

Betriebsoptimierung verteilter Erzeuger, Speicher und Lasten im Niederspannungsnetz

Zur Erlangung des akademischen Grades eines

DOKTOR-INGENIEURS

von der KIT-Fakultät für
Elektrotechnik und Informationstechnik des
Karlsruher Instituts für Technologie (KIT)

genehmigte

DISSERTATION

von

Dipl.-Ing. Benjamin Matthi

geb. in Lahr im Schwarzwald

Tag der mndlichen Prfung:

Hauptreferent:

Korreferent:

26.01.2024

Prof. Dr.-Ing. Michael Powalla

Prof. Dr.-Ing. Marc Hiller

Kurzzusammenfassung

Das effiziente, ökologische und wirtschaftliche Management zukünftiger Energiesysteme birgt bedeutende Herausforderungen. Ein zentrales Element hierbei ist die sichere und effektive Einbindung von erneuerbaren Energiequellen, Energiespeichern und steuerbaren Verbrauchern in das bestehende Energiesystem. Im Rahmen dieser Arbeit werden Ansätze zur Unterstützung dieser Integration vorgestellt, weiterentwickelt und gegenübergestellt.

Ein essenzieller Schritt hin zu einer bestmöglichen Integration erneuerbarer Energiequellen ist die Schaffung von Transparenz in den Energienetzen. Diese Transparenz ermöglicht es, den Fluss und die Verteilung von Energie im Netz präzise zu überwachen und zu steuern. In dieser Arbeit wird das Ziel der Netztransparenz mittels probabilistischer Lastflussmodelle und Leistungsprognosen adressiert. Insbesondere wird ein effizientes Modell für den Lastfluss unter Berücksichtigung der statistischen Unsicherheiten in Niederspannungsnetzen entwickelt und dessen Leistungsfähigkeit im Vergleich zu etablierten Ansätzen evaluiert.

Ein weiterer zentraler Aspekt bei der Integration erneuerbarer Energiequellen in das bestehende Energiesystem ist die Betriebsoptimierung verteilter Energieressourcen, zu denen Photovoltaikanlagen, Speichersysteme und Wärmepumpen gehören. Das Hauptziel besteht darin, die vorhandenen Flexibilitätsressourcen im Netz effizient zu nutzen, wodurch Netzengpässe vermieden, Übertragungsverluste minimiert und ein stetiger Ausbau erneuerbarer Energien gewährleistet werden kann. Innerhalb dieses Rahmens werden unterschiedliche Strategien zur Betriebsoptimierung hinsichtlich ihrer Praktikabilität und Performance bewertet und kategorisiert. Besonderes Augenmerk wird zudem auf die Behandlung von Unsicherheiten in Mess- und Prognosedaten gelegt.

Um die Effektivität der betrachteten Ansätze und Algorithmen zu bewerten, wird ein Simulationsmodell entwickelt, das die Realität komplexer Energiesysteme abbildet. Es fasst mathematische Beschreibungen für die wichtigsten Elemente eines elektrifizierten Energiesystems in der notwendigen Detailtiefe zusammen. Insbesondere die Modelle für Batteriespeicher, Wechselrichter und PV-Anlagen wurden durch eine umfassende Validierung mittels Labor- und Feldmessungen verifiziert.

Als dritter zentraler Aspekt wird in der Arbeit der notwendige Infrastrukturausbau betrachtet, insbesondere wenn die Betriebsoptimierung allein nicht die gewünschten Ergebnisse erzielt. Es werden sowohl für den Netzausbau als auch die Installation von Speichern zur Erhöhung der Flexibilität Optimierungsansätze vorgestellt und verglichen.

Mit den entwickelten Ansätzen stellt die Arbeit einen umfassenderen Werkzeugkasten zur Lösung der Herausforderungen bei der Integration erneuerbarer Energien in das Energiesystem zur Verfügung.

Inhaltsverzeichnis

Abkürzungen und Symbole	v
1 Einleitung	1
1.1 Schwerpunkte und Aufbau der Arbeit	2
1.2 Arbeitsübersicht	4
2 Grundlagen der Energieversorgung	7
2.1 Einführung in das Energiemanagement	7
2.2 Elektrische Energieversorgungsnetze	10
3 Simulationsumgebung für komplexe Energiesysteme	15
3.1 Thermisches Gebäudemodell	16
3.2 Thermisches Speichermodell	17
3.3 Wärmepumpenmodell	18
3.4 Modellierung des Batteriespeichersystems	22
3.5 PV-Modellierung und Ertragsabschätzung	25
3.6 Modellierung des elektrischen Netzes	29
3.7 Zusammenfassung der Simulationsumgebung	30
4 Netzzustandserkennung in Verteilnetzen mit volatilen Erzeugern und Lasten . .	33
4.1 Vereinfachung der Lastflussgleichung für Niederspannungsnetze	33
4.2 Probabilistischer Lastfluss	37
4.3 Zustandsschätzung im Verteilnetz	42
4.4 Vergleich der Algorithmen zur Netzzustandsbestimmung und Diskussion	43
4.5 Zusammenfassung der probabilistischen Lastflussberechnung	45
5 Modellierung von Energiesystemkomponenten zur Betriebsoptimierung	47
5.1 Modellierung der Komponenten für die Optimierung	48
5.2 Adaptive Parameteridentifikation	52
5.3 Kernpunkte der Modellierung von Energiesystemkomponenten zur Betriebsoptimierung	57
6 Betriebsoptimierung verteilter Erzeuger und Speicher	59
6.1 Einordnung zentraler und dezentraler Algorithmen	59
6.2 Prognose von Last und Erzeugung	63
6.3 Effizientes Energiemanagement auf lokaler Ebene	65
6.4 Betrieb unter Vorhersage-Unsicherheiten	69
6.5 Ansatz eines verteilten Energiemanagements	78
6.6 Zusammenfassung der Betriebsoptimierung und Schlüsselerkenntnisse	83

7	Optimale Systemauslegung zur Engpassvermeidung und Integration erneuerbarer Energien	85
7.1	PV-Speichersysteme - Dimensionierung für optimierten Eigenverbrauch bei gleichzeitiger Netzverträglichkeit	86
7.2	Messstellenplatzierung zur Zustandsschätzung im Verteilnetz	87
7.3	Speicherplatzierung und Auslegung	91
7.4	Zusammenfassung des Kapitels	98
8	Zusammenfassung und Ausblick	99
8.1	Ergebnisse der Arbeit	99
8.2	Ausblick	101
A	Anhang	103
A.1	Matrizengleichungen der Gebäudemodelle	103
A.2	Netzmodelle	103
A.3	Modellierung der Photovoltaik-Erzeugung	106
A.4	Alternating Direction Method of Multipliers (ADMM)	113
	Abbildungsverzeichnis	115
	Tabellenverzeichnis	117
	Eigene Veröffentlichungen	119

Abkürzungen und Symbole

Abkürzungen

EMS _{EC}	Zentrales Energiemanagement für eine Energy Community, EC
EMS _{VPP}	Energiemanagement System für ein VPP (Virtual Power Plant)
ADMM	Alternating Direction Method of Multipliers: Optimierungsalgorithmus, der konvexe Probleme löst, indem er sie in kleinere Teile zerlegt
BAFA	Bundesamt für Wirtschaft und Ausfuhrkontrolle
CHP	Combined Heat and Power, Kraft-Wärme-Kopplung: gleichzeitige Gewinnung von elektrischer Energie und nutzbarer Wärme
DER	Distributed Energy Resources: Verteilte Energiere Ressourcen (z.B. Erzeuger, steuerbare Lasten, Speicher)
DSR	Demand Side Response: Anreizen einer Distributed Energy Resources, DER zur Änderung des Energieverbrauchs durch bestimmte Signale (etwa Energiepreise)
EC	Energy Community: Energiegemeinschaft bestehend aus mehreren VPP
EMS	Energy Management System: Energiemanagement System
KNN	Künstliche Neuronale Netze
PLR	Part Load Ratio (Teillastverhältnis)
VPP	Virtuelles Kraftwerk: Zusammenschluss mehrerer DER
kW _p	Kilowattpeak: maximale Leistung einer Photovoltaik-Anlage unter standardisierten Testbedingungen (STC)
BESS	Battery Energy Storage System
BI	Direktstrahlung (beam irradiance)
COP	Leistungsfaktor (Coefficient of Performance)
DHI	Horizontale Diffusstrahlung (diffuse horizontal irradiation)
DI	Diffusstrahlung (DI, Diffuse Irradiance)
DOD	Depth of Discharge: relativer Anteil der Nennkapazität eines elektrischen Energiespeichers, welcher entladen wurde
DSM	Demand-Side-Management (auch Lastmanagement): Anpassung der Last anstelle der Kraftwerksleistung durch Netzbetreiber
DSSE	Distribution System State Estimation
GEP-LLV	Gaussian Error Propagation - Linear Low Voltage Gauss'sche Fehlerfortpflanzung unter Verwendung der Niederspannungsnäherung
GEP	Gaussian Error Propagation Gauss'sche Fehlerfortpflanzung
GHI	Horizontale Globalstrahlung (global horizontal irradiation)

GM	Generation Management: Optimierung, Überwachung und Steuerung der Energieerzeugung in einem Stromnetz
MPC	Model Predictive Control
NBI	Direktstrahlung in der Normalebene (normal beam irradiation)
PMU	Phasor Measurement Unit
POA	Strahlung auf die geneigte Ebene
REF	reflektierte Strahlung
SOC	State of Charge: Ladezustand der Batterie
STC	Standard Test Conditions: 1000 W/m Bestrahlungsstärke, 25 °C, Luftmasse (AM) von 1,5 auf Meereshöhe (ca. 45° Sonnenwinkel), senkrechter Lichteinfall
nRMSE	Normalized Root Mean Squared Error: RMSE normalisiert auf die Nennleistung
p.u.	Per Unit: definiert Werte relativ zu einem festgelegten Basiswert wie etwa die Nennspannung $\left(\frac{\text{tatsächlicher Wert}}{\text{Basiswert}} \right)$
JEKF	Joint Extended Kalman Filter
LLV	Linear-Low-Voltage: linearen Niederspannungsnaherung
MC-LLV	Monte-Carlo Linear-Low-Voltage: Monte-Carlo Methode unter Nutzung der linearen Niederspannungsnaherung
MC-NR	Monte-Carlo Newton-Raphson: Monte-Carlo Methode unter Nutzung des Newton-Raphson Lastflusses
PLF	Probabilistischer Lastfluss (Probabilistic Loadflow)
PV	Photovoltaik
WLS	Weighted Least Squares: Regressionsmethode die bei der Zustandsschätzung verwendet wird

Symbole

C_i	Interne Wärmekapazität des Gebäudes einschließlich der thermischen Masse der Luft und der Möbel
C_w	Wärmekapazität der Aussenhülle (Wände) des Gebäudes
P_{nom}	Nennleistung
P_{EC}	Stromerzeugung der kompletten EC
P_{CHP}	Leistung des BHKWs
P_{ac}	AC Leistung aus dem PV-Wechselrichter
P_{batt}	Leistung der Batterie
P_{curt}	Abgeregelte erneuerbare Erzeugung (curtailment)
P_{dc}	DC Leistung aus den PV-Modulen
P_{dem}	Lokaler Verbrauch (demand)

P_{grid}	Leistung am Netzverknüpfungspunkt (Point of Common Coupling)
P_{res}	Erneuerbare Erzeugung (generation)
P_{vpp}	Netto-Strombedarf des VPP
P	Leistung (Erzeugung, Verbrauch, Speicher, etc)
T_a	Außentemperatur
T_h	Temperatur der heißen Seite des Kreisprozesses
T_{in}	Temperatur des internen Knotens eines thermischen Gebäudemodells
T_k	Temperatur der kalten Seite des Kreisprozesses
T_w	Temperatur der Außenwände
U_{ia}	Wärmeleitfähigkeit zwischen der Außenluft und dem Innenknoten des Gebäudes (Komponenten mit vernachlässigbarer thermischer Masse, wie Fenster und Türen)
U_{iw}	Wärmeleitfähigkeit zwischen den Gebäudewänden und dem Innenraum
U_{wa}	Wärmeleitfähigkeit zwischen Außenluft und den Gebäudewänden
α_E	Azimuthwinkel des PV moduls
α_S	Azimuthwinkel der Sonne
\mathbf{n}	Vektor des Messrauschens
\mathbf{v}	Vektor des Systemrauschens
\dot{Q}_h	Wärmestrom der Heizung
\dot{Q}_{int}	Interner Wärmegewinn durch künstliche Beleuchtung, Menschen und elektrische Geräte Geräte
$\dot{Q}_{\text{tank, in}}$	Wärmestrom in den Tank
$\dot{Q}_{\text{tank, loss}}$	Verlustwärmestrom des Tanks
$\dot{Q}_{\text{tank, out}}$	Wärmestrom aus dem Tank
ϵ_σ	Schätzfehler der Standardabweichung
ϵ_{ADMM}	Abbruchkriterium für den adaptiven ADMM (Toleranzmaß)
ϵ_{pred}	Relativer Vorhersagefehler
η_{PLR}	Part Load Performance Efficiency. Effizienz eines Systems unter Teillastbedingungen (Part Load Ratio, PLR) relativ zum Nennbetrieb P_{nom}
η_{carnot}	Carnot Wirkungsgrad
η	Wirkungsgrad eines Systems
γ_E	Anstellwinkel des PV Moduls
γ_S	Sonnenhöhenwinkel
$\hat{\mathbf{x}}$	Schätzung des Systemzustandsvektors
κ	Preis für den erzeugten oder verbrauchten Strom jeder Einheit
\mathbb{I}	Einheitsmatrix
\mathbf{x}	Zustandsvektor $[x_0, x_1, \dots, x_n]^\top$
\mathcal{J}	Die Kosten-/Zielfunktion (auch Gütekriterium)
μ	Mittelwert einer Verteilung
ν	Gütegrad: relative Größe, die zeigt, wie nah ein reales thermodynamisches Verfahren zum perfekten theoretischen Vergleichsprozess steht
\bar{P}_{grid}	Maximales Leistungslimit am Netzverknüpfungspunkt (Point of Common Coupling)

σ	Standardabweichung einer Verteilung
$\varepsilon_{\text{carnot}}$	Carnot Leistungszahl
A	Diskrete Zustandsübergangsmatrix
B	Die diskrete Eingangsmatrix
C	Diskrete Ausgabematrix
H(x)	Hessematrix von $h(\mathbf{x})$
M_I	Strommatrix
M_V	Spannungsmatrix
W	Gewichtsmatrix ($W_{i,i} = \sigma_i^{-2}$)
Y	Admittanzmatrix
χ	Zustandsraumvektor zusammengesetzt aus den Systemzuständen \mathbf{x} und den Modellparametern \mathbf{w}
$\sigma_{\hat{\mathbf{x}}}$	Unsicherheit des Schätzwertes $\hat{\mathbf{x}}$
Z	Messvektor für die Zustandsschätzung
u	Eingangsvektor
w	Vektor der Modellparameter
c_{temp}	Temperaturkoeffizient des PV-Modells
g_{∞}	Gleichzeitigkeitsfaktor
g_{res}	Resultierender Gleichzeitigkeitsfaktor für das Netzgebiet
$h(\mathbf{x})$	Messfunktion: bildet die Messungen auf den Systemzustand ab
k_{sun}	Faktor für den Wärmegewinn durch Sonneneinstrahlung (GHI)
t_{h}	MPC-Vorhersagehorizontzeit
$\Sigma_{\hat{\mathbf{x}}}$	Kovarianzmatrix des geschätzten Systemzustands $\hat{\mathbf{x}}$
Σ_n	Kovarianzmatrix des Messrauschens n
C_{batt}	Kapazität der Batterie

1 Einleitung

Das europäische Energiesystem vollzieht einen Wandel hin von zentraler Erzeugung durch Großkraftwerke hin zu verteilten erneuerbaren Energiequellen wie Sonne, Wind und Wasserkraft. Die Europäische Union hat das Ziel, den Anteil der erneuerbaren Energien am Bruttoenergieverbrauch bis 2030 auf mindestens 45 % zu erhöhen, und plant gleichzeitig, die Emissionsrechte bis 2030 schrittweise um 62 Prozent im Vergleich zu 2005 zu kürzen [1, 2]. Einige Mitgliedstaaten streben bis 2050 einen Anteil von 100 % erneuerbarer Energie an. Auch das deutsche Energiesystem erfährt substantielle Veränderungen, mit einem Anstieg des Anteils der erneuerbaren Energien an der elektrischen Energieerzeugung von 4% im Jahr 1990 auf 41% im Jahr 2021 [3].

Der Umstieg auf erneuerbare Energien verringert einerseits die Abhängigkeit von fossilen Energieträgern und damit von globalen Lieferketten und trägt andererseits zur Reduktion von Kohlendioxidemissionen bei. Dieser Übergang erfordert eine umfassende Elektrifizierung des Energiesystems, der Industrie, des Verkehrs und der Gebäude sowie die Erzeugung von Wasserstoff. Dies erhöht den Strombedarf und erfordert einen konsequenten Ausbau der erneuerbaren Energien und der Infrastruktur [4, 5]. Die gesamte Stromkreislänge im deutschen Übertragungsnetz soll von etwa 35.000 Stromkreiskilometern im Jahr 2021 auf 50.000 Stromkreiskilometer im Jahr 2035 ansteigen [5].

Um diese Transformation effizient zu gestalten, muss die Flexibilität im Stromsystem deutlich erhöht werden. Energieeffizienzmaßnahmen in allen Sektoren, eine starke Flexibilisierung der Last und Erzeugung sowie eine intelligente Steuerung der Niederspannungsnetze sind unerlässlich für die Integration erneuerbarer Energien. Ein effizientes Energiemanagement nutzt die geschaffene Flexibilität und sichert den stabilen Betrieb des Energiesystems. Selbst wenn alle Flexibilitäten genutzt werden, wird ein gewisser Ausbau der Netzkapazität erforderlich sein, um den Transport der Energie vom Erzeugungsort zum Verbraucher zu unterstützen.

Herausforderungen für die Integration dezentraler erneuerbarer Energien ins Niederspannungsnetz

Die Eingliederung erneuerbarer Energieressourcen, speziell dezentraler Energiequellen wie Photovoltaik (PV)-Anlagen auf Gebäuden, stellt neue Anforderungen an das Niederspannungsnetz. Dieses Netz fungierte bisher als Distributionsinfrastruktur, die Wohngebäude und Betriebe mit elektrischer Energie versorgt. Traditionell ist dieses Netz für einen unidirektionalen Stromfluss von Großkraftwerken zu den Verbrauchern konzipiert. Mit der Zunahme von dezentralen erneuerbaren Energien muss das Niederspannungsnetz nun auch bidirektionale Stromflüsse akzeptieren, da Überschussenergie, generiert von PV-Dachanlagen und ähnlichen dezentralen Ressourcen, ins Netz eingespeist wird [6]. Die angeschlossenen Erzeuger können eine wesentlich höhere Nennleistung haben als die angeschlossenen

Verbraucher. Hinzu kommt, dass der unregelmäßige Charakter erneuerbarer Energiequellen und die hohe Korrelation von Lasten und Energieressourcen bei naiven Betriebsstrategien zu Leistungsspitzen im Netz führen. Diese wiederum können Überspannungen oder Unterspannungen auslösen, die Schäden an elektrischen Geräten verursachen und die Qualität der Stromversorgung der Verbraucher beeinträchtigen können.

Fortgeschrittene Messinfrastruktur, Netzautomatisierung und Managementsysteme für dezentrale Energieressourcen erhöhen die Flexibilität und Intelligenz des Niederspannungsnetzes und unterstützen die Integration erneuerbarer Energien. Dieser Ansatz wird allgemein als Smart Grid bezeichnet [7]. Das Hauptziel eines solchen intelligenten Stromnetzes ist es, die Effizienz, Zuverlässigkeit und Flexibilität der Stromversorgung zu verbessern und gleichzeitig die ökologischen Auswirkungen der Energieerzeugung und des -verbrauchs zu minimieren. Zudem kann eine zusätzliche Verstärkung des Netzes erforderlich werden, um sicherzustellen, dass das Niederspannungsnetz die erhöhten Leistungsflüsse bewältigen und eine stabile Stromversorgung für die Verbraucher aufrechterhalten kann.

Für die Herausforderung der Integration erneuerbarer Energien in das Niederspannungsnetz liefert diese Arbeit systematische Beiträge und Lösungsansätze. Im folgenden Kapitel werden die konkreten Probleme und Fragestellungen erläutert, die in der Arbeit behandelt werden.

1.1 Schwerpunkte und Aufbau der Arbeit

Die Arbeit adressiert verschiedene Fragestellungen und Herausforderungen, die bisher in der Forschung nicht vollständig behandelt wurden und die insbesondere in ihrer Kombination eine Schlüsselrolle für den optimierten Betrieb und die Weiterentwicklung von Energieverteilnetzen darstellen. Zunächst wird der intelligente Betrieb von Flexibilität im Stromnetz untersucht, einschließlich des optimierten Betriebs von Speichern und Wärmepumpen. Sollte die Flexibilisierung nicht ausreichen, wird ein optimierter Ausbau des Energiesystems einschließlich des Netzausbaus und der optimierten Platzierung von Energiespeichern im Niederspannungsnetz betrachtet. Für eine Reihe von Herausforderungen, die von der Entwicklung einer detaillierten Simulationsumgebung über die Klassifizierung von Betriebsstrategien bis hin zum Umgang mit Prognoseunsicherheiten reichen, werden in der Arbeit Lösungen erarbeitet. Das Thema wird aus verschiedenen Perspektiven beleuchtet, um einen umfassenden Einblick in die Komplexität und Vielfalt der Probleme zu geben, die im Bereich der Energieverteilung und -optimierung zukünftiger Energiesysteme auftreten können. Jedes einzelne dieser Themen stellt eine Herausforderung in der aktuellen Forschung dar und bedarf daher einer eingehenden Untersuchung und Analyse.

Im Kontext dieser Arbeit liegt der Schwerpunkt auf drei Entwicklungsfelder:

1. **Netztransparenz im Verteilnetz:** Die Schaffung von Netztransparenz, insbesondere in Netzen mit wenigen Messpunkten, ist von entscheidender Bedeutung. Trotz der Bedeutung dieser Transparenz sind die heutigen Verteilnetze größtenteils unzureichend überwacht, insbesondere in Gebieten mit wenigen Messpunkten und unsicherer Verbrauchs- oder Erzeugungssituation. Da erneuerbare Energien wie Wind und Sonne von Natur aus volatil sind und nicht genau vorhergesagt werden können, reichen traditionelle, deterministische Methoden oft nicht aus, um

den Lastfluss im Netz zuverlässig zu berechnen und vorherzusagen. Dies stellt ein Risiko für die Netzstabilität und die effiziente Nutzung und Steuerung der Netzinfrastruktur dar.

Im Kontext der Netztransparenz in elektrischen Verteilnetzen kommt der probabilistischen Lastflussanalyse eine entscheidende Bedeutung zu. Sie ermöglichen eine explizite Berücksichtigung der inhärenten Unsicherheiten sowohl bei der Energieerzeugung als auch beim Verbrauch. Das daraus resultierende tiefgehende Verständnis des Netzzustandes stellt eine wesentliche Grundlage für die Optimierung des Netzbetriebes dar. In Kapitel 4 werden verschiedene dieser Methoden ausführlich behandelt und systematisch miteinander verglichen.

- 2. Optimierter Betrieb für Wirtschaftlichkeit, Energieeffizienz und Netzstabilität:** Ein optimierter Betrieb von Energieanlagen ist entscheidend, um erneuerbare Energiequellen, Energiespeicher und steuerbare Lasten, wie Wärmepumpen, wirtschaftlich, effizient und gleichzeitig sicher in das bestehende Energiesystem zu integrieren. Die Hauptaspekte, welche in dieser Arbeit betrachtet werden, sind die Folgenden.

Vereinfachte adaptive Modelle zur Betriebsoptimierung: Energiesysteme sind hochkomplex und dynamisch. Viele Variablen beeinflussen sich gegenseitig. Gleichzeitig ist eine einfache Modellierung für die effiziente Nutzung optimaler Betriebsstrategien unerlässlich. In diesem Zusammenhang stellt auch die Skalierbarkeit eine große Herausforderung dar, insbesondere in Energiesystemen, die sich zunehmend in Richtung Dezentralisierung entwickeln. Ein wesentlicher Vorteil vereinfachter adaptiver Modelle ist ihre Implementierbarkeit in einfachen Hardwareumgebungen. Im Vergleich zu komplexeren Algorithmen benötigen diese Modelle weniger Rechenleistung und Speicherplatz, was sie für den Einsatz in Hardware mit begrenzten Ressourcen prädestiniert. Sie können lokal ausgeführt werden, wodurch auch Datenschutzbedenken ausgeräumt werden. Wie Komponenten für die Betriebsoptimierung effektiv abgebildet werden können und wie genau Optimierungsmodelle im Kontext eines optimierten Betriebs im Niederspannungsnetz sein müssen, wird in Kapitel 5 gezeigt.

Einordnung von Betriebsstrategien: Eine genaue Einordnung und Klassifizierung von unterschiedlichen zentralen und dezentralen Betriebsstrategien im Kontext von Energiemanagementalgorithmen ist nur bedingt vorhanden. Die Konzepte von zentralen, verteilten und dezentralen Methoden sind je nach Anwendung unterschiedlich klassifiziert und es gibt keinen klaren Konsens. Ein Vorschlag für eine neue, zweidimensionale Einordnung wird in Kapitel 6.1.1 gegeben.

Einfluss von Vorhersageunsicherheiten: Die Herausforderungen im Umgang mit Unsicherheiten, deren Einfluss und ob diese durch Speicher ausgeglichen werden kann, werden in Kapitel 6.4 im Kontext des optimierten Betriebs diskutiert. Eine Methode zur recheneffizienten, linearen Fehlerpropagation durch das Netzmodell wird in Kapitel 4.2.2 hergeleitet.

3. Ausbau der Infrastruktur: Die entscheidenden Schritte für einen weiteren Ausbau der erneuerbaren Energien, nachdem die Betriebsoptimierung ausgeschöpft wurde, wird am Beispiel eines realen Niederspannungsnetzes erörtert.

Platzierung von Messstellen im Verteilnetz: Für den sicheren Betrieb von Netzen mit hohem Anteil erneuerbarer Energien ist die Netztransparenz unerlässlich. Um den Netzstatus in Echtzeit zu erfassen, sind Messstellen unerlässlich. Eine gute Platzierungsstrategie maximiert den Gewinn an Netztransparenz pro installierter Messstelle. Durch diese klare Übersicht lassen sich notwendige Investitionen effektiv planen und Prioritäten setzen, was die Gesamtsicherheit des Netzes stärkt. Eine effiziente Möglichkeit, die Netztransparenz in Niederspannungsnetzen durch optimal platzierte Messstellen zu erhöhen, wird im Kapitel 7.2 erarbeitet.

Platzierung von Speichersystemen im Verteilnetz: Die strategische Platzierung von Speichersystemen in Verteilnetzen kann deren Stabilität maßgeblich verbessern und die Aufnahmefähigkeit erneuerbarer Energien erhöhen. In Abschnitt 7.3 wird eine Strategie zur optimalen Platzierung von Speichern in Netzen mit signifikantem Anteil erneuerbarer Energien erarbeitet. Das Hauptziel dieser Strategie ist die Einhaltung der Netzgrenzen bei hohen PV-Anteilen durch intelligent platzierte Speichersysteme unter Berücksichtigung und Minimierung der Kosten. Des Weiteren wird die Erweiterung der Netzinfrastruktur als eine potenzielle Alternative erörtert.

Detaillierte Simulationsumgebung für komplexe Energiesysteme

Jede der oben genannten Dimensionen wird nicht nur theoretisch untersucht, sondern auch in einer detaillierten Simulationsumgebung validiert, die speziell für diese Arbeit entwickelt wurde. Diese ermöglicht die umfassende Analyse von Netzen, energietechnischen Anlagen und die thermische Simulation von Gebäuden. Die ganzheitliche, detaillierte Simulationsumgebung des Energiesystems ist eine große Herausforderung, da verschiedene Disziplinen kombiniert werden müssen. Zu Beginn dieser Arbeit gab es keine frei verfügbare Umgebung, welche die detaillierte Simulation der Netze, energietechnischen Anlagen sowie die exakte thermische Simulation von Gebäuden für komplette Niederspannungsnetze erlaubt. In Kapitel 3 wird die in dieser Arbeit entwickelte Simulationsumgebung beschrieben. Diese ist komplett parallelisierbar und kann somit auf Rechenclustern ausgeführt werden. Hierbei wird auch auf die Modelle einzelner Komponenten eingegangen, die teilweise mit Labormesswerten kalibriert wurden.

1.2 Arbeitsübersicht

Die Betrachtung der zuvor genannten Aspekte sowie das Herausarbeiten von Lösungswegen sind zentrale Punkte dieser Arbeit. Diese ermöglichen es, den zukünftigen Betrieb von Energieverteilernetzen effizienter zu gestalten. Die Struktur dieser Arbeit ist in Abbildung 1.1 dargestellt, welche einem Ablaufdiagramm für den optimierten Betrieb ähnelt. Die Elemente dieses Diagramms beinhalten eine

Referenz zu dem entsprechenden Kapitel der Arbeit, wodurch eine klare Verbindung zwischen der visuellen Darstellung und dem Text hergestellt wird.

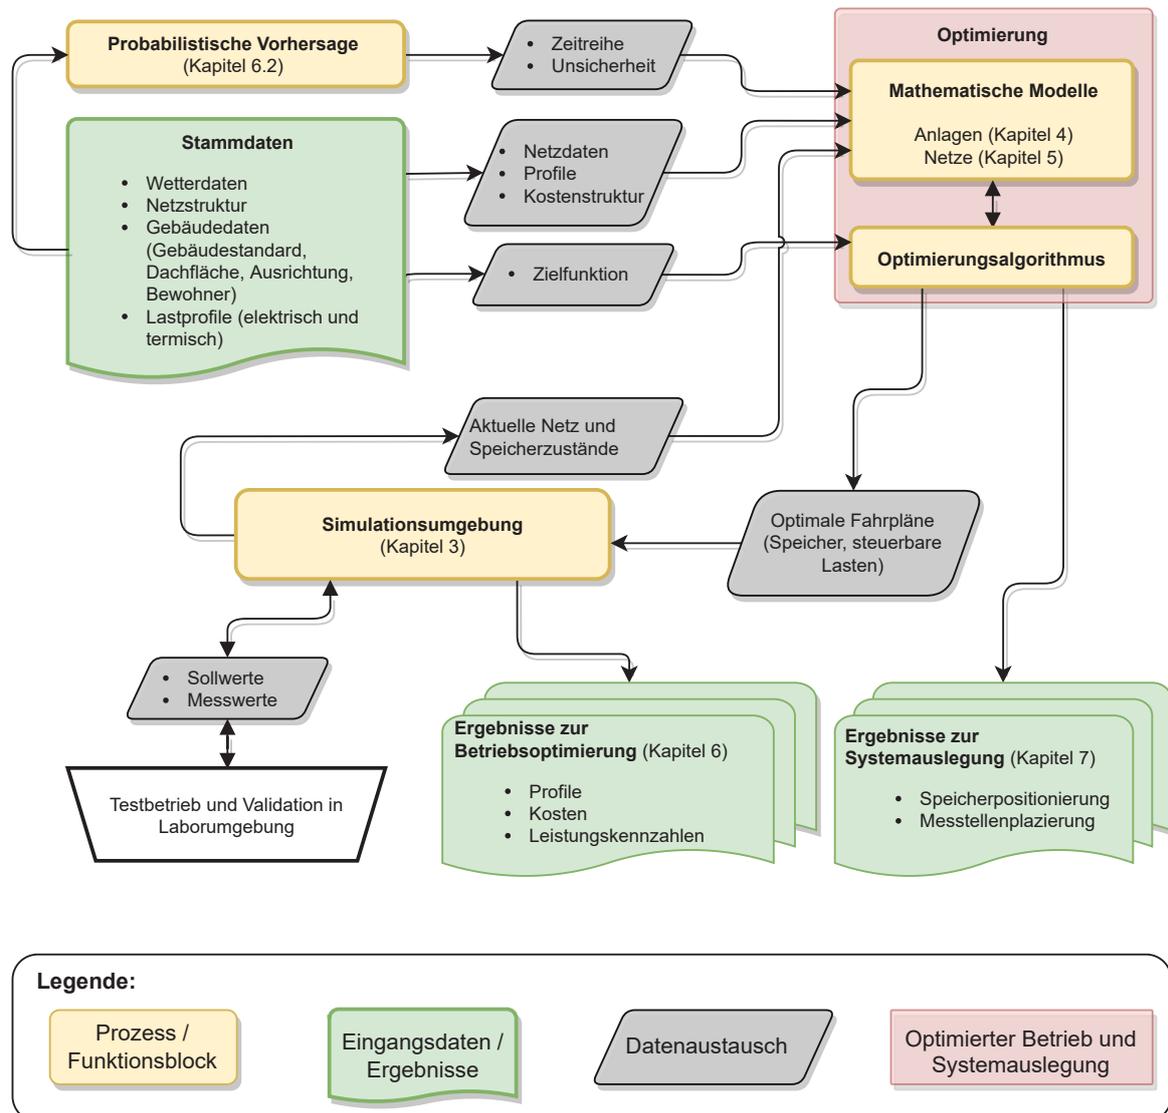


Abbildung 1.1 Funktionaler Zusammenhang und Aufbau der Arbeit, angelehnt an ein Flussdiagramm.

2 Grundlagen der Energieversorgung

Das Energiemanagement ist ein entscheidender Aspekt bei der Gewährleistung eines nachhaltigen und effizienten Energiesystems. Es gibt mehrere Grundkonzepte, die im Energiemanagement üblicherweise verwendet werden, darunter Energieeinsparung, -speicherung, -überwachung und -verschiebung. Weiterhin werden Methoden und Verfahren zur rationellen Energieverwendung sowie der Nutzung von Flexibilität eines Systems angewandt, um auf verschiedene Energienachfrage- und Angebotsszenarien unter vorgegebenen Randbedingungen zu reagieren und diese zu bewältigen.

2.1 Einführung in das Energiemanagement

Energiemanagementsysteme spielen eine entscheidende Rolle bei der Abstimmung von Energieerzeugung und -verbrauch, insbesondere in einem Energiesystem, das stark auf erneuerbaren Quellen basiert. Da erneuerbare Energiequellen wie Wind und Sonne variabel und nicht immer exakt vorhersehbar sind, ist es eine Herausforderung, die Erzeugung und den Verbrauch im Einklang zu halten.

Wenn lokale Energieerzeugung und -verbrauch zu allen Zeiten ausgeglichen sind, erhöht dies die Effizienz der genutzten Energie und minimiert sowohl Energieverluste durch Übertragung als auch den Bedarf an Zwischenspeicherung. Eine Harmonisierung von Energieerzeugung und -verbrauch kann durch diverse Strategien erreicht werden.

Einerseits ermöglicht die Integration intelligenter Technologien, dass Verbraucher ihren Energiebedarf zeitlich an Phasen hoher erneuerbarer Energieproduktion anpassen. Dies könnte beispielsweise durch den Einsatz von Smart-Devices realisiert werden, die primär in Zeiten hoher Verfügbarkeit erneuerbarer Energien aktiviert werden.

Andererseits bieten Energiespeichersysteme die Möglichkeit, Überschüsse aus erneuerbaren Energien temporär zu speichern und bei Bedarf, insbesondere in Phasen reduzierter Energieproduktion, lokal zur Verfügung zu stellen oder ins Netz einzuspeisen. Solche Speichertechnologien variieren in ihrer Kapazität, reichend von großen Lösungen wie Pumpspeicherkraftwerken bis hin zu kleineren Systemen wie Photovoltaik-Batteriespeichern.

2.1.1 Betriebsoptimierung

Energiemanagementsysteme helfen dabei, den Energieverbrauch und die -erzeugung besser aufeinander abzustimmen. Sie können etwa Verbrauchsdaten analysieren, Prognosen für die erneuerbare Energieerzeugung erstellen und automatisch Geräte oder Speicher steuern, um die Übereinstimmung zwischen Erzeugung und Verbrauch zu verbessern. In diesem Sinne sind sie ein Schlüsselwerkzeug für

die effiziente Nutzung von erneuerbaren Energien. Um diese Ziele zu erreichen, wird die vorhandene Flexibilität im Energiesystem genutzt, welche durch folgende Mechanismen genutzt werden kann.

Nachfragesteuerung (Demand Side Response, DSR): Dies beinhaltet die Fähigkeit, die Nachfrage nach Energie an das verfügbare Angebot anzupassen. Das kann durch wirtschaftliche Anreize erfolgen (wie variable Tarife, die den Verbrauch in Zeiten niedrigerer Preise fördern). Die Entscheidung, wie die Nachfrage angepasst werden kann, wird hierbei vom Verbraucher getroffen. Beispielsweise können Gebäude- oder industrielle Systeme so gesteuert werden, dass sie weniger Energie verbrauchen, wenn das Angebot knapp ist oder die Preise hoch sind.

Erzeugungsmanagement (Generation Management, GM): Das Erzeugungsmanagement ist ein automatisiertes System, das zur Optimierung, Überwachung und Steuerung der Energieerzeugung in einem Stromnetz eingesetzt wird. Es ist ein integraler Bestandteil der modernen Stromerzeugungsinfrastruktur und spielt eine entscheidende Rolle bei der Gewährleistung der Versorgungssicherheit, Effizienz und Zuverlässigkeit des Stromnetzes. Das klassische Stromsystem basierend auf fossilen Brennstoffen nutzt das Erzeugungsmanagement, um der Last zu folgen. In einem System mit erneuerbaren Energien sollten jedoch die Verbraucher weitgehend der Verfügbarkeit von Strom aus erneuerbaren Energien folgen.

Lastmanagement (Demand Side Management, DSM): Der Prozess der direkten Steuerung der Last anstelle der Erzeugerleistung. Die Vorgabe erfolgt hier in der Regel vom Netzbetreiber zur Vermeidung von Netzengpässen oder vom Energiehändler zur Nutzung von Überschüssen aus konventioneller Stromerzeugung (z.B. Nutzung von Grundlast aus Kernkraftwerken durch Nachtspeicherheizungen). Erreicht werden kann dies durch ein direktes Eingreifen des Versorgungsunternehmens in Echtzeit, durch den Einsatz von frequenzabhängigen Relais, die die Leistungsschalter auslösen (Rundsteuerung) oder durch Zeitschaltuhren.

2.1.2 Randbedingungen für das Energiemanagement

Randbedingungen spielen eine entscheidende Rolle für die Implementierung und Optimierung von Energiemanagementsystemen, insbesondere im Hinblick auf Flexibilität. Hier sind einige Beispiele, wie diese Faktoren berücksichtigt werden können.

Transportkapazitäten (Netze): Die Kapazität von Stromnetzen kann die Fähigkeit einschränken, Energie von Orten mit Überschuss (z.B. Gebiete mit hoher Wind- oder Solarenergieproduktion) zu Orten mit hoher Nachfrage zu transportieren. Intelligente Netze können helfen, diese Herausforderung zu bewältigen, indem sie die Energieverteilung effizienter koordinieren. Durch intelligenten Netzbetrieb kann der notwendige Netzausbau und die Netzverstärkung zur Erhöhung der Transportkapazitäten minimiert werden.

Energiespeicherkapazität: Hier kann überschüssige Energie zu Zeiten gespeichert werden, in denen das Angebot die Nachfrage übersteigt, und dann freigesetzt werden, wenn das Angebot knapp ist. Beispiele für Energiespeicher sind Batterien, Wärmespeicher, und Pumpspeicherkraftwerke.

Energie Verschiebungs- und Einsparpotential: Dies bezieht sich auf die Fähigkeit, die Nachfrage nach Energie zu verschieben, um das Angebot und die Nachfrage besser in Einklang zu

bringen. Dies kann durch Technologien wie DSR erreicht werden, die Anreize für Verbraucher schaffen, ihren Energieverbrauch zu Zeiten hoher Nachfrage zu reduzieren. Die Größe dieses Verschiebe Potentials kann von verschiedenen Faktoren abhängen, darunter die Art der Lasten (z.B. industriell, gewerblich, häuslich), die Bereitschaft der Verbraucher zur Teilnahme und die technologischen Möglichkeiten zur Steuerung des Energieverbrauchs.

Energieerzeugungskapazität: Dabei geht es um die Kapazität der Energieerzeugung vor Ort. Dies kann dazu beitragen, die Transportwege von Energie zu verringern und lokale Energiequellen zu schaffen.

In die Planung und Umsetzung von Strategien für ein flexibles Energiemanagement fließen die oben genannten und weitere Parameter als Randbedingungen ein. Eine detaillierte Analyse liefert die spezifischen Anforderungen, die in Abstimmung mit verschiedenen Stakeholdern, darunter Energieerzeuger, Netzbetreiber, Verbraucher und Regulierungsbehörden gewichtet werden müssen. Im Kontext dieser Arbeit werden die Randbedingungen in Optimierungsproblemen abgebildet. Diese können dann zum Beispiel mithilfe einer Modellprädiktiven Regelung in einem Energiemanagementsystem eingesetzt werden.

