Energiesysteme (ISE). Abrufbar unter: <https://www.ise.fraunhofer.de/content/dam/ise/de/documents/publications/studies/aktuelle-fakten-zur-photovoltaik-in-deutschland.pdf>. [geprüft am 21.08.2018]
- Wittmann-Hohlbein, M. & Pistikopoulos, E. N. (2011): „A robust optimization based approach to the general solution of mp-MILP problems“ in *21st European Symposium on Computer Aided Process Engineering*, Hrsg. E. N. Pistikopoulos; M. Georgiadis & A. C. Kokossis. Elsevier, S. 527–531.
- Wöhe, G.; Döring, U. & Brösel, G. (2016): *Einführung in die Allgemeine Betriebswirtschaftslehre*. Vahlen, Franz, München.
- Wolfe, P. (2008): „The implications of an increasingly decentralised energy system“. *Energy Policy*, Vol. 36, Heft 12, S. 4509–4513.
- Wosnitza, F. & Hilgers, H. G. (2012): *Energieeffizienz und Energiemanagement – Ein Überblick heutiger Möglichkeiten und Notwendigkeiten*. Springer Spektrum, Wiesbaden.
- Würfel, P. (2000): *Physik der Solarzellen*. Spektrum, Akad. Verl., Heidelberg, Berlin.
- Würfel, P. & Trupke, T. (2003): „Solarzellen der dritten Generation – Grenzen des Wirkungsgrades von Solarzellen“. *Physik Journal*, Vol. 2, Heft 12, S. 45–51 [geprüft am 17.07.2018].
- Xi, X.; Sioshansi, R. & Marano, V. (2014): „A stochastic dynamic programming model for co-optimization of distributed energy storage“. *Energy Systems*, Vol. 5, Heft 3, S. 475–505.
- Xu, D.; Kang, L.; Chang, L. & Cao, B. (2005): „Optimal sizing of standalone hybrid wind/pv power systems using genetic algorithms“ in *Canadian Conference on Electrical and Computer Engineering, 2005*, S. 1722–1725.

- Yan, H. & Luh, P. B. (1997): „A fuzzy optimization-based method for integrated power system scheduling and inter-utility power transaction with uncertainties“. *IEEE Transactions on Power Systems*, Vol. 12, Heft 2, S. 756–763.
- Yazdanie, M.; Densing, M. & Wokaun, A. (2016): „The role of decentralized generation and storage technologies in future energy systems planning for a rural agglomeration in Switzerland“. *Energy Policy*, Vol. 96, S. 432–445.
- Yuan, Y. & Sen, S. (2009): „Enhanced Cut Generation Methods for Decomposition-Based Branch and Cut for Two-Stage Stochastic Mixed-Integer Programs“. *INFORMS Journal on Computing*, Vol. 21, Heft 3, S. 480–487.
- Zantow, R. & Dinauer, J. (2011): *Finanzwirtschaft des Unternehmens – Die Grundlagen des modernen Finanzmanagements*. Pearson Studium, München.
- Zhu, X. (2006): *Discrete two-stage stochastic mixed-integer programs with applications to airline fleet assignment and workforce planning problems*. Dissertation, Blacksburg, USA. Abrufbar unter: <https://vtechworks.lib.vt.edu/bitstream/handle/10919/27212/dissertation.pdf?sequence=1&isAllowed=y> [geprüft am 22.02.2015].

II Abkürzungsverzeichnis

Θ-DES	Optimierungsebene für dezentrale Energiesysteme
approx.	approximativ
abzgl.	abzüglich
ADP	Approximative Dynamische Programmierung
ANF	Annuitätenfaktor
BZ	Brennstoffzelle
bzgl.	bezüglich
CHP	Combined Heat and Power
COP	Leistungszahl oder auch Jahresarbeitszahl (<i>Coefficient of Performance</i>)
CP	Leistungspreis (<i>capacity price</i>)
DAX	Deutscher Aktienindex
determ.	deterministisch
DDSIP	<i>Dual Dekomposition in Stochastic Integer Programmierung</i>
DG	Diesgeneratoren
DP	dynamischer Preis
DSM	Demand-Side-Management
DWD	Deutscher Wetterdienst
EA	evolutionärer Algorithmus
EEG	Erneuerbare-Energien-Gesetz
EEWärmeG	Erneuerbare-Energien-Wärmegesetz des Bundes
EF	Elektrofahrzeug
EGO	effiziente globale Optimierung
Eins.	Einsatzplanung
elektr. / el.	elektrisch
EnEG	Energieeinspargesetz
EnEV	Energieeinsparverordnung
EPEX	<i>European Power Exchange</i>
Erstst.	Erststufe
erw.	erwartet
ESC	<i>Energy Supply Cooperative</i>
EVA	Eigenverbrauchsabgabe
EV-Lösung	Deterministische Lösung der Erwartungswerte
EVPI	<i>Expected Value of Perfect Information</i>
EWärmeG	Erneuerbare-Wärmegesetz des Lands Baden-Württemberg

ext.	extern
geom.	geometrisch
GH	Großhandel
Gl.	Gleichung
GPS	Generalisierte Mustersuche
GSS	Generalisierte Set-Suche
H-AP	hoher Arbeitspreis
H-EVA	hohe Eigenverbrauchsabgabe
HJDS	Hooke-Jeeves-Direkt-Suche
HPC	High-Performance-Computing
H-Zins	hoher Kalkulationszins
IIP	Institut für Industriebetriebslehre und Industrielle Produktion
IKT	Informations- und Kommunikationstechnologien
ILP	ganzzahliges lineares Programm (<i>Integer Linear Program</i>)
Inv.	Investitionsplanung
KWK	Kraft-Wärme-Kopplung
LP	lineares Programm (<i>Linear Program</i>)
lt. mündl.	laut mündlich
MAPE	mittlerer absoluter prozentualer Fehler (<i>Mean Absolute Percentage Error</i>)
max.	maximal
MCS	Multilevel-Koordinatensuche
MILP	gemischt-ganzzahliges lineares Programm (<i>Mixed-Integer Linear Program</i>)
min.	minimal
MINLP	gemischt-ganzzahliges nicht lineares Programm (<i>Mixed-Integer Non-Linear Program</i>)
MIP	gemischt-ganzzahliges Programm (<i>Mixed-Integer Program</i>)
N	Netz
n. a.	nicht angegeben
N-AP	niedriger Arbeitspreis
NLP	nicht lineares Programm (<i>Non-Linear Program</i>)
NP	nicht polynomiell
NPV	Kapitalwert (<i>Net Present Value</i>)
opt.	optimal
o. Ä.	oder Ähnliches
P2H / P2G	Power-to-Heat-/Power-to-Gas-Applikation
PCM	<i>Phase Change Materials</i>

PHELIX	<i>Physical-Electricity-Index</i>
polit.	politisch
progn.	prognostiziert
PV	Photovoltaik
Ref	Referenz
RMSPE	Wurzel aus dem mittleren quadratischen prozentualen Fehler (<i>Root Mean Squared Percentage Error</i>)
RW	Raumwärme
RWS	Raumwärmespeicher
S1-Lösung	Deterministische Lösung eines repräsentativen Szenarios
SAHC	Algorithmus des steilsten Abstiegs (<i>Steepest Ascent Hill Climbing</i>)
SDO	sequenzielles Design zur Optimierung
SDP	Stochastische Dynamische Programmierung
SMAC	<i>Sequential Model-based Algorithm Configuration</i>
SMBO	sequenzielles modellbasiertes Optimierungsverfahren
SMILP	stochastisches gemischt-ganzzahliges lineares Programm (<i>Stochastic Mixed-Integer Linear Program</i>)
SoC	Speicherstand (<i>State of Charge</i>)
SS	stochastische Lösung
ST	Solarthermieanlage
stoch.	stochastisch
StrEG	Stromeinspeisungsgesetz
tägl.	täglich
therm. / th.	thermisch
TPE	<i>Tree-based Parzen Estimator</i>
Transform.	Transformation
u.a.	unter anderem
UBC	<i>University of British Columbia</i>
Übers.	Übersetzung
VBA	<i>Visual Basic Application</i>
VDEW	Verband der Elektrizitätswirtschaft e. V.
Verf.	Verfasser
Vers.	Version
vgl.	vergleiche
vola	Volatilität
VSS	Wert der stochastischen Lösung (<i>Value of Stochastic Solution</i>)

W	Windenergieanlage
WW	Warmwasser
WWS	Warmwasserspeicher
ZS	Zeitscheibe
zzgl.	zuzüglich

III Abbildungsverzeichnis

Abb. 1.1:	Entwicklung der installierten PV-Anlagen (< 100 kWp) in Deutschland.....	2
Abb. 1.2:	Streuung der Globalstrahlung und Temperatur in Karlsruhe von 2000 bis 2016.....	3
Abb. 2.1:	Struktur des Endenergiebedarfs in Deutschland und in deutschen Haushalten einschließlich des Energieträgereinsatzes nach Anwendungsbereichen im Jahr 2016.....	16
Abb. 2.2:	Historische Entwicklung der PV-Einspeisevergütung und -Eigenverbrauchsabgabe sowie der Endkunden-Strompreise in Deutschland	17
Abb. 2.3:	Durchschnittlicher Strompreis (Arbeitspreis) für Endverbraucher auf Haushaltsebene in Deutschland und dessen einzelne absolute und relative Bestandteile für 2015.....	18
Abb. 2.4:	Entwicklung des Strompreises (Arbeitspreises) für Endverbraucher auf Haushaltsebene, der EEG-Umlage und des Großhandelspreises von 2016 bis 2035 gemäß verschiedenen Studien	19
Abb. 3.1:	Schema eines dezentralen Energiesystems.....	29
Abb. 3.2:	Mittlere PV-Ertragsprofile bei ertragsmaximaler Süd-Ausrichtung sowie Ost-West-Ausrichtung für 2016 in Karlsruhe	31
Abb. 3.3:	Referenzlastprofile des VDEW und der VDI-Richtlinie 4655 für Werktage.....	35
Abb. 3.4:	Referenzlastprofile der VDI-Richtlinie 4655 für Werktage.....	37
Abb. 3.5:	Physikalische Einteilung von Speichertechnologien nach Anwendungsgebiet.....	38
Abb. 3.6:	Durchschnittliche und max./min. nominale DAX-Rendite sowie max./min. Inflationsrate in Deutschland p. a. in Abhängigkeit des Betrachtungs- bzw. Anlagehorizonts von 1967 bis 2016.....	41
Abb. 4.1:	Szenariotrichter.....	54
Abb. 6.1:	Konzept zur Generierung der Inputdaten für die Optimierung unter Berücksichtigung von Unsicherheiten.....	73
Abb. 6.2:	Generierungsprozess der Inputdaten für die Optimierung eines Wohnquartiers.....	78
Abb. 6.3:	PV-Angebot und Energienachfrage eines Wohnquartiers an einem typischen sonnigen Sonntag im Spätherbst	79

Abb. 6.4:	Schematisches Energieflussdiagramm des Wohnquartiers	84
Abb. 7.1:	Methodik zur Bewältigung rechentechnischer Herausforderungen des komplexen SMILP	90
Abb. 7.2:	Automatisierte Algorithmuskonfiguration	99
Abb. 8.1:	Aufbau des Energiesystems des Wohnquartiers.....	102
Abb. 8.2:	Jährlicher Arbeitspreis, PV-Eigenverbrauchsabgabe und Großhandelspreis für die Fälle 1–3.....	108
Abb. 8.3:	Kostenaufteilung der Investitions- und Einsatzplanung im Referenzfall ..	110
Abb. 8.4:	Energieflussdiagramm des Wohnquartiers für 100 Szenarien des Referenzfalls (Jahreswerte).....	111
Abb. 8.5:	Charakteristische Werte und deren Streuung von 100 Szenarien für die opt. Lösung des Referenz-falls, rechts als Box-and-Whisker-Plot gezeigt.	112
Abb. 8.6:	Lastdauerlinienbereich von 100 Szenarien des Referenzfalls.....	113
Abb. 8.7:	Optimale Kapazitäten der Energiesystemkomponenten der Fallstudie für den Referenzfall (Ref) und die sechs Alternativfälle.....	117
Abb. 8.8:	Relative Minimal-, Maximal- und Mittelwerte der wöchentlichen optimalen Speicherstände des Raumwärme(RW)-, Warmwasser(WW)- und elektr. Speichers von 100 Szenarien.....	124
Abb. 8.9:	Kostenaufteilung der Investitions- und Einsatzplanung für Sonderfall I und II.....	125
Abb. 8.10:	Links: bivariates Histogramm der min. Gesamtenergiekosten und opt. PV-Anlage (200-€- bzw. 3-kWp-Klassenbreite) sowie stoch. Lösung (SS); rechts: Histogramm der opt. PV-Anlage (3-kWp-Klassenbreite) sowie stoch. und determ. Lösung (SS, EV, S1)	127
Abb. 8.11:	Links: bivariates Histogramm der min. Gesamtenergiekosten und opt. RW-Speicher (200-€- u. 100-l-Klassenbreite) sowie stoch. Lösung (SS); rechts: Histogramm der opt. RW-Speicher (100-l-Klassenbreite) sowie stoch. und determ. Lösung (SS, EV, S1).....	128
Abb. 8.12:	Links: bivariates Histogramm der min. Gesamtenergiekosten und opt. WW-Speicher (200-€- u. 100-l-Klassenbreite) sowie stoch. Lösung (SS); rechts: Histogramm der opt. WW-Speicher (100-l-Klassenbreite) sowie stoch. und determ. Lösung (SS, EV, S1).....	129
Abb. 9.1:	Variabilität der PV-Erzeugung von 100 Szenarien und der max. Gradienten für einen exemplarischen Juni-Tag.....	142
Abb. 9.2:	Einfluss der zeitl. Auflösung auf die optimalen Kapazitäten für den Raumwärmespeicher (RWS) und den Warmwasserspeicher (WWS).....	143

-
- Abb. 9.3: Gesamte Rechenzeit in Sekunden und gesamter Rechenaufwand in Euro in Abhängigkeit von den verwendeten CPU-Kernen unter Verwendung der Standard-CPLEX-Konfiguration und der mit SMAC optimierten CPLEX-Konfiguration inklusive des Konfigurationsaufwands..... 145
- Abb. A.1: Preis-Dauerlinie von historisch beobachteten und simulierten stündlichen Day-ahead-Preisen (PHELIX-Spotmarkt) für vier Jahre..... 160

IV Tabellenverzeichnis

Tab. 4.1:	Entscheidungsrelevante Einflussgrößen bei der Optimierung von Wohnquartieren aus Sicht des privaten Entscheiders und ihre Unsicherheitskategorien (in Anlehnung an Urschel 2010).....	51
Tab. 5.1:	Forschungsüberblick über die Optimierung dezentraler Energiesysteme unter sicheren Bedingungen.....	62
Tab. 5.2:	Forschungsüberblick über die Optimierungsverfahren zur Berücksichtigung von Unsicherheiten.....	68
Tab. 7.1:	Programmdimension des SMILP mit Regret-Minimierung der Fallstudie in Kapitel 8.....	89
Tab. 8.1:	Allgemeine Modellannahmen der Energiesystemkomponenten des Wohnquartiers für alle betrachteten Fälle.....	105
Tab. 8.2:	Fallbeschreibung für ungewisse Parameter.....	107
Tab. 8.3:	Berechnungsergebnisse der Fallstudie des Referenzfalls und der sechs Alternativfälle	118
Tab. 8.4:	Matrix der minimierten erwarteten Gesamtenergiekosten	120
Tab. 8.5:	Matrix des Regrets	121
Tab. 8.6:	Berechnungsergebnisse der Sonderfälle I und II im Vergleich zum Referenzfall.....	126
Tab. 8.7:	Gesamtenergiekosten mit optimaler Investition der stochastischen, EV- und S1-Lösung.....	130
Tab. 9.1:	Gesamte Rechenzeit für das stochastische Programm der Fallstudie mit Regret-Minimierung.....	144
Tab. 9.2:	Anzahl der Iterationen der Optimierung des Masterprogramms: DDSIP im Vergleich zum SAHC-Algorithmus.....	148
Tab. A.1:	Vergleich der simulierten und historischen Wetterdaten mittels vier ausgewählter Indikatoren.....	159
Tab. A.2:	Vergleich statistischer Kennzahlen simulierter und historischer Preise.....	160
Tab. A.3:	H0-Profile im Vergleich zur gemessenen Elektrizitätsnachfrage von 28 Haushalten eines Wohnquartiers in Köln.....	161
Tab. B.1:	Nomenklatur des zweistufigen stochastischen Optimierungsprogramms θ -DES mit Regret-Minimierung für das dezentrale Energiesystem eines Wohnquartiers.....	163
Tab. C.1:	Ableitungsfreie Optimierungsalgorithmen für das in Abschnitt 7.1 vorgestellte Masterprogramm.....	165