

Masterthesis

im Rahmen der Prüfung zur Erlangung des akademischen Grades
Master of Engineering (M.Eng.)
im Studiengang
Systemtechnik

Vergleich von Methoden
zur Reduktion der zeitlichen Komplexität
für die Optimierung sektorgekoppelter Energiesysteme

vorgelegt von
Katharina Esterl

erarbeitet im Rahmen des Forschungsprojekts *eGoⁿ*



Kurzfassung

Zur Verminderung des anthropogenen Klimawandels spielt die Transformation des Energiesystems eine entscheidende Rolle. Im Rahmen der Energiewende wird elektrische Energie zunehmend durch erneuerbare Energien eingespeist. Unterdessen beinhaltet die fortschreitende Sektorkopplung die Integration von Strom-, Wärme-, Gas- und Mobilitätssektor in einem kombinierten Energiesystem. So stehen den fluktuierenden - weil wetterabhängigen - Einspeisern durch die fortschreitende Sektorkopplung erhöhte Bedarfe und veränderte Bedarfsmuster gegenüber. Gleichzeitig ergeben sich durch Kopplung der Sektoren neue Flexibilitätsoptionen.

Zur Untersuchung der Herausforderungen und Chancen wird die Transformation des Energiesystems durch Modellierung und Optimierung sektorgekoppelter Systeme begleitet. Aktuelle Energiesystemmodelle weisen als Folge der stetigen Zunahme des Anteils erneuerbarer Energien in der Stromerzeugung sowie der fortschreitende Sektorkopplung zunehmende Komplexitäten auf. Zur Optimierung dieser Systeme bedarf es deshalb Methoden zur Reduktion der Komplexität. Ziel dieser Methoden ist es, die Komplexität eines Optimierungsproblems unter Wahrung aller wichtigen Informationen zu reduzieren, sodass eine Berechnung bei genügender Genauigkeit und gleichzeitig akzeptabler Rechenzeit ermöglicht wird.

Die vorliegende Arbeit vergleicht die Anwendung von Methoden zur Reduktion der zeitlichen Komplexität für die Optimierung sektorgekoppelter Energiesysteme. Weiterhin wird die Verwendung eines *2-Level-Ansatzes* untersucht, der die Optimierung des Netz- und Speicherausbaus mithilfe der in der Komplexität reduzierten Zeitreihen in einer ersten Optimierungsstufe und die Einsatzoptimierung mithilfe der vollkomplexen Zeitreihen in einer zweiten Optimierungsstufe beinhaltet.

Die folgenden Methoden werden betrachtet:

- *Downsampling*: Reduktion der Zeitreihen auf jeden n-ten Zeitschritt
- *Clustering auf typische Perioden*: Reduktion der Zeitreihen auf eine bestimmte Anzahl typischer Perioden; Betrachtung von typischen Tagen, Wochen und Monaten
- *Segmentation*: Reduktion der Zeitreihen auf eine bestimmte Anzahl von Segmenten aufeinanderfolgender Zeitschritte mit unterschiedlicher Länge

Die Untersuchung der Methoden erfolgt mithilfe eines Minimalbeispiels. Die Methoden werden anhand der Genauigkeit der Optimierungsergebnisse und der Reduktion der Rechenzeit bewertet. Diejenigen Methoden, die sich als am besten geeignet herausstellen, werden anschließend zur Reduktion der zeitlichen Komplexität in einem räumlich hochaufgelösten, sektorgekoppelten Energiesystemmodell verwendet, sodass die grundsätzliche Anwendbarkeit

der ausgewählten Methoden sowie des *2-Level-Ansatzes* für komplexere Systeme nachgewiesen wird.

Es empfiehlt sich die Verwendung von *Downsampling* und *Segmentation*. Die Optimierungsergebnisse weisen unter Anwendung dieser Methoden hohe Genauigkeiten in vergleichsweise kleinen zeitlichen Auflösungen auf. Die Fehlerkonvergenzlinien zeichnen sich durch gute Nachvollziehbarkeit aus. Das ist besonders wertvoll, wenn die Durchführung zeitlich vollkomplexer Referenzrechnungen aufgrund der räumlichen Komplexität des Systems nicht möglich ist. Die Methoden beinhalten großes Reduktionspotential und ermöglichen eine gute Abschätzung der Rechenzeiten. Das Reduktionspotential ist unter Anwendung von *Downsampling* um einen von der räumlichen Komplexität des betrachteten Systems abhängigen Offset größer, der sich durch die unter Anwendung von *Segmentation* notwendige Zeit zur Durchführung des Clusterverfahrens für die Aggregation der Zeitreihen ergibt.

Weiterhin ist die Anwendung des *2-Level-Ansatzes* zu empfehlen. Damit werden optimierte Einsatzzeitreihen in voller zeitlicher Auflösung erzeugt. Weiterhin bewirkt die Anwendung eine Verbesserung der Genauigkeit in den relevanten Auflösungsbereichen sowie durch die ausgleichende Wirkung der zweiten Optimierungsstufe bei Unterschätzung des Systemausbaus in der ersten Stufe die Vereinheitlichung der Fehlerkonvergenzkurve. Die Differenz der Ergebnisse der beiden Optimierungsstufen stellt einen Indikator für die Genauigkeit des Optimierungsergebnisses dar. Damit sind die Ergebnisse besser einschätzbar. Demgegenüber steht eine Verminderung der Reduktion der Rechenzeit um einen von der räumlichen Komplexität des Systems abhängigen Offset. Weil die Rechenzeit zur Optimierung in der zweiten Stufe wesentlich kleiner ist als die Rechenzeit zur kombinierten Optimierung von Ausbau und Einsatz im zeitlich vollkomplexen System, hält sich die Verringerung des Reduktionspotentials in akzeptablen Grenzen.

Abstract

In order to mitigate anthropogenic climate change, the transformation of the energy system plays a decisive role. As part of the energy transition, electrical energy is increasingly being fed in by renewable energies. Meanwhile, progressive sector coupling involves the integration of the electricity, heating, gas and mobility sectors in a combined energy system. Thus, the fluctuating (because weather-dependent) feeders are facing increased demands and changed demand patterns. At the same time, new flexibility options arise through coupling of the sectors.

To investigate the challenges and opportunities, the transformation of the energy system is accompanied by modelling and optimisation of sector-coupled systems. As a result of the steady increase of the share of renewable energies in electricity generation and the progressing sector coupling, current energy system models show increasing complexities. Therefore, methods for reducing complexity are needed to optimise these systems. The aim of these methods is to reduce the complexity of an optimisation problem while preserving all important information, so that a calculation is possible with sufficient accuracy and acceptable computing time at the same time.

This thesis compares the application of time complexity reduction methods for the optimisation of sector-coupled energy systems. Furthermore, this work investigates the use of a *2-level-approach*, which involves optimising grid and storage expansion using the complexity-reduced time series in the first step and optimising dispatch using the fully complex time series in the second step.

The following methods are considered:

- *Downsampling*: reduction of the time series to every n-th time step
- *Clustering to typical periods*: reduction of the time series to a certain number of typical periods; consideration of typical days, weeks and months
- *Segmentation*: reduction of the time series to a certain number of segments of adjacent time steps with different lengths

The methods are examined using a minimal example. The methods are evaluated on the basis of the accuracy of the optimisation results and the reduction of the computing time. The methods turning out to be the most suitable are then applied in a spatially high-resolution, sector-coupled energy system model. The aim is to demonstrate the applicability of the selected methods and the *2-level-approach* to more complex systems.

The use of *Downsampling* and *Segmentation* is recommended. The optimisation results show high accuracies in comparatively small temporal resolutions. The error convergence curves are characterised by good traceability, which is particularly valuable when the performance of

temporally fully complex reference calculations is not possible due to the spatial complexity of the system. The methods show great reduction potential and allow a good estimation of the computation times. The reduction potential is larger under application of *Downsampling* by an offset depending on the spatial resolution. This results from the time necessary to perform the clustering procedure for the aggregation of the time series in the *Segmentation*.

In addition, the application of the *2-level-approach* is recommended. This produces optimised dispatch time series in full temporal resolution. Furthermore, the application causes an improvement of the accuracy in the relevant resolution ranges as well as the unification of the error convergence curve due to the balancing effect of the second optimisation level in case of underestimation of the system expansion in the first level. The difference between the results of the two optimisation levels is an indicator for the accuracy of the optimisation result. This makes it easier to estimate the accuracy. On the other hand, the reduction is reduced by an offset depending on the spatial complexity of the system. Because the computing time for optimisation in the second stage is considerably smaller than the computing time for combined optimisation of expansion and dispatch in the temporally fully complex system, the reduction of the reduction potential is limited to a acceptable measure.

Inhaltsverzeichnis

Kurzfassung	I
Abstract	III
Abkürzungsverzeichnis	VII
Abbildungsverzeichnis	VIII
Tabellenverzeichnis	IX
1 Einleitung	1
2 Stand der Wissenschaft	4
2.1 Reduktion der Komplexität zur Optimierung von Energiesystemen	4
2.2 Methoden zur Reduktion der zeitlichen Komplexität	6
2.3 Herausforderungen bei der Auswahl einer geeigneten Methode	13
3 Methodik der Untersuchung	15
3.1 Grundlagen der eGo ⁿ -Modelle und -Tools	15
3.1.1 Einordnung der Datenmodelle und Tools	16
3.1.2 Verwendetes Tool eTraGo	17
3.2 Anforderungen an Methoden der Reduktion der zeitlichen Komplexität	24
3.3 Auswahl zu untersuchender Methoden und Varianten	26
3.3.1 Downsampling	27
3.3.2 Clustering auf typische Perioden	28
3.3.3 Segmentation	35
3.4 2-Level-Ansatz	37
3.5 Durchführung von Rechnungen zur Untersuchung der Methoden	39
3.5.1 Übersicht über durchgeführte Rechnungen	40
3.5.2 Verwendetes Minimalbeispiel	42
3.5.3 Bedingungen der Berechnungen mit <i>eTraGo</i>	43
3.6 Bewertungskriterien	44
3.6.1 Betrachtung der aggregierten Zeitreihen	44
3.6.2 Bewertung anhand des Optimierungsergebnisses	45
3.6.3 Bewertung anhand der Rechenzeit	45
4 Untersuchung der Methoden anhand eines Minimalbeispiels	47
4.1 Darstellung der Ergebnisse	47
4.1.1 Betrachtung der aggregierten Zeitreihen	47
4.1.2 Betrachtung der Optimierungsergebnisse	50

4.1.3	Betrachtung der Rechenzeiten	58
4.2	Diskussion der Ergebnisse und Bewertung der Methoden	61
4.2.1	Diskussion der Ergebnisse	61
4.2.2	Bewertung der Methoden	64
4.2.3	Bewertung des 2-Level-Ansatzes	66
5	Anwendung ausgewählter Methoden in eTraGo	67
5.1	Darstellung der Ergebnisse	67
5.1.1	Betrachtung der Optimierungsergebnisse	67
5.1.2	Betrachtung der Rechenzeit	68
5.2	Diskussion der Ergebnisse	70
6	Diskussion der Methodik und Ergebnisse	72
6.1	Einordnung in den Stand der Wissenschaft	72
6.2	Kritische Betrachtung der Methodik	73
7	Fazit und Ausblick	76
	Literaturverzeichnis	81
A	Anhang	i
A.1	Anhang Methodik	i
A.1.1	Übersicht über Implementierungen	i
A.1.2	Attributzeitreihen im Minimalbeispiel	ii
A.2	Anhang Ergebnisse	iii
A.2.1	Minimalbeispiel: Betrachtung der aggregierten Zeitreihen	iii
A.2.2	Minimalbeispiel: Ergebnisse der Einsatzoptimierung	v
A.2.3	Minimalbeispiel: Abbildung des Speicherverhaltens	vii
A.2.4	Minimalbeispiel: Abbildung des Speicherverhaltens des Gasnetzspeichers unter Anwendung von <i>Segmentation</i>	viii

Abkürzungsverzeichnis

Abkürzungen

H₂	Wasserstoff
CH₄	Methan
PV	Photovoltaik
DSM	Demand Side Management
LOPF	Linear Optimal Power Flow
AOE	Average Objective Error (nach Gleichung 3.13)
ATR	Average Time Reduction (nach Gleichung 3.15)
RMSE	Root Mean Squared Error (nach Gleichung 3.11)

Akronyme

OEDB	<u>O</u> pen <u>E</u> nergy <u>D</u> ata <u>B</u> ase
<i>eGoⁿ</i>	<u>E</u> lectricity <u>G</u> rid <u>O</u> ptimization (with <u>n</u> flexibilities) - Tool
<i>eTraGo</i>	<u>E</u> lectricity <u>T</u> ransmission <u>G</u> rid <u>O</u> ptimization - Tool
<i>eDisGo</i>	<u>E</u> lectricity <u>D</u> istribution <u>G</u> rid <u>O</u> ptimization - Tool
<i>ding0</i>	<u>D</u> istribution <u>N</u> etwork <u>G</u> enerat <u>O</u> r - Tool
<i>PyPSA</i>	<u>P</u> ython for <u>P</u> ower <u>S</u> ystem <u>A</u> nalysis - Tool

Abbildungsverzeichnis

2.1	Übersicht über zeitliche Inputdaten eines Energiesystemmodells	6
2.2	Prinzipielle Funktionsweisen der häufig verwendeten Methoden zur Reduktion der zeitlichen Komplexität	8
3.1	Einordnung des betrachteten Datenmodells und dazugehörigen Tools <i>eTraGo</i>	17
3.2	Darstellung des Modells des sektorgekoppelten Energiesystems	18
3.3	Darstellung des Modellierungskonzepts in <i>eTraGo</i>	20
3.4	Prinzipielle Funktionsweise des <i>agglomerativen Clusterverfahrens</i>	30
3.5	Prinzipielle Funktionsweise der Verknüpfung von typischen Perioden	34
3.6	Prinzipielle Funktionsweise des verwendeten <i>2-Level-Ansatzes</i>	38
3.7	Darstellung des verwendeten Minimalbeispiels	42
4.1	Minimalbeispiel: Gegenüberstellung originaler und aggregierter Zeitreihen . .	48
4.2	Minimalbeispiel: Darstellung des RMSE_tot der aggregierten Zeitreihen . . .	49
4.3	Minimalbeispiel: Darstellung des AOE	51
4.4	Minimalbeispiel: Darstellung des AOE bei Berücksichtigung von Extremzeitschritten	53
4.5	Minimalbeispiel: Darstellung von Ausbaurkosten und marginalen Kosten . . .	55
4.6	Minimalbeispiel: Gegenüberstellung der Abbildung des Speicherverhaltens . .	57
4.7	Minimalbeispiel: Darstellung der Rechenzeit	59
4.8	Minimalbeispiel: Darstellung des ATR	60
5.1	<i>eTraGo</i> : Darstellung der Systemkosten und des AOE	68
5.2	<i>eTraGo</i> : Darstellung der Rechenzeit	69
5.3	<i>eTraGo</i> : Darstellung des ATR	70
A.1	Minimalbeispiel: Einspeise- und Lastzeitreihen im System	ii
A.2	Minimalbeispiel: Gegenüberstellung originaler und aggregierter Zeitreihen . .	iv
A.3	Minimalbeispiel: Darstellung der Ergebnisse der Einsatzoptimierung	vi
A.4	Minimalbeispiel: Gegenüberstellung der Abbildung des Speicherverhaltens . .	viii
A.5	Minimalbeispiel: CH ₄ -Speichernutzung bei Anwendung von <i>Segmentation</i> . .	viii

Tabellenverzeichnis

2.1	Übersicht über häufig verwendete Methoden	6
2.2	Übersicht über aktuelle wissenschaftliche Arbeiten	12
3.1	Modellkomponenten in <i>eTraGo</i>	21
3.2	Übersicht über Anforderungen	26
3.3	Einordnung der in <i>eTraGo</i> implementierten Methoden	27
3.4	Arbeitsschritte des <i>Clusterings auf typische Perioden</i>	35
3.5	Arbeitsschritte der <i>Segmentation</i> -Methode	37
3.6	Übersicht über durchgeführte Rechnungen	41
A.1	Übersicht über relevante Implementierungen und Verweise zu <i>GitHub</i>	i

1 Einleitung

Mit dem Bundes-Klimaschutzgesetz 2021 (BMUV (2021)) definiert Deutschland seinen Pfad zur Klimafreundlichkeit und verpflichtet sich zur Treibhausgasneutralität bis 2045. Die Transformation des Energiesystems spielt dabei eine entscheidende Rolle. Im Rahmen der Energiewende gilt es, elektrische Energie mithilfe erneuerbarer Energien, also beispielsweise mithilfe von Windkraft- und PV-Anlagen, einzuspeisen. Unterdessen lässt sich die Dekarbonisierung vieler weiterer Sektoren wie des Mobilitätssektors oder Wärmesektors am einfachsten durch Kopplung mit dem elektrischen Sektor realisieren. So stehen den fluktuierenden weil wetterabhängigen Einspeisern durch die fortschreitende Sektorkopplung erhöhte Bedarfe und veränderte Bedarfsmuster gegenüber. Die Sektorkopplung stellt das elektrische Energiesystem vor neue Herausforderungen, gleichzeitig bietet die Integration weiterer Sektoren neue Flexibilitätsoptionen, die es insbesondere im Hinblick auf die Erhöhung des Anteils weniger regelbarer erneuerbarer Energien in der Stromerzeugung auszunutzen gilt.

Die Transformation des Energiesystems wird seit Jahrzehnten durch stetige Versuche der Modellierung der Systeme und der Vorhersage der Weiterentwicklung begleitet (Hoffmann, Kotzur, Stolten und Robinius (2020)). Die Bedeutung von Energiesystemmodellen ist aufgrund der Zunahme von Rechnerkapazitäten, der Notwendigkeit der Versorgungssicherheit und der fortschreitenden Integration wetterabhängiger erneuerbarer Einspeiser stetig gestiegen (Hoffmann et al. (2020)). So nimmt die Energiesystemmodellierung während der heutigen Transformation des Energiesystems eine bedeutende Rolle ein.

Zwar ermöglichen steigende Rechnerkapazitäten für eine lange Zeit die Berechnung immer komplexerer Systeme, jedoch zeichnet sich heute ein Rückgang der Zunahme der Rechnerkapazitäten ab. Dem gegenüber steht als Folge der stetigen Zunahme des Anteils erneuerbarer Energien in der Stromerzeugung sowie der fortschreitende Sektorkopplung eine Erhöhung der Komplexität aktueller Energiesystemmodelle (Hoffmann et al. (2020)). Um dennoch räumlich und zeitlich hochaufgelöste Modelle optimieren zu können, bedarf es Methoden zur Reduktion der Komplexität. Ziel dieser Methoden ist es, die Komplexität eines Optimierungsproblems unter Wahrung aller wichtigen Informationen zu reduzieren, sodass eine Berechnung bei genügender Genauigkeit und gleichzeitig akzeptabler Rechenzeit ermöglicht wird.

In der Regel werden die räumlichen und/oder zeitlichen Inputdaten eines Optimierungsproblems reduziert. Insbesondere die Reduktion der zeitlichen Komplexität bringt durch die Eigenschaften aktueller Energiesystemmodelle erhebliche Herausforderungen mit sich. Diese sind vor allem auf die Integration verschiedener Sektoren mit unterschiedlichen Charakteristiken in Erzeugungs- und Lastzeitreihen, auf die Modellierung wetterabhängiger erneuerbarer Einspeisung sowie auf die Notwendigkeit der korrekten Abbildung von Speicherverhalten zurückzuführen. In aktuellen Arbeiten wird eine Vielzahl von Methoden zur Reduktion der zeitlichen Komplexität vorgestellt und stetig weiterentwickelt. In dem folgenden Punkt stimmen

die Arbeiten überein: Weil die Eignung einer Methode zur Reduktion der zeitlichen Komplexität sowohl von den Eigenschaften der im System integrierten Zeitreihen als auch von der mathematischen Struktur des Optimierungsproblems abhängt und die Übersichtlichkeit mit zunehmender Komplexität erschwert wird, sind zur Auswahl einer geeigneten Methode spezifische Untersuchungen im betrachteten Energiesystemmodell notwendig.

Die vorliegende Untersuchung wird im Rahmen des Forschungsprojekts *eGoⁿ* erarbeitet, das die Entwicklung eines sektorgekoppelten und netzebenenübergreifenden Modells und Planungstools des deutschen Energienetzes beinhaltet. Ziel ist die ganzheitliche Untersuchung der Transformation eines integrierten Energiesystems und insbesondere der Herausforderungen und Chancen im Hinblick auf die Sektorkopplung und weitere elektrische Flexibilität. Das im Rahmen der Arbeit betrachtete Tool *eTraGo* wird zur Optimierung von Netz- und Speicherausbau auf Hoch- und Höchstspannungsebene des sektorgekoppelten Energienetzes in Deutschland entwickelt. Das dazugehörige Datenmodell zeichnet sich durch eine hohe räumliche und zeitliche Auflösung aus. Zur Lösung des Optimierungsproblems bedarf es der Reduktion der räumlichen und zeitlichen Komplexität.

Bisher wurde *eTraGo* für Untersuchungen innerhalb des elektrischen Sektors verwendet. Die Integration der Sektoren Gas, Wärme und Mobilität geht mit einer Erhöhung der Komplexität der Inputdaten sowie des Modellierungskonzeptes einher. Deshalb sind Untersuchungen notwendig, um eine geeignete Methode zur Reduktion der zeitlichen Komplexität auszuwählen. Weiterhin bedarf die Schnittstelle des betrachteten Tools *eTraGo* zum dazugehörigen Tool *eDisGo*, das zur Optimierung auf Nieder- und Mittelspannungsebene dient, besonderer Aufmerksamkeit. Zur netzebenenübergreifenden Optimierung wird ein *Top-Down-Ansatz* verwendet, sodass die Optimierungsergebnisse in *eTraGo* als Eingangsdaten zur Optimierung in *eDisGo* dienen. Die durch die Schnittstelle gestellten Anforderungen an Methoden zur Reduktion der zeitlichen Komplexität bleiben in den bisherigen Arbeiten mit *eTraGo* unberücksichtigt.

In der vorliegenden Arbeit sollen deshalb Methoden zur Reduktion der zeitlichen Komplexität für die Optimierung sektorgekoppelter Energiesysteme verglichen werden. Ziel ist es, die Eignung der Methoden zu überprüfen, um diejenige Methode, die sich am besten eignet, für zukünftige Untersuchungen mit *eTraGo* zu empfehlen. Dabei soll ein *2-Level-Ansatz* verwendet werden, der die Optimierung des Netz- und Speicherausbaus mithilfe der in der Komplexität reduzierten Zeitreihen im ersten Schritt und die Einsatzoptimierung mithilfe der vollkomplexen Zeitreihen im zweiten Schritt beinhaltet. Dieser Ansatz berücksichtigt die speziellen Anforderungen der Schnittstelle zu *eDisGo*. Im Rahmen dieser Arbeit sollen folgende Fragen beantwortet werden:

1. Welche Methode eignet sich am besten zur Reduktion der zeitlichen Komplexität für die Optimierung des betrachteten, räumlich hochaufgelösten, sektorgekoppelten Energiesystemmodells in *eTraGo*?
2. Welche minimale zeitliche Auflösung ist bei Anwendung der ausgewählten Methode festzulegen?

-
3. Ist der beschriebene *2-Level-Ansatz* in dem betrachteten räumlich und zeitlich hochaufgelösten Energiesystemmodell zur Optimierung in *eTraGo* anwendbar?
 4. Wie wirkt sich die Verwendung des *2-Level-Ansatzes* mit zweistufiger Optimierung im Vergleich zu einer einstufigen Optimierung auf die Ergebnisse aus?

Die Untersuchung der Methoden erfolgt anhand eines Minimalbeispiels, dessen Modellierungskonzept und Inputdaten analog zum betrachteten Datenmodell und Tool *eTraGo* ausgewählt sind. Das ermöglicht die Berechnung eines zeitlichen vollkomplexen Referenzfalls ohne Reduktion der räumlichen Komplexität. Im Anschluss an die Untersuchung der Methoden im Minimalbeispiel werden die Methoden, die sich als am vielversprechendsten herausstellen, mithilfe von *eTraGo* im komplexen Datenmodell angewandt. Das im Rahmen dieser Arbeit betrachtete Datenmodell des sektorgekoppelten Energiesystems Deutschlands sowie das dazugehörige Tool *eTraGo* sind zum Zeitpunkt der Durchführung dieser Untersuchung nicht gänzlich fertiggestellt. Ziel der Rechnungen in *eTraGo* ist der Nachweis der grundsätzlichen Anwendbarkeit der ausgewählten Methoden sowie des verwendeten *2-Level-Ansatzes*.

Im folgenden Kapitel soll zunächst der Stand der Wissenschaft festgehalten werden (Kapitel 2) bevor die Vorgehensweise dieser Untersuchung dargestellt wird. Dazu werden zunächst die Grundlagen der Modelle und Tools des Forschungsprojekts *eGoⁿ* sowie im Detail die verwendeten Tools und Datenmodelle beschrieben (Kapitel 3.1). In Kapitel 3.2 werden die Anforderungen formuliert, die an Methoden zur Reduktion der zeitlichen Komplexität für die Optimierung des betrachteten sektorgekoppelten Energiesystems mit *eTraGo* gestellt werden. Aus dem Stand der Wissenschaft und den identifizierten Anforderungen werden diejenigen Methoden ausgewählt, die im Rahmen dieser Untersuchung verglichen werden sollen. In Kapitel 3.3 werden die notwendigen Arbeitsschritte sowie die Implementierung der einzelnen Methoden ausführlich beschrieben. Weiterhin wird der verwendete *2-Level-Ansatz* erläutert (Kapitel 3.4). In Kapitel 3.5 ist eine Übersicht über die in der vorliegenden Arbeit durchgeführten Rechnungen gegeben. Dieses Kapitel enthält alle relevanten Informationen zum Minimalbeispiel, den getroffenen Einstellungen in *eTraGo* sowie zum Solver und zur verwendeten Hardware. In Kapitel 3.6 werden zum Abschluss der Beschreibung der Vorgehensweise die Kriterien zur Bewertung der Methoden festgehalten. In Kapitel 4 werden die Ergebnisse der Untersuchung der Methoden anhand des Minimalbeispiels dargestellt (Kapitel 4.1) und anschließend diskutiert (Kapitel 4.2). In diesem Zuge werden die untersuchten Methoden sowie der verwendete *2-Level-Ansatz* bewertet. Im darauffolgenden Kapitel werden die Ergebnisse der Rechnungen in *eTraGo* dargestellt und diskutiert (Kapitel 5, bevor die Ergebnisse in Kapitel 6 in den Stand der Wissenschaft eingeordnet werden. Weiterhin wird die Methodik der vorliegenden Untersuchung kritisch betrachtet. Kapitel 7 fasst die Erkenntnisse zusammen, beantwortet die Forschungsfragen und gibt einen Ausblick auf sinnvolle zukünftige Untersuchungen.

2 Stand der Wissenschaft

Im Folgenden wird der Stand der Wissenschaft festgehalten. Zunächst soll die Vorgehensweise zur Reduktion der Komplexität für die Optimierung von Energiesystemmodellen dargestellt werden, bevor die prinzipiellen Funktionsweisen von Methoden zur Reduktion der zeitlichen Komplexität erläutert werden. Anschließend werden Erkenntnisse aus verschiedenen Arbeiten dokumentiert, die für die Auswahl einer geeigneten Methode zur Anwendung in einem sektorgekoppelten Energiesystemmodell von Bedeutung sind.

2.1 Reduktion der Komplexität zur Optimierung von Energiesystemen

Die stetige Zunahme des Anteils erneuerbarer Energien in der Stromerzeugung sowie die fortschreitende Sektorkopplung haben steigende Komplexitäten von Energiesystemmodellen zur Folge. Es ist eine Reduktion der Komplexität notwendig, um die zur Untersuchung der Transformation des Energiesystems notwendigen Berechnungen räumlich und zeitlich hochaufgelöster Energiesystemmodelle gewährleisten zu können. Ziel ist es, die Komplexität von Optimierungsproblemen zu reduzieren, sodass eine Berechnung unter Wahrung einer möglichst hohen Genauigkeit bei gleichzeitig akzeptabler Rechenzeit ermöglicht wird.

In der Regel ist die Komplexität eines Energiesystemmodells maßgeblich bestimmt durch die folgenden Eigenschaften (Hoffmann et al. (2020)):

- **räumliche Dimension:** Betrachtungsraum und räumliche Auflösung
- **zeitliche Dimension:** betrachteter Zeithorizont und zeitliche Auflösung
- **technische Dimension:** Eigenschaften der Modellkomponenten
- **ökonomische Dimension:** Kostenfunktionen

Die Inputdaten des Modells charakterisieren die räumliche und zeitliche Dimension, während die technische und ökonomische Dimension durch das Modellierungskonzept mit den enthaltenen mathematischen Strukturen und Kostenfunktionen beschrieben wird (Hoffmann et al. (2020)). Die räumliche Dimension ist definiert durch die Anzahl der Knoten des Netzmodells und deren Verbindungen untereinander (Hoffmann et al. (2020)). Die zeitliche Dimension ist charakterisiert durch die zeitliche Auflösung, also die betrachteten Zeiteinheiten wie z. B. Stunden, sowie durch den betrachteten Zeithorizont, z. B. ein Jahr. Diese Eigenschaften betreffen weiterhin die Frage nach intertemporalen Abhängigkeiten, z. B. zur Modellierung von Speicherverhalten (Hoffmann et al. (2020)). Die technische und ökonomische Dimension ist definiert durch die mathematische Darstellung der Modellkomponenten und deren Rolle für

die Optimierung sowie durch Kostenfunktionen. Dabei ist relevant, ob es sich um eine Simulation der Einsätze und Lastflüsse handelt, oder ob und wie die verschiedenen Komponenten optimiert werden, z. B. ob nur der Einsatz einer Komponente oder auch der Ausbau optimiert wird. Außerdem spielt eine Rolle, welche dynamische Abhängigkeiten in der mathematischen Struktur des Modells bestehen (Hoffmann et al. (2020)).

Entsprechend der beschriebenen Eigenschaften kann die Komplexität eines Modells an verschiedenen Stellen reduziert werden. Insbesondere wenn das Modellierungskonzept, das den Anforderungen der jeweiligen Untersuchungen angepasst wird, nicht verändert werden soll, wird auf die Reduktion der Inputdaten zurückgegriffen. Es gilt, die Inputdaten so zu reduzieren, dass alle relevanten Informationen der Inputdaten erhalten bleiben, um eine ausreichende Genauigkeit der Optimierungsergebnisse zu gewährleisten.

Die räumliche Komplexität kann durch Reduktion der Anzahl der vorhandenen Knoten sowie deren Verbindungen untereinander reduziert werden. Grundsätzlich sind zwei Schritte notwendig, um die Netztopologie zu reduzieren (Biener und Garcia Rosas (2020)). Im ersten Schritt werden die im Originalnetz vorhandenen Knoten in Cluster eingeteilt. Häufig wird dazu ein *k-means Clustering* verwendet, das die Knoten anhand ihrer geografischen Positionen einteilt. Aktuell gewinnen Methoden an Bedeutung, die die elektrischen Distanzen zwischen den Knoten und damit die tatsächliche Netztopologie berücksichtigen (Biener und Garcia Rosas (2020)). Im zweiten Schritt werden die Netzstrukturen innerhalb der Cluster reduziert. Es ist üblich, die Knoten innerhalb eines Clusters zu einem repräsentativen Knoten zusammenzufassen, die Leitungen innerhalb der Cluster zu vernachlässigen und Leitungen zwischen Knoten verschiedener Cluster zu abstrakten Leitungen zwischen den jeweiligen repräsentativen Knoten zusammenzufassen (Biener und Garcia Rosas (2020)). So wird das Netz mit seiner originalen Anzahl an Knoten und Verbindungen auf ein Netz mit einer geringeren Anzahl an Knoten und Verbindungen reduziert.

Die zeitliche Komplexität der Inputdaten ist charakterisiert durch den betrachteten Zeithorizont sowie die zeitliche Auflösung (Hoffmann et al. (2020)). Diese Eigenschaften bestimmen die Anzahl der betrachteten Zeitschritte. Die zeitabhängigen Inputdaten stellen die Zeitreihen der zeitabhängigen Attribute über die Zeitschritte dar (Hoffmann et al. (2020)). Die zeitabhängigen Attribute stellen vor Berechnung des Energiesystemmodells bekannte Daten wie Einspeisezeitreihen wetterabhängiger erneuerbarer Einspeiser oder Lastzeitreihen dar. In Abhängigkeit der für die Untersuchung relevanten Inputdaten sowie der räumlichen Komplexität des Energiesystemmodells kann die Anzahl der Zeitreihen variieren, was in Abbildung 2.1 deutlich wird. Zur Reduktion der Komplexität wird die Anzahl der betrachteten Zeitschritte reduziert und durch Gewichtung der bestehenden Zeitschritte auf den ursprünglichen Betrachtungshorizont hochgerechnet.

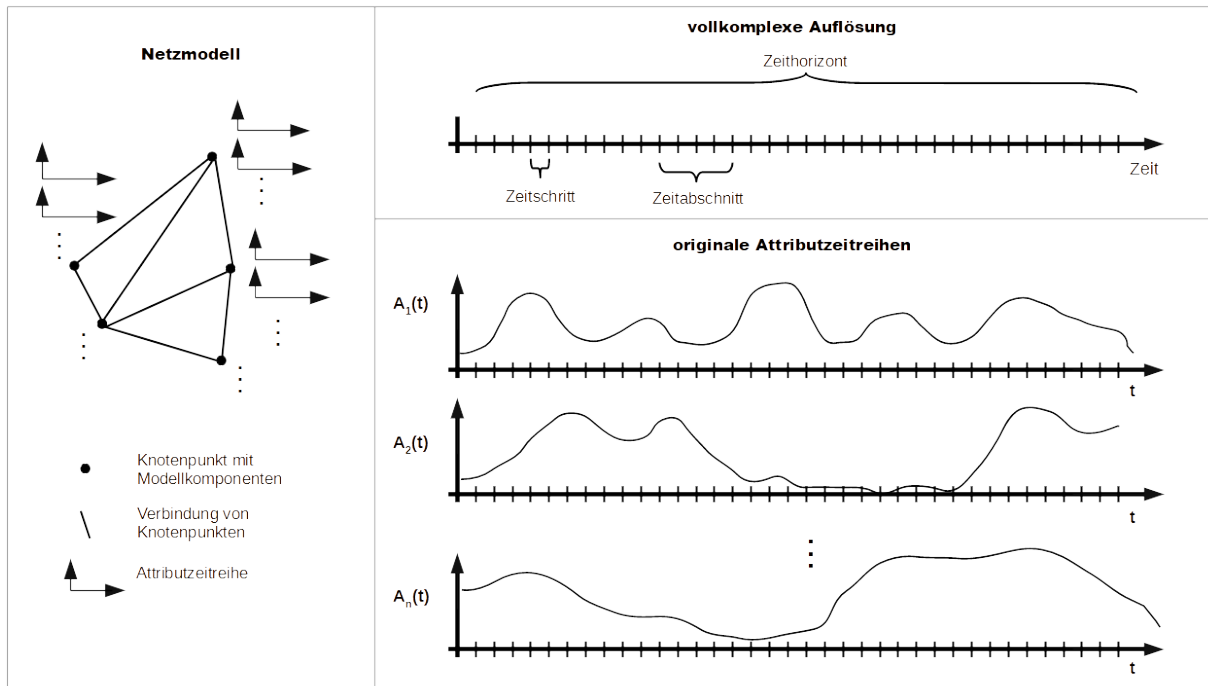


Abbildung 2.1: Übersicht über zeitliche Inputdaten eines Energiesystemmodells

2.2 Methoden zur Reduktion der zeitlichen Komplexität

In der Literatur wird eine Vielzahl von Methoden zur Reduktion der zeitlichen Komplexität vorgestellt und stetig weiterentwickelt. In den aktuell veröffentlichten Übersichtsarbeiten von Hoffmann et al. (2020) und Teichgraber und Brandt (2022) werden die verschiedenen Methoden systematisch eingeordnet, es werden Trends analysiert und der Forschungsstand dargestellt. Die Arbeit von Hoffmann et al. (2020) ordnet die am häufigsten verwendeten Methoden in die in Tabelle 2.1 dargestellten Kategorien ein. Es wird unterschieden zwischen Methoden, die die Auflösung der Zeitreihen auf bestimmte Zeitschritte reduzieren und Methoden, die die Zeitreihen auf typische Zeitabschnitte reduzieren. Methoden, die die reduzierten Zeitreihen basierend auf der Position der Zeitschritte bzw. Zeitabschnitte innerhalb der Zeitreihe erstellen, sind als zeitbasiert eingeordnet, während Methoden, die die Charakteristiken der Attributzeitreihen berücksichtigen, als eigenschaftsbasiert eingeordnet werden. Grundsätzlich können die eingeordneten Methoden beliebig miteinander kombiniert oder durch zusätzliche Funktionalitäten ergänzt werden. Im Folgenden sollen zunächst die prinzipiellen Funktionsweisen der Methoden erklärt werden. Abbildung 2.2 ergänzt die Erklärungen um eine Visualisierung der prinzipiellen Funktionsweisen.

Tabelle 2.1: Übersicht über häufig verwendete Methoden zur Reduktion der zeitlichen Komplexität nach Hoffmann et al. (2020)

	Variation der Auflösung	Ermittlung typischer Perioden
zeitbasiert	Downsampling	Manuelle Auswahl und Mittelwertbildung
eigenschaftsbasiert	Segmentation	Clustering

Downsampling

Bei Anwendung dieser Methode werden Gruppen aufeinanderfolgender Zeitschritte durch einen Zeitschritt repräsentiert. Die Ermittlung der zusammengefassten Zeitschritte erfolgt anhand deren Position in der Zeitreihe. Für jede Gruppe wird ein Zeitschritt als repräsentativ angenommen. Dieser repräsentative Zeitschritt wird entsprechend der Anzahl der Zeitschritte seiner Gruppe gewichtet, sodass das Optimierungsergebnis auf den betrachteten Zeithorizont hochskaliert wird. Zum Beispiel kann eine Zeitreihe über ein Jahr mit stündlicher Auflösung (8760 Zeitschritte) auf jeden fünften Zeitschritt, also jede fünfte Stunde, reduziert werden. Dann werden ein Fünftel der originalen Zeitschritte, also 1752 Stunden, statt 8760 Stunden betrachtet. Dabei repräsentiert jede fünfte Stunde der originalen Zeitreihe entsprechend jeweils fünf aufeinanderfolgende Stunden, wodurch die Gewichtung der repräsentativen Stunden vorgegeben ist.

Segmentation

Diese Methode beinhaltet die eigenschaftsbasierte Bestimmung von repräsentativen Zeitschritten. Die Ermittlung zusammengefasster Zeitschritte erfolgt anhand der Werte der zeitabhängigen Attribute. So werden die Zeitschritte in eine bestimmte Anzahl an Cluster eingeteilt, sodass Zeitschritte mit ähnlichen Attributwerten denselben Clustern angehören. Zur Erhaltung der Konsekutivität der Zeitschritte innerhalb der Zeitreihe werden nur aufeinanderfolgende Zeitschritte in dieselben Cluster eingeordnet. So können intertemporale Abhängigkeiten berücksichtigt werden, um die Abbildung von Speicherverhalten zu ermöglichen. Für jedes Cluster wird ein repräsentativer Zeitschritt festgelegt. Durch die Gewichtung der repräsentativen Zeitschritte, die sich aus der Anzahl der zugeordneten Zeitschritte ergibt, wird der gesamte Zeithorizont betrachtet. Mit dieser Methode ergibt sich damit eine Zeitreihe bestehend aus Segmenten unterschiedlicher Länge.

Manuelle Auswahl typischer Perioden und Mittelwertbildung

Bei Anwendung dieser Methode werden typische Zeitabschnitte, als typische Perioden bezeichnet, ausgewählt, auf die die originale Zeitreihe reduziert wird. Dazu wird die Zeitreihe zunächst in Zeitabschnitte gleicher Länge aufgeteilt, jeder Zeitabschnitt besteht also aus der gleichen Anzahl an Zeitschritten. Die typischen Perioden werden anschließend anhand deren Position innerhalb der Zeitreihe ausgewählt. So kann beispielsweise eine Zeitreihe über ein Jahr mit stündlicher Auflösung (8760 Zeitschritte) zunächst in 365 Zeitabschnitte mit einer Länge von je 24 Zeitschritten, also in 365 Tage eingeteilt werden. Anschließend werden beispielsweise drei Tage pro Monat (z. B. ein Wochentag, Samstag und Sonntag) als typische Tage ausgewählt, sodass die Zeitreihe auf 36 typische Perioden mit je einer Länge von 24 Zeitschritten, also auf 864 Zeitschritte reduziert wird. Mithilfe der Gewichtung der typischen Perioden wird das Optimierungsergebnis auf den vollen Zeithorizont hochskaliert. Unter Mittelwertbildung ist in diesem Zusammenhang die Aggregation zusammenhängender Zeitabschnitte auf typische Perioden gemeint. In diesem Fall könnten beispielsweise alle Tage eines Monats auf einen typischen Tagen zusammengefasst werden, in dem die Mittelwerte der Attribute gebildet werden. So erhält man einen durchschnittlichen Tag pro Monat, sodass die Zeitreihe auf zwölf typische Tage reduziert werden kann.

Clustering auf typische Perioden

Diese Methode reduziert die originale Zeitreihe auf typische Zeitabschnitte (typische Perioden), die basierend auf den Werten der zeitabhängigen Attribute identifiziert werden. Zunächst wird die originale Zeitreihe in Zeitabschnitte gleicher Länge eingeteilt. Anschließend werden die Zeitabschnitte eigenschaftsbasiert in eine bestimmte Anzahl an Clustern eingeteilt, sodass Zeitabschnitte, für die die Attributwerte ähnlich sind, den selben Clustern zugeordnet werden. Für jedes Cluster werden repräsentative Zeitabschnitte ausgewählt, die als typische Perioden bezeichnet werden. Die Zeitreihe wird auf diese typischen Perioden reduziert. Durch die Gewichtung der typischen Perioden, die sich aus der Anzahl der dem Cluster zugehörigen Zeitabschnitte ergibt, wird das Optimierungsergebnis auf den gesamten betrachteten Zeithorizont hochskaliert.

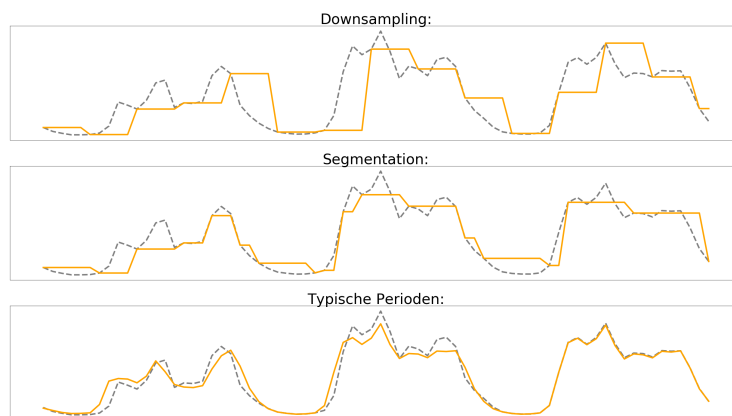


Abbildung 2.2: Prinzipielle Funktionsweisen der häufig verwendeten Methoden zur Reduktion der zeitlichen Komplexität

Um unter Verwendung des *Clusterings auf typische Perioden* Speicherverhalten korrekt abzubilden, ist die Implementierung zusätzlicher Nebenbedingungen erforderlich (Hoffmann et al. (2020)). Wenn nämlich die Zeitabschnitte der Zeitreihe in Abhängigkeit der Ähnlichkeiten der Attributwerte in Cluster eingeteilt werden, bleibt die Reihenfolge der Zeitabschnitte innerhalb der originalen Zeitreihe in der Regel nicht bestehen. Zur Berücksichtigung intertemporaler Zusammenhänge wie des Speicherverhaltens im System ist der Erhalt der Konsekutivität der Zeitreihe jedoch notwendig. Andernfalls können die Änderungen der Speicherfüllstände über die Zeit sowie die Begrenzung der Füllstände durch die Speicherkapazitäten nicht korrekt berücksichtigt werden. In der Arbeit von Hoffmann et al. (2020) werden verschiedene Optionen vorgestellt, die die Abbildung von Speicherverhalten annähern. So wird durch die periodische Festlegung des Speicherfüllstands der Füllstand von allen Speichern im System für den Beginn und das Ende einer jeden Periode auf einen bestimmten Wert gelegt. Diese Festlegung ermöglicht die Abbildung von Speicherverhalten innerhalb der betrachteten Perioden und die logische Verknüpfung der Perioden. Allerdings kann das Speicherverhalten über den Zeithorizont der Perioden, also zum Beispiel saisonales Speicherverhalten bei Clustering auf typische Tage, nicht abgebildet werden (Hoffmann et al. (2020)). In aktuellen Arbeiten findet vor allem die von Kotzur, Markewitz, Robinius und Stolten (2018b) vorgestellte Option Anwendung, die auf den Arbeiten von Gabrielli, Gazzani, Martelli und Mazzotti (2018) und Renaldi und Friedrich (2017) basiert. Ziel ist es, die typischen Perioden mithilfe einer zweiten

Zeitschicht zu verknüpfen. Durch Superposition von intra-periodischen und inter-periodischen Speicherfüllständen wird das Speicherverhalten trotz der Reduktion der Zeitreihe in den übrigen Prozessen über die volle, originale Zeitreihe abgebildet. Dieser Ansatz stellt eine bessere Näherung der Abbildung von Speicherverhalten dar, allerdings erhöhen die notwendigen Nebenbedingungen die Komplexität des Optimierungsproblems in Abhängigkeit der Anzahl der betrachteten typischen Perioden (Büttner (2020)).

Grundsätzlich liegen allen vier beschriebenen Methoden die folgenden beiden Schritte zugrunde:

1. Einteilung der Zeitschritte bzw. Zeitabschnitte in Gruppen / Cluster
2. Festlegung eines repräsentativen Zeitschrittes oder Zeitabschnittes pro Gruppe / Cluster

Für die eigenschaftsbasierte Zuordnung von Zeitschritten bzw. -abschnitten in Cluster stehen verschiedene Clusterverfahren zur Verfügung, die mit unterschiedlichen Distanzmetriken kombiniert werden können. Clusterverfahren beschreiben die Verfahren zur Ermittlung der Gruppen bestehend aus ähnlichen Objekten, die Distanzmetriken definieren die Ähnlichkeiten der betrachteten Objekte. Eine ausführliche Beschreibung der Optionen ist in den Arbeiten von Hoffmann et al. (2020), Kotzur, Markewitz, Robinius und Stolten (2018a), Raventós (2018) und Viole (2020) zu finden. Sowohl die als zeitbasiert, als auch die als eigenschaftsbasiert eingeordneten Methoden erfordern die Festlegung von als repräsentativ angenommenen Zeitschritten bzw. -abschnitten pro Gruppe bzw. Cluster. Es bestehen verschiedene Optionen zur Auswahl dieser. So können durch Mittelwertbildung durchschnittliche Zeitschritte bzw. -abschnitte pro Gruppierung erzeugt werden. Kotzur et al. (2018a) weisen in ihrer Arbeit in Übereinstimmung mit weiteren Arbeiten nach, dass die Verwendung von durchschnittlichen Zeitschritten tendenziell eine Unterschätzung der Systemanforderungen zur Folge hat, da Extrempunkte aus den Zeitreihenprofilen ausgeglättet werden. Aus diesem Grund werden häufig einzelne Zeitschritte bzw. -abschnitte pro Gruppierung als repräsentativ ausgewählt. Bei den eigenschaftsbasierten Methoden hat sich die Auswahl desjenigen Zeitschrittes bzw. -abschnitts bewährt, der dem Median des Clusters entspricht (Kotzur et al. (2018a)). In aktuellen Arbeiten haben sich die Verwendung von *median-basierten hierarchischen Clusterverfahren mit Ward's Kriterium* oder die Verwendung eines *k-medoids Clusterings* etabliert (Kotzur et al. (2018a), Hoffmann, Priesmann et al. (2021), Pineda und Morales (2018), Raventós und Bartels (2020), Viole (2020)).

In den meisten Anwendungsfällen sind Zeitpunkte, in denen extreme Anforderungen an das System gestellt werden, besonders interessant, da zu diesen Zeitpunkten Netzengpässe und Versorgungsunsicherheiten auftreten und sich damit die Notwendigkeit zum Ausbau von Netz und Speichermöglichkeiten ableiten lässt. Die Aggregation der Attributzeitreihen auf repräsentative Zeitschritte bzw. -abschnitte birgt die Gefahr der Ausglättung von Spitzen und somit die Missachtung von Zeitpunkten extremer Anforderungen (Kotzur et al. (2018a)). Aus diesem Grund werden in einigen Arbeiten Extrempunkte der originalen Zeitreihen in die aggregierten Zeitreihen eingefügt. Es handelt sich dabei je nach verwendeter Reduktionsmethode um Extremzeitschritte oder Perioden, die Extremzeitschritte enthalten. Dazu gilt es zunächst, Zeitpunkte zu identifizieren, die extreme Anforderungen an das System stellen. Als

Kriterien zur Auswahl dieser Extremzeitpunkte können beispielsweise Extrema verschiedener Attributzeitreihen oder aufsummierter Zeitreihen dienen. Grundsätzlich erhöht sich die Schwierigkeit der Identifikation der kritischen Zeitpunkte mit zunehmender Komplexität des Systems (Hoffmann et al. (2020)). Nach Anwendung der ausgewählten Methode zur Aggregation der Zeitreihen werden die identifizierten Zeitschritte bzw. Perioden in die aggregierten Zeitreihen eingefügt. Kotzur et al. (2018a) beschreiben in ihrer Arbeit ausführlich verschiedene Arten des Hinzufügens dieser Zeitschritte. So können die identifizierten Extremzeitschritte bzw. Extremperioden einfach als zusätzliche Zeitschritte bzw. zusätzliche Perioden in die aggregierten Zeitreihen eingefügt werden oder als repräsentative Zeitschritte bzw. typische Perioden einer Gruppierung festgelegt werden. Die Berücksichtigung von Extremzeitpunkten findet in verschiedenen Arbeiten Anwendung (z. B. Kotzur et al. (2018a), Pfenninger (2017)). Die Vorgehensweisen zur Identifikation der kritischen Zeitpunkte sowie zur Berücksichtigung innerhalb der aggregierten Zeitreihen unterscheidet sich dabei je nach Anwendungsfall.

Die beschriebenen und in Abbildung 2.2 visualisierten Methoden stellen Grundformen der in Tabelle 2.1 dargestellten Kategorien dar. Die Methoden werden häufig in der beschriebenen Weise genutzt, in einigen Arbeiten finden sie in abgewandelter Form Anwendung. So beschreiben Renaldi und Friedrich (2017) in ihrer Untersuchung eine zeitbasierte Methode, die die Verwendung verschiedener Auflösungen, also verschiedener Zeitschichten beinhaltet. So kann berücksichtigt werden, dass die Komponenten des Energiesystems unterschiedliche kritische Zeithorizonte aufweisen, innerhalb derer sie operieren. Die Anwendung dieser Methode erfordert gutes Wissen über die einzelnen Modellkomponenten und deren Charakteristiken (Hoffmann et al. (2020)). Andere Methoden, die den eigenschaftsbasierten Methoden zuzuordnen sind, beinhalten zusätzlich die Erhaltung spezieller Charakteristiken oder statistischer Merkmale. So werden in der aktuellen Arbeit von Hoffmann, Kotzur und Stolten (2021) statistische Merkmale der originalen Zeitreihen in den aggregierten Zeitreihen erhalten, indem spezielle Merkmale der Jahresdauerlinien der Attribute berücksichtigt werden. Ähnlich arbeiten Kannengießler et al. (2019) und Poncelet, Höschle, Delarue, Virag und D’haeseleer (2017) in ihren Untersuchungen. Es wird deutlich, dass die beschriebenen Ansätze zur Reduktion der zeitlichen Komplexität ständig an spezielle Energiesystemmodelle und Optimierungsaufgaben angepasst sowie weiterentwickelt werden. Daraus entstehen eine Vielzahl verschiedener Varianten. Außerdem bestehen einige weitere Ansätze, die nicht in die von Hoffmann et al. (2020) identifizierten Kategorien eingeordnet werden können. Es handelt sich hierbei meist um Methoden, die speziell für bestimmte Energiesystemmodelle und Optimierungsaufgaben entwickelt worden sind und deshalb nur sehr vereinzelt Anwendung finden. In der vorliegenden Arbeit sollen diese nicht explizit erläutert werden. In der Übersichtsarbeit von Hoffmann et al. (2020) sind diese der Vollständigkeit halber dennoch kurz erklärt.

Unabhängig von der Auswahl der Methode zur Reduktion der zeitlichen Komplexität gewinnen mehrstufige Verfahren an Bedeutung, die die Begrenzung des durch die Reduktion der Zeitreihen herbeigeführten Fehlers beinhalten. Durch mehrstufige Optimierungsverfahren werden mithilfe durchgeführter Optimierungen gewonnene Systeminformationen zur Aggregation der Zeitreihen genutzt. In einigen Fällen werden die durch die Reduktion der zeitlichen Komplexität herbeigeführten Ungenauigkeiten begrenzt. In der Arbeit von Baumgärtner et al. (2019) werden in einem iterativen Verfahren durch die Verwendung verschiedener Optimie-

rungsansätze obere und untere Grenzen des Ergebnisses festgelegt und durch die Limitierung der Lücke zwischen den Grenzen eine geeignete zeitliche Auflösung abgeleitet. Dabei werden die Netzsynthese, also die Optimierung des Netz- und Speicherausbaus, von der Optimierung der Einsatzplanung unterschieden. Auch Bahl, Söhler, Hennen und Bardow (2018) und Kannengießer et al. (2019) unterscheiden in ihren mehrstufigen Verfahren die Netzsynthese und die Optimierung der Einsatzplanung. In den bereits genannten Übersichtsarbeiten (Hoffmann et al. (2020), Teichgraeber und Brandt (2022)) wird den mehrstufigen Verfahren eine hohe Bedeutung für zukünftige Forschung eingeräumt. Diese Verfahren beinhalten die Anpassung der Aggregation anhand von Optimierungsergebnissen anstelle der Anpassung anhand spezieller Merkmale der Attributzeitreihen. Weil die mathematische Struktur des Optimierungsproblems für die Güte der Aggregation von Zeitreihen eine zentrale Rolle spielt, empfehlen Hoffmann et al. (2020) und Teichgraeber und Brandt (2022) die Weiterentwicklung und Generalisierung dieser Verfahren.

Tabelle 2.2 gibt eine Übersicht über die Verwendung von Methoden zur Reduktion der zeitlichen Komplexität in aktuellen wissenschaftlichen Arbeiten. Bei den meisten Arbeiten handelt es sich um Untersuchungen von Methoden zur räumlichen Komplexitätsreduktion, in einigen werden die genannten Verfahren zur Untersuchung eines Systems angewandt. In der Tabelle sind insbesondere Informationen bezüglich der räumlichen Auflösung des betrachteten Energiesystemmodells sowie über die im Energiesystemmodell enthaltenen Sektoren gegeben.

Tabelle 2.2: Übersicht über die Verwendung von Methoden zur Reduktion der zeitlichen Komplexität in aktuellen wissenschaftlichen Arbeiten

Arbeit	Energiesystemmodell	Methode
Müller, Schachler, Scharf et al. (2019)	elektrisches System räumlich aufgelöst	Downsampling
Renaldi und Friedrich (2017)	elektrisches System ohne räumliche Auflösung	Downsampling mit mehreren Zeitschichten
Pfenninger (2017)	elektrisches System räumlich aufgelöst	Downsampling und Clustering auf typische Perioden ohne Verknüpfung der Perioden
Kotzur et al. (2018a)	sektorgekoppeltes System ohne räumliche Auflösung	Clustering auf typische Perioden ohne Verknüpfung der Perioden
Caglayan, Heinrichs, Stolten und Robinius (2019)	sektorgekoppeltes Systems (Strom- und Wasserstoffsektor) räumlich aufgelöst	Clustering auf typische Perioden ohne Verknüpfung der Perioden
Gabrielli et al. (2018)	sektorgekoppeltes System ohne räumliche Auflösung	Clustering auf typische Perioden mit Verknüpfung der Perioden
Hoffmann, Priesmann et al. (2021)	sektorgekoppeltes System ohne räumliche Auflösung und elektrisches System räumlich aufgelöst	Clustering auf typische Perioden mit Verknüpfung der Perioden
Poncelet et al. (2017)	elektrisches System ohne räumliche Auflösung	Clustering auf typische Perioden ohne Verknüpfung der Perioden mit optimierungsbasiertem Ansatz
Kannengießner et al. (2019)	sektorgekoppeltes System mit und ohne räumliche Auflösung	Clustering auf typische Perioden mit Verknüpfung der typischen Perioden mit mehrstufigem Verfahren
Bahl et al. (2018)	sektorgekoppeltes System ohne räumliche Auflösung	Clustering auf typische Perioden mit Verknüpfung der typischen Perioden mit mehrstufigem Verfahren
Baumgärtner et al. (2019)	sektorgekoppeltes System ohne räumliche Auflösung und elektrisches System räumlich aufgelöst	Clustering auf typische Perioden mit Verknüpfung der typischen Perioden mit mehrstufigem Verfahren
Pineda und Morales (2018)	elektrisches System räumlich aufgelöst	Clustering auf typische Perioden mit Verknüpfung der Perioden und Segmentation
Raventós und Bartels (2020) und Raventós (2018)	elektrisches System räumlich aufgelöst	Clustering auf typische Perioden mit Verknüpfung der Perioden und Segmentation
Viole (2020)	eines sektorgekoppeltes System (Strom- und Gassektor) räumlich aufgelöst	Clustering auf typische Perioden mit Verknüpfung der Perioden und Segmentation
Hoffmann, Kotzur und Stolten (2021)	sektorgekoppeltes System ohne räumliche Auflösung und elektrisches System räumlich aufgelöst	Clustering auf typische Perioden in Kombination mit Segmentation

2.3 Herausforderungen bei der Auswahl einer geeigneten Methode

Grundsätzlich hat sich in den letzten Jahren die Verwendung von eigenschaftsbasierten Methoden etabliert, während zeitbasierte Methoden in aktuellen Arbeiten weniger zu finden sind (Hoffmann et al. (2020)). Das liegt mutmaßlich daran, dass die untersuchten Energiesystemmodelle immer komplexer und damit unübersichtlicher werden, sodass die zeitbasierte Auswahl repräsentativer Zeitschritte schwierig ist, während die Ermittlung von Ähnlichkeiten durch Clusterverfahren auch für große Datenmengen einfach durchführbar ist.

Die Methode des *Clusterings auf typische Perioden* wird, so ist es in den Arbeiten von Hoffmann et al. (2020) und Teichgraeber und Brandt (2022) festgehalten und wird mit Blick auf Tabelle 2.2 deutlich, in den Arbeiten der letzten Jahre am meisten verwendet. In vielen Arbeiten konnten durch die Verwendung des *Clusterings auf typische Perioden* gute Ergebnisse erzielt werden (Kotzur et al. (2018b), Hoffmann, Priesmann et al. (2021), Caglayan et al. (2019)). Der Vorteil dieser Methode ist das Ausnutzen der Periodizität der Attributzeitreihen. Unter Anwendung dieser Methode werden sich wiederholende Muster innerhalb der Attributzeitreihen verwertet, wodurch sich ein hohes Reduktionspotential ergeben kann, falls die Periodizitäten in möglichst vielen der enthaltenen Attributzeitreihen präsent sind (Hoffmann et al. (2020)). Falls das nicht der Fall ist, ergeben sich durch die Anwendung der Methode Abweichungen. Dies gilt insbesondere für Energiesystemmodelle mit einem hohen Anteil an Stromerzeugung durch Windkraftanlagen, wie Kotzur et al. (2018a), Gabrielli et al. (2018) und Raventós und Bartels (2020) aus ihren Untersuchungen ableiten. Raventós und Bartels (2020) empfehlen für das in ihrer Arbeit räumlich hochaufgelöste Stromnetzmodell mit einem hohen Anteil an Stromerzeugung durch Windkraftanlagen deshalb nach Vergleich der Anwendung des *Clusterings auf typische Perioden* mit Verknüpfung der Perioden nach Kotzur et al. (2018b) und der Anwendungen der *Segmentation*-Methode die Verwendung der letzteren Methode. Die Verwendung dieser ermöglicht nach Raventós und Bartels (2020) eine bessere Verkürzung der Rechenzeit und eine höhere Genauigkeit der Optimierungsergebnisse. Außerdem konvergiert der durch Anwendung der *Segmentation* induzierte Fehler in dieser Untersuchung vorhersehbar zu Null, was für den durch das *Clustering auf typische Perioden* induzierten Fehler nicht der Fall ist.

Die Arbeit von Raventós und Bartels (2020) thematisiert weiterhin analog zu weiteren Arbeiten (Kotzur et al. (2018a) und Caglayan et al. (2019)) die Abhängigkeit von der räumlichen Komplexität. Raventós und Bartels (2020) stellen fest, dass die Reduktion der räumlichen Komplexität effizienter ist als die Reduktion der zeitlichen Komplexität. Sofern die räumliche Auflösung der Ergebnisse wie beispielsweise die räumliche Verteilung von Speichern oder anderen Komponenten weniger relevant sind für die Untersuchung, kann die Komplexität des Optimierungsproblems durch die Reduktion der räumlichen Komplexität stärker reduziert werden, ohne zu viel Genauigkeit des Gesamtergebnisses einzubüßen. Weiterhin kommen Caglayan et al. (2019) und Kotzur et al. (2018a) zu dem Ergebnis, dass die Reduktion der zeitlichen Komplexität in räumlich reduzierten Modellen besser funktioniert als in räumlich hochaufgelösten Modellen. Die Ursache dafür liegt nach Caglayan et al. (2019) in der Verschiedenartigkeit der vielen Attributzeitreihen an verschiedenen Knoten im Netz, die

sich insbesondere für Einspeisezeitreihen erneuerbarer Einspeiser unter Berücksichtigung verschiedener Wetterzeitreihen in Abhängigkeit der geografischen Gegebenheiten verstärkt. Aus diesem Grund ist die Reduktion der räumlichen unbedingt vor der Reduktion der zeitlichen Komplexität durchzuführen.

Eine besondere Herausforderung bei der Reduktion der zeitlichen Komplexität stellen Speicher dar. Theoretisch erlauben sowohl die Anwendung der *Segmentation* als auch (unter Implementierung zusätzlicher Nebenbedingungen) die Anwendung des *Clusterings auf typische Perioden* die Abbildung von Speicherverhalten. Nichtsdestotrotz stellen Hoffmann, Priesmann et al. (2021), Baumgärtner et al. (2019) und Raventós (2018) fest, dass die Verwendung dieser Methoden in Modellen mit hohen Speicherkapazitäten ungenauere Optimierungsergebnisse liefern als in Modellen mit weniger oder ohne Speicherkapazität. Hoffmann, Priesmann et al. (2021) stellen in ihrer Arbeit fest, dass die Existenz von Speichern im Modell sowie die Dauer ihrer Zyklen ein wichtigeres Kriterium für die Auswahl der Methode und ggf. die Auswahl der Länge von Perioden darstellen als die Periodizität bestimmter Zeitreihen.

In dem folgenden Punkt stimmt ein großer Teil aller betrachteten Untersuchungen überein: Die Wahl einer geeigneten Methode zur Reduktion der zeitlichen Komplexität lässt sich aufgrund der zunehmenden Komplexität der Energiesystemmodelle und der damit zunehmenden Unübersichtlichkeit mit dem heutigen Wissensstand in der Regel nicht ohne Untersuchung der Anwendbarkeit einzelner Methoden auf das spezielle System treffen (Teichgraeber und Brandt (2022), Hoffmann, Priesmann et al. (2021), Raventós und Bartels (2020), Pfenninger (2017)). Die Anwendbarkeit einer Methode zur Reduktion der zeitlichen Komplexität ist nämlich abhängig von den Eigenschaften der Attributzeitreihen und der mathematischen Struktur der Systemoptimierung. Aus diesem Grund kann die Güte einer Methode auch nicht an der Genauigkeit der aggregierten Zeitreihen im Vergleich zu den originalen Attributzeitreihen gemessen werden (Kotzur et al. (2018a), Raventós und Bartels (2020), Hoffmann, Priesmann et al. (2021), Teichgraeber und Brandt (2022)). Im besten Fall sollte die Auswahl einer geeigneten Methode stattdessen mithilfe der Optimierungsergebnisse des zeitliche vollkomplexen Systems getroffen werden (Teichgraeber und Brandt (2022)).

3 Methodik der Untersuchung

Zur Untersuchung von Methoden für die Reduktion der zeitlichen Komplexität werden das im Rahmen des Forschungsprojekts *eGoⁿ* entwickelte Netzdatenmodell des sektorgekoppelten Energienetzes auf Hoch- und Höchstspannungsebene in Deutschland sowie das dazugehörige Tool *eTraGo* verwendet. Im Folgenden sollen zunächst die Grundlagen der *eGoⁿ*-Modelle und Tools sowie das für die durchgeführten Untersuchungen relevante Tool *eTraGo* vorgestellt werden.

Anschließend sollen die Anforderungen an Methoden zur Reduktion der zeitlichen Komplexität festgehalten werden, bevor die Auswahl der im Rahmen dieser Arbeit untersuchten Methoden und deren Varianten erläutert und deren schrittweise Funktionsweise sowie die Implementierung der verschiedenen Methoden vorgestellt werden.

Im Rahmen dieser Arbeit soll ein 2-Level-Ansatz angewandt werden. Dieser beinhaltet zunächst eine Optimierung des Netz- und Speicherausbaus auf Grundlage der nach Anwendung einer Methode zur Reduktion der zeitlichen Komplexität aggregierten Zeitreihen des Systems. Anschließend wird unter Berücksichtigung der Ergebnisse des Netz- und Speicherausbaus der Einsatz der verschiedenen Komponenten auf Grundlage der originalen Zeitreihen optimiert. Der verwendete 2-Level-Ansatz soll im Rahmen dieses Kapitels vorgestellt werden.

Im Anschluss soll ein Überblick über die im Rahmen dieser Arbeit durchgeführten Rechnungen gegeben werden. Die Methoden zur Reduktion der zeitlichen Komplexität werden zunächst mithilfe eines Minimalbeispiels untersucht, das sich am betrachteten Datenmodell und Tool *eTraGo* orientiert. Anschließend werden die Methoden innerhalb des Tools *eTraGo* angewandt. Im Zuge des Überblicks über die Durchführung der Rechnungen sollen Solverinformationen und Informationen zur verwendeten Hardware festgehalten werden.

Zuletzt werden die Kriterien zur Bewertung der Methoden zur Reduktion der zeitlichen Komplexität erläutert.

3.1 Grundlagen der *eGoⁿ*-Modelle und -Tools

Im Rahmen des Forschungsprojektes *eGoⁿ* wird ein im Vorgängerprojekt *open_eGo* entwickeltes, transparentes und netzebenenübergreifendes Planungstool für das elektrische Netz in Deutschland weiterentwickelt. Dieses Tool dient zur Ermittlung volkswirtschaftlich günstiger Ausbauszenarien im Hinblick auf die fortschreitende Erhöhung des Anteils erneuerbarer Erzeugung und unter Berücksichtigung alternativer Flexibilitätsoptionen. Alle verwendeten

Daten und Methoden sind ausführlich im Abschlussbericht des Forschungsprojekts dokumentiert (Müller, Schachler, Bunke et al. (2019)). Zur Abbildung der voranschreitenden Elektrifizierung wird das Modell um Bedarfe und Flexibilitäten der Sektoren Gas, Wärme und Mobilität sowie um zusätzliche elektrische Flexibilitäten ergänzt. Ziel ist es, ein integriertes Planungstool des Energiesystems in Deutschland bereitzustellen und Herausforderungen und Chancen der Sektorkopplung sowie weiterer elektrischer Flexibilitäten zu untersuchen. Eine ausführliche Dokumentation der Daten und Methoden wird im Abschlussbericht des Forschungsprojekts auf der dazugehörigen Website¹ nachzulesen sein.

3.1.1 Einordnung der Datenmodelle und Tools

Das integrierte Netzplanungstool *eGoⁿ* setzt sich aus den Tools *eTraGo* und *eDisGo* und deren jeweiligen Datenmodellen zusammen. Alle Open-Data-Netzdatenmodelle sind auf der OEDB² veröffentlicht. Die modular entwickelten Tools sind als Open-Source-Tools auf GitHub³ zugreifbar.

eTraGo stellt das Tool zur Optimierung von Netz- und Speicherausbau auf Hoch- und Höchstspannungsebene dar. Mithilfe öffentlich verfügbarer Daten wird im Rahmen des *dataprocessing* ein räumlich und zeitlich hochaufgelöstes Modell des Netzes erstellt. Das europäische Ausland wird, abstrahiert auf wenige Knotenpunkte, ebenfalls berücksichtigt. Eine detaillierte Beschreibung des Tools ist im folgenden Kapitel (Kapitel 3.1.2) nachzulesen.

Analog zu *eTraGo* dient *eDisGo* zur Optimierung in der Nieder- und Mittelspannungsebene. Innerhalb des Tools *ding0* werden basierend auf geografischen Gegebenheiten und unter Berücksichtigung der historischen Entwicklung der Netzstruktur ortsspezifische Netze für die einzelnen Mittelspannungsnetzgebiete generiert. Niederspannungsnetzgebiete werden anhand angepasster Referenznetzmodelle modelliert.

Zur netzebenenübergreifenden Optimierung des Energiesystems in *eGoⁿ* wird ein Top-Down-Ansatz verwendet, der die Nutzung der beiden beschriebenen Tools *eTraGo* und *eDisGo* kombiniert. Dazu wird zunächst das Hoch- und Höchstspannungsnetz optimiert. Die relevanten Optimierungsergebnisse, also Erzeugungseinsatz, Speichereinsatz und Speicherausbau, werden anschließend zur Optimierung des Mittel- und Niederspannungsnetzes verwendet. Als Referenzpunkte für die Schnittstellen dienen die im Datenmodell des Hoch- und Höchstspannungsnetzes enthaltenen Umspannwerke zur Mittelspannungsebene.

Um die Rechenzeit zu verkürzen, wird die Komplexität des Netzdatenmodells in *eTraGo* in der Regel in der räumlichen und zeitlichen Dimension reduziert. Durch räumliche Clusterverfahren verringert sich die räumliche Auflösung auf eine festgelegte Anzahl an Netzknotenpunkten. Aufgrund der Zuordnung der Mittelspannungsnetze zu Umspannwerken müssen die Optimierungsergebnisse deshalb disaggregiert, also auf die Originalkomponenten der einzelnen Cluster verteilt werden, bevor die Ergebnisse in *eDisGo* verwendet werden können. Die Reduktion der zeitlichen Komplexität resultiert in aggregierten Zeitreihen, auf deren Basis

¹<https://ego-n.org/>

²<https://openenergy-platform.org/>

³<https://github.com/openego/>

Netz- und Speicherausbau optimiert werden. Die entsprechend der zeitlichen Aggregation charakteristischen, optimierten Zeitreihen werden identisch an *eDisGo* weitergegeben. Damit nimmt die Aggregation der Zeitreihen in *eTraGo*, die unabhängig ist von jeglichen Charakteristiken der Zeitreihen in *eDisGo*, maßgeblich Einfluss auf die Auflösung der Inputdaten der Optimierung der Nieder- und Mittelspannungsnetze.

Abbildung 3.1 gibt eine Übersicht über die beschriebene Entwicklung der Datenmodelle sowie die Einbindung der erläuterten Tools innerhalb der eGoⁿ-Toollandschaft.

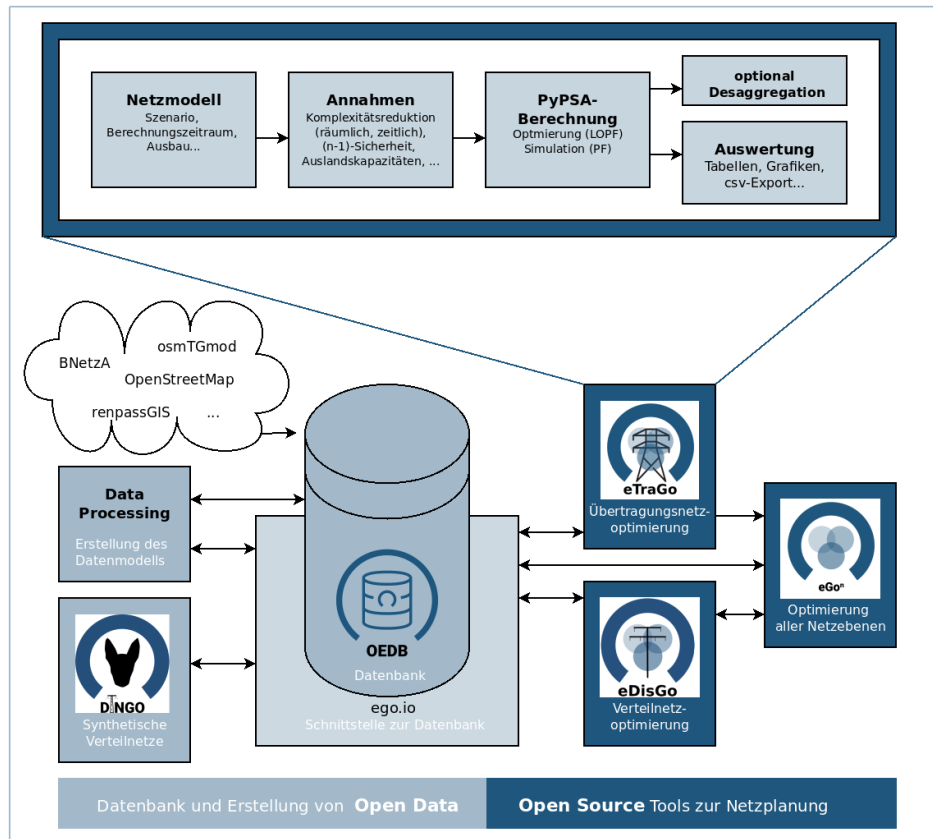


Abbildung 3.1: Einordnung des betrachteten Datenmodells und dazugehörigen Tools *eTraGo* in die eGoⁿ-Datenmodelle und Tools in Anlehnung an Müller, Schachler, Bunke et al. (2019) und Büttner (2020)

3.1.2 Verwendetes Tool eTraGo

Im Rahmen dieser Arbeit soll das Tool *eTraGo* verwendet werden, das zur Optimierung von Netz- und Speicherausbau auf Hoch- und Höchstspannungsebene des sektorgekoppelten Energienetzes in Deutschland entwickelt wird. Abbildung 3.1 zeigt *eTraGo* mit seinen einzelnen Funktionalitäten eingeordnet in die eGoⁿ-Toollandschaft. Im Folgenden werden das betrachtete Datenmodell und die wichtigsten Funktionalitäten beschrieben. Eine ausführliche Beschreibung der Daten und Methoden ist der Dokumentation⁴ zu entnehmen.

⁴<https://etrigo.readthedocs.io/en/latest/>

Netzmodell und Modellierungskonzept

Das Open-Data-Netzmodell ist auf der OEDB⁵ abgelegt. Zur Modellierung wird das Python-Tool *PyPSA*⁶ verwendet. Die Daten werden importiert und als *PyPSA*-Komponenten mit entsprechenden Parametern eines *PyPSA*-Netzwerks implementiert.

Das Datenmodell zeichnet sich durch eine hohe räumliche Auflösung aus. Abbildung 3.2 zeigt die Topologie Energienetzmodells für Deutschland (a) sowie einen Ausschnitt des Netzes in Schleswig-Holstein (b). Mithilfe zweier Szenarien werden verschiedene Stadien des Netzes abgebildet. So orientiert sich die Abbildung des Kraftwerksparks im *eGon2035*-Szenario an den Prognosen der Übertragungsnetzbetreiber für das Jahr 2035 (Nahmacher, P., Anderski, T., Apfelbeck, J., Ganer, P. et. al. (2021)), während im *eGon100RE*-Szenario ein vollständig durch erneuerbare Erzeugung gespeistes Energiesystem abgebildet ist. Die zeitliche Auflösung definiert sich durch die Betrachtung eines Jahres in stündlicher Auflösung, sodass sich 8760 betrachtete Zeitschritte ergeben.

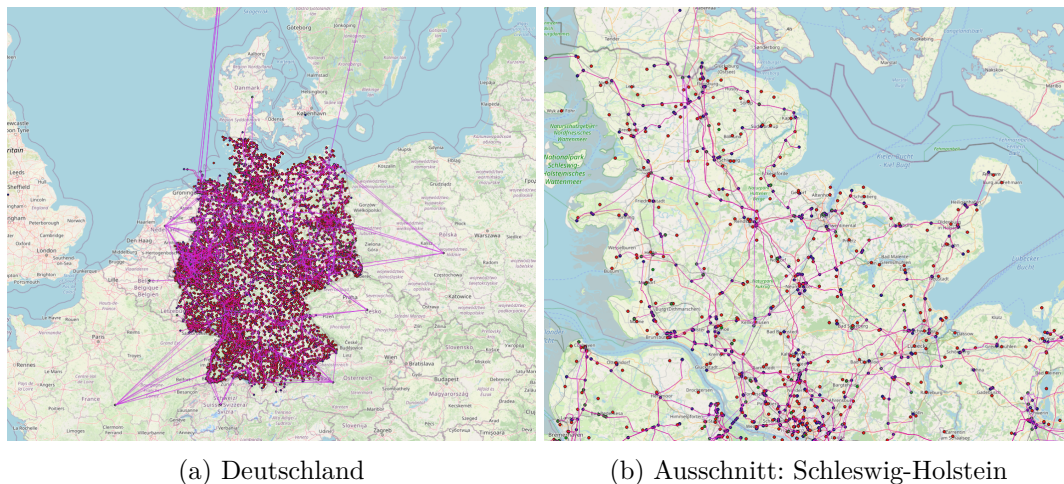


Abbildung 3.2: Darstellung des Modells des sektorgekoppelten Energiesystems der Hoch- und Höchstspannungsebene in Deutschland (*eGon2035*-Szenario)

Das Modellierungskonzept des sektorgekoppelten Energiesystems ist als Reduktion des Datenmodells auf die vorhandenen Komponenten in Abbildung 3.3 dargestellt. Die verschiedenen Sektoren (elektrischer Sektor, Mobilitätssektor, Gassektor und Wärmesektor) sind durch verschiedene Farben gekennzeichnet. Tabelle 3.1 zeigt eine Übersicht über die Implementierung der Modellkomponenten als *PyPSA*-Komponenten, gibt Informationen zu den zu optimierenden Parametern der Komponenten und stellt zeitabhängige Parameter der Komponenten dar.

In hellblauer Farbe sind drei elektrische Knoten („AC“) abgebildet, die durch Leitungen verbunden sind. Da Freileitungs-Monitoring implementiert ist, weisen die Leitungen zeitabhängige Kapazitäten auf. Der elektrische Sektor enthält weiterhin Generatoren, Lasten und Speicher. Generatoren umfassen je nach betrachtetem Szenario konventionelle Einspeiser wie Gaskraftwerke sowie erneuerbare Einspeiser wie Windkraft- und PV-Anlagen. Außerdem ist

⁵<https://openenergy-platform.org/>

⁶<https://pypsa.readthedocs.io/>

Demand Side Management (DSM) als elektrische Flexibilität implementiert. Die zeitlich verschiebbaren Lastanteile sind als Speicher mit zeitabhängigen Lade- und Entladeleistungen sowie zeitabhängigen Kapazitäten modelliert.

In dunkelblau markiert ist die Modellierung des Mobilitätssektors zu sehen („EV“-Knoten). Dieser beinhaltet Lasten, die das Laden von elektrisch betriebenen Fahrzeugen darstellen, sowie Speicher, die zeitabhängige elektrische Flexibilitäten abbilden. Es ist zu beachten, dass die Version des im Rahmen dieser Arbeit verwendeten Tools *eTraGo* sowie das zugrundeliegende Datenmodell keinen Mobilitätssektor enthalten, da die Modellierung dieses Sektors zum Zeitpunkt der Erstellung der Arbeit noch nicht abgeschlossen ist.

Die Komponenten des Gassektors sind grün dargestellt. Es sind Methanknoten („CH₄“) und Wasserstoffknoten („H₂“) zu unterscheiden. Sowohl an CH₄- als auch an H₂-Knoten liegen Lasten an. Einspeiser sind lediglich an CH₄-Knoten zu finden, während die Erzeugung von Wasserstoff über Energieumwandlung realisiert ist. In der Abbildung sind zwei H₂-Knoten zu sehen, die jeweils über Brennstoffzellen und Elektrolyseure mit dem elektrischen Sektor gekoppelt sind. Der untere Knoten stellt einen Knoten an einer Salzkaverne dar, einem natürlichen Speicherort für Wasserstoff, der als Speicher modelliert ist. Der obere H₂-Knoten ist über eine begrenzte direkte Einspeisung, über Methanisierung und über Dampfreformierung mit dem CH₄-Netz gekoppelt. Die CH₄-Knoten sind durch eine Gasleitung verbunden, die Speicherkapazität des Gasnetzes ist mithilfe eines weiteren Speichers modelliert. Das Gasnetz ist über Gasturbinen an das elektrische Netz und über Gasverbrennung an das Wärmenetz angeschlossen. Außerdem ist Kraft-Wärme-Kopplung implementiert, die eine weitere Kopplung von Gassektor zur elektrischem Sektor und Wärmesektor darstellt.

In rot und gelb sind die Komponenten des Wärmesektors zu sehen. Hier wird zwischen zentraler Wärmeversorgung („DH“), beispielsweise Fernwärmenetze in Städten, und dezentraler Wärmeversorgung („IH“) in ländlichen Gebieten unterschieden. In beiden Fällen liegen Wärmebedarfe an und es sind jeweils Wärmespeicher implementiert. Geo- und solarthermische Anlagen dienen zur Einspeisung. Sowohl die zentralen als auch die dezentralen Wärmeknoten sind über Gasverbrennung und Kraft-Wärme-Kopplung mit dem Gassektor und über Wärmepumpen mit dem elektrischen Sektor gekoppelt.

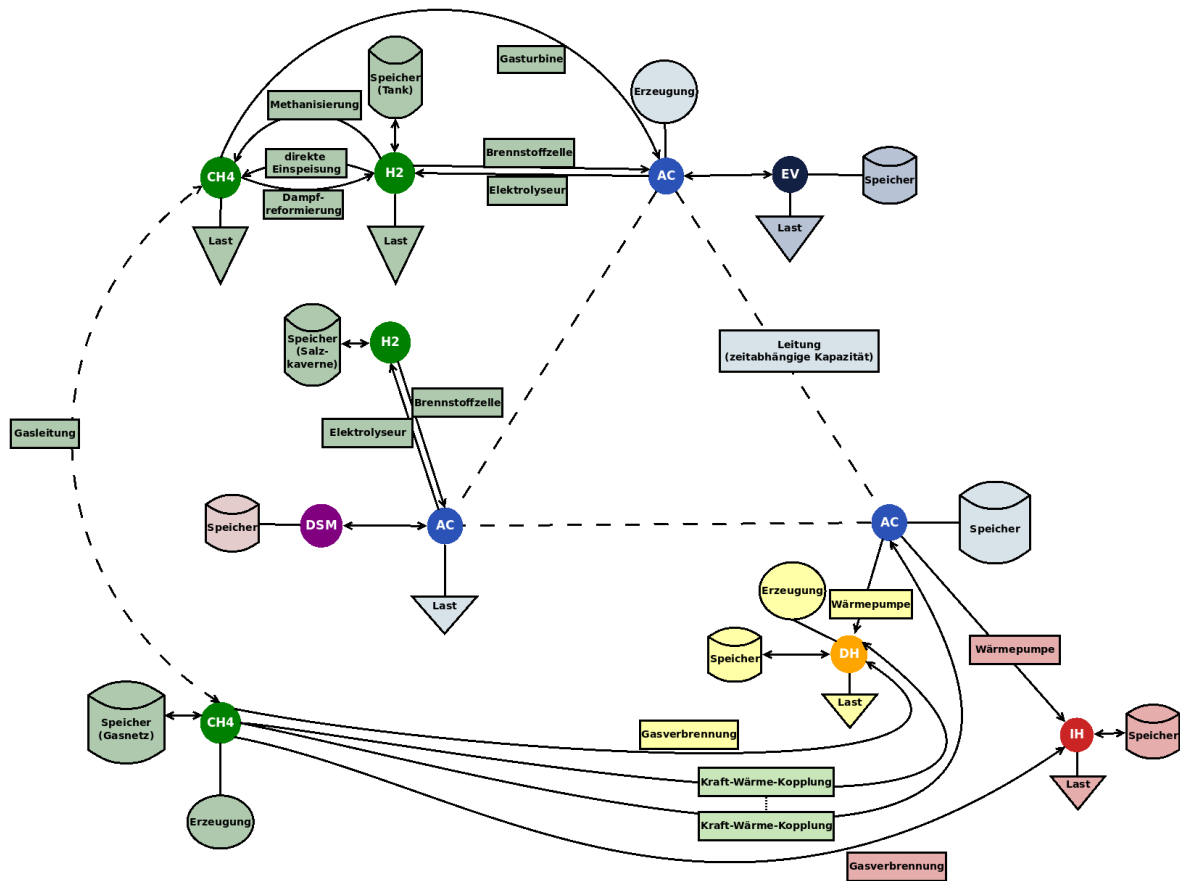


Abbildung 3.3: Darstellung des Modellierungskonzepts in *eTraGo*

Tabelle 3.1: Modellkomponenten in eTraGo mit optimierten und zeitabhängigen Parametern

Modellkomponente (PyPSA-Komponente)	optimierte Parameter	zeitabhängige Parameter
elektrischer Sektor		
Knoten (<i>Bus</i>)	-	-
Leitung (<i>Line</i>)	Einsatz, Ausbau	max. Kapazität
Last (<i>Load</i>)	-	Leistung
Einspeiser (<i>Generator</i>)	Einsatz	max. Einspeiseleistung von Windkraft- und PV-Anlagen
Speicher (<i>Storage Unit</i>)	Einsatz, Ausbau	-
DSM-Komponenten (<i>Bus, Link, Store</i>)	Einsatz	Lade- und Entladeleistung sowie Kapazität Speichers
Mobilitätssektor*		
* in der in dieser Arbeit verwendeten Version (noch) nicht enthalten		
Knoten (<i>Bus</i>)	-	-
Last (<i>Load</i>)	-	Leistung
elektrische Flexibilität (<i>Bus, Link, Store</i>)	Einsatz	Lade- und Entladeleistung sowie Kapazität Speichers
Gassektor		
H ₂ - / CH ₄ -Knoten (<i>Bus</i>)	-	-
CH ₄ -Leitung (<i>Link</i>)	Einsatz	-
CH ₄ -Einspeiser (<i>Generator</i>)	Einsatz	-
H ₂ - / CH ₄ -Last (<i>Load</i>)	-	Leistung
H ₂ - / CH ₄ -Speicher (<i>Bus, Links, Store</i>)	Einsatz, Ausbau	-
H ₂ ↔ CH ₄ (<i>Links</i>): Einspeisung H ₂ ins CH ₄ -Netz	Einsatz	-
Methanisierung	Einsatz, Ausbau	-
Dampfreformierung	Einsatz, Ausbau	-
Wärmesektor		
Knoten (<i>Bus</i>)	-	-
Einspeiser (<i>Generator</i>)	Einsatz	max. Einspeiseleistung geo-/ solarthermischer Anlagen
Last (<i>Load</i>)	-	Leistung
Speicher (<i>Bus, Links, Store</i>)	Einsatz, Ausbau	-
sektorkoppelnde Technologien		
Elektrolyseur (<i>Link</i>)	Einsatz, Ausbau	-
Brennstoffzelle (<i>Link</i>)	Einsatz, Ausbau	-
Gasturbine (<i>Link</i>)	Einsatz	-
Wärmepumpe (<i>Link</i>)	Einsatz	Wirkungsgrad
Gasverbrennung	Einsatz	-
Kraft-Wärme-Kopplung (<i>Links</i>)	Einsatz	-

Komplexitätsreduktion und weitere Annahmen

Nach Import des Datenmodells und Erstellung des *PyPSA*-Netzes, wird das erzeugte Netz je nach vorgenommenen Einstellungen unter Treffen verschiedener Annahmen angepasst. Eine Beschreibung der Einstellungsmöglichkeiten ist der Dokumentation⁷ zu entnehmen.

Insbesondere ist in diesem Zuge die Reduktion der Komplexität zu nennen. Die räumliche und zeitliche Auflösung des Modells haben eine hohe Komplexität des Optimierungsproblems zur Folge, das in den meisten Fällen mit den zur Verfügung stehenden Ressourcen nicht gelöst werden kann. Deshalb werden Methoden angewandt, die die Komplexität reduzieren. Dabei wird zuerst die räumliche und anschließend die zeitliche Komplexität reduziert.

Die räumliche Auflösung kann im Rahmen eines *k-means Clusterings* oder eines *k-medoids Dijkstra Clusterings* reduziert werden. Beim *k-means Clustering* werden die Originalknoten des Netzes unter Berücksichtigung ihrer geografischen Position zu Clustern zusammengefasst und durch repräsentative Knoten ersetzt. Das *k-medoids Dijkstra Clustering* berücksichtigt bei der Bildung der Cluster die Topologie des Netzes. Eine ausführliche Beschreibung der Methoden und deren Implementierung sowie ein Vergleich der Anwendbarkeit ist in der dazu angefertigten studentischen Arbeit (Esterl (2021)) nachzulesen.

Die Reduktion der zeitlichen Auflösung beinhaltet die Aggregation der Zeitreihen der Modellkomponenten (vgl. Tabelle 3.1). Zur Reduktion der zeitlichen Komplexität stehen aktuell drei verschiedene Methoden zur Auswahl:

- **Skip Snapshots:** Reduktion der Zeitreihen auf jeden n-ten Zeitschritt
- **Snapshot Clustering - Typical Periods:** Reduktion der Zeitreihen auf eine bestimmte Anzahl typischer Perioden (z.B. Tage)
- **Snapshot Clustering - Segmentation:** Reduktion der Zeitreihen auf eine bestimmte Anzahl von Segmenten aufeinanderfolgender Zeitschritte mit unterschiedlicher Länge

Die verschiedenen Methoden sowie deren Implementierungen werden ausführlich in Kapitel 3.3 beschrieben und deren Anwendbarkeit soll im Rahmen dieser Arbeit untersucht und verglichen werden.

Optimierungsverfahren

Zur technisch-ökonomischen Optimierung wird der Linear Optimal Power Flow (LOPF) des Python-Tools *PyPSA*⁸ verwendet. Ziel ist die Minimierung der jährlichen Gesamtsystemkosten, die sich aus den Grenzkosten der Energieerzeugung sowie des Energietransports und den Investitionskosten in den Ausbau der auszubauenden Netzkomponenten zusammensetzen (Brown, Hörsch und Schlachtberger (2018)). Technische Zusammenhänge wie die Kirchhoff'sche Knotenregel sind durch Nebenbedingungen formuliert (Brown et al. (2018)). Tabelle 3.1 weist aus, welche Modellkomponenten optimiert werden und ob diese hinsichtlich der Einsatzplanung oder hinsichtlich des Einsatzes und des Ausbaus optimiert werden. Es ergibt sich die in Ausdruck 3.1 formulierte Zielfunktion (Müller, Schachler, Bunke et al. (2019)).

⁷<https://etrigo.readthedocs.io/en/latest/>

⁸<https://pypsa.readthedocs.io/>

$$\begin{aligned}
& \min_{\substack{F_\ell, H_{n,s} \\ g_{n,r,t}, h_{n,s,t}}} \left[\sum_{\ell} c_\ell \cdot F_\ell + \sum_{n,r,t} (w_t \cdot o_{n,r} \cdot g_{n,r,t}) \right. \\
& \left. + \sum_{n,s} c_{n,s} \cdot H_{n,s} + \sum_{n,s,t} w_t \cdot o_{n,s} \cdot [h_{n,s,t}]^+ \right] \tag{3.1}
\end{aligned}$$

ℓ : Index Leitung/Transformator	$o_{n,r}$: Grenzkosten des Erzeugers n, r
n : Index Netzknoten	$g_{n,r,t}$: Einspeisung des Erzeugers n, r, t
r : Index Erzeuger	$c_{n,s}$: Kapitalkosten des Speichers n, s
t : Index Zeitschritt	$H_{n,s}$: Nennleistung des Speichers n, s
s : Index Speicher	$o_{n,s}$: Grenzkosten des Speichers n, s
c_ℓ : Kapitalkosten Leitung/Transformator	$h_{n,s,t}$: Einsatz von Speicher n, s, t
F_ℓ : Nennleistung Leitung/Transformator	
w_t : Gewichtung des Zeitschritts	

Da der LOPF keine Anpassung der Widerstandsbeläge an die ausgebauten Kapazitäten der Leitungen und Transformatoren beinhaltet, sind mehrere Iterationen mit anschließender Anpassung der Parameter bis zur Konvergenz mit dem Netzausbau notwendig. Die Widerstandsbeläge werden in *eTraGo* nach jeder Iteration nach Gleichung 3.2 an die ausgebaute Kapazität angepasst (Büttner (2020)). Als Konvergenzkriterium kann ein Grenzwert der Änderung der Zielfunktion zwischen zwei Iterationen oder eine definierte Anzahl an Iterationen vorgegeben werden. Im letzteren Fall besteht die Gefahr einer Lösung mit nicht vollständig konvergiertem Netzausbau, jedoch ist die Rechenzeit besser abzuschätzen. Im Laufe der Entwicklung von *eTraGo* sind einige Optimierungen durchgeführt worden. Die Festlegung von vier Iterationen hat sich dabei als geeignet herausgestellt, da in weiteren Iterationen nur noch geringfügige Änderungen des Zielfunktionswerts auftreten und somit Konvergenz erreicht ist.

$$\frac{x_{l,opt}}{x_l} = \frac{s_{nom}}{s_{nom,opt}} \tag{3.2}$$

Gleichung 3.1 stellt eine lineare Näherung des Optimierungsproblems dar. Diese Näherung ist aufgrund der in der Hoch- und Höchstspannungsebene vorliegenden Bedingungen zulässig (Müller, Schachler, Bunke et al. (2019)). Zur Berücksichtigung der Blindleistung kann auf die lineare Optimierung eine nicht-lineare Lastflussberechnung folgen. Diese Option ist in *eTraGo* manuell einzustellen, soll für die vorliegende Arbeit jedoch keine Rolle spielen.

Auswertung und/oder Disaggregation

Nach der Netzberechnung stehen die Ergebnisse zur Auswertung bereit. Dazu beinhaltet *eTraGo* eine Vielzahl von Methoden. Alternativ können die Methoden räumlich disaggregiert und wie in 3.1.1 zur Optimierung des Nieder- und Mittelspannungsnetzes verwendet werden.

3.2 Anforderungen an Methoden der Reduktion der zeitlichen Komplexität

Das Ziel der Reduktion der zeitlichen Komplexität ist es, die zeitlichen Inputdaten eines Optimierungsproblems so zu reduzieren, dass alle relevanten Informationen der Daten grundsätzlich erhalten bleiben, um eine genügende Genauigkeit der Ergebnisse der Optimierung bei gleichzeitig akzeptabler Rechenzeit zu gewährleisten.

Aktuelle Modelle sektorgekoppelter Energiesystemen zeichnen sich durch einen hohen Anteil erneuerbarer Energien in der Erzeugung sowie durch die Integration verschiedener Energiesektoren aus. So ist es auch für das im Rahmen dieser Arbeit betrachtete Modell der Fall. Dieses enthält Lastzeitreihen der verschiedenen Sektoren, also z. B. elektrische Lasten, elektrische Lasten aus dem Mobilitätssektor, Wärmelasten und Gaslasten, sowie Zeitreihen der maximalen Einspeiseleistung von wetterabhängigen erneuerbaren Energieerzeugern wie Windkraftanlagen, PV-Anlagen und geo- und solarthermischen Anlagen (siehe auch Tabelle 3.1).

Schon die Betrachtung des rein elektrischen Systems beinhaltet die Berücksichtigung von Attributzeitreihen mit unterschiedlichen Charakteristiken. Die konventionellen elektrischen Lastzeitreihen, die sich aus den elektrischen Verbräuchen in Haushalten, in Gewerbe, Handel und Dienstleistungen und in der Industrie zusammensetzen, weisen tendenziell repetitive Muster innerhalb von Tagen auf. Ähnlich verhält es sich mit Zeitreihen der maximalen Einspeiseleistung von PV-Anlagen, die abhängig ist vom Tagesverlauf der Sonnenstrahlung. Die Zeitreihen der maximalen Einspeiseleistung von Windkraftanlagen hingegen zeigen diese Muster nicht, der Verlauf ist vergleichsweise unregelmäßig und weist tendenziell saisonale Schwankungen auf. Wie in Kapitel 2 beschrieben, erfordern Einspeisezeitreihen von Windkraftanlagen besonderer Vorsicht, da wichtige Variabilitäten bei der Aggregation tendenziell verloren gehen.

Wenn die Zeitreihen reduziert werden sollen, ohne deren relevanten Charakteristiken zu verlieren oder zu verändern, stellt die Verschiedenheit dieser, sowie insbesondere die Varianz der für die einzelnen Zeitreihen kritischen Zeithorizonte, eine Herausforderung dar. Diese Schwierigkeit verschärft sich durch die Integration der weiteren Sektoren, da zusätzliche Attributzeitreihen mit individuellen Charakteristiken berücksichtigt werden müssen. So weisen die Attributzeitreihen im Gas- und Wärmesektor wiederum tendenziell saisonale Muster auf, während die Lastprofile, die durch die Berücksichtigung der Nutzung von elektrischen Fahrzeugen hinzukommen, repetitive Muster innerhalb von Tagen zeigen.

Wenn der Fokus bei der Aggregation der Zeitreihen beispielsweise auf den Mustern im Tagesverlauf liegt und die saisonalen Muster vernachlässigt werden, werden der Ausbau und die Nutzung von Komponenten, deren Attributzeitreihen diese saisonalen Muster aufweisen, im Optimierungsergebnis mit hoher Wahrscheinlichkeit ebenfalls vernachlässigt. Daher gilt es zu überprüfen, wie die verschiedenen Methoden die Charakteristiken der Attributzeitreihen abbilden, mit welcher Genauigkeit das Optimierungsproblem nach Reduktion der Zeitreihen gelöst werden kann und wie sich das Ergebnis zusammensetzt, also ob die verschiedenen

Sektoren sowie Einspeiser in den Verhältnissen abgebildet werden, wie es im originalen Optimierungsproblem der Fall ist.

Je nach Betrachtungsraum und räumlicher Auflösung unterscheiden sich die Attributzeitreihen weiterhin an verschiedenen Knoten im Netz beispielsweise in Abhängigkeit der geografischen oder demografischen Bedingungen. Damit nimmt die Varianz der zu berücksichtigenden Profile und die Schwierigkeit der adequaten Reduktion zu. Weiterhin besteht eine Abhängigkeit zwischen der Reduktion der räumlichen und zeitlichen Komplexität (vgl. Kapitel 2). Diese Sensitivität der Reduktion der zeitlichen Komplexität auf die räumliche Komplexität gilt es bei der Wahl einer geeigneten Methode zu berücksichtigen.

Aktuelle Energiesystemmodelle sind weiterhin durch die Integration verschiedener Speicher- und Flexibilitätsoptionen charakterisiert. Durch die Kopplung des Stromsektors mit den Sektoren Gas, Wärme und Mobilität erhöht sich die Speicherkapazität des Energiesystems maßgeblich. Die Fähigkeit der Abbildung von Speicherverhalten stellt deshalb eine relevante Anforderung an Methoden zur Reduktion der zeitlichen Komplexität dar. Weil in sektorgekoppelten Energiesystemen sowohl Kurz- als auch Langzeitspeicher eine wichtige Rolle spielen, ist zu beachten, dass kurzzeitiges sowie saisonales Speicherverhalten abbildbar sein sollte. In Kapitel 2 ist dargestellt, dass sich analog zu der Schwierigkeit der Berücksichtigung der kritischen Zeithorizonte der Attributzeitreihen ebenso die Berücksichtigung der verschiedenen Horizonte, innerhalb derer verschiedene Speicher operieren, als schwierig gestaltet. Die Abbildung des Speicherverhaltens gilt es deshalb besonders im Auge zu behalten.

Grundsätzlich besteht bei der Aggregation von Zeitreihen die Gefahr, dass Spitzen aus den originalen Zeitreihenprofilen ausgeglättet werden (vgl. Kapitel 2), weil extreme Zeitschritte einer Gruppierung nicht als repräsentativ festgelegt werden. Das bedeutet, dass Zeitpunkte mit extremen Anforderungen an das System missachtet werden. Damit besteht die Gefahr der Unterschätzung des Ergebnisses, was im Hinblick auf die Sicherstellung der Versorgung und der Vorhersage von Systemkosten unerwünscht ist.

Wie in Kapitel 2 beschrieben, werden aggregierte Zeitreihen deshalb in einigen Arbeiten um extreme Zeitpunkte ergänzt, um einer Unterschätzung der Systemanforderungen vorzubeugen. Mit zunehmender Komplexität der Energiesystemmodelle jedoch erhöht sich die Schwierigkeit der Identifikation derjenigen Zeitschritte, die diese besonderen Anforderungen an das System stellen (vgl. Kapitel 2). Dies gilt insbesondere in sektorgekoppelten Modellen mit vielen verschiedenen Lastzeitreihen und potentiellen Erzeugungszeitreihen sowie in Modellen mit Speichern und vielen Flexibilitätsoptionen, die potentiell kritische Zeitpunkte ausgleichen. Deshalb gilt es, die Notwendigkeit des Hinzufügens von Extremzeitschritten oder Extremperioden sowie die Kriterien zur Identifikation dieser Extremzeitschritte bzw. -perioden zu überprüfen.

Für das im Rahmen dieser Arbeit betrachtete Tool *eTraGo* (vgl. Kapitel 3.1) zu dem Modell des sektorgekoppelten Energienetzes auf Hoch- und Höchstspannungsebene in Deutschland ergeben sich durch die Schnittstelle zum Tool *eDisGo*, mithilfe dessen die Nieder- und Mittelspannungsebene berechnet werden kann, weitere Anforderungen. Relevante Optimierungsergebnisse des Tools *eTraGo*, wie beispielsweise die Zeitreihen der Erzeugerleistungen, werden zur netzebenenübergreifenden Optimierung an das Tool *eDisGo* weitergegeben (vgl.

Kapitel 3.1.1). Es gilt, hochaufgelöste Zeitreihen weiterzugeben, um eine möglichst genaue Berechnung der Nieder- und Mittelspannungsebene zu ermöglichen. Falls eine Reduktion der zeitlichen Komplexität des Optimierungsproblems in *eDisGo* notwendig ist, sollten speziell geeignete Methoden ausgewählt und angewandt werden, da die Charakteristiken der verschiedenen Attributzeitreihen in der Hoch- und Höchstspannungsebene nicht zwingend den Charakteristiken der Attributzeitreihen in der Nieder- und Mittelspannungsebene entsprechen. Dies sollte gegebenenfalls speziell für *eDisGo* untersucht werden.

Tabelle 3.2 stellt eine Zusammenfassung der identifizierten Herausforderungen bei der Reduktion der zeitlichen Komplexität in sektorgekoppelten Energiesystemmodellen dar.

Tabelle 3.2: Zusammenfassung der Ziele und Herausforderungen bei der Reduktion der zeitlichen Komplexität in sektorgekoppelten Energiesystemmodellen

Ziele

1. Reduktion der Komplexität des Optimierungsproblems → Reduktion der Rechenzeit
 2. Erhalt der relevanten Informationen → Erhalt einer genügenden Genauigkeit
-

Herausforderungen

- Verschiedenheit der unterschiedlichen Attributzeitreihen
 - insbesondere Varianz der kritischen Zeithorizonte der verschiedenen Attributzeitreihen
 - adäquate Berücksichtigung der Einspeisezeitreihen von Windkraftanlagen
 - Abhängigkeit zur räumlichen Komplexität
 - Notwendigkeit der Fähigkeit zur korrekten Abbildung von Speicherverhalten (Kurzzeit- sowie Langzeitspeicherung)
 - Varianz der Horizonte, innerhalb derer verschiedene Speicher operieren
 - tendenzielle Gefahr der Unterschätzung der Systemanforderungen
 - bei Hinzufügen von Extremzeitpunkten: Identifikation der kritischen Zeitpunkte
 - speziell für *eTraGo*: Berücksichtigung der Schnittstelle zu *eDisGo*
-

3.3 Auswahl zu untersuchender Methoden und Varianten

Wie in Kapitel 3.1.2 erklärt, stehen in *eTraGo* aktuell drei verschiedene Methoden zur Auswahl, um die zeitliche Komplexität zu reduzieren. Diese drei Methoden lassen sich wie folgt in die in Kapitel 2 erklärten nach Hoffmann et al. (2020) identifizierten Kategorien der häufig verwendeten Methoden einordnen.

Tabelle 3.3 zeigt, dass mit den implementierten Methoden drei der vier nach Hoffmann et al. (2020) identifizierten Kategorien zur Auswahl stehen. Die Methode, die in *eTraGo* unter dem Namen *Skip Snapshots* implementiert ist, entspricht nach Hoffmann et al. (2020) einer Methode in Form des *Downsamplings*. Diese Methode wurde in den im Rahmen der Forschungsprojekte erarbeiteten Untersuchungen bisher häufig angewendet (Müller, Schachler,

Scharf et al. (2019), Büttner (2020)). Weiterhin sind insbesondere die beiden Kategorien der eigenschaftsbasierten Methoden, die für zukünftige Untersuchungen als besonders relevant eingestuft werden, durch die Methoden, die unter *Snapshot Clustering - Segmentation* und *Snapshot Clustering - Typical Periods* zu finden sind, abgedeckt. Aus diesem Grund soll im Rahmen dieser Arbeit die Anwendbarkeit dieser drei Methoden in verschiedenen Varianten untersucht werden.

Tabelle 3.3: Einordnung der in *eTraGo* implementierten Methoden in die Kategorien der häufig verwendeten Methoden zur Reduktion der zeitlichen Komplexität nach Hoffmann et al. (2020)

	Variation der Auflösung	Ermittlung typischer Perioden
zeitbasiert	Skip Snapshots	-
eigenschaftsbasiert	Snapshot Clustering - Segmentation	Snapshot Clustering - Typical Periods

Im Folgenden werden die Methoden sowie mögliche Varianten detailliert erklärt und deren Implementierung dargestellt. Unter Bezugnahme auf die in Kapitel 3.2 formulierten Anforderungen wird die Auswahl der im Rahmen dieser Arbeit untersuchten Varianten begründet.

Um die Anforderungen zu erfüllen, die im Hinblick auf die Schnittstelle von *eTraGo* zu *eDisGo* gestellt werden, soll im Rahmen dieser Arbeit eine 2-Level-Optimierung durchgeführt werden. Dieser *2-Level-Ansatz* sowie dessen Vorteile hinsichtlich der Schnittstelle und der Verwendung innerhalb von *eTraGo* selbst werden im letzten Abschnitt dieses Kapitels erläutert.

Im Anhang A.1.1 findet sich eine Übersicht über die für die vorliegenden Arbeiten relevanten Implementierungen sowie Verweise zu *GitHub*, unter denen die jeweiligen Codes zu finden sind.

3.3.1 Downsampling

Beim *Downsampling* werden Gruppen aufeinanderfolgender Zeitschritte durch einen Zeitschritt repräsentiert, der basierend auf seiner Position innerhalb der Zeitreihe als repräsentativ für die Zeitschritte seiner Gruppe ausgewählt wird (vgl. Kapitel 2). So werden beispielsweise im Fall von *eTraGo* die vollkomplexen Zeitreihen, die ein Jahr in stündlicher Auflösung umschreiben, auf jede n -te Stunde reduziert. Die als repräsentativ ausgewählten Stunden werden entsprechend der Anzahl der unberücksichtigten Stunden ihrer Gruppe n -fach gewichtet, um das Optimierungsergebnis auf das gesamte Jahr hochzuskalieren. Die Anzahl der zu berücksichtigenden Stunden kann ausgewählt werden und definiert die zeitliche Komplexität des Optimierungsproblems.

Das *Downsampling* ist in *eTraGo* unter dem Namen *Skip Snapshots* zu finden. Die Auswahl der zu berücksichtigenden Stunden ist in den Einstellungen im ausführenden Skript `app1.py` zu treffen. Implementiert ist diese Methode innerhalb der Methode `skip_snapshots()` im Skript `cluster/snapshot.py`, indem die *snapshots* des *PyPSA*-Netzes entsprechend der Angaben reduziert und gewichtet werden.

3.3.2 Clustering auf typische Perioden

Das *Clustering auf typische Perioden* beinhaltet eigenschaftsbasiertes Clustering zur Ermittlung typischer Perioden, auf die die originalen Zeitreihen reduziert werden (vgl. Kapitel 2). Im Fall von *eTraGo* können die originalen Zeitreihen stündlicher Auflösung über ein Jahr beispielsweise auf 120 typische Tage reduziert werden. Dazu werden alle 365 Tage der originalen Zeitreihe in Cluster ähnlicher Tage eingeteilt und ein repräsentativer Tag pro Cluster als typischer Tag ermittelt. Die Länge der betrachteten Perioden sowie die Anzahl der typischen Perioden sind dabei wählbar.

Im Folgenden werden die Arbeitsschritte der Methode beschrieben sowie Variationsmöglichkeiten aufgezeigt. Tabelle 3.4 fasst die Erläuterungen zusammen.

1. Auswahl der Zeitreihen und deren Gewichtung

Zunächst gilt es, diejenigen Attributzeitreihen des Systems auszuwählen, anhand deren Eigenschaften die Cluster gebildet werden sollen. Im klassischen Fall werden alle im System vorhandenen Attributzeitreihen berücksichtigt, alternativ können bestimmte Attributzeitreihen ausgewählt werden. Weiterhin können die verschiedenen Attributzeitreihen unterschiedlich gewichtet werden, sodass die Eigenschaften einzelner Attributzeitreihen während der Beurteilung der Ähnlichkeiten stärkeren Einfluss nehmen als die Eigenschaften anderer Zeitreihen. Es ist zu beachten, dass es sich hierbei um die Auswahl und Gewichtung der Inputzeitreihen für das Clusterverfahren handelt. Nach Ermittlung der Cluster und Festlegung der repräsentativen Perioden entfällt die Auswahl sowie Gewichtung und es werden alle im System vorhandenen Attributzeitreihen entsprechend der identifizierten typischen Perioden reduziert.

In der vorliegenden Arbeit sollen alle im System vorhandenen Erzeugungs- und Lastzeitreihen zur Bildung der Cluster berücksichtigt werden. Unter Erzeugungszeitreihen sind die Zeitreihen der potentiellen Erzeugung erneuerbarer Einspeiser zu verstehen. Wie in Tabelle 3.1 nachzulesen ist, beinhaltet *eTraGo* weiterhin Zeitreihen zur Beschreibung der Flexibilitätsbänder von DSM und innerhalb des Mobilitätssektors. Diese Zeitreihen ergeben sich aus den Lastzeitreihen der entsprechenden Sektoren, weshalb sie zur Bildung der Cluster nicht extra herangezogen werden sollen. Weiterhin soll keine unterschiedliche Gewichtung der verschiedenen Zeitreihen vorgenommen werden, sodass alle Erzeugungs- und Lastzeitreihen gleichermaßen einbezogen werden.

2. Normierung

Die ausgewählten Zeitreihen sind für den Prozess des Clusterings vorzubereiten. Darunter fällt die Normierung der Daten, die sicherstellt, dass die Zeitreihen zur Einteilung der Cluster unabhängig von deren Größenordnungen und Einheiten gleichermaßen bzw. gemäß der im ersten Schritt vorgegebenen Gewichtung berücksichtigt werden. In den meisten Arbeiten wird eine *min-max Normierung* angewandt, in manchen Veröffentlichungen ist die *z-Normierung* zu finden (Hoffmann et al. (2020)).

In der vorliegenden Arbeit wird die üblicherweise verwendete *min-max Normierung* genutzt, die durch Gleichung 3.3 beschrieben wird. Für die Zeitreihe des Attributs $a \in \mathbb{A}$ bestehend aus den Zeitschritten $s \in \mathbb{S}$ ergibt sich der normierte Wert x zum Attribut a im Zeitschritt s durch die folgende Gleichung.

$$x_{a,s} = \frac{x'_{a,s} - \min(x'_a)}{\max(x'_a) - \min(x'_a)} \quad (3.3)$$

a :	Index des Attributs
\mathbb{A} :	Set der Attribute
s :	Index des Zeitschritts
\mathbb{S} :	Set der Zeitschritte
$x_{a,s}$:	normierter Wert eines Attributs in einem Zeitschritt
$x'_{a,s}$:	originaler Wert eines Attributs in einem Zeitschritt
x'_a :	originale Werte eines Attributs

3. Rearrangement

Als nächstes sind die betrachteten Zeitabschnitte einzuführen. Das bedeutet, dass die originale Zeitreihe, bestehend aus einem Set \mathbb{S} mit einer Anzahl an Zeitschritten N_s , in ein Set aus Zeitabschnitten \mathbb{P} eingeteilt wird, wobei die einzelnen Zeitabschnitte sich wiederum jeweils aus einem Set \mathbb{T} einer bestimmten Anzahl N_t aus Zeitschritten zusammensetzen: $\mathbb{S} = \mathbb{P} \times \mathbb{T}$.

Die Länge der betrachteten Zeitabschnitte ist wählbar. Um die Periodizität von Zeitreihen auszunutzen, werden Zeitreihen mit stündlicher Auflösung häufig in Zeitabschnitte von 24 Stunden, also in Tage, oder Zeitabschnitte mit 168 Stunden, also in Wochen, überführt. Wie in Kapitel 2 beschrieben, können in Systemen mit hohen Speicherkapazitäten weiterhin die Zeithorizonte, innerhalb derer die Speicher operieren, ebenfalls als Kriterium zur Wahl der Länge der betrachteten Zeitabschnitte herangezogen werden. Deshalb soll in dieser Arbeit die Reduktion auf typische Tage, auf typische Woche sowie auf typische Monate verglichen werden.

4. Clustering

Nach der Einführung der betrachteten Zeitabschnitte kommt es zur Einteilung der Cluster sowie zur Ermittlung der typischen Perioden. Dazu ist zunächst eine Anzahl an gewünschten typischen Perioden und damit die Anzahl der Cluster festzulegen.

Wie bereits in Kapitel 2 beschrieben, steht eine Vielzahl von Clusterverfahren zur Verfügung, die mit verschiedenen Distanzmetriken kombiniert werden können. Weiterhin bestehen verschiedene Optionen zur Festlegung der repräsentativen Perioden pro Cluster (vgl. Kapitel 2). Im Rahmen dieser Arbeit soll in Übereinstimmung mit einer Vielzahl weiterer aktueller Arbeiten ein *median-basiertes hierarchisches Clusterverfahren mit Ward's Kriterium* verwendet werden. Das Clusterverfahren wird in der vorliegenden Arbeit nicht variiert, da sich das ausgewählte Verfahren in vielen Arbeiten als geeignet erwiesen hat und der Clusteralgorithmus selbst nur einen kleinen Einfluss auf die Eignung der Methode zur Reduktion der zeitlichen Komplexität nimmt, solange keine durchschnittlichen Perioden als repräsentative Perioden angenommen werden (Kotzur et al. (2018a)).




Abbildung 3.4: Prinzipielle Funktionsweise des hierarchischen Clusterings mit *Bottom-Up-Verfahren* (= *agglomeratives Clusterverfahren*)
Abbildung in Anlehnung an Raventós (2018)

Abbildung 3.4 zeigt die prinzipielle Funktionsweise dieses Clusterverfahrens. Es handelt sich hierbei um ein *agglomeratives Clusterverfahren*, das zunächst jedes einzelne Objekt, in diesem Fall jede einzelne Periode als eigenes Cluster initialisiert und die Cluster dann in einem *Bottom-Up-Verfahren* schrittweise nach Ähnlichkeit vereinigt. Die folgenden Schritte werden dabei durchlaufen.

1. Initialisierung jedes einzelnen Objekts als Cluster
2. Ermittlung des Mittelwerts eines jeden Clusters
3. Vereinigung von Clustern nach *Ward's Kriterium*
4. Überprüfung der Anzahl der vorhandenen Cluster
 - a) Wiederholung ab Schritt 2, falls die Anzahl der gewünschten Cluster nicht erreicht ist
 - b) ansonsten Beendigung

Das Kriterium zur Vereinigung von Clustern ist durch das *Ward's Kriterium* gegeben, das die durch die Vereinigung von Clustern bedingte Zunahme der aufsummierten Varianzen innerhalb aller Cluster minimiert. So ergeben sich Cluster mit Objekten, die eine hohe Ähnlichkeit aufweisen. Die Zunahme der Varianz bei Vereinigung der Cluster i und j ergibt sich durch die quadrierte euklidische Distanz zwischen den Clusterzentren definiert, wie es in Gleichung 3.4 formuliert ist.

$$D_{Ward}(i, j) = d_E^2(\{\mathbf{v}_i\}, \{\mathbf{v}_j\}) = \|\mathbf{v}_i - \mathbf{v}_j\|^2 \quad (3.4)$$

$D_{Ward}(i, j)$:	Zunahme der Varianz durch Vereinigung zweier Cluster
i, j :	Indizes zweier Cluster
$d_E(\{\mathbf{v}_i\}, \{\mathbf{v}_j\})$:	euklidische Distanz zwischen zwei Vektoren
$\{\mathbf{v}_i\}, \{\mathbf{v}_j\}$:	Vektoren der Clusterzentren

Das Ergebnis dieses Schrittes sind die ermittelten typischen Perioden, auf die die Zeitreihe reduziert wird, sowie deren Gewichtung zur Skalierung auf den gesamten betrachteten Zeithorizont, die sich aus der Anzahl der zu repräsentierenden Perioden im entsprechenden Cluster ergibt.

5. optional: Hinzufügen von Extremperioden

Wie in Kapitel 2 beschrieben, besteht optional die Möglichkeit, die aggregierten Zeitreihen durch Perioden mit Extremzeitpunkten zu ergänzen, um die Berücksichtigung von für das System kritischen Zeitpunkten sicherzustellen. Die folgenden Schritte beschreiben das Vorgehen zur Berücksichtigung von Extremzeitpunkten.

1. Identifikation von Extremzeitpunkten in den originalen Attributzeitreihen, zum Beispiel
 - Zeitpunkte maximaler aufsummierter Last im System
 - Zeitpunkte maximaler aufsummierter Erzeugung im System
 - Extrempunkte der Residuallast des Systems
2. Aggregation der Zeitreihen mithilfe ausgewählter Methode
3. Hinzufügen von Extremzeitschritten
 - **Anfügen:** Einfügen des Extremzeitschritts als zusätzlichen Zeitschritt in die aggregierten Zeitreihen
 - **Zusätzliches Cluster Center:** Hinzufügen des Extremzeitschrittes als zusätzlichen repräsentativen Zeitschritt einer neuen Gruppierung; basierend auf der Ähnlichkeit werden weitere Zeitschritte der neuen Gruppierung zugeordnet
 - **Ersetzen der repräsentativen Periode:** Hinzufügen des Extremzeitschritts als repräsentativen Zeitschritt derjenigen Gruppierung, der der Zeitschritt zugeordnet ist

In der vorliegenden Arbeit soll die Reduktion der Zeitreihen mit und ohne Hinzufügen von Extremperioden durchgeführt und verglichen werden. So soll ermittelt werden, ob ein Hinzufügen von Extremzeitpunkten notwendig ist, um den Netz- und Speicherausbau genügend genau zu berechnen. Bei Berücksichtigung von Extremzeitpunkten sollen diese durch Extrema in der Residuallast des Systems identifiziert werden. Es werden also Zeitpunkte als kritisch angenommen, zu denen besonders viel potentielle Erzeugung durch erneuerbare Einspeiser einer geringen Last oder eine besonders hohe Gesamtlast wenig Erzeugung durch erneuerbare Einspeiser gegenübersteht. Während dieser Zeitpunkte wird das Energienetz vor besondere Anforderungen gestellt, sodass diese Zeitpunkte bei Berechnung des Netz- und Speicherausbaus besonderen Einfluss nehmen könnten. Die Extremperioden sollen in einer Variation einfach an die aggregierten Zeitreihen angefügt und in einer weiteren Variation als Ersatz der repräsentativen Periode ihres jeweiligen Clusters berücksichtigt werden.

6. Um- bzw. Rückskalierung

Je nach Festlegung der typischen Perioden pro Cluster bedarf es einer Umskalierung dieser typischen Perioden zur Sicherstellung der Wahrung bestimmter relevanter Eigenschaften der originalen Attributzeitreihen, zum Beispiel der Mittelwerte der einzelnen Attribute über den gesamten Zeithorizont. Je nach Anwendungsfall bestehen verschiedene Optionen, die insbesondere dann interessant sind, wenn typische Perioden als durchschnittliche und damit künstliche erzeugte Perioden pro Cluster definiert sind (Hoffmann et al. (2020)). Eine

Auswahl verschiedener Varianten sowie deren Vor- und Nachteile sind in der Arbeit von Hoffmann et al. (2020) nachzulesen. In der vorliegenden Arbeit werden die Medoide der Cluster als typische Perioden angenommen und keine Umskalierung vorgenommen.

In jedem Fall bedarf es der Rückskalierung der aggregierten Zeitreihen auf deren originale Werte. Dieser Schritt entspricht der Umkehrung der Normierung, die mit Gleichung 3.3 definiert ist. Die Rückskalierung des normierten Werts c einer typischen Periode k des Attributs a im Zeitschritt t erfolgt durch den in Gleichung 3.5 definierten Zusammenhang.

$$c'_{a,k,t} = c_{a,k,t}(\max(x'_a) - \min(x'_a)) + \min(x'_a) \quad (3.5)$$

- a : Index des Attributs
- \mathbb{A} : Set der Attribute
- k : Index des Clusters
- \mathbb{C}_k : Set der Cluster
- t : Index des Zeitschritts innerhalb einer Periode
- \mathbb{T} : Set der Zeitschritte innerhalb einer Periode
- c' : rüskalierter Wert einer typischen Periode
- c : normierter Wert einer typischen Periode
- x'_a : originale Werte eines Attributs

7. Implementierung von Nebenbedingungen

Zuletzt bedarf das *Clustering auf typische Perioden* der Implementierung zusätzlicher Nebenbedingungen, da die Konsektutivität der originalen Zeitreihe nicht bestehen bleibt und intertemporale Abhängigkeiten wie Speicherverhalten andernfalls nicht korrekt abbildbar sind (vgl. Kapitel 2). Dazu stehen verschiedene Optionen zur Verfügung. Im Rahmen dieser Arbeit soll die von Kotzur et al. (2018b) vorgestellte Methode Anwendung finden, weil dieses Verfahren die korrekte Abbildung von Speicherverhalten innerhalb sowie über den Zeithorizont der betrachteten Perioden hinaus, also zum Beispiel saisonales Speicherverhalten, ermöglicht. Das Verfahren beinhaltet die Verknüpfung der typischen Perioden in einer zweiten Zeitschicht. Dazu wird zwischen einem intra-periodischen und einem inter-periodischen Speicherfüllstand unterschieden. Der intra-periodische Speicherfüllstand SOC^{intra} beschreibt den zeitabhängigen Verlauf des Füllstandes innerhalb der verschiedenen typischen Perioden. Der SOC^{intra} eines Speichers st der typischen Periode k im Zeitschritt $t + 1$ ergibt sich durch den in Gleichung 3.6 beschriebenen Zusammenhang. Weiterhin wird festgelegt, dass der SOC^{intra} in der ersten Stunde einer jeden typischen Periode Null sein soll. Der inter-periodische Speicherfüllstand SOC^{inter} beschreibt den Speicherfüllstand für jeden einzelnen Zeitabschnitt des betrachteten Zeithorizonts. Die Berechnung des SOC^{inter} eines Speichers st eines Zeitabschnitts $z + 1$ erfolgt anhand des in Gleichung 3.7 beschriebenen Zusammenhangs. Zur Erhaltung der energetischen Jahresbilanz sollen der SOC^{inter} am Ende und am Anfang des betrachteten Zeithorizonts gleich sein. Durch Superposition der Speicherfüllstände der beiden verschiedenen Zeitschichten wird nun der Speicherfüllstand der Speicher berechnet. Gleichung 3.8 definieren die durch die Speicherkapazität gegebene Begrenzung des Speicherfüllstands. Abbildung 3.5 visualisiert die beschriebene Methode.

$$\begin{aligned}
 SOC_{st,k,t+1}^{intra} &= SOC_{st,k,t}^{intra} (1 - \eta_{st}^{self} \Delta t) + \Delta t [\eta_s^{char} \dot{E}_{st,k,t}^{char} - \frac{\dot{E}_{st,k,t}^{dis}}{\eta_{st}^{dis}}] \quad \forall \quad t, k \\
 SOC_{st,k,1}^{intra} &= 0 \quad \forall \quad k
 \end{aligned} \tag{3.6}$$

$$\begin{aligned}
 SOC_{st,z+1}^{inter} &= SOC_{st,z}^{inter} (1 - \eta_{st}^{self} \Delta t)^{N_t} + SOC_{st,k=f(z),N_t+1}^{intra} \quad \forall \quad z \\
 SOC_{st,N_z+1}^{inter} &= SOC_{st,1}^{inter} \quad \forall \quad z
 \end{aligned} \tag{3.7}$$

$$0 \leq SOC_{st,z}^{inter} (1 - \eta_{st}^{self} \Delta t)^{N_t} + SOC_{st,k=f(z)}^{intra} \leq D_{st} \quad \forall \quad t, z \tag{3.8}$$

SOC^{intra} :	intra-periodischer Speicherfüllstand
SOC^{inter} :	inter-periodischer Speicherfüllstand
st :	Index des Speichers
k :	Index des Clusters
t :	Index des Zeitschritts innerhalb einer Periode
N_t :	Anzahl der Zeitschritte innerhalb einer Periode
Δt :	Länge eines Zeitschritts
z :	Index der Periode
N_z :	Anzahl der Perioden
η^{self} :	Selbstentladungsrate
η^{char} :	Ladewirkungsgrad
η^{dis} :	Entladewirkungsgrad
\dot{E} :	Energiefluss zum Laden bzw. Entladen

Im Anhang seiner Arbeit stellen Kotzur et al. (2018b) einen Ansatz zur Vereinfachung der beschriebenen Nebenbedingungen dar. Dieser beinhaltet eine Erhöhung der Anzahl der Variablen und einer Verringerung der Anzahl der Gleichungen, sodass die Komplexität des Gleichungssystems insgesamt reduziert wird. Insbesondere unter der Annahme kleiner Selbstentladungsraten ergeben sich durch die Verwendung dieses vereinfachten Ansatzes keine Abweichungen im Ergebnis. Deshalb soll dieser Ansatz im Rahmen dieser Arbeit ebenfalls verwendet und verglichen werden.

$$\begin{aligned}
 SOC_{st,k,t}^{intra} &\leq SOC_{st,k,max}^{intra} \quad \forall \quad t, k \\
 SOC_{st,k,t}^{intra} &\geq SOC_{st,k,min}^{intra} \quad \forall \quad t, k
 \end{aligned} \tag{3.9}$$

$$\begin{aligned}
 SOC_{st,z}^{inter} + SOC_{st,k=f(z),max}^{intra} &\leq D_{st} \quad \forall \quad z \\
 SOC_{st,z}^{inter} (1 - \eta_{st}^{self} \Delta t)^{N_t} + SOC_{st,k=f(z),min}^{intra} &\geq 0 \quad \forall \quad z
 \end{aligned} \tag{3.10}$$

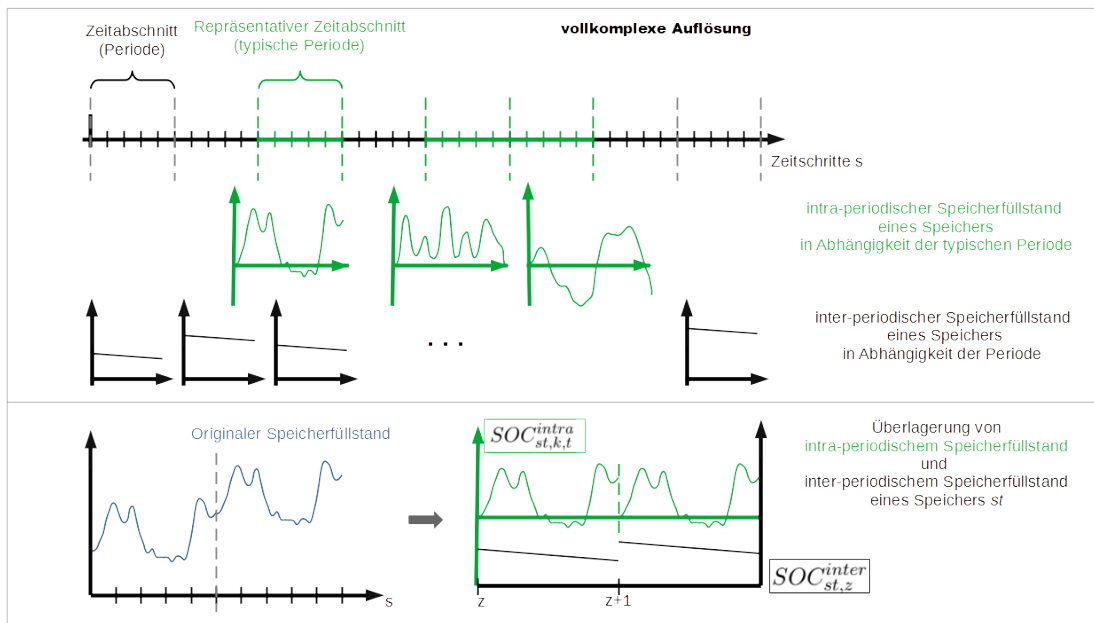


Abbildung 3.5: Prinzipielle Funktionsweise der Verknüpfung von typischen Perioden nach Kotzur et al. (2018b)

Abbildung in Teilen in Anlehnung an Kotzur et al. (2018b)

Das *Clustering auf typische Perioden* ist in *eTraGo* als **Snapshot Clustering** mit der Option `typical_periods` implementiert. Die Einstellungen zur Durchführung der Reduktion mithilfe dieser Methode erfolgt im ausführenden Skript `appl.py`. Hier können die Länge der betrachteten Perioden, die Anzahl der typischen Perioden sowie das optionale Hinzufügen von Extrempersistenzen festgelegt werden. Implementiert ist die Methode im Skript `cluster/snapshot.py`, wo sie im Rahmen der Methode `run()` ausgeführt wird. Die Auswahl der Attributzeitreihen, die zur Bildung der Cluster berücksichtigt werden, erfolgt in der Methode `prepare_pypsa_timeseries()`. Die Durchführung der Normierung und des Rearrangements, die Ermittlung der typischen Perioden, das optionale Hinzufügen von Extrempersistenzen sowie die Um- bzw. Rückskalierung erfolgt mithilfe des Python-Tools *tsam*⁹ in der Methode `tsam_cluster`. Die Implementierung der Nebenbedingungen zur Ermöglichung der Abbildung von Speicherverhalten ist in `tool/constraints.py` unter `snapshot_clustering_seasonal_storage()` zu finden.

⁹<https://tsam.readthedocs.io/en/latest/>

Tabelle 3.4: *Clustering auf typische Perioden*: Arbeitsschritte, abgeleitete Variationsmöglichkeiten und im Rahmen dieser Arbeit betrachtete Variationen

Arbeitsschritt	mögliche Variationen	in dieser Arbeit betrachtete Variationen
1. Auswahl der Zeitreihen und deren Gewichtung Auswahl der Attributzeitreihen, die zur Bildung der Cluster berücksichtigt werden; Festlegung der Gewichtung der Zeitreihen	Auswahl der Zeitreihen; Gewichtung	alle Erzeugungs- und Lastzeitreihen; ohne Gewichtung
2. Normierung Normierung der ausgewählten Zeitreihen	Art der Normierung	<i>min-max Normierung</i>
3. Rearrangement Einführung der betrachteten Zeitabschnitte	Länge der Zeitabschnitte	24 Zeitschritte (Tage), 168 Zeitschritte (Wochen)
4. Clustering Anzahl der Cluster bzw. typ. Perioden; Einteilung der Cluster; Ermittlung der repräsentativen Perioden	Anzahl der Cluster; Wahl von Clusterverfahren und Distanzmetrik, Vorgehen bei Festlegung der repräsentativen Periode	typ. Tage: [5..365], typ. Wochen: [4..52]; typ. Monate: [1..12] <i>median-basiertes hierarchisches Clusterverfahren mit Ward's Kriterium</i>
5. optional: Hinzufügen von Extremprioden Identifikation besonders kritischer Zeitpunkte; Hinzufügen der identifizierten Extremprioden in aggregierte Zeitreihe	Vorgehen bei Identifikation und bei Hinzufügen zu aggregierter Zeitreihe	Identifikation durch Extrema der Residuallast; ohne Hinzufügen sowie mit Hinzufügen durch Anfügen und durch Ersatz der repräsentativen Perioden
6. Um- und Rückskalierung optional: Umskalierung Rückskalierung (Umkehrung der Normierung)	optionale Umskalierung	nur Rückskalierung
7. Implementierung von Nebenbedingungen Implementierung von Nebenbedingungen zur Ermöglichung der Abbildung von intertemporalen Abhängigkeiten wie Speicherverhalten	Vorgehen zur Verknüpfung der Perioden durch Nebenbedingungen	Verknüpfung typischer Perioden nach Kotzur et al. (2018b) (normaler und vereinfachter Ansatz)

3.3.3 Segmentation

Bei Anwendung von *Segmentation* werden aufeinanderfolgende Zeitschritte nach Ähnlichkeit in Cluster eingeteilt und die originale Zeitreihe auf repräsentative Zeitschritte pro Cluster reduziert (vgl. Kapitel 2). Im Fall von *eTraGo* wird die vollkomplexe Zeitreihe in stündlicher Auflösung über ein Jahr auf eine vorgegebene Anzahl an Segmenten bestehend aus aufeinanderfolgenden Stunden reduziert.

Die Vorgehensweise zur Durchführung der Aggregation mithilfe *Segmentation* ist ähnlich zur Vorgehensweise bei Verwendung des *Clustering auf typische Tage*, dessen Arbeitsschritte umfassend in Kapitel 3.3.2 erläutert sind. Auf eine detaillierte Beschreibung der einzelnen Schritte wird in diesem Kapitel verzichtet, stattdessen wird die Vorgehensweise im Folgenden unter Bezugnahme auf die Erklärungen im vorherigen Kapitel kurz erklärt sowie mögliche Variationen der *Segmentation*-Methode abgeleitet und für die im Rahmen dieser Arbeit durchgeführten Untersuchungen ausgewählt. Tabelle 3.5 gibt eine Zusammenfassung.

Genau wie in Kapitel 3.3.2 beschrieben gilt es auch bei Verwendung der *Segmentation* zunächst diejenigen Attributzeitreihen auszuwählen und zu gewichten, die zur Bildung der Cluster herangezogen werden sollen. Wie auch in der zuvor beschriebenen Methode sollen alle Erzeugungs- und Lastzeitreihen ausgewählt und ungewichtet berücksichtigt werden (vgl. Kapitel 3.3.2). Im zweiten Schritt werden die Attributzeitreihen normiert. Dazu wird eine *min-max-Normierung* nach Gleichung 3.3 angewandt. Der Schritt des *Rearrangements* entfällt bei der *Segmentation*-Methode, wenn, wie in dieser Arbeit, aufeinanderfolgende Zeitschritte geclustert werden sollen.

Als nächstes steht die Bildung der Cluster an. Die Festlegung der Anzahl der Cluster bzw. der Segmente gibt die zeitliche Auflösung vor. Wie in Kapitel 3.3.2 beschrieben stehen verschiedene Clusterverfahren zur Verfügung, die mit unterschiedlichen Distanzmetriken kombiniert werden können. Im Rahmen dieser Arbeit soll ein *median-basiertes hierarchisches Clusterverfahren mit Ward's Kriterium* verwendet werden. Dieses ist detailliert in Kapitel 3.3.2 beschrieben. Zu beachten ist, dass bei der *Segmentation*-Methode nur aufeinanderfolgende Zeitschritte in dieselben Cluster zugeordnet werden können.

Das Hinzufügen von Extremzeitschritten kann optional in gleicher Weise wie in Kapitel 3.3.2 beschrieben durchgeführt werden. In der vorliegenden Arbeit soll die Anwendung der *Segmentation*-Methode ohne Hinzufügen und mit Hinzufügen von Extremzeitschritten verglichen werden. Die Extremzeitschritte sollen in einer Variation einfach an die aggregierten Zeitreihen angefügt und in einer weiteren Variation als Ersatz der repräsentativen Periode ihres Clusters berücksichtigt werden. Die Identifikation der kritischen Zeitpunkte erfolgt anhand von Extrema in der Residuallast des Systems (vgl. Kapitel 3.3.2).

Zuletzt können die aggregierten Zeitreihen umskaliert werden. Dieser optionale Schritt findet in der vorliegenden Arbeit keine Anwendung. Die Rückskalierung ist ein notwendiger Arbeitsschritt, der durch Verwendung des in Gleichung 3.5 beschriebenen Zusammenhangs umgesetzt wird.

Unter Verwendung von *Segmentation* bleibt die Konsekutivität der originalen Zeitreihe erhalten, deshalb ist die Implementierung zusätzlicher Nebenbedingungen nicht notwendig.

Diese Methode ist in *eTraGo* als *Snapshot Clustering* mit der Option `segmentation` implementiert. Im ausführenden Skript `appl.py` werden die Anzahl der Segmente sowie das optionale Hinzufügen von Extremperioden ausgewählt werden. Implementiert ist die Methode im Skript `cluster/snapshot.py`, wo sie im Rahmen der Methode `run()` ausgeführt wird. Die Auswahl der Attributzeitreihen, die zur Bildung der Cluster berücksichtigt werden, erfolgt in der Methode `prepare_pypsa_timeseries()`. Die Durchführung der Normierung, die

Ermittlung der typischen Perioden sowie die Um- bzw. Rückskalierung erfolgt mithilfe des Python-Tools *tsam*¹⁰ in der Methode `tsam_cluster`. Das optionale Hinzufügen von Extremschritten ist ebenfalls innerhalb der Methode `tsam_cluster`, jedoch unabhängig von dem Python-Tool *tsam* extra implementiert.

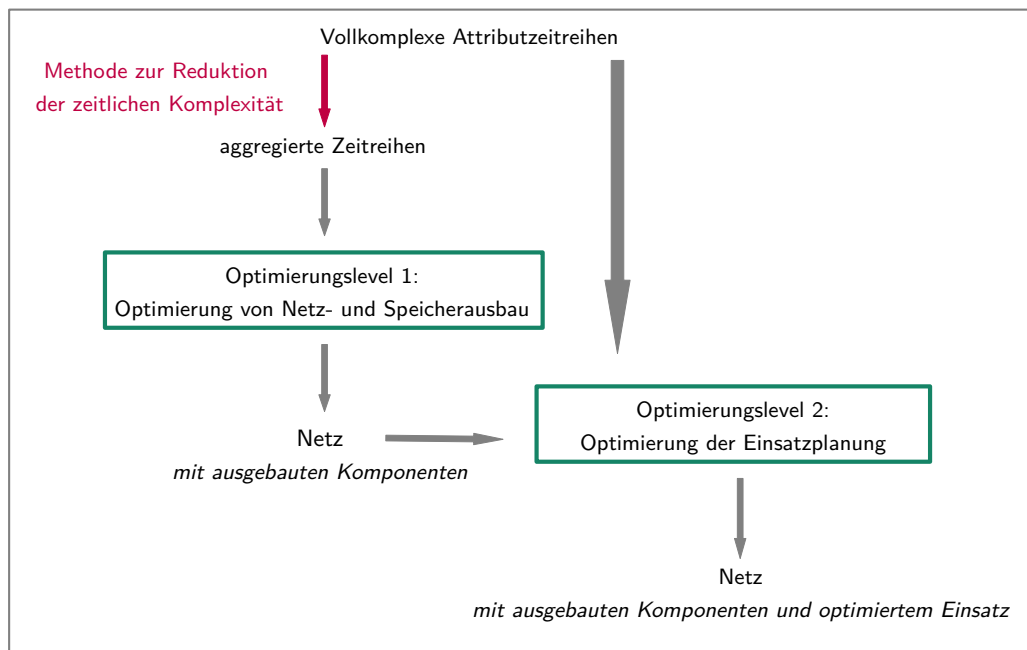
Tabelle 3.5: *Clustering auf typische Perioden*: Arbeitsschritte, abgeleitete Variationsmöglichkeiten und im Rahmen dieser Arbeit betrachtete Variationen

Arbeitsschritt	mögliche Variationen	in dieser Arbeit betrachtete Variationen
1. Auswahl der Zeitreihen und deren Gewichtung Auswahl der Attributzeitreihen, die zur Bildung der Cluster berücksichtigt werden; Festlegung der Gewichtung der Zeitreihen	Auswahl der Zeitreihen; Gewichtung	alle Erzeugungs- und Lastzeitreihen; ohne Gewichtung
2. Normierung Normierung der ausgewählten Zeitreihen	Art der Normierung	<i>min-max Normierung</i>
3. Clustering Anzahl der Cluster bzw. typ. Perioden; Einteilung der Cluster; Ermittlung der repräsentativen Perioden	Anzahl der Cluster; Wahl von Clusterverfahren und Distanzmetrik, Vorgehen bei Festlegung der repräsentativen Periode	Segmente: [1000..8760]; <i>median-basiertes hierarchisches Clusterverfahren mit Ward's Kriterium</i>
4. optional: Hinzufügen von Extremperioden Identifikation besonders kritischer Zeitpunkte; Hinzufügen der identifizierten Extremperioden in aggregierte Zeitreihe	Vorgehen bei Identifikation und bei Hinzufügen zu aggregierter Zeitreihe	Identifikation durch Extrema der Residuallast; ohne Hinzufügen sowie mit Hinzufügen durch Anfügen und durch Ersatz der repräsentativen Perioden
5. Um- und Rückskalierung optional: Umskalierung Rückskalierung (Umkehrung der Normierung)	optionale Umskalierung	nur Rückskalierung

3.4 2-Level-Ansatz

Wie in Kapitel 3.2 beschrieben, bestehen in *eTraGo* zusätzlich zu den sonstigen Anforderungen aufgrund der Schnittstelle zu *eDisGo* weiterhin spezielle Anforderungen. Zur Erfüllung dieser speziellen Anforderungen sollen die in den vorherigen Abschnitten beschriebenen Methoden in einer 2-Level Optimierung verwendet werden. Abgeleitet ist diese Idee aus den in Kapitel 2 beschriebenen Arbeiten mit mehrstufigen Verfahren (z. B. Kannengießer et al. (2019)), wobei es sich bei dem hier verwendeten um einen vereinfachten Ansatz handelt. Abbildung 3.6 visualisiert die Vorgehensweise des *2-Level-Ansatzes*.

¹⁰<https://tsam.readthedocs.io/en/latest/>

Abbildung 3.6: Prinzipielle Funktionsweise des verwendeten *2-Level-Ansatzes*

Das erste Optimierungslevel ist links dargestellt. Die vollkomplexen Attributzeitreihen des Energiesystemmodells werden zunächst mithilfe einer der beschriebenen Methoden (Kapitel 3.3.1, 3.3.2 und 3.3.3) in ihrer zeitlichen Komplexität reduziert. Anschließend wird das System mit den enthaltenen aggregierten Zeitreihen optimiert. Wie in Kapitel 3.1.2 wird ein LOPF des Python-Tools *PyPSA* verwendet. Es werden der Einsatz der entsprechenden Komponenten sowie Netz- und Speicherausbau, wie in Tabelle 3.1 dargestellt, optimiert. Das Ergebnis dieses Levels soll das optimal ausgebaute System darstellen, der optimierte Einsatz der Komponenten wird nicht weiter verwendet.

Rechts ist das zweite Optimierungslevel zu sehen. Die zweite Optimierung soll eine Einsatzoptimierung im ausgebauten System darstellen. Dazu sollen die originalen Attributzeitreihen, also die vollkomplexen Zeitreihen verwendet werden. Es wird also das nach der ersten Optimierung ausgebaute System verwendet und mit den vollkomplexen Zeitreihen hinsichtlich des Einsatzes der Komponenten optimiert, sodass die Einsatzzeitreihen am Ende in voller Komplexität vorliegen. Auch zur zweiten Optimierung wird ein LOPF des Python-Tools *PyPSA* verwendet.

Wie in Kapitel 2 beschrieben, ergibt sich die Komplexität einer Optimierung nicht nur durch die räumlichen und zeitlichen Inputdaten, sondern auch durch die techno-ökonomische Dimension. Diese umfasst unter anderem den Umstand, welche Komponenten in welchem Umfang optimiert werden. Grundsätzlich weist die Optimierung des Einsatzes von Komponenten eine deutlich geringere Komplexität auf als die Optimierung des Ausbaus. Deshalb beinhaltet der *2-Level-Ansatz* die Optimierung von Netz- und Speicherausbau mit den zeitlich reduzierten Zeitreihen. Um vollkomplexe Zeitreihen an *eDisGo* weitergeben zu können, soll anschließend eine Einsatzoptimierung mithilfe der vollkomplexen Zeitreihen durchgeführt werden. So nimmt die Reduktion der zeitlichen Komplexität in *eTraGo* keinen direkten Einfluss auf die Inputdaten der Optimierung in *eDisGo*.

Implementiert ist der *2-Level-Ansatz* direkt im ausführenden Skript `app1.py`. Die ausführende Methode `run_etrigo` ruft, wie in Kapitel 3.1.2 beschrieben, nacheinander die das *PyPSA*-Netz erstellenden und zur Optimierung vorbereitenden Funktionalitäten auf. Nach der Reduktion der räumlichen und vor Reduktion der zeitlichen Komplexität werden im Zuge des *2-Level-Ansatzes* zunächst alle relevanten Attributzeitreihen in voller Komplexität zwischengespeichert, bevor die Methode zur zeitlichen Komplexitätsreduktion angewandt und Netz- und Speicherausbau mithilfe der aggregierten Zeitreihen optimiert werden. Anschließend werden die aggregierten Attributzeitreihen des Systems durch die originalen Zeitreihen und die Komponenten durch die ausgebauten Komponenten ersetzt. Die Ausbauvariablen werden negiert, sodass das ausgebaute Netz mithilfe der vollkomplexen Zeitreihen hinsichtlich des Einsatzes der Komponenten optimiert wird.

3.5 Durchführung von Rechnungen zur Untersuchung der Methoden

Die Methoden und Varianten werden zunächst anhand eines Minimalbeispiels untersucht. Dadurch kann ein besserer Überblick über die verschiedenen Attributzeitreihen, die Aggregation der Zeitreihen und die aggregierten Zeitreihen behalten werden, sodass die potentiellen Auswirkungen auf die Ergebnisse besser nachvollziehbar sind. Weiterhin ist die Berechnung eines zeitlich vollkomplexen Referenzfalls ohne Reduktion der räumlichen Komplexität möglich.

Nach Untersuchung der Methoden anhand des Minimalbeispiels sollen diejenigen Methoden, die sich als am vielversprechendsten herausstellen, in *eTraGo* für die Optimierung des räumlich hochaufgelösten, sektorgekoppelten Energiesystems der Hoch- und Höchstspannungsebene angewandt werden. Während der Anfertigung dieser Arbeit ist die Entwicklung von *eTraGo* sowie des dazugehörigen Datenmodells noch nicht abgeschlossen. Auf eine ausführliche Auswertung der Ergebnisse wird deshalb verzichtet. Ziel der Rechnungen in *eTraGo* ist es, grundsätzlich nachzuweisen, dass die ausgewählten Methoden sowie der in Kapitel 3.4 beschriebene *2-Level-Ansatz* zur Reduktion der zeitlichen Komplexität des betrachteten Datenmodells in *eTraGo* angewendet werden können.

Mit dem Ziel der Untersuchung der in 3.3 beschriebenen Methoden und deren Varianten im Minimalbeispiel sowie der Überprüfung der Anwendbarkeit in *eTraGo* ergibt sich eine Vielzahl an durchzuführenden Berechnungen. Im Folgenden soll zunächst ein Überblick über die durchgeführten Rechnungen gegeben werden. Anschließend werden das verwendete Minimalbeispiel und die Bedingungen der Berechnung in *eTraGo* dargestellt. Es werden die in den Rechnungen vorgenommenen Einstellungen, die Auswahl des Solvers sowie Informationen der verwendeten Hardware dokumentiert.

3.5.1 Übersicht über durchgeführte Rechnungen

Tabelle 3.6 gibt eine Übersicht über die im Rahmen der Arbeit durchgeführten Rechnungen. In der linken Spalte sind die in Kapitel 3.3 beschriebenen Methoden aufgelistet. Die mittlere Spalte zeigt auf, welche Variationen anhand des Minimalbeispiels untersucht werden. Ergänzend dazu dienen für die Methoden *Clustering auf typische Perioden* und *Segmentation* die Tabellen 3.4 und 3.5. Insbesondere ist in der vorliegenden Tabelle die Variation der zeitlichen Auflösung festgehalten. In allen Fällen soll ein breites Auflösungsspektrum abgedeckt sein, um bestenfalls eine minimal notwendige zeitliche Komplexität ableiten und die Fehlerkonvergenz betrachten zu können. Die Ergebnisse dieser Rechnungen und die Bewertung der Methoden sind in Kapitel 4 nachzulesen.

Die Untersuchung eines Minimalbeispiels ermöglicht die Berechnung eines zeitlich vollkomplexen Referenzfalls. Auch für die Rechnungen in *eTraGo* wird ein solcher Fall berechnet. Dazu ist die räumliche Komplexität stark zu reduzieren.

Für die Optimierung des räumlich hochaufgelösten, sektorgekoppelten Energiesystems der Hoch- und Höchstspannungsebene in *eTraGo* wird die Anwendung derjenigen Methoden, die sich aus den Untersuchungen anhand des Minimalbeispiels als am vielversprechendsten herausstellen, überprüft. Damit ergeben sich die in der rechten Spalte festgehaltenen Variationen. Die Auswahl dieser Methoden sowie die Festlegung der zeitlichen Auflösung werden in Kapitel 4.2.2 begründet, die Ergebnisse der Rechnungen mit *eTraGo* finden sich in Kapitel 5.

Zur Ermöglichung des *Clusterings auf typische Monate* und *Clusterings auf typische Wochen* wird der original betrachtete Zeithorizont eines Jahres mit 8760 Zeitschritten auf 8736 bzw. 8640 Zeitschritte gekürzt. Das ist notwendig, um eine ganze Zahl an Perioden innerhalb des Zeithorizonts erreichen zu können. Es wurden Referenzrechnungen in zeitlich vollkomplexer Auflösung mit den entsprechenden Zeithorizonten durchgeführt. Die sich dadurch ergebenden Abweichungen betragen in der ersten Optimierungsstufe zwischen 1 % und 3 %. Für die Berechnungen der Genauigkeit der ersten Optimierungsstufe sowie der aggregierten Zeitreihen (vgl. Kapitel 3.6) werden die Ergebnisse auf die speziell ermittelten Referenzwerte bezogen. Da nur die Netzkonfiguration der ersten Optimierungsstufe übernommen wird und die Optimierung der Einsatzplanung anhand der zeitlich vollkomplexen Auflösung durchgeführt wird, ergeben sich unter der Verwendung des *2-Level-Ansatzes* noch kleinere Fehler. Diese Abweichungen werden deshalb vernachlässigt. Zur Überprüfung der Anwendbarkeit der Methoden wird diese Vorgehensweise als geeignet angenommen.

Tabelle 3.6: Übersicht über durchgeführte Rechnungen

Methode	Minimalbeispiel	räumlich hochaufgelöstes Modell in <i>eTraGo</i>
Referenzfall: zeitlich vollkomplex	✓	✓Reduktion der räumlichen Komplexität auf 50 elektrische Knoten und 30 Gasknoten
Downsampling	Auflösung: jeden n-ten Zeitschritt mit n = [1, 2, 3, 5, 10, 20, 30, 50, 100, 150]	Auflösung: jeden n-ten Zeitschritt mit n = [3, 5, 10]
Clustering auf typische Perioden		
Typische Tage	Auflösung: [365, 350, 300, 250, 200, 150, 120, 100, 60, 40, 20, 10, 5] typ. Tage Extremperioden: - ohne Extremperioden - Anfügen - Ersatz repräsentativer Periode Verknüpfung der Perioden: nach Kotzur et al. (2018b) (klassisch und vereinfachter Ansatz)	-
Typische Wochen	Auflösung: [52, 48, 44, 40, 36, 32, 28, 24, 20, 16, 12, 8, 4] typ. Wochen Extremperioden: - ohne Extremperioden - Anfügen - Ersatz repräsentativer Periode Verknüpfung der Perioden: nach Kotzur et al. (2018b)	-
Typische Monate	Auflösung: [12, 11, 10, 9, 8, 7, 6, 5, 4, 3, 2, 1] typ. Monate Extremperioden: - ohne Extremperioden - Anfügen - Ersatz repräsentativer Periode Verknüpfung der Perioden: nach Kotzur et al. (2018b)	-
Segmentation	Auflösung: [8760, 8000, 7000, 6000, 5000, 4000, 3000, 2000, 1000, 500, 200, 100] Segmente Extremzeitschritte: - ohne Extremperioden - Anfügen - Ersatz repräsentativer Periode	Auflösung: [2900, 1750, 880] Segmente ohne explizite Berücksichtigung von Extremzeitschritten

3.5.2 Verwendetes Minimalbeispiel

Um durch die Untersuchung der Methoden anhand des Minimalbeispiels Rückschlüsse auf deren Anwendbarkeit in *eTraGo* ziehen zu können, sind das Modellierungskonzept des Minimalbeispiels sowie die enthaltenen Zeitreihen analog zu *eTraGo* auszuwählen. Dementsprechend beinhaltet das Minimalbeispiel die in Tabelle 3.1 aufgelisteten Komponenten, die nach der in Kapitel 3.3 beschriebenen Weise miteinander verknüpft sind. Der Mobilitätssektor ist ausgespart, da die Modellierung dieses Sektors zum Zeitpunkt der Erstellung dieser Arbeit noch nicht abgeschlossen ist. Deshalb ist dieser Sektor weder im Minimalbeispiel noch in der verwendeten Version des Tools *eTraGo* und des zugrundeliegenden Datenmodells enthalten. Das Minimalbeispiel enthält ansonsten alle in *eTraGo* vorhandenen Arten von Erzeugungs- und Lastzeitreihen, um sicherzustellen, dass die verschiedenen Charakteristiken der unterschiedlichen Attributzeitreihen vorhanden sind. Es handelt sich bei den verwendeten Attributzeitreihen um originale Zeitreihen des *eTraGo* zugrundeliegenden Datenmodells. Die Dimensionierung und weitere Parametrisierung der Modellkomponenten (z. B. Wirkungsgrad und Kosten) des Minimalbeispiels ergeben sich aus der schrittweisen Anpassung nach Durchführung von Testrechnungen des vollkomplexen Systems und der Parametrisierung der Komponenten des betrachteten, *eTraGo* zugrundeliegenden Datenmodells. In Abbildung 3.7 ist die Topologie dargestellt. Im Anhang A.1.2 sind die verwendeten Einspeise- und Lastzeitreihen dargestellt. Außerdem ist im Anhang A.1.1 ein Verweis auf das Skript im *eTraGo*-Repository bei *GitHub* zu finden.

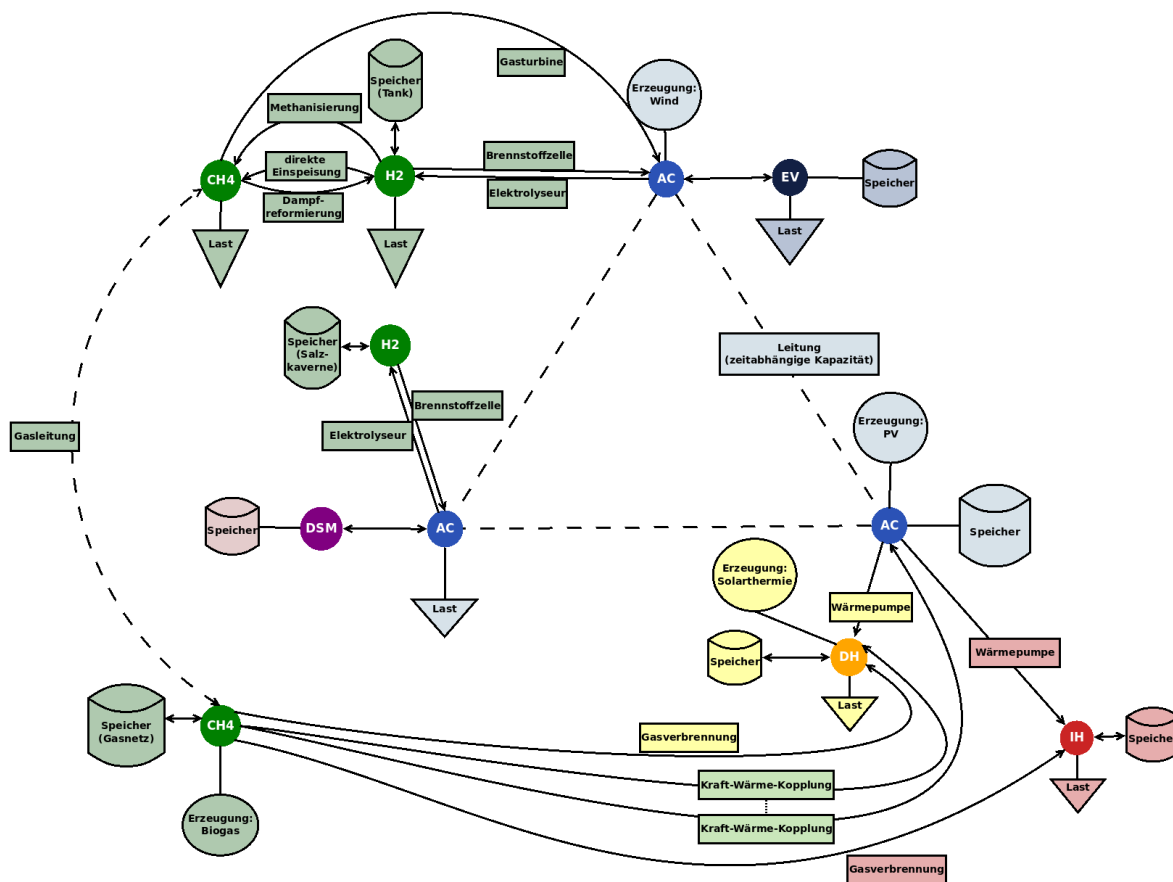


Abbildung 3.7: Darstellung des verwendeten Minimalbeispiels

Zur Optimierung ist der Solver *Gurobi*¹¹ mit seinen Standardeinstellungen ausgewählt. Die Berechnungen werden auf einem Server mit 45 Intel(R) Xeon(R) CPU E5-2643 0 @ 3.30GHz and 198 GB RAM durchgeführt.

3.5.3 Bedingungen der Berechnungen mit *eTraGo*

Die Grundlagen des Tools *eTraGo* sowie des verwendeten Datenmodells sind in Kapitel 3.1 nachzulesen. Sowohl das betrachtete Datenmodell des sekorggekoppelten deutschen Energiesystems der Hoch- und Höchstspannungsebene als auch das verwendete Tool *eTraGo* befinden sich zum Zeitpunkt der Erstellung dieser Arbeit in der Entwicklung. Die Fertigstellung und endgültige Validierung des Datenmodells und Tools stehen zum Zeitpunkt der Verwendung noch aus. Weiterhin ist zu beachten, dass die Version des im Rahmen dieser Arbeit verwendeten Tools *eTraGo* sowie das zugrundeliegende Datenmodell keinen Mobilitätssektor enthalten, da die Modellierung dieses Sektors zum Zeitpunkt der Erstellung der Arbeit noch nicht abgeschlossen ist. Die folgenden *Commits* dokumentieren die verwendeten Versionen von Datenmodell und Tool:

- Datenmodell (*eGon-data*): Commit 6e361c6607e9d6c28890c9652661dae48f288404 ¹²
- Tool (*eTraGo*): Commit 3b172cbff8da850f8513a0c425b38633b6f84991 ¹³

Die räumliche Auflösung wird im Zuge der durchgeführten Rechnungen auf 50 elektrische Knoten und 30 Gasknoten reduziert. Alle vorgenommenen Einstellungen sind in der `app1.py` dokumentiert; ein Verweis auf das Skript ist im Anhang A.1.1 zu finden. Die Berechnungen werden, ebenso wie die Rechnungen im Minimalbeispiel, auf einem Server mit 45 Intel(R) Xeon(R) CPU E5-2643 0 @ 3.30GHz and 198 GB RAM durchgeführt. Zur Optimierung ist *Gurobi*¹⁴ als Solver ausgewählt. Die LOPF werden in vier Iterationen durchgeführt. Weiterhin haben sich in bisherigen Untersuchungen in *eTraGo* die folgenden Einstellungen als geeignet erwiesen und werden deshalb auch im Rahmen dieser Arbeit verwendet.

- `'method': 2`
- `'crossover': 0`
- `'BarConvTol': 1.e-5`
- `'FeasibilityTol': 1.e-5`

¹¹<https://www.gurobi.com/>

¹²<https://github.com/openego/eGon-data/commit/6e361c6607e9d6c28890c9652661dae48f288404>

¹³<https://github.com/openego/eTraGo/commit/3b172cbff8da850f8513a0c425b38633b6f84991>

¹⁴<https://www.gurobi.com/>

3.6 Bewertungskriterien

Grundsätzlich ist das Ziel der Reduktion der zeitlichen Komplexität, eine Berechnung des Optimierungsproblems bei genügender Genauigkeit der Ergebnisse und gleichzeitig akzeptabler Rechenzeit zu ermöglichen. Aus diesem Grund gilt es, die Reduktion der Rechenzeit sowie die Genauigkeit der Ergebnisse zu untersuchen. Weil die Reduktion der zeitlichen Komplexität durch die Reduktion der zeitlichen Inputdaten erreicht wird, sollen im Rahmen dieser Arbeit aggregierte Attributzeitreihen im Vergleich zu den originalen Attributzeitreihen betrachtet werden. Wie in Kapitel 2 beschrieben, kann durch die Bewertung der Genauigkeit der aggregierten Attributzeitreihen jedoch nicht unbedingt auf die Eignung der Methode zur Reduktion der zeitlichen Komplexität geschlossen werden. Deshalb soll die Auswahl der Methoden zur Reduktion der zeitlichen Komplexität durch die Betrachtung der Rechenzeit und durch eine ausführliche Analyse der Optimierungsergebnisse erfolgen.

3.6.1 Betrachtung der aggregierten Zeitreihen

Durch die Betrachtung der aggregierten Zeitreihen und den Vergleich mit den originalen Attributzeitreihen sollen die Auswirkungen der Methoden zur Reduktion auf die Charakteristiken der verschiedenen Attributzeitreihen offengelegt werden. Zur Verdeutlichung werden die Zeitreihen in Form von Heatmaps visuell gegenübergestellt.

Die Genauigkeit einer aggregierten Zeitreihe im Vergleich zur originalen Zeitreihe kann weiterhin wie in der Arbeit von Hoffmann, Priesmann et al. (2021) mithilfe des RMSE (Root Mean Squared Error) nach dem in Gleichung 3.11 dargestellten Zusammenhang quantifiziert werden. Im Rahmen dieser Arbeit soll der durchschnittliche Fehler der aggregierten Attributzeitreihen des Systems als RMSE_{tot} nach Gleichung 3.12 betrachtet werden.

$$\text{RMSE} = \sqrt{\frac{1}{|\mathbb{P}| \times |\mathbb{T}|} \sum_{|\mathbb{C}|} \sum_{p \in \mathbb{C}_k} \sum_{|\mathbb{T}|} (x_{p,t} - \tilde{x}_{k,t})^2} \quad (3.11)$$

$$\text{RMSE}_{\text{tot}} = \sqrt{\frac{1}{|\mathbb{A}|} \sum_{|\mathbb{A}|} \text{RMSE}_a^2} \quad (3.12)$$

RMSE:	Root Mean Squared Error
$ \mathbb{P} $:	Anzahl der Perioden
$ \mathbb{T} $:	Anzahl der Zeitschritte pro Periode
$ \mathbb{C} $:	Anzahl der typischen Perioden
$x_{p,t}$:	Wert der originalen Zeitreihe der Periode p im Zeitschritt k
$\tilde{x}_{k,t}$:	Wert der aggregierten Zeitreihe der typischen Periode k im Zeitschritt t
RMSE_{tot} :	durchschnittlicher RMSE über die Attributzeitreihen \mathbb{A}
$ \mathbb{A} $:	Anzahl der zeitabhängigen Attribute
a :	Index des Attributs

3.6.2 Bewertung anhand des Optimierungsergebnisses

Die Genauigkeit des Optimierungsergebnisses soll im Rahmen dieser Untersuchung mithilfe des AOE (Average Objective Error) nach Gleichung 3.13 quantifiziert werden (Pineda und Morales (2018)).

$$\text{AOE} = \frac{x_{\text{aggregiert}} - x_{\text{Ref}}}{x_{\text{Ref}}} \quad (3.13)$$

AOE:	Average Objective Error
$x_{\text{aggregiert}}$:	Zielfunktionswert der Rechnung im zeitlich reduzierten Modell
x_{Ref} :	Zielfunktionswert der Referenzrechnung im zeitlich vollkomplexen Modell

Der Zielfunktionswert ergibt sich wie in Kapitel 3.1 beschrieben nach Gleichung 3.1 aus den Kosten für den Netz- und Speicherausbau sowie aus den marginalen Kosten des Systems. Bei Verwendung des *2-Level-Ansatzes* ergibt das das Äquivalent des Zielfunktionswerts nach Gleichung 3.14 aus den Ausbaurkosten der ersten Optimierungsstufe und den marginalen Kosten der zweiten Optimierungsstufe.

$$x_{2\text{Level}} = x_{\text{Ausbau,Level1}} + x_{\text{marginal,Level2}} \quad (3.14)$$

$x_{2\text{Level}}$:	Äquivalent des Zielfunktionswerts unter Verwendung des <i>2-Level-Ansatzes</i>
$x_{\text{Ausbau,Level1}}$:	Ausbaurkosten der ersten Optimierungsstufe
$x_{\text{marginal,Level2}}$:	marginale Kosten der zweiten Optimierungsstufe

Im Rahmen der Analyse des Optimierungsergebnisses sollen weiterhin die Zusammensetzung der Systemkosten sowie der Ausbaurkosten und der marginalen Kosten analysiert werden. Es soll untersucht werden, ob die verschiedenen Sektoren und Technologien analog zur Berechnung des vollkomplexen Referenzsystems berücksichtigt oder ob bestimmte Sektoren oder Technologien aufgrund der Reduktion der zeitlichen Komplexität unter- oder überschätzt werden. Unter Betrachtung der optimierten Komponenteneinsätze soll insbesondere die Abbildung des Speicherverhaltens überprüft werden.

Außerdem soll der Einfluss des verwendeten *2-Level-Ansatzes* (vgl. Kapitel 3.4) untersucht werden. Deshalb sollen die Ergebnisse der Optimierung der ersten Stufe und die Ergebnissen des *2-Level-Ansatzes* in den verschiedenen beschriebenen Analysepunkten gegenübergestellt werden.

3.6.3 Bewertung anhand der Rechenzeit

Die Reduktion der Rechenzeit im Vergleich zur für die Berechnung des vollkomplexen Systems notwendigen Rechenzeit soll nach Raventós (2018) durch in in Gleichung 3.15 formulierten Zusammenhang dargestellt werden. Es wird die Reduktion der zur Optimierung benötigten Rechenzeit ermittelt. Weil je nach verwendeter Methode auch die Aggregation der Zeitreihen Rechenzeit in Anspruch nimmt, soll diese dazu notwendige Zeit bei der Ermittlung des ATR

berücksichtigt werden. Weiterhin ist auch im Hinblick auf die Rechenzeit interessant, welchen Einfluss der *2-Level-Ansatz* nimmt, sodass die notwendige Zeit für die erste und zweite Optimierung getrennt voneinander ausgewiesen werden sollen.

$$\text{ATR} = \frac{t_{\text{Ref}} - t_{\text{aggregiert}}}{t_{\text{Ref}}} \quad (3.15)$$

AOE: Average Time Reduction

$t_{\text{aggregiert}}$: notwendige Zeit für Aggregation und Optimierung (*2-Level-Ansatz*)

t_{Ref} : notwendige Zeit zur einfachen Optimierung im zeitlich vollkomplexen Modell

4 Untersuchung der Methoden anhand eines Minimalbeispiels

Im Folgenden sollen die Ergebnisse der in Kapitel 3.5 beschriebenen Rechnungen zur Untersuchung der Methoden anhand des verwendeten Minimalbeispiels dargestellt werden. Anschließend werden die Ergebnisse diskutiert und die Methoden anhand der in Kapitel 3.6 erläuterten Kriterien bewertet. Die Bedingungen der Berechnungen sowie die vorgenommenen Einstellungen sind in Kapitel 3.5.2 dokumentiert.

4.1 Darstellung der Ergebnisse


Im Folgenden werden die Ergebnisse der Rechnungen dargestellt. Zunächst sollen die mithilfe der zu untersuchenden Methoden aggregierten Zeitreihen betrachtet werden, bevor die Optimierungsergebnisse und die Reduktion der Rechenzeit analysiert werden.

4.1.1 Betrachtung der aggregierten Zeitreihen


Abbildung 4.1 stellt die durch verschiedene Methoden reduzierten Attributzeitreihen den entsprechenden originalen Zeitreihen in Form von Heatmaps gegenüber. Es sind beispielhaft die Zeitreihen der potentiellen Einspeiseleistung der PV-Anlage, der potentiellen Einspeiseleistung der Windkraftanlage und der zentralen Wärmelast ausgewählt (vgl. Kapitel 3.5.2). In jedem der Graphen stellt die untere Heatmap die originale Zeitreihe dar. Die Heatmaps der aggregierten Zeitreihen sind durch die verwendete Methode und die zeitliche Auflösung beschrieben. Die Verkürzung der Heatmaps der mithilfe *Clustering auf typische Monate* und *Clustering auf typische Wochen* reduzierten Zeitreihen ergeben sich aus den in Kapitel 3.5.1 beschriebenen notwendigen Verkürzungen der Zeitreihen. Analog dazu sind Heatmaps ebenfalls für die weiteren im Minimalbeispiel vorhandenen Attributzeitreihen erstellt; diese befinden sich im Anhang A.2.1.

Die Heatmap der originalen Zeitreihe der potentiellen PV-Einspeisezeitreihe zeigt Tage mit viel Sonneneinstrahlung durch helle Streifen an. Die diskreten Streifen sind bei Betrachtung der Graphen der höheren zeitlichen Auflösung auch in den aggregierten Zeitreihen abgebildet. Die mithilfe des *Clusterings auf typische Monate* und *Clusterings auf typische Wochen* aggregierten potentiellen Einspeisezeitreihen weisen im Vergleich zur originalen Zeitreihe deutliche Abweichungen in der Verteilung der Streifen auf, während die Heatmap der anderen aggregierten Zeitreihen der Heatmap der originalen Zeitreihe ähnlicher sind. Ebenso verhält es sich bei Betrachtung der Abbildung mit der kleineren zeitlichen Auflösung, dabei sind insgesamt deutlichere Abweichungen zur originalen potentiellen Einspeisezeitreihe zu sehen. Während


in der durch *Clustering auf typische Tage* reduzierten Zeitreihen analog zur originalen Zeitreihe diskrete Streifen zur Identifikation von Tagen mit viel Sonneneinstrahlung zu erkennen sind, verschwimmen diese in den Heatmaps der mithilfe von *Segmentation* und *Downsampling* reduzierten Methode zu weniger hellen, breiteren Streifen.




(a) pot. PV-Einspeisung in p.u.
(~ 1000 Zeitschritte)




(b) pot. PV-Einspeisung in p.u.
(~ 3000 Zeitschritte)




(c) pot. Wind-Einspeisung in p.u.
(~ 1000 Zeitschritte)



(d) pot. Wind-Einspeisung in p.u.
(~ 3000 Zeitschritte)



(e) zentrale Wärmelast in MW
(~ 1000 Zeitschritte)



(f) zentrale Wärmelast in MW
(~ 3000 Zeitschritte)

Abbildung 4.1: Gegenüberstellung ausgewählter originaler und aggregierter Attributzeitreihen bei verschiedenen zeitlichen Auflösungen in Form von Heatmaps

Die Heatmap der originalen potentielle Einspeisezeitreihe der Windkraftanlage ist durch verschieden breite helle Streifen charakterisiert und gibt ein unregelmäßiges Muster wider. Insbesondere die Heatmaps, die dem *Clustering auf typische Monate* und *clustering auf typische*

Tage zuzuordnen sind, zeigen in beiden betrachteten zeitlichen Auflösungen signifikant abweichende Muster. Die mithilfe *Segmentation* und *Downsampling* reduzierten Zeitreihen sehen der originalen Zeitreihe am ähnlichsten.

In den Heatmaps der Wärmelastzeitreihe werden die saisonalen Schwankungen der Zeitreihe durch hellere Bereiche (höhere Lasten) während der Wintermonate und dunklere Bereiche (weniger hohe Lasten) während der Sommermonate markiert. Für die beiden dargestellten zeitlichen Auflösungen weisen die Heatmaps der durch *Clustering auf typische Monate* und *Clustering auf typische Wochen* aggregierten Zeitreihen die deutlichsten Unterschiede zur Heatmap der originalen Zeitreihe auf. Insbesondere die Reduktion der Zeitreihe auf einen repräsentativen Monat weist erhebliche Unterschiede im Muster auf. Die weiteren Heatmaps zeigen vor allem im Falle der höheren zeitlichen Auflösung deutlichere Ähnlichkeit mit der Heatmap der originalen Zeitreihe.

Abbildung 4.2 bildet den $RMSE_{tot}$ nach Gleichung 3.12 (vgl. Kapitel 3.6.1) als durchschnittlichen Fehler der aggregierten Attributzeitreihen im Minimalbeispiel in Abhängigkeit der gewählten zeitlichen Auflösung ab. Grundsätzlich zeigen die dargestellten Kurven einen ähnlichen Verlauf. Die Fehler der aggregierten Zeitreihen sind in kleinen Auflösungen am größten und nehmen bis zur vollen Komplexität zu Null hin ab. Im Bereich kleinerer Auflösungen ist die Abnahme des Fehlers größer als im Bereich größerer Auflösungen.




Abbildung 4.2: Darstellung des durchschnittlichen RMSE der aggregierten Zeitreihen im System in Abhängigkeit der Auflösung

Die Abweichung der durch das *Clustering auf typische Monate* aggregierten Zeitreihen ist über das gesamte Auflösungsspektrum hinweg am größten. Die Kurve, die den Fehler der durch *Clustering auf typische Wochen* reduzierten Zeitreihen abbildet, liegt deutlich darunter. Die Kurve des durch das *Clustering auf typische Tage* induzierten Fehlers zeigt an, dass die Abweichung der Zeitreihen unter Verwendung des *Clustering auf typische Perioden* bei Betrachtung von Tagen im Vergleich zur Betrachtung von Wochen und Monaten über das gesamte Auflösungsspektrum hinweg am geringsten ist.

Im Bereich kleinerer Auflösungen liegen die Fehler der durch *Clustering auf typische Tage* und der durch *Segmentation* reduzierten Zeitreihen in einem ähnlichen Bereich. Ab einer Betrachtung von etwa 1000 Zeitschritten ergeben sich durch Reduktion mithilfe *Segmentation* die kleinsten Fehler. Der Fehler, der sich für die mithilfe des *Downsamplings* reduzierten Zeitreihen ergibt, ist insbesondere für kleine zeitliche Auflösungen vergleichsweise hoch, ab einer Auflösung von etwa 3000 berücksichtigten Zeitschritten befindet sich der Fehler in einem ähnlichen Bereich wie der durch das *Clustering auf typische Tage* erzeugte Fehler.

4.1.2 Betrachtung der Optimierungsergebnisse

Die Untersuchung der Optimierungsergebnisse gliedert sich in die Betrachtung deren Genauigkeit, die Betrachtung der Zusammensetzung der Systemkosten und der Zusammensetzung der Kosten für Netz- und Speicherausbau und in die Betrachtung der Abbildung des Speicherverhaltens.

Analog zur Analyse der Zusammensetzung des Netz- und Speicherausbau kann die Zusammensetzung der Einsatzoptimierung im Anhang A.2.2 betrachtet werden. Es ergeben sich keine wesentlichen Unterschiede zur Zusammensetzung des Ausbaus sowie keine relevanten Erkenntnisse, weshalb diese Ergebnisse im Folgenden nicht explizit erläutert werden.

Betrachtung der Genauigkeit

Im Folgenden soll die Genauigkeit der Optimierungsergebnisse zunächst anhand der Abweichung des Ergebnisses vom Zielfunktionswert der vollkomplexen Referenzrechnung betrachtet werden. Abbildung 4.3 zeigt den AOE nach Gleichung 3.13 (vgl. Kapitel 3.6.2) bei Verwendung der verschiedenen Methoden in Abhängigkeit der zeitlichen Auflösung. Dabei wird zwischen dem Fehler nach Durchführung der einstufigen Optimierung basierend auf den aggregierten Zeitreihen und dem Fehler nach Verwendung des *2-Level-Ansatzes* mit Durchführung einer zusätzlichen Optimierung des Komponenteneinsatzes basierend auf den vollkomplexen Zeitreihen unterschieden. Zur Erleichterung der Vergleichbarkeit markieren die roten Horizontalen den Fehlerbereich von 5%. Zunächst sollen die Ergebnisse der Verwendung des *2-Level-Ansatzes* beschrieben werden, anschließend werden die Verwendung von zweistufiger Optimierung im *2-Level-Ansatz* und einstufiger Optimierung verglichen.

Es ist festzustellen, dass alle in Abbildung 4.3 dargestellten Kurven des *2-Level-Ansatzes* einen ähnlichen Kurvenverlauf zeigen. Im Bereich kleinerer Auflösungen sind die Fehler vergleichsweise hoch, die Systemkosten werden hier deutlich überschätzt. Mit zunehmender Anzahl berücksichtigter Zeitschritte nimmt der Fehler zunächst stark, im Bereich höherer zeitlicher Auflösung dann schwächer ab. Die Kurven ähneln damit dem Ast einer Hyperbel. Dieser Verlauf ist grundsätzlich in allen dargestellten Graphen identifizierbar, nichtsdestotrotz ergeben sich für einige Methoden im Übergangsbereich von starker zu schwacher Fehlerabnahme Anstiege der Fehler trotz Erhöhung der zeitlichen Auflösung sowie klare Unterschiede in der Höhe der Fehler und in der minimal notwendigen Auflösung zu Erreichung des Fehlerbereichs von 5%.

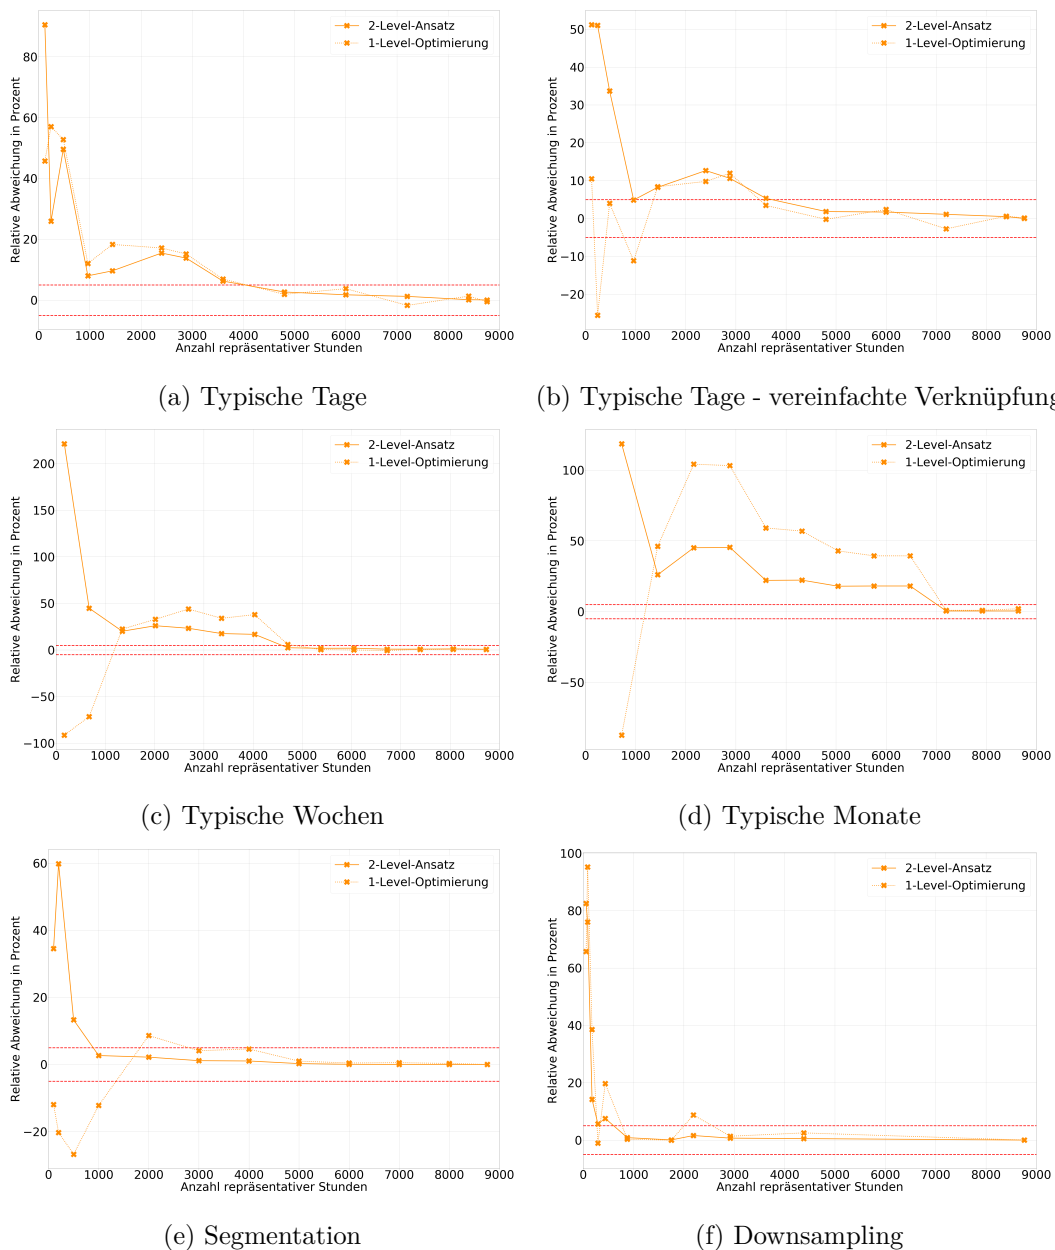


Abbildung 4.3: Darstellung des AOE in Abhängigkeit der zeitlichen Auflösung

Die Graphen, die den Fehler bei Reduktion der Zeitreihen auf typische Tage beschreiben, weisen maximale Fehler im Bereich zwischen 30 % und 90 % auf. Sie zeigen einen sehr ähnlichen Kurvenverlauf mit einem Anstieg des Fehlers im Bereich von 2000 berücksichtigten Zeitschritten. Insgesamt liegt der Fehler bei Verwendung der vereinfachten Methode zur Verknüpfung typischer Tage unterhalb des Fehlers, der sich bei Verwendung des klassischen Ansatzes ergibt. Ab einer zeitlichen Auflösung von mindestens 4000 repräsentativen Stunden liegen die Fehler beider Methoden im Bereich bis 5 % und sinken mit zunehmender zeitlicher Komplexität annähernd konstant bis zur vollen Auflösung auf Null ab.

Die Kurvenverläufe des Fehlers bei Anwendung des *Clusterings auf typische Monate* und *Clusterings auf typische Tage* ähneln den beschriebenen Verläufen unter Verwendung von *Clusterings auf typische Tage* insbesondere in der Tatsache, dass ebenso Fehlerzunahmen im Bereich von 2000 berücksichtigten Zeitschritten auftreten. Allerdings sind die Fehler über

ein breites Auflösungsspektrum hinweg größer als die, die durch *Clustering auf typische Tage* erzeugt werden. Bei einer Auflösung von etwa 4000 repräsentativen Stunden, wo die Fehler beim *Clustering auf typische Tage* den Fehlerbereich 5 % erreichen, ergeben sich unter Verwendung dieser Methoden Fehler von etwa 25 %. Der Fehlerbereich von 5 % wird im Fall des *Clusterings auf typische Wochen* erst mit einer Auflösung von etwa 4500 repräsentativen Zeitschritten und im Fall des *Clusterings auf typische Monate* erst ab etwa 7000 berücksichtigten Stunden erreicht.

Die Graphen, die den durch Verwendung von *Segmentation* und *Downsampling* erzeugten Fehler darstellen, erreichen den Fehlerbereich von 5 % schon bei sehr geringen zeitlichen Auflösungen. Zwar liegen die maximalen Abweichungen bei den kleinsten betrachteten Auflösungen ähnlich hoch wie bei den anderen Methoden (zwischen 30 % und 90 %), jedoch ist die Änderungsrate des Fehlers in diesem Bereich sehr hoch, sodass die 5 %-Markierung schon ab einer Betrachtung von mindestens 1000 berücksichtigten Stunden erreicht wird. Von dieser Auflösung an konvergieren die Kurven mit Zunahme der repräsentativen Stunden zu einem Fehler von Null.

Abbildung 4.3 zeigt, dass sich der durch die Reduktion der zeitlichen Komplexität herbeigeführte Fehler unter Verwendung der mehrstufigen Optimierung des *2-Level-Ansatzes* im Vergleich zur einstufigen Optimierung für die meisten untersuchten Methoden und für einen Großteil aller betrachteten Auflösungen reduziert. So markiert die gepunktete Linie in fast allen Graphen größere Abweichungen unter Verwendung einer einstufigen Optimierung als sich für die Verwendung der zweistufigen Optimierung ergeben. Es sind jedoch zwei Ausnahmen zu nennen. Zum Einen ergeben sich im Bereich kleiner zeitlicher Auflösungen unter Anwendung von *Segmentation* geringere Abweichungen nach einstufiger Optimierung. Ab einer zeitlichen Komplexität von mindestens etwa 1500 berücksichtigten Stunden gilt das nicht. Unter Anwendung des *2-Level-Ansatzes* reduziert sich der erzeugte Fehler mit Zunahme der zeitlichen Komplexität, während die einstufige Optimierung einen zwischenzeitigen Fehleranstieg zur Folge hat. Zum Anderen zeigt der Graph, der die Fehler bei Aggregation der Zeitreihen mithilfe von *Clustering auf typische Tage* bei Verknüpfung der typischen Tagen nach dem vereinfachten Ansatz abbildet, dass für diese Rechnungen für die meisten betrachteten Auflösungen kleinere Abweichungen auftreten, wenn die einstufige Optimierung durchgeführt wird. Insgesamt zeigen die Kurven der einstufigen Optimierung und des *2-Level-Ansatzes* jedoch sehr ähnliche Fehler an.

Auffällig ist weiterhin, dass die einstufige Optimierung bei den meisten der betrachteten Methoden in geringen zeitlichen Auflösungen eine Unterschätzung des Zielfunktionswerts beinhaltet, während das Ergebnis unter Verwendung des *2-Level-Ansatzes* in allen Fällen überschätzt wird. Die Ausnahme bilden die Graphen, die dem *Clustering auf typische Tage* und dem *Downsampling* zuzuordnen sind. Hier erfolgt sowohl bei einstufiger als auch bei zweistufiger Optimierung eine Überschätzung in den kleinsten betrachteten Auflösungen. In höheren Auflösungen kommt es auch nach der einstufigen Optimierung tendenziell zu Überschätzungen des Werts. Insgesamt obliegen die Fehler bei Verwendung der einstufigen Optimierung mehr Schwankungen, die Fehler pendeln in Abhängigkeit der zeitlichen Auflösung um den optimalen Referenzwert. Bei Verwendung des *2-Level-Ansatzes* ist - mit Ausnahme der be-

schriebenen Fehlerzunahmen unter Verwendung des *Clusterings auf typische Perioden* - eine kontinuierlichere Annäherung an einen Fehler von Null zu erkennen.

Analog zur vorherigen Abbildung zeigt Abbildung 4.4 den AOE bei Verwendung der verschiedenen Methoden unter expliziter Berücksichtigung von Extrempereoden. Die grünen Kurven zeigen die Fehler bei Anfügen von Extrempereoden, die blauen Kurven stellen die Fehler bei Ersatz von Clustern durch Extrempereoden dar. Um den Vergleich zu den Ergebnissen der Rechnungen ohne explizite Berücksichtigung von Extrempereoden zu erleichtern, sind die entsprechenden Fehlerkurven ebenfalls eingetragen.

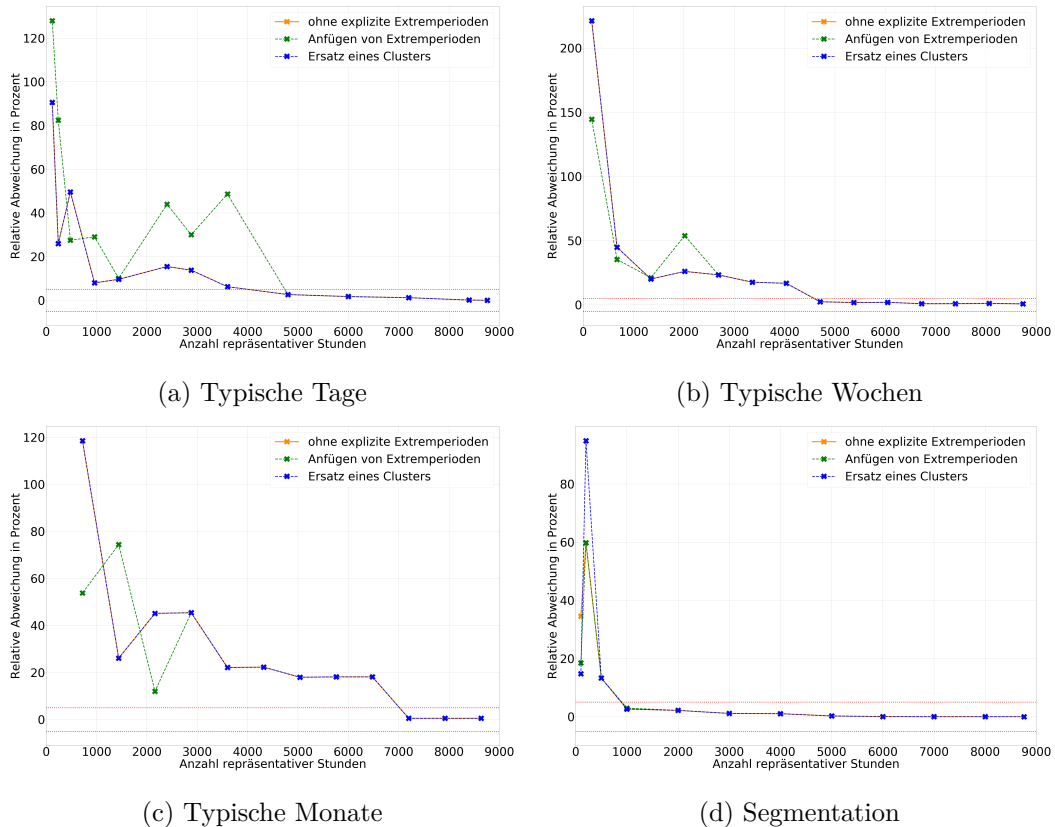


Abbildung 4.4: Darstellung des AOE in Abhängigkeit der zeitlichen Auflösung bei Berücksichtigung von Extrempereodenschritten

Zunächst einmal ist festzustellen, dass sich Unterschiede im Vergleich zur Verwendung der entsprechenden Methoden ohne explizite Berücksichtigung von Extrempereoden lediglich in den kleineren betrachteten zeitlichen Auflösungen ergeben. Während diese Unterschiede bei Verwendung des *Clusterings auf typische Perioden* je nach Länge der betrachteten Perioden bis zu Auflösungen von 3000 bis 5000 repräsentativen Stunden auftreten, weisen die Ergebnisse bei Anwendung von *Segmentation* schon ab etwa 500 berücksichtigten Zeitschritten identische Fehlerkurven auf.

Durch *Clustering auf typische Tage* ergeben sich bei Ersatz eines Clusters die gleichen Fehler wie ohne explizite Berücksichtigung der Extrempereoden. Das Anfügen der Extrempereoden hat eine Veränderung des Fehlers zur Folge. Die Fehlerkurve, die Anfügen von Extrempereoden zuzuordnen ist, liegt für die meisten betrachteten Auflösungen oberhalb der Kurve

ohne explizite Berücksichtigung der Extrempereoden und zeigt damit größere Fehler an. Insgesamt ist die Fehlerkurve durch mehr Schwankungen charakterisiert. Unter Verwendung von *Segmentation* ergibt sich bei Ersatz von Clustern durch die identifizierten Extrempereoden eine deutliche Erhöhung des Fehlers im Bereich der zeitlichen Auflösung von etwa 300 repräsentativen Stunden, während das Anfügen der Extrempereoden die gleichen Fehler zur Folge hat wie ohne explizite Berücksichtigung von Extrempereoden. Ansonsten ergeben sich hier keinerlei Unterschiede in den Fehlerkurven.

Betrachtung der Zusammensetzung der Systemkosten und insbesondere der Ausbaurkosten

Der Zielfunktionswert der Optimierung ergibt sich nach Gleichung 3.1 (vgl. Kapitel 3.1) aus den Kosten für den Ausbau sowie den marginalen Kosten des Systems und das Äquivalent unter Anwendung des *2-Level-Ansatzes* analog nach Gleichung 3.14. Im Folgenden soll die Zusammensetzung der Optimierungsergebnisse untersucht werden. Abbildung 4.5 zeigt die berechneten Kosten für den Netz- und Speicherausbau ermittelt mithilfe des ersten Optimierungslevels sowie die berechneten marginalen Kosten ermittelt während der ersten Optimierungsstufe und unter Verwendung der vollkomplexen Zeitreihen in der zweiten Optimierungsstufe. Weiterhin ist die Zusammensetzung der Ausbaurkosten mithilfe der Balken abgebildet. Unabhängig von der Genauigkeit der Systemkosten kann durch Vergleich der Verhältnisse zueinander die Berücksichtigung der verschiedenen Sektoren und Technologien überprüft werden.

Die Kurven, die die Kosten des Netz- und Speicherausbaus abbilden, zeigen in einigen Fällen ähnliche Kurvenverläufe wie die Kurven der AOE in Abbildung 4.3. So zeichnen sich die Ausbaurkosten unter Verwendung von *Clustering auf typische Tage* und *Downsampling* durch eine Überschätzung der Ausbaurkosten in kleinen zeitlichen Auflösungen aus. In diesen Fällen nähern sich die Kosten in Abhängigkeit der zeitlichen Komplexität von oben an die im Referenzfall ermittelten optimalen Kosten an. In den anderen Graphen werden die Ausbaurkosten für die kleinsten betrachteten zeitlichen Auflösungen unterschätzt und in etwas höheren Auflösungen tendenziell überschätzt, sodass sich die Ausbaurkosten auch in diesen Fällen von oben an die optimalen Kosten annähern.

In vielen Graphen ist im Bereich kleiner zeitlicher Auflösungen eine Überschätzung der Ausbaurkosten für Gasspeicher zu sehen. Dies gilt insbesondere für die Kosten, die sich unter Verwendung des *Clusterings auf typische Monate* ergeben, wo die Überschätzung des notwendigen Gasspeicherausbaus bis in höhere Auflöungsbereiche reicht. Bei *Clustering auf typische Tage* und *Downsampling* werden die Kosten zum Ausbau der verschiedene Technologien koppelnden Links im Bereich kleiner Auflösungen signifikant überschätzt. Demgegenüber steht eine Unterschätzung der Komponenten des elektrischen Sektors im Bereich kleiner zeitlicher Auflösungen für fast alle abgebildeten Graphen. Die Verwendung von *Segmentation* und *Clustering auf typische Tage* mit Verknüpfung der Tage nach dem vereinfachten Ansatz zeigen bei kleinen zeitlichen Auflösungen eine Unterschätzung der Kosten des Wärmespeicherausbaus auf. Unter Anwendung von *Segmentation* und *Downsampling* ergibt sich die Zusammensetzung der Ausbaurkosten bereits in vergleichsweise kleinen zeitlichen Auflösungen ab etwa 1000 repräsentativen Zeitschritten analog zur Zusammensetzung der Kosten im vollkomplexen Referenzfall.

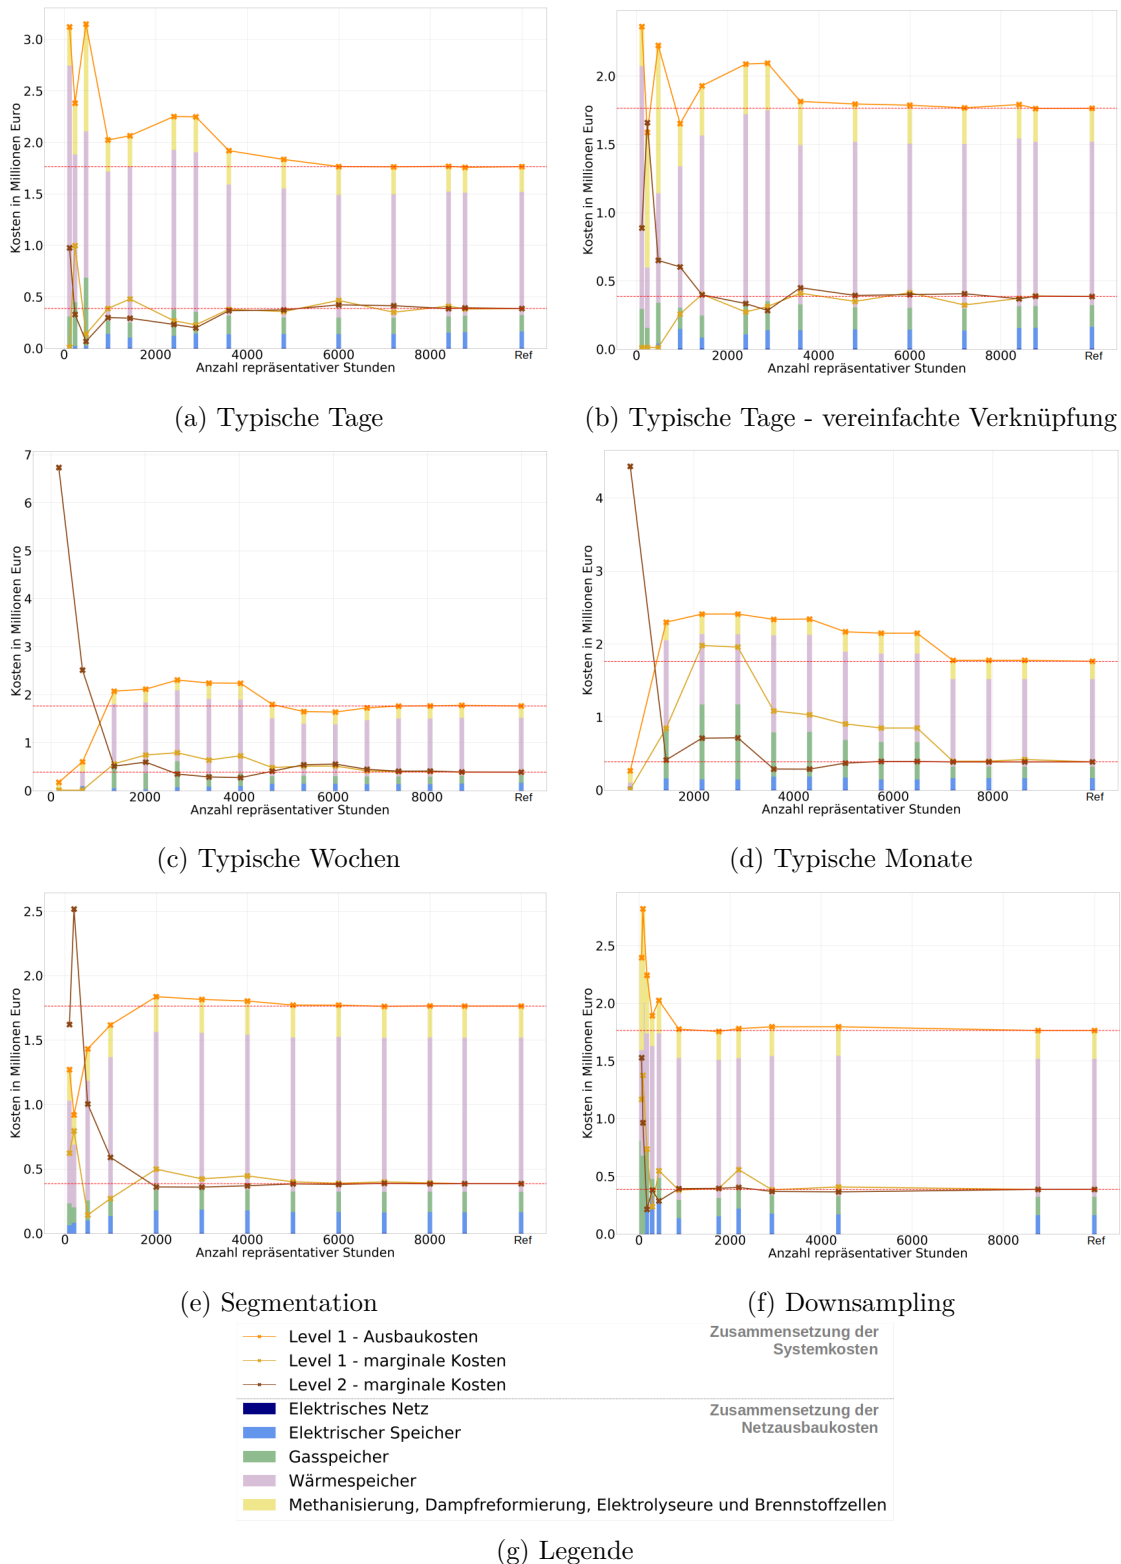


Abbildung 4.5: Darstellung von Ausbaurkosten und marginalen Kosten in Abhängigkeit der zeitlichen Auflösung

Die marginalen Kosten nach Ermittlung in der zweiten Optimierungsstufe zeigen in allen Graphen bei den kleinsten betrachteten zeitlichen Auflösungen eine signifikante Überschätzung. Dies ist insbesondere unter Verwendung derjenigen Methoden zu beobachten, die in den entsprechenden zeitlichen Auflösungen eine Unterschätzung der Ausbaurkosten aufweisen. Die marginalen Kosten, die während der ersten Optimierungsstufe berechnet werden,

zeigen diese Spitze zu Beginn der Kurven entweder gar nicht oder weniger stark. Mit Ausnahme des Graphen, der die Verwendung von *Clustering auf typische Wochen* beschreibt, wo sich größere Unterschiede zwischen den berechneten marginalen Kosten ergeben, schwanken die marginalen Kosten nach Berechnung in Level 1 und Level 2 ab einer Betrachtung von etwa 2000 repräsentativen Stunden in ähnlichen Bereichen um den optimalen Wert, an den sie sich mit zunehmender zeitlicher Auflösung annähern.

Betrachtung der Abbildung von Speicherverhalten

Im Folgenden soll die Darstellung des Speicherverhaltens überprüft werden. Dazu ist in Abbildung 4.6 der Verlauf des Speicherfüllstands ausgewählter Speicher des Systems nach Anwendung des *2-Level-Ansatzes* in Form von Heatmaps dargestellt. Die Graphen sind analog zu der Gegenüberstellung originaler und aggregierter Attributzeitreihen in Abbildung 4.1 aufgebaut. Die jeweils untere Heatmap jedes Graphen zeigt den Verlauf des Speicherfüllstands in der zeitlich vollkomplexen Referenzrechnung. Die weiteren Heatmaps eines Graphen sind durch die in der jeweiligen Rechnung zur Reduktion der zeitlichen Komplexität verwendete Methode und die zeitliche Auflösung gekennzeichnet. Es sind die Speicherfüllstände des elektrischen Speichers, des zentralen Wärmespeichers und des CH₄-Gasnetzspeichers (vgl. Kapitel 3.5.2) abgebildet. Die Darstellungen der weiteren im System vorhandenen Speicher sind im Anhang A.2.3 zu finden.

Das Muster der Heatmap der Referenzrechnung, die den Speicherfüllstand des elektrischen Speichers abbildet, zeichnet sich durch diskrete helle Streifen aus und zeigt damit die Verwendung des elektrischen Speichers als Kurzzeitspeicher. Auch die Ergebnisse der zeitlich aggregierten Rechnungen weisen entsprechende diskrete Streifen auf, jedoch ergeben sich unter Anwendung von *Clustering auf typische Monate* und *Clustering auf typische Tage* weniger helle Streifen sowie eine abweichende Verteilung der Streifen. Das gilt insbesondere für die kleinere betrachtete zeitliche Auflösung, wo eine deutliche Unterschätzung der Speichernutzung angezeigt wird. Die übrigen Methoden bilden die Speichernutzung insbesondere unter Betrachtung der höheren zeitlichen Auflösung vergleichsweise genau ab.

Der Wärmespeicher dient als saisonaler Speicher, sodass sich für die Heatmap der Referenzrechnung Farbverläufe ergeben, die eine langfristige Aufladung und Speicherung während der Sommermonate und Nutzung der gespeicherten Energie in den Wintermonaten anzeigen. Die Speichernutzung wird unter Betrachtung eines typischen Monats sowie vier typischer Wochen deutlich unterschätzt. Mit Erhöhung der zeitlichen Auflösung wird die Nutzung besser abgebildet. Grundsätzlich weisen die den verschiedenen Methoden zuzuordnenden Heatmaps recht deutlich das charakteristische Muster der saisonalen Nutzung auf, Unterschiede ergeben sich hauptsächlich in der Auslastung der Speicher. Die Verwendung des *Clustering auf typische Tage* bewirkt in beiden betrachteten Auflösungen eine Überschätzung der Wärmespeichernutzung in den Wintermonaten. Insbesondere in der höheren betrachteten Auflösung wird die Speichernutzung unter Anwendung von *Clustering auf typische Tage*, *Downsampling* und *Segmentation* sehr genau abgebildet.







(a) Elektrischer Speicher
(~ 1000 Zeitschritte)(b) Elektrischer Speicher
(~ 3000 Zeitschritte)(c) zentraler Wärmespeicher
(~ 1000 Zeitschritte)(d) zentraler Wärmespeicher
(~ 3000 Zeitschritte)(e) CH₄-Gasnetzspeicher
(~ 1000 Zeitschritte)(f) CH₄-Gasnetzspeicher
(~ 3000 Zeitschritte)

Abbildung 4.6: Gegenüberstellung der Abbildung des Speicherverhaltens nach Anwendung des *2-Level-Ansatzes* durch Betrachtung des Speicherfüllstands (in MWh) bei verschiedenen zeitlichen Auflösungen in Form von Heatmaps

Der Gasspeicher wird, so zeigt es die Heatmap der Referenzrechnung an, über das gesamte Jahr hinweg ausgelastet und dient zu bestimmten Zeitpunkten mit besonderer Auslastung als Ergänzung des Wärmespeichers, der während derselben Zeitpunkte kaum Energie gespeichert hat. Es ergibt sich ein vergleichsweise unregelmäßiges Muster. Über alle abgebildeten Heatmaps hinweg sind tendenziell mehr Abweichungen zur Abbildung im Referenzfall zu sehen, als es bei den anderen betrachteten Speichern der Fall ist. Unter Betrachtung der kleineren zeitlichen Auflösung wird die Speichernutzung durch Anwendung von *Downsampling* und *Seg-*

mentation vergleichsweise genau abgebildet. Unter Verwendung von *Clustering auf typische Tage* ergeben sich leichte Abweichungen, während die Heatmaps, die der Reduktion mittels *Clustering auf typische Monate* und *Clustering auf typische Wochen* zuzuordnen sind, eine deutliche Überschätzung aufweisen. Tendenziell wird die Speichernutzung bei Anwendung von *Segmentation* und *Downsampling* unterschätzt, in den entsprechenden Heatmaps bilden sich mehr dunklere Bereiche. Die durch Rechnungen mit höherer zeitlicher Auflösung erzeugten Heatmaps zeigen insgesamt weniger Abweichungen zum Verlauf der Referenzrechnung. Allerdings weist die Heatmap, die der Reduktion mittels *Segmentation* zuzuordnen ist, eine deutliche Unterschätzung der Speichernutzung in den Sommermonaten auf, die einer überschätzten Nutzung im Zeitraum direkt davor gegenübersteht. Das Muster weicht damit signifikant und deutlicher als unter Betrachtung der kleineren zeitlichen Auflösung vom Muster der Referenzrechnung ab.

4.1.3 Betrachtung der Rechenzeiten

Abbildung 4.7 zeigt die für die Aggregation der Zeitreihen sowie die Optimierungen der beiden Stufen des *2-Level-Ansatzes* notwendige Rechenzeit in Abhängigkeit der zeitlichen Auflösung. Die einzelnen Graphen sind jeweils einer der zu untersuchenden Methoden zuzuordnen. In jedem der Graphen stellt der rechte Balken die Rechenzeit des zeitlich vollkomplexen Referenzfalls dar. Die rote Horizontale markiert die Zeit, die zur einstufigen Optimierung des Systems ohne Reduktion der zeitlichen Komplexität notwendig ist. Diese Zeit stellt damit die Referenzzeit dar.

Für alle untersuchten Methoden trägt die zur Aggregation der Zeitreihen notwendige Zeit einen Bruchteil der Gesamtrechenzeit bei. Lediglich im Graph, der die Rechenzeiten bei Verwendung von *Segmentation* zeigt, wird die notwendige Zeit zur Aggregation in den Balken überhaupt ersichtlich. Die Rechenzeit zur Durchführung der Optimierung der Einsatzplanung im ausgebauten System mit den vollkomplexen Zeitreihen ist in allen Rechnungen in etwa gleich groß und im Verhältnis zur Referenzzeit deutlich kürzer.

Durch Anwendung der Methoden des *Clusterings auf typische Perioden* mit Verknüpfung der typischen Perioden nach Kotzur et al. (2018b) ist die Rechenzeit des ersten Optimierungslevels, das zur Optimierung von Ausbau des Netzes mithilfe der aggregierten Zeitreihen dient, schon in geringen zeitlichen Auflösungen ähnlich hoch wie die Referenzzeit und in größeren Auflösungen sogar um ein Vielfaches höher als die Referenzzeit. Insbesondere bei Betrachtung des Graphen, der die Rechenzeiten bei Anwendung von *Clustering auf typische Tage* darstellt, ist weiterhin auffällig, dass die Rechenzeit nicht eindeutig mit Erhöhung der zeitlichen Auflösung steigt, sodass die maximal notwendige Rechenzeit im Bereich um 120 typischen Tagen auftritt. Unter Verwendung des vereinfachten Ansatzes zur Kopplung der typischen Perioden wird die Rechenzeit des ersten Optimierungslevels deutlich reduziert, sodass beim *Clustering auf typische Tage* eine Reduktion der Gesamtrechenzeit bis zur Berücksichtigung von etwa 150 typischen Tagen erreicht wird. Außerdem steigt die Rechenzeit über einen großen Teil der zeitlichen Auflösung nachvollziehbar mit zunehmender zeitlicher Komplexität an.

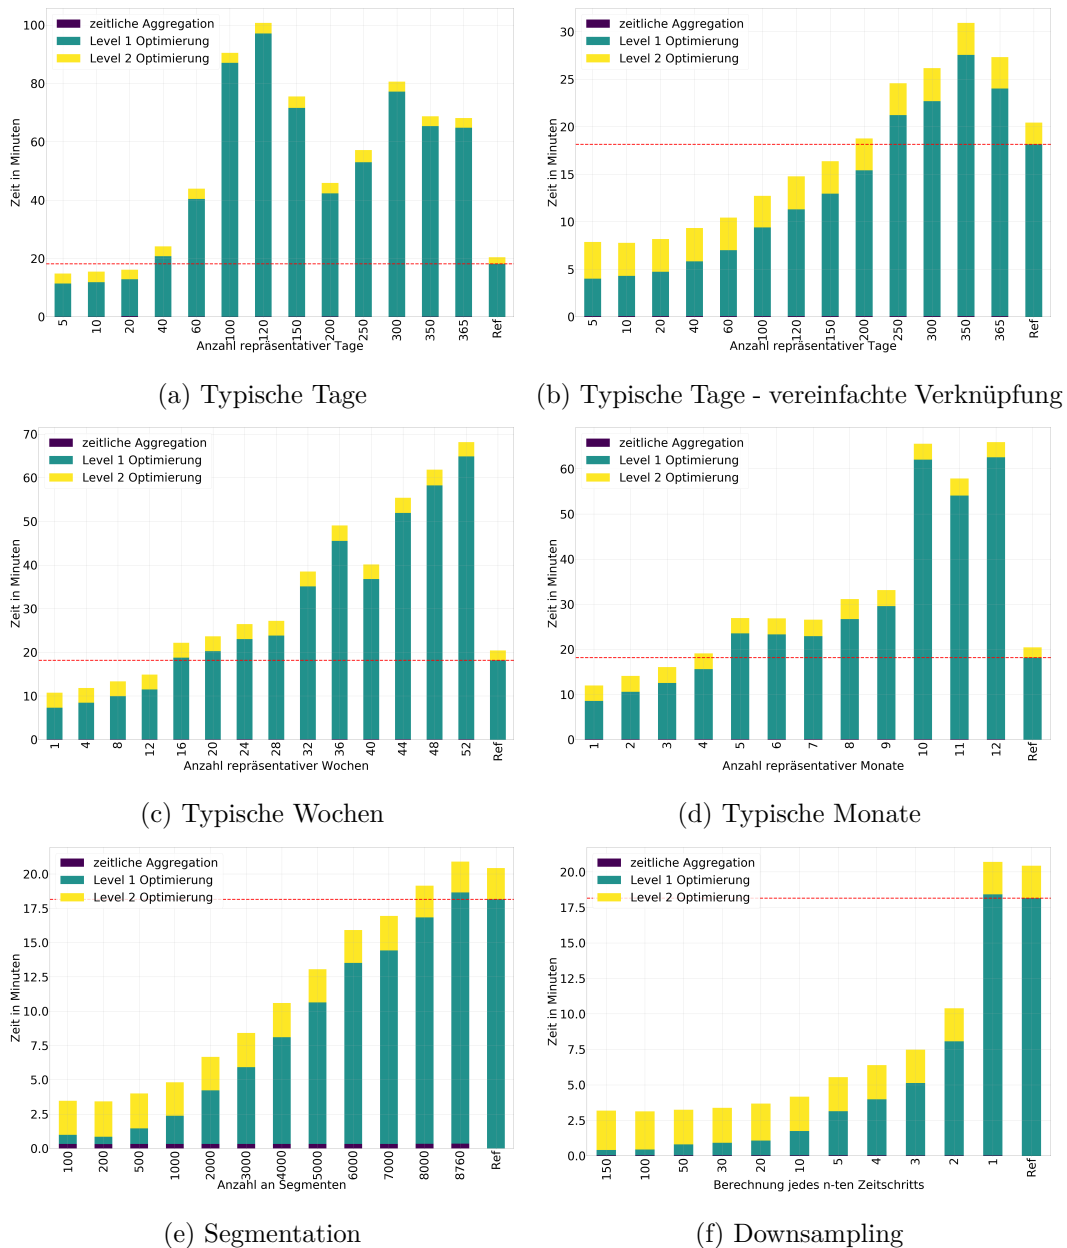


Abbildung 4.7: Darstellung der Rechenzeit in Abhängigkeit der zeitlichen Auflösung

Eine stetige Zunahme der Rechenzeit zur Erhöhung der zeitlichen Komplexität ist ebenso für die Anwendung von *Segmentation* und *Downsampling* zu beobachten. Die Rechenzeit zur Optimierung von Netz- und Speicherausbau liegt unter Verwendung von *Segmentation* bis zur Auswahl der vollkomplexen Auflösung unterhalb der Referenzrechenzeit. Durch den notwendigen Aufschlag zur Aggregation der Zeitreihen und zur Optimierung der Einsatzplanung mithilfe der vollkomplexen Zeitreihen ergibt sich eine Reduktion der Rechenzeit bis zu einer zeitlichen Auflösung von etwa 7000 Segmenten. Die kleinsten Rechenzeiten ergeben sich bei Verwendung des *Downsamplings*. Es ist eine deutliche Reduktion der Gesamtrechenzeit bis zu einer Betrachtung von jedem zweiten Zeitschritt festzustellen.

In Abbildung 4.8 ist die Reduktion der Rechenzeit als ATR nach Gleichung 3.15 (vgl. Kapitel 3.6.3) bei Verwendung ausgewählter Methoden zur Reduktion der zeitlichen Komplexität visualisiert. Es wird jeweils zwischen der Anwendung der Methoden bei einstufiger Optimie-

rung und innerhalb des *2-Level-Ansatzes* unterschieden. Es ist zu beachten, dass die Kurven im negativen Zahlenbereich eine Erhöhung der Rechenzeit im Vergleich zur Referenzzeit anzeigen.

Die Abbildung zeigt eine lineare Abhängigkeit der Reduktion der Rechenzeit von der Auswahl der zeitlichen Auflösung an. Am deutlichsten wird die lineare Abhängigkeit unter Verwendung von *Downsampling* und *Segmentation*, während die Kurve, die die Reduktion mithilfe *Clustering auf typische Tage* beschreibt, leichte Unterschiede in der Änderungsrate aufweist. Eine Weiterhin findet sich in dieser Kurve eine Ausnahme im Bereich der höchsten betrachteten zeitlichen Auflösung, wo die Rechenzeit trotz Erhöhung der zeitlichen Komplexität sinkt.

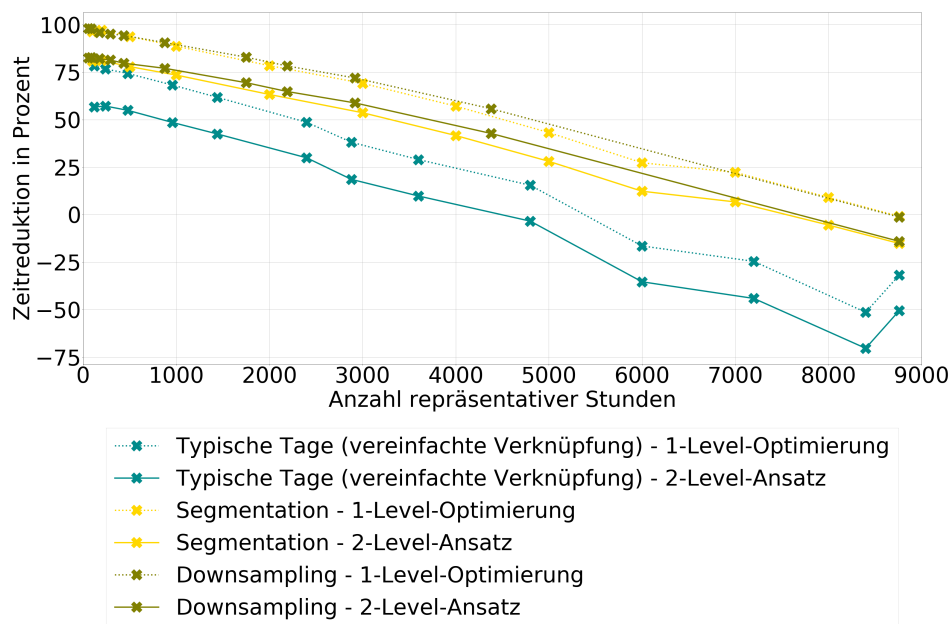


Abbildung 4.8: Darstellung des ATR in Abhängigkeit der zeitlichen Auflösung

Die Kurven, die der Reduktion mittels *Downsampling* und *Segmentation* zuzuordnen sind, liegen nah aneinander. Wie bereits in Abbildung 4.7 zu sehen ist, ergibt sich für die Rechenzeit der Optimierung von Netz- und Speicherausbau über das gesamte Auflösungsspektrum hinweg eine Reduktion der Rechenzeit von über 90 % bei den kleinsten betrachteten Auflösungen bis hin zu 0 % bei Betrachtung der vollen zeitlichen Komplexität. Durch die Optimierung der Einsatzplanung mithilfe der vollkomplexen Zeitreihen verringert sich die Reduktion um etwa 15 %.

Der Graph des *Clustering auf typische Tage* unter Verwendung des vereinfachten Ansatzes zur Verknüpfung der typischen Perioden nach Kotzur et al. (2018b) liegt unterhalb der anderen Kurven und beschreibt damit eine geringere Reduktion der Gesamtrechenzeit. Die Graphen zeigen, dass eine Reduktion der Rechenzeit unter Verwendung des *2-Level-Ansatzes* nur bis zu einer Auflösung von etwa 5500 berücksichtigten Zeitschritten erreicht wird. Bei einstufiger Optimierung wird die Rechenzeit bis zu einer zeitlichen Komplexität von etwa 4500 berücksichtigten Zeitschritten erreicht.

4.2 Diskussion der Ergebnisse und Bewertung der Methoden

Im Folgenden sollen die im vorherigen Abschnitt dargestellten Ergebnisse zunächst diskutiert werden. Anschließend sollen die Methoden, wie in Kapitel 3.6 erläutert, anhand der Genauigkeit der Optimierungsergebnisse und der Reduktion der Rechenzeit bewertet werden. Weiterhin soll der im Rahmen dieser Arbeit angewandte *2-Level-Ansatz* bewertet werden.

4.2.1 Diskussion der Ergebnisse

Die Betrachtung der aggregierten Zeitreihen lässt vermuten, dass die Methoden *Clustering auf typische Monate* und *Clustering auf typische Wochen* nicht geeignet sind, um die relevanten Informationen der Inputdaten zu erhalten. Insbesondere die Heatmap, die der Reduktion der Wärmezeitreihe auf einen repräsentativen Monat (Abbildung 4.1 (b)) zuzuordnen ist, sticht aufgrund der signifikanten Abweichung des Musters zur originalen Zeitreihe hervor. Die Ursache liegt darin, dass ein einziger repräsentativer Monat keine saisonalen Schwankungen abdecken kann, da diese die Zeitspanne eines Monats überschreiten. Im Gegensatz dazu eignet sich die Reduktion auf typische Tage bei gleicher zeitlicher Auflösung deutlich besser, weil bei gleicher Anzahl betrachteter Zeitschritte (z. B. ein Monat bzw. 30 Tage entsprechen 720 Stunden) durch die Verteilung der repräsentativen Tage im Jahr eine größere Varianz der betrachteten Zeitschritte repräsentiert werden kann. Aus diesem Grund scheint sich die Betrachtung von Tagen beim *Clustering auf typische Perioden* besser als die Betrachtung längerer Zeitabschnitte zu eignen. Gleichzeitig werden durch die Wahl des *Clustering auf Tage* repetitive Muster innerhalb von Tagen verwertet, was insbesondere anhand der Heatmap der Reduktion der potentiellen PV-Einspeisezeitreihe (Abbildung 4.1 (a)) deutlich wird. Dadurch weist die Heatmap der durch *Clustering auf typische Tage* reduzierten Zeitreihe die gleichen hellen, diskreten Streifen auf wie die originale Zeitreihe, während die Streifen unter Verwendung von *Downsampling* und *Segmentation* zu breiteren, weniger hellen Streifen verwischen, weil die charakteristischen Muster der originalen Zeitreihe nicht verwertet werden und die Charakteristiken dieser speziellen originalen Zeitreihe damit weniger stark berücksichtigt werden. Für die Abbildung des vergleichsweise unregelmäßigen Musters der Wind-Einspeisezeitreihe wiederum scheint sich das *Clustern auf typische Perioden* weniger zu eignen. Die Charakteristiken der originalen Zeitreihe scheinen besser durch die Reduktion mithilfe *Segmentation* und *Downsampling* abgebildet werden zu können.

Sowohl den Heatmaps in Abbildung 4.1 als auch den RMSE in Abbildung 4.2 nach zu urteilen, werden die Zeitreihen des Systems am besten durch *Clustering auf typische Tage*, *Segmentation* und *Downsampling* abgebildet. Die Fehler der aggregierten Zeitreihen sind am geringsten für mithilfe *Clustering auf typische Tage* und *Segmentation* reduzierte Zeitreihen. Ab einer minimalen zeitlichen Auflösung von etwa 3000 repräsentativen Zeitschritten weisen auch die durch *Downsampling* reduzierten Zeitreihen Fehler im ähnlichen Bereich auf.

In Übereinstimmung mit den Erkenntnissen der Untersuchung des RMSE weisen die Optimierungsergebnisse unter Verwendung von *Segmentation* insbesondere ab einer Betrachtung von

mindestens 1000 repräsentativen Stunden vergleichsweise kleine Abweichungen auf. Weiterhin ergeben sich durch Verwendung von *Clustering auf typische Tage*, wie durch die RMSE-Kurven in Abbildung 4.2 zu vermuten, weniger genaue Ergebnisse als durch Anwendung von *Segmentation*, jedoch genauere Ergebnisse im Vergleich zur Anwendung von *Clustering auf typische Wochen* und *Clustering auf typische Monate*. Im Widerspruch zu den Analysen des RMSE stehen die Optimierungsergebnisse der Rechnungen mit Reduktion der Zeitreihen anhand von *Downsampling*. Bereits ab einer Auflösung von unter 1000 berücksichtigten Zeitschritten ist eine hohe Genauigkeit der Ergebnisse gegeben, obwohl der RMSE vergleichsweise große Abweichungen der aggregierten Zeitreihen zu den originalen Zeitreihen anzeigt.

Die Kurvenformen der AOE (vgl. Abbildung 4.3) der Ergebnisse des *2-Level-Ansatzes* weisen unabhängig von der verwendeten Methode zur Reduktion der zeitlichen Komplexität einen ähnlichen Verlauf auf, der dem Ast einer Hyperbel mit dem Mittelpunkt im Ursprung entspricht. Dieser beinhaltet eine signifikante Überschätzung der Systemkosten im Bereich der kleinsten betrachteten zeitlichen Auflösungen. Für einige Methoden wie beispielsweise bei Reduktion der Zeitreihen mithilfe *Downsampling* weisen die Graphen der AOE der einstufigen Optimierung einen ähnlichen Verlauf auf. Für andere Methoden wie beispielsweise unter Verwendung von *Segmentation* ist im Bereich kleiner zeitlicher Auflösungen eine Unterschätzung des Zielfunktionswert nach einstufiger Optimierung festzustellen. In denselben Rechnungen ist in den entsprechenden Auflösungsbereichen eine Unterschätzung der Ausbaurkosten sowie gleichzeitig eine signifikante Überschätzung der marginalen Kosten der zweiten Optimierungsstufe zu beobachten (vgl. Abbildung 4.5).

Der Grund dafür, dass alle AOE-Kurven unter Verwendung des *2-Level-Ansatzes* einen ähnlichen Verlauf mit signifikanter Überschätzung im Bereich kleiner zeitlicher Auflösungen und Annäherung an das optimale Ergebnis der Referenzrechnung mit zunehmender zeitlicher Komplexität von oben hin aufweisen, ist, dass eine potentielle Unterschätzung der Ausbaurkosten durch eine Überschätzung der in der zweiten Optimierungsstufe berechneten marginalen Kosten des Systems ausgeglichen werden. Dahingegen bringt eine Unterschätzung der Ausbaurkosten eine Unterschätzung der marginalen Kosten der ersten Optimierungsstufe mit sich. Dies ergibt Sinn, da Ausbau und Einsatzplanung kombiniert optimiert werden.

Die Analyse der Ergebnisse zeigt, dass die mithilfe der aggregierten Zeitreihen ermittelten Systeme zwar auch mit den vollkomplexen Zeitreihen lösbar sind, jedoch ergeben sich zum Lösen des Optimierungsproblems deutlich höhere Systemkosten. Die marginalen Kosten der ersten und zweiten Optimierungsstufe unterscheiden sich in diesen Fällen signifikant. Grundsätzlich ist zu beobachten, dass die Optimierungsergebnisse eine hohe Genauigkeit aufweisen, wenn die marginalen Kosten der beiden Optimierungsstufen nah beieinander liegen.

Die explizite Berücksichtigung von Extremzeitschritten hat lediglich in kleineren zeitlichen Auflösungen eine Veränderung der Ergebnisse zur Folge. Das liegt daran, dass die anhand der Extremwerte der Residuallast identifizierten Extremzeitschritte im Bereich höherer zeitlicher Auflösungen mit größerer Wahrscheinlichkeit ohnehin als repräsentative Zeitschritte oder innerhalb von Clustern mit sehr ähnlichen repräsentativen Perioden berücksichtigt werden.

Die Beobachtungen nach Überprüfung der Zusammensetzung der Ausbaurkosten (Abbildung 4.5) und der Abbildung des Speicherverhaltens (Abbildung 4.6) weisen nur wenige Überein-

stimmungen hinsichtlich der Über- und Unterschätzung bestimmter Sektoren und Technologien auf. Die Ursache dafür liegt in der Verwendung des *2-Level-Ansatzes*. Dadurch ergeben sich, wie bereits oben erklärt wurde, insbesondere bei Unterschätzung des notwendigen Ausbaus Unterschiede in der Einsatzoptimierung der beiden Optimierungslevel. Grundsätzlich sind signifikante Unter- und Überschätzungen bestimmter Sektoren oder Technologien nur dann zu beobachten, wenn auch der Zielfunktionswert bzw. unter Verwendung des *2-Level-Ansatzes* dessen Äquivalent ungenau ist. Mit genügender Genauigkeit des Gesamtergebnisses ab einer minimalen zeitlichen Auflösung, die mit der Verwendung der verschiedenen Methoden variiert, stimmen auch die Zusammensetzung der Ausbaurkosten sowie die Auslastung der Speicher mit den Ergebnissen der vollkomplexen Referenzrechnung überein.

Grundsätzlich konnte durch Überprüfung der Speicherabbildung nachgewiesen werden, dass die Möglichkeit der Abbildung von Kurz- und Langzeitspeichern durch die Verwendung von *Clustering auf typische Tage*, *Segmentation* und *Downsampling* schon in vergleichsweise kleinen Auflösungen gegeben ist. Die deutlichsten Abweichungen zum Speicherverhalten in der Referenzrechnung ergeben sich in der Nutzung des Gasspeichers. Insbesondere fällt die Verschlechterung der Abbildung des Speicherverhaltens bei Anwendung von *Segmentation* in der höheren im Vergleich zur niedrigeren zeitlichen Auflösung ins Auge. Um zu überprüfen, ob es sich um eine Ausnahme oder ein Merkmal der Verwendung von *Segmentation* handelt, zeigt Abbildung A.5 die Nutzung des Gasnetzspeichers unter Anwendung von *Segmentation* in weiteren zeitlichen Auflösungen. Die Abbildung weist nach, dass es sich tatsächlich um eine Ausnahme handelt, die im Rahmen dieser Arbeit unerklärt bleibt.

Die Betrachtung der Rechenzeiten (Abbildung 4.7) zeigt, dass eine Reduktion der Rechenzeit über kleine zeitliche Auflösungen von etwa 1000 repräsentativen Stunden hinaus nur durch Verwendung von *Downsampling*, *Segmentation* und *Clustering auf typische Perioden* unter Anwendung des vereinfachten Ansatzes zur Verknüpfung typischer Perioden erreicht wird.

Bei Verwendung der klassischen Methode zur Verknüpfung der typischen Perioden nach Kotzur et al. (2018b) ergeben sich trotz der Reduktion der Zeitreihen in vielen Auflösungen Rechenzeiten, die deutlich höher als die Rechenzeit des vollkomplexen Referenzfalls sind. Das liegt daran, dass die Einführung der Nebenbedingungen die Komplexität des Optimierungsproblems maßgeblich erhöhen. Die Erhöhung ist abhängig von der Anzahl der Speichern im System, der Anzahl der Perioden, der Anzahl der Zeitschritte pro Periode und der Anzahl der typischen Perioden. Aus diesem Grund ergeben sich je nach betrachteten Zeitabschnitten unterschiedliche Rechenzeiten und keine konstant steigenden Rechenzeiten zunehmenden zeitlichen Auflösungen.

Durch Verwendung des vereinfachten Ansatzes erhöht sich die Anzahl der Variablen des Optimierungsproblems, aber die Anzahl der notwendigen Nebenbedingungen verringert sich. Aus diesem Grund ist die zur Optimierung benötigte Rechenzeit unter Verwendung des vereinfachten Ansatzes signifikant kleiner. Abbildung 4.8 zeigt weiterhin, dass sich unter Anwendung der vereinfachten Methode über ein großes Auflösungsspektrum hinweg zunehmende Rechenzeiten bei zunehmender zeitlicher Auflösung ergeben. Es ist ein etwa linearer Zusammenhang zwischen Reduktion der Rechenzeit und zeitlicher Komplexität des Optimierungsproblems zu beobachten. Dieses Erkenntnis ist wertvoll, da die Abschätzung von Rechenzeiten ermöglicht

wird. Allerdings ist fraglich, ob dieser Zusammenhang auch in höheren räumlichen Auflösungen besteht, da die Komplexität der Nebenbedingungen auch durch eine Erhöhung der räumlichen Komplexität steigt.

Das Reduktionspotential (vgl. Abbildung 4.8) ist unter Anwendung von *Downsampling* am größten, das Reduktionspotential bei Anwendung von *Segmentation* ist wenige Prozent reduziert, aber ebenfalls vergleichsweise hoch. Der Versatz der Kurven ist durch die notwendige Zeit zur Durchführung des Clusterings bei Anwendung von *Segmentation* zu erklären. Weil keinerlei zusätzliche Nebenbedingungen implementiert werden, reduziert sich die Komplexität des Optimierungsproblems unter Anwendung dieser Methoden analog zur Reduktion der zeitlichen Auflösung. Durch Betrachtung der halben Anzahl an berücksichtigten Zeitschritten halbiert sich die notwendige Zeit zur Optimierung in der ersten Stufe. Aus diesem Grund verläuft die Kurve der 1-Level Optimierung unter Anwendung von *Downsampling* von über 90 % bei sehr kleinen Auflösungen zu 0 % bei voller zeitlicher Komplexität.

Die Rechenzeit zur Durchführung der Einsatzoptimierung beträgt etwa 15 % der Referenzzeit und ist unabhängig von der zeitlichen Auflösung in der ersten Optimierungsstufe. Damit reduziert sich das Reduktionspotential über das gesamte Auflösungsspektrum um 15 %.

4.2.2 Bewertung der Methoden

Nach Untersuchung der Methoden anhand der Genauigkeit der Optimierungsergebnisse lassen sich die Verwendung von *Segmentation* und *Downsampling* als am besten geeignet für die Reduktion der zeitlichen Komplexität festhalten. Die in Abbildung 4.3 dargestellten Fehlerkurven erreichen den Fehlerbereich von 5 % bereits bei vergleichsweise kleinen zeitlichen Auflösungen von etwa 1000 repräsentativen Zeitschritten. Die Kurven zeigen ab dieser minimalen Auflösung weiterhin eine stetige Konvergenz zum Fehler von Null. Eine solche Konvergenzkurve ermöglicht eine bessere Nachvollziehbarkeit der Ergebnisse von Optimierungsproblemen, für die eine zeitlich vollkomplexe Berechnung nicht möglich ist.

Unter Anwendung von *Segmentation* und *Downsampling* ist keine generelle Unter- oder Überschätzung spezieller Sektoren oder Technologien zu beobachten. Die Zusammensetzung der Ausbaukosten sowie der Komponentenauslastung der Einsatzplanung weisen analog zur Genauigkeit des Endergebnisses schon in vergleichsweise kleinen Auflösungen die Verhältnisse auf, die sich durch Berechnung des zeitlich vollkomplexen Referenzfalls ergeben. Die weitestgehend korrekte Abbildung von kurz- und langfristigem Speicherverhalten unter Verwendung der Methoden innerhalb des *2-Level-Ansatzes* konnte nachgewiesen werden.

Insbesondere die Verwendung von *Clustering auf typische Monate* und *Clustering auf typische Wochen* scheint zur Anwendung in dem im Rahmen dieser Arbeit untersuchten System nicht geeignet zu sein. Die Verwendung dieser Methoden haben vergleichsweise hohe Abweichungen der Ergebnisse zur Folge. Zwar weist die Anwendung von *Clustering auf typische Tage* geringere Fehler auf, dennoch liegen diese über ein breites Auflösungsspektrum hinweg signifikant über den Abweichungen, die sich durch Anwendung von *Segmentation* und *Downsampling* ergeben. Der Fehlerbereich von 5 % wird unter Reduktion der Zeitreihen mithilfe von *Clustering auf typische Tage* erst bei einer minimalen zeitlichen Auflösung von etwa 3500

repräsentativen Zeitschritten erreicht. Weiterhin sind in der Fehlerkurve, die sich durch *Clustering auf typische Perioden* ergibt, Schwankungen festzustellen, die eine Abschätzung des Fehlers in komplexeren Rechnungen erschweren.

Die explizite Berücksichtigung von Extremzeitschritten hat nur in Einzelfällen eine Verbesserung der Genauigkeit zur Folge, allzu häufig erhöht sich der Fehler durch Anwendung dieser Variante. Grundsätzlich zeichnen sich die resultierenden Fehlerkurven durch deutlich stärkere Schwankungen aus. Weil die Lösbarkeit der Systeme auch ohne explizite Berücksichtigung der Extremzeitschritte gegeben und durch die Anwendung dieser Variante kein eindeutiger Mehrwert zu beobachten ist, ist die Anwendung nicht zu empfehlen.

Unabhängig von der Bewertung anhand der Genauigkeit der Optimierungsergebnisse, resultiert auch die Betrachtung der Reduktion der Rechenzeit in der Empfehlung der Verwendung von *Segmentation* und *Downsampling*. Durch Anwendung dieser Methoden wird über ein breites Auflösungsspektrum hinweg eine vergleichsweise hohe Reduktion der Gesamtrechenzeit erzielt.

Bei Anwendung von *Clustering auf typische Perioden* führt die Implementierung der notwendigen Nebenbedingungen zur Ermöglichung der Abbildung von korrektem Speicherverhalten über große Auflösungsbereiche hinweg sogar zu einer Erhöhung der Gesamtrechenzeit. Die Verwendung des vereinfachten Ansatzes zur Kopplung der typischen Perioden reduziert die Komplexität signifikant. Bei einer zeitlichen Auflösung von etwa 3500 repräsentativen Zeitschritten, die aufgrund der Genauigkeit der Optimierungsergebnisse als minimale zeitliche Auflösung zu empfehlen ist, ergibt sich unter Anwendung des *2-Level-Ansatzes* jedoch lediglich ein Reduktionspotential von etwa 10 % (vgl. Abbildung 4.8). Weiterhin ist der Zusammenhang zwischen der Reduktion der Rechenzeit und der zeitlichen Auflösung schlechter abzuschätzen, da die Komplexität der Nebenbedingungen abhängig ist von der Anzahl der Speicher im System, also von der räumlichen Komplexität. Es besteht die Gefahr, dass der in dieser Untersuchung beobachtete lineare Zusammenhang zwischen Reduktion der Rechenzeit und zeitlicher Auflösung wie bei *Clustering auf typische Perioden* unter Verwendung des klassischen Ansatzes zur Verknüpfung der Perioden in anderen Systemen nicht gilt.

Im Vergleich dazu ergeben sich unter Anwendung von *Segmentation* und *Downsampling* innerhalb des *2-Level-Ansatzes* im Bereich zwischen 1000 und 3000 repräsentativen Zeitschritten nach Abbildung 4.8 ein Reduktionspotential von 75 % bis 50 %. Weiterhin sind die notwendigen Rechenzeiten besser prognostizierbar, weil ein direkter Zusammenhang zwischen der Zeit zur Optimierung in der ersten Stufe und der Anzahl der betrachteten Zeitschritte besteht. Die Rechenzeitzuschläge für die Durchführung des Clusterings bei Anwendung von *Segmentation* und für die Durchführung der zweiten Optimierungsstufe sind über das volle Auflösungsspektrum konstant sind.

Die notwendige Zeit zur Durchführung des Clusterverfahrens für die Ermittlung der Segmente bei Anwendung von *Segmentation* ist abhängig von der räumlichen Komplexität des Systems, die maßgeblich die Anzahl der im Clusterverfahren zu berücksichtigenden Zeitreihen bestimmt. Es ist davon auszugehen, dass die Zeit in allen Fällen deutlich kleiner ist als die

notwendige Zeit zur Optimierung des zeitlich vollkomplexen Systems. Dennoch ist das Reduktionspotential durch Anwendung von *Segmentation* um einen von der räumlichen Komplexität des Systems abhängigen Prozentsatz geringer als bei Verwendung von *Segmentation*.

4.2.3 Bewertung des 2-Level-Ansatzes

Die Verwendung des *2-Level-Ansatzes* berücksichtigt die speziellen Anforderungen der Schnittstelle zwischen *eTraGo* und *eDisGo* (vgl. Kapitel 3.4). Im Folgenden soll der Ansatz weiterhin basierend auf den beschriebenen Ergebnissen bewertet werden.

Die Untersuchung der Genauigkeit der Optimierungsergebnisse verdeutlicht, dass die Verwendung des *2-Level-Ansatzes* in den meisten Fällen eine Verbesserung der Genauigkeit zur Folge hat. Dies gilt insbesondere innerhalb des nach Analyse der Ergebnisse als relevant identifizierten Auflösungsbereichs ab 1000 repräsentativer Zeitschritte. In keinem Fall hat die Durchführung der zweiten Optimierung in diesem Auflösungsbereich zu einer Verschlechterung der Genauigkeit geführt.

Die Anwendung des *2-Level-Ansatzes* bewirkt die Vereinheitlichung der Form der Fehlerkurven in Abbildung 4.3. Die Ergebnisse nähern sich einheitlich mit ähnlichem Verlauf von oben an einen Fehler von Null an. Das Wissen um diese Fehlerkonvergenz ermöglicht eine bessere Abschätzung der Genauigkeit von Ergebnissen in komplexeren Systemen.

Die Lösbarkeit des mithilfe der in der zeitlichen Komplexität reduzierten Inputdaten optimierten Netzkonfiguration mit den originalen Zeitreihen stellt ein Gütekriterium für die angewandte Methode zur Reduktion der zeitlichen Komplexität dar. Weiterhin ergeben sich durch Anwendung des *2-Level-Ansatzes* und den Vergleich der Optimierungsergebnisse der ersten und zweiten Optimierung neue Strategien zur Analyse der Ergebnisse und möglichen Abschätzung der Genauigkeiten. Eine potentielle Unterschätzung des Systemausbaus nach der ersten Optimierungsstufe wird durch eine signifikante Überschätzung der marginalen Kosten in der zweiten Optimierungsstufe ausgeglichen, sodass die marginalen Kosten der ersten und zweiten Optimierungsstufe in diesem Fall stark divergieren. Die Betrachtung der marginalen Kosten der beiden Optimierungsstufen kann deshalb auf die Genauigkeit der Ergebnisse hinweisen. Das ist besonders wertvoll, wenn die Durchführung zeitlich vollkomplexer Referenzrechnungen aufgrund der räumlichen Komplexität des Systems nicht möglich ist.

Die notwendige Rechenzeit zur Optimierung der Einsatzplanung anhand der vollkomplexen Zeitreihen ist in allen Rechnungen in etwa konstant und im Verhältnis zur Gesamtrechenzeit klein. Die Anwendung des *2-Level-Ansatzes* verringert das Reduktionspotential der verschiedenen Methoden in diesen Rechnungen um 15 %. Grundsätzlich ist die notwendige Zeit zur Durchführung der Einsatzoptimierung basierend auf den vollkomplexen Zeitreihen abhängig von der räumlichen Auflösung des Systems. Es ist davon auszugehen, dass sie in jedem Fall nur einen kleinen Anteil der benötigten Rechenzeit zur kombinierten Optimierung von Netzausbau und Komponenteneinsatz betragen wird und das Reduktionspotential deshalb nur in geringem Maße verringert.

Die Verwendung des *2-Level-Ansatzes* ist deshalb zu empfehlen.

5 Anwendung ausgewählter Methoden in eTraGo

Nach Untersuchung der Methoden zur Reduktion der zeitlichen Komplexität anhand des Minimalbeispiels scheinen die Anwendung von *Segmentation* und *Downsampling* am vielversprechendsten zur adäquaten Reduktion der zeitlichen Komplexität in *eTraGo*. Deshalb soll die Anwendbarkeit dieser Methoden überprüft werden. Auf eine ausführliche Auswertung der Optimierungsergebnisse wird verzichtet, da sowohl das verwendete Tool *eTraGo* als auch das zugrundeliegende Modell zum Zeitpunkt der Erstellung der Arbeit noch in Entwicklung sind.

Das im Rahmen dieser Arbeit betrachtete Datenmodell zeichnet sich im Vergleich zum Minimalbeispiel durch seine hohe räumliche Komplexität aus. Damit erhöht sich die Anzahl der im System vorhandenen Attributzeitreihen. Der Rechenaufwand zur Durchführung von *Segmentation* steigt damit. Es gilt zu überprüfen, welchen Einfluss die Erhöhung der Komplexität auf die notwendige Zeit zur Aggregation der Zeitreihen nimmt. Weiterhin ist die notwendige Rechenzeit zur Optimierung der Einsatzplanung anhand der originalen Zeitreihen im Rahmen des *2-Level-Ansatzes* zu prüfen.

Aus den Untersuchungen im Minimalbeispiel ist eine zeitliche Auflösung von 1000 repräsentativen Zeitschritten als minimale zu betrachtende Auflösung abzuleiten. Um die Methoden anhand verschiedener zeitlicher Auflösungen zu überprüfen, werden Rechnungen im Bereich von etwa 800 bis 3000 berücksichtigten Stunden durchgeführt. Für beide Methoden werden in etwa die gleichen zeitlichen Auflösungen ausgewählt. Die weiteren Einstellungen und Rechenbedingungen sind in Kapitel 3.5 nachzulesen.

Im Folgenden sollen zuerst die Ergebnisse dargestellt und anschließend diskutiert werden.

5.1 Darstellung der Ergebnisse

Zunächst werden kurz die Optimierungsergebnisse betrachtet und anschließend die Rechenzeit analysiert.

5.1.1 Betrachtung der Optimierungsergebnisse

Abbildung 5.1 zeigt die Optimierungsergebnisse der Rechnungen der mithilfe *Segmentation* reduzierten Komplexität oben und der mithilfe *Downsampling* reduzierten Komplexität unten. Die vergleichbaren zeitlichen Auflösungen sind direkt übereinander dargestellt. In beiden Diagrammen sind rechts die Ergebnisse der zeitlich vollkomplexen Referenzrechnung abgebildet. Es sind die Zusammensetzung der Systemkosten nach Gleichung 3.1 bzw. Gleichung

3.14 (*2-Level-Ansatz*) aus Ausbaurkosten und marginalen Kosten abgebildet (vgl. Kapitel 3.6). Weiterhin sind die marginalen Kosten der ersten Optimierungsstufe markiert. Die Kostenangaben sind mit der linken y-Achse gegeben, während anhand der rechten Achse die AOE nach Gleichung 3.13 (vgl. Kapitel 3.6.2) abzulesen sind.

Alle erzeugten Ergebnisse liegen sehr nah an den Ergebnissen der Referenzrechnung. Das gilt für die Systemkosten an sich als auch für deren Zusammensetzung aus Ausbaurkosten und marginalen Kosten. Die marginalen Kosten der ersten und zweiten Optimierungsstufe sind weiterhin sehr ähnlich. Die sich ergebenden AOE liegen in einem Bereich zwischen 0,05 % und 0,4 %.

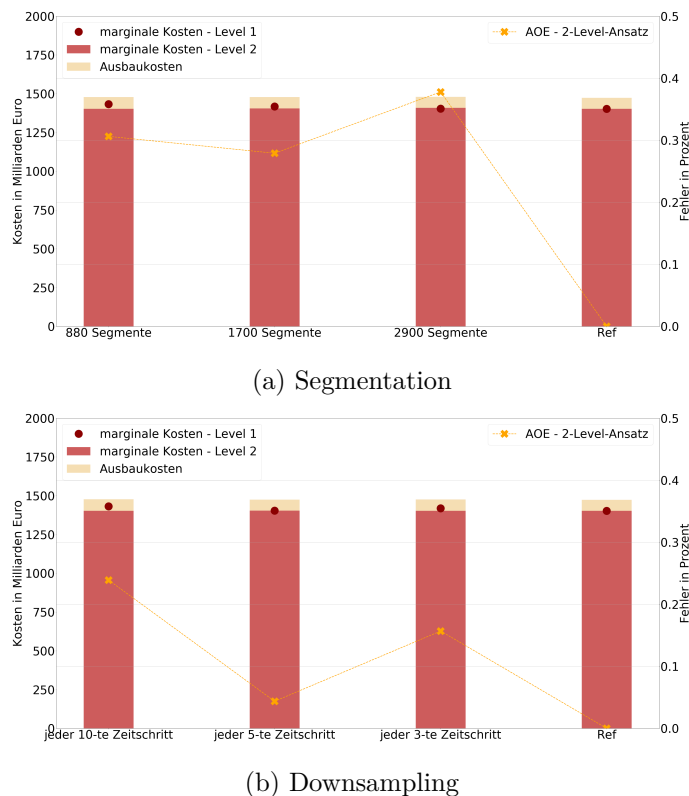


Abbildung 5.1: Darstellung der Systemkosten sowie des AOE

5.1.2 Betrachtung der Rechenzeit

Abbildung 5.2 stellt die für die durchgeführten Rechnungen benötigten Rechenzeiten dar. Die vertikalen Abtrennungen markieren die Rechnungen mit etwa gleicher zeitlicher Auflösung. Ganz rechts ist die Rechenzeit der zeitlich vollkomplexen Referenzrechnung dargestellt. Die Rechenzeiten der Rechnungen mit Reduktion der zeitlichen Komplexität setzen sich aus den notwendigen Zeiten zur Aggregation der Zeitreihen und den Rechenzeiten der ersten und zweiten Optimierungsstufe zusammen.

Grundsätzlich ergeben sich unter Anwendung der Methoden deutlich kürzere Rechenzeiten als ohne Reduktion der zeitlichen Komplexität. Weiterhin nehmen die Zeiten mit zunehmender zeitlicher Auflösung zu.

Die Rechenzeiten unter Verwendung von *Segmentation* liegen für die gleichen betrachteten zeitlichen Auflösungen höher als bei Reduktion mittels *Downsampling*. Die Ursache dafür ist die notwendige Zeit zur Aggregation der Zeitreihen. Unter Anwendung von *Segmentation* ergibt sich zur Durchführung der Reduktion eine über die verschiedenen betrachteten zeitlichen Auflösungen hinweg etwa konstante, zusätzlich benötigte Zeit, die die Gesamtrechenzeit im Vergleich zur Reduktion mithilfe *Downsampling* erhöht.

Die Rechenzeiten zur Optimierung in der ersten Optimierungsstufe sind unter Anwendung beider Methoden pro betrachtete zeitliche Auflösung etwa gleich groß. Die Rechenzeit erhöht sich mit Zunahme der zeitlichen Komplexität.

Die Rechenzeiten zur Optimierung des Komponenteneinsatzes mithilfe der vollkomplexen Zeitreihen ist für alle durchgeführten Rechnungen etwa konstant. Die Zeit trägt zur Erhöhung der Gesamtrechenzeit bei, ist im Vergleich zur notwendigen Zeit für die Optimierung des zeitlich vollkomplexen Referenzfalls aber deutlich kleiner.

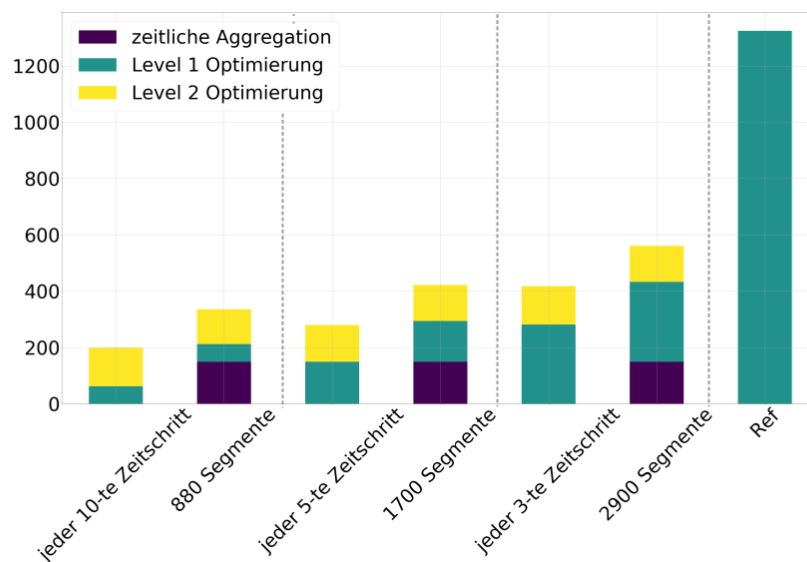


Abbildung 5.2: Darstellung der Rechenzeit

Es ergeben sich die in Abbildung 5.3 dargestellten Verläufe des ATR nach Gleichung 3.15 (vgl. Kapitel 3.6.3). Die Abbildung zeigt die Reduktion der Rechenzeit in Abhängigkeit der zeitlichen Auflösung. Es wird unterschieden zwischen der Anwendung eines *2-Level-Ansatzes* und der Durchführung einer einstufigen Optimierung.

Es wird der lineare Zusammenhang zwischen der zeitlichen Auflösung und der Reduktion der Rechenzeit deutlich. Durch die Anwendung des *2-Level-Ansatzes* reduziert sich das Reduktionspotential der Methoden um etwa 10%. Unter Anwendung von *Downsampling* im *2-Level-Ansatz* wird die Gesamtrechenzeit im betrachteten Auflösungsspektrum zwischen 73% und 85% reduziert. Bei Reduktion der Zeitreihen mittels *Segmentation* ist das Reduktionspotential um 10% geringer, sodass sich die Rechenzeiten bei Anwendung des *2-Level-Ansatzes* im betrachteten Auflösungsbereich um 63% bis 75% reduzieren.

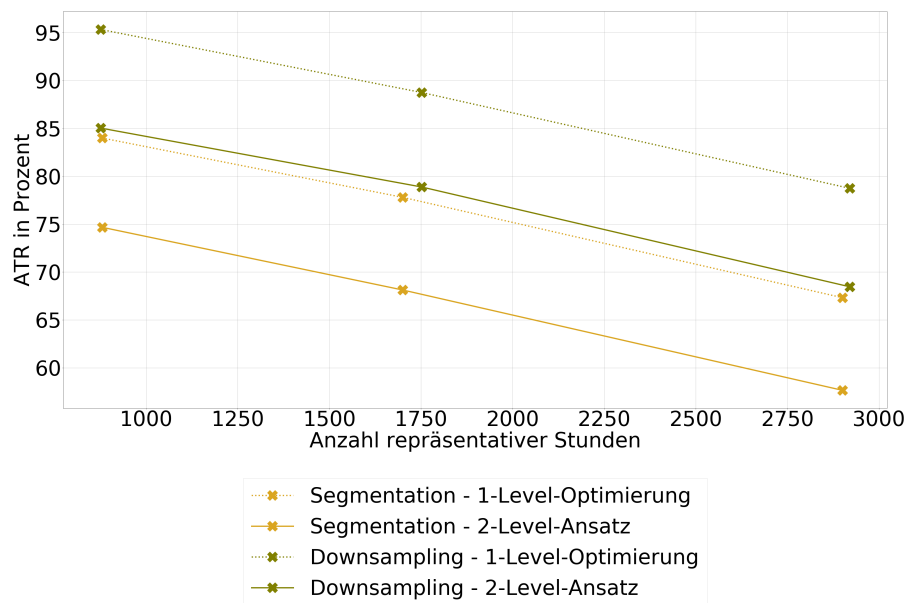


Abbildung 5.3: Darstellung des ATR

5.2 Diskussion der Ergebnisse

Durch Anwendung der Methoden zur Reduktion der zeitlichen Komplexität wird der Netz- und Speicherausbau in den durchgeführten Rechnungen weder wesentlich unter- noch überschätzt. Entsprechend den Beobachtungen aus 4.2 sind die marginalen Kosten der beiden Optimierungsstufen sehr ähnlich.

Insgesamt weisen die Ergebnisse eine sehr hohe Genauigkeit auf. Im Vergleich zu den Ergebnissen der Anwendung der Methoden im Minimalbeispiel sind die induzierten Fehler in dem betrachteten Auflösungsspektrum deutlich kleiner. Möglicherweise liegt die Ursache in der Reduktion der räumlichen Komplexität, die die Aggregation und damit die Veränderung der Attributzeitreihen pro Knotenpunkt zur Folge hat. Anscheinend sind die Ergebnisse unter Betrachtung eines räumlich komplexeren Systems weniger sensitiv auf Veränderungen der zeitlichen Inputdaten. Unter Umständen ergeben sich diese hohen Genauigkeiten auch nur aufgrund bestimmter Charakteristiken des unfertigen Datenmodells oder Tools. So ist beispielsweise der Anteil der Einspeisung durch erneuerbare Energien in der verwendeten Version des Datenmodells geringer, als dieser im fertigen Datenmodell sein wird, weil potentielle Einspeisezeitreihen erneuerbarer Erzeugungseinheiten fehlen. Inwieweit sich die Beobachtungen für weitere Berechnungen des räumlich hochauflösten Datenmodell in *eTraGo* bestätigen, ist anhand weiterer Untersuchungen mit dem fertiggestellten Datenmodell und Tool und insbesondere anhand einer Sensitivitätsanalyse der räumlichen Auflösung zu überprüfen.

Die Betrachtungen der Rechenzeiten sowie der Reduktion der Rechenzeiten im Vergleich zur Referenzzeit zeigen, dass die Verwendung von *Segmentation* und *Downsampling* im betrachteten Auflösungsspektrum große Reduktionspotentiale aufweisen. Die Reduktion der Gesamtrechenzeit ist in den entsprechenden Auflösungsbereichen größer als in den Untersuchungen

anhand des Minimalbeispiels. Die Unterschiede der Reduktionspotentiale haben verschiedene Ursachen.

Zum Einen wird im Falle der Kurven, die dem *Downsampling* zuzuordnen sind, deutlich, dass die Durchführung der zweiten Optimierungsstufe eine Verminderung der Reduktion um 10 % zur Folge hat, weil die Durchführung dieser Optimierung etwa 10 % der Referenzzeit beansprucht. Im Minimalbeispiel ergeben sich an dieser Stelle 15 % Verminderung. Die Optimierung der zweiten Stufe braucht also - relativ gemessen an der Referenzzeit - mehr Rechenzeit. Grundsätzlich ist die notwendige Zeit zur Optimierung des Komponenteneinsatzes basierend auf den vollkomplexen Zeitreihen maßgeblich von der räumlichen Komplexität abhängig. Dass die Optimierung im Minimalbeispiel relativ zur Referenzzeit dennoch mehr Zeit in Anspruch nimmt, liegt mutmaßlich an den Solvereinstellungen. Die Einstellungen zur Optimierung im Minimalbeispiel sind andere als die Einstellungen zur Optimierung in *eTraGo* (vgl. Kapitel 3.5.1).

Zum Anderen vermindert sich das Reduktionspotential unter Anwendung von *Segmentation* weiterhin zusätzlich durch die zur Aggregation der Zeitreihen benötigte Zeit. Diese Zeit beträgt unabhängig von der zeitlichen Auflösung in den Rechnungen mit *eTraGo* etwa 10 % der Referenzzeit, während sie im Minimalbeispiel zirka 5 % der Referenzzeit beträgt. Grundsätzlich ist auch diese Rechenzeit abhängig von der räumlichen Komplexität, die die Anzahl der im Clusterverfahren zu berücksichtigenden Zeitreihen vorgibt.

Grundsätzlich wird deutlich, dass die zur Optimierung in der zweiten Stufe des *2-Level-Ansatzes* notwendige Rechenzeit im Verhältnis zur Referenzzeit deutlich kleiner und die resultierende Verminderung des Reduktionspotentials akzeptabel ist, sodass der *2-Level-Ansatz* auch für die Anwendung im räumlich hochaufgelösten Modell zur Optimierung in *eTraGo* empfohlen wird. Weiterhin wird die deutlich, dass die Verwendung von *Downsampling* insbesondere bei Betrachtung räumlich komplexer Systeme besseres Reduktionspotential aufweist.

6 Diskussion der Methodik und Ergebnisse

In diesem Kapitel werden die Ergebnisse der Untersuchung der Methoden anhand des Minimalbeispiels (vgl. Kapitel 4) und der Rechnungen mit dem komplexen Datenmodell in *eTraGo* (vgl. Kapitel 5) in den Stand der Wissenschaft eingeordnet. Außerdem wird die im Rahmen dieser Arbeit verwendete Methodik (vgl. Kapitel 3) kritisch betrachtet.

6.1 Einordnung in den Stand der Wissenschaft

In Übereinstimmung mit vielen weiteren Arbeiten (z. B. Hoffmann, Priesmann et al. (2021) und Teichgraber und Brandt (2022)) wird anhand der im Rahmen dieser Arbeit durchgeführten Untersuchung deutlich, dass diejenigen Methoden, die die originalen Zeitreihen beispielsweise gemessen am RMSE am besten abbilden, nicht unbedingt die Methoden sind, die die geringsten Abweichungen der Optimierungsergebnisse aufweisen (vgl. Kapitel 4.2). Das ist insbesondere bei Betrachtung der Ergebnisse unter Verwendung von *Downsampling* zu beobachten, die in der in Kapitel 4 dargestellten Untersuchung in sehr kleinen zeitlichen Auflösungen bereits hohe Genauigkeiten aufweisen, während der RMSE in den gleichen Auflösungen vergleichsweise hohe Abweichungen der aggregierten Zeitreihen von den originalen Zeitreihen anzeigt.

Die Erhöhung der Rechenzeit durch Anwendung von *Clustering auf typische Perioden* aufgrund der notwendigen Nebenbedingungen zur Verknüpfung der typischen Perioden nach Kotzur et al. (2018b) wird analog zu den vorliegenden Ergebnissen (vgl. Kapitel 4.2) auch in weiteren Arbeiten beobachtet (Büttner (2020), Raventós (2018), Viole (2020)). Wie in der Arbeit von Raventós (2018) ermöglicht die Anwendung des vereinfachten Ansatzes nach Kotzur et al. (2018b) eine Verbesserung dieser Problematik.

In den Arbeiten von Pineda und Morales (2018), Raventós und Bartels (2020) und Viole (2020) wird die Anwendung von *Segmentation* und *Clustering auf typische Tage* in räumlich hochaufgelösten Energiesystemmodellen verglichen. Die Arbeit von Pineda und Morales (2018) berücksichtigt die Kopplung typischer Perioden durch einen vereinfachten Ansatz, während die typischen Perioden in den anderen beiden Arbeiten nach dem in der vorliegenden Arbeit verwendeten Ansatz von Kotzur et al. (2018b) verknüpft werden. Dass Nebenbedingungen zur Abbildung des Speicherverhaltens bei Verwendung des *Clusterings auf typische Perioden* berücksichtigt werden, ist wichtig, weil die Speicher im in der vorliegenden Arbeit betrachteten System eine hohe Relevanz haben und die Ergebnisse sonst schlecht vergleichbar sind. In den Arbeiten von Raventós und Bartels (2020) und Viole (2020) wird *eTraGo* zur Optimierung verwendet. Das betrachtete Modell in der Untersuchung von Raventós und Bartels

(2020) entspricht dem elektrischen Modell der Hoch- und Höchstspannungsebene in Schleswig-Holstein und zeichnet sich durch einen hohen Anteil der Einspeisung durch Windkraftanlagen aus. Das in der Arbeit von Violen (2020) optimierte System beinhaltet den elektrischen Sektor sowie eine im Vergleich zu dieser Arbeit vereinfachte Abbildung des Gassektors. In Übereinstimmung mit den Ergebnissen dieser Arbeit wird in beiden Arbeiten die Verwendung von *Segmentation* präferiert. Zwar liegen die durch Verwendung der Methoden induzierten Fehler in einem ähnlichen Bereich, jedoch konvergieren die Fehler unter Anwendung von *Segmentation* besser nachvollziehbar zu Null. Weiterhin lassen sich die Rechenzeiten besser reduzieren. Diese Beobachtungen decken sich mit den Ergebnissen der vorliegenden Arbeit.

Clustering auf typische Perioden und *Segmentation* werden in einer Vielzahl aktueller Arbeiten untersucht, sodass diese Methoden, die der Kategorie der eigenschaftsbasierten Methoden zuzuordnen sind, in der Übersichtsarbeit von Hoffmann et al. (2020) als besonders relevant eingeordnet werden. Es sind jedoch kaum aktuelle Arbeiten zu finden, die eigenschaftsbasierte Methoden mit zeitbasierten Methoden wie *Downsampling* vergleichen. Lediglich in der Arbeit von Pfenninger (2017) ist das der Fall. In dieser Arbeit schneidet die Verwendung von *Downsampling* im Vergleich zu den weiteren untersuchten Methoden weder wesentlich schlechter noch wesentlich besser ab, allerdings unterscheiden sich die Anwendungsfälle dieser Arbeit deutlich von dem im Rahmen der vorliegenden Arbeit betrachteten Energiesystemmodell. Grundsätzlich scheint der Wert der Reduktion der zeitlichen Komplexität mittels *Downsampling* in aktuellen Arbeiten unterschätzt zu werden.

Die Motivation der Verwendung des *2-Level-Ansatzes* ist die Berücksichtigung der speziellen Anforderungen der Schnittstelle zwischen *eTraGo* und *eDisGo* (vgl. Kapitel 3.2). Durch die Analyse der Auswirkungen des *2-Level-Ansatzes* auf die Optimierungsergebnisse und den Vergleich der Ergebnisse der Optimierungsstufen, ergeben sich zusätzlich neue Strategien zur Abschätzung der Genauigkeit der Ergebnisse einer unter Reduktion der zeitlichen Komplexität durchgeführten Optimierung. Diese Ausnutzung des *2-Level-Ansatzes* weist Parallelen zur üblichen Verwendung mehrstufiger Optimierungsverfahren auf. So werden in Bahl et al. (2018) und Baumgärtner et al. (2019) die Systeminformationen einer ersten Optimierungsstufe zur Aggregation der Zeitreihen genutzt und die Abweichungen von Ergebnissen aus verschiedenen Optimierungsdurchläufen begrenzt.

6.2 Kritische Betrachtung der Methodik

Grundsätzlich hat die Verwendung eines Minimalbeispiels zur Untersuchung der Anwendbarkeit der Methoden einige Vorteile. Die geringere Komplexität des Systems ermöglicht einen besseren Überblick über die verschiedenen Attributzeitreihen, die Wirkung der Reduktionsmethoden auf die diese Zeitreihen und die Auswirkungen der Aggregation auf die Optimierungsergebnisse. Weiterhin können viele Rechnungen in verschiedenen zeitlichen Auflösungen in vergleichsweise kurzer Zeit durchgeführt werden. Durch kleinschrittige Erhöhung der zeitlichen Auflösung bis zur vollen Auflösung lassen sich genaue Fehlerkonvergenzlinien über das gesamte Auflösungspektrum ableiten. Diese Fehlerkonvergenzlinien sind - sofern sie übertragbar sind - wertvoll für die Abschätzung von Genauigkeiten in komplexeren Systemen.

Weiterhin dient die Anwendung der Methoden in voller zeitlicher Auflösung (z. B. ein Jahr durch *Clustering auf typische Tage* als 365 Tage) zur Verifikation der Implementierung der entsprechenden Methoden oder ggf. notwendiger Nebenbedingungen.

Die Voraussetzung dafür, dass die Erkenntnisse der Untersuchungen anhand eines Minimalbeispiels übertragbar sind auf das komplexe Energiesystemmodell, ist die Übereinstimmung der Inputdaten und der mathematischen Struktur des Optimierungsproblems. Deshalb ist das Modellierungskonzept des Minimalbeispiels analog zu dem Modellierungskonzept in *eTraGo* ausgewählt. Bei den im Minimalbeispiel verwendeten Attributzeitreihen handelt es sich außerdem um Zeitreihen des im Rahmen dieser Arbeit betrachteten Datenmodells.

Das Aussparen des Mobilitätssektors sollte keinen großen Einfluss nehmen, da die Berücksichtigung lediglich eine zusätzliche Flexibilitätsoption in Analogie zur Modellierung von DSM abbildet und keine neuen Arten von Komponenten oder Ansätzen hinzugefügt werden. Allerdings beinhaltet die Berücksichtigung des Mobilitätssektors auch die Berücksichtigung zusätzlicher Lastzeitreihen mit tendenziell repetitiven Mustern über den Tag. Da im Minimalbeispiel jedoch ohnehin nur eine zusätzliche Attributzeitreihe berücksichtigt worden wäre und die charakteristischen Merkmale auch in anderen Attributzeitreihen abgebildet sind, ist davon auszugehen, dass sich die Ergebnisse kaum verändern würden.

Grundsätzlich konnten durch die Untersuchung der Methoden anhand des Minimalbeispiels wertvolle Erkenntnisse gewonnen werden. Es ist davon auszugehen, dass sich die nach Untersuchung anhand des Minimalbeispiels ausgewählten Methoden auch im komplexen System besser eignen als die anderen betrachteten Methoden. Das ist insbesondere der Fall, weil die Ergebnisse der Untersuchung der Rechenzeit auch auf räumlich hochaufgelöste Systeme übertragbar sind und die ausgewählten Methoden höhere Reduktionspotentiale aufweisen. Es ist anzunehmen, dass die Fehlerkonvergenzlinien in ihrem Verlauf übertragbar sind und dass eine genügende Genauigkeit des Zielfunktionswerts (bzw. des Äquivalents) eine genügend Genauigkeit der Berücksichtigung der verschiedenen Sektoren und Technologien und der Abbildung des Speicherverhaltens beinhaltet. Weiterhin sind die Strategien zur Einschätzung der Genauigkeit der Ergebnisse durch den Vergleich der Ergebnisse der Optimierungsstufen des *2-Level-Ansatzes* anwendbar.

Nichtsdestotrotz können die Untersuchungen anhand des Minimalbeispiels weitere Untersuchungen im räumlich hochaufgelösten Modell nicht ersetzen. Mithilfe dieser gewonnenen Erkenntnisse gilt es, die Anwendung der ausgewählten Methoden im räumlich aufgelösten System zu untersuchen, um die Übertragbarkeit der Ergebnisse nachzuweisen und die im komplexen Modell erreichbaren Genauigkeiten abzuschätzen.

So wird das Verhältnis der Anteile der Zeitreihen mit bestimmten Charakteristiken innerhalb der Gesamtanzahl der Zeitreihen (z. B. Anteil der Zeitreihen mit repetitiven Mustern über den Tag im Verhältnis zu Zeitreihen mit saisonalen Muster) erst durch Betrachtung im räumlich aufgelösten System deutlich. Wie in den Kapiteln 2 und 3.2 erklärt, besteht weiterhin eine Abhängigkeit zwischen räumlicher und zeitlicher Komplexität. Die räumliche Auflösung bestimmt die Anzahl der zu berücksichtigenden Zeitreihen. Durch Reduktion der räumlichen Komplexität werden einzelne Zeitreihen zusammengefasst, sodass sich die zeitlichen Inputdaten des Systems verändern. Deshalb ist insbesondere die Sensitivität der Reduktion der

zeitlichen Komplexität auf die räumliche Komplexität bzw. die Reduktion der räumlichen Komplexität zu überprüfen.

Die im Rahmen dieser Arbeit angewandte Methodik erlaubt also den Vergleich von Methoden hinsichtlich ihrer Eignung zur Reduktion der zeitlichen Komplexität für die Optimierung sektorgekoppelter Energiesysteme und die Empfehlung ausgewählter Methoden. Außerdem vereinfachen die Erkenntnisse der Untersuchung anhand des Minimalbeispiels die notwendigen Analysen im räumlich hochaufgelösten Modell. Die grundsätzliche Anwendbarkeit der Methoden sowie der Verwendung des *2-Level-Ansatzes* konnte nachgewiesen werden. Die Bewertung der Auswirkungen der Anwendung dieser Methoden auf die Genauigkeit der Optimierungsergebnisse in einem räumlich hochaufgelösten sektorgekoppelten Energiesystemmodell und insbesondere der Sensitivität auf die Reduktion der räumlichen Komplexität bleibt jedoch aus.

7 Fazit und Ausblick

Nach Untersuchung der Methoden anhand des Minimalbeispiels stellt sich die Anwendung von *Segmentation* und *Downsampling* für die Reduktion der zeitlichen Komplexität zur Optimierung des sektorgekoppelten Energiesystemmodells in *eTraGo* als am besten geeignet heraus (vgl. Kapitel 4). Im Vergleich zu den restlichen untersuchten Methoden werden ab einer zeitlichen Auflösung von etwa 1000 repräsentativen Zeitschritten gute Genauigkeiten erreicht. Das Potential zur Reduktion der Rechenzeit ist bei diesen Methoden am größten. Weiterhin zeichnen sich sowohl die Fehlerkonvergenzkurven als auch die Reduktion der Rechenzeit in Abhängigkeit der zeitlichen Auflösung durch gute Nachvollziehbarkeit aus.

Außerdem empfiehlt sich die Anwendung des *2-Level-Ansatzes*. Außer der Berücksichtigung der speziellen Anforderungen der Schnittstelle zwischen *eTraGo* und *eDisGo*, bewirkt die Anwendung in den betrachteten Rechnungen meist eine Verbesserung der Genauigkeit (und in den relevanten Auflösungsbereichen in keinem Fall eine wesentliche Verschlechterung) sowie die Vereinheitlichung der Fehlerkonvergenzkurve, die sich mit zunehmender Komplexität von oben an einen Fehler von Null annähert. Weiterhin stellt die Lösbarkeit der mithilfe der reduzierten Zeitreihen optimierten Netzkonfiguration ein Gütekriterium für die verwendete Methode dar. Zusätzlich ergeben sich durch den Vergleich der Optimierungsergebnisse der ersten und zweiten Optimierungsstufen neue Möglichkeiten zur Abschätzung der Genauigkeit der Ergebnisse ohne den Vergleich mit einer zeitlich vollkomplexen Referenzrechnung. Demgegenüber steht eine Verminderung der Reduktion um einen von der räumlichen Komplexität des Systems abhängigen Offset. Weil davon auszugehen ist, dass die Rechenzeit zur Optimierung in der zweiten Stufe wesentlich kleiner ist als die Rechenzeit zur kombinierten Optimierung von Ausbau und Einsatz im zeitlich vollkomplexen System, ist mit einer Verringerung des Reduktionspotentials in akzeptablen Maßen zu rechnen.

Durch die in Kapitel 5 beschriebenen Rechnungen konnte die Anwendbarkeit der Methoden sowie des *2-Level-Ansatzes* für die Optimierung des räumlich hochaufgelösten Datenmodells in *eTraGo* nachgewiesen werden.

Für eine Bewertung der Methoden anhand der Genauigkeit der Ergebnisse nach Reduktion der zeitlichen Komplexität sind das Datenmodell und Tool fertigzustellen und zusätzliche Berechnungen in verschiedenen räumlichen Auflösungen durchzuführen. Die in der vorliegenden Arbeit erzeugten Ergebnisse deuten darauf hin, dass die Anwendung von *Segmentation* und *Downsampling* die Erhaltung einer hohen Genauigkeit ermöglichen.

Unter Anwendung der Methoden im räumlich aufgelösten Modell wird deutlich, dass die Verwendung von *Downsampling* die Reduktion der Zeitreihen mittels *Segmentation* gemessen an der Reduktion der Rechenzeit aufgrund des Offsets, der sich durch die zur Aggregation der Zeitreihen notwendige Rechenzeit ergibt, übertrifft. Sowohl der Rechenzeitzuschlag, der sich

bei Anwendung von *Segmentation* aufgrund der Aggregation ergibt, als auch der Zuschlag, der sich durch die zweite Optimierungsstufe des *2-Level-Ansatzes* ergibt, sind abhängig von der räumlichen Komplexität des Systems und im Vergleich zur notwendigen Rechenzeit zur zeitlich vollkomplexen Optimierung des Energiesystems deutlich kleiner. Aus diesem Grund ergibt sich dennoch ein genügend großes Reduktionspotential.

Die Ergebnisse der vorliegenden Arbeit hinsichtlich der Anwendung von *Segmentation*, *Clustering auf typische Perioden* und der Verwendung des *2-Level-Ansatzes* stimmen mit den Ergebnissen vergleichbarer Studien überein. Der Wert der Reduktion der zeitlichen Komplexität mittels *Downsampling* scheint in aktuellen Arbeiten unterschätzt zu werden.

Die im Rahmen der Arbeit angewandte Methodik erlaubt die Empfehlung einer Methode zur Anwendung in sektorgekoppelten Energiesystemen. Die Bewertung der Auswirkungen der Anwendung auf die Genauigkeit des speziellen Systems bleibt jedoch insbesondere hinsichtlich der betrachteten räumlichen Komplexität zu untersuchen. Durch die in der vorliegenden Untersuchung gewonnen Erkenntnisse werden die notwendigen Untersuchungen und die Abschätzung der Auswirkungen vereinfacht.

Die Forschungsfragen lassen sich damit wie folgt beantworten:

1. Welche Methode eignet sich am besten zur Reduktion der zeitlichen Komplexität für die Optimierung des betrachteten, räumlich hochaufgelösten, sektorgekoppelten Energiesystemmodells in *eTraGo*?

Es wird die Verwendung von *Downsampling* oder *Segmentation* innerhalb des beschriebenen *2-Level-Ansatzes* empfohlen. Insbesondere unter Betrachtung hoher räumlicher Auflösungen ergibt sich durch Anwendung von *Downsampling* höheres Reduktionspotential. Eine ausführliche Auswertung der Beeinflussung der Genauigkeit der Ergebnisse im räumlich hochaufgelösten Modell bleibt ausstehend.

2. Welche minimale zeitliche Auflösung ist bei Anwendung der ausgewählten Methode festzulegen?

Es wird bei einer Betrachtung eines Jahres in stündlicher Auflösung (8760 Zeitschritte) eine Berechnung von mindestens etwa 1000 Zeitschritten empfohlen. Ob diese minimale Auflösung ausreicht, um eine genügende Genauigkeit der Ergebnisse im räumlich hochaufgelösten Modell zu ermöglichen, bleibt zu untersuchen.

3. Ist der beschriebene *2-Level-Ansatz* in dem betrachteten räumlich und zeitlich hochaufgelösten Energiesystemmodell zur Optimierung in *eTraGo* anwendbar?

Der beschriebene *2-Level-Ansatz* ist unter Verminderung des Reduktionspotentials um einen akzeptablen Prozentsatz anwendbar.

4. Wie wirkt sich die Verwendung des *2-Level-Ansatzes* mit zweistufiger Optimierung im Vergleich zu einer einstufigen Optimierung auf die Ergebnisse aus?

Die Anwendung hat eine Vereinheitlichung der Fehlerkonvergenzlinie zur Folge. Aufgrund der ausgleichenden Wirkung der Ergebnisse der zweiten Optimierungsstufe bei

Unterschätzung des Systemausbaus während der ersten Optimierungsstufe, nähern sich die Fehler einheitlich von oben an einen Fehler von Null an. Ein Indikator für genaue Ergebnisse ist deshalb die Differenz zwischen den marginalen Kosten der beiden Optimierungsstufen. Grundsätzlich weisen die Optimierungsergebnisse in den meisten Rechnungen eine höhere Genauigkeit und in den relevanten Auflösungsbereichen in keinem Fall wesentliche Verschlechterungen auf.

Im nächsten Schritt gilt es, die Anwendung von *Segmentation* und *Downsampling* im räumlich hochaufgelösten Modell zu untersuchen und die Optimierungsergebnisse hinsichtlich deren Genauigkeit zu überprüfen. Insbesondere ist dabei die Sensitivität auf die räumliche Komplexität und die Reduktion dieser zu überprüfen, indem die Berechnungen in verschiedenen räumlichen Auflösungen wiederholt werden. Zur Analyse können die im Rahmen dieser Arbeit gewonnenen Erkenntnisse genutzt werden.

Außerdem könnte die Weiterentwicklung des *2-Level-Ansatzes* einen Mehrwert für das im Rahmen dieser Arbeit betrachtete Tool darstellen. So könnte durch Warnungen bei großen Abweichungen zwischen den marginalen Kosten der Optimierungsstufen auf mögliche Ungenauigkeiten in der Ausbauoptimierung hingewiesen werden. In komplizierteren Verfahren könnten die Analysen der Ergebnisse der Optimierungsstufen sowie die notwendigen Änderungen der Reduktionsparameter automatisiert werden, sodass der *2-Level-Ansatz* im üblichen Sinne der mehrstufigen Optimierungsverfahren genutzt wird.

Aufgrund des Zusammenhangs der räumlichen und zeitlichen Inputdaten sollte weiterhin die Möglichkeit der integrierten Reduktion der räumlichen und zeitlichen Komplexität in einem gemeinsamen Verfahren überdacht werden. Dabei sind mehrstufige Optimierungsverfahren mit schrittweisen Anpassungen der Reduktionsparametern denkbar.

Literaturverzeichnis

- Bahl, B., Söhler, T., Hennen, M. & Bardow, A. (2018). Typical periods for two-stage synthesis by time-series aggregation with bounded error in objective function. *Frontiers in Energy Research*, 5. Zugriff auf <https://www.frontiersin.org/article/10.3389/fenrg.2017.00035> doi: 10.3389/fenrg.2017.00035
- Baumgärtner, N., Temme, F., Bahl, B., Hennen, M., Hollermann, D. & Bardow, A. (2019, 06). Rises4 rigorous synthesis of energy supply systems with seasonal storage by relaxation and time- series aggregation to typical periods..
- Biener, W. & Garcia Rosas, K. R. (2020). Grid reduction for energy system analysis. *Electric Power Systems Research*, 185, 106349. Zugriff auf <https://www.sciencedirect.com/science/article/pii/S0378779620301553> doi: <https://doi.org/10.1016/j.epsr.2020.106349>
- BMUV. (2021). *Lesefassung des Bundes-Klimaschutzgesetzes 2021*. Zugriff auf https://www.bmu.de/fileadmin/Daten_BMU/Download_PDF/Klimaschutz/ksg_aendg_2021_bf.pdf
- Brown, T., Hörsch, J. & Schlachtberger, D. (2018). PyPSA: Python for Power System Analysis. *Journal of Open Research Software*, 6 (4). Zugriff auf <https://doi.org/10.5334/jors.188> doi: 10.5334/jors.188
- Büttner, C. (2020). *Technisch-ökonomische Optimierung des Übertragungsnetzausbaus in Deutschland unter Berücksichtigung von (n-1)-Ausfallanalysen*.
- Caglayan, D., Heinrichs, H., Stolten, D. & Robinius, M. (2019, 10). The impact of temporal complexity reduction on a 100% renewable european energy system with hydrogen infrastructure.
doi: 10.20944/preprints201910.0150.v1
- Esterl, K. (2021). *Räumliche Komplexitätsreduktion in eTraGo - Entwicklung eines k-medoids Dijkstra Clusterings*.
- Gabrielli, P., Gazzani, M., Martelli, E. & Mazzotti, M. (2018). Optimal design of multi-energy systems with seasonal storage. *Applied Energy*, 219, 408-424. Zugriff auf <https://www.sciencedirect.com/science/article/pii/S0306261917310139> doi: <https://doi.org/10.1016/j.apenergy.2017.07.142>
- Hoffmann, M., Kotzur, L. & Stolten, D. (2021, 11). The pareto-optimal temporal aggregation of energy system models.
- Hoffmann, M., Kotzur, L., Stolten, D. & Robinius, M. (2020). A review on time series aggregation methods for energy system models. *Energies*, 13 (3). Zugriff auf <https://www.mdpi.com/1996-1073/13/3/641> doi: 10.3390/en13030641
- Hoffmann, M., Priesmann, J., Nolting, L., Praktiknjo, A., Kotzur, L. & Stolten, D. (2021, 03). Typical periods or typical time steps? a multi-model analysis to determine the optimal temporal aggregation for energy system models.

- Kannengießer, T., Hoffmann, M., Kotzur, L., Stenzel, P., Schuetz, F., Peters, K., ... Robinius, M. (2019). Reducing computational load for mixed integer linear programming: An example for a district and an island energy system. *Energies*, 12 (14). Zugriff auf <https://www.mdpi.com/1996-1073/12/14/2825> doi: 10.3390/en12142825
- Kotzur, L., Markewitz, P., Robinius, M. & Stolten, D. (2018a). Impact of different time series aggregation methods on optimal energy system design. *Renewable Energy*, 117, 474-487. Zugriff auf <https://www.sciencedirect.com/science/article/pii/S0960148117309783> doi: <https://doi.org/10.1016/j.renene.2017.10.017>
- Kotzur, L., Markewitz, P., Robinius, M. & Stolten, D. (2018b, 03). Time series aggregation for energy system design: Modeling seasonal storage. *Applied Energy*, 213, 123. doi: 10.1016/j.apenergy.2018.01.023
- Müller, U. P., Schachler, B., Bunke, W.-D., Bartels, J., Glauer, M., Büttner, C., ... Wendiggensen, J. (2019). *Netzebenenübergreifendes Planungsinstrument zur Bestimmung des optimalen Netz- und Speicherausbaus in Deutschland integriert in einer OpenEnergyPlattform*. Zugriff auf <https://www.uni-flensburg.de/fileadmin/content/abteilungen/industrial/dokumente/downloads/veroeffentlichungen/forschungsergebnisse/20190426endbericht-openego-fkz0325881-final.pdf>
- Müller, U. P., Schachler, B., Scharf, M., Bunke, W.-D., Günther, S., Bartels, J. & Pleßmann, G. (2019). Integrated techno-economic power system planning of transmission and distribution grids. *Energies*, 12 (11). Zugriff auf <https://www.mdpi.com/1996-1073/12/11/2091> doi: 10.3390/en12112091
- Nahmacher, P., Anderski, T., Apfelbeck, J., Ganer, P. et. al. (2021). *Netzentwicklungsplan Strom 2035, Version 2021 – Entwurf der Übertragungsnetzbetreiber*. Zugriff auf <https://www.netzentwicklungsplan.de/de/netzentwicklungsplaene/netzentwicklungsplan-2035-2021>
- Pfenninger, S. (2017). Dealing with multiple decades of hourly wind and pv time series in energy models: A comparison of methods to reduce time resolution and the planning implications of inter-annual variability. *Applied Energy*, 197, 1-13. Zugriff auf <https://www.sciencedirect.com/science/article/pii/S0306261917302775> doi: <https://doi.org/10.1016/j.apenergy.2017.03.051>
- Pineda, S. & Morales, J. (2018, 05). Chronological time-period clustering for optimal capacity expansion planning with storage. *IEEE Transactions on Power Systems*, PP, 1-1. doi: 10.1109/TPWRS.2018.2842093
- Poncelet, K., Höschle, H., Delarue, E., Virag, A. & D'haeseleer, W. (2017). Selecting representative days for capturing the implications of integrating intermittent renewables in generation expansion planning problems. *IEEE Transactions on Power Systems*, 32 (3), 1936-1948. doi: 10.1109/TPWRS.2016.2596803
- Raventós, O. (2018). *Temporal complexity reduction techniques and their use in power system modelling*.
- Raventós, O. & Bartels, J. (2020). Evaluation of temporal complexity reduction techniques applied to storage expansion planning in power system models. *Energies*, 13 (4). Zugriff auf <https://www.mdpi.com/1996-1073/13/4/988> doi: 10.3390/en13040988
- Renaldi, R. & Friedrich, D. (2017). Multiple time grids in operational optimisation of energy systems with short- and long-term thermal energy storage. *Energy*,

133, 784-795. Zugriff auf <https://www.sciencedirect.com/science/article/pii/S0360544217308782> doi: <https://doi.org/10.1016/j.energy.2017.05.120>

Teichgraeber, H. & Brandt, A. R. (2022). Time-series aggregation for the optimization of energy systems: Goals, challenges, approaches, and opportunities. *Renewable and Sustainable Energy Reviews*, 157, 111984. Zugriff auf <https://www.sciencedirect.com/science/article/pii/S1364032121012478> doi: <https://doi.org/10.1016/j.rser.2021.111984>

Viole, I. (2020). *Temporal complexity reduction for modelling the sector coupling of gas and electricity*.

A Anhang

A.1 Anhang Methodik

A.1.1 Übersicht über Implementierungen

Im Folgenden soll eine Übersicht über die für die vorliegende Arbeit relevanten Implementierungen gegeben werden. Es wird vermerkt, welche Teile im Rahmen dieser Arbeit implementiert worden sind. Alle anderen Implementierungen waren bereits verfügbar. Weiterhin sind Verweise zu Repositories, Branches, Dateien und Funktionen bei *GitHub* gegeben, unter denen die jeweiligen Codes zu finden sind.

Tabelle A.1: Übersicht über relevante Implementierungen und Verweise zu *GitHub* verwendeter Branch im *eTraGo*-Repository:

im Rahmen dieser Arbeit entwickelt und zur Anwendung der Methoden verwendet

<https://github.com/openego/eTraGo/tree/feature/%23340-temporal-complexity-reduction>

Downsampling:

<https://github.com/openego/eTraGo/blob/3b172cbff8da850f8513a0c425b38633b6f84991/etrigo/cluster/snapshot.py#L567>

Commit: <https://github.com/openego/eTraGo/commit/3b172cbff8da850f8513a0c425b38633b6f84991>

Clustering auf typische Perioden:

Ergänzung um Option zur Wahl von typ. Wochen und Monaten

<https://github.com/openego/eTraGo/blob/3b172cbff8da850f8513a0c425b38633b6f84991/etrigo/cluster/snapshot.py#L71>

Nebenbedingungen zur Verknüpfung der typ. Perioden nach Kotzur et al. (2018b)

- Ergänzung um Nebenbedingungen für Stores sowie Ergänzung des vereinfachten Ansatzes

<https://github.com/openego/eTraGo/blob/3b172cbff8da850f8513a0c425b38633b6f84991/etrigo/tools/constraints.py#L1090>

Segmentation:

Ergänzung um Option zur Wahl expliziten Berücksichtigung von Extremzeitschritten

<https://github.com/openego/eTraGo/blob/3b172cbff8da850f8513a0c425b38633b6f84991/etrigo/cluster/snapshot.py#L71>

Minimalbeispiel mit *2-Level-Ansatz*:

im Rahmen dieser Arbeit entwickelt

https://github.com/openego/eTraGo/blob/feature/%23340-temporal-complexity-reduction/etrigo/Minimalbeispiel_MA.py

Anwendung in *eTraGo*:

Ergänzung des *2-Level-Ansatzes*

<https://github.com/openego/eTraGo/blob/feature/%23340-temporal-complexity-reduction/etrigo/appl.py>

A.1.2 Attributzeitreihen im Minimalbeispiel

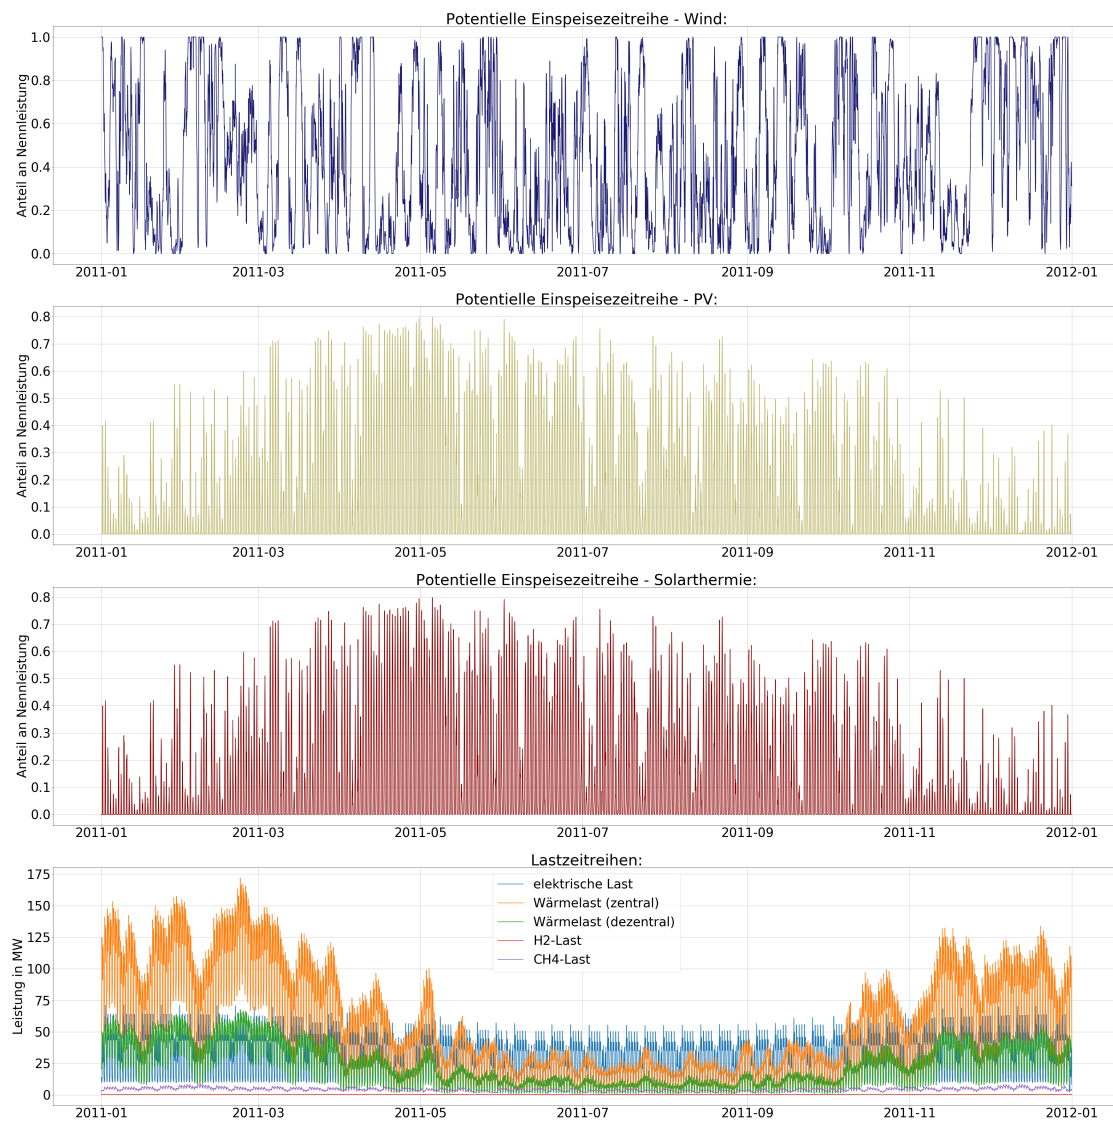



Abbildung A.1: Minimalbeispiel: Einspeise- und Lastzeitreihen im System


A.2 Anhang Ergebnisse

A.2.1 Minimalbeispiel: Betrachtung der aggregierten Zeitreihen




(a) pot. solartherm. Einspeisung in p.u.
(1000 Zeitschritte)

(b) pot. solartherm. Einspeisung in p.u.
(~ 3000 Zeitschritte)



(c) elektrische Last in MW
(~ 1000 Zeitschritte)


(d) elektrische Last in MW
(~ 3000 Zeitschritte)




(e) dezentrale Wärmelast in MW
(~ 1000 Zeitschritte)

(f) dezentrale Wärmelast in MW
(~ 3000 Zeitschritte)


Gegenüberstellung originaler und aggregierter Attributzeitreihen bei verschiedenen zeitlichen Auflösungen in Form von Heatmaps




(g) CH₄-Last in MW
(~ 1000 Zeitschritte)



(h) CH₄-Last in MW
(3000 Zeitschritte)




(i) H₂-Last in MW
(~ 1000 Zeitschritte)




(j) H₂-Last in MW
(~ 3000 Zeitschritte)

Abbildung A.2: Gegenüberstellung originaler und aggregierter Attributzeitreihen bei verschiedenen zeitlichen Auflösungen in Form von Heatmaps


A.2.2 Minimalbeispiel: Ergebnisse der Einsatzoptimierung




(a) Level 1: Typische Tage




(b) Level 2: Typische Tage




(c) Level 1: Typische Tage
- vereinfachte Verknüpfung




(d) Level 2: Typische Tage
- vereinfachte Verknüpfung




(e) Level 1: Typische Wochen



(f) Level 2: Typische Wochen


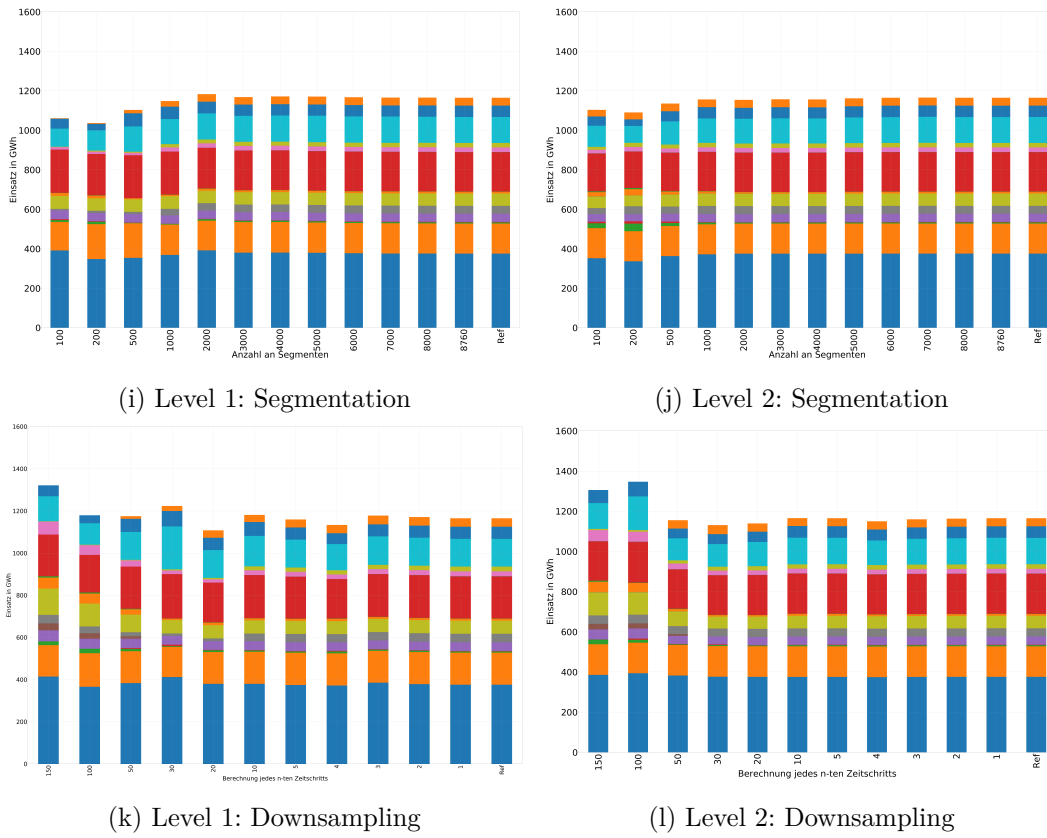


(g) Level 1: Typische Monate



(h) Level 2: Typische Monate


Darstellung der Ergebnisse der Einsatzoptimierung in Abhängigkeit der zeitlichen Auflösung




(m) Legende

Abbildung A.3: Darstellung der Ergebnisse der Einsatzoptimierung in Abhängigkeit der zeitlichen Auflösung


A.2.3 Minimalbeispiel: Abbildung des Speicherverhaltens




(a) DSM-Speicher
(1000 Zeitschritte)




(b) DSM-Speicher
(~ 3000 Zeitschritte)




(c) dezentraler Wärmespeicher
(~ 1000 Zeitschritte)



(d) dezentraler Wärmespeicher
(~ 3000 Zeitschritte)




(e) H₂-Salzkaverne
(~ 1000 Zeitschritte)



(f) H₂-Salzkaverne
(~ 3000 Zeitschritte)

Gegenüberstellung der Abbildung des Speicherverhaltens nach Anwendung des *2-Level-Ansatzes* durch Betrachtung des Speicherfüllstands (in MWh) bei verschiedenen zeitlichen Auflösungen in Form von Heatmaps



(g) H₂-Tank
(~ 1000 Zeitschritte)

(h) H₂-Tank
(~ 3000 Zeitschritte)

Abbildung A.4: Gegenüberstellung der Abbildung des Speicherverhaltens nach Anwendung des *2-Level-Ansatzes* durch Betrachtung des Speicherfüllstands (in MWh) bei verschiedenen zeitlichen Auflösungen in Form von Heatmaps

A.2.4 Minimalbeispiel: Abbildung des Speicherverhaltens des Gasnetzspeichers unter Anwendung von *Segmentation*

Abbildung 4.6 zeigt eine Verschlechterung der Abbildung der Speichernutzung des Gasnetzspeichers bei Erhöhung der zeitlichen Auflösung von 1000 auf 3000 betrachtete Segmente. Diese Beobachtung konnte nicht erklärt werden. Um zu überprüfen, ob es sich um eine Ausnahme oder ein Merkmal der Verwendung von *Segmentation* handelt, zeigt die folgende Abbildung die Abbildung der Nutzung des Gasnetzspeichers unter Anwendung von der Methode in weiteren zeitlichen Auflösungen. Die Abbildung weist nach, dass es sich tatsächlich um eine Ausnahme handelt, die im Rahmen dieser Arbeit unerklärt bleibt.

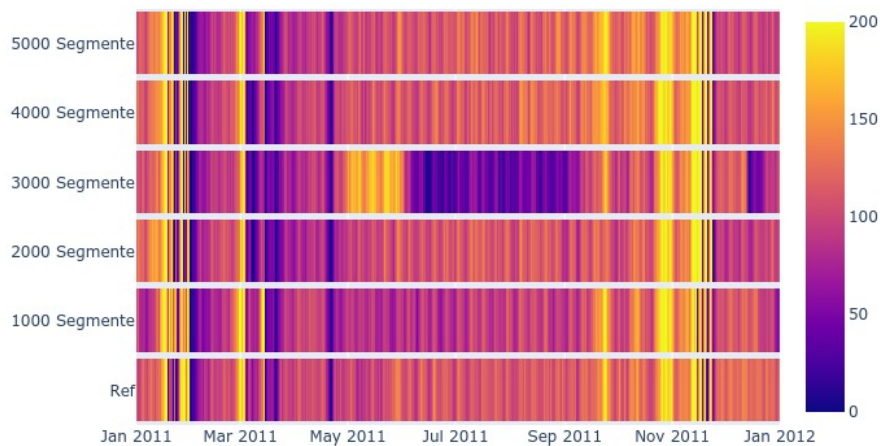


Abbildung A.5: Minimalbeispiel: Abbildung der CH₄-Speichernutzung bei Anwendung von *Segmentation*