2.1.3 Einführung in die Modellprädiktive Regelung

Die modellprädiktive Regelung (Model Predictive Control, MPC) ist ein optimierungsbasierter Regelalgorithmus, der ein dynamisches Modell verwendet, um die Zielfunktion \mathcal{J} basierend auf den aktuellen Messungen zum Zeitschritt k mit N Vorhersagen in der Zukunft zu optimieren. Das Optimierungsproblem kann wie folgt dargestellt werden

$$\mathcal{J} = \arg \min_{\mathbf{u}} \sum_k^{k+N-1} f(\mathbf{u}_k) \quad (2.1)$$

unter den Nebenbedingungen

$$\begin{aligned} \dot{\mathbf{x}}_{k+1} &= \mathbf{A}\mathbf{x}_k + \mathbf{B}\mathbf{u}_k \\ \underline{\mathbf{x}} &\leq \mathbf{x}_k \leq \bar{\mathbf{x}} \\ \underline{\mathbf{u}} &\leq \mathbf{u}_k \leq \bar{\mathbf{u}}. \end{aligned} \quad (2.2)$$

Das übergeordnete Ziel der modellprädiktiven Regelung ist es, eine Sequenz von optimierten Stellgrößen \mathbf{u} zu bestimmen, die den Systemzustand \mathbf{x} innerhalb der entsprechenden unteren $\underline{\mathbf{x}}$ und oberen $\bar{\mathbf{x}}$ Grenzen hält. Dies wird durch die Optimierung eines Gütekriteriums \mathcal{J} erreicht, das auf einem dynamischen Modell basiert und Messdaten im Zeitschritt k sowie N zukünftige Vorhersagen berücksichtigt. Dabei müssen die Randbedingungen der Variablen eingehalten werden. Das Ergebnis dieses Optimierungsprozesses sind die optimalen Stellgrößen. Da die MPC einen gleitenden Zeithorizont verwendet, wird nur das erste Element der Stellgrößenfolge implementiert. Wenn sich der Zeithorizont zum nächsten Zeitschritt $k + 1$ verschiebt, wird der Modellzustand erneut initialisiert und die Optimierung der Kostenfunktion \mathcal{J} unter Berücksichtigung der Messungen im Zeitschritt $k + 1$ mit N

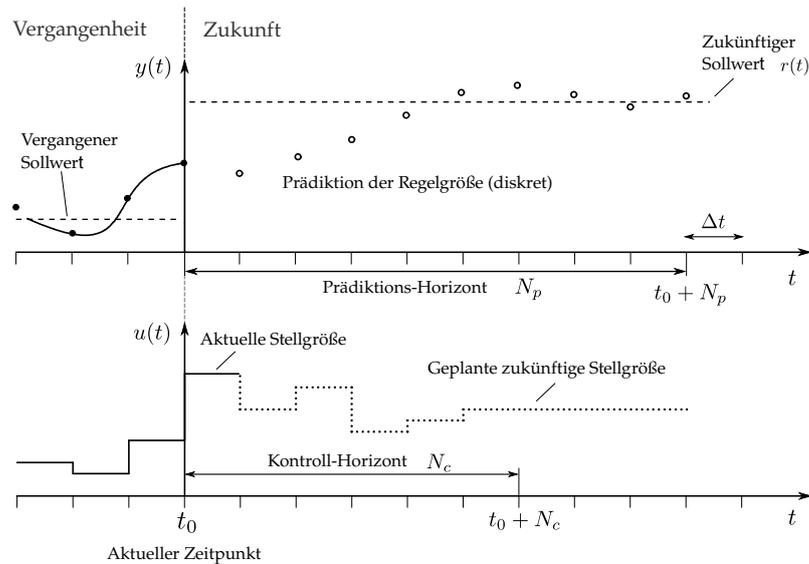


Abbildung 2.1 Ablaufdiagramm der Modellprädiktiven Regelung (in Anlehnung an [8]).

zukünftigen Vorhersagen durchgeführt. Wiederum wird nur das erste Element der Stellgrößensequenz implementiert. Die Funktionsweise ist in Abbildung 2.1 dargestellt.

2.2 Elektrische Energieversorgungsnetze

Die Energieübertragungsnetze sind ein wichtiger Aspekt des europäischen Energiesystems. In diesem Kapitel wird ein kurzer Überblick über den Aufbau der deutschen Energienetzstruktur gegeben – vom Verteilnetz bis zum Übertragungsnetz. Die Arbeit selbst beschäftigt sich mit der Betriebsoptimierung im Niederspannungsnetz. Eine grafische Übersicht wird in Abbildung 2.2 gegeben.

Das europäische Stromnetz ist nach Spannungshöhe und Funktion in verschiedene Netzebenen gegliedert. Die Netzebene mit den höchsten Spannungen ist das Höchstspannungsnetz (Ebene 1). Das Höchstspannungsnetz fungiert als Übertragungsnetz und überträgt elektrische Energie über weite Strecken. In der klassischen Betrachtungsweise von elektrischen Stromnetzen sind die großen Kraftwerksblöcke und somit ein Großteil der Kraftwerksleistung, an das Übertragungsnetz angeschlossen. Die untergeordneten Netzebenen (Ebene 2 bis 7) haben die Aufgabe, die elektrische Energie lokal eingegrenzt zu verteilen und werden deshalb als Verteilnetz bezeichnet. Die niedrigste Netzebene, das Niederspannungsnetz, verteilt die elektrische Energie bis zu den Endverbrauchern. Im Zuge der Energiewende steigt die Bedeutung der Niederspannungsebene als Ort der Energieerzeugung und -speicherung jedoch beträchtlich.

Um eine Beschädigung von Betriebsmitteln vorzubeugen, müssen Stromnetze innerhalb zulässiger Betriebsgrenzen betrieben werden. Im Verteilnetz sind hierbei die zulässige Stromtragfähigkeit und das zulässige Spannungsband, in welchem sich alle Spannungen in einem Stromnetz befinden müssen, von Bedeutung. Die wichtigste Maßnahme zur Spannungshaltung im Verteilnetz ist die Möglichkeit mithilfe von, im Transformator eingebauten, Stufenschaltern das Übersetzungsverhältnis an der Oberspannungsseite zu verändern, wodurch sich auch die Spannung an der Unterspannungsseite verändert.

Transformatoren mit Stufenschaltern zwischen Mittelspannungs- und Niederspannungsebene, sogenannte Regelbare Ortsnetztransformatoren (RONT), sind jedoch noch relativ selten. Das zulässige Spannungsband, in dem die Niederspannungsebene für eine Spannungsänderung verantwortlich sein darf, insbesondere bei bidirektionalem Lastfluss, mit 2,5-5% von der Nennspannung relativ klein [9].

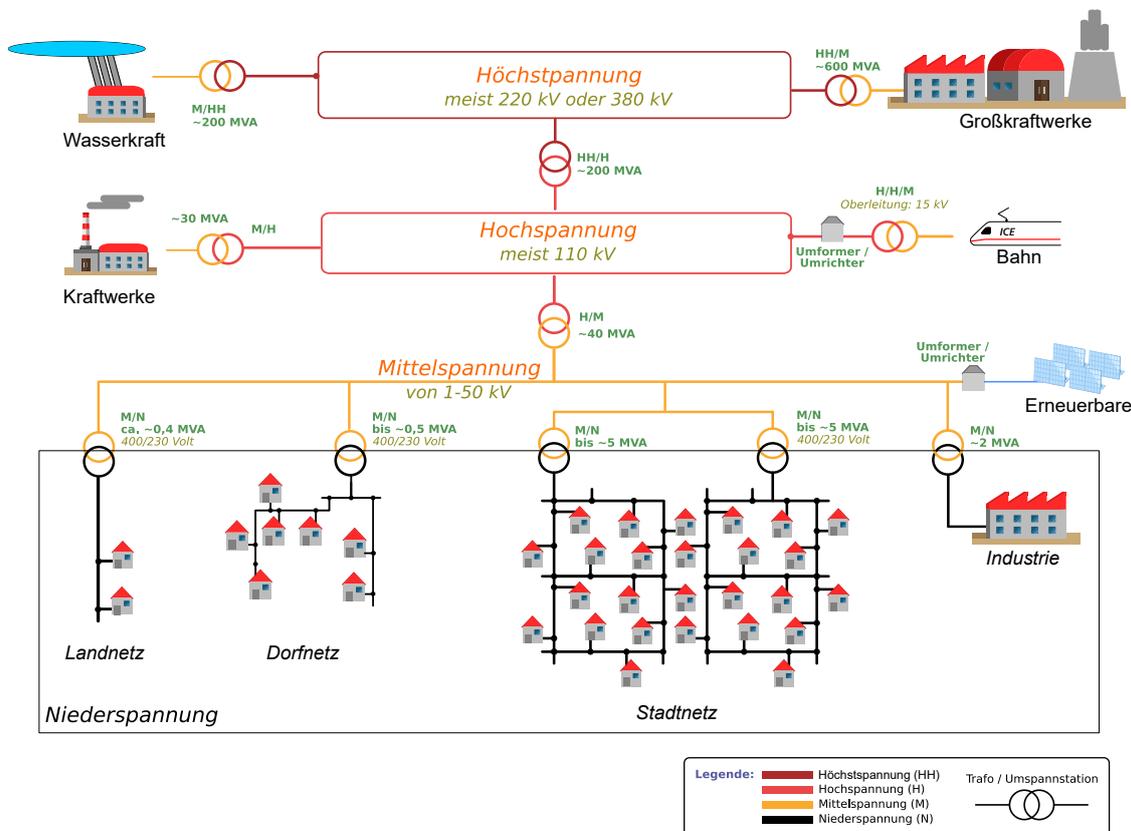


Abbildung 2.2 Übersicht über die Netzebenen (in Anlehnung an [10]).

Nach der VDE-AR-N 4105 des Forums Netztechnik/Netzbetrieb des VDE (FNN) [11], darf eine Spannungsänderung durch Betriebsmittel auf der Niederspannungsebene maximal 3% betragen. Die Netzfrequenz ist ein kritischer Parameter, wird jedoch durch die Kopplung der Niederspannungsnetze an Übertragungsnetze im europäischen Verbundnetz konstant bei 50 Hz gehalten. Im Niederspannungsnetz liegt das Augenmerk auf der Aufrechterhaltung der Spannungsstabilität und Sicherstellung der Versorgungssicherheit auch beim Anschluss von dezentralen Energieerzeugern. Insgesamt zielt der optimierte Betrieb von Niederspannungsnetzen darauf ab, die Netzauslastung zu maximieren, bevor ein Netzausbau erfolgen muss, Verluste zu minimieren und damit eine konstante und zuverlässige Stromversorgung für die Endverbraucher sicherzustellen.

2.2.1 Übertragungsnetz

Das Übertragungsnetz dient dem Transport elektrischer Energie über hunderte Kilometer von den Kraftwerken zu den Verbrauchern. Die Länge der Übertragungsnetze beträgt zurzeit ca. 37000 km [12]. Bei einem Kraftwerksausfall ermöglichen andere Kraftwerke im Verbundnetz die kurzzeitige Kompensation des Leistungseinbruchs [9]. Das europäische Verbundnetzwerk ENTSO-E repräsentiert

39 Übertragungsnetzbetreiber (engl. Transmission System Operator, TSO) aus 35 Staaten Europas [13]. Neben der Versorgungssicherheit zählen die Entwicklung des europäischen Strommarkts und die Integration erneuerbarer Energiequellen zu den Aufgaben des ENTSO-E. Die vier Übertragungsnetzbetreiber (ÜNB) 50Hertz-Transmission, Amprion, TenneT TSO und TransnetBW tragen die Verantwortung für die Übertragungsnetze in Deutschland. Neben der allgemeinen Betriebsführung gehört die Sicherstellung der Systemdienstleistungen Frequenz- und Spannungshaltung, Blindleistungsbereitstellung und Versorgungswiederaufbau nach einem Lastabwurf zu ihrem Tätigkeitsbereich. Zum Übertragungsnetz gehören die Höchst- und die Hochspannungsnetze.

Höchstspannungsnetze: Mehr als die Hälfte des gesamten öffentlichen elektrischen Energiebedarfs wird durch Kraftwerke und Windparks in die Höchstspannungsnetze der 380 kV und 220 kV Ebene eingespeist. Mit der zunehmenden Anzahl von dezentralen erneuerbaren Energieanlagen wird dieser Prozentsatz jedoch kleiner. Höchstspannungs- oder Transportnetze sind in einer Maschennetzstruktur angelegt, was einen weiträumigen Austausch von Energie mit anderen Regulierungsbereichen ermöglicht [6].

Hochspannungsnetze: Hochspannungsnetze (HS-Netze) besitzen eine Nennspannung von 110 kV und können aufgrund ihrer Eigenschaften sowohl Teil eines Übertragungsnetzes, als auch Teil eines Verteilnetzes sein. Strahlennetze kommen bei 110 kV Netzen am häufigsten zum Einsatz, seltener erfolgt die Ausführung als Maschennetz. Hochspannungsnetze erhalten ihre Energie aus dem übergeordneten Höchstspannungsnetz und versorgen damit hauptsächlich monodirektional Krankenhäuser, Universitäten, Raffinerien, Flughäfen und die Großindustrie. Bis auf die höheren Leistungen, größeren Strecken und den Eigenschaften der Impedanz ähneln sie dem Mittel- und Niederspannungsnetz [6]. In Deutschland sind 86.000 km Hochspannungsleitungen [14] verlegt.

2.2.2 Verteilnetz

Das Verteilnetz umfasst das Mittelspannungsnetz mit einer Länge von ca. 521.000 km [14] und das Niederspannungsnetz mit einer Länge von 1.194.000 km [14]. Aufgabe des Verteilnetzes ist die Verteilung der elektrischen Energie an die Endverbraucher. Durch die zunehmende Anzahl regenerativer Erzeugungsanlagen in den Mittel- und Niederspannungsnetzen kommt es zu bidirektionalen Energieflüssen, da in Zeiten hoher Einspeisung und geringer Last überschüssige Energie in die höheren Netzebenen transportiert wird.

Mittelspannungsnetze: Nach der Umwandlung der 110 kV eines Hochspannungsnetzes in einem Transformator liegt das Spannungsniveau von Mittelspannungsnetzen zwischen 10 kV und 30 kV. energieintensive Gebäude wie Fabriken, Verwaltungen und Kaufhäuser besitzen einen eigenen Anschluss an das Mittelspannungsnetz. In Wohngebieten stehen Ortsnetztransformatoren, welche die Mittelspannung auf 400 V umspannen [6].

Niederspannungsnetze: In den Niederspannungsnetzen befinden sich Endverbrauchergeräte, die eine Spannung von 400 V (Leiter-Leiter-Spannung) bzw. 230 V (Leiter-Erde-Spannung) nutzen. Da in Niederspannungsnetzen ein Neutralleiter zu den drei üblichen Leitern hinzukommt, spricht man hier auch von Vierleiternetzen [6]. Wegen der geringen Spannung und den relativ kurzen Leitungslängen im Niederspannungsnetz ist der Wirkwiderstand deutlich größer als der Blindwiderstand. Die Wirkleistung verändert primär den Spannungsbetrag. Dagegen hat die Blindleistung einen großen Einfluss auf den Spannungswinkel und eine sehr geringe Auswirkung auf den Spannungsbetrag. Eine Vereinfachung der Berechnung des Spannungsbetrags für das Niederspannungsnetz wurde in Kapitel 4.1 hergeleitet.

3 Simulationsumgebung für komplexe Energiesysteme

Dieses Kapitel dient der Beschreibung des Simulationsmodells, welches in dieser Arbeit als Ersatz für ein Versuchsmodell (Experiment) verwendet wird. Modelle sind unverzichtbare Werkzeuge für die umfangreiche Analyse und Evaluation von Versuchsreihen im Energiesystem, da großskalige Modellversuche sehr aufwendig und teuer sind.

Die Verwendung von Simulationsmodellen in der Energieforschung hat in den vergangenen Jahren stark zugenommen, da sie eine kosteneffektive Möglichkeit bieten, um die Auswirkungen von verschiedenen Szenarien auf das Energiesystem zu untersuchen. Diese Modelle können dazu beitragen, das Verhalten von Energiesystemen unter verschiedenen Bedingungen zu verstehen und zu optimieren, um so die Effizienz und Nachhaltigkeit der Energieversorgung zu verbessern.

Das in dieser Arbeit verwendete Simulationsmodell bildet das gesamte Energiesystem ab und integriert diverse Energiequellen – darunter erneuerbare Energien, traditionelle Kraftwerke und Speichersysteme. Es ist darauf ausgelegt, das Verhalten des Energiesystems unter vielfältigen Szenarien authentisch zu simulieren. Die Realitätsnähe des Modells wurde durch eine sorgfältige Kalibrierung von einzelnen Modellkomponenten im Labor gewährleistet.

Durch die Verwendung des Simulationsmodells können verschiedene Aspekte und Randbedingungen des Energiesystems untersucht werden, wie die Integration erneuerbarer Energien in das Stromnetz, die Optimierung von Betriebsstrategien und Steuerungsalgorithmen oder die Bewertung der Wirtschaftlichkeit von Energiespeichersystemen. Diese können unter unterschiedlichen Randbedingungen, wie Lastprofilen, Wetterbedingungen oder Betriebsstrategien betrachtet werden. Ferner können die Auswirkungen von Änderungen der Systemparameter wie Kapazität und Effizienz von Energiespeichern oder der Installation von zusätzlichen Erzeugungseinheiten untersucht werden.

In Abbildung 3.1 ist der Aufbau des Simulationsmodells dargestellt.

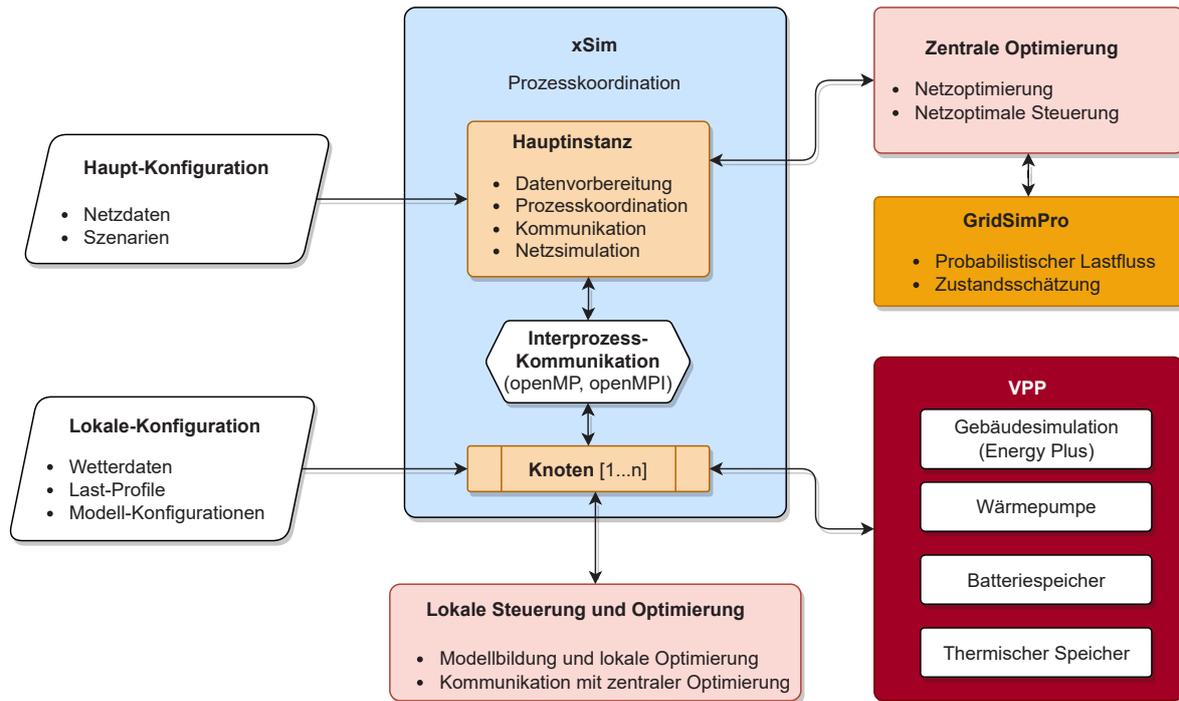


Abbildung 3.1 Funktionaler Aufbau des Simulationsmodells. Das xSim Paket stellt die Hauptkomponente der Simulationsumgebung dar. Das VPP (Virtual Power Plant) Paket beinhaltet die Komponenten des Energiesystems, welche in einem Quartier vorhanden sein können und bei geeigneter Steuerung als lokales virtuelles Kraftwerk agieren. Weitere Pakete beinhalten die Optimierung (Kapitel 6) und die Netzsimulation (GridSimPro, siehe Kapitel 4).

3.1 Thermisches Gebäudemodell

Das thermische Gebäudemodell dient zur Abschätzung des thermischen Gebäudeenergiebedarfs und der zeitabhängigen Gebäudeinnentemperatur in Abhängigkeit von Heizleistung und Wetter. Weiterhin werden verschiedene Komponenten implementiert, um eine vollständige Gebäudesimulation zu ermöglichen, z.B. ein thermischer Speicher und eine Wärmepumpe. Die Gebäudesimulation ist in Python implementiert und nutzt EnergyPlus [15] als Gebäudesimulations-Framework.

EnergyPlus wurde entwickelt, um den thermischen Leistungsbedarf von Gebäuden unter verschiedenen Betriebs- und Wetterbedingungen zu simulieren. Das Modell verwendet eine Kombination aus Wärmeübertragungs- und Massenbilanzgleichungen, um den Energiefluss und die Temperaturverteilung innerhalb des Gebäudes zu berechnen [16]. Die Simulation wurde in verschiedenen Studien validiert und zeigte in den Testfällen eine gute Übereinstimmung mit den experimentell bestimmten Messwerten [17–20].

Das zugrunde liegende Gebäudemodell orientiert sich an einem Referenzgebäude, welches flexibel an diverse Simulationsszenarien angepasst werden kann. Faktoren wie der Energiestandard des Gebäudes oder die Ausrichtung des Gebäudes, die signifikanten Einfluss auf die solare Wärmegewinnung hat, können gezielt modifiziert werden. Dadurch kann der Heizwärmebedarf für verschiedene Szenarien berechnet werden. In den folgenden Abschnitten wird eine detaillierte Darstellung des Gebäudemodells sowie dessen Einordnung in entsprechende Energiestandards vorgenommen.

Als Ausgangspunkt dient ein Einfamilienhaus mit einer Nutzfläche von $179,5 \text{ m}^2$, was im Kontext von Anlagensimulationen in Europa als repräsentativ betrachtet werden kann. Die Gebäudehülle umfasst eine Fläche von $416,8 \text{ m}^2$, während der Bruttorauminhalt bei 561 m^3 liegt. Die Berechnung dieser Werte erfolgt auf der Grundlage der Außenmaße des Referenzgebäudes, wobei die Nutzfläche proportional zum Gebäudevolumen angenommen wird. Die Bodenplatte des Gebäudes grenzt an einen unbeheizten Keller an und der Dachboden zählt nicht zur beheizten Fläche. Es wird angenommen, dass das Gebäude keiner Beschattung unterliegt und kein Sonnenschutz vorhanden ist. Durch gezielte Modifikation der Wandstärke sowie der Isolationsmaterialien kann das Gebäudemodell an verschiedene Energiestandards angepasst werden.

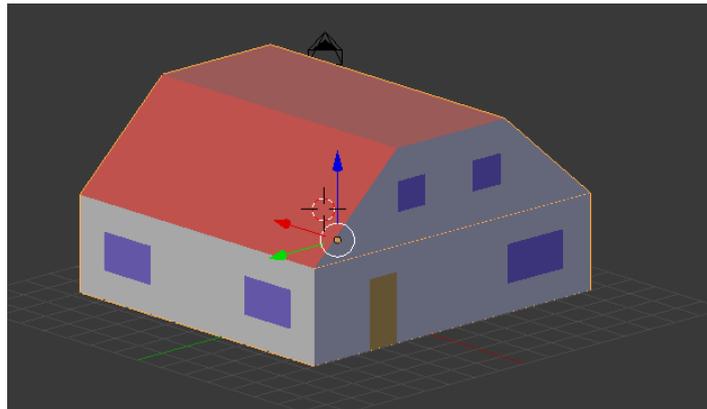


Abbildung 3.2 Modell des Referenzgebäudes [21].

3.2 Thermisches Speichermodell

In der Literatur wurden bereits eine Vielzahl an Modellen von thermischen Schichtspeichern vorgestellt [22–24]. Dabei wird häufig ein Ansatz verfolgt, bei dem die zugrunde liegenden Differenzialgleichungen linearisiert werden [25]. Diese Linearisierung kann die Analyse der komplexen Wechselwirkungen zwischen Ausgleichsströmungen, Wärmeübertragung und thermischen Verlusten vereinfachen, indem sie die Beschreibung des Systems auf quasi stationäre Zustände und ein lineares Modell reduziert. Die Linearisierung wird an einem Arbeitspunkt vorgenommen, der sich am vorherigen Zustand des Tanks orientiert. Für eine genaue Zeitreihensimulation ist es wichtig, eine angemessene Schrittweite zu wählen. In der aktuellen Implementierung wurde dies berücksichtigt, wobei das Speichermodell mit einer maximalen zeitlichen Auflösung von 60 s betrieben wird. Die Linearisierung erleichtert die Integration des thermischen Schichtspeichermodells in größere Systemsimulationen, wie sie im Energiebereich häufig vorkommen. Die Berechnungsstruktur basiert auf einem Knotenmodell, wobei jeder Knoten eine Schicht im Speicher repräsentiert und deren Eigenschaften speichert [22, 26, 27]. Zusätzlich zu den diskreten Knoten, welche eine Schicht im Speicher repräsentieren, wird in der obersten Schicht, eine kontinuierliche Variable eingeführt, welche eine kontinuierliche Abbildung des Tank-Ladezustands erlaubt. Dies ist in Abbildung 3.3 dargestellt.

Obwohl dieser Ansatz gewisse Einschränkungen in Bezug auf die Genauigkeit haben kann, insbesondere in Regionen, in denen das System stark von der Linearisierung abweicht, bietet er dennoch ein grundlegend realistisches Modell für das Verhalten des Speichers.

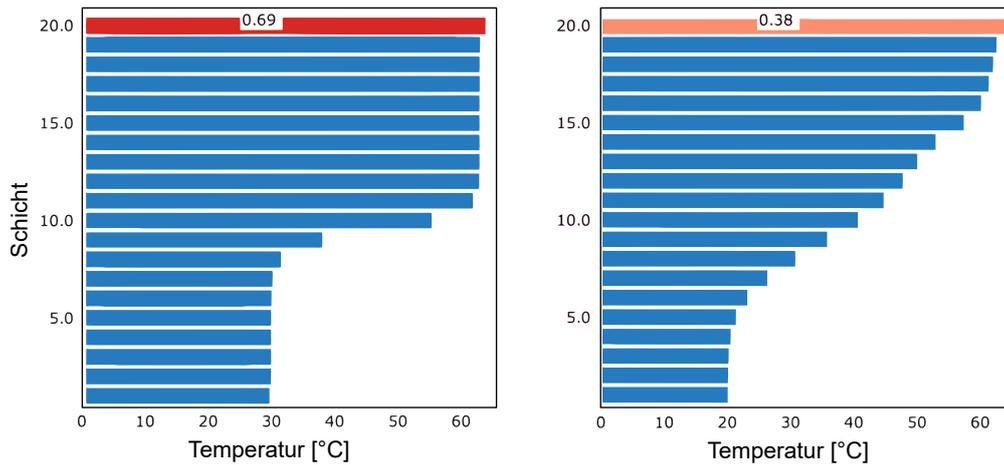


Abbildung 3.3 Plot der Temperaturverteilung im thermischen Schichtspeicher zu Beginn der Simulation (links) und nach einem vollen Lade- und Entladezyklus [21].

3.3 Wärmepumpenmodell

Ein nachhaltiges Energiesystem muss die Sektoren Strom, Wärme und Verkehr adressieren. Die Elektrifizierung von Prozessen unterstützt die Abkehr von fossilen Brennstoffen. Damit sind Wärmepumpen ein wichtiger Baustein zur Energiewende und werden zu zunehmendem Strombedarf führen. Daher ist die Integration von Wärmepumpen in das Simulationsmodell eines zukunftsfähigen Energiesystems essenziell, um den steigenden Gebrauch dieser Technologie zu Rechnung zu tragen. Die Modellierung der Wärmepumpe berücksichtigt dabei das Spannungsfeld zwischen Detailgenauigkeit und Modellkomplexität.

Wärmepumpen basieren auf dem Carnot-Zyklus und umfassen verschiedene Phasen: die Absorption von Wärme durch das Kältemittel aus der Umgebungsluft oder geothermisch erwärmtem Wasser während der Verdampfungsphase; die Erwärmung und Verdichtung des gasförmigen Kältemittels im Kompressor; die Wärmeübertragung von dem abgekühlten Kältemittel auf das Wasser im Wärmetauscher während der Verflüssigungsphase; und schließlich die Reduzierung des Drucks und die Abkühlung des Kältemittels in der Drossel, bevor es zurück in den Verdampfer geleitet wird, um den Zyklus zu schließen. Die Kreisläufe einer Wärmepumpe sind in Abbildung 3.4 dargestellt.

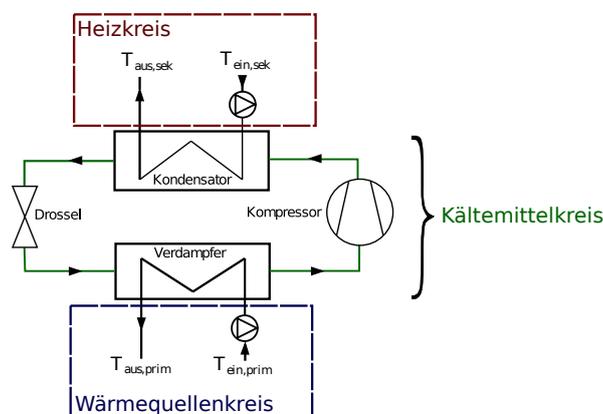


Abbildung 3.4 Schema einer Wärmepumpe mit eingezeichneten Teilkreisen und Komponenten [21].

Die Durchführung einer detailgenauen thermischen Simulation von Wärmepumpensystemen stellt aufgrund der hohen Rechenanforderungen eine erhebliche Herausforderung dar. Jeder Simulationszeitschritt erfordert die Lösung eines vollständigen thermodynamischen Kreisprozesses, welcher Verdampfung, Kompression, Kondensation und Expansion beinhaltet. Diese Phasen sind durch physikalische Gleichungen charakterisiert, die in Bezug auf diverse thermodynamische Parameter und unter Berücksichtigung variierender Randbedingungen gelöst werden müssen. Daher ist eine ausführliche thermische Simulation oftmals unpraktikabel, insbesondere bei der Simulation von längeren Zeiträumen oder auf eine große Anzahl von Systemen.

Das hier vorgestellte Wärmepumpen-Modell zielt auf die Entwicklung eines realistischen, aber nicht übermäßig komplexen Modells ab. Das Ziel der Vereinfachung ist die effiziente Berechnung der Leistungszahl (Coefficient of Performance, COP), d. h. des Verhältnisses von Wärmeabgabe (\dot{Q}_h) zu elektrischer Energiezufuhr ($P_{el, HP}$), wie in Gleichung 3.1 definiert. Die Temperaturen der kalten und warmen Seite (T_k, T_h) sind dabei von besonderer Bedeutung, da sie einen direkten Einfluss auf die Carnot-Leistungszahl (ε_{carnot}) haben. Zudem haben mechanische Verluste eine erhebliche Auswirkung auf den Wirkungsgrad. Diese werden im Gütegrad ν berücksichtigt.

$$\text{COP} = \frac{\dot{Q}_h}{P_{el, HP}} = \nu \cdot \varepsilon_{carnot} \quad (3.1)$$

$$\varepsilon_{carnot} = \frac{T_k}{T_k - T_h} = \frac{1}{\eta_{carnot}} \quad (3.2)$$

3.3.1 Modellierung

Um einen besseren Überblick über die Effizienzberechnungen einer Wärmepumpe zu erhalten, werden im Folgenden die einzelnen Berechnungsschemata aufgeteilt und gesondert erläutert. Diese Aufteilung ist ebenfalls in der Abbildung 3.5 zu sehen. Im ersten Schritt wird das temperaturabhängige Teillastverhalten bestimmt. Im zweiten Schritt wird die Leistungsabhängigkeit der Wärmepumpe abgebildet.

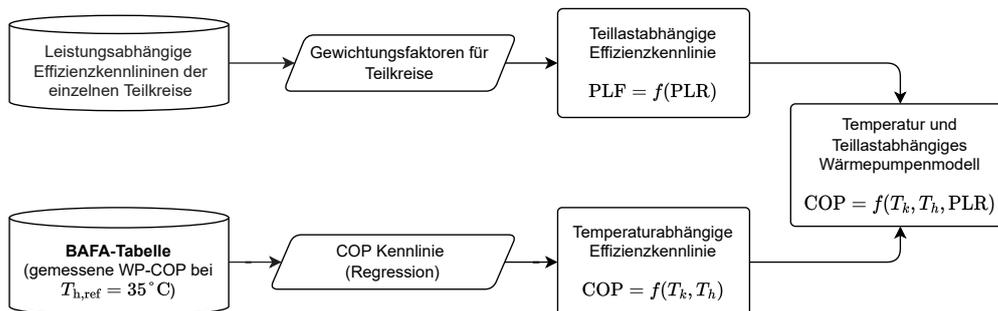


Abbildung 3.5 Darstellung der Einflussfaktoren für die Modellierung der Wärmepumpe: Gewichtung der Effizienzkennlinien der Teilkreise und Anpassung des temperaturabhängigen Wirkungsgrades gemäß den Daten des Bundesamts für Wirtschaft und Ausfuhrkontrolle (BAFA) [21, 28].

Temperaturabhängiges Teillastverhalten

Die Effizienz einer Wärmepumpe, repräsentiert durch den Leistungskoeffizienten oder COP, korreliert direkt mit der Temperaturspanne zwischen der Wärmequelle (T_k) und dem Heizsystem (T_h). Ein höheres Temperaturniveau der Quelle und eine niedrigere Heiztemperatur erhöhen den COP, da die Wärmepumpe weniger Energie aufwenden muss, um die Wärme auf das erforderliche Niveau anzuheben. Andererseits führen eine kühlere Quelltemperatur und eine höhere Heiztemperatur zu einem niedrigeren COP, weil mehr Energie für den Wärmetransport notwendig ist.

Um den thermischen Einfluss der Quelltemperatur auf den COP zu ermitteln, wurde eine Funktion für den $\text{COP}_{\text{nom, ref}}$ aus den Daten des Prüf- und Effizienznachweisen vom Bundesamt für Wirtschaft und Ausfuhrkontrolle (BAFA) [29] erstellt (Gleichung 3.3). Diese Tabelle beinhaltet alle förderfähigen Wärmepumpen in Deutschland und ihre jeweiligen Daten und Kennzahlen unter Referenzbedingungen ($T_{h, \text{ref}}$).

$$\text{COP}_{\text{nom, ref}}(T_k, T_{h, \text{ref}}) = f(T_k) \quad (3.3)$$

Nach der Bestimmung des $\text{COP}_{\text{nom, ref}}$ bei Nominalleistung kann über das Verhältnis der Carnot-Wirkungsgrade der thermische Einfluss auf die Leistungszahl angenähert werden, wie in Gleichung 3.4 beschrieben.

$$\text{COP}_{\text{nom}}(T_k, T_h) = \text{COP}_{\text{nom, ref}}(T_k, T_{h, \text{ref}}) \cdot \frac{\eta_{\text{carnot}}(T_k, T_{h, \text{ref}})}{\eta_{\text{carnot}}(T_k, T_h)} \quad (3.4)$$

Leistungsbezogenes Teillastverhalten

Seit einigen Jahren dominieren Wärmepumpen mit variabler Drehzahl den Markt. Deshalb ist neben der Temperaturabhängigkeit eine realistische Modellierung des Teillastbetriebs von Bedeutung. Für die Leistungsfähigkeit einer Wärmepumpe bei Teillast spielt die relative Auslastung (Part Load Ratio, PLR) und die entsprechende Effizienz der Teilkomponenten eine große Rolle.

Gemäß Abbildung 3.4 kann eine Wärmepumpe in drei Teilkreise und sieben Komponenten unterteilt werden, welche zur besseren Übersicht in Tabelle 3.1 in Anlehnung an ihre stofflich entkoppelten Teilkreise dargestellt sind. Der Gesamtwirkungsgrad der Wärmepumpe setzt sich aus den gewichteten Wirkungsgraden der einzelnen Komponenten zusammen und ist in Gleichung 3.5 dargestellt.

$$\eta_{\text{PLR}}(\text{PLR}) = \sum_{i \in \mathcal{K}_{\text{WP}}} \kappa_i \frac{\eta_i(\text{PLR})}{\eta_{i, \text{nom}}} \quad (3.5)$$

wobei

$$\text{PLR} = \frac{P}{P_{\text{nom}}} \quad (3.6)$$

Hierbei bezeichnet η_{PLR} das Verhältnis der tatsächlichen Effizienz im Teillastbetrieb $\eta(\text{PLR})$ zur Effizienz bei Nennleistung η_{nom} . Die relative Leistung PLR wird durch das Verhältnis der tatsächlichen

Leistung P zur Referenz- oder Nennleistung P_{nom} ausgedrückt. Die Effizienzkennlinien $\eta_i(\text{PLR})$ der unterschiedlichen Komponenten der Wärmepumpe wurden aus der TESP_y Bibliothek [30] entnommen. Diese Effizienzwerte erlauben es, die Kennlinien der verschiedenen Teilkreise zu bestimmen und daraus einen Gesamteffizienzwert zu berechnen. Dabei werden innerhalb der Teilkreise die Gewichtungsfaktoren κ für die Komponenten bestimmt, welche von der spezifischen Rolle im System abhängen.

Tabelle 3.1: Komponenten des Wärmepumpenmodells, aufgeteilt nach den drei Teilkreisen.

Teilkreise	Komponenten (\mathcal{K}_{WP})
Wärmequellenkreis (Teilkreis 1)	Pumpe, Heiße Seite des Verdampfers
Kompressorkreis (Teilkreis 2)	Kalte Seite des Verdampfers, Kompressor, Heiße Seite des Kondensators
Heizkreis (Teilkreis 3)	Kalte Seite des Kondensators, Pumpe

Anlaufverhalten

Während des Starts muss eine Wärmepumpe die thermische Trägheit des Systems überwinden und das Kältemittel und die Wärmeträgerflüssigkeit auf die gewünschte Betriebstemperatur bringen. Dies erfordert eine erhebliche Energiemenge und kann zu einem hohen anfänglichen Stromverbrauch führen. Der genaue Energiebedarf hängt von Faktoren wie der Größe der Wärmepumpe, dem Temperaturunterschied zwischen der Wärmequelle und der Wärmesenke und der thermischen Masse des Systems ab. Für das Anlaufverhalten wird die ermittelte Kurve nach Nielsen [31] in das Modell einbezogen. Dies führt zu einer Überhöhung der Leistungsaufnahme beim Anlaufen abhängig von der Kältemitteltemperatur.

3.3.2 Abschluss der Modellentwicklung und Kalibrierung

Die finale Wärmepumpenmodell ergibt sich unter Verwendung von Gleichung 3.4 und 3.5 zu:

$$\text{COP}(T_k, T_h, \text{PLR}) = \eta_{\text{PLR}}(\text{PLR}) \cdot \text{COP}_{\text{nom}}(T_k, T_h) \quad (3.7)$$

Für die Validierung und Verbesserung wurden verschiedene Studien analysiert und die Ergebnisse bei der Wärmepumpenmodellierung berücksichtigt.

Da der Kompressor die dominierende mechanische Komponente ist, bestimmt er den Wirkungsgrad in hohem Maße. Dies wurde in [32, 33] und auch in [34] experimentell untersucht und die Ergebnisse unterstreichen die bedeutende Rolle des Kompressors für die Effizienz einer Wärmepumpe.

Das hier vorgestellte Wärmepumpenmodell wurde anhand einer experimentellen Kennlinie validiert [34]. Dabei wurde die Methode der kleinsten Fehlerquadrate (Least-Square-Fitting) verwendet, um zu ermitteln, mit welchen Gewichtungsfaktoren die einzelnen Teilkreis-komponenten der Wärmepumpe zum Gesamtwirkungsgrad beitragen. Die größten Gewichtungsfaktoren fallen hierbei für den Kompressorkreis und den Kompressor an, was die Wichtigkeit des Kompressors für das Teillastverhalten einer Wärmepumpe bestätigt.

In der Abbildung 3.6 ist der Vergleich zwischen Modell und finaler Kennlinie dargestellt.

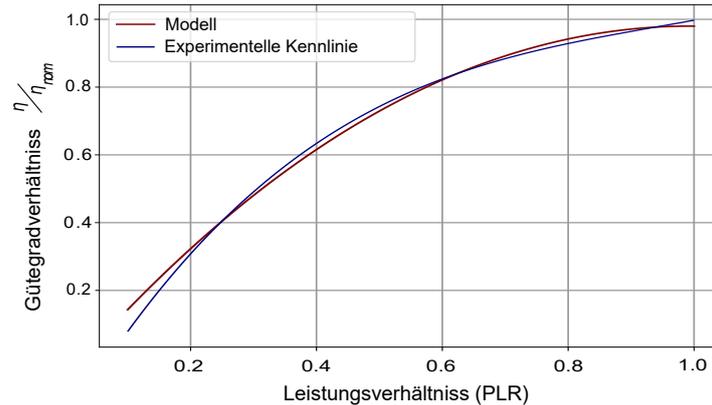


Abbildung 3.6 Vergleich des Modells [21] und der Referenzkennlinie [34] über die Teillastbereiche.

3.4 Modellierung des Batteriespeichersystems

Die Charakteristik von Batteriespeichersystemen wird durch ein komplexes Zusammenspiel verschiedener Einflussgrößen geprägt, unter anderem durch die Temperatur, den Ladezustand sowie die Ladeleistung. Um das Verhalten dieser Systeme unter variierenden Betriebsbedingungen voraussagen und damit eine effiziente und wirksame Betriebsführung realisieren zu können, werden Modelle herangezogen.

Es existieren unterschiedliche Kategorien von Modellen für Batteriespeichersysteme, die jeweils einen spezifischen Grad an Komplexität und Genauigkeit aufweisen.

Empirische Modelle: beruhen auf experimentellen Daten und nutzen empirische Beziehungen zur Abbildung der Systemdynamik. Sie basieren auf real ermittelten Messdaten des Batterieverhaltens unter diversen Betriebszuständen. Empirische Modelle zeichnen sich durch eine relativ einfache Struktur und geringeren Rechenressourcenverbrauch im Vergleich zu komplexeren Modellen, wie Ersatzschaltbild- oder elektrochemischen Modellen, aus. Daher sind sie besonders geeignet für Anwendungen in der Dimensionierung und Leistungseinschätzung sowie in der schnellen Bewertung unterschiedlicher Betriebsszenarien. Während empirische Modelle besonders vorteilhaft in der Vorhersage des Verhaltens des Batteriespeichersystems unter stationären Bedingungen und in der Abschätzung der Auswirkungen verschiedener Lasten auf das System sind, kann die Genauigkeit unter dynamischen oder instationären Bedingungen limitiert sein. Ferner erlauben sie keinen Einblick in die physikalischen und chemischen Mechanismen, die dem Batterieverhalten zugrunde liegen. Bei Bedarf an einem detaillierteren Verständnis des Batteriespeichersystems können daher komplexere Modellarten, wie Ersatzschaltbild- oder elektrochemische Modelle, erforderlich sein.

Ersatzschaltkreismodelle: repräsentieren die Batterie in Form eines Ersatzschaltkreises, bestehend aus Widerständen, Kapazitäten und weiteren Schaltungselementen. Diese Modelle sind in ihrer Komplexität höher angesiedelt als empirische Modelle, können jedoch eine präzisere Darstellung des Batterieverhaltens unter verschiedenen Betriebsbedingungen liefern.

Elektrochemischen Modelle: Modelle, welche die in der Batterie ablaufenden elektrochemischen Reaktionen simulieren, berücksichtigen Einflussgrößen wie Diffusion, Reaktionskinetik und das Verhalten der Elektroden. Diese Modelle stellen die komplexeste und genaueste Form von Batteriemodellen dar, sie erfordern jedoch detaillierte Kenntnisse über die Batteriechemie und die Materialeigenschaften.

Während empirische Modelle eine schnelle Abschätzung des Batterieverhaltens unter verschiedenen Bedingungen ermöglichen, sind sie möglicherweise nicht unter allen Betriebsbedingungen ausreichend genau. Für ein detaillierteres Verständnis des Batteriespeichersystems können komplexere Modellansätze erforderlich sein. Der Einsatz eines empirischen Modells für ein Batteriespeichersystem ist dann angemessen, wenn ein einfaches, leicht handhabbares Modell zur Analyse und Bewertung des Systems genügt. Daher wurde in dieser Arbeit auf ein empirisches Modell für das Batteriespeichersystem zurückgegriffen.

3.4.1 Modellbildung auf der Grundlage von Laboruntersuchungen an Batteriespeichersystemen

Das im Labor des Zentrums für Sonnenenergie- und Wasserstoff-Forschung Baden-Württemberg (ZSW) getestete Batteriespeichersystem ist ein kommerzielles AC-gekoppeltes System mit Notstromversorgung für Stromausfälle. Es ist in der Lage, in dreiphasigem Betrieb bis zu 20 kVA Leistung ein- oder auszuspeisen und kann asymmetrische Lasten mit bis zu 6,67 kVA pro Phase speisen. Zudem ist das System in der Lage, Blindleistung zu liefern oder aufzunehmen, und kann mit einem Leistungsfaktor im Bereich von -1 bis 1 betrieben werden. Die Standardkonfiguration des Systems arbeitet in einem Ladezustandsbereich (SOC) von 10 % bis 90 % und ermöglicht eine Entladetiefe (DOD) von 80 %.

Tabelle 3.2: Systemwirkungsgrade des Batteriespeichersystems für verschiedene Leistungen, gemessen an einem Vollzyklus.

P_{soll} [kW]	E_{in} [kWh]	E_{out} [kWh]	SOC_0 [%]	SOC_{min} [%]	DOD [%]	$C_{\text{sys, eff}}$ [kWh]	η [%]
20	13,38	-9,22	90	7	83	11,11	69,0
15	13,07	-9,68	90	7	83	11,66	74,1
10	12,68	-9,92	90	11	79	12,55	78,2
5	12,21	-9,74	91	13	78	12,49	79,8
Mittelwert						11,95	75,3

Der Systemwirkungsgrad wird definiert als das Verhältnis der ausgespeisten zur eingespeisten Energie des Speichersystems. Die Ergebnisse der Laboruntersuchungen sind in Tabelle 3.2 dargestellt. Der Systemwirkungsgrad über verschiedene Entladetiefen ist zudem in Abbildung 3.7 abgebildet.

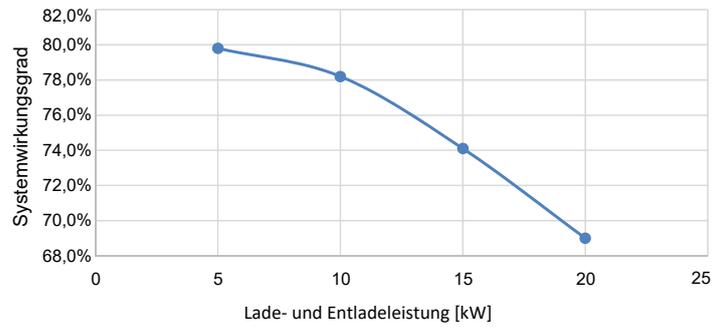


Abbildung 3.7 Batterie Systemwirkungsgrad für verschiedene Entladetiefen.

Ein Batteriespeichersystem kann üblicherweise nicht mit voller Leistung bis zu 100 % SOC geladen werden. Dies wurde ebenfalls im Modell berücksichtigt. Eine Validation des Modells ist in Abbildung 3.8 dargestellt.

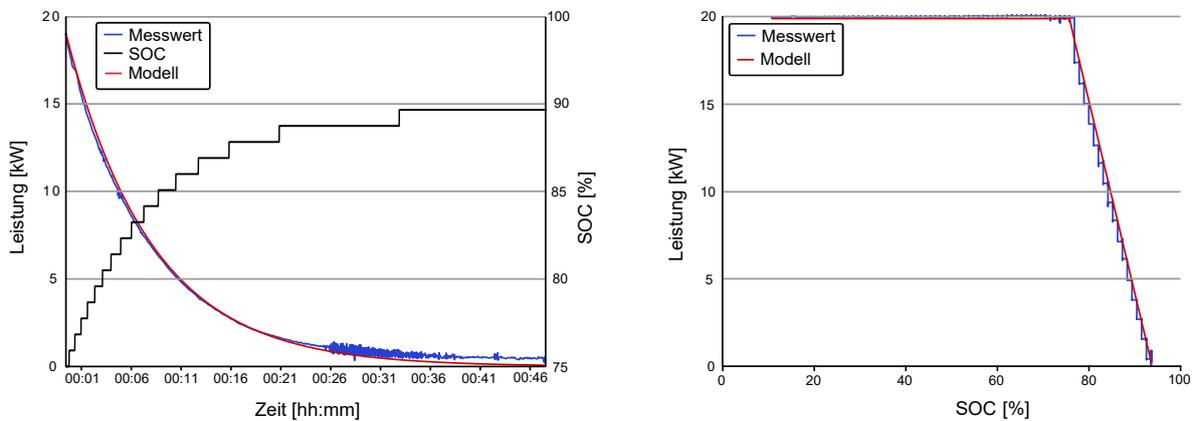


Abbildung 3.8 Validation des Batteriemodells für hohe SOC Bereiche.

Alterungsmodell

Das Batterie-Alterungsmodell ermöglicht die Abschätzung der Batteriealterung und basiert auf einem im Projekt Solion [35] entwickelten Ansatz. Das Modell ist ein energiebasiertes Modell und berücksichtigt daher die typischen Eingangsgrößen: Ladezustand (SOC), Temperatur (T) und Zyklustiefe DOD. Der Ausgabewert des Modells ist ein Indikator für den Zustand der Batterie (State-of-Health). Bei einer neuen Batterie ist der Wert 0 und bei einer Batterie, die das Lebensende erreicht hat 1. Das Ende der Lebensdauer ist definiert als 80% der ursprünglichen Kapazität oder ein Anstieg des Innenwiderstands um den Faktor 2. Der zunehmende Widerstand führt zu einem sinkenden Wirkungsgrad über die Lebensdauer [36]. Dieser relative Effizienzverlust wird regelmäßig berechnet und die Modellparameter werden angepasst. Es wird davon ausgegangen, dass beide Effekte (Kapazitätsverlust und Widerstandserhöhung) korreliert sind und beide Kriterien am Ende der Lebensdauer erreicht werden. Die Energieverluste werden durch den Innenwiderstand verursacht, weshalb die Energieeffizienz mit der Alterung abnimmt.

3.5 PV-Modellierung und Ertragsabschätzung

Bei der Ertragsberechnung von Photovoltaik-Anlagen (PV) werden sowohl analytische als auch datengetriebene Modelle verwendet, wobei jeder Ansatz seine eigenen Vorzüge und Herausforderungen aufweist. Analytische Modelle ermöglichen eine allgemeine Ertragsabschätzung, die auf bekannten Anlageneigenschaften basiert, und bieten den Vorteil, dass sie ohne spezifische Informationen über die jeweilige Anlage angewendet werden können. Im Gegensatz dazu können datengetriebene Methoden, die auf historischen Daten und individuellen Anlageneigenschaften basieren, eine präzisere Ertragsprognose liefern [37]. Allerdings erfordern diese Modelle eine umfassende Datenbasis und müssen für jede Anlage neu angepasst oder trainiert werden, was den Einsatz in Szenarien erschwert, in denen keine spezifischen Daten vorliegen. Bei dieser Arbeit ist ein zentrales Kriterium die Fähigkeit, ein Modell auf Anlagen anzuwenden, bei denen außer den Anlageneigenschaften keine weiteren spezifischen Informationen bekannt sind. In diesem Kontext spielen analytische Modelle eine entscheidende Rolle, da sie auf grundlegenden physikalischen Prinzipien und allgemein bekannten Eigenschaften basieren, wie Neigung, Ausrichtung und lokalen Sonneneinstrahlung. Diese Herangehensweise ermöglicht eine Ertragsabschätzung, die breit anwendbar und unabhängig von individuellen Anlagendaten ist, was den Einsatz in verschiedenen Kontexten ohne aufwendige Anpassungen oder Neutraining erleichtert.

Das PV-Modul Modell basiert auf einer von Huld modifizierten Form [38] des sogenannten King-SANDIA-Modells [39]. Die Berechnung der Gleichstromleistung der Photovoltaikanlage erfolgt mit der Leistung der PV-Anlage unter Standard Test Conditions (STC) P_{STC} , der Einstrahlung unter STC $I_{STC} = 1000 \text{ W/m}^2$, der momentanen Totalstrahlung POA auf das Modul und des relativen Modulwirkungsgrades η_{rel} :

$$P_{dc} = P_{STC} \cdot \frac{POA}{I_{STC}} \cdot \eta_{sys} \cdot \eta_{rel} \quad (3.8)$$

Die Systemeffizienz η_{sys} berücksichtigt sonstige Verlustquellen, wie Mismatching der Module, Reflexionen an der Moduloberfläche, Verschmutzungen, Widerstandsverluste der Gleichstromverkabelung u. a. und wird pauschal zu $\eta_{sys} = 95\%$ angenommen. Tabelle 3.3 zeigt eine Übersicht der verschiedenen Verlustquellen.

Tabelle 3.3: Sonstige Verlustquellen des PV-Modells

Verlustquelle	Höhe des Verlustes
Mismatching	1%
Reflexionen	1,5%
Verschmutzungen	2%
Gleichstromverkabelung	0,5%

3.5.1 Wirkungsgrad des Photovoltaikmoduls

Der relative Wirkungsgrad des Photovoltaikmoduls kann mit folgender Gleichung beschrieben werden [38]:

$$\eta_{\text{rel}} = 1 + k_1 \cdot \mathcal{R} + k_2 \cdot \mathcal{R}^2 + (k_3 + k_4 \cdot \mathcal{R} + k_5 \cdot \mathcal{R}^2) \cdot \Delta T + k_6 \cdot \Delta T^2 \quad (3.9)$$

wobei

$$\mathcal{R} = \ln \frac{POA}{I_{\text{STC}}}, \quad \Delta T = T_{\text{Mod}} - T_{\text{STC}}.$$

Die Koeffizientenwerte von k_1 bis k_6 variieren in Abhängigkeit von der spezifischen Photovoltaikmodultechnologie. In Tabelle A.2 werden die entsprechenden Koeffizienten für die drei Technologien - kristallines Silizium (c-Si), Kupfer-Indium-Diselenid (CIS) und Cadmiumtellurid (CdTe) - dargestellt.

Modultemperatur

Die Modultemperatur T_{Mod} ist ein kritischer Parameter bei der Modellierung von Photovoltaiksystemen. Während ein Anstieg der Modultemperatur einen geringfügigen Anstieg des Modulstroms einer PV-Anlage verursacht, ergibt sich eine bedeutende Verringerung der Modulspannung. Für kristalline PV-Module liegt die Temperaturabhängigkeit etwa bei $-0,4\%/K$. Das bedeutet, dass eine Erhöhung der Modultemperatur um 10 K zu einem Leistungsverlust von etwa 4% führt. In der Sommerzeit kann dieser Leistungsverlust bis zu 20% betragen.

Ein gängiger Ansatz zur Berechnung der Modultemperatur ist ein linearer Modellansatz:

$$T_{\text{Mod}} = T_{\text{U}} + c_{\text{temp}} \cdot POA \quad (3.10)$$

In dieser Gleichung repräsentiert T_{U} die Umgebungstemperatur, POA steht für die auf das Modul einfallende Strahlung und c_{temp} ist der Temperaturkoeffizient, der durch die Montageart des Moduls beeinflusst wird [40]. Die Tabelle A.3 zeigt die Temperaturkoeffizienten für verschiedene Installationsmethoden wie Freiflächenanlagen, Aufdachanlagen und dachintegrierte Anlagen.

Darüber hinaus berücksichtigt das von David King vorgeschlagene Temperaturmodell [39] die Windgeschwindigkeit v_{W} , gemessen in 10 m Höhe, um die Modultemperatur genauer zu bestimmen:

$$T_{\text{Mod}} = POA \cdot \exp(a + b \cdot v_{\text{W}}) + T_{\text{U}}. \quad (3.11)$$

3.5.2 Wechselrichtermodell

Das Wechselrichtermodell beschreibt den Wirkungsgrad η_{WR} des Wechselrichters durch den Ansatz

$$\eta_{\text{WR}} = \frac{P_{\text{ac}}}{P_{\text{dc}}} = 1 - \frac{k_0 + k_1 \cdot P_{\text{dc}} + k_2 \cdot P_{\text{dc}}^2}{P_{\text{dc}}}, \quad (3.12)$$

Die drei Koeffizienten k_0 bis k_2 geben die drei Komponenten der Verluste in einem Wechselrichter an. Die konstanten Eigenverluste sind mit k_0 , die Verluste, welche linear mit dem Strom ansteigen, mit k_1 und Verluste, welche quadratisch mit dem Strom ansteigen, mit k_2 berücksichtigt. Die in der Simulation verwendeten Koeffizienten stammen aus [41] und wurden basierend auf Messwerte aus dem Testfeld angepasst.

3.5.3 Auswahl des Diffusstrahlungsmodells

Um das optimal geeignete Modell zur Berechnung der Gesamtstrahlung (POA) zu identifizieren, wurde eine systematische Analyse durchgeführt, bei der die Fehler der berechneten und gemessenen POA unter Verwendung der sechs in Abschnitt A.3 dargestellten Diffusstrahlungsmodelle gegenübergestellt wurden.

Die finale Phase dieser Auswertung beinhaltet eine Korrelation der gemessenen (POA_{gemessen}) und der auf Basis der Modelle prognostizierten ($POA_{\text{berechnet}}$) Gesamtstrahlung. Diese Korrelation wurde für verschiedene Ausrichtungen (Neigung: 40° , Azimuth: Süd, Ost, West) über einen definierten Zeitraum (31.10.2014 bis 16.1.2015) durchgeführt.

Die gesammelten Ergebnisse implizieren, dass das Perez-Modell die geringste Diskrepanz zwischen den berechneten und gemessenen POA-Werten aufweist (siehe Abbildung 3.9). Obwohl die alternativen Diffusstrahlungsmodelle bei Betrachtung spezifischer Ausrichtungen (West- und Ostausrichtung) vergleichbare Resultate liefern, zeigt das Perez-Modell auch bei der dominierenden Südausrichtung eine überlegene Genauigkeit.

Für sämtliche nachfolgenden Simulationen wird daher das Perez-Modell zur Kalkulation der Gesamtstrahlung (POA) herangezogen.

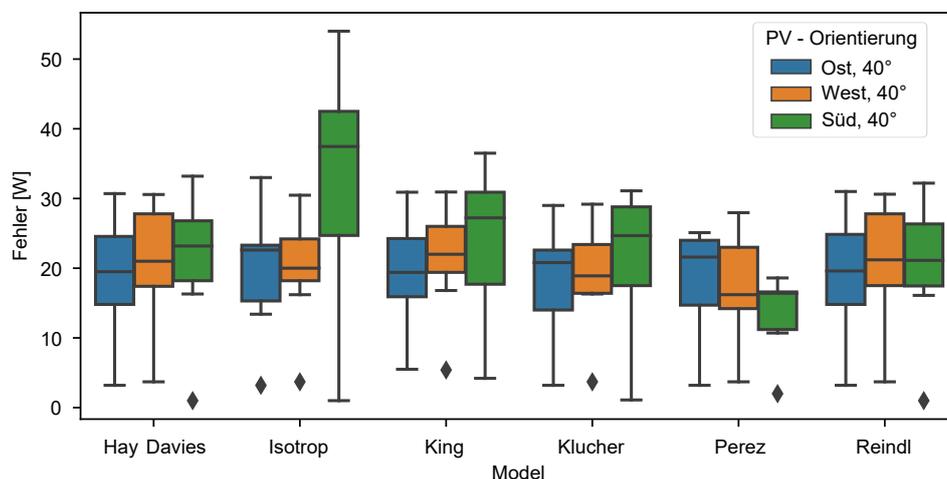


Abbildung 3.9 Vergleich der Strahlungsmodelle anhand ihres Fehlers für verschiedene Ausrichtungen (40° Süd, Ost und West)[42].

3.5.4 Abschätzung der PV-Erzeugung aus Satellitendaten

Zur Schätzung des PV-Ertrags von Gebieten, in denen keine Solarstrahlung gemessen wurde, können Einstrahlungsdaten von Satelliten herangezogen werden. Dabei wird ein Einstrahlungsmodell wie Helioclim-4 [43] verwendet, um Satelliteneinstrahlungsdaten auf einem 1 km x 1 km großen Raster abzurufen. Anhand dieser Daten wird die Einstrahlung auf der Ebene des PV-Moduls (POA) berechnet. Auf der Grundlage der POA Einstrahlungswerte und der Spezifikationen der PV-Module kann die PV-Leistungsabgabe mithilfe der Modelle aus Abschnitt 3.5 berechnet werden.

Die geschätzte PV-Ausgangsleistung wird anhand der tatsächlichen PV-Ausgangsdaten validiert und kalibriert, um Genauigkeit und Zuverlässigkeit zu gewährleisten. Dies wurde in diesem Fall anhand von Daten des Solartestfelds Widderstall des ZSW durchgeführt. Die Genauigkeit der Schätzung hängt von Faktoren wie der Qualität und Auflösung der Satellitendaten, der Genauigkeit der verwendeten mathematischen Modelle und der Verfügbarkeit von tatsächlichen PV-Leistungsdaten für die Validierung und Kalibrierung ab.

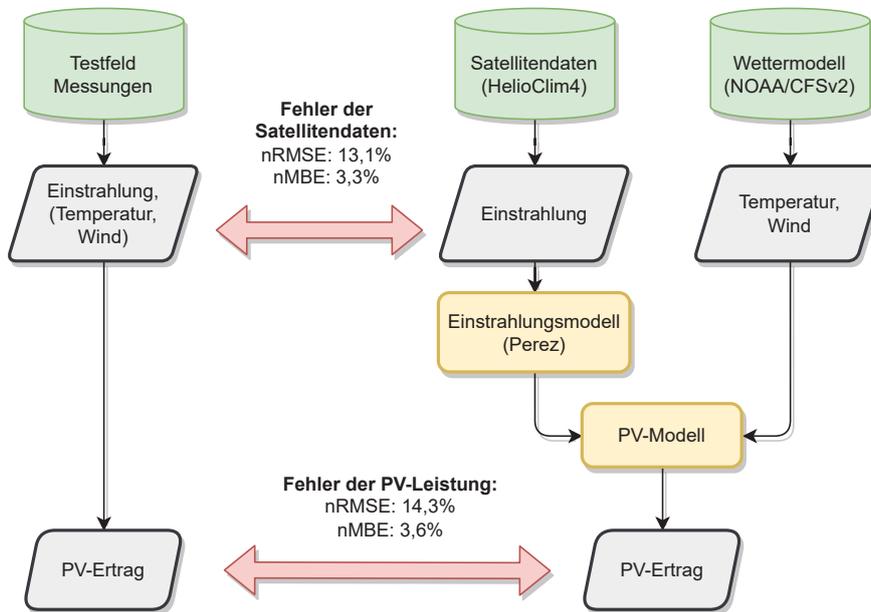


Abbildung 3.10 Abschätzung der PV-Erzeugung aus Satellitendaten [42].

In Abbildung 3.10 ist der Ablauf der Ertragsschätzung sowie die Ergebnisse dargestellt. In der vorliegenden Untersuchung ist der aggregierte Fehler (14,3%) geringer als die Summe der Einzelfehler (RMSE der Satellitendaten: 13,1%, Modellfehler der Diffusstrahlung: $\approx 1,5\%$). Dies lässt sich durch eine teilweise Kompensation der beiden Fehlerarten erklären. Hier bedeutet das, dass Über- oder Unterschätzungen in der Satellitendatenfehler durch entgegengesetzte Abweichungen im Modellfehler der Diffusstrahlung teilweise ausgeglichen werden.

Es ist wichtig zu beachten, dass diese Art der Fehlerkompensation stark von den spezifischen Charakteristika der beiden Fehlerarten abhängt. Beispielsweise könnten stark korrelierte Fehler zu einem Gesamtfehler führen, der größer ist als jeder der Einzelfehler. Dies sind etwa Fehler, die gleichzeitig dazu tendieren, zu über- oder zu unterschätzen. Eine genauere Beschreibung der Fehlerfortpflanzung wird in Kapitel 4.2.2 anhand von Spannungsschätzungen im Verteilnetz gegeben.

3.6 Modellierung des elektrischen Netzes

Um die elektrischen Netzzustände in der Simulationsumgebung realistisch abzubilden, müssen alle elektrischen Größen abhängig von den Leistungsflüssen an den Netz-Knoten bestimmt werden. Hierzu wurde ein Tool zur Berechnung des Netzzustandes erstellt, welches auf der open source Software PYPOWER [44] basiert und das Newton-Raphson Verfahren verwendet, um den Netzzustand zu bestimmen. Obwohl das Newton-Raphson-Verfahren bei geeigneten Startwerten ein gutes Konvergenzverhalten aufweist [45], handelt es sich bei diesem Verfahren durch die komplexen Berechnungen in jedem Iterationsschritt vor allem bei großen Netzen auch um ein sehr rechenintensives Verfahren.

Die verwendeten Netzmodelle basieren auf realen und synthetischen Netzen, welche in Anhang A.2 dargestellt sind.

3.6.1 Newton-Raphson Verfahren

Die Newton-Raphson-Methode ist eine iterative Methode zur Lösung von nichtlinearen Gleichungssystemen, die bei der Lastflussberechnung von Energiesystemen angewendet wird. Die Grundidee der Newton-Raphson-Methode besteht darin, mit einer anfänglichen Schätzung der unbekannt Variablen (Spannungen und Phasenwinkel) zu beginnen und diese iterativ zu aktualisieren, bis diese zum Lösungswert konvergieren.

In dem Kontext von elektrischen Energiesystemen ist das Ziel der Lastflussberechnung die Ermittlung der Spannungsgrößen (Betrag und Phase) an den Knotenpunkten des Netzes. Gegeben sind die aktiven und reaktiven Leistungen an diesen Knoten. Dies stellt ein nichtlineares Gleichungssystem dar, dessen Lösung mittels der Newton-Raphson-Methode erzielt werden kann. Die Methode benötigt eine anfängliche Schätzung für die Spannungshöhe und den Phasenwinkel an jedem Bus (\mathbf{x}). Zudem muss eine Knotenpunkt-Admittanz-Matrix \mathbf{Y} gebildet werden, die die Netztopologie beschreibt. Zur Berechnung müssen Ableitungen der Leistungsgleichungen gebildet werden, die zur sogenannten Jacobi-Matrix \mathbf{J} zusammengefasst werden.

Die allgemeine Form des Newton-Raphson-Verfahrens für ein Gleichungssystem ist

$$\Delta \mathbf{x} = -\mathbf{J}^{-1} f(\mathbf{x}). \quad (3.13)$$

wobei \mathbf{x} der Vektor der Unbekannten ist (in diesem Fall die Spannungen und Phasenwinkel) und \mathbf{J} die Jacobimatrix des Systems $f(\mathbf{x})$ ist, welche die partiellen Ableitungen der nichtlinearen Funktionen in Bezug auf die Unbekannten enthält. $f(\mathbf{x})$ ist der Vektor der nichtlinearen Funktionen, die das Lastflussproblem repräsentieren. $\Delta \mathbf{x}$ ist der Korrekturvektor, der zur aktuellen Schätzung von \mathbf{x} hinzugefügt wird, um eine verbesserte Schätzung zu erhalten. Dieser Prozess wird iterativ durchgeführt, wobei in jeder Iteration die Jacobimatrix aktualisiert wird und eine neue Schätzung von \mathbf{x} berechnet wird, bis eine gewünschte Genauigkeit erreicht ist (typischerweise definiert durch einen bestimmten Schwellenwert für den Betrag von $f(\mathbf{x})$).

Die Newton-Raphson-Methode ist bekannt für ihre Effizienz und Robustheit bei der Lastflussberechnung, besonders in großskaligen Energiesystemen, wo die nichtlinearen Gleichungen oft hochdimensional und stark gekoppelt sind. Allerdings können bei schlechter Initialisierung Konvergenzprobleme auftreten. Fortschritte in der Methode, wie die Fast-Decoupled und die DC-Lastflussanalyse, können unter bestimmten Bedingungen zu schnellerer Konvergenz führen.

3.7 Zusammenfassung der Simulationsumgebung

Die entwickelte Simulationsumgebung ermöglicht die integrierte Modellierung und Simulation mehrerer Reglerhierarchien in Verbindung mit einer umfassenden Parallelisierung auf allen Ebenen. Sie ermöglicht weiterhin die detaillierte Einbindung von thermischen Gebäudemodellen sowie die Abbildung von Verteilnetzen in einer Umgebung, die die Simulation von gesamten Niederspannungsnetzen mit allen Gebäuden ermöglicht.

Das thermische Gebäudemodell basiert auf dem EnergyPlus-Gebäudesimulation-Framework und ermöglicht die Abschätzung des thermischen Energiebedarfs eines Gebäudes und der Innentemperatur unter Berücksichtigung von Heizleistung und Wetterbedingungen. Es umfasst verschiedene Komponenten, wie einen thermischen Speicher und eine Wärmepumpe. Es wurde in verschiedenen Studien validiert und zeigt eine gute Genauigkeit. Durch die Anpassung des Modells an den deutschen EnEV-Standard können verschiedene Szenarien simuliert werden, um die Energieeffizienz eines Gebäudes zu bewerten und Optimierungsmöglichkeiten zu identifizieren.

Die Einbindung des Wärmepumpenmodells ermöglicht die Berücksichtigung der Effizienz der Wärmepumpe in Abhängigkeit von Temperatur und Lastzustand. Es verwendet Kennlinien der Teilkreise der Wärmepumpe, um den Gesamtwirkungsgrad zu berechnen, und berücksichtigt auch das Anlaufverhalten der Wärmepumpe. Das Modell wurde anhand von experimentellen Daten und Referenzkennlinien kalibriert, um eine hohe Übereinstimmung mit den realen Betriebsbedingungen zu gewährleisten.

Für die Batteriemodellierung wurde ein empirisches Modell verwendet, das auf experimentellen Daten basiert. Es berücksichtigt den Systemwirkungsgrad für verschiedene Leistungsstufen sowie den Kapazitätsverlust und den Anstieg des Innenwiderstands im Laufe der Zeit, um den Zustand der Batterie (State-of-Health) abzuschätzen. Das Modell ermöglicht die Analyse und Bewertung des Batterieverhaltens und bietet eine einfache und praktikable Methode, um den Energieverbrauch zu optimieren.

Die PV-Ertragsschätzung erfolgt mittels eines modifizierten King-SANDIA-Modells, das die Gleichstromleistung der PV-Anlage unter Berücksichtigung von Einstrahlung, Modulwirkungsgrad und Systemeffizienz berechnet. Die Modultemperatur und der Wechselrichterwirkungsgrad werden ebenfalls berücksichtigt. Die PV-Ertragsabschätzung basiert auf Satellitendaten zur Einstrahlung, die auf PV-Modulniveau umgerechnet werden, und wird durch Validierung und Kalibrierung der PV-Ausgangsdaten verbessert.

Die Validierung des Photovoltaikmodells mit empirischen Daten ermöglicht es, seine Fähigkeit zur präzisen Vorhersage des PV-Ertrags und zur Bewertung der Systemleistung unter realen Betriebsbedingungen zu bestätigen. Durch diesen Validierungsprozess wird das Vertrauen in die Genauigkeit und Zuverlässigkeit des Photovoltaikmodells gestärkt und ermöglicht es den Anwendern, fundierte

Entscheidungen bezüglich des Designs, der Optimierung und des Betriebs von PV-Anlagen zu treffen. Die Verwendung von Satellitendaten oder Strahlungsmessungen zur Einstrahlungserfassung ermöglicht eine breite Anwendbarkeit der PV-Modelle und gewährleistet, dass die Vorhersagen des PV-Ertrags präzise und realitätsnah sind, unabhängig von der geografischen Lage des Verteilnetzes.

Die Netzsimulation verwendet das Newton-Raphson-Verfahren aus [44] zur Berechnung des Netzzustands und zur Analyse des Lastflusses in elektrischen Netzen.

Insgesamt bietet diese Simulationsumgebung eine umfassende Plattform zur Analyse, Optimierung und Bewertung komplexer Energiesysteme, indem sie detaillierte thermische Gebäudemodelle, Wärmepumpenmodelle, Batteriemodelle, PV-Ertragsschätzungen und Netzsimulationen integriert.

4 Netzzustandserkennung in Verteilnetzen mit volatilen Erzeugern und Lasten

Für einen sicheren Betrieb von Verteilnetzen, insbesondere solchen mit hohem Anteil an erneuerbaren Energiequellen, muss eine genaue Kenntnis des aktuellen Netzzustands gewährleistet sein. Dadurch kann nicht nur innerhalb der vorhandenen Netzkapazitäten ein optimierter Betrieb sichergestellt werden, sondern auch die Bewertung von zusätzlichem Netzausbau im Kontext erneuerbarer Energien kann erleichtert werden. Dieses Kapitel basiert auf den Veröffentlichungen [46–48].

Da Verteilnetze oft unzureichend mit Messstellen ausgestattet sind, werden Netzzustandsberechnungen oftmals auf Lastschätzungen oder unsichere Vorhersagen gestützt. In diesen Fällen können probabilistische Lastflussmethoden verwendet werden, um den Netzzustand zu bestimmen. Inhärente Unsicherheiten und Fehlerquellen, die aus Messungenauigkeiten, Modellierungsfehlern oder der variablen Natur erneuerbarer Energiequellen resultieren, werden berücksichtigt [49].

Während von deterministischen Methoden oft nur ein singulärer Schätzwert geliefert wird, wird von probabilistischen Lastflussmethoden eine Wahrscheinlichkeitsverteilung möglicher Netzzustände bereitgestellt [50–52]. Dadurch kann ein differenziertes Risikomanagement gefördert und eine ressourcenschonende Netzplanung und -betrieb unterstützt werden. Sie werden daher als unerlässlich im modernen Netzbetrieb, insbesondere bei hohen Unsicherheiten, betrachtet.

In diesem Kapitel werden die verschiedenen Ansätze zur Gewährleistung von Netztransparenz bei unsicheren Einspeisungs- und Verbrauchswerten beleuchtet. Zunächst wird eine linearisierte Lastflussmethode für Niederspannungsnetze hergeleitet (Kapitel 4.1). Anschließend werden unterschiedliche probabilistische Lastflussansätze vorgestellt und hinsichtlich ihrer Genauigkeit und Effizienz bewertet. Es wird eine Methode, welche auf der Gauss'schen Fehlerfortpflanzung basiert (Kapitel 4.2) vorgestellt [53] sowie die Zustandsschätzung (Kapitel 4.3) behandelt.

4.1 Vereinfachung der Lastflussgleichung für Niederspannungsnetze

In Niederspannungsnetzen, die typischerweise Spannungen von 400 V aufweisen, sind die Leitungslängen im Vergleich zu höheren Spannungsebenen oft relativ kurz. Infolgedessen dominieren ohmscher Widerstand und Leitungsinduktivität das Übertragungsverhalten, während kapazitive Effekte oft marginal sind [54]. Aufgrund dieser geringen Relevanz kapazitiver Beiträge werden sie in vielen Modellen und Berechnungen für Niederspannungsnetze vernachlässigt. Infolgedessen kann, wenn ein Zweitor-Modell zur Beschreibung der Leitungscharakteristik in Niederspannungsnetzen verwendet wird, die

Kapazität häufig vernachlässigt werden. Dies ist in Abbildung 4.1 dargestellt. Dies führt zu einer signifikanten Vereinfachung des Modells und reduziert die Komplexität bei Berechnungen, ohne wesentliche Genauigkeitsverluste zu verursachen.

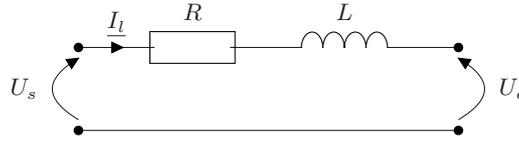


Abbildung 4.1 Leitungsmodell für das Niederspannungsnetz [46].

Ist der aktive Widerstand R deutlich größer als der reaktive Widerstand X , vereinfachen sich die Berechnungen des resultierenden Spannungsabfalls über eine Leitung. Dies ist in Niederspannungsnetzen der Fall [55], wobei hieraus eine geringe und daher vernachlässigbare Phasenverschiebung θ resultiert. Das zugehörige Phasendiagramm wird in Abbildung 4.2 dargestellt.

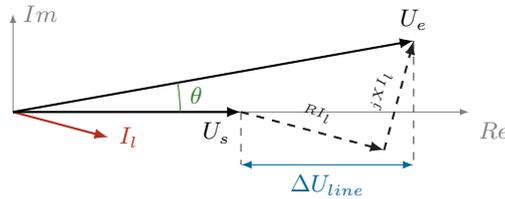


Abbildung 4.2 Phasendiagramm der Niederspannungsnetz-Approximation. Wenn die Phasenverschiebung θ zwischen dem Anfang und dem Ende einer Leitung klein ist, kann der Imaginärteil der Spannungsdifferenz vernachlässigt werden [46].

Durch Anwendung der Vereinfachungen für Niederspannungsnetze ergibt sich die Spannungsberechnung gemäß

$$\Delta U_{line} = R \Re(I_{line}) + X \Im(I_{line}) \quad \text{für } R \gg X \quad (4.1)$$

Um den gesamten Spannungsabfall von der Referenz zu einem spezifischen Knoten (ΔU_{knoten}) zu ermitteln, ist eine Addition der Spannungsabfälle jeder Leitung zwischen dem betreffenden Knoten und dem Slack-Knoten notwendig. Dies kann durch Matrixmultiplikation mit der Leitungsmatrix M_I erreicht werden. Zudem lässt sich die Summation der Leitungsströme durch Multiplikation mit ihrer transponierten Form M_I^T darstellen. Gleichung (4.2) liefert die vollständige Berechnung.

Geschätzte Werte werden durch ein Dach symbolisiert; beispielsweise ist \hat{U}_{knoten} der geschätzte Wert der Knotenspannung. Der absolute Wert der Knotenspannung U_{knoten} wird mittels Gleichung (4.2) berechnet, vorausgesetzt die Referenzknotenspannung U_{slack} ist im Vorfeld bekannt.

$$U_{knoten} = U_{slack} - \Delta U_{knoten} \quad (4.2)$$

Für eine verbesserte Lastflussberechnung werden die Gleichungen (4.4) und (4.2) iterativ berechnet, bis eine Konvergenz zwischen der geschätzten Spannung \hat{U}_{knoten} und U_{knoten} erreicht ist. Solange das Netz in seiner Struktur konstant bleibt, lässt sich für beide Berechnungen dieselbe Matrix M_I anwenden.

4.1.1 Repräsentation des Netzes in Matrixform

Abbildung 4.3 veranschaulicht ein einfaches Netz, das so strukturiert ist, dass es die beiden verschiedenen Matrizen für den linearisierten Lastfluss darstellt. Es besteht aus sechs Knoten. Knoten (0) dient als Slack-Knoten und Knoten (1) – (5) dienen als Lastknoten. Für alle Leitungen gilt die gleiche Impedanz.

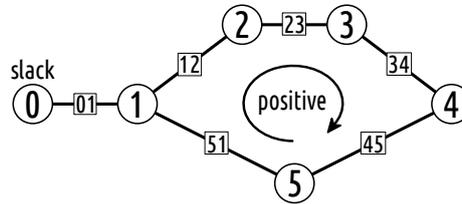


Abbildung 4.3 Ein kleines illustratives Netz als Beispiel für die Berechnung der Strommatrix M_I [46].

Die Matrix M_V (Gl. 4.3) bildet die zu einer einzelnen Leitung gehörenden Spannungsabfälle auf den Gesamtspannungsabfall ab, indem sie alle Leitungsspannungsabfälle ΔU_l vom Slackknoten zu dem jeweiligen Knoten im Netz addiert. Die Spaltenindizes stellen die Leitungsindizes (z.B. [01]) und die Zeilenindizes die Knotennummer (z.B. (0)) dar.

$$M_V = \begin{matrix} & [01] & [12] & [23] & [34] & [45] & [51] \\ \begin{matrix} (0) \\ (1) \\ (2) \\ (3) \\ (4) \\ (5) \end{matrix} & \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 0 \end{bmatrix} \end{matrix} \quad (4.3)$$

Die Differenz zwischen Knotenspannung und Slack-knoten ΔU_{knoten} , die sich aus der Multiplikation der Matrix M_V und dem Leitungsspannungsabfallvektor ΔU_{line} ergibt, wird durch die folgende Gleichung dargestellt:

$$\Delta U_{\text{knoten}} = M_V \cdot \Delta U_{\text{line}} \quad (4.4)$$

Um die Ströme entlang jeder einzelnen Leitung zu erhalten, wird jeder Knotenstrom unabhängig berechnet. Gleichung (4.5) zeigt die Matrix \mathbf{M}_I für das Netz in Abbildung 4.3:

$$\mathbf{M}_I = \begin{matrix} & \begin{matrix} [01] & [12] & [23] & [34] & [45] & [51] \end{matrix} \\ \begin{matrix} (0) \\ (1) \\ (2) \\ (3) \\ (4) \\ (5) \end{matrix} & \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & z'_2 & z''_2 & z''_2 & z''_2 & z''_2 \\ 1 & z'_3 & z'_3 & z''_3 & z''_3 & z''_3 \\ 1 & z'_4 & z'_4 & z'_4 & z''_4 & z''_4 \\ 1 & z'_5 & z'_5 & z'_5 & z'_5 & z''_5 \end{bmatrix} \end{matrix} \quad (4.5)$$

Ausgehend von den in unserem Beispiel getroffenen Annahmen teilen sich die Ströme von den Leerlauf- zu den Lastschienen und aufgrund des vorhandenen Rings in zwei Pfade auf. Betrachtet man beispielsweise den Pfad von der Sammelschiene (1) zur Sammelschiene (2), so kann der Strom von einem der beiden Pfade fließen, entweder von der Leitung [12] oder von den Leitungen [51], [45], [34] und [23]. Das Verhältnis der Pfadströme wird durch das jeweilige Leitungsimpedanzverhältnis bestimmt, in diesem Fall die Werte von z'_2 bis z'_5 . Zur besseren Verdeutlichung wird hier anhand von Beispielen gezeigt, wie die Einträge der Strommatrix \mathbf{M}_I berechnet werden:

$$z'_2 = 1 - \frac{Z_{12}}{Z_{12} + Z_{23} + Z_{34} + Z_{45} + Z_{51}} \quad (4.6a)$$

$$z'_3 = 1 - \frac{Z_{12} + Z_{23}}{Z_{12} + Z_{23} + Z_{34} + Z_{45} + Z_{51}} \quad (4.6b)$$

Die Berechnungsvorschrift zur Gewinnung der Einträge ist der Stromteilerregel entnommen. Die Werte von Z_{ab} stellen die Impedanz der Leitung von Knoten a zu Knoten b dar. Die Werte von z''_a in Gleichung (4.3) sind definiert als $z''_a = z'_a - 1$.

Aufgrund der in allen Leitungen unseres Beispielnetzes angenommenen gleichen Impedanz zerfällt der Knotenstrom I_2 in $z'_2 = 80\%$, der durch die Leitung [12] fließt, und $z'_2 - 1 = -20\%$ entlang der Leitungen [51], [45], [34] und [23]. Im Vergleich zur definierten positiven Umfangsrichtung fließt der Strom im unteren Pfad in entgegengesetzter Richtung, weshalb ihm ein negatives Vorzeichen zugewiesen wird.

Der Strom für jede Leitung, \mathbf{I}_{line} , wird durch Addition der einzelnen Zweigströme der Knoten berechnet. Er ergibt sich durch Multiplikation von \mathbf{M}_I und dem Vektor $\mathbf{I}_{\text{knoten}}$, der die Ströme in jedem Knoten enthält.

$$\mathbf{I}_{\text{line}} = \mathbf{M}_I^T \cdot \mathbf{I}_{\text{knoten}} \quad (4.7)$$

Basierend auf den Annahmen über ähnliche Leitungsimpedanzen in der Strommatrix \mathbf{M}_I in Bezug auf unser Beispiel in Abbildung 4.3, dann ist die resultierende Matrix \mathbf{M}_I :

$$\mathbf{M}_I = \begin{matrix} & \begin{matrix} [01] & [12] & [23] & [34] & [45] & [51] \end{matrix} \\ \begin{matrix} (0) \\ (1) \\ (2) \\ (3) \\ (4) \\ (5) \end{matrix} & \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0.8 & -0.2 & -0.2 & -0.2 & -0.2 \\ 1 & 0.6 & 0.6 & -0.4 & -0.4 & -0.4 \\ 1 & 0.4 & 0.4 & 0.4 & -0.6 & -0.6 \\ 1 & 0.2 & 0.2 & 0.2 & 0.2 & -0.8 \end{bmatrix} \end{matrix} \quad (4.8)$$

Matrixform des Spannungsabfalls

In gleicher Weise wie die Knotenspannung durch die Verwendung der deterministischen Lastflussberechnung kann ein Mittelwert gebildet werden. Daher werden die ehemals deterministischen Variablen, die für die Wirk- und Scheinleistung verwendet werden, durch die jeweiligen Mittelwerte ihrer Verteilungen ersetzt [56–58]. Durch die Matrixgleichung

$$\mu_{\Delta U_{\text{knoten}}} = \mathbf{M}_V \cdot \frac{\mathbf{R}_L \circ \mathbf{M}_I^\top \cdot \mu_{P,\text{knoten}} + \mathbf{X}_L \circ \mathbf{M}_V^\top \cdot \mu_{Q,\text{knoten}}}{\hat{\mathbf{U}}_{\text{knoten}}} \quad (4.9)$$

kann der Mittelwert des Spannungsabfalls im Niederspannungsnetz mit dieser Methode sehr effizient bestimmt werden.

4.2 Probabilistischer Lastfluss

Aufgrund von Unsicherheiten in Last und Erzeugung, unstetigen Lastmustern, schwankender Erzeugung und sich zeitabhängigen ändernden Bedingungen wird der Betrieb von Stromnetzen zunehmend anspruchsvoller. Daher werden deterministische Verfahren zunehmend durch den Probabilistischer Lastfluss (PLF) ersetzt. Dieser berücksichtigt die genannten Unsicherheiten und die Netzkonfigurationen, um die Systemsicherheit zu erhöhen und Überlastungen im Netz zu vermeiden [50, 51, 55, 58–72].

Die Ursprünge des PLF gehen auf eine Arbeit von Borkowska [73] zurück. Die PLF-Analyse hilft dabei, den Zustand des Systems und seine Verteilungen in Bezug auf die probabilistisch eingespeiste und verbrauchte Leistung sowie die Verbindung zwischen beiden zu bestimmen.

Verschiedene Arbeiten bieten einen Überblick über die Entwicklung des PLF und deren Entwicklung [55, 61, 70]. Oft wird unter anderem die Monte-Carlo-Simulation verwendet, um Spannungs- und Stromverteilungen in Stromnetzen zu bestimmen [61, 74]. Weitere Konzepte nutzen Kumulanten [63] oder verwandte Konzepte wie die Gram-Charlier Serien, Cornish-Fisher und Edgeworth um die Wahrscheinlichkeitsverteilungen abzuschätzen [63, 71, 75]. In [65] wird ein kumulantenbasierter Ansatz

verwendet, der mit verschiedenen Arten von Wahrscheinlichkeitsverteilungen in Energiesystemen umgehen kann, wobei Clustering-Techniken eingesetzt werden, um die Windleistungsverteilung an eine diskrete Verteilung anzupassen.

4.2.1 Monte Carlo Simulation

Diese Methode basiert auf wiederholten Netzwerkzustandsberechnungen mit Lastflussgleichungen, wobei Knotenleistungen als stochastische Variablen mit einer bestimmten Verteilung dargestellt werden. Es werden hierbei verschiedene Zufallsstichproben aus den Fehlerverteilungen verwendet und für jede Stichprobe werden die Spannungswerte berechnet. Hierbei werden über 1000 Stichproben [58, 59] durchgeführt, um eine Wahrscheinlichkeitsverteilung zu bilden. Trotz hoher Genauigkeit ist ein Nachteil der Methode die Zeitintensität der Simulation aufgrund einer großen Anzahl von Iterationen.

Algorithmus 1 : Monte-Carlo Linear-Low-Voltage (MC-LLV)

```

for all samples do
  while convergence not reached do
     $\hat{\mathbf{U}}_{\text{knoten}} \leftarrow \mathbf{U}_{\text{knoten}}$ 
     $\mathbf{U}_{\text{knoten}} \leftarrow \text{eval. equation (4.4) and (4.2)}$ 
  end
end
return  $\mathbf{U}$ 

```

In dieser Arbeit werden zwei Varianten der Monte-Carlo Simulation verwendet:

Monte-Carlo Newton-Raphson (MC-NR): Bei diesem Verfahren wird eine Monte Carlo Simulation unter Verwendung des Newton-Raphson Lastflussverfahrens verwendet.

Monte-Carlo Linear-Low-Voltage (MC-LLV): Bei diesem Verfahren wird die oben eingeführte Näherung für das Niederspannungsnetz verwendet. Der Ablauf ist in Algorithmus 1 beschrieben [47].

4.2.2 Linearer Fehlerfortpflanzung

Um probabilistische Lastflussmethoden in numerischen Optimierungsstrategien anwendbar zu machen, ist es von wesentlicher Bedeutung, dass der Algorithmus eine geringe Laufzeit hat. Die Monte-Carlo-Methode ist rechentechnisch sehr anspruchsvoll, da sie die Wahrscheinlichkeitsverteilung durch sampling approximiert. Alternativ können die zugehörigen Parameter auch analytisch ermittelt werden. Während der Vorhersage sollte der Fehler einer Normalverteilung folgen, und im Kontext der Wahrscheinlichkeitsverteilung sind der Mittelwert (μ) und die Standardabweichung (σ) ausreichend, um ihn zu beschreiben. Dabei wird das Gesetz der Fehlerfortpflanzung (Gaussian Error Propagation (GEP) [76]) verwendet, um die beschreibenden Momente der Wahrscheinlichkeitsverteilung durch das System, in diesem Fall ein elektrisches Netz, zu propagieren.

Der Mittelwert wird als Parameter an die Systemfunktion $f(x)$ (Lastflussgleichungen) übergeben:

$$\mu_y = f(\mu_x) \quad (4.10)$$

Die Standardabweichung wird durch eine Taylor-Approximation erster Ordnung von $f(x)$ um den geschätzten Mittelwert approximiert [77–79]:

$$\sigma_y^2 = \sum_i \left[\frac{\partial f(\mu_x)}{\partial x_i} \right]^2 \sigma_{x_i}^2 + \sum_i \sum_{j \neq i} \frac{\partial f(\mu_x)}{\partial x_i} \frac{\partial f(\mu_x)}{\partial x_j} \sigma_{x_i} \sigma_{x_j} r_{x_i, x_j} \quad (4.11)$$

Dabei stellt r_{x_i, x_j} den Korrelationskoeffizienten zwischen x_i und x_j dar. Wenn die Wahrscheinlichkeitsverteilungen unkorreliert sind, ist der Korrelationskoeffizient r gleich null und der zweite Term von Gleichung (4.11) kann vernachlässigt werden.

In Szenarien, in denen die Profile der Fehler signifikant korreliert sind, kann der zweite Term in Gleichung (4.11) nicht ignoriert und muss entsprechend in die Analyse einbezogen werden. Dieser Umstand erfordert einen erhöhten Rechenaufwand, da die bedingte Summe berechnet werden muss.

Wird die Niederspannungsnäherung unter Verwendung von Gleichung (4.4) und (4.2) verwendet, wird diese Methode in dieser Arbeit als GEP-LLV bezeichnet.

Korrelation der Lastprofile

Lastprofile, die die zeitliche Stromnachfrage von Haushalten oder anderen Einheiten darstellen, können durch eine Vielzahl von Faktoren beeinflusst werden. Dazu gehören zum Beispiel Verhaltensmuster, Tageszeit, Jahreszeit und Wetterbedingungen. Dabei kann der Korrelationskoeffizient dazu genutzt werden, um den Grad der Beziehung zwischen diesen Faktoren und den Lastprofilen zu untersuchen. Beispielsweise kann er genutzt werden, um zu bewerten, inwieweit Änderungen in den Wetterbedingungen mit Änderungen in den Lastprofilen korrelieren. Bei kälterem Wetter kann der Energieverbrauch für die Heizung in den Haushalten steigen, während bei heißem Wetter der Verbrauch für die Kühlung steigen kann. Bei sonnigem Wetter produzieren Haushalte mit Photovoltaikanlagen mehr Energie, was ihren Nettoenergieverbrauch senkt.

Im Kontext der realen Energieverbrauchsmuster spiegelt der Tagesrhythmus der Verbraucher oft stark korrelierte Lastprofile wider. Diese Ähnlichkeit im Verbrauchsverhalten ist inhärent in den Nutzerlastprofilen und führt zu charakteristischen Mustern der Korrelation. In Abbildung 4.4 ist die Verteilung der Pearson-Korrelationskoeffizienten r für ein Set von 100 Haushaltlastprofilen illustriert. Die Verteilung weist eine maximale Wahrscheinlichkeit bei einem Korrelationswert von etwa $r = 0,1$ auf. Dies repräsentiert den durchschnittlichen Korrelationswert über einen längeren Zeitraum. Reale Profile weisen ein individuelles, zeitabhängiges Korrelationsmuster auf. Je nach Korrelationsmuster und Anforderungen an die Zustandserkennung müssen diese Muster in der probabilistischen Lastflussrechnung berücksichtigt werden.

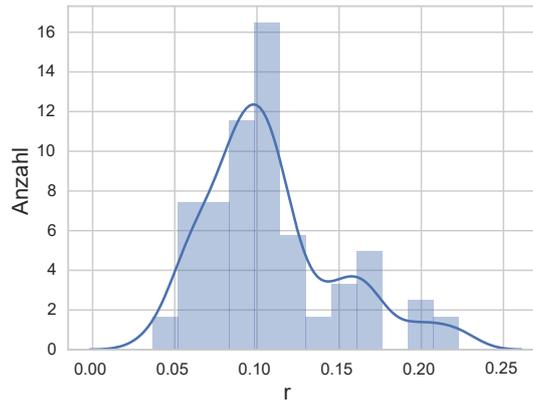


Abbildung 4.4 Verteilung der Kreuzkorrelation r zwischen verschiedenen Haushaltslastprofilen.

Korrekturmethoden

Der Vorteil der oben dargestellten analytischen Lastflussmethoden ist, dass Sie in einer linearen Gleichung dargestellt werden kann. Die Linearisierung geht jedoch mit einem Präzisionsverlust einher, der von der Größe der Standardabweichung in Bezug auf die Nichtlinearität der Lastflussgleichung abhängt. Zudem werden die Fehler mit zunehmender Entfernung des jeweiligen Knotens zum Slack-Knoten größer. Dies geschieht, weil sich die Schätzfehler in der Standardabweichung über alle Knoten der Leitungen vom Slackknoten zum entsprechenden Knoten addieren.

Die folgende Gleichung (4.12) zeigt den Schätzfehler der Standardabweichung.

$$\epsilon_{\sigma} = \hat{\sigma}(U) - \sigma(U) \quad (4.12)$$

wobei $\hat{\sigma}(U)$ die Schätzung der Standardabweichung der Spannungsverteilung durch die GEP darstellt. $\sigma(U)$ ist die Standardabweichung der Spannungsverteilung, die mit der Monte-Carlo-Methode unter Verwendung der Monte-Carlo Newton-Raphson (MC-NR) Methode.

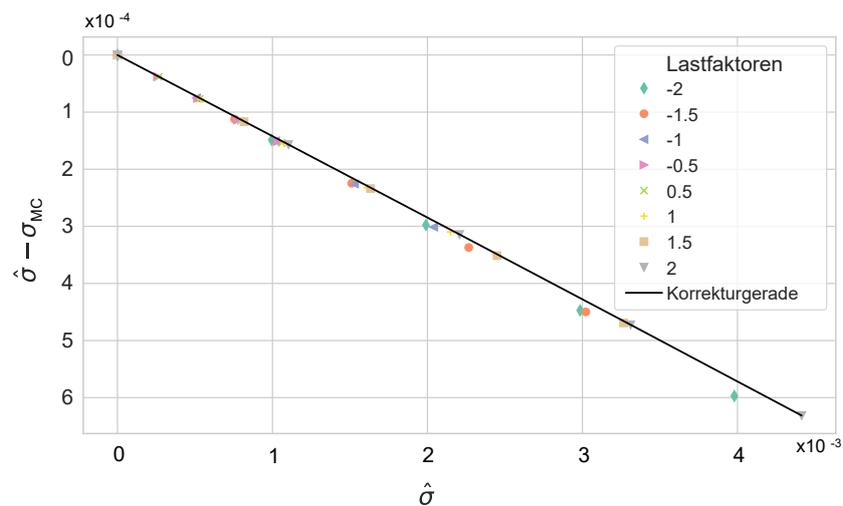


Abbildung 4.5 Beziehung zwischen dem Schätzfehler der Standardabweichung $\epsilon_{\sigma} = \hat{\sigma} - \sigma_{MC}$ und der geschätzten Standardabweichung $\hat{\sigma}$) für das GEP Verfahren ohne Fehlerkorrektur für einen Knoten im Testnetz. Die Fehler sind insgesamt gering und können gut durch eine Gerade approximiert und somit korrigiert werden.[47]

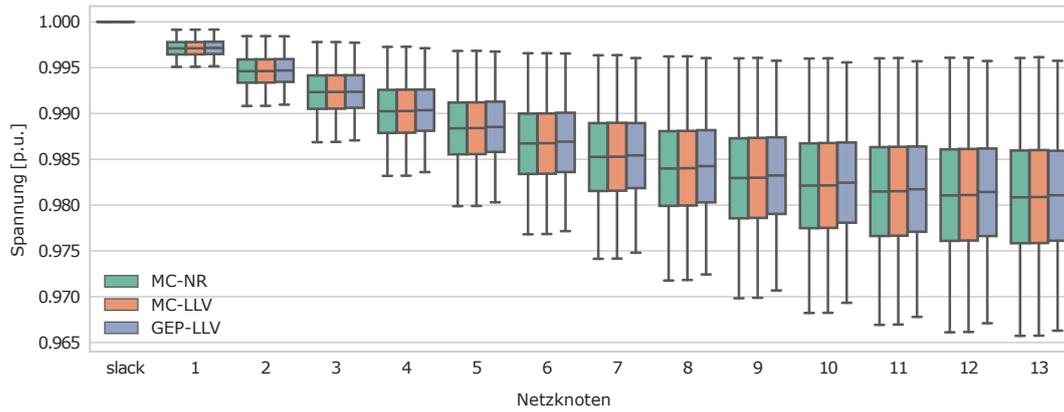


Abbildung 4.6 In diesem Boxplot wird die Spannungsverteilung an den verschiedenen Knotenpunkten dargestellt. Bei einem Vergleich der Monte-Carlo-Methoden, nämlich MC-NR und MC-LLV, zeigt sich, dass beide Ansätze ähnliche Resultate liefern. Die Gauss'sche Fehlerfortpflanzung unter Verwendung der Niederspannungsnäherung (Gaussian Error Propagation - Linear Low Voltage, GEP-LLV) liefert bei deutlich weniger Rechenaufwand noch gute Ergebnisse [47]. Der Plot zeigt den Median mit den Quartilen als Box. Die Whisker geben den 1,5-fachen Interquartilsabstand an.

Um den Einfluss der approximierten Standardabweichung $\hat{\sigma}(U)$ auf den Fehler ϵ_σ zu analysieren, wird eine Sensitivitätsanalyse durchgeführt. Ein beispielhaftes Ergebnis für einen Knoten ist in Abbildung 4.5 dargestellt. Die Marker stehen für unterschiedliche Lastszenarien in Bezug auf den Referenzfall. Außerdem sind die Standardabweichungen auf den Referenzfall normiert. Der Schätzfehler der Standardabweichung ϵ_σ ist proportional zur geschätzten Standardabweichung $\hat{\sigma}(U)$. Die mittlere Knotenleistung hingegen hat keinen Einfluss auf den Fehler.

Daher kann für jeden einzelnen Knoten eine Korrekturgerade anhand der Datenpunkte $(\epsilon_\sigma, \hat{\sigma}(U))$ berechnet werden (siehe Abbildung 4.5). Die Parameter des resultierenden Geraden beschreiben das Verhältnis zwischen geschätzter Standardabweichung und Schätzfehler nahezu unabhängig von der entsprechenden Knotenlast (μ_{knoten}), wenn die Mittelwerte der anderen Lasten im Netz von einem Knoten zum anderen nicht wesentlich variieren.

Der Fehler kann durch die Linearisierung der Lastflussgleichungen erklärt werden. Wenn die Standardabweichung zunimmt, nimmt auch der Fehler der Linearisierung zu, da die Werte weiter vom Linearisierungspunkt entfernt sind. Die Steigung der Anpassung der kleinsten Quadrate scheint proportional zum Abstand zwischen dem entsprechenden Knoten und dem Slack-Knoten zu sein. Wie bereits erwähnt, ist dies auf die Summierung aller Linearisierungsfehler zwischen dem Slack-Knoten und dem untersuchten Knoten zurückzuführen.

Wenn der Lastvorhersagefehler als Normalverteilung dargestellt wird, sind der Mittelwert sowie die Standardabweichung der Wirk- und Blindleistung die einzigen Variablen, die sich über zwei Berechnungszeitpunkte hinweg ändern. Außerdem ist der Fehler, wie bereits erwähnt, proportional zur Standardabweichung der Lasten und ziemlich unabhängig von seinem Mittelwert, weshalb die symmetrische Eigenschaft des Fehlers seine Kompensierbarkeit ermöglicht.

Die für eine Fehlerkompensation erforderlichen Parameter werden durch die beschriebene Anpassung nach der Methode der kleinsten Quadrate geschätzt. Die Korrekturparameter werden nur einmal vor dem Optimierungsprozess berechnet, da sich die Parameter nur dann ändern, wenn sich die Netztopologie ändert.

4.3 Zustandsschätzung im Verteilnetz

Die Methode der Zustandsschätzung in Verteilnetzen ist ein Verfahren zur Überwachung und Steuerung von Verteilnetzen [80, 81]. Sie ermöglicht es, den aktuellen Zustand des Netzes basierend auf verfügbaren Messungen und dem bekannten Netzmodell zu schätzen. Da die verfügbaren Messdaten oft unvollständig und fehlerbehaftet sind, ist der Prozess der Zustandsschätzung in der Regel ein Optimierungsproblem, das auf der Methode der kleinsten Quadrate (Least Squares Method) basiert. Hierbei wird ähnlich dem linearen probabilistischen Lastfluss die Unsicherheit linear propagiert. Das zugrundeliegende Optimierungsproblem wird allerdings mithilfe des Gauss-Newton Verfahrens gelöst.

Zustandsschätzung mittels gewichteter kleinster Quadrate

In einem Netz mit N Knoten hat der Zustandsvektor $\mathbf{x} \in \mathbb{R}^{(2N-1) \times 1}$ die Form $x = [\theta_2, \theta_3, \dots, \theta_n, |V_1|, |V_2|, \dots, |V_N|]^T$, wobei θ_i den Phasenwinkel, und $|V_i|$ die Beträge der Spannungen am i -ten Knoten. Der Phasenwinkel θ_1 am Referenzknoten wird normalerweise als null angenommen.

Um den Netzzustand zu schätzen, ist mindestens ein Satz von $2N - 1$ Messungen nötig ($z \in \mathbb{R}^{L \times 1}$, $L > 2N - 1$). Wenn die Menge der verfügbaren Echtzeitmessungen ausreicht, um den Systemzustandsvektor zu berechnen, wird das System als beobachtbar bezeichnet, andernfalls ist das System nicht beobachtbar [82]. In diesem Fall werden sogenannte Pseudomesswerte verwendet. Diese stellen eine Schätzung des Messwertes und dessen Unsicherheit dar.

Die Messungen sind mit dem Zustandsvektor durch ein System von nicht linearen Gleichungen verbunden. Das System kann wie folgt beschrieben werden:

$$\mathcal{Z} = h(\mathbf{x}) + \mathbf{n} \quad (4.13)$$

wobei $h(\mathbf{x})$ eine Menge von nicht linearen Messfunktionen des Zustandsvektors sind und \mathcal{Z} den Vektor bezeichnet, der die Messungen enthält. Die Messfehler werden mit \mathbf{n} bezeichnet und durch ein mittelwertfreies Gauß'sches Rauschen modelliert. Die Messungen können Wirk- und Blindleistungseinspeisungen, Spannungshöhe, Spannungswinkel und den Strom umfassen.

Der Ansatz der gewichteten kleinsten Quadrate (Weighted Least Squares (WLS)), ist ein Ansatz, um oben genanntes Gleichungssystem zu lösen. Dieser basiert auf der Linearisierung der Beziehung zwischen den Messungen und den Zustandsvariablen. Das Ziel ist es hierbei den quadratischen Fehler zu minimieren und \mathbf{x} zu berechnen:

$$J(\mathbf{x}) = [\mathcal{Z} - h(\mathbf{x})]^T \Sigma_n^{-1} [\mathcal{Z} - h(\mathbf{x})] \quad (4.14)$$

Aufgrund der Nichtlinearität der Messfunktionen wird das Gauß-Newton-Verfahren verwendet. Dabei wird die Lösung iterativ gewonnen. Die optimale Schätzung des Zustands \mathbf{x} wird als $\hat{\mathbf{x}}$ bezeichnet.

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} J(\mathbf{x}) \quad (4.15)$$

Die Kovarianzmatrix der Endzustandsschätzung $\hat{\mathbf{x}}$ ist gegeben durch

$$\Sigma_{\hat{\mathbf{x}}} = \left[\mathbf{H}^\top(\mathbf{x}) \mathbf{W} \mathbf{H}(\mathbf{x}) \right]^{-1} \quad (4.16)$$

Die Gewichtsmatrix \mathbf{W} wird gleich dem Kehrwert der Messkovarianzmatrix Σ_n gewählt. Hierdurch werden Messpunkte mit größerer Unsicherheit weniger stark berücksichtigt. Die Matrix $\mathbf{H}(\mathbf{x}) \in \mathbb{R}^{L \times (2N-1)}$ ist die partielle Ableitung erster Ordnung von $h(\mathbf{x})$, welche in jeder Iteration des Gauß-Newton-Verfahrens benötigt wird.

4.4 Vergleich der Algorithmen zur Netzzustandsbestimmung und Diskussion

In diesem Kapitel werden die vorgestellten Methoden verglichen und bewertet. Hierbei werden zunächst die zur Validation verwendeten Lastszenarien definiert und im Anschluss die Ergebnisse vorgestellt.

Für die Evaluierung der Zustandserfassung in elektrischen Netzen wurden standardisierte Annahmen hinsichtlich der Lastverteilung vorausgesetzt. Besonders in Niederspannungsnetzen, wie sie in Wohngebieten vorliegen, spielt die spezifische Netzstruktur sowie die Verteilung der Lasten an den verschiedenen Netzpunkten eine entscheidende Rolle. Es ist wichtig zu betonen, dass in solchen Netzen Spitzenlasten in der Regel nicht gleichzeitig auftreten. Unterschiedliche Verbrauchsmuster in Haushalten führen zu einer zeitlichen Streuung der Höchstlasten. Um diesen charakteristischen Aspekt zu berücksichtigen, wird der Lastfaktor g_{res} verwendet. Dieser Faktor hilft dabei, die variierende Auslastung des Netzes und die daraus resultierenden Auswirkungen auf die Netzzustandserkennung realistisch abzubilden [83].

$$g_{\text{res}} = g_\infty + (1 - g_\infty) \cdot n^{-3/4} \quad (4.17)$$

wobei $P_{\text{res}} = P_{\text{max}} \cdot g_{\text{res}}$. Zudem wird ein $\cos \phi = 0,95$ angenommen sowie $P_{\text{max}} = 30 \text{ kW}$ und $g_\infty = 0,06$ definiert.

In diesen Ausdrücken steht n für die Anzahl der Lastknoten. Ferner repräsentieren P_{res} und P_{max} die resultierende und die maximal mögliche Last.

Zur Evaluation der Algorithmen wird sowohl für die Wirk- als auch für die Blindleistung eine Normalverteilung angenommen. In der Realität spiegelt diese die Vorhersageunsicherheiten für Last oder Erzeugung wider. Für alle Lasten wird eine einheitliche relative Standardabweichung angenommen, welche in Abhängigkeit des jeweiligen Leistungswertes in Prozent ausgedrückt wird. Dies führt zum Beispiel bei einer relativen Standardabweichung von 0,3 zu $\sigma_P = 0,3 P_{\text{res}}$ und $\sigma_Q = 0,3 Q_{\text{res}}$.

4.4.1 Vergleich der Niederspannungsnäherung mit dem Newton-Raphson Lastfluss

Eine Gegenüberstellung der Resultate, die aus den beiden Monte Carlo-Methoden hervorgehen, offenbart lediglich minimale Differenzen zwischen diesen. Diese Erkenntnis wird in Tabelle 4.1 unterstrichen, die den höchsten beobachteten Unterschied zwischen den beiden Methoden für die jeweiligen Einsatzszenarien und Netzstrukturen aufzeigt. Bei der MC-LLV Methode wird ein vereinfachtes Niederspannungsmodell verwendet, welches deutlich effizienter zu berechnen ist. Die Größenordnung der Fehler ist über alle betrachteten Szenarien sehr gering.

Tabelle 4.1: Vergleich der Monte-Carlo-Methoden: MC-NR gegen MC-LLV. Es werden verschiedene Netze und Standardabweichungen σ verglichen. Dargestellt ist die maximale Differenz zwischen beiden Methoden in [p.u.] für den jeweiligen Fall [47].

Rel. Vorhersagefehler (σ)		5 %	10 %	20 %	30 %
Landnetz	$\Delta \sigma$	5.15×10^{-6}	5.83×10^{-6}	8.77×10^{-6}	1.35×10^{-5}
	$\Delta \mu$	8.31×10^{-7}	1.67×10^{-6}	3.70×10^{-6}	6.47×10^{-6}
Dorfnetz	$\Delta \sigma$	1.80×10^{-5}	1.87×10^{-5}	2.19×10^{-5}	2.65×10^{-5}
	$\Delta \mu$	2.47×10^{-6}	4.98×10^{-6}	1.02×10^{-5}	1.61×10^{-5}
Verzweigtes Netz	$\Delta \sigma$	5.07×10^{-5}	5.28×10^{-5}	6.05×10^{-5}	7.49×10^{-5}
	$\Delta \mu$	4.11×10^{-6}	8.28×10^{-6}	1.86×10^{-5}	3.28×10^{-5}

4.4.2 Vergleich der Methoden anhand verschiedener Netze

In diesem Kapitel werden vorgestellten Methoden bezüglich ihrer Genauigkeit zur Berechnung der Standardabweichung und des Mittelwertes verglichen.

Tabelle 4.2: RMSE in [p.u.] der Spannungsabweichung für die Korrelationen von $r = 0.0$ und $r = 0.1$.

Netz	Methode	$r = 0.0$		$r = 0.1$	
		μ	σ	μ	σ
einfaches Netz	MC-LLV	$3,58 \cdot 10^{-6}$	$5,72 \cdot 10^{-8}$	$5,18 \cdot 10^{-6}$	$1,3059 \cdot 10^{-7}$
	WLS	$1,05 \cdot 10^{-4}$	$1,59 \cdot 10^{-4}$	$2,04 \cdot 10^{-5}$	$7,35 \cdot 10^{-5}$
	GEP	$8,61 \cdot 10^{-6}$	$1,19 \cdot 10^{-3}$	$1,39 \cdot 10^{-5}$	$1,69 \cdot 10^{-3}$
	GEP korr.		$4,60 \cdot 10^{-5}$		$3,89 \cdot 10^{-5}$
Kerber Dorfnetz [83]	MC-LLV	$5,22 \cdot 10^{-6}$	$1,04 \cdot 10^{-7}$	$7,55 \cdot 10^{-6}$	$2,36 \cdot 10^{-7}$
	WLS	$1,62 \cdot 10^{-6}$	$8,84 \cdot 10^{-5}$	$5,87 \cdot 10^{-5}$	$1,62 \cdot 10^{-4}$
	GEP	$1,62 \cdot 10^{-6}$	$4,27 \cdot 10^{-3}$	$5,13 \cdot 10^{-5}$	$6,07 \cdot 10^{-3}$
	GEP korr.		$1,39 \cdot 10^{-5}$		$1,77 \cdot 10^{-5}$
Komplex	MC-LLV	$6,47 \cdot 10^{-6}$	$1,37 \cdot 10^{-7}$	$9,36 \cdot 10^{-6}$	$3,12 \cdot 10^{-7}$
	WLS	$1,60 \cdot 10^{-4}$	$2,28 \cdot 10^{-4}$	$4,26 \cdot 10^{-5}$	$9,12 \cdot 10^{-5}$
	GEP	$1,37 \cdot 10^{-6}$	$5,63 \cdot 10^{-3}$	$2,97 \cdot 10^{-6}$	$8,17 \cdot 10^{-3}$
	GEP korr.		$3,26 \cdot 10^{-5}$		$4,02 \cdot 10^{-5}$

Die Spannungsergebnisse sind in Tabelle 4.2 aufgeführt. Die Schätzungen für den Spannungsmittelwert sowie die Standardabweichung sind bei allen angewandten Methoden zufriedenstellend. Die Monte-Carlo-Simulation in Kombination mit der Niederspannungsnäherung MC-LLV liefert dabei die präzisesten Ergebnisse. Eine weitere deutliche Fehlerreduktion lässt sich durch die Korrektur des Schätzfehlers mittels Gauss'scher Fehlerfortpflanzung erzielen.

4.4.3 Effizienzanalyse der Berechnungsmethoden

Bei der Verwendung einer probabilistischen Load-Flow-Methode in der numerischen Optimierung spielen zwei Faktoren, nämlich die Kompliziertheit des Problems (so gering wie möglich) und die Laufzeit des Algorithmus, eine wichtige Rolle. Die relativen Berechnungszeiten der Algorithmen als Fallbeispiele sind in Tabelle 4.3 verfügbar. Jeder einzelne Algorithmus wird in einer Python-Umgebung ausgeführt und läuft auf demselben Rechner (Intel Core i7-4790 CPU @ 3,60 GHz) unter ähnlichen Bedingungen.

Tabelle 4.3: Rechenzeit der probabilistischen Lastfluss-Methoden für das Dorfnetz.

Methode	Einzellauf [s]	Gesamtzeit [s]
MC-NR	2.56×10^{-2}	23.67
MC-LLV	8.91×10^{-3}	8.24
WLS		6.87×10^{-1}
GEP		8.80×10^{-2}
GEP korrigiert		1.18×10^{-1}

Für eine vollständige Monte-Carlo Lauf werden $1 \cdot 10^3$ Stichproben berechnet. Das führt bei der MC-NR Methode zu einer Laufzeit von 23,7 s wohingegen die MC-LLV Methode nur eine Laufzeit von etwa 8 s benötigt. Im Vergleich zum Newton-Rhapson-Algorithmus (MC-NR) ist die Niederspannungsnäherung (MC-LLV) also etwa dreimal schneller. Eine mögliche Begründung dieser Beobachtung ist, dass die MC-LLV keine Matrixinversion benötigt. Ähnlich wie bei der Admittanzmatrix muss auch die Strommatrix M_I , die die Topologie des Netzes darstellt, nur einmal im Voraus berechnet werden.

Methoden, die den Mittelwert und die Standardabweichung der Verteilung direkt schätzen, weisen alle eine Laufzeit von weniger als einer Sekunde auf. Selbst unter Berücksichtigung von Korrekturen ist die GEP-Methode dabei etwa fünfmal effizienter als die WLS-Methode.

4.5 Zusammenfassung der probabilistischen Lastflussberechnung

Das Kapitel konzentriert sich auf die Erkennung von Netzbedingungen in Verteilungsnetzen mit volatilen Erzeugern und Lasten unter Unsicherheiten.

Es wird eine Methode für Niederspannungsnetze eingeführt, die die Berechnungen von Spannungsabfällen vereinfacht. Zusätzlich werden Matrixdarstellungen vorgestellt, die die Berechnung von Spannungsabfällen und Strömen effizient gestalten.

Die Monte-Carlo-Methode (MC-NR) liefert die genauesten Ergebnisse und basiert nicht auf der Annahme einer Normalverteilung, ist aber auch die rechenintensivste Methode. Bei dieser Methode wird für jede Stichprobe ein Newton-Raphson-Lastfluss berechnet. Die MC-LLV-Methode ist eine praktikable Option für eine schnellere Schätzung von nicht normalverteilten Knotenleistungen und bietet eine gute Balance zwischen Genauigkeit und Rechenzeit. Die Wahl der geeigneten Methode hängt jedoch von den spezifischen Anforderungen, Randbedingungen und der verfügbaren Rechenleistung ab.

Das entwickelte probabilistische Lastflussverfahren auf Basis der Gaußschen Fehlerfortpflanzung (GEP) arbeitet mit der Annahme normalverteilter Unsicherheiten. Mittelwerte und Standardabweichungen werden zur Beschreibung der Wirk- und Scheinleistungsverteilungen und zur Berechnung der Spannungsabfälle verwendet. Ein Fallbeispiel vergleicht verschiedene Methoden zur Berechnung der Spannungshäufigkeitsverteilung. Die Besonderheit des Verfahrens liegt in seiner Effizienz bei der Anwendung in radialen Niederspannungsnetzen, da auf eine Matrixinversion verzichtet werden kann. Im Vergleich dazu benötigen sowohl die Methode MC-NR als auch die Methode WLS eine Matrixinversion in jeder Iteration.

Darüber hinaus hat die GEP-Methode den Vorteil, dass sie effektiv in lineare Optimierungsprobleme integriert werden kann. Dies kann einerseits für den optimierten Betrieb unter Unsicherheit und im erweiterten Fall auch für die optimale Platzierung von Speichern, wie in Kapitel 7.3.4 beschrieben, eingesetzt werden.

5 Modellierung von Energiesystemkomponenten zur Betrieboptimierung

Die zunehmende Integration erneuerbarer Energien in Energiesysteme stellt eine Herausforderung dar, da diese Ressourcen oft intermittierend und schwer vorhersagbar sind. Um den effizienten Betrieb solcher Energiesysteme zu gewährleisten, ist eine genaue Modellierung und Optimierung der einzelnen Komponenten erforderlich. Eine detaillierte Modellierung der Komponenten ist jedoch aufgrund ihrer Komplexität und der damit verbundenen Rechenanforderungen oft unrealistisch.

Vor diesem Hintergrund wird in dieser Arbeit die Modellierung von Energiesystemkomponenten zur Betrieboptimierung untersucht. Durch Vereinfachungen und Approximationen wird versucht, die Komplexität der Modelle zu reduzieren, ohne wesentliche Eigenschaften und Zusammenhänge zu vernachlässigen. Dies ermöglicht die Anwendung effizienter Optimierungsmethoden, um den Betrieb von erneuerbaren Energieressourcen, intermittierenden Erzeugungseinheiten und Energiespeichern zu optimieren.

Die Vereinfachung der Komponentenrepräsentation ist ein multidisziplinärer Ansatz, der ein Verständnis der charakteristischen Eigenschaften und des Verhaltens der Komponenten erfordert. Durch die geeignete Auswahl von Modellen, Gleichungen, Parametern und Beziehungen können die relevanten Aspekte der Komponenten erfasst und gleichzeitig der Rechenaufwand reduziert werden. Dabei ist es wichtig, die richtige Balance zwischen Modellkomplexität und Genauigkeit zu finden, um realistische und aussagekräftige Ergebnisse zu erhalten. Zu diesem Zweck werden sowohl statische Modelle verwendet, die über den Simulationszeitraum konstant bleiben, als auch adaptive Modelle, die sich an sich ändernde Umgebungsbedingungen anpassen.

Die Ergebnisse dieses Kapitels werden in den Kapiteln 6 und 7 vorgestellten Optimierungsmethoden verwendet, die in der Lage sind, große und komplexe Energiesysteme zu modellieren und hinsichtlich Wirtschaftlichkeit und Netzverträglichkeit zu optimieren. Durch die Verwendung vereinfachter Repräsentationen der Komponenten können Systeme zur Betrieboptimierung und Entscheidungsunterstützung in Energiesystemen entwickelt werden, die die Integration erneuerbarer Energien ermöglichen und zur Schaffung nachhaltiger Energieinfrastrukturen beitragen.

In den weiteren Abschnitten dieses Kapitels werden detaillierte Ansätze und Modelle zur Vereinfachung der Komponentenrepräsentation vorgestellt. Es wird diskutiert, wie die einzelnen Komponenten modelliert werden können und welche Vereinfachungen angewendet werden können, um die Komplexität zu reduzieren. Ein wichtiger Punkt in diesem Kapitel ist die adaptive Parameteridentifikation. Da

die thermische Gebäudemodellierung eine der komplexesten Aufgaben in diesem Kontext darstellt, wird die adaptive Parameteridentifikation an diesem Beispiel durchgeführt

5.1 Modellierung der Komponenten für die Optimierung

In der Modellierung und Simulation spielen Gray Box-, White Box- und Black Box-Modelle eine bedeutende Rolle bei der Beschreibung und Analyse von Systemen.

Black Box-Modelle fokussieren auf das externe Verhalten eines Systems, ohne detaillierte Kenntnisse über die internen Mechanismen zu erfordern. Sie basieren oft auf den Ansätzen des maschinellen Lernens.

Statistische Ansätze und maschinelles Lernen werden verwendet, um Zusammenhänge und Verhalten auf Basis von Ein- und Ausgabedaten zu analysieren. White Box-Modelle (wie EnergyPlus) hingegen basieren auf einem umfassenden Verständnis der internen Struktur und nutzen physikalische Gesetze oder mathematische Gleichungen zur Modellierung. Sie erfordern genaue Informationen über das System und seine Komponenten.

Gray Box-Modelle stellen einen Mittelweg dar, indem sie sowohl auf bekanntem Wissen als auch auf datengetriebenen Komponenten basieren. Sie ermöglichen eine flexiblere Modellierung, bei der sowohl das Systemwissen als auch Messdaten berücksichtigt werden können. Der Vorteil von Gray-Box-Modellen besteht darin, dass sie genauer und rechnerisch effizienter sein können als Black-Box-Modelle und gleichzeitig flexibler und einfacher zu konstruieren sind als White-Box-Modelle. Gray-Box-Modelle können auch Einblicke in das Systemverhalten geben, die bei Black-Box-Modellen nicht möglich sind.

Die Wahl des Modelltyps hängt von der verfügbaren Kenntnis des Systems, den verfügbaren Daten und den spezifischen Modellierungsanforderungen ab. Die Anwendung und Entwicklung dieser Modelle spielt eine wichtige Rolle bei der Modellierung komplexer Systeme und der Vorhersage ihres Verhaltens.

5.1.1 Lineare Modellierung der Komponenten

Um die Modellierung von erneuerbaren Energieressourcen (z.B. PV und Wind), intermittierenden Erzeugungseinheiten oder Energiespeichern mit begrenzter Kapazität zu standardisieren, wird, wenn nicht anders angegeben, eine standardisierte Formulierung gemäß dem *Power Node* Framework verwendet [84].

Abhängig von den Geräteeigenschaften und dem Energieangebot und -bedarf werden die Nebenbedingungen aufgelistet und die Entscheidungsvariablen definiert, um die charakteristischen Eigenschaften der Power-Nodes abzubilden. Softwaretechnisch wurde dies durch das Python Paket *CVXPY* [85, 86] abgebildet.

Das daraus resultierende Optimierungsproblem ist als gemischt-ganzzahliges lineares Programm (MILP) formuliert, das durch einen Branch-and-Bound-Algorithmus gelöst werden kann. Die Komplexität und die Berechnungszeiten sind stark problemabhängig, da das Problem in mehrere lineare

Programme (LPs) aufgeteilt werden muss, bei denen die ganzzahligen Bedingungen zwar gelockert, aber dennoch begrenzt sind [87–90]. Lineare Programme können jedoch effizient mit Standardverfahren wie dem Simplex-Algorithmus gelöst werden [91, 92].

Besonderes Augenmerk wurde auf eine effiziente Implementierung gelegt: Die Modelle werden als lineare Modelle konzipiert, um auch auf lokaler Energiemanagement-Hardware mit begrenzten Rechenressourcen optimiert werden zu können. Diese Konzentration auf Effizienz gewährleistet, dass das Modell in praktischen Anwendungsszenarien effektiv eingesetzt werden kann. Das von der Modellprädiktiven Regelung verwendete Modell muss alle relevanten Komponenten des Energiesystems erfassen, um eine Optimierung zu ermöglichen.

5.1.2 Batteriespeicher

Die Batterie wird als Energiespeicher mit fester Lade- und Entladeeffizienz modelliert. Dies vernachlässigt die nichtlinearen Eigenschaften des Batteriewirkungsgrads, bietet aber dennoch eine ausreichende Genauigkeit. Bei Bedarf kann die Effizienz stückweise linear definiert werden, wodurch die Nichtlinearitäten angenähert werden.

Das Modell kann wie folgt beschrieben werden:

$$\dot{x}_{\text{batt}} = \frac{\eta}{C_{\text{batt}}} P_{\text{batt}>0} + \frac{1}{\eta C_{\text{batt}}} P_{\text{batt}<0} \quad (5.1)$$

Hierbei ist $0 \leq x \leq 1$ der Ladezustand der Batterie.

5.1.3 Wärmepumpe

Die Wärmepumpe wird als linear zeitvariantes System (LTV) modelliert, da die Leistungszahl von den Temperaturdifferenzen abhängt, welche sich wiederum im Tagesverlauf ändert.

Die Wärmeenergieabgabe der Wärmepumpe wurde anhand Gleichung 3.7 modelliert. Im Gegensatz zu Gleichung 3.7 wird die Wärmepumpeneffizienz η_{PLR} (PLR) linearisiert. Dadurch kann der COP durch eine lineare Beziehung zwischen der Wärmepumpenleistung P_{el} und dem abgegebenen Wärmestrom \dot{Q}_{HP} abgebildet werden. Während des modellprädiktiven Betriebs (MPC) wird der COP auf der Grundlage der Vorhersagen für die Außentemperatur (T_{k}) geschätzt.

5.1.4 Thermischer Speicher

Das Warmwasserspeichermodell für die modellprädiktive Regelung (Model Predictive Control, MPC) ist ein Tankmodell mit drei Zonen, die heiße, die gemischte und die kalte Zone. Dabei wird die durchschnittliche Tanktemperatur wie folgt berechnet:

$$\dot{x}_{\text{tank}} = \dot{Q}_{\text{tank, in}} - \dot{Q}_{\text{tank, out}} - \dot{Q}_{\text{tank, loss}} \quad (5.2)$$

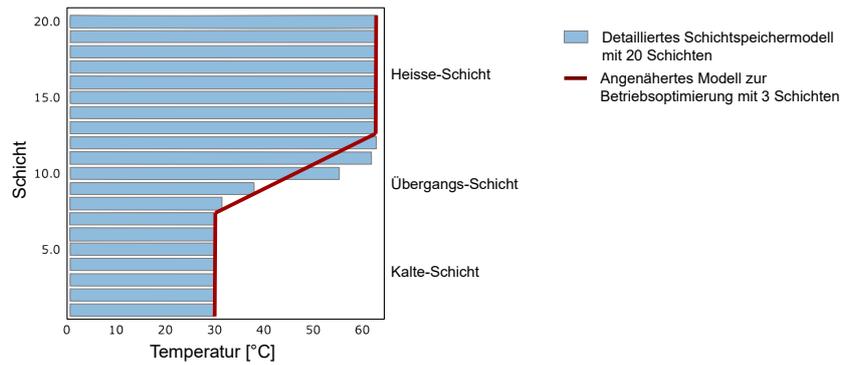


Abbildung 5.1 Der Temperaturverlauf für einen halb gefüllten Speicher nach dem idealisierten Speichermodell in rot und der Temperaturverlauf für einen nach dem Knotenmodell simulierten Speicher in blau.

Die Tankverluste basieren auf einer linearen Beziehung zwischen der durchschnittlichen Speichertemperatur x_{tank} und der Umgebungstemperatur um den Speicher T_{amb} und können wie folgt berechnet werden:

$$\dot{Q}_{\text{tank, loss}} = \Lambda_{\text{tank}} (x_{\text{tank}}, T_{\text{amb}}) \quad (5.3)$$

Dabei beschreibt Λ_{tank} die Eigenschaften des Tanks im Hinblick auf die Wärmeverluste. In Abbildung 5.1 ist ein qualitativer Vergleich zwischen dem vereinfachten Tankmodell und dem detaillierten Schichtmodell gegeben. Die Höhe der gemischten Zone kann individuell angepasst werden.

5.1.5 Thermisches Gebäudemodell auf Basis von elektrischen Ersatzschaltbildern

In diesem Fall handelt es sich bei den theoretischen Strukturen um verschiedene vereinfachte RC-Kreise (pauschaler Wärmewiderstand und Kapazität) wie in Abbildung 5.2 dargestellt. Sie werden online anhand lokaler Messwerte der Temperaturen angepasst und ermöglichen so die Implementierung komplexer Regelalgorithmen. Sie erlauben es uns auch, Simulationen von mehreren Gebäuden in einem realistischen Zeitrahmen durchzuführen und das thermische Verhalten der Gebäude ausreichend detailliert zu erfassen.

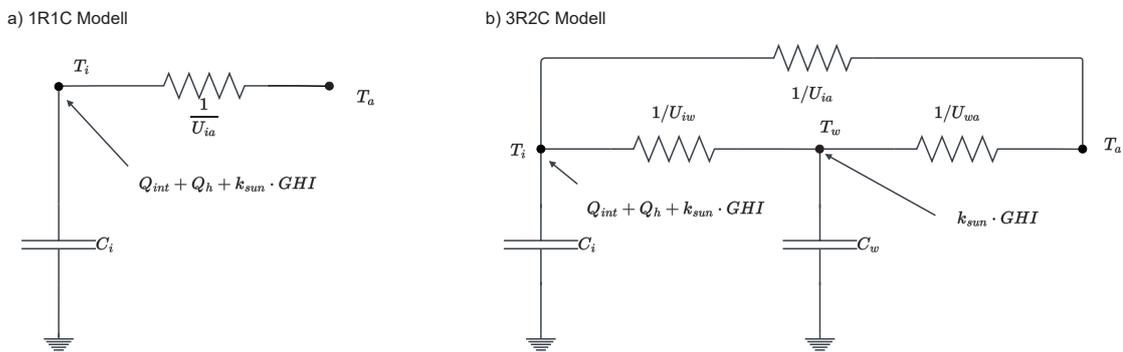


Abbildung 5.2 Strukturelle Darstellung der 1R1C und 3R2C thermischen Gebäudemodelle - Veranschaulichung der Komplexität und Konfiguration jedes Modells für Anwendungen im Energiemanagement [93].

Durch die Verwendung der RC-Kreise aus Abbildung 5.2 als Ersatzschaltbild kann ein Zustandsraummodell abgeleitet werden. Die Parameter des Gebäudemodells werden im Parametervektor \mathbf{w} zusammengefasst. Das Zustandsraummodell kann beschrieben werden mit

$$\mathbf{x}_{k+1} = \mathbf{A}(\mathbf{w}_k)\mathbf{x}_k + \mathbf{B}(\mathbf{w}_k)\mathbf{u}_k + \mathbf{v}_k \quad (5.4)$$

$$\mathbf{y}_k = \mathbf{C}\mathbf{x}_k + \mathbf{n}_k \quad (5.5)$$

5.1.6 Modellbewertung und -Auswahl

Bei der Gebäudemodellierung gibt es oft einen Kompromiss zwischen Modellkomplexität und Genauigkeit. Ein komplexeres Modell kann die zugrunde liegenden physikalischen Phänomene besser erfassen und eine genauere Darstellung des Gebäudeverhaltens liefern. Ein komplexeres Modell kann jedoch auch schwieriger zu kalibrieren sein, mehr Daten erfordern und rechenintensiver sein, was zu höheren Kosten und geringerer Modellleistung führen kann.

In diesem Abschnitt werden die in Abbildung 5.2 gezeigten Modelle verglichen. Die Bewertung erfolgt durch die Anpassung der Modelle an Zeitreihen, die aus verschiedenen Jahreszeiten mit unterschiedlichen Längen ausgewählt wurden, und den anschließenden Vergleich der durchschnittlichen Modellfehler.

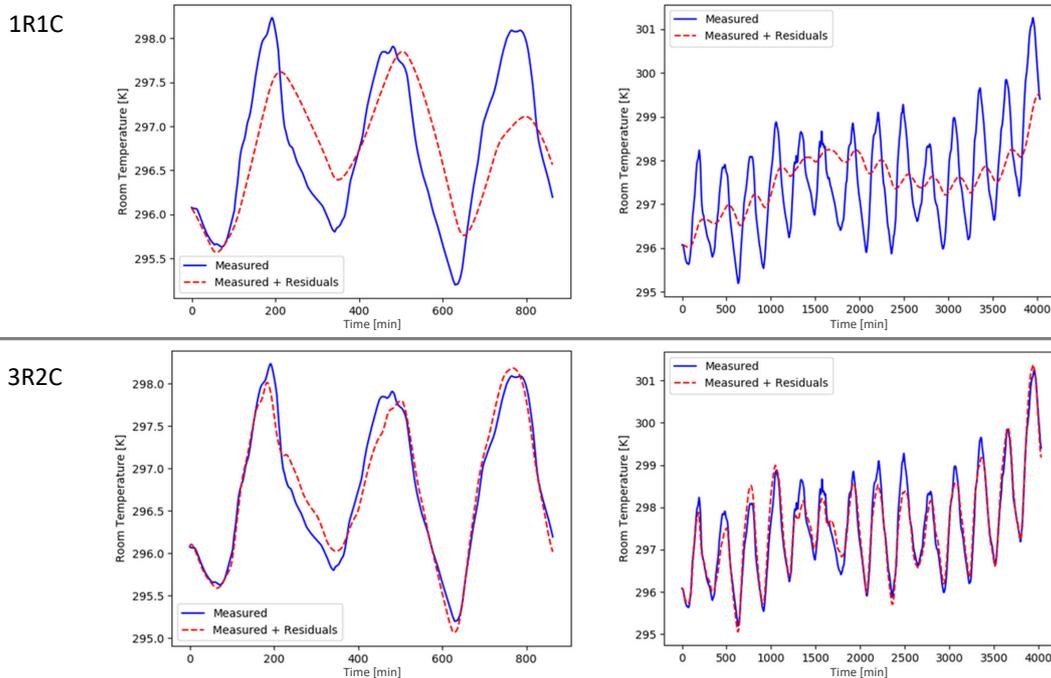


Abbildung 5.3 Modellvorhersagezeiträumen (rot) im Vergleich zu Messungen (blau) für verschiedene Horizontlängen (links: 3 Tage, rechts: 14 Tage). Das einfachere 1R1C-Modell schneidet akzeptabel ab, wenn es auf kurze Horizonte angepasst wird. Für längere Horizonte gibt das Modell das tatsächliche thermische Verhalten nicht wieder [93].

In Abbildung 5.3 ist ein Beispielvorhersagezeitraum für das 1R1C- und das 3R2C-Modell für zwei Vorhersagehorizonte dargestellt. Der kürzere Vorhersagehorizont (3 Tage) wird vom 1R1C-Modell noch einigermaßen erfasst. Bei längeren Horizonten erlaubt die geringe Komplexität des 1R1C-Modells keine detaillierte Darstellung der Innentemperatur und erfasst lediglich die langfristigen Trends. Das komplexere 3R2C-Modell erfasst sowohl die kurzfristigen Temperaturänderungen als auch den langfristigen Trend.

Dies ist auch in Abbildung 5.4 zu sehen. Dort werden verschiedene Modellordnungen und Anpassungszeiträume verglichen. Die Approximationsgüte der komplexeren Modelle nimmt mit zunehmender Länge der Zeitreihen ab. Der Unterschied zwischen dem 3R2C Modell und einem Modell höherer Ordnung (4R3C) ist auch bei längeren Zeitreihen nicht signifikant. Daher wurde das 3R2C-Modell für die weitere Auswertung ausgewählt.

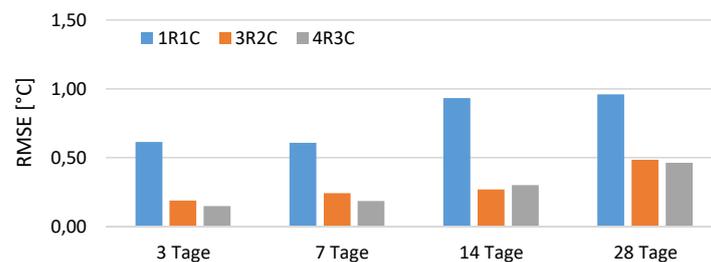


Abbildung 5.4 Die Güte des thermischen Gebäudemodells hängt von der Länge des Vorhersagehorizonts ab. Längere Horizonte erhöhen den Fehler in der Temperaturschätzung. Komplexere Modelle verringern den Fehler [93].

5.2 Adaptive Parameteridentifikation

Die Parameteridentifikation ist eine grundlegende Aufgabe bei der mathematischen Modellierung, die darauf abzielt, die Werte der unbekanntesten Parameter in einem mathematischen Modell zu bestimmen, die die beobachteten Daten am genauesten beschreiben. Bei der Parameteridentifizierung werden die Vorhersagen des Modells mit den tatsächlichen Daten verglichen und die Parameter angepasst, um die Diskrepanz zwischen den beiden zu minimieren.

Die Parameteridentifikation kann mit verschiedenen Methoden geschehen, wie z.B. der Schätzung nach der Methode der kleinsten Quadrate oder der Maximum-Likelihood-Schätzung. Auch der Kalman-Filter ist ein Algorithmus, der zur Parameteridentifikation verwendet werden kann. Es handelt sich um einen rekursiven Algorithmus, der den Zustand eines Systems in jedem Zeitschritt auf der Grundlage von Messungen und einem angenommenen Modell des Systems schätzt. Es gibt verschiedene Arten von Kalman-Filter, darunter den Standard-Kalman-Filter, den erweiterten Kalman-Filter und den Unscented-Kalman-Filter. Diese unterscheiden sich hinsichtlich der Annahmen über das zugrundeliegende Modell.

Für den Modellprädiktiven Regler und die dahinterstehende Optimierung ist es von Vorteil, wenn die dahinterstehenden Modelle keine zu große Komplexität aufweisen, da sich dies direkt auf die nötige Rechenleistung auswirkt. Gleichzeitig ist es bei einer geringen Modellkomplexität oft nicht möglich, das Verhalten für alle möglichen Umgebungsbedingungen perfekt abzubilden.

Eine weitere Herausforderung ist die Modellierung, wenn die Datenlage beschränkt ist. Neuronale Netzwerke und ähnliche komplexe Modelle sind für ihr Verlangen nach umfangreichen Datenmengen bekannt, um eine effektive Generalisierungsleistung zu erzielen. Dies ist auf die hohe Anzahl an Parametern zurückzuführen, die in diesen Modellen trainiert werden müssen. Methoden wie Daten-Augmentation und Transfer-Lernen können zwar genutzt werden, um das Modelltraining zu verbessern und zu beschleunigen, selbst wenn die zur Verfügung stehende Datenmenge begrenzt ist. Diese Methoden müssen aber auch auf einer speziellen Hardware trainiert werden und können nicht on-Site kalibriert werden.

Adaptive, selbstlernende Modelle, auch als Online-Lernmodelle bezeichnet, bieten einen Vorteil in dynamischen Anwendungsfällen, in denen sich die Parameter über die Zeit hinweg verändern können. Solche Modelle aktualisieren ihre Parameter kontinuierlich auf der Grundlage neu verfügbarer Daten, im Gegensatz zu traditionellen batchbasierten Lernmodellen, die einmalig auf einer festgelegten Menge von Trainingsdaten trainiert werden und deren Parameter nach dem Training statisch bleiben. Dies ermöglicht den adaptiven Modellen eine höhere Flexibilität und Anpassungsfähigkeit an sich verändernde Umgebungen.

Trotz dieser Vorteile ergeben sich auch Herausforderungen bei der Verwendung adaptiver, selbstlernender Modelle. Sie können anfällig für Overfitting sein, insbesondere wenn die neuesten Daten Rauschen oder Ausreißer enthalten, und sie erfordern kontinuierliche Rechenressourcen für die ständige Aktualisierung ihrer Parameter. Dies macht es notwendig, die spezifischen Anforderungen und Beschränkungen des jeweiligen Anwendungsfalls zu berücksichtigen, um die Eignung solcher Modelle zu beurteilen.

Da die Speicherung thermischer Energie ein erhebliches Potenzial zur Verbesserung der Energieeffizienz von Gebäuden und zur Senkung der Energiekosten bietet, wird die adaptive Parameteridentifikation an diesem Beispiel getestet. Die Technik kann allerdings prinzipiell auch für andere Anlagentypen, welche sich auf ändernde Umgebungsbedingungen anpassen müssen, angewendet werden. So können beispielsweise Erzeugungsmodelle für PV-Anlagen adaptiv gestaltet werden, um sich optimal auf ändernde Albedo und Umgebungsbedingungen anpassen zu können.

5.2.1 Adaptive Schätzung thermischer Gebäudemodelle

Mit modernen Energiemanagementsystemen kann überschüssige Energie, die in Schwachlastzeiten erzeugt wird, in der thermischen Masse des Gebäudes gespeichert werden, wodurch der Bedarf an Energie aus dem Netz in Spitzenlastzeiten verringert wird. Die Integration von thermischen Modellen in Energiemanagementsysteme ermöglicht die Optimierung des Energieverbrauchs des Gebäudes als Reaktion auf veränderte Bedingungen und Energiepreise, was zu noch größeren Energieeinsparungen, Kostensenkungen und Umweltvorteilen führt. Um die oben genannten Vorteile zu nutzen, muss ein thermisches Gebäudemodell in das Energiemanagementsystem integriert werden. Einer der Hauptvorteile thermischer Gebäudemodelle besteht darin, dass sie als Reaktion auf veränderte Bedingungen oder Energiepreise Entscheidungen in Echtzeit unterstützen können.

Die Online-Parameterschätzung für thermische Gebäudemodelle bietet eine Reihe von Vorteilen für Gebäudeenergiemanagementprogramme. Einer der Hauptvorteile der online Parameterschätzung ist

die Möglichkeit, Modellierungsfehler und Diskrepanzen kontinuierlich und in Echtzeit zu erkennen und zu korrigieren. Dies ermöglicht eine genauere Darstellung des Gebäudeverhaltens, wodurch das Potenzial für modellbasierte Fehler und suboptimale Steuerungsstrategien verringert wird. Die Online-Parameterschätzung kann auch die Zuverlässigkeit des Modells verbessern und es robuster gegenüber Änderungen der Betriebsbedingungen und Messstörungen machen: Durch die kontinuierliche Aktualisierung der Modellparameter als Reaktion auf sich ändernde Bedingungen, wie z. B. Belegungsmuster oder Wetterbedingungen, können die Steuerungsstrategien die Genauigkeit des Modells erhöhen. Ferner kann die Online-Parameterschätzung den Bedarf an manueller Kalibrierung und Wartung des Gebäudeenergiemodells verringern. Durch die Automatisierung der Parameterschätzung kann das Modell effizienter und kostengünstiger aktualisiert und gewartet werden. Der oben erwähnte Algorithmus der kleinsten Quadrate (LS) kann als rekursive Methode für die Zustandsraumparameterschätzung formuliert werden. Dieser Ansatz ist als rekursive Methode der kleinsten Quadrate (RLS) bekannt. Für die Schätzung von thermischen Gebäudeparametern kann der mathematische Ansatz und Algorithmus von [94, 95] verwendet werden.

Joint Extended Kalman Filter

Der Kalman-Filter ist ein weiterer weitverbreiteter Algorithmus auf dem Gebiet der Zustandsbeobachter, der in vielen Anwendungen eingesetzt wird. Er verwendet einen sogenannten optimalen Schätzer, um den Erwartungswert des quadrierten Beobachterfehlers zu minimieren, der seine Varianz darstellt. Stochastische Störungen, Mess- und Prozessrauschen werden ebenfalls berücksichtigt. Für die Zustandsschätzung des dynamischen Systems müssen sowohl die stochastischen Störungen als auch das Mess- und Prozessrauschen einer Gaußschen Normalverteilung entsprechen.

In der Regel umfasst der diskrete Zustand \mathbf{x}_k die tatsächlichen physikalischen Zustände, die im Falle des 3R2C-Modells die Raum- und Wandtemperatur sind. Um den Zustand \mathbf{x}_k und die Modellparameter \mathbf{w}_k gemeinsam schätzen zu können, muss der Zustandsraum erweitert werden:

$$\boldsymbol{\chi}_k = \begin{pmatrix} \mathbf{x}_k \\ \mathbf{w}_k \end{pmatrix}. \quad (5.6)$$

Das nichtlineare Zustandsraumsystem ist also definiert durch

$$\boldsymbol{\chi}_{k+1} = F(\boldsymbol{\chi}_k, \mathbf{u}_k) + \mathbf{v}_k \quad (5.7)$$

mit

$$F(\boldsymbol{\chi}_k, \mathbf{u}_k) = \begin{bmatrix} f(\boldsymbol{\chi}_k, \mathbf{u}_k) \\ \mathbf{w}_k \end{bmatrix}. \quad (5.8)$$

Der erweiterte Kalman-Filter kann dann zur gemeinsamen Schätzung der tatsächlichen Zustände und der Parameter der Zustandsübergangsmatrix verwendet werden. Dazu wird das nicht lineare

System über eine Taylor-Approximation um einen Arbeitspunkt linearisiert, wobei die erweiterte und linearisierte Systemmatrix \bar{A}_k definiert ist durch

$$\bar{A}_k = \frac{\partial F(\boldsymbol{\chi})}{\partial \boldsymbol{\chi}} = \begin{bmatrix} \frac{\partial f(\mathbf{x}_k, \mathbf{w}_k)}{\partial \boldsymbol{\chi}_k} \\ \mathbb{I} \end{bmatrix}. \quad (5.9)$$

Dabei stellt \mathbb{I} die Einheitsmatrix dar. Der Joint Extended Kalman Filter (JEKF) unterscheidet sich in der Struktur des Algorithmus nicht wesentlich von dem erweiterten Kalman-Filter [96].

Eine Möglichkeit, die Genauigkeit der dynamischen Zustandsschätzung des erweiterten Kalman-Filters (EKF) zu verbessern, ist die adaptive Schätzung der Prozessparameter [97]. Die Methode erlaubt die adaptive Schätzung der Kovarianzmatrizen des Prozessrauschens (Q) und des Messrauschens (R), welche die Filterleistung erheblich beeinflussen. Herkömmliche Methoden haben gezeigt, dass die Schätzung dieser Matrizen für optimale Filterergebnisse unzureichend ist, was die Entwicklung dieses adaptiven Ansatzes unter Verwendung von Innovation und Residuum motivierte.

5.2.2 Ergebnisse der adaptiven Parameteridentifikation

Bei der Online-Schätzung ist die Konvergenzanalyse eines Algorithmus ein wichtiger Leistungsaspekt. Um die Konvergenz der Modellparameter zu testen, wurde ein synthetisches Gebäudemodell mit bekannten Parametern erstellt.

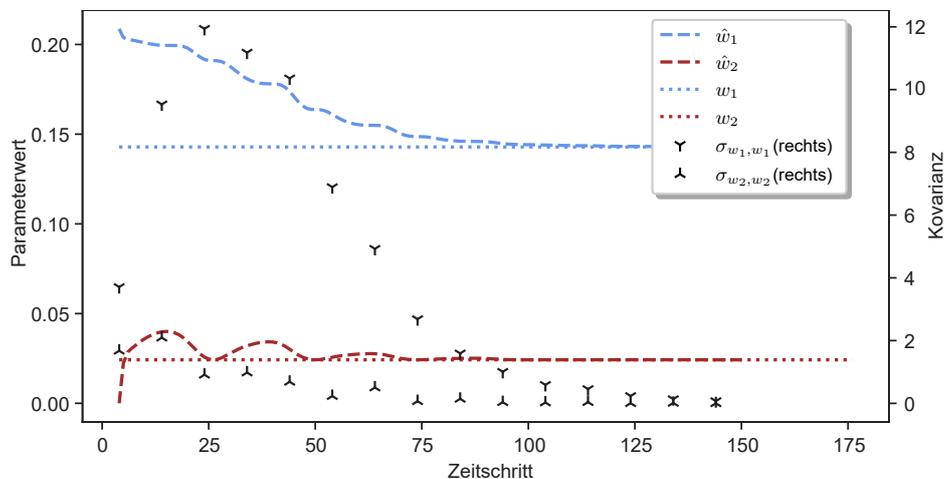


Abbildung 5.5 Konvergenz der Parameter eines synthetischen 1R1C-Modells [93]. Auf der rechten y-Achse ist die Kovarianz der Parameter dargestellt. Mit zunehmender Anzahl von Beobachtungen konvergieren die Parameterschätzungen \hat{w} gegen die wahren Parameter w und die Kovarianz nimmt ab.

Die Konvergenz der Gewichtparameter ist in Abbildung 5.5 dargestellt. Hier wurde ein Modell mit bekannten Parametern durch den JEKF geschätzt und der Konvergenzverlauf zu den Modellparametern geplottet. Zudem ist auf der rechten Seite die Kovarianz der Parameterschätzung dargestellt. Im Verlauf der Simulation konvergieren die Parameter zu den wahren Werten und die Kovarianz nimmt ab.

Die Konvergenz des 1R1C-Modells in einem realistischen Szenario mit Daten aus EnergyPlus-Simulationen (siehe Kapitel 3.1) ist in Abbildung 5.6 dargestellt. Anfänglich wiesen die Vorhersagen

eine hohe Unsicherheit auf, die in Grau dargestellt ist. Nach der Konvergenz des Modells waren die Vorhersagen wesentlich stabiler und genauer.

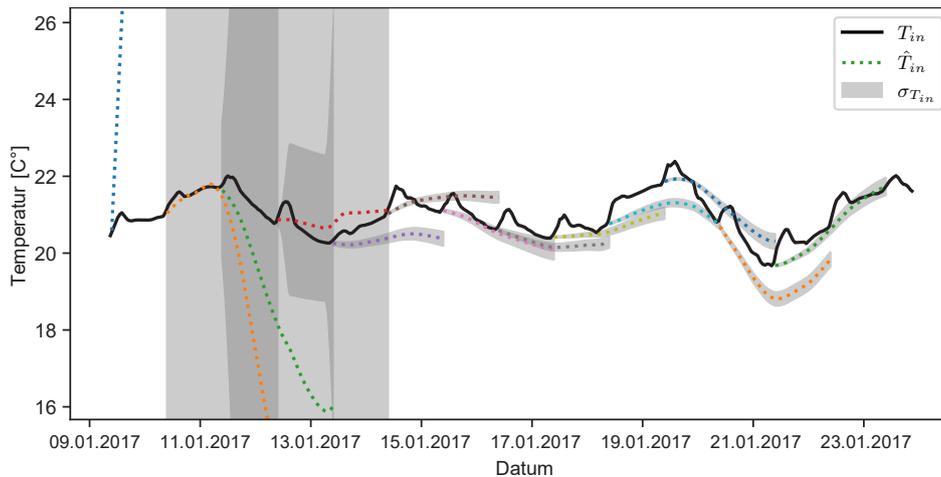


Abbildung 5.6 Konvergenz des 1R1C-Modells unter Verwendung von Eingangsdaten aus EnergyPlus-Simulationen. Der graue Bereich zeigt die Standardabweichung $\sigma_{T_{in}}$ und die gestrichelte Linie den geschätzten Mittelwert \hat{T}_{in} der Vorhersagen. Die Vorhersagegenauigkeit steigt mit der Anzahl der Beobachtungen (Zeitschritte) [93].

Mit einem Online-Parameterschätzverfahren wie dem JEKF kann die Vorhersagegenauigkeit einfacher Modelle verbessert werden, da die Parameter ständig an die neuen Bedingungen angepasst werden. Dies ist in Abbildung 5.7 zu sehen, wo die Vorhersagegenauigkeit der Modelle über einen Zeitraum von drei Wochen im Januar verglichen wird. Das Modell 1R1C schneidet für kürzere Zeiträume etwas besser ab als das komplexere Modell 3R2C. Bei längeren Zeiträumen hingegen ist die Leistung des 3R2C-Modells etwas besser als die des 1R1C-Modells.

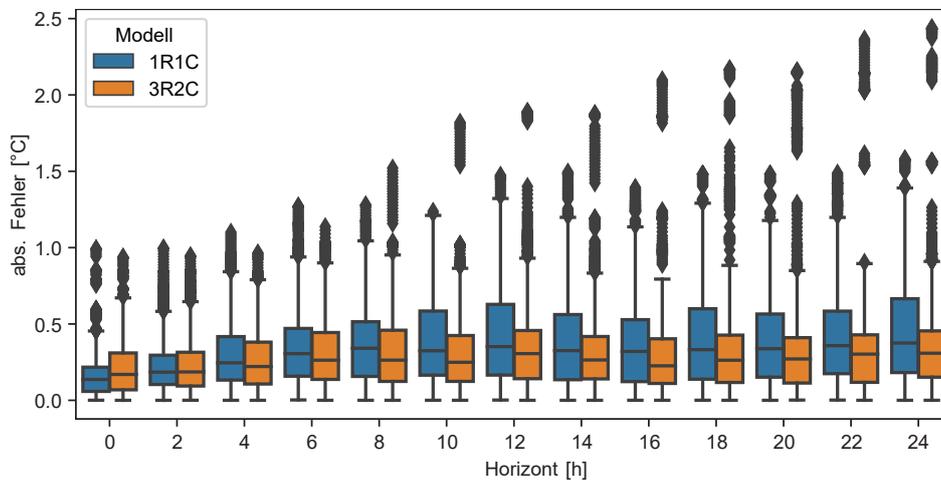


Abbildung 5.7 Vergleich der T_{in} -Vorhersagegenauigkeit des adaptiven 1R1C-Modells und des 3R2C-Modells unter Verwendung der Online-Parameterschätzung (JEKF) für einen 3-Wochen-Zeitraum im Januar für den Standort Stuttgart, Deutschland. Die x-Achse zeigt den Vorhersagehorizont bis zu 24h, die y-Achse die Verteilung des T_{in} -Vorhersagefehlers in °C [93].

5.3 Kernpunkte der Modellierung von Energiesystemkomponenten zur Betriebsoptimierung

In diesem Kapitel wurde die vereinfachte Repräsentation der Komponenten für die Betriebsoptimierung in Bezug auf erneuerbare Energieressourcen, intermittierende Erzeugungseinheiten und Energiespeicher mit begrenzter Kapazität diskutiert. Es wurden verschiedene Methoden zur Parameteridentifikation vorgestellt. Diese Methoden ermöglichen es, die unbekannt Parameter in einem mathematischen Modell zu bestimmen, um die beobachteten Daten am genauesten zu beschreiben.

Die mathematische Modellierung der Komponenten wurde anhand von Batteriespeichern, Wärmepumpen und thermischen Gebäudemodellen erläutert. Es wurde gezeigt, wie diese Komponenten in Energiemanagementsysteme integriert werden können, um eine Optimierung des Energieverbrauchs zu ermöglichen. Am Beispiel des Gebäudemodells wurden die Modellperformanz entsprechend ihrer Komplexität und Genauigkeit bewertet, wobei das Ziel darin bestand, ein angemessenes Gleichgewicht zwischen Genauigkeit und Rechenleistung zu finden.

Ein Schwerpunkt lag auf der adaptiven Parameteridentifikation für thermische Gebäudemodelle. Die adaptive Schätzung ermöglicht eine kontinuierliche Aktualisierung der Modellparameter in Echtzeit, um Änderungen in den Betriebsbedingungen und Messstörungen zu berücksichtigen. Es wurden verschiedene adaptive Filteransätze, wie der Joint Extended Kalman Filter (JEKF), vorgestellt und deren Konvergenz analysiert. Die adaptive Schätzung verbessert die Genauigkeit der Zustandsschätzung und ermöglicht eine effizientere Modellaktualisierung und Wartung. Im Ergebnis ermöglicht der Algorithmus eine Reduktion der Modellkomplexität bei gleichbleibender Vorhersagegüte. Alternativ ist auch eine Verbesserung der Innentemperaturvorhersage um etwa 20% bei Nutzung des 1R1C Modells möglich.

Insgesamt bietet die vereinfachte Repräsentation der Komponenten und die adaptive Parameteridentifikation wichtige Werkzeuge für die Betriebsoptimierung von Energiesystemen. Durch die Nutzung dieser Ansätze können Energiemanagementsysteme effizienter gestaltet und Energieeinsparungen sowie Kostensenkungen erreicht werden.

6 Betriebsoptimierung verteilter Erzeuger und Speicher

In diesem Kapitel liegt der Fokus auf den Methoden und Algorithmen zur Optimierung des Betriebs verteilter Energiequellen und Lasten, einschließlich Photovoltaik-Anlagen, Speichersystemen und Wärmepumpen. Hauptziel der Betriebsoptimierung besteht darin, die im Netz verfügbaren Flexibilitätsressourcen bestmöglich auszuschöpfen. Damit sollen Netzengpässe vermieden und ein Ausbau der erneuerbaren Energien gefördert werden. Im Verlauf des Kapitels wird eine eingehende Analyse der Betriebsoptimierung verteilter Energieerzeuger und Speichersysteme durchgeführt, wobei ein besonderer Schwerpunkt auf der Kategorisierung von Algorithmen und der Untersuchung von Vorhersageunsicherheiten liegt.

Ein Hauptbestandteil des Kapitels besteht in der Erörterung der Einordnung zentraler und dezentraler Algorithmen. Der Abschnitt zielt darauf ab, ein Verständnis für unterschiedlichen Algorithmen zu schaffen und ihre potenziellen Rollen und Beiträge zur Betriebsoptimierung verteilter Energieerzeuger und Speicher aufzuzeigen. Weiterhin werden Beispiele einzelnen Algorithmientypen und ihrer spezifischen Anwendungen innerhalb des Energiesystems aufgeführt. Im weiteren Verlauf des Kapitels werden verschiedene Typen des Energiemanagements beschrieben und ausgewertet.

Die Untersuchung von Vorhersageunsicherheiten stellt einen weiteren zentralen Punkt in diesem Kapitel dar. In diesem Abschnitt wird dargelegt, wie die Unsicherheit in der Prognose von Last und Erzeugung das Energiemanagement beeinflusst und welche Strategien entwickelt werden können, um diese Unsicherheiten zu bewältigen und die Betriebsoptimierung zu verbessern.

Nachfolgend wird ein Ansatz für das verteilte Energiemanagement dargelegt, welcher eine Koordination von Energieressourcen über diverse Standorte hinweg vorsieht. Es wird ein Szenario für das verteilte Energiemanagement skizziert und die potenziellen Beiträge dieser Strategie zur Optimierung der Energieversorgung diskutiert.

Dieses Kapitel liefert nicht nur eine grundlegende theoretische Grundlage für die Einordnung von Algorithmen und die Untersuchung von Vorhersageunsicherheiten, sondern bietet auch praxisnahe Anwendungen und Lösungsansätze für die Betriebsoptimierung verteilter Energieerzeuger und Speichersysteme.

6.1 Einordnung zentraler und dezentraler Algorithmen

Zentrale, dezentrale und verteilte Systeme sind Begriffe, die zur Beschreibung verschiedener Arten von Systemen oder Organisationen verwendet werden. In den 1960er Jahren unterschied der Ingenieur

Paul Baran [98] in Studien über Kommunikationsnetze zwischen zentralen, dezentralen und verteilten Systemen. Dabei beschrieb er „dezentral“ als einen unscharfen Zustand zwischen dem zentralen und dem verteilten System [99]. Während Barans Positionierung von Verteilung und Dezentralisierung entlang desselben Kontinuums im Kontext von Kommunikationsnetzwerken sinnvoll war, erfordert ein komplexerer regelungstechnischer oder organisatorischer Kontext eine umfassendere Sichtweise.

Im Kontext der Systemforschung hat eine Verschiebung in der Verwendung der Begriffe „dezentral“ und „verteilt“ stattgefunden, insbesondere innerhalb des Sektors der Softwareentwicklung [100]. Der Begriff „verteilte“ Systeme repräsentieren jetzt eine moderate Position, während „dezentrale“ Systeme das Extrem bilden. Diese Verschiebung im Vokabular kann auf die Arbeiten von Fischer, Lynch und Paterson aus dem Jahr 1985 zurückgeführt werden, in denen sie die „Unmöglichkeit eines verteilten Konsenses“ in asynchronen Netzwerken betonten [99, 101]. In der Organisationsforschung hingegen werden die Begriffe „verteilt“ und „dezentral“ oft synonym verwendet.

Die Entwicklung und der Erfolg der Blockchaintechnologie hat zu weiterer Diskussion über die Definition geführt. Vitalik Buterin, ein führender Blockchain-Experte, schlug eine dreidimensionale Sicht der Dezentralisierung in Bezug zur Blockchaintechnologie vor [99, 102]: Bei der *architektonischen Dezentralisierung* werden der physische Aufbau und die Fehlertoleranz des Systems untersucht. Dies bezieht sich auf die physische Struktur des Systems und die Anzahl der beteiligten Computer. Dabei wird berücksichtigt, wie das System auf mehrere Computer verteilt ist und wie viele Ausfälle es verkraften kann. Eine stark dezentralisierte Architektur würde eine große Anzahl von Computern umfassen, was das System widerstandsfähiger gegen einzelne Ausfälle macht. Die *politische Dezentralisierung* bezieht sich auf die Verteilung der Kontroll- und Entscheidungsbefugnisse auf einzelne Personen oder Organisationen, die das System überwachen. Eine stark dezentralisierte politische Struktur würde ein verteiltes Netzwerk von Entscheidungsträgern umfassen, wodurch die Machtkonzentration verringert würde. Die *logische Dezentralisierung* schließlich bewertet die Schnittstellen- und Datenstrukturen. Dabei wird berücksichtigt, ob das System als eine einzige zusammenhängende Einheit oder als ein dezentrales Netzwerk von miteinander verbundener Komponenten erscheint. Ein logischerweise dezentralisiertes System würde die Merkmale der Modularität und Interoperabilität aufweisen, die einen unabhängigen Betrieb seiner Bestandteile ermöglichen.

6.1.1 Übertragung auf Netz- und Energiemanagement

Die mehrdimensionale Aufteilung der Begriffe erlaubt auch für Systeme im Bereich des Energiemanagements eine bessere Kategorisierbarkeit der verschiedenen Ansätze. Hierbei bieten sich im Bereich des Energiemanagements eine Einteilung in die verschiedenen Arten des Informationsaustauschs und -Topologien einerseits und andererseits in die verschiedenen Arten der Entscheidungsfindung.

Informationsaustausch / Topologie: Hier wird die Art des Informationsaustauschs beschrieben. Wichtig ist hierbei zu beachten, dass es rein um den Informationsaustausch geht und die Art der Informationsübertragung sowie Kommunikationswege offen bleibt. Diese reicht von Systemen ohne aktive Kommunikation über unidirektionaler Kommunikation hin zu komplexen vermaschten Kommunikationstopologien.

keine aktive Kommunikation: Es gibt keine aktive Kommunikationsmöglichkeit. Vorgaben werden nur offline, etwa bei der Installation der Anlage, gesetzt.

gering/einfach: Die Kommunikationsmöglichkeiten sind gering, teilweise nur unidirektional und die Topologie nicht vermascht.

hoch/komplex: Gute Kommunikationsmöglichkeiten, ggf. vermascht oder hierarchisch aufgebaut. Dies ist die technisch anspruchsvollste Kommunikationsinfrastruktur, hat aber gleichzeitig den Vorteil einer hohen Redundanz und Betriebssicherheit [98].

Entscheidung / Koordination: Da eine rein zentral koordinierte Regelung aller regenerativen Erzeuger aufgrund der sehr großen Datenmenge numerisch kaum handhabbar ist und die Anforderungen an die Kommunikationsinfrastruktur enorm wären, gibt es verschiedene Ansätze, dies zu entschärfen. Eine Möglichkeit besteht darin, die Entscheidungstopologie in mehrere Ebenen aufzuteilen.

zentral: In einem zentralisierten System sind die Entscheidungsfindung und die Kontrolle an einem einzigen Ort oder einer einzigen Einrichtung zentralisiert. Die Entscheidung kann hierbei automatisch durch einen Optimierer getroffen werden oder wird manuell vorgegeben.

verteilt: verteilte Systeme haben mehrere Kontroll- und Entscheidungspunkte. Die Regelung erfolgt dezentral durch autonome Einheiten. Je nach Kommunikationstopologie kann eine Kommunikation untereinander oder mit der Leitstelle erfolgen. Beispiele hierfür sind etwa intelligente, regelbare Ortsnetztransformatoren.

dezentral: Die Regelung erfolgt dezentral durch autonome Einheiten, welche untereinander kommunizieren. Dezentralisierte Systeme haben keinen zentralen Kontrollpunkt und die Entscheidungsfindung ist über das Netz verteilt.

Der Hauptunterschied zwischen diesen drei Konzepten besteht in der Ebene der Kontrolle, der Entscheidungsfindung und dem physischen Standort der Komponenten. Zentralisierte Systeme haben einen einzigen Koordinator, verteilte Systeme haben mehrere Koordinatoren- und Entscheidungspunkte und dezentralisierte Systeme haben keinen zentralen Koordinatoren und die Entscheidungsfindung ist über das Netz verteilt.

Diese beiden Dimensionen – Informationsaustausch und Entscheidungsfindung – bieten einen umfassenden Rahmen für das Verständnis der verschiedenen Aspekte der Dezentralisierung im Energiesystem. Bei Bedarf können weitere Abstufungen eingeführt oder der Ansatz kann um weitere Dimensionen erweitert werden. Eine weitere mögliche Dimension wäre etwa die Verknüpfung mit den politischen Rahmenbedingungen.

Einordnung ausgewählter Methoden des Energiemanagements

Anhand der zuvor eingeführten Einteilung können die Algorithmen in einer zweidimensionalen Matrix eingeordnet werden, welche in Abbildung 6.1 dargestellt ist. Eine Auswahl der Fälle soll hier beschrieben werden.

Vorgabe der Tarife erfolgt von einer Zentralen Stelle aus. Ein Beispiel für eine Umsetzung wird in Abschnitt 6.3.2 vorgestellt.

- f) **Verteilte Koordination mit Feedback:** Bei einem verteilten System sind die Entscheidungsfindung und die Kontrolle auf mehrere Standorte oder Einrichtungen verteilt. Eine verteilte Steuerung im Kontext eines VPP ist etwa ein Netz von kleinen Kraftwerken oder erneuerbaren Energiequellen, in dem mehreren Einheiten die Stromerzeugung unabhängig voneinander steuern. Diese sind jeweils einer lokalen Regelung unterworfen, verfolgen aber gleichzeitig globale Vorgaben und Anreiz wie Einspeiselimits oder Preisanreize. Dies kann etwa durch den Alternating Direction Method of Multipliers (ADMM) Algorithmus geschehen, welcher in Abschnitt 6.5 vorgestellt wird.
- i) **Dezentrale Konsensbildung:** In einem dezentralen System gibt es keine zentrale Instanz und die Entscheidungen werden von verteilten Einheiten getroffen, die jeweils über ein bestimmtes Maß an Autonomie verfügen. Die dezentrale Konsensbildung bezeichnet ein Paradigma, bei dem ein Netzwerk von autonom agierenden Knoten (Nodes) durch gemeinsame Protokolle einen Konsens über den aktuellen Zustand des Systems erreicht. Im Gegensatz zu traditionellen Systemen, die auf zentralen Instanzen basieren, erfolgt die Validierung und Bestätigung von Handlungen durch eine verteilte Gruppe von Teilnehmern. Dieser Prozess wird durch Konsensmechanismen wie Proof-of-Work (PoW), Proof-of-Stake (PoS) oder andere Algorithmen gesteuert. Durch die dezentrale Konsensbildung wird ein Vertrauensnetzwerk geschaffen, da die Integrität und Sicherheit der Blockchain durch die gemeinsame Validierung und Überprüfung der Teilnehmer gewährleistet wird.

6.2 Prognose von Last und Erzeugung

Moderne Algorithmen des Energiemanagements stützen sich häufig auf Prognosen des elektrischen Verbrauchs und der Erzeugung [103, 104]. Typischerweise haben diese Prognosen eine zeitliche Auflösung im Minutenbereich und erstrecken sich über einen Horizont von etwa 24 Stunden, bedingt durch die ausgeprägte tägliche Saisonalität. Die Lastvorhersage spielt eine zentrale Rolle bei der Planung und dem Betrieb von elektrischen Verteilnetzen. Daher wurden in der wissenschaftlichen Literatur bereits zahlreiche Methoden zur Lastvorhersage getestet und evaluiert. Viele dieser Methoden sind aus dem Bereich der Zeitreihenvorhersage bekannt [105, 106].

Die ARIMA (AutoRegressive Integrated Moving Average)-Modelle sind verbreitete Methoden zur Analyse und Prognose von Zeitreihen und eignen sich hervorragend für Anwendungen in der Lastprognose im Stromsektor [107, 108]. ARIMA-Modelle kombinieren autoregressive, integrierte und gleitende Durchschnittskomponenten, um eine robuste Modellierung von Strukturen in Zeitreihendaten zu ermöglichen. Sie profitieren von ihrer Fähigkeit, stationäre Daten oder solche, die durch Differenzierung stationär gemacht werden können, effektiv zu modellieren. Im Kontext der Lastprognose können ARIMA-Modelle verwendet werden, um saisonale Muster wie den täglichen oder wöchentlichen Lastverlauf sowie langfristige Trends wie das Wachstum der Stromnachfrage zu erfassen.

Mit dem Aufkommen von Machine Learning und Deep Learning Technologien haben künstliche neuronale Netze (KNN) zunehmend Anwendung in der Prognose gefunden [109]. KNN, insbesondere tiefe neuronale Netze, sind in der Lage, komplexe und nichtlineare Beziehungen in Daten zu erfassen, die von traditionellen statistischen Modellen oft nicht erfasst werden können. Sie sind besonders effektiv bei der Handhabung von hochdimensionalen Problemen und können eine Vielzahl von Informationen, einschließlich Wetterdaten, historischer Lastdaten und Informationen über spezielle Ereignisse, integrieren. Trotz ihrer rechenintensiven Natur können neuronale Netze präzise Kurz- und Langzeitprognosen liefern und sind daher in Szenarien nützlich, in denen die Genauigkeit von großer Bedeutung ist. Allerdings erfordert ihre Anwendung spezielle Kenntnisse und Erfahrung in der Datenpräparation, Modellierung und Validierung sowie hohe Rechenleistung. Im Vergleich mit Zeitreihenanalysen schneiden künstliche neuronale Netze aufgrund ihrer Fähigkeit, nicht lineare Funktionen sowie effizient Zusatzinformationen wie Wochenend- oder Feiertagsdaten zu verarbeiten, besser ab [110, 111]. Einen Überblick über Lastvorhersagetechniken wird in [112] gegeben. Unter anderem werden maschinelles Lernen, Deep Learning und weitere Ansätze aus dem Umfeld des Maschinellen-Lernens betrachtet. Schlussfolgernd wird vorgeschlagen, Hybridmodelle zu nutzen.

Dennoch ist zu beachten, dass die Modellierungsfähigkeiten der Prognosemodelle auf historischen Daten beruhen. Daher können sie anfällig für Veränderungen im zugrunde liegenden System sein. Bei signifikanten Veränderungen im Verbraucherverhalten, technologischen Innovationen oder regulatorischen Entscheidungen müssen die Modelle entsprechend angepasst oder neu kalibriert werden.

6.2.1 Probabilistische Vorhersagen

Probabilistische Prognosen sind ein entscheidendes Instrument, um die inhärente Unsicherheit von Lastprognosen zu bewältigen. Anstelle eines einzigen prognostizierten Punktwerts liefern probabilistische Prognosen eine Wahrscheinlichkeitsverteilung über mögliche zukünftige Lastwerte. Diese Verteilungen bieten eine quantifizierte Bewertung des Unsicherheitsbereichs und ermöglichen daher eine bessere Risikoeinschätzung, die bei Entscheidungsprozessen von entscheidender Bedeutung sein kann [113–115].

Die Anwendung probabilistischer Prognosemodelle auf die Lastprognose bietet zahlreiche Vorteile. Sie können dazu beitragen, das Risiko extremer Lastschwankungen zu managen, und unterstützen optimale Entscheidungen in Bezug auf die Steuerung von Energieerzeugungsanlagen, indem sie die Unsicherheit in der zukünftigen Last berücksichtigen. Insbesondere in einem volatilen Energiemarkt, in dem Nachfrage und Angebot schnell schwanken können, bieten probabilistische Prognosen wertvolle Informationen für eine effektive und effiziente Steuerung des Energieflusses.

Verschiedene Methoden können zur Erstellung probabilistischer Prognosen eingesetzt werden, darunter Bayesianische Mixture-Density Modelle [116], Quantilregression [117], Gradienten-Boosting-Regression [117], neuronale Netze [118] und Methoden basierend auf Monte-Carlo-Simulationen.

Neuronale Netze

Die Nutzung von KNNs und anderer Deep-Learning-Methoden ist in der aktuellen Forschung weit verbreitet, insbesondere zur Prognose komplexer Phänomene, da diese Methoden die Fähigkeit besitzen, komplexe Muster und Abhängigkeiten in den Daten zu erfassen. Es ist jedoch zu beachten, dass die Anwendung von KNN eine umfangreiche Menge an historischen Daten erfordert, aufgrund der hohen Anzahl an trainierbaren Parametern. Daher können bei kleineren Datensätzen andere maschinelle Lernmethoden oft besser abschneiden.

In der vorliegenden Arbeit werden für probabilistische Prognosen unter anderem auf Feedforward-KNNs zurückgegriffen, die im Rahmen des NemoGrid-Projekts umgesetzt wurden [21]. Diese bestehen aus zwei vollständig vernetzten Hidden-Layers, welche von einer Eingabe- und einer Ausgabeschicht flankiert werden. Die spezifische Ausgestaltung der Ausgabeschicht unterscheidet sich je nach Vorhersageaufgabe - deterministisch oder probabilistisch.

Bei der deterministischen Vorhersage generiert das KNN eine einzelne Lastprognose für jeden Prognoseschritt. Im Kontrast dazu verwendet das probabilistische KNN einen Klassifizierungsansatz, wie er in [119, 120] beschrieben wird. Für jeden Prognoseschritt prognostiziert das KNN die Wahrscheinlichkeit, dass die Last in eine von mehreren definierten Klassen fällt. Diese Klassen werden durch Aufteilung des Bereichs der möglichen Lastleistungen in N gleich große Bins bestimmt. Eine beispielhafte Vorhersage ist in Abbildung 6.2 dargestellt.

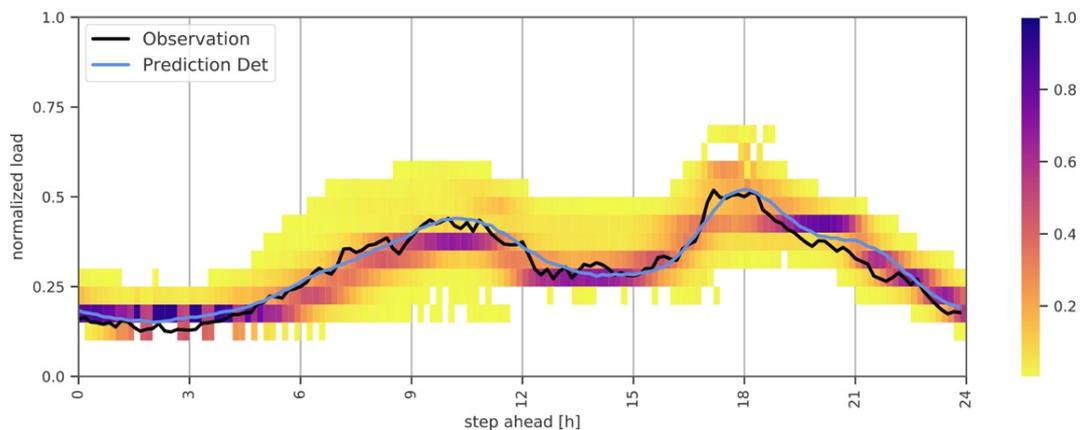


Abbildung 6.2 Beispiel einer kombinierten deterministischen und probabilistischen Vorhersage basierend auf dem Neuronalen-Netz aus dem NemoGrid Projekt [21]. Die Farben auf der rechten Seite zeigen die vorhergesagte Wahrscheinlichkeit der probabilistischen Prognose an.

6.3 Effizientes Energiemanagement auf lokaler Ebene

In diesem Abschnitt werden verschiedene Methoden und Strategien für ein effizientes Energiemanagement auf lokaler Ebene untersucht. Diese Methoden lassen sich in Abbildung 6.1 unter d) einordnen. Angesichts der zunehmenden dezentralen Energieerzeugung und der wachsenden Bedeutung erneuerbarer Energien gewinnt ein intelligentes Energiemanagement auch auf lokaler Ebene an Bedeutung. Vorrangiges Ziel ist es, die Energiekosten zu minimieren, die Netzbelastung zu reduzieren und erneuerbare Energien effizient zu integrieren.

Zwei Haupttypen von Energiemanagementmethoden werden vorgestellt: Regelbasierte und optimierungsbasierte Ansätze. Regelbasierte Verfahren nutzen einfache Heuristiken und Regeln, um zur Steuerung von Verbrauchern und Speichern [121]. Optimierungsbasierte Verfahren hingegen nutzen Modellierungs- und Optimierungstechniken, um optimale Ladepläne zu erstellen und den Eigenverbrauch unter Berücksichtigung verschiedener Restriktionen zu maximieren. [122, 123]. Ein wesentlicher Aspekt dieser Methoden ist die Integration von Wärmepumpen, wodurch eine Sektorkopplung ermöglicht wird.

Ein weiterer Fokus liegt auf der Anwendung von dynamischen Tarifen und Preisanreizen. Durch variable Stromtarife können Verbraucher motiviert werden, ihren Energieverbrauch in Zeiten niedriger Preise oder höherer Verfügbarkeit erneuerbarer Energien zu verlagern, was die Integration dieser Energien unterstützt.

Die Wirksamkeit dieser Methoden und Strategien wird anhand der Fallstudie eines Einfamilienhauses mit Photovoltaikanlage, Batteriespeicher und Wärmepumpe demonstriert. Die Analyse liefert wertvolle Einblicke in die Effizienz und Effektivität der verschiedenen Energiemanagementansätze.

Zusammenfassend ermöglicht ein intelligentes und optimiertes Energiemanagement auf lokaler Ebene den Verbrauchern, ihren Eigenverbrauch zu maximieren, die Abhängigkeit vom Stromnetz zu verringern und einen nachhaltigen Einsatz erneuerbarer Energien zu fördern. Dieses Kapitel bietet konkrete Einblicke und Handlungsempfehlungen für ein effizientes und nachhaltiges Energiemanagement auf lokaler Ebene.

6.3.1 Untersuchte Energiemanagementverfahren

Die in diesem Unterabschnitt vorgestellten Ladeschemata sind regelbasiert und die Ladesteuerung hat keine Wechselwirkung mit variablen Stromtarifen. In Abbildung 6.3 ist die Funktionsweise der ersten drei Batterieladealgorithmen dargestellt.

Der Betrieb einer Wärmepumpe kann unabhängig von der Batterie gesteuert werden, wenn ein regelbasiertes System aktiv ist. Im Normalbetrieb wird eine einfache Ein-/Aus-Regelung verwendet, bei der die Wärmepumpe abhängig vom Füllstand des Warmwasserspeichers ein- und ausgeschaltet wird. Um jedoch DSR zu nutzen, muss eine zusätzliche Betriebsstrategie eingeführt werden.

Bei dieser Strategie wird eine feste Preisgrenze von 0,20 €/kWh festgelegt, um den Betrieb der Wärmepumpe auszulösen. Wenn der Strompreis unter diese Grenze fällt und noch freie Kapazität im Warmwasserspeicher vorhanden ist, wird die Wärmepumpe für mindestens 20 Minuten eingeschaltet. Dadurch erhöht sich der Stromverbrauch bei niedrigen Strompreisen, während der Warmwasserspeicher als zeitlicher Puffer fungiert.

Direct Charging: Lädt die Batterie mit der gesamten überschüssigen PV-Erzeugung. Die Vorteile sind ein hoher Eigenverbrauch. Der Nachteil ist eine hohe Netzbelastung aufgrund der hohen Stromeinspeisung.

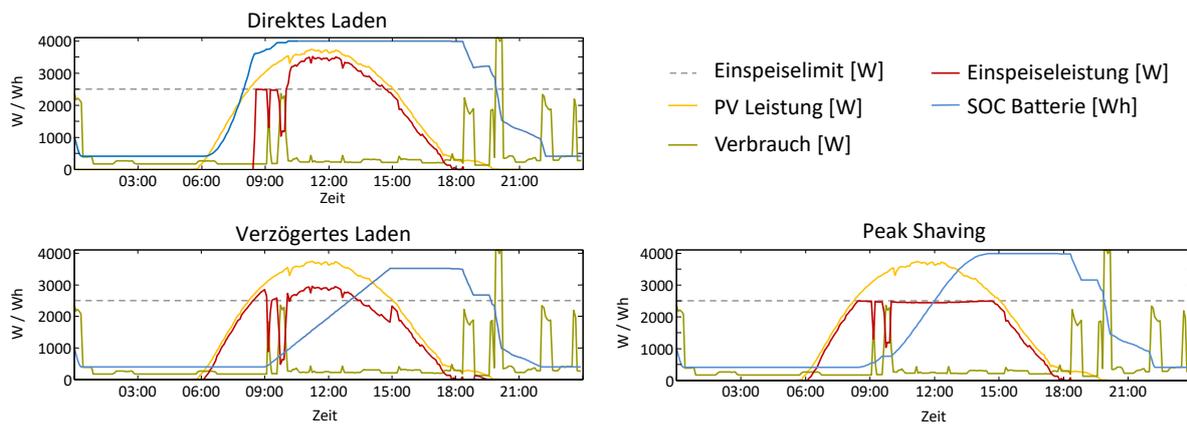


Abbildung 6.3 Regelbasierte Verfahren [124].

Delayed Charging: Basierend auf einem zeitabhängigen maximalen Batterieladezustand (SOC), der in den Sommermonaten (Mai bis September) von 09:00 Uhr bis 15:00 Uhr linear erhöht wird. Die Vorteile liegen in der Kombination aus hohem Eigenverbrauch und geringer Netzbelastung.

Peak Shaving: Die Batterie wird nur geladen, wenn Einspeisegrenze überschritten wird (\bar{P}_{grid}). Die Vorteile sind ein geringer Energieverlust oberhalb der Einspeisegrenze, da die gesamte Batteriekapazität für die Speicherung der gedeckelten Einspeisespitze zur Verfügung steht. Nachteilig sind der geringe Eigenverbrauch und das Risiko, die Batteriekapazität nicht vollständig zu nutzen, wenn die Einspeisegrenze (\bar{P}_{grid}) nicht korrekt eingestellt ist.

Adaptive Peak Shaving: Wie Peak Shaving, aber das Einspeiselimit wird prognosebasiert so angepasst, dass die Batteriekapazität vollständig ausgenutzt wird. Vorteilhaft ist der geringe Energieverlust oberhalb der Einspeiseobergrenze, da die gesamte Batteriekapazität zur Speicherung der gekappten Einspeisespitze zur Verfügung steht [125].

Darüber hinaus werden folgende auf Optimierungsmethoden basierende Strategien eingeführt:

MPC_{Batt}: Lädt die Batterie nach einem optimierten Ladeplan. Die Optimierungskriterien sind z.B. der Energiepreis oder die Menge der eingekürzten PV-Energie. Vorteilhaft ist das Nahezu-Optimum in Bezug auf die Kostenfunktion, die nach Bedarf definiert werden kann. Mit einer geeigneten Kostenfunktion kann ein hoher Eigenverbrauch bei gleichzeitig geringer Netzbelastung erreicht werden. Dagegen ist die Methode im Vergleich zu regelbasierten Ansätzen rechenintensiver und Vorhersagen für Last und PV-Erzeugung werden benötigt.

MPC_{Batt+HP}: Generiert einen optimierten Fahrplan für die Batterieladung sowie die Wärmepumpe. System- und Einspeisebeschränkungen werden dabei explizit berücksichtigt. Bietet die gleichen Vorteile wie das MPC Batt-Schema, optimiert aber gleichzeitig die Batterie und die Wärmepumpe.

6.3.2 Dynamische Tarife und Preisanreize

Dynamische Tarife sind flexible Preisgestaltungen im Energiesektor, bei denen die Kosten für Strom oder Energie je nach Angebot und Nachfrage in Echtzeit oder zu bestimmten Zeitpunkten variieren

[126–128]. Sie können Anreize zur Verlagerung des Stromverbrauchs auf Zeiten mit niedrigeren Preisen oder höherer Verfügbarkeit erneuerbarer Energien bieten. Durch eine angemessene Anpassung der Tarife können die Verbraucher dazu angeregt werden, ihren Stromverbrauch in umweltfreundlichere und kostengünstigere Zeiten zu verlagern, was zu einer effizienteren Energienutzung, einer Verringerung der Spitzenlasten und einer besseren Integration erneuerbarer Energien führt.

Die Kombination von Wind- und Solarenergie und ihre mögliche Komplementarität in der Energiebereitstellung sind für die zukünftige Energieversorgung von großem Interesse. Ein wichtiger Faktor für die effiziente Nutzung beider Energiequellen ist die zeitliche Abstimmung zwischen erneuerbarer Energieerzeugung und Nachfrage. Die Gleichzeitigkeit von erneuerbarer Erzeugung und lokaler Nachfrage kann durch den Einsatz von DSR erhöht werden. Um einen Anreiz zu schaffen, der eine verstärkte Nutzung der Windenergie provoziert, wird ein variabler Windtarif eingeführt. Um die Menge der von den Windparks erzeugten Energie zu bestimmen, wurde die folgende Annahme getroffen. Zu jedem Zeitpunkt entspricht die Menge der normalisierten Windstromerzeugung ihrem Anteil am Strommix. D. h. wenn die Winderzeugung am höchsten ist, wird angenommen, dass der gesamte Strom aus Windkraft stammt.

Der variable Tarif wiederum wird ebenfalls als Funktion der normierten Windenergieerzeugung angenommen, wie in Abbildung 6.4 dargestellt, mit 0,15 €/kWh für die maximale Windenergieerzeugung und 0,30 €/kWh ohne Windanteil im Strommix. Die Zeitkurve der Winderzeugung wurde aus der Summe der normierten Leistungsdaten eines Offshore-Windparks in der Ostsee und eines Onshore-Windparks an der Nordsee abgeleitet. Für den Vergleich der Energiekosten mit und ohne Anreiz wurde der Standardtarif als Jahresdurchschnitt des variablen Tarifs angenommen. Dies führt für die gegebene Zeitreihe der Windenergieproduktion zu einem Strompreis von rund 0,26 €/kWh. Die Einspeisevergütung unterhalb der Einspeisegrenze wurde mit 0,13 €/kWh angesetzt.

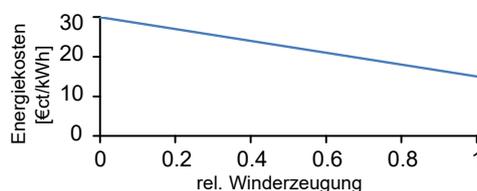


Abbildung 6.4 Beispiel eines zeitvariablen Stromtarifs: der Strompreis ist abhängig von der relativen Winderzeugung im Netz [124].

6.3.3 Vergleich der lokalen Energiemanagementalgorithmen

In diesem Abschnitt werden die zuvor erwähnten Algorithmen an einem Beispielfall auf ihre Effektivität hin untersucht. Hierfür wird ein simuliertes Einfamilienhaus verwendet, ausgestattet mit einer 8 Kilowattpeak (kW_p) Photovoltaikanlage, einem 8 Kilowattstunden (kWh) Batteriespeicher und einer Wärmepumpe mit 1400-Liter-Warmwasserspeicher. Die Simulation stützt sich auf Zeitreihen von PV-Erzeugung und Außentemperatur sowie lokale Stromnachfrage zur Versorgung von Haushaltsgeräten.

Die Stromproduktion der PV-Anlage basiert auf Daten eines Feldtestgeländes in Süddeutschland, normiert auf 1000 kWh pro kW_p . Der jährliche Energiebedarf des Hauses für Heizung liegt bei 5750 kWh/a, für Warmwasser bei 1750 kWh/a.

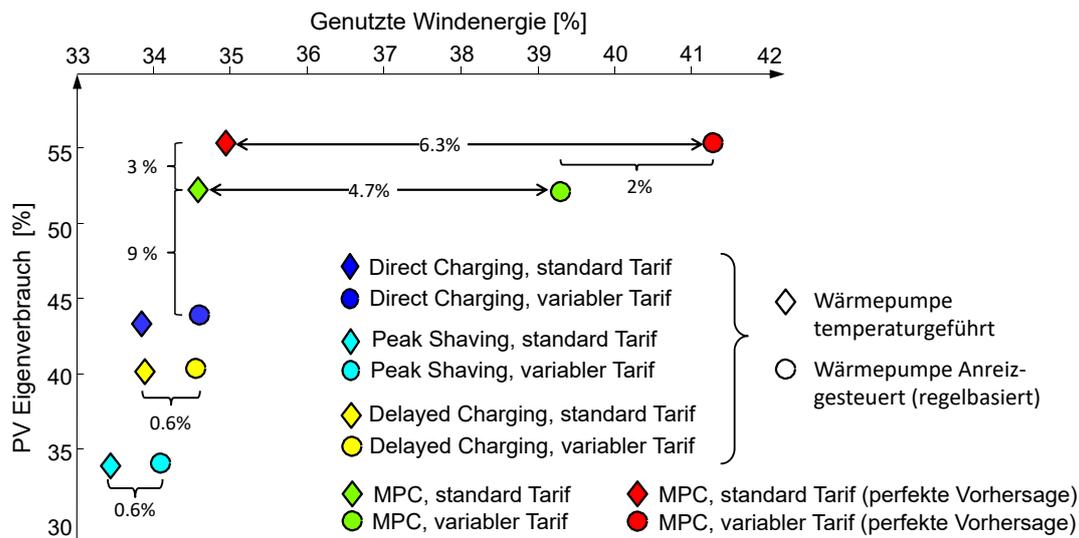


Abbildung 6.5 PV-Eigenverbrauchslevel versus Windenergienutzung der verschiedenen Strategien bei einer Einspeisegrenze von 30% PVpeak [124].

Die Ergebnisse sind in Abbildung 6.5 dargestellt und zeigen unterschiedliche Werte für den Eigenverbrauch und die Nutzung von Windenergie abhängig von der Betriebsstrategie.

Der Peak-Shaving-Algorithmus führt zu den geringsten Werten für Eigenverbrauch und Windenergienutzung, da die Batterie nur geladen wird, wenn die Einspeisegrenze ins Netz überschritten wird. Durch die Verwendung des variablen Tarifs zur Steuerung der Wärmepumpe könnte die Nutzung der Windenergie um etwa 0,6% erhöht werden.

Bei Verwendung des verzögerten Ladealgorithmus steigt der Eigenverbrauch im Vergleich zur Spitzenlastreduzierung um etwa 6%. Die Windenergienutzung erhöht sich bei verzögertem Laden und Verwendung des variablen Tarifs ebenfalls um etwa 0,6%.

Der direkte Ladealgorithmus führt zu dem höchsten Eigenverbrauch (etwa 43%) unter den betrachteten Algorithmen. Der Verbrauch von Windenergie ist dabei vergleichbar mit dem der verzögerten Ladung, mit leichten Verbesserungen, wenn der variable Tarif verwendet wird.

Mit der Anwendung des modellprädiktiven Regelungsalgorithmus kann der Eigenverbrauch durch optimierten Betrieb der Wärmepumpe und Nutzung des Batteriespeichers weiter auf etwa 52% erhöht werden. Die Nutzung von Windenergie erreicht ca. 34% und steigt mit dem variablen, windabhängigen Tarif um etwa 7 Prozentpunkte auf 41% an, ohne negative Auswirkungen auf den Eigenverbrauch. Bei der Verwendung von hypothetisch fehlerfreien Vorhersagen für Last und Erzeugung lässt sich die Nutzung von PV und Wind um etwa 2% weiter steigern (siehe Abbildung 6.5).

6.4 Betrieb unter Vorhersage-Unsicherheiten

Um den reibungslosen und nahezu optimalen Betrieb von Speichern und steuerbarer Erzeugung in einem Netz mit einem hohen Anteil an erneuerbaren Energien zu gewährleisten, ist es wichtig, über genaue Prognosen für Last und Erzeugung zu verfügen. Aber selbst mit den heute verfügbaren Prognosen kann der Vorhersagefehler einen erheblichen Einfluss auf die Betriebsleistung des Systems haben.

In diesem Abschnitt werden die Auswirkungen des Vorhersagefehlers auf den optimierten Betrieb im Fall eines kleinen virtuellen Kraftwerks verglichen und analysiert [53].

6.4.1 Unsicherheitsbetrachtung in der Optimierung durch Szenarien

Die stochastische Optimierung ist eine mathematische Methode, die darauf abzielt, optimale Lösungen für Probleme mit inhärenter Unsicherheit zu finden. Diese Technik ist von besonderer Bedeutung bei der Behandlung von Szenarien mit unvorhersehbaren Variablen, wie sie in verschiedenen realen Anwendungen vorkommen. Die zugrundeliegende Methodik der stochastischen Optimierung umfasst die Generierung einer großen Anzahl potenzieller Lösungsszenarien, die dann in ein Optimierungsproblem einfließen, um die wahrscheinlichste optimale Lösung zu ermitteln [129–132].

Stochastische Modelle verwenden Szenarien und deren Wahrscheinlichkeiten als Repräsentationen eines multivariaten Zufallsdatenprozesses. Diese Modelle berücksichtigen eine Vielzahl von Variablen, die in der Realität oft nicht vorhersehbar sind, wie z. B. die elektrische Last, die Wasserführung in Wasserkraftwerken und Schwankungen der Brennstoff- und Strompreise. Diese umfassende Modellierung ermöglicht es, die Komplexität realer Systeme in die Analyse einzubeziehen und zuverlässige, robuste Lösungen zu entwickeln, die die Unsicherheiten und Variabilität der realen Welt berücksichtigen.

Wetterbedingungen und andere Faktoren beeinflussen die Lastprofile von Haushalten und damit auch die Korrelation zwischen diesen Profilen. Wenn beispielsweise zwei Haushalte in der gleichen klimatischen Region liegen, könnten ihre Lastprofile stärker korreliert sein, weil sie ähnliche Wettermuster erleben. Gleichzeitig spiegelt sich das auch in der Korrelation zwischen den Prognosen wider. Unvorhergesehene Wetterereignisse können die Lastprognosen für Haushalte in der gleichen Region ähnlich beeinflussen, wodurch diese eine höhere Korrelation aufweisen. Wenn die Wettervorhersagen jedoch sehr genau sind, hängen die Prognosefehler eher von anderen Faktoren ab und können zu einer geringeren Korrelation zwischen den Prognosen führen. Diese Effekte müssen bei der Betrachtung von Unsicherheiten mitberücksichtigt werden.

Im Kontext von Energieversorgungssystemen hat sich die stochastische Programmierung auf Szenariobasis als effektiv erwiesen, um verschiedene Betriebs- und Planungsprobleme zu adressieren [133–136]. Die Anwendung dieser Technik hat gezeigt, dass die Berücksichtigung von Unsicherheiten im Entscheidungsprozess zu einem zuverlässigeren Betrieb von Energiesystemen führt.

Nachfolgend wird der Prozess der Szenarienerstellung für die Berücksichtigung von Unsicherheiten in Optimierungsproblemen beschrieben und erläutert. Die Ergebnisse der einzelnen Schritte werden in Abbildung 6.6 visualisiert.

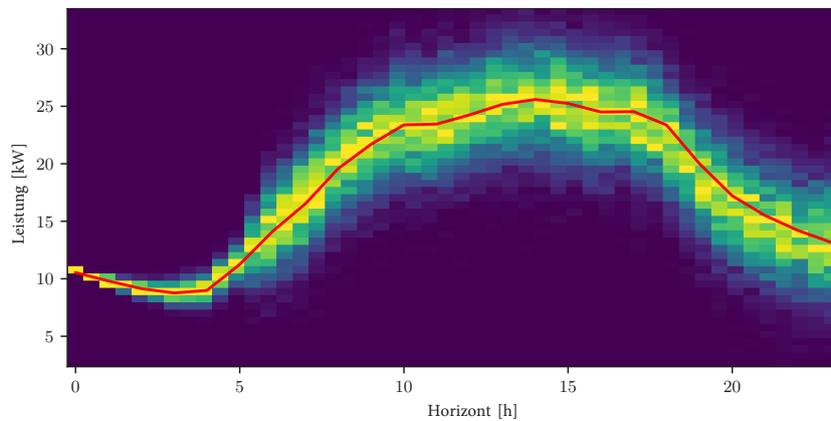
Erstellen von Szenarien: Die Erstellung von Szenarien ist der erste Schritt der stochastischen Optimierung. Dabei wird eine Reihe potenzieller Lösungen erstellt, die alle möglichen Ergebnisse der ungewissen Situation abdecken. Beispielsweise könnten in einem Anlageportfolio verschiedene Schätzungen für Aktienkurse und Zinssätze berücksichtigt werden.

Die hier verwendete Methode [137] berücksichtigt sowohl die Korrelation der Prognosefehler als auch die Verteilungen der Prognosen. Diese Herangehensweise stützt sich auf die Transformation von Prognosefehlern in eine multivariate Gauß-Verteilung, wobei die wechselseitige Abhängigkeit durch eine spezifische Kovarianzmatrix repräsentiert wird. In einem rekursiven Prozess wird diese Matrix kontinuierlich aktualisiert, um nachhaltigen Schwankungen in den Charakteristiken der Prognosefehler angemessen Rechnung zu tragen. Ein Beispiel für Szenarien ist in Abbildung 6.6b dargestellt.

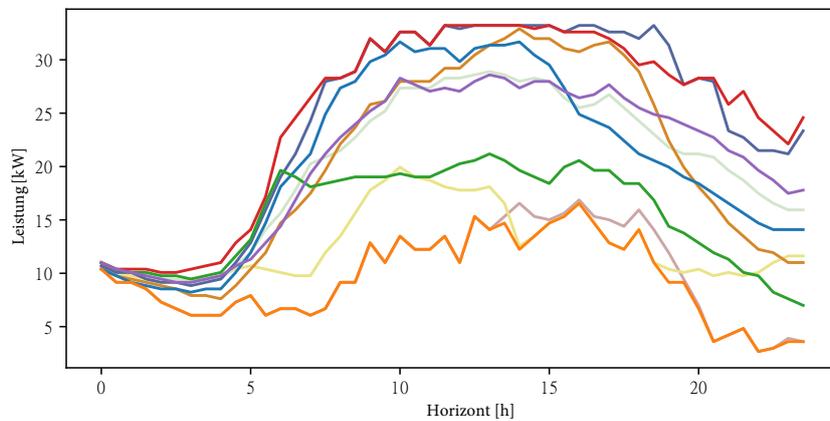
Reduktion der Szenarien: Oftmals stellt die Berücksichtigung aller möglichen Szenarien in der Optimierungsaufgabe eine rechnerische Herausforderung dar und führt zu umfangreichen Modellen. Daher werden in der Praxis oft reduzierte Modelle verwendet, die eine kleinere Anzahl von Szenarien berücksichtigen. Dabei wird die Menge der generierten Szenarien auf eine überschaubare Größe reduziert, wobei eine ausreichende Vielfalt erhalten bleibt, sodass eine optimale Lösung gefunden werden kann. Es gibt viele verschiedene Möglichkeiten, Szenarien zu reduzieren, aber zu den gängigen Methoden gehören das Clustering und die Auswahl repräsentativer Punkte aus jedem Cluster.

In diesem Kontext bieten der in dieser Arbeit verwendete Reduktionsalgorithmus [138] eine Möglichkeit zur Ermittlung einer Teilmenge des ursprünglichen Szenariosatzes und zur Neuzuweisung von Wahrscheinlichkeiten zu den beibehaltenen Szenarien. Darüber hinaus können Algorithmen zur Erstellung von Szenarienbäumen genutzt werden, um die Anzahl der Knoten einer Menge von individuellen Szenarien durch Anpassung der Baumstruktur und Bündelung ähnlicher Szenarien zu reduzieren. Ein Beispiel für die Szenarienreduktion ist in Abbildung 6.6c dargestellt.

(a) Probabilistische Vorhersage. In rot ist der Mittelwert dargestellt, der Farbverlauf repräsentiert die Häufigkeitsverteilung.



(b) Gesampelte Szenarien anhand der probabilistischen Vorhersage in Abbildung 6.6a.



(c) Selektierte Trajektorien nach der Reduktion der Szenarien aus Abbildung 6.6b

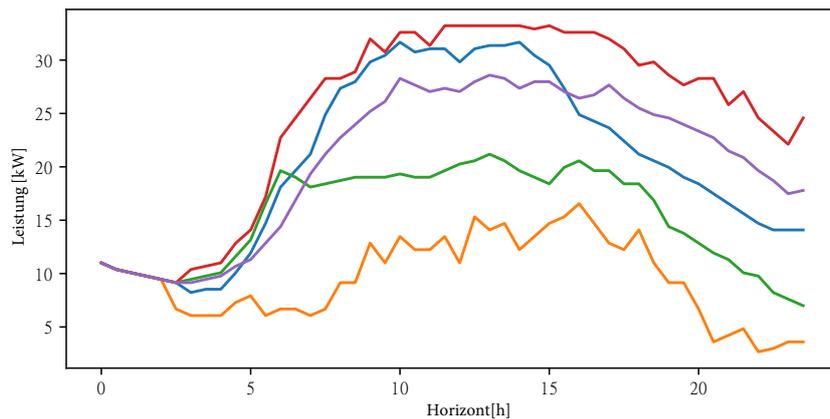


Abbildung 6.6 Beispielhafte Darstellung der Szenarienerstellung: In der ersten Abbildung (a) ist eine beispielhafte probabilistische Vorhersage dargestellt. In Abbildung (b) sind die erzeugten Szenarien dargestellt. Diese werden schließlich reduziert (c), sodass durch weniger Szenarien die Unsicherheiten abgebildet werden können.

6.4.2 Simulationsszenario und mathematische Problemformulierung

Das betreffende virtuelle Kraftwerk (VPP) setzt sich aus Leistungsknoten zusammen, welche die verteilten Energiequellen (DER), den lokalen Energiebedarf sowie das externe Stromnetz repräsentieren. Die verteilten Energiequellen beinhalten Kraft-Wärme-Kopplungsanlagen (CHP) und erneuerbare Energieerzeuger wie Photovoltaik (PV) und Windkraftanlagen (siehe Abbildung 6.7). Hierbei wird angenommen, dass die Kontrollinstanz (EMS) mit allen gesteuerten und gemessenen Einheiten direkt verbunden ist. Der Algorithmus kann in Abschnitt 6.1.1 somit unter a) eingeordnet werden.

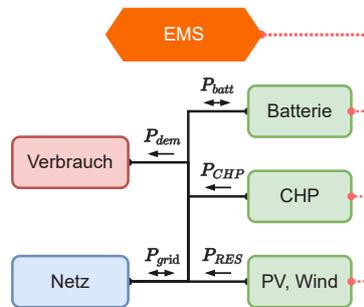


Abbildung 6.7 Skizze des virtuellen Kraftwerks (VPP) mit den entsprechenden Einheiten und den Leistungsflüssen [53]. EMS stellt hierbei das Energiemanagementsystem dar und CHP das Blockheizkraftwerk.

Zusätzlich wird eine Batterie als Kurzzeit-Energiespeicher eingesetzt, um Ungleichgewichte zwischen Energieerzeugung und -nachfrage auszugleichen. Es wird angenommen, dass sowohl die Batterieleistung (P_{batt}) als auch die elektrische Leistungserzeugung durch das CHP-System (P_{CHP}) durch einen Energiemanagement-Algorithmus reguliert werden können. Weiterhin wird davon ausgegangen, dass das CHP-System während seines Betriebs eine Mindestleistung aufweist und unterschiedliche zeitliche Anforderungen für Anlaufzeit und Abschaltzeiten hat [139–141]. Zudem ist es möglich, die Energieerzeugung aus erneuerbaren Quellen zu reduzieren (P_{res}).

Um die saisonale Varianz von Last und Energieerzeugung zu berücksichtigen, ohne die Komplexität der Simulation zu steigern, werden drei exemplarische Tage simuliert: ein Sommertag, ein Übertag zwischen Sommer und Herbst sowie ein Wintertag. Die vollständige Liste der Randbedingungen für dieses Szenario ist in Tabelle 6.1 dargestellt.

Tabelle 6.1: Simulationsszenario und Randbedingungen [53].

Parameter	Beschreibung	Wert
CHP startup time	Startzeit des BHKW	15 min.
CHP min. uptime	Minimale Betriebszeit des BHKW	20 min.
CHP min. downtime	Minimale Stillstandszeit des BHKW	15 min
\bar{P}_{CHP}	Maximale Leistung des BHKW	20 kW
$\underline{P}_{\text{CHP, on}}$	Minimale Leistung des BHKW im Betrieb	6 kW
\bar{P}_{RES}	Maximale Leistung aus erneuerbaren Quellen	30 kW
\bar{P}_{demand}	Maximale Nachfrageleistung	50 kW
\bar{P}_{grid}	Maximale Leistung am Netzanschlusspunkt	10 kW
C_{batt}	Batteriekapazität	20 kW h
\bar{P}_{batt}	Maximale Batterieleistung	20 kW
t_{control}	Kontrollintervalle	[0, 5, 10, 15, 30, 60, 90, 120, ..., 600] min.
Δt_{opt}	Optimierungsintervall	5 min.

Um die Auswirkungen unterschiedlicher Unsicherheiten auf die Effektivität des Energiemanagements zu untersuchen, ist es notwendig, synthetische Vorhersagen für verschiedene Vorhersagefehler (ϵ_{pred}) zu generieren. Der Prozess, wie dies geschieht, ist in Abbildung 6.8 veranschaulicht.

Als Ausgangspunkt dienen Prognosezeitreihen sowie die tatsächlich gemessene Erzeugung aus Wind- und PV-Anlagen (Prognosedatenbank). Basierend auf diesen Daten wird ein Fehlermodell entwickelt, das die Prognosefehler über den gesamten Vorhersagehorizont hinweg modelliert [53].

Dieses Modell wird verwendet, um mithilfe des in Abschnitt 6.4.1 beschriebenen Verfahrens synthetische Vorhersagen mit unterschiedlichen relativen Fehlern (ϵ_{pred}) zu erstellen. Als Referenz werden die tatsächlichen Vorhersagen herangezogen und ausgewertet.

In diesem Prozess dient das Fehlermodell als eine Art „Störfaktor“, der systematisch auf die ursprünglichen Messdaten angewendet wird, um verschiedene Szenarien mit eingebauten Ungenauigkeiten zu erzeugen. Dadurch können wir die Robustheit und Leistungsfähigkeit des Energiemanagements unter verschiedenen Unsicherheitsbedingungen analysieren und bewerten.

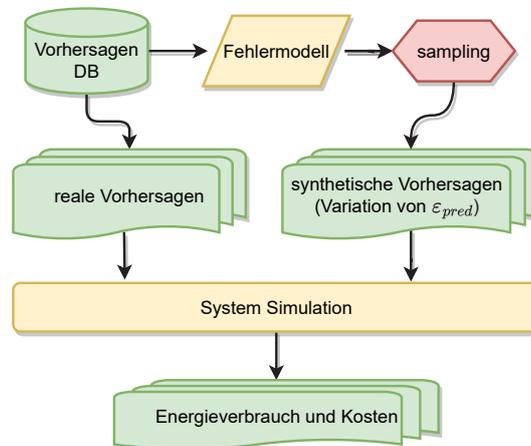


Abbildung 6.8 Darstellung der Szenarien zur Bewertung verschiedener Vorhersageunsicherheiten ϵ_{pred} [53].

Problemformulierung

Die Kostenfunktion des Problems kann wie folgt ausgedrückt werden:

$$\min_{P_g} \sum_{g \in G} P_g \kappa_g$$

unter den Nebenbedingungen:

$$\begin{aligned} \sum_{g \in G} P_g &= 0 \\ \dot{x}_{\text{batt}} &= \frac{\eta}{C_{\text{batt}}} P_{\text{batt} > 0} + \frac{1}{\eta C_{\text{batt}}} P_{\text{batt} < 0} \\ 0 &\leq x \leq 1 \\ \underline{P}_{\text{batt}} &\leq P_{\text{batt}} \leq \overline{P}_{\text{batt}} \\ 0 &\leq P_{\text{RES}} \leq \overline{P}_{\text{RES}} \\ \underline{P}_{\text{CHP}} &\leq P_{\text{CHP}} \leq \overline{P}_{\text{CHP}} \quad \text{wenn } P_{\text{CHP}} > 0 \\ \underline{P}_{\text{grid}} &\leq P_{\text{grid}} \leq \overline{P}_{\text{grid}} \end{aligned} \tag{6.1}$$

Dabei bezeichnet P_g das Stromangebot bzw. die Stromnachfrage durch den Erzeuger/Verbraucher g im Netz, während der κ_g den Preis pro kWh gelieferten/verbrauchten Stroms [€/kWh] betrifft. Die Variable P_{grid} entspricht der vom externen Netz gelieferten Leistung und P_{batt} beschreibt die von der Batterie erzeugte Leistung, begrenzt durch die minimale Leistung $\underline{P}_{\text{batt}}$ und die maximale Leistung $\overline{P}_{\text{batt}}$. Die Nachfrage der Verbraucher wird mit P_{dem} und die entsprechende Grenze mit $\overline{P}_{\text{dem}}$ bezeichnet.

Darüber hinaus ist das Stromangebot P_{RES} der erneuerbaren Energien mit einer maximalen Einspeiseleistung von $\overline{P}_{\text{RES}}$ beaufschlagt. Das Blockheizkraftwerk wird durch P_{CHP} mit einer maximalen Ausgangsleistung $\overline{P}_{\text{CHP}}$ im zugehörigen Netz dargestellt. Der Ladezustand (SOC) der Batterie wird mit x bezeichnet und auf $0 \leq x \leq 1$ mit der Speicherkapazität C_{batt} normiert. Die Optimierung wird über den diskreten Zeithorizont T durchgeführt.

6.4.3 Kostenannahmen

Für den Optimierungsprozess ist es notwendig, die Kosten für jede dezentrale Energiequelle (DER) sowie die Kosten für Strom und Batterien zu definieren. Diese Kosten sind in der Tabelle 6.2 zusammengefasst. Für die Batterie wird angenommen, dass nur die Anschaffungs- und Betriebskosten zu den Optimierungskosten beitragen (Steuern werden vernachlässigt) [142]. Die Stromgestehungskosten des BHKW werden auf 0,10 €/kWh geschätzt [143].

Der Strompreis wird mit 0,30 €/kWh und die Einspeisevergütung mit 0,03 €/kWh angenommen. Zusätzlich werden die Kosten für die Begrenzung der regenerativen Stromerzeugung entsprechend den gestaffelten Stromgestehungskosten [144] angesetzt.

Tabelle 6.2: Für das Optimierungsmodell verwendete Kosten [53].

Parameter	Beschreibung	Kosten
κ_{batt}	Kosten für Batteriespeicherung	0,15 €/kWh
$\kappa_{\text{CHP, gen}}$	Kosten für BHKW-Stromerzeugung	0,10 €/kWh
$\kappa_{\text{CHP, start}}$	Kosten für BHKW-Start	0,30 € pro Start
$\kappa_{\text{grid, draw}}$	Kosten für Netzbezug	0,30 €/kWh
$\kappa_{\text{grid, feedin}}$	Einspeisevergütung für das Netz	0,03 €/kWh
$\kappa_{\text{RES, curtailment}}$	Kosten für die Drosselung erneuerbarer Energien	0,10 €/kWh

6.4.4 Einfluss des Vorhersagefehlers auf die Betriebskosten

Um den Einfluss des Vorhersagefehlers auf die Planung von Anwendungen zu zeigen, wird eine Simulation auf der Grundlage der zuvor genannten Szenarien durchgeführt. Alle Ergebnisse sind auf den Basisfall normiert: perfekte Vorhersagen ($\epsilon_{\text{pred}} = 0.0$) und keine Batterie.

In Abbildung 6.9 sind die Gesamtkosten in Abhängigkeit von der Vorhersagegenauigkeit für ein Szenario mit und ohne Batterie dargestellt. Auf der x-Achse sind die Vorhersagefehlerszenarien aufgelistet und auf der y-Achse sind die Kosten relativ zu einem Szenario ohne Vorhersagefehler und ohne Batterie dargestellt. Das erste Fehlerszenario (*real*) zeigt die Kosten, die auf realen, mit neuronalen Netzen erzeugten Vorhersagen basieren. Der zweite Punkt (*real (wc)*) beschreibt ein Worst-Case-Szenario auf der Grundlage realer Vorhersagen (robuste Optimierung). Dies ist das konservativste Szenario, das einen sicheren Betrieb der Anlage bei Vorhersagefehlern gewährleisten soll. Die folgenden Spalten beschreiben synthetische Vorhersageszenarien mit einem relativen RMSE ϵ_{pred} von 0.0, 0.1 und 0.2 bezogen auf den Maximalwert des Profils.

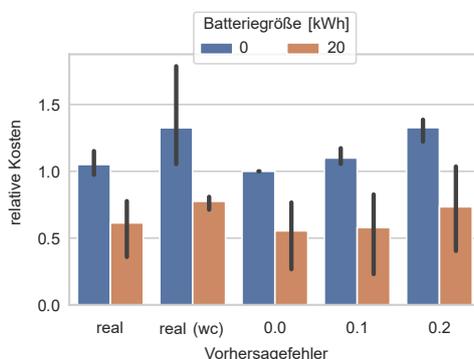


Abbildung 6.9 Vergleich der relativen Kosten der verschiedenen Fehlerszenarien mit und ohne Batterie. Die Fehlerbalken zeigen das 95 %ige Vertrauensintervall der zugrunde liegenden Daten. Die Fehlerszenarien sind: **real** – reale Vorhersage; **real (wc)** – Worst-Case-Szenario (robuste Optimierung); **0.0, 0.1, 0.2** – relativer RMSE ϵ_{pred} bezogen auf den Maximalwert der Profile [53].

Abbildung 6.9 zeigt, dass die Kosten mit abnehmender Prognosegenauigkeit steigen. Ein Grund dafür ist das verzögerte Anfahrverhalten des BHKW: Die Steuerung muss die benötigte Leistung 15 Minuten vor dem Abrufzeitpunkt anfordern, damit genügend Zeit zum Anfahren des BHKW bleibt. Dies wird auch in Abbildung 6.10 deutlich, in der die Kosten pro Gerät für ein Szenario ohne Batterie dargestellt sind. Mit zunehmendem Prognosefehler sinkt der BHKW-Einsatz. Gleichzeitig steigt die Menge an Energie, die aus dem Netz bezogen wird, um die fehlende Energie aus der CHP zu kompensieren. Die Menge der reduzierten erneuerbaren Erzeugung (EE-Abfall) ist in allen Szenarien etwa gleich.

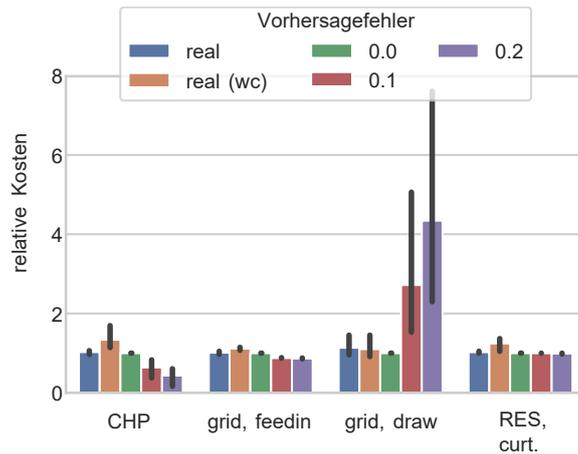


Abbildung 6.10 Vergleich der relativen Kosten pro Einheit für den Fall ohne Batterie [53]. In der Abbildung stehen die Abkürzungen **CHP** für Blockheizkraftwerk, **grid, feedin** für die Einspeisung ins Netz, **grid, draw** für den Netzbezug, und **RES curt.** für die Drosselung erneuerbarer Energien.

Das gleiche Diagramm ist in Abbildung 6.11a für ein Szenario mit einer 20-kWh-Batterie dargestellt. Im Vergleich zum Szenario ohne Batterie muss nur sehr wenig EE-Energie reduziert werden, da der Überschuss in der Batterie gespeichert werden kann.

Der Batterieverbrauch selbst sinkt mit zunehmenden Prognosefehlern. Da ein erhöhter Batterieeinsatz auch die Betriebskosten erhöht, wird er nur dann eingesetzt, wenn er für die Gesamtkosten über den Optimierungshorizont als vorteilhaft prognostiziert wird. Überschätzt die Prognose die lokale Erzeugung und unterschätzt sie die lokale Nachfrage, wird der Batterieeinsatz reduziert.

In jedem Fall senkt der Einsatz einer Batterie die Gesamtkosten, da der Batteriepreis pro kWh in diesem Szenario günstiger ist als der Strombezug aus dem Netz. Außerdem kann die Batterie bis zu einem gewissen Grad die Auswirkungen von Prognosefehlern kompensieren: Die Kosten für $\epsilon_{\text{pred}} = 0.1$ sind fast die gleichen wie für den Fall mit $\epsilon_{\text{pred}} = 0.0$ und der notwendige Strombezug aus dem Netz kann reduziert werden.

Die realen Vorhersagen sind um etwa 5 % schlechter als die perfekten Vorhersagen ($\epsilon_{\text{pred}} = 0.0$). Das Worst-Case-Szenario verursacht die höchsten Kosten, bietet aber auch die höchste Betriebssicherheit.

Robuste Optimierung Bei der robusten Optimierung wird die Worst-Case-Schätzung des Prognosefehlers für die Optimierung verwendet. Dadurch wird ein ausfallsicherer Betrieb trotz Prognosefehler gewährleistet [145, 146]. Abbildung 6.11a zeigt die Kosten pro Gerät im Vergleich zum Fall mit perfekter Vorhersage. Die Worst-Case-Prognose zeigt die höchste CHP-Nutzung und den geringsten Netzbezug. Dies ist auf die Worst-Case-Optimierung zurückzuführen: Da das BHKW eine Anfahrzeit von 15 Minuten hat, wird es vorsichtshalber eingeschaltet, wenn die prognostizierte Last eine Deckungslücke aufweist, die die Netzgrenzen überschreiten könnte. Dies führt auch zu einer stärkeren Nutzung der Batterie (siehe Abbildung 6.11b), da die gesamte überschüssige Energie in der Batterie gespeichert wird, bevor sie ins Netz eingespeist wird. Außerdem ist die aus dem Netz bezogene Energiemenge geringer als bei allen anderen Strategien, was die Robustheit des Ansatzes zeigt. Ein weiterer Nachteil ist die erhöhte Menge an abgeregelter erneuerbarer Energie.

6.4.5 Vergleich

Die hier vorgestellten Ergebnisse zeigen, wie wichtig genaue Vorhersagen für den Betrieb von Energiesystemen sind. Für das vorgestellte Szenario ohne Batterie führt ein relativer Vorhersagefehler von 10 % zu einer Erhöhung der Betriebskosten um 8 % und ein Vorhersagefehler von 20 % zu einer Erhöhung um ca. 25 %. Wird dem System eine Batterie hinzugefügt, führt ein relativer Vorhersagefehler von 10 % zu einer Erhöhung der Betriebskosten um etwa 2 % und ein Fehler von 20 % zu einer Erhöhung um etwa 30 %.

Eine genaue kurzfristige Leistungsvorhersage ist insbesondere dann erforderlich, wenn Geräte mit einer Anlaufverzögerung in das System integriert werden. Die Auswirkungen des Vorhersagefehlers können durch die Verwendung einer Batterie verringert werden. Wenn eine hohe Ausfallsicherheit erforderlich ist (z.B. bei kritischen Anlagen, die in einer Umgebung mit strengen Netzrestriktionen betrieben werden), kann eine robuste Optimierung durchgeführt werden. Dies erhöht die Betriebssicherheit, aber auch die Kosten.

Auch für den Speicherbetrieb ist eine hohe Prognosegüte wichtig, um die Batterie effizient zu nutzen.

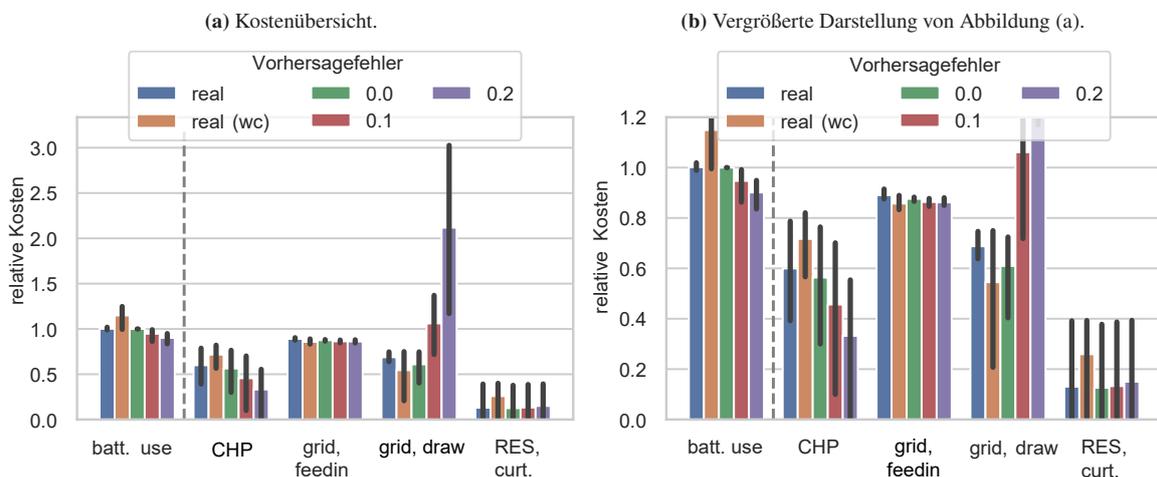


Abbildung 6.11 Vergleich der relativen Kosten pro Einheit für den Fall mit einer Batterie. Alle Kosten sind relativ zum Referenzfall, mit Ausnahme der Batteriekosten: Sie sind auf das Szenario mit perfekter Vorhersage und einer Batterie normiert [53]. In der Abbildung stehen die Abkürzungen **CHP** für Blockheizkraftwerk, **grid, feedin** für die Einspeisung ins Netz, **grid, draw** für den Netzbezug, **RES curt.** für die Drosselung erneuerbarer Energien und **batt. use** für die Batterienutzung.

6.5 Ansatz eines verteilten Energiemanagements

In diesem Abschnitt wird ein Ansatz für das verteilte Energiemanagement vorgestellt. Dieser basiert auf dem ADMM Algorithmus und kann in Abschnitt 6.1.1 unter der Kategorie *f) Verteilte Koordination mit Feedback* eingeordnet werden.

Hierzu wird das Konzept der (Energy Community, EC) betrachtet. Eine EC, auch als Eigenverbrauchsgemeinschaft bezeichnet, ist ein Zusammenschluss von Einzelpersonen, Unternehmen oder anderen

Organisationen, die sich darauf konzentrieren, selbst erzeugte Energie, in der Regel aus erneuerbaren Quellen, zu nutzen. Diese Gruppen, die oft in geografischer Nähe zueinander liegen, erzeugen, speichern, verbrauchen und handeln gemeinsam Energie.

Das Hauptziel einer SCC besteht darin, die Selbstversorgung mit Energie zu maximieren und die Abhängigkeit von externen Energieversorgern zu minimieren. Mitglieder einer SCC können etwa Photovoltaikmodule auf ihren Gebäuden installieren und den erzeugten Strom für den eigenen Bedarf verwenden. Überschüssiger Strom kann in Energiespeichern gespeichert oder an andere Mitglieder der Gemeinschaft verteilt werden.

Die VPP (Virtual Power Plant) in der Energy Community, EC können Energie untereinander austauschen, überschüssige Energie an andere VPPs verkaufen oder bei Bedarf Energie von anderen VPPs beziehen. Dadurch wird die Flexibilität und Effizienz der Energieversorgung in der EC verbessert. Das zentrale Ziel bleibt dabei die Optimierung des Energiemanagements und die Nutzung erneuerbarer Energien, um die Gesamtkosten im Netz zu reduzieren und eine nachhaltigere Energieversorgung zu erreichen.

6.5.1 Szenario für das verteilte Energiemanagement

Das Simulationsszenario für das verteilte Energiemanagement besteht aus einer Eigenverbrauchsgemeinschaft (EC) welches aus mehreren virtuellen Kraftwerken besteht. Diese VPP sind analog zu dem in Abschnitt 6.4.2 vorgestellten Konzept aufgebaut. Jedes VPP in der EC ist eine Gruppe von dezentralen Energieressourcen (DER) wie Photovoltaikanlagen, Windkraftanlagen, Batteriespeichern und möglicherweise anderen Energiequellen.

Die VPPs innerhalb des ECs arbeiten zusammen, um den Energiebedarf der Gemeinschaft zu decken und das Energiemanagement zu optimieren. Jedes VPP kann seine eigenen lokalen Energiemanagement- und Steuerungsstrategien haben, die auf den Zustand und die Kapazität der angeschlossenen DER basieren. Die Kommunikation und Koordination zwischen den VPPs ermöglicht es der EC, den Energieverbrauch zu optimieren, die Verfügbarkeit erneuerbarer Energien zu maximieren und die Energiekosten zu senken.

Das EC ist in Abbildung 6.12 dargestellt, das in diesem Szenario aus drei VPPs besteht.

Das Energiemanagement ist für den kosteneffizienten Betrieb aller Geräte innerhalb des EC verantwortlich. Das Ziel ist die Minimierung der Gesamtkosten:

$$\mathcal{J} = \arg \min_P \sum_{i \in EC} f_i(P_{\text{dem}}, P_{\text{batt}}, P_{\text{res}}, P_{\text{curt}}) + g(P_{\text{EC}}, \kappa) \quad (6.2)$$

Dabei ist f_i die lokale Kostenfunktion des VPP i . Die globale oder gemeinsame Kostenfunktion, hier als $g(P_{\text{VPP}}, \kappa)$ bezeichnet, hängt in diesem Fall von der Gesamtenergie P_{EC} ab, die von einem EC in das

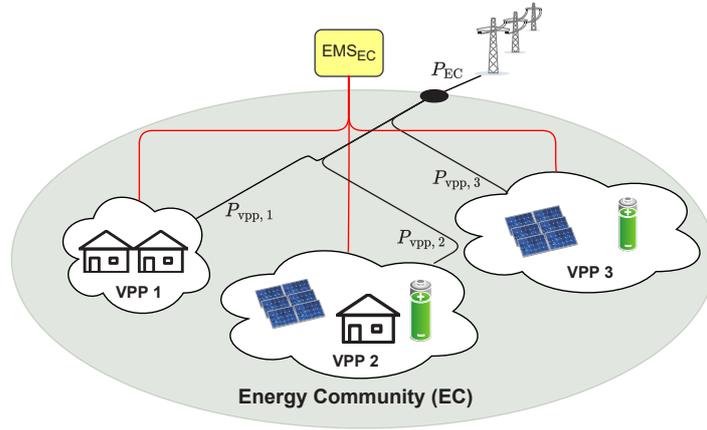


Abbildung 6.12 Topologie des SCC mit drei VPPs für das Simulationsszenario. Das zentrale Energiemanagement ist als EMSEC dargestellt.

Netz eingespeist oder daraus entnommen wird und dem jeweiligen Energiepreis κ . Weiterhin gelten die Nebenbedingungen:

$$P_{\text{EC}} = \sum_{i \in \text{EC}} P_{\text{vpp},i} \quad \underline{P}_{\text{EC}} \leq P_{\text{EC}} \leq \overline{P}_{\text{EC}} \quad (6.3)$$

Lokale Kostenfunktionen und zugehörige Nebenbedingungen für die VPPs werden auf Basis des Power-Node-Konzepts definiert [84]. Es wird angenommen, dass diese lokalen Kostenfunktionen für alle VPPs gleich sind.

Das Ziel der Optimierung ist es, die Gesamtkosten zur Deckung des Energiebedarfs innerhalb einer Energie-Community EC zu minimieren. Diese ergeben sich aus dem Zusammenspiel VPPs und deren lokalen Energieflüssen: dem Verbrauch (P_{dem}), der erzeugten Energie (P_{res}), der Energie, die ins Netz eingespeist oder daraus entnommen wird (P_{vpp}), und der zur Batterieladung oder -entladung verwendeten Energie (P_{batt}). Der Energiebedarf (P_{dem}) in den VPPs wird in dieser Arbeit als nicht steuerbar angesehen. Zudem sind die Leistungsflüsse in jedem VPP durch Maximal- und Minimalwerte begrenzt.

6.5.2 Verteiltes Energiemanagement

Der Alternating Direction Method of Multipliers (ADMM) ist ein Optimierungsalgorithmus, der zur Lösung einer Vielzahl von Problemen eingesetzt werden kann, darunter lineare und nicht lineare, konvexe und nicht konvexe Probleme. Er ist besonders nützlich für die Bewältigung großer Optimierungsprobleme, die mit herkömmlichen Methoden schwer zu lösen sind.

Die Grundidee des ADMM besteht darin, ein großes Optimierungsproblem in kleinere, leichter handhabbare Teilprobleme aufzuteilen und diese dann abwechselnd unter dem Austausch der lokalen Variablen zu lösen [147]. Hierbei gibt es verschiedene Formulierungen, welche sich in den auszutauschenden Informationen unterscheiden [148, 149].

Ablauf des Algorithmus: Basierend auf Abbildung 6.12 lässt sich der hier genutzte Algorithmus wie folgt beschreiben: Die lokalen Controller (EMS_{VPP}) sind für die spezifischen Anlagen innerhalb ihrer jeweiligen virtuellen Kraftwerke (VPPs) verantwortlich. Jeder EMS_{VPP} erhält Informationen und Anweisungen vom zentralen Controller EMS_{EC} und verwendet diese Informationen zur Durchführung seiner spezifischen Optimierungsaufgabe.

In jeder Iteration berechnet jeder EMS_{VPP} die optimale Steuerstrategie für seine jeweilige Anlage oder Gruppe von Anlagen, basierend auf den aktuellen Betriebsbedingungen, den Systemanforderungen und den vom EMS_{EC} bereitgestellten Anweisungen. Diese lokale Optimierungsaufgabe kann verschiedene Ziele haben, wie z.B. die Maximierung der Energieeffizienz, die Minimierung der Kosten oder die Erfüllung bestimmter Leistungskriterien.

Nachdem der EMS_{VPP} die lokale Optimierung durchgeführt hat, sendet er die Ergebnisse zurück an den EMS_{EC} . Der EMS_{EC} führt dann die Konsensbildung durch und aktualisiert die Dualvariablen (siehe A.4) basierend auf den empfangenen Ergebnissen. Dieser Prozess wird iterativ fortgesetzt, bis die Systemleistung optimiert ist.

Auf diese Weise können die EMS_{VPP} s effektiv die Anlagen in ihren jeweiligen VPP steuern, während sie gleichzeitig mit dem EMS_{EC} kommunizieren, um die Gesamtleistung des Systems zu optimieren. Dieser Ansatz ermöglicht es, die Vorteile der zentralen Koordination mit der Flexibilität und Anpassungsfähigkeit der lokalen Steuerung zu kombinieren.

Der detaillierte, hier verwendete Algorithmus ist in Kapitel A.4 dargestellt.

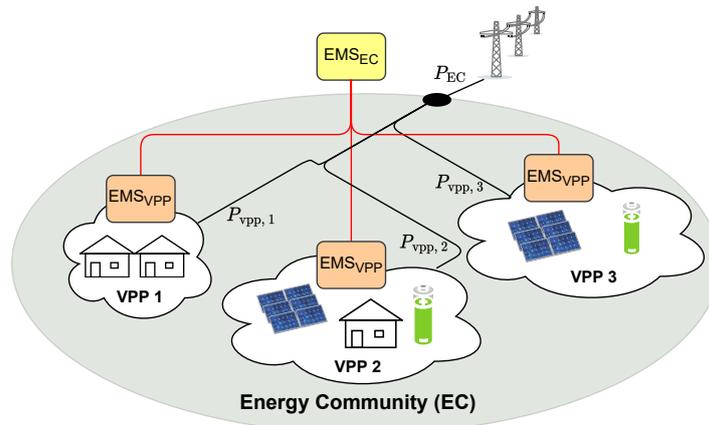


Abbildung 6.13 Aufbau eines dezentralen Energiemanagements für das zuvor eingeführte Simulationsszenario.

6.5.3 Ergebnisse des verteilten Energiemanagements

Die vorliegenden Resultate deuten auf eine hohe Wirksamkeit der dezentralen Optimalregelung hin. Trotz der dezentralisierten Struktur des Ansatzes wird eine Leistung erreicht, die der eines zentralisierten Algorithmus ähnelt. Eine geringfügige Abweichung von unter 3% hinsichtlich der Energiekosten verdeutlicht die Effektivität und Leistungsfähigkeit des dezentralen Regelungsalgorithmus. Diese Abweichung resultiert aus der Tatsache, dass die Anzahl der Iterationen vom gewählten Konvergenzkriterium bestimmt wird. In diesem speziellen Fall wurde das Kriterium so gewählt, dass es eine hohe Recheneffizienz priorisiert (early stopping). Das durchschnittliche Konvergenzverhalten für

das beschriebene Szenario ist in Abbildung 6.14 dargestellt. Bei konvexen Problemen konvergiert der ADMM-Algorithmus sublinear [150]. Mathematisch ausgedrückt bedeutet das, dass der Fehler e_k in der k -ten Iteration durch die Ungleichung $e_k \geq \frac{C}{k^\alpha}$ beschrieben werden kann, wobei C und $\alpha > 0$ Konstanten sind. In den späteren Iterationen des Algorithmus verringert sich der Fortschritt, weshalb er sich der Lösung zunehmend langsamer nähert.

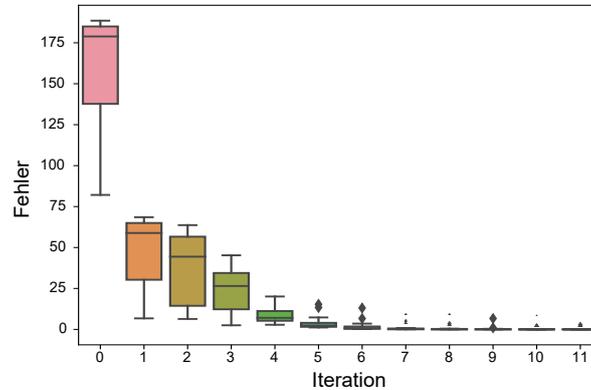


Abbildung 6.14 Konvergenzverhalten des dezentralen Algorithmus. Auf der X-Achse ist die Anzahl der Iterationen und auf der Y-Achse die Abweichung zwischen den lokalen Variablen p im EMS_{VPP} und der Kopie z im EMS_{EC} ($\|\bar{p}(t) - \bar{z}(t)\|$) [21].

Kommunikationsunterbrechung

In verteilten Energiemanagementsystemen, wie jenen mit einer Self-Consumption Community (SCC) und virtuellen Kraftwerken (VPPs), spielt die Kommunikationsinfrastruktur eine entscheidende Rolle. Sie ermöglicht den Informationsaustausch zwischen den Einheiten und ist daher essenziell für das Funktionieren des Gesamtsystems.

Im Fall einer Kommunikationsunterbrechung wird die Informationsweitergabe unterbrochen, was zu einer Beeinträchtigung der Systemleistung führen kann. Für solche Szenarien kann eine Ausfallstrategie implementiert werden, um die Auswirkungen zu minimieren und die Betriebskontinuität zu gewährleisten.

Im Kontext des ADMM-basierten verteilten Energiemanagements könnte eine mögliche Ausfallstrategie darin bestehen, die abhängigen Variablen auf den letzten optimierten Wert zu setzen, der von der ausgefallenen Einheit vor der Unterbrechung empfangen wurde. Diese Vorgehensweise stellt eine Art von Best-Response-Strategie dar, in der die anderen Einheiten ihre Aktionen auf der Grundlage der zuletzt bekannten Informationen über die ausgefallene Einheit anpassen.

Die ausgefallene Einheit selbst ist während der Unterbrechung vom Kommunikationsnetzwerk isoliert und kann daher nicht mit den anderen Einheiten interagieren. Sie würde aber basierend auf ihren zuletzt verfügbaren Daten ihre Optimierungsaufgabe weiterhin lokal lösen. Sobald die Kommunikation wiederhergestellt ist, wird die Einheit ihre Daten aktualisieren und sich wieder in den Prozess der gemeinsamen Optimierung integrieren. Die Wiederaufnahme des Informationsaustauschs ermöglicht es dem System, wieder voll funktionsfähig zu werden und eine optimale Leistung zu erzielen.

In einem Testfall wurde bei einer Kommunikationsunterbrechung von 15h in dem zuvor geschilderten Szenario (Vorhersagehorizont: 24h) eine relative Abweichung der Kosten von 0,55 % festgestellt.

Diese Strategie dient dazu, die Robustheit des verteilten Energiemanagementsystems gegenüber Kommunikationsunterbrechungen zu verbessern. Es ist jedoch wichtig zu beachten, dass die Wahl der spezifischen Ausfallstrategie von den spezifischen Anforderungen und Einschränkungen des Systems und seiner Betriebsumgebung abhängt.

6.5.4 Interpretation als Marktgleichgewicht

In Energiemanagementsystemen für Virtuelle Kraftwerke (VPP) ermöglicht die Anwendung des ADMM in seiner nicht skalierten Form eine direkte Analogie zum klassischen Walras-Gleichgewicht [147]. Anders als in der skalierten Form, bei der ein Normierungsfaktor verwendet wird, bietet die unskalierte Form eine intuitive Interpretation: Die optimale duale Variable entspricht unmittelbar den Gleichgewichtspreisen für Energie in einem VPP. Jede dezentrale Energieerzeugungsanlage, die als Agent im VPP agiert, handelt basierend auf diesen Preisen, um ihre individuellen Kosten zu minimieren. Der Gleichgewichtszustand tritt ein, wenn die gesamte Energiemenge, die auf dem Markt angeboten wird, genau der Menge entspricht, die nachgefragt wird. In diesem Kontext wird die Rolle der Dualvariablen besonders deutlich: Sie repräsentiert nicht nur die Preissignale, die den Austausch und die Verteilung von Energie im VPP steuern, sondern sie dient auch als Mechanismus zur Sicherstellung eines stabilen und effizienten Marktbetriebs.

6.6 Zusammenfassung der Betriebsoptimierung und Schlüsselerkenntnisse

In diesem Kapitel wird eine eingehende Analyse der Betriebsoptimierung verteilter Energieerzeuger und Speichersysteme durchgeführt, wobei ein besonderer Schwerpunkt auf der Kategorisierung von Algorithmen und der Untersuchung von Vorhersageunsicherheiten liegt. Beide Themen stellen innovative Aspekte der Arbeit dar, deren Untersuchung und Verständnis neue Wege für effizientere und nachhaltigere Energiemanagementstrategien eröffnet.

Ein Hauptbestandteil des Kapitels besteht in der Erörterung der Einordnung zentraler und dezentraler Algorithmen. Hierzu wurde in Kapitel 6.1 eine neue Matrixstruktur entworfen, welche die Algorithmen in zwei Dimensionen – Entscheidungsfindung und Kommunikation – einordnet. Dieser Abschnitt zielt darauf ab, ein fundiertes Verständnis der unterschiedlichen Algorithmen zu schaffen und ihre potenziellen Rollen und Beiträge zur Betriebsoptimierung verteilter Energieerzeuger und Speicher aufzuzeigen.

Im weiteren Verlauf des Kapitels 6.1.1 werden verschiedene Typen und Algorithmen des Energiemanagements beschrieben und in die neue Matrixstruktur eingeordnet. Es wird eine eingehende Untersuchung an einer Auswahl von Algorithmentypen durchgeführt und ihre spezifischen Anwendungen innerhalb des Energiesystems dargelegt. Die regelbasierten Verfahren umfassen die direkte Batterieladung, verzögertes Laden, Spitzenlastreduzierung und Verfahren, basierend auf der Modellprädiktiven

Regelung. Zusätzlich wurde die Nutzung dynamischer Tarife und Preisanreize diskutiert und an einem Beispiel vorgestellt. Durch variable Tarife kann die Nutzung von erneuerbaren Energien gefördert werden.

Die Untersuchung des Einflusses von Vorhersageunsicherheiten stellt einen weiteren zentralen Punkt in Kapitel 6.4 dar. In diesem Abschnitt wird dargelegt, wie die Unsicherheit in der Prognose von Last und Erzeugung das Energiemanagement beeinflusst und welche Strategien entwickelt werden können, um diese Unsicherheiten zu bewältigen und die Betriebsoptimierung zu verbessern. So führt etwa ein Vorhersagefehler von 10% zu einer Erhöhung der Betriebskosten von etwa 8%. Durch einen Batteriespeicher kann diese Erhöhung auf etwa 2% reduziert werden.

Nachfolgend wird ein Ansatz basierend auf dem ADMM Algorithmus [147] für das verteilte Energiemanagement von Eigenverbrauchsgemeinschaften (ECs) dargelegt, welcher eine Koordination von Energieressourcen über diverse Standorte hinweg vorsieht. Es wird ein Szenario für das verteilte Energiemanagement skizziert und die potenziellen Beiträge dieser Strategie zur Optimierung der Energieversorgung diskutiert und die Auswirkungen von Kommunikationsausfällen erörtert.

Dieses Kapitel liefert nicht nur eine Grundlage für die Einordnung von Algorithmen und die Untersuchung von Vorhersageunsicherheiten, sondern bietet auch praxisnahe Anwendungen und Lösungsansätze für die Betriebsoptimierung verteilter Energieerzeuger und Speichersysteme. Mit diesen Untersuchungen und der neuen zweidimensionalen Einordnung von Energiemanagementalgorithmen leistet dieses Kapitel einen Beitrag zum Verständnis von Potenzialen und Herausforderungen in diesem Bereich.

7 Optimale Systemauslegung zur Engpassvermeidung und Integration erneuerbarer Energien

Dieses Kapitel fokussiert sich auf die Entwicklung von kosteneffizienten Lösungsmöglichkeiten bei der Gestaltung und dem Ausbau von zukunftssicheren Energiesystemen bei komplexen Anforderungen. In der Übergangsphase hin zu einer nachhaltigeren Energieversorgung steht die Energiewirtschaft vor der Aufgabe, das bisherige System durch robusten und kosteneffektiven Ausbau so weiterzuentwickeln, dass die maximale Menge erneuerbarer Energien genutzt werden kann. Gleichzeitig sollte die Belastungen für Umwelt, Infrastruktur und Kosten minimal bleiben.

Während das vorherige Kapitel vorrangig die zeitliche Optimierung von Last, Erzeugung und Speicherung thematisierte, fokussiert sich dieses Kapitel auf die räumliche Dimension. Hierbei wird sowohl erörtert, an welchen Stellen im Energienetz zusätzliche Ausbaumaßnahmen erforderlich sind, um eine stärkere Integration von erneuerbaren Energien zu ermöglichen, als auch die optimale Platzierung von Messstellen untersucht.

Im Rahmen dieses Kapitels werden verschiedene Aspekte der Batteriespeicherplatzierung behandelt, um die Netze zu entlasten [151]. Unter Berücksichtigung verschiedener Szenarien hinsichtlich der Durchdringung von Photovoltaik und der maximalen Spannungsabweichung analysiert das Kapitel die optimale Platzierung von Batterien im Netz und deren Auswirkungen auf die Netzstabilität. Ferner bietet es eine umfassende wirtschaftliche Analyse der Implementierung solcher Systeme. Vergleichend wird zudem eine Strategie für den automatisierten Netzausbau durch Leistungsverstärkung vorgestellt und mit der Platzierung von Batteriespeichersystemen verglichen.

Ferner werden Methoden zur optimierten und strategische Platzierung von Messstellen vorgestellt. Durch die optimierte Installation von Messstellen im Verteilnetz wird die Zustandsschätzung im Verteilnetz verbessert und somit die Netztransparenz erhöht. Dadurch können Echtzeitdaten über den Energiefluss und die Netzbelastung gewonnen werden, um eine effektive Netzsteuerung und -überwachung zu ermöglichen.

Es ist zu beachten, dass die im Kapitel vorgestellten Methoden zur optimalen Systemauslegung besonders dann zum Tragen kommen sollten, wenn der optimierte Betrieb durch die Anwendung neuer Regelstrategien allein nicht ausreicht, um einen stabilen Betrieb bei weiterem Ausbau der DER zu gewährleisten. Insgesamt liefert dieses Kapitel sowohl praktische als auch theoretische Einblicke, die zur Beschleunigung des Übergangs zu einer nachhaltigeren und widerstandsfähigeren Energiezukunft beitragen können.

7.1 PV-Speichersysteme - Dimensionierung für optimierten Eigenverbrauch bei gleichzeitiger Netzverträglichkeit

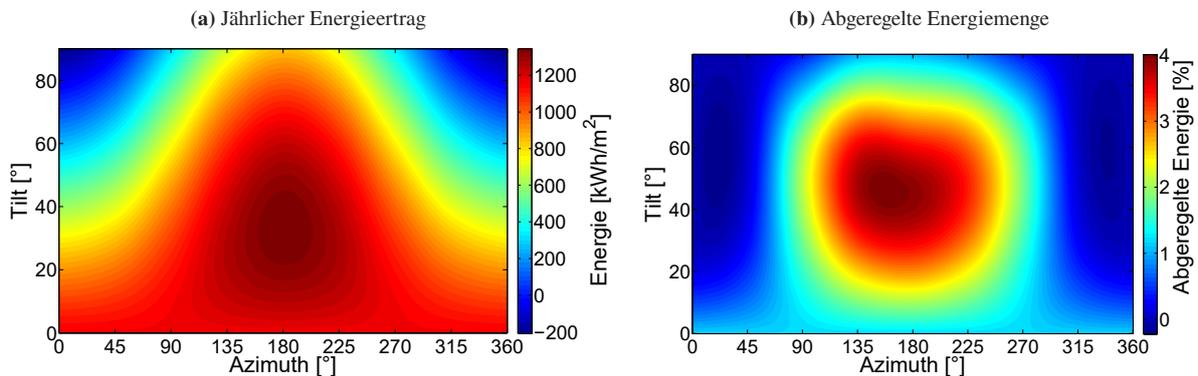


Abbildung 7.1 In 7.1a ist der Jahresertrag abhängig von der Ausrichtung dargestellt, in Abbildung 7.1b die Abregelung im Falle eines Einspeiselimits von 60 % [152].

Angesichts der Diskussion um den erforderlichen Netzausbau und Maßnahmen zur Einbindung von Solarerzeugung durch Photovoltaik (PV) Anlagen wird hier der Einfluss von der PV-Anlagen Ausrichtung und Montage, den Einbezug von Eigenverbrauch und den Einsatz von Batteriespeichern auf die Abregelungsverluste erläutert.

Die Studie basiert auf ausgiebigen Messdatensätzen aus dem Testfeld Widderstall des ZSW. Als Input für die Einstrahlungsmodellierung dienten jährliche Minutenmittelwerte von solaren Strahlungsmessungen, einschließlich der Parameter Globalstrahlung und diffuser horizontaler Einstrahlung, sowie Umgebungslufttemperaturdaten vom August 2013 bis September 2014. Zur Überprüfung des Modells wurden synchron aufgezeichnete Strahlungsmessungen von Pyranometern und Betriebsdaten, sowie PV-Modultemperaturen von verschiedenen Testgeneratoren herangezogen. Die Ertragssimulationen wurden gemäß Kapitel 3.5 durchgeführt.

Zur Simulation des Eigenverbrauchs in Haushalten wurden fünfzehn verschiedene Lastprofile mit 5-Minuten-Zeitschritten und einem jährlichen Energieverbrauch zwischen 3000 kWh und 5500 kWh verwendet. Schließlich wurde ein Batteriespeicher, der mit einem verzögerten Ladealgorithmus aus Kapitel 6.3.1 arbeitet, untersucht.

Die Ergebnisse der Studie verdeutlichen, dass die Abregelungsverluste erheblich gesenkt werden können, indem PV-Anlagen auf Dächern montiert werden, die nicht nach Süden ausgerichtet sind. Mit einer Einspeisebegrenzung von 70 Prozent der PV-Nennleistung verringern sich die Energieverluste um etwa zwei Drittel, wenn die Ausrichtung der PV-Anlage von Süden nach Westen verändert wird.

Bei einer typischen Einfamilienhaus-PV-Anlage sinkt der mittlere abgeregelter Energiebedarf durch Eigenverbrauch um mindestens ein Drittel. Die Verwendung von Batteriespeichern mit einem intelligenten, verzögerten Ladealgorithmus kann die Ertragsverluste weiter reduzieren. Bei einer Batterie mit 5 kWh Kapazität Batterie würden sich die Verluste um etwa 3 bis 5 Prozentpunkte reduzieren im Vergleich zu den Verlusten bei reinem Eigenverbrauch (bei Einspeisegrenzen 30% bis 50%,

Südausrichtung). Bei einer geeigneten Auslegung von PV-Anlage und Batterie in Bezug auf den Jahresverbrauch des Haushalts sind die Energieverluste bei einer Einspeisegrenze von 60% der Nennleistung PV-Leistung selbst bei Südausrichtung weniger als 1% des jährlichen Energieertrags.

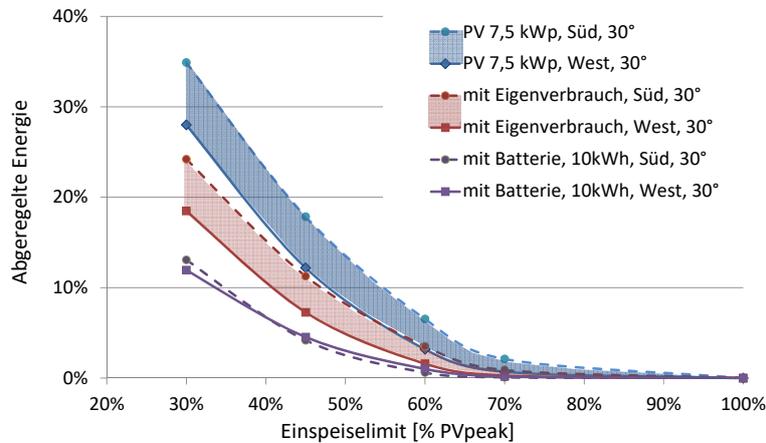


Abbildung 7.2 Anteil der abgeregelten Energie in Abhängigkeit von der Einspeisegrenze für verschiedene Szenarien [152, 153]. Der Eigenverbrauch wird berechnet anhand von 15 verschiedenen Haushaltsprofilen bei einer nach Süden und Westen ausgerichtete PV Anlagen (c-Si-Modulen, 7,5kWp, Gebäude montiert, ZSW-Testfeld Widderstall).

7.2 Messstellenplatzierung zur Zustandsschätzung im Verteilnetz

Der Mangel an Messstellen führt oft zu unbeobachtbaren Netzen, die einige beobachtbare Teilsysteme enthalten. Die Beobachtbarkeit des gesamten Netzes kann durch Hinzufügen von Schätzungen der Last und der Erzeugung zu den unbeobachteten Knotenpunkten erhalten werden. Diese sind normalerweise mit einer Unsicherheit behaftet. Diese A-priori-Informationen (Pseudomessungen) in Kombination mit den Echtzeitmessungen erlauben es, den Zustand des gesamten Systems zu schätzen.

Um die Genauigkeit der Netzzustandsabschätzung zu erhöhen, können weitere Messeinheiten in das Netz eingebracht werden. Um einen kosteneffizienten Betrieb des Netzes zu gewährleisten, ist eine geeignete Platzierung wichtig [154]. Die Messstellen sollten so platziert werden, dass die Gesamt-Messunsicherheit im Netz minimiert und somit die maximale Genauigkeit bei minimalem Aufwand bei der Zustandsschätzung erreicht wird.

In diesem Abschnitt werden verschiedene Platzierungsstrategien mit dem Ziel, die Schätzgenauigkeit mit minimaler Investition zu erhöhen, auf ein deutsches Verteilnetz angewendet und verglichen. Die Ergebnisse zeigen, dass die Leistungsfähigkeit der Platzierungsstrategie sowohl von der richtigen Wahl der Kostenfunktion als auch der Optimierungsstrategie abhängt [48].

7.2.1 Messtechnik im Verteilnetz

Zur Überwachung von Stromverteilernetzen steht eine breite Palette von Messinstrumenten zur Verfügung, die hinsichtlich ihrer technischen Spezifikationen und Kosten variieren. Phasor-Messgeräte

(Phasor Measurement Unit, PMUs) sind ein Beispiel für hoch entwickelte Messinstrumente, die weit mehr als grundlegende Spannungs- und Strommessungen liefern. Sie sind speziell darauf ausgelegt, den Phasenwinkel zwischen verschiedenen Knoten, Stationen oder Umspannwerken präzise zu bestimmen. Die Einbeziehung dieser Phasenwinkelinformationen kann die Genauigkeit der Zustandsschätzung verbessern, ist aber insbesondere auf Übertragungsebene relevant.

Ungeachtet der ausgereiften Technologie und den detaillierten Messdaten, die diese Geräte bereitstellen können, stellen ökonomische Aspekte eine Begrenzung für ihre umfassende Anwendung in Verteilungsnetzen dar [155]. Die Kosten für Anschaffung und Betrieb dieser Messinstrumente können die wirtschaftliche Machbarkeit einer umfassenden Überwachung und Steuerung von Verteilungsnetzen beeinflussen.

Im Kontext von Niederspannungsnetzen stellen Smart Meter eine kosteneffizientere Alternative dar. Sie erlauben, den Energiebedarf und die Energieerzeugung aus der Ferne zu messen und Marktsignale an Verbraucher und Produzenten zu senden. Dies fördert eine reaktive Netzsteuerung. Dennoch sind Smart Meter im Vergleich zu PMUs nicht in der Lage, Phasemessungen durchzuführen. Dies führt dazu, dass die Zustandsschätzung von Verteilungsnetzen (DSSE) auf verfügbare Spannungs- und Strommessungen angewiesen ist, was deren Genauigkeit und Informationsgehalt potenziell einschränkt.

7.2.2 Zielfunktion zur Messstellen-Platzierung

Für die optimale Platzierung von Messstellen muss die Zielfunktion definiert werden. Optimierungsbasierte Ansätze haben in der Regel den Vorteil, dass schnell eine qualitativ hochwertige Lösung erreicht werden kann. Das Konvergenzverhalten hängt allerdings von der Zielfunktion ab, insbesondere davon, ob sie konvex und glatt ist.

Bei der Zählerplatzierung ist die resultierende Gesamtschätzungsunsicherheit innerhalb des Netzes von Interesse. Eine Möglichkeit ist es, die euklidische Norm der Standardabweichung des geschätzten Zustands zu verwenden:

$$\mathcal{J} = \arg \min_{b \in B} \|\sigma_{\hat{x}}\|_p \quad (7.1)$$

wobei $p \in \{1, 2, \infty\}$. Weiterhin bezeichne b die Menge der mit Messgeräten ausgestatteten Knoten und B die Menge aller für eine Zählerplatzierung geeigneten Knoten innerhalb des Netzes. Der Vektor $\sigma_{\hat{x}}^2$ entspricht den Diagonaleinträge der Schätzkovarianzmatrix $\Sigma_{\hat{x}}$ (Gleichung 4.16).

Auswahl der Zielfunktion und des Optimierungsansatzes

Die in Gleichung 7.1 definierte Kostenfunktion der Smart-Meter-Platzierung ist nicht-glatt und nicht-konvex und daher schwer zu optimieren. In Abbildung 7.3 ist die Oberfläche der Zielfunktion für eine Platzierung von zwei Messstellen dargestellt. Hier ist deutlich zu erkennen, dass die Oberfläche sehr zerklüftet und mit steilen Kanten durchsetzt ist. Um die Fragmentierung und die Möglichkeiten für lokale Optima zu verringern, kann die Zuordnungsmatrix optimiert werden. Im Idealfall entspricht

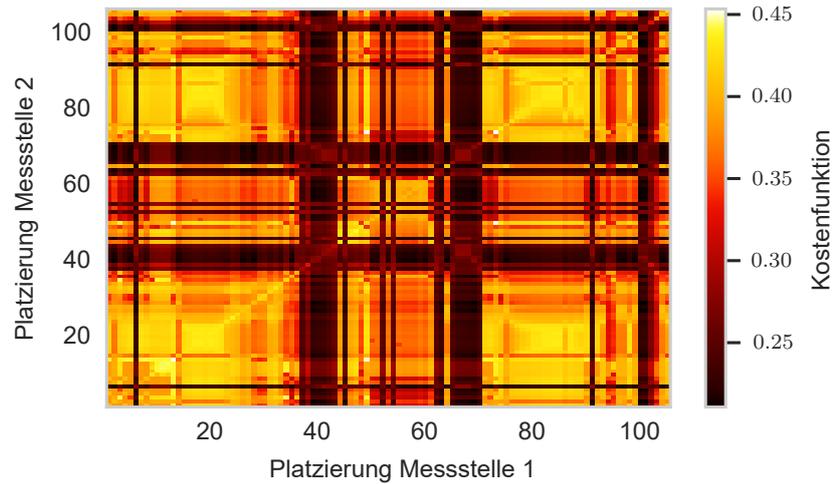


Abbildung 7.3 Abbildung der Kostenfunktion $\mathcal{J} = \|\sigma_{\hat{x}}\|_1$, welche die Schätzgenauigkeit im Netz repräsentiert, für eine Platzierung von 2 Smart-Meter [48]. Die Komplexität der Optimierungsoberfläche ist deutlich zu erkennen und kann durch eine geschickte Anordnung der Knoten in bestimmten Fällen verbessert werden.

der eine Schritt innerhalb des Suchraums der Bewegung zu einem benachbarten Knoten innerhalb des realen Netzes. Dies kann natürlich nicht für alle Knoten und Standorte innerhalb des Netzes erreicht werden. Um eine Knotenreihenreihenfolge zu erhalten, die die oben genannten Eigenschaften hat, wurde eine Tiefensuche (Depth-First-Search, DFS) auf dem Graphen des Netzmodells durchgeführt und die Knoten wurden entsprechend neu geordnet.

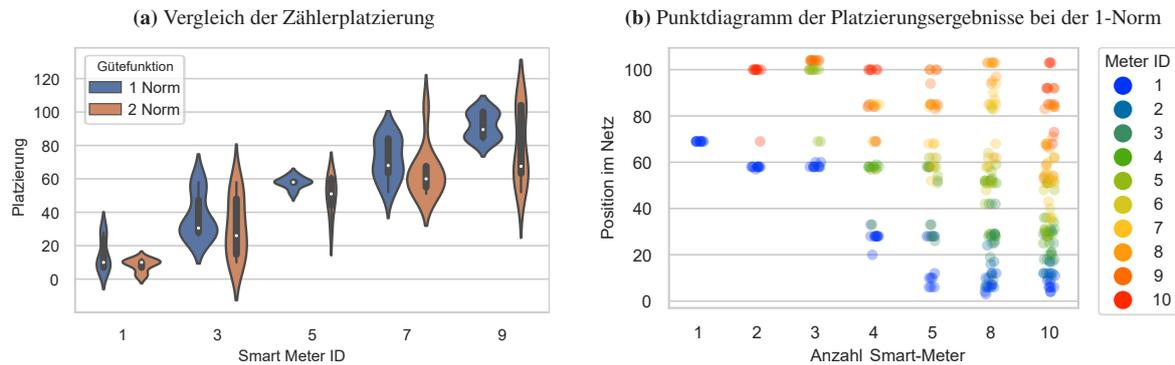


Abbildung 7.4 (b): Punktdiagramm der Platzierungsergebnisse des Algorithmus mit 10 verschiedenen Initialisierungen. (a): Vergleich der Zählerplatzierung mit $\|\sigma_{\hat{x}}\|_1$ und $\|\sigma_{\hat{x}}\|_2$ als Zielfunktion. Die Optimierung wurde mit dem stochastischen Hill-Climb-Algorithmus und 10 verschiedenen Initialisierungen durchgeführt [48].

Zur Optimierung der Messstellenplatzierung wurden verschiedene Algorithmen verglichen. So wurde die in [156] vorgestellte Policy-Gradient Methode mit Gradientenverfahren sowie stochastische Optimierungsansätze verglichen. Die besten Ergebnisse wurden mit dem stochastischen Hill-Climb-Algorithmus erzielt, weshalb dieser für alle weiteren Analysen verwendet wird.

Die Auswahl der in der Zielfunktion verwendeten Norm hat einen entscheidenden Einfluss auf die Performance eines Optimierungsalgorithmus. Die 1-Norm ($\|\sigma_{\hat{x}}\|_1$) strebt die Minimierung des kumulativen Betrags der Vektorunsicherheiten an. Dagegen bestraft die 2-Norm ($\|\sigma_{\hat{x}}\|_2$) die Unsicherheiten quadratisch, was zur Folge hat, dass Ausreißer eine disproportional hohe Wirkung auf das Optimierungsergebnis ausüben können. Die Supremumsnorm, oft auch als Unendlichkeitsnorm bezeichnet ($\|\sigma_{\hat{x}}\|_\infty$), berechnet die größte Einzelunsicherheit innerhalb des betrachteten Vektors.

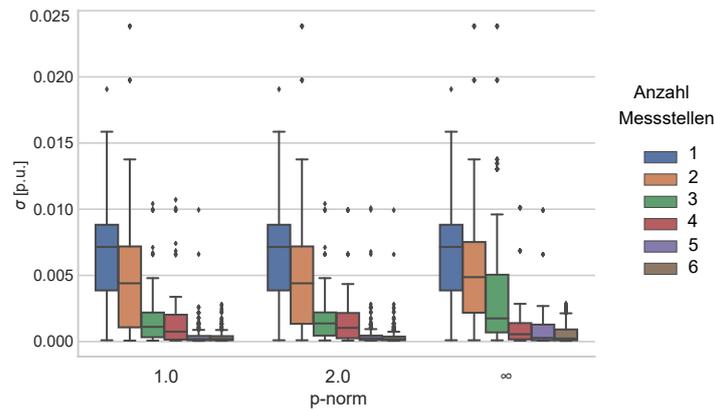


Abbildung 7.5 Vergleich der Standardabweichung der Spannungsschätzung im Netz σ [p.u.] in Abhängigkeit von der Kostenfunktion und der Anzahl von Messstellen. Auch hier liefert $\|\sigma_{\hat{x}}\|_1$ als Kostenfunktion insgesamt das beste Ergebnis, also die geringste Unsicherheit in der Spannungsschätzung $\sigma_{\hat{x}}$.

In Abbildung 7.4a sind die Ergebnisse von zwei Optimierungsläufen mit der $\|\sigma_{\hat{x}}\|_1$ und der $\|\sigma_{\hat{x}}\|_2$ als Zielfunktion dargestellt. Beide wurden mit dem stochastischen Hill-Climb-Algorithmus mit 10 verschiedenen Initialisierungen optimiert. In diesem Fall wurden fünf Messstellen platziert. Ihre jeweilige Position im Netz ist auf der y-Achse und die Zählernummer auf der x-Achse dargestellt. Da der Algorithmus mit 10 verschiedenen Werten initialisiert wurde, erhält man eine Verteilung der Platzierung und nicht nur einen einzigen Wert.

Beide Zielfunktionen führen zu einer ähnlichen Platzierung, die $\|\sigma_{\hat{x}}\|_1$ führt jedoch im Durchschnitt zu einer etwas engeren Verteilung und wird daher für die weiteren Ergebnisse als Optimierungskriterium gewählt. Deshalb wurde die euklidische 1-Norm $\|\sigma_{\hat{x}}\|_1$ als Zielfunktion für die Minimierung der Gesamtunsicherheit im Netz gewählt.

Die Ergebnisse hinsichtlich der Platzierung für verschiedene Anzahlen von Smart-Metern sind in Abbildung 7.4b dargestellt. Auf der y-Achse ist die Fitness ($\|\sigma_{\hat{x}}\|_1$) dargestellt und auf der x-Achse die Anzahl der Messstellen. Es ist zu erkennen, dass das Gesamtfitnessniveau für die verschiedenen Ausgangspunkte fast gleich ist, obwohl die resultierende Platzierung leicht abweichen kann.

Eine gute und zuverlässige Platzierungslösung wurde unter Verwendung eines Multistart-Hillclimb-Optimierungsalgorithmus mit der 1-Norm der Spannungsstandardabweichung als Kostenfunktion gefunden.

7.2.3 Ergebnisse der Messstellenplatzierung

Die optimalen Platzierungen im Netz sind in Abbildung 7.6 dargestellt. Hierbei wird ersichtlich, dass die optimale Platzierung von Messstellen im Verteilnetz oft am Ende des Strangs und an Verbindungspunkten mehrerer Stränge stattfindet. Messstellen am Strangende liefern wertvolle Informationen über den Netzzustand, da der Spannungsabfall gegen Ende größer wird. Messstellen an Verbindungspunkten messen die Spannung und den Stromfluss durch das Netz an diesen Punkten und können Informationen über den Zustand mehrerer Stränge gleichzeitig liefern. Diese Platzierung ermöglicht eine effektive

Überwachung des Netzwerks, frühzeitige Problemerkennung und unterstützt die Erstellung von Lastflussmodellen zur Optimierung des Netzbetriebs. Die genauen Details hängen jedoch von vielen Faktoren ab, einschließlich der spezifischen Netztopologie und den Kosten für Installation und Wartung der Messstellen.

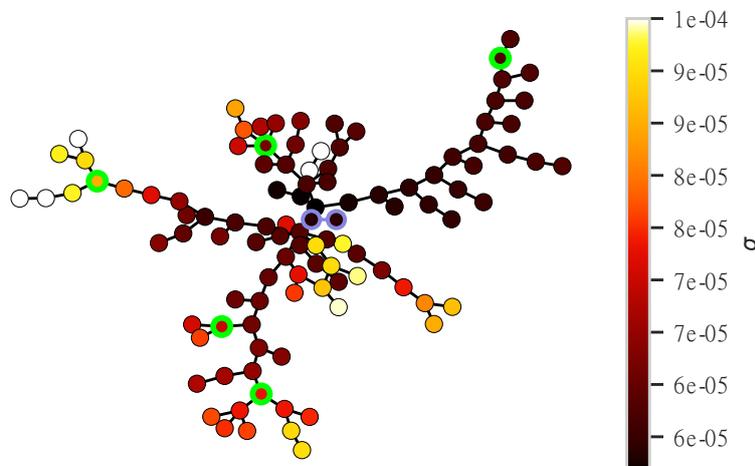


Abbildung 7.6 Ergebnisse der optimierungsbasierten Platzierung für 5 intelligente Zähler [48]. Die grünen Kreise zeigen die Position der Messstellen an (Messgenauigkeit= $1 \cdot 10^{-3}$ p.u.). Die Farbe der Knoten stellt die Standardabweichung σ am entsprechenden Knoten dar. Es wird davon ausgegangen, dass am Trafo (lila) sowohl Leistung als auch Spannung gemessen wird.

Die Effizienz des Verfahrens zur optimalen Platzierung der Messpunkte kann auch durch einen Vergleich zwischen der besten Platzierung und der schlechtest möglichen Platzierung veranschaulicht werden: Im Falle von zwei platzierten Messstellen ist die Summe der Unsicherheit im schlechtesten Fall ($\|\sigma_{\hat{x}}\|_1^{\text{worst}} = 0,45$ p.u.) etwa doppelt so hoch wie im Fall der besten Platzierung ($\|\sigma_{\hat{x}}\|_1^{\text{opt}} = 0,22$ p.u.).

7.3 Speicherplatzierung und Auslegung

Im Rahmen der hohen Durchdringung von DER im Energiesystem erlangen Batteriespeichersysteme zunehmend eine höhere Priorität. Ihre potenzielle Fähigkeit, Übertragungsverluste zu minimieren, Engpässe bei der Integration erneuerbarer dezentraler Energien zu beseitigen und zur Regulierung von Spannung und Frequenz beizutragen, macht sie unverzichtbar [157, 158].

Es existieren zahlreiche Studien im Kontext des optimierten Netzbetriebs, die sich mit der optimalen Steuerung von Batteriespeichern in Verteilnetzen befassen [159–162]. Sie können dazu beitragen, Spitzenlasten zu reduzieren und den Bedarf an Netzausbau zu verringern [163].

Die Herausforderung besteht jedoch in der optimalen Platzierung dieser Batteriespeichersysteme in Verteilungsnetzen, da dies eine sorgfältige Analyse einer Vielzahl von Faktoren erfordert. Durch spezifische Anwendungen und Betriebsstrategien entsteht jedoch der Bedarf nach geeigneten Methoden zur Dimensionierung und Positionierung dieser Systeme, um die Kosten und Verluste zu minimieren [164].

Die Struktur eines Netzes, die geografische Verteilung erneuerbarer Ressourcen und die Beschränkungen des Leistungsflusses können sich auf die optimale Positionierung von Energiespeichern auswirken

[165]. Das mathematische Problem zur Bestimmung der optimalen Lage und Größe von Speichern ist typischerweise nicht-konvex und hochdimensional. Die methodischen Ansätze zur Lösung dieses Problems können in analytische [166], künstliche Intelligenz-gestützte, klassische und heuristische Techniken unterteilt werden [167].

Motalleb et al. präsentierten eine heuristische Strategie zur Bestimmung der optimalen Standorte und Kapazitäten eines Mehrzweck-Batteriespeichersystems (BESS), unter Berücksichtigung der Verteilungs- und Übertragungsnetze [168]. Fossati et al. ermittelten die optimale Leistungskapazität eines BESS zur Minimierung der Betriebskosten eines Mikronetzwerks auf der Grundlage genetischer Algorithmen [169].

In [170, 171] wurden Untersuchungen durchgeführt, wie durch Partikelschwarmoptimierung (PSO) die Summe der Betriebskosten minimiert und gleichzeitig der optimale Standort und die optimale Größe des BESS erzielt werden können. Das Ziel der Arbeit in [172] war die Verbesserung der Frequenzregulierung und Reduzierung der Betriebskosten durch die Integration eines Lastabwurfschemas mit der optimalen Dimensionierung eines BESS. Die Ergebnisse demonstrierten eine verbesserte Leistung der Frequenzregulierung im Vergleich zu einem analytischen Algorithmus mit einem Lastabwurfschema. Ein erkanntes Problem bei den hier verwendeten Partikelschwarmoptimierung (PSO) ist, dass sie rechenintensiv sind und die Unsicherheit besteht, ob sie zur global optimalen Lösung konvergieren.

In [164] wird eine konvexe Relaxation des Second-Order-Cone-Programming (SOCP) der Leistungsflussgleichungen für die optimale Dimensionierung und Platzierung eines BESS mit reduziertem Rechenaufwand vorgestellt. Dabei wird die Zielfunktion auf zwei verschiedene Arten formuliert: Minimierung der Investition vs. Leistungsverluste und Minimierung der Investition vs. Betriebskosten-Nutzen in einem Markt mit variablen Preisen.

In [173] wird eine umfangreiche Literaturübersicht über die optimale Zuweisung und Steuerung von Battery Energy Storage System, BESS durchgeführt. Ferner werden verschiedene Technologien und die Vorteile der BESS diskutiert. Auch einige Fallstudien zur Anwendung von BESS in verschiedenen Teilen der Welt werden vorgestellt. Abschließend betont dieser Artikel die zukünftige Verbesserung der BESS-Steuerung und -Leistung, um komplexere Probleme zu lösen, die aus der Beteiligung der erneuerbaren Energieerzeugung am Energiesystem entstehen.

Wie in [128, 174] diskutiert, können Energiespeichern auch im Fall von dynamischen Energiepreisen zur ökonomischen Optimierung genutzt werden. Das Problem wird als stochastisches Optimierungsproblem über einen endlichen Zeithorizont formuliert, mit dem Ziel, die langfristigen durchschnittlichen Kosten für den verbrauchten Strom sowie die Investitionen in den Speicher zu minimieren.

7.3.1 Problemstellung

Die optimale Platzierung von Batteriespeichersystemen hängt von verschiedenen Faktoren ab. Einerseits ist die Positionierung in Bezug auf Lastzentren entscheidend, um Übertragungsverluste zu minimieren und die Energieversorgung in Zeiten hoher Nachfrage sicherzustellen. Andererseits spielt die geografische Verteilung erneuerbarer Energiequellen eine wichtige Rolle, da Batteriespeichersysteme

dazu dienen, überschüssige Energie zu speichern und bei Bedarf freizusetzen. Zudem sind Speicherkapazität und Nennleistung der Systeme wichtige technische Aspekte. Neben diesen technischen Faktoren ist die Wirtschaftlichkeit der Batteriespeichersysteme ein weiterer entscheidender Aspekt.

7.3.2 Monetäre Bewertung

In diesem Abschnitt wird ein Überblick über die Kosten gegeben, die bei der Platzierung von Batterien und dem Ausbau des Netzes zu berücksichtigen sind. Diese Kostenfaktoren sind für eine korrekte Beurteilung der optimalen Positionierung und Größe von Batteriesystemen entscheidend.

Kosten für Energiespeicher

Zur korrekten Beurteilung der Gesamtkosten für die Platzierung von Energiespeichern ist es notwendig, die Kosten in leistungs- und kapazitätsbezogene Kosten zu unterteilen. In [175] wird die Aufteilung der relativen Kostenkomponenten von Batteriespeichersystemen in einer Langzeitanalyse des Speichermarktes, die seit 2014 durchgeführt wird, betrachtet. Hierbei werden die Gesamtkosten in Zellkosten, Kosten für die Leistungselektronik und Kosten für periphere Systeme aufgeteilt. Bei Heimsystemen machen die relativen Kosten für die leistungselektronischen Komponenten 42 % der Gesamtsystemkosten aus. Für die vorliegende Arbeit wird davon ausgegangen, dass die Kosten für die Leistungselektronik linear mit der Nennleistung des Batteriesystems steigen. Die geschätzten Kosten für das Batteriesystem, die aus [176] für das Jahr 2019 entnommen wurden, sind in Tabelle 7.1 aufgeführt.

Tabelle 7.1: Batterieinstallationskosten für 2019 [151].

Typ	Proz.	Kosten/Wert
Kapazität	42 %	130 €/kWh
Peripherie	28 %	87 €/kWh
Leistungselektronik	30 %	93 €/kW
Installation	-	20 000 €/batt
Batterielebensdauer	-	10 Jahre

Netzausbaukosten

Die spezifischen Ausbaukosten umfassen hauptsächlich Kabel- und Installationskosten. In Tabelle 7.2 sind die spezifischen Kosten für Kabel bzw. Leitungen nach Leitungstyp aufgeführt.

Die Kosten für das Verlegen von Kabeln können erheblich variieren, abhängig von der Bodenbeschaffenheit. Bei Ackerland belaufen sich die Kosten auf etwa 20 000 €/km, während sie sich bei steinigem Untergrund verdoppeln (40 000 €/km). In städtischen Gebieten, in denen neue Straßen gebaut werden müssen, können die Kosten auf bis zu 80 000 €/km ansteigen [177]. Es wird davon ausgegangen, dass die Installationskosten für jede zusätzliche parallele Leitung um etwa 15 % steigen. Zur Berechnung der jährlichen Kosten muss die Nutzungsdauer der Leitungen festgelegt werden. In der Regel wird für

Erdkabel eine Lebensdauer von 40 Jahren angesetzt [178], und die übliche Nutzungsdauer nach der Stromnetzentgeltverordnung beträgt ebenfalls 40 Jahre [179].

Tabelle 7.2: Netzausbaukosten für den automatisierten Netzausbau [151].

Leitungstyp	Kostentyp	Kosten
0.4 kV, $4 \times 50 \text{ mm}^2$	Installation	60 000 €/km
	Anschaffung	3500 €/km
0.4 kV $4 \times 120 \text{ mm}^2$	Installation	60 000 €/km
	Anschaffung	9900 €/km
0.4 kV $4 \times 150 \text{ mm}^2$	Installation	60 000 €/km
	Anschaffung	12 000 €/km
Parallele Leitung	Installation	zusätzliche 15% der Installationskosten
Trafo, 630 kVA	Gesamt	21 000 €

7.3.3 Automatisierter Netzausbau

Bei der Untersuchung von optimierten Netzausbaumaßnahmen mithilfe von Evolutionären Algorithmen wurde in [180] festgestellt, dass der optimale Netzausbau in strangförmigen Niederspannungsnetzen vornehmlich vom Trafo ausgehend stattfindet. Daraufhin wurde in dieser Arbeit ein heuristisches Verfahren zum automatisierten und bedarfsgerechten Netzausbau entwickelt [151]. Dieses Verfahren identifizierte die kritischen Knoten jedes Strangs und führte den Netzausbau so lange durch, bis die festgelegten Spannungsgrenzen an den jeweiligen Knoten erfüllt waren. Ein Flussdiagramm des verwendeten Algorithmus ist in Abbildung 7.7 dargestellt. Bei der Auswahl der günstigsten Optionen für den Netzausbau orientiert sich der Algorithmus an den Kosten, die in Tabelle 7.2 aufgeführt sind. In diesem Zusammenhang wurde auch beurteilt, ob es kosteneffektiver ist, mehrere kleinere Leitungen parallel zu verlegen oder eine größere Leitung zu installieren.

7.3.4 Optimierte Speicherplatzierung und Betrieb zur Netzentlastung

Ziel des Algorithmus ist die optimierte Platzierung von Batteriespeichersystemen zum Ausgleich von Spannungsverletzungen innerhalb des Niederspannungsnetzes. Das Ziel ist dabei die Minimierung der Installationskosten auf Basis von Tabelle 7.1 unter der Randbedingung, dass alle Netzgrenzen innerhalb ihrer Betriebsgrenzen liegen.

Der Algorithmus basiert auf einer linearisierten Lastflussmethode, die in Kapitel 4 [46] vorgestellt wurde, und dem Optimierungsproblem, welches in Kapitel 6.4 [53] verwendet wird. Das resultierende Optimierungsproblem wird mittels sukzessiver linearer Programmierung (SLP) gelöst. Die Spannungsabfälle im Verteilnetz werden mit dem oben erwähnten linearisierten Lastfluss-Algorithmus berechnet. Der Simulationszeitraum beträgt jeweils drei Tage in unterschiedlichen Jahreszeiten, wodurch mehrere Ladezyklen erfasst werden.

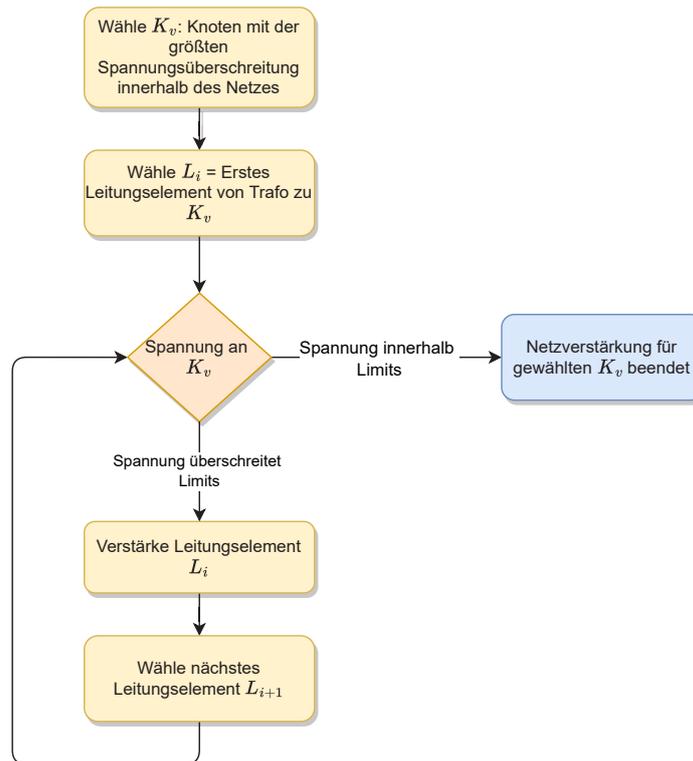


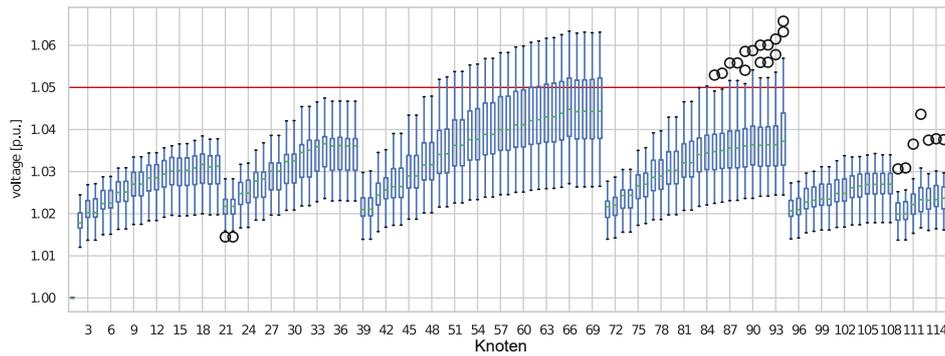
Abbildung 7.7 Flussdiagramm des heuristischen Netzausbaualgorithmus. Die oben gezeigte Methode wird für alle Stränge wiederholt [151].

Der die Auswirkungen der optimalen Batterieplatzierung und des Betriebs kann anhand einer Beispielrechnung gezeigt werden: In Abbildung 7.8a ist die Spannungssituation im Netz für einen Tag mit hoher solarer PV-Erzeugung und ohne installierte Batterie oder Drosselung der PV-Erzeugung dargestellt. Die Spannungsgrenze innerhalb des Netzes liegt bei 1,05 p.u., die hier in zwei Strängen überschritten wird. In Abbildung 7.8b ist die Spannungsverteilung bei Nutzung des optimierten Betriebs einer Batterie und Abregelung dargestellt: Die Spannungsgrenzen werden zu jeder Zeit eingehalten. Dazu wurde eine Batterie an Knoten 65 mit einer Größe von 83 kWh installiert.

7.3.5 Ergebnisse und Vergleich zwischen Batteriespeicherplatzierung und Netzausbau

Die Ergebnisse der Batterieplatzierung sind in Tabelle 7.3 für die verschiedenen Szenarien zusammengefasst. Für das Szenario mit einer Durchdringung von 50 % und einer maximalen Spannungsabweichung von 5 % relativ zu V_{nom} ist keine Batterieplatzierung erforderlich. Wird die maximale Spannungsabweichung auf 3 % verringert, müssen zwei Batterien platziert werden. Für das Szenario mit 80 % PV-Durchdringung ergibt sich eine maximale Spannungsabweichung von 5 % relativ zu V_{nom} und die Standorte der Batterien bleiben fast gleich wie zuvor, aber die Größe nimmt zu. Wird in diesem Fall die maximale Spannungsabweichung auf 3 % verringert, muss eine dritte Batterie hinzugefügt werden. Die Ergebnisse sind zusätzlich in Abbildung 7.9 dargestellt. Hier sind die Platzierungen für die 80 % PV-Durchdringung und beide Spannungsbegrenzungen in einem Diagramm dargestellt. In

- (a) Szenario ohne Batterie oder aktives Energiemanagement im Netz. Die Spannungsgrenze liegt bei 1,05 p.u. und wird deutlich überschritten.



- (b) Szenario mit optimal platzierten und gesteuerten Batterien (platziert an den Knoten 65 und 93). Die Spannungsgrenze werden eingehalten.

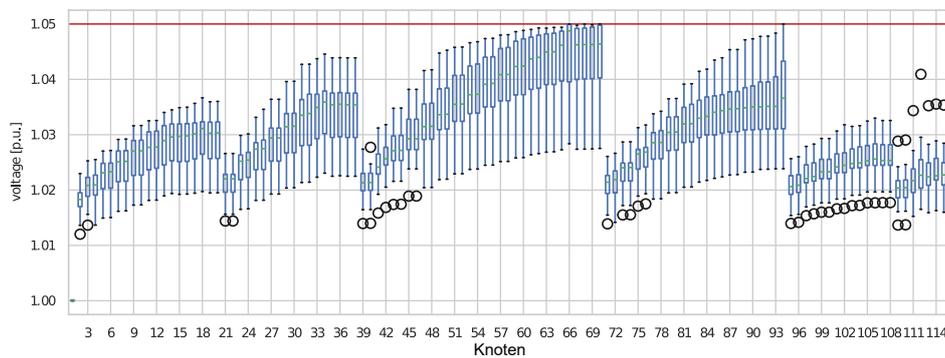


Abbildung 7.8 Die Abbildungen zeigen die Spannungsverteilungen an einem Tag mit hoher Photovoltaik-Erzeugung in einem Verteilnetz. Die Daten sind dargestellt als Box-Whisker-Plot mit den Whiskern auf 1,5-mal dem Interquartilbereich (IQR) und Kreisen, die die Ausreißer darstellen. [151].

allen Fällen variiert die Platzierung der Batterie nur geringfügig um ein oder zwei Knoten. Dies deutet darauf hin, dass die Lösungsfläche in Bezug auf die Position der Batterie im Netz relativ flach ist.

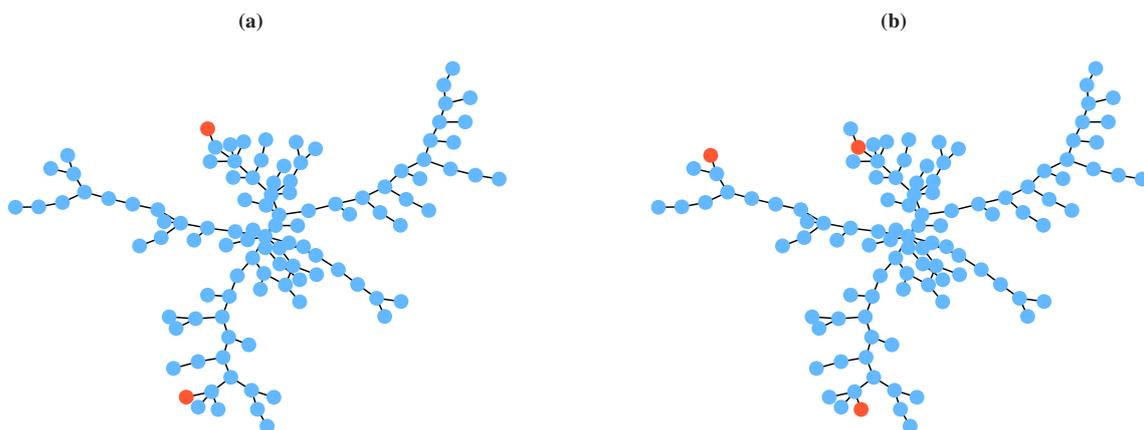


Abbildung 7.9 Optimale Batterieplatzierung für die Spannungsstabilität innerhalb des Testnetzes. (a) 50 % PV-Durchdringung, Spannungsgrenze 3 %. (b) 80 % PV-Durchdringung, Spannungsgrenze 3 % [151].

In diesem Abschnitt werden die Ergebnisse der Batterieplatzierung und des automatisierten Netzausbaus verglichen. Zudem werden einige Beschränkungen für die Anzahl der zu platzierenden Batterien

Tabelle 7.3: Größe, maximale Leistung und Lage der Batterien [151].

PV pen.	ΔV_{\max}	batt. 1		batt. 2		batt. 3	
		C [kWh]	Knoten #	C [kWh]	Knoten #	C [kWh]	Knoten #
50 %	5 %	-	-	-	-	-	-
	3 %	57	30	120	42	-	-
80 %	5 %	68	30	149	43	-	-
	3 %	497	29	426	45	116	59

hinzugefügt, um die Empfindlichkeit der Platzierung auf hinsichtlich der Anzahl von installierten Batterien zu untersuchen. Daher werden zwei zusätzliche Szenarien eingeführt: eines, bei dem die Anzahl der Batterien auf 5 festgelegt ist, und eines mit 10 Batterien.

Die Ergebnisse hinsichtlich der absoluten Investitionskosten sind in Tabelle 7.4 dargestellt. Die günstigste Lösung für die gegebenen Szenarien ist die Installation von Batterien zur Aufrechterhaltung der Netzspannungsstabilität. Die Kosten steigen mit zusätzlichen Batterien, obwohl die individuelle Größe der Batterien abnimmt. Die teuerste Option in Bezug auf die Investitionskosten ist der Netzausbau.

Tabelle 7.4: Gesamtkosten für die untersuchten Szenarien [151].

PV pen.	ΔV_{\max}	grid reinf.	5 batt.	10 batt.	unconstr.	
		[k€]	[k€]	[k€]	[k€]	[n batt.]
50 %	3%	710	113	163	83	2
	5%	-	-	-	-	-
80 %	3%	1679	290	340	287	3
	5%	488	104	154	74	2

Ein interessanterer Vergleich ist die Höhe der jährlichen Kosten, da die gerechnete Lebensdauer für Leitungen und Batteriespeicher unterschiedlich sind. In diesem Fall werden die Wartungskosten für die Batterie und das Netz vernachlässigt, da sie stark variieren. Wie bereits erwähnt, wird für die Batterie eine Lebensdauer von 10 Jahre, und die Lebensdauer der Kabel wird mit 40 Jahre angenommen. Die Ergebnisse dieses Vergleichs sind in Tabelle 7.5 dargestellt.

Tabelle 7.5: Jährlicher Kostenvergleich (angenommene Lebensdauer: Batterie=10 yr, Kabel=40 yr) [151].

PV Anteil	ΔV_{\max}	Netzausbau	5 Batterien	10 Batterien	Unbeschränkt	
		[k€]	[k€]	[k€]	[k€]	[n Batterien]
50%	3%	18	11	16	8	2
	5%	0	0	0	0	0
80%	3%	42	29	34	29	3
	5%	12	10	15	7	2

Das Ergebnis ist ähnlich wie bei den Investitionskosten, obwohl der Unterschied zwischen der Batterieplatzierung und der Netzausbau weniger ausgeprägt ist. Im gewählten Szenario ist die Installation von Batterien jedoch immer günstiger als der Netzausbau.

7.4 Zusammenfassung des Kapitels

Dieses Kapitel liefert eine umfassende Analyse zur optimalen Auslegung von Energiesystemen, bei der sowohl technische als auch ökonomische Aspekte in Betracht gezogen werden. Im Fokus stehen die Dimensionierung von PV-Speichersystemen, die Platzierung von Messstellen im Verteilnetz und die optimale Batterieplatzierung.

Im Kontext der PV-Speichersysteme stellt die Untersuchung fest, dass die sorgfältige Auswahl der Montageorte und Ausrichtungen von PV-Anlagen, insbesondere solche, die nicht nach Süden ausgerichtet sind, sowie der strategische Einsatz von Batteriespeichern, die Abregelungsverluste erheblich verringern können. Dies hat erhebliche Auswirkungen auf den effizienten weiteren Ausbau von DER in Netzen, in denen die Einspeiseleistung limitiert werden muss.

Die strategische Platzierung von Messstellen im Verteilnetz ist ein kritischer Faktor für die Zustandsschätzung im Netz. Die Verwendung einer Kostenfunktion zur Bestimmung der optimalen Platzierung kann die gesamte Messunsicherheit im Netz minimieren und die Beobachtbarkeit erhöhen, wodurch die Effizienz und Effektivität des Netzbetriebs verbessert wird. Dazu wurden in Kapitel 7.2 verschiedene Kostenfunktionen untersucht und bewertet sowie typische Regeln zur Messstellenplatzierung hergeleitet.

Die optimale Platzierung und Dimensionierung von Batteriespeichersystemen in Verteilungsnetzen trägt zur Reduzierung von Netzverlusten, zur Verbesserung der Spannungs- und Frequenzregulierung und zur Verringerung des Bedarfs an Netzausbau bei. Die gründliche Analyse von Faktoren wie Netzstruktur, geografische Verteilung der erneuerbaren Ressourcen und Einschränkungen des Leistungsflusses ist erforderlich, um optimale Ergebnisse zu erzielen. Das hier vorgestellte Verfahren ermöglicht eine effiziente Auslegung. Weitere Verbesserungen könnten die Berücksichtigung von Alterungsprozessen im Betrieb und der Platzierung sein. Vorschläge zur Modellierung und Implementierung werden in [181, 182] gegeben. Die hierfür notwendigen Alterungsmodelle sind in der Praxis für kommerziell verfügbare Batteriespeichersysteme allerdings selten verfügbar. Eine Analyse verschiedener Szenarien zeigt, dass unter den gegebenen Annahmen die Kosten für die Installation von Batterien zur Aufrechterhaltung der Netzspannungsstabilität konkurrenzfähig zum Netzausbau ist. Dieses Ergebnis ist stark von den getroffenen Annahmen abhängig und verschiebt sich Richtung Netzausbau oder Lastmanagement, wenn höhere Kosten für Speichersysteme anfallen.

Die Einbeziehung einer hohen Durchdringung von Distributed Energy Resources (DER) in zukünftige Energiesysteme erhöht die Komplexität und Notwendigkeit weiterer Ausbau und Investitionsstrategien. In diesem Kontext tragen die in diesem Kapitel behandelten Bereiche entscheidend dazu bei, eine sichere und zuverlässige Energieversorgung zu gewährleisten, während gleichzeitig die Investitionskosten minimiert und daher auch die Umweltauswirkungen verringert werden.

8 Zusammenfassung und Ausblick

Die Weiterentwicklung und Optimierung von Energieverteilnetzen mit einem hohen Anteil an dezentral eingespeister erneuerbarer Energie ist essenziell, jedoch bislang nicht vollständig entwickelt. Die Arbeit stellt Lösungsansätze bereit und zielt darauf ab, die Komplexität und Vielschichtigkeit der auftretenden Probleme im Bereich der Energieverteilung und -optimierung umfassend zu beleuchten.

8.1 Ergebnisse der Arbeit

Die vorliegende Arbeit befasst sich mit mehreren wesentlichen Aspekten im Zusammenhang mit der Integration erneuerbarer Energien und der Verbesserung der Energieeffizienz. Nachfolgend werden die wichtigsten Ergebnisse der Arbeit zusammengefasst.

8.1.1 Simulationsumgebung für komplexe Energiesysteme

Im Rahmen der Arbeit wurde eine wissenschaftliche Simulationsumgebung geschaffen, die als ganzheitliche Plattform zur Analyse, Optimierung und Bewertung komplexer Energiesysteme genutzt werden kann. Mit dieser Umgebung können neu entwickelten Methoden und Algorithmen, etwa zur optimierten Platzierung von Flexibilität und deren Betrieb, bewertet werden. Hierfür wurden detaillierte Modelle zu den thermischen Eigenschaften von Gebäuden, zu Wärmepumpen und Batteriespeichern, sowie PV-Ertragsprognosen und Netzsimulationen integriert. Die Modelle für Batteriespeichersysteme, Wechselrichter und Photovoltaik-Anlagen werden anhand von Messwerten validiert.

Ertragsabschätzung von PV-Anlagen: Die präzise Ertragsabschätzung von Photovoltaik (PV)-Anlagen erfüllt zwei essenzielle Funktionen: Sie steigert die Netztransparenz und ermöglicht eine fundierte Einschätzung der Netzkonsequenzen bei weiterem PV-Ausbau. Grundlage dieser Abschätzung sind Modelle, welche Faktoren wie Einstrahlung, Modulwirkungsgrad, Systemeffizienz und Wechselrichterwirkungsgrad miteinbeziehen. Die Zuverlässigkeit dieser Modelle wird durch einen Abgleich mit tatsächlich gemessenen Erzeugungswerten vom PV-Testfeld des ZSW bestätigt. Im Ergebnis kann der Ertrag von unbekanntem PV-Dachanlagen auf Basis von Satellitendaten mit einem nRMSE von 14,3 % geschätzt werden. Zudem dient die Ertragsabschätzung als Eingangsgröße für Simulationen, insbesondere wenn der tatsächliche PV-Ertrag unbekannt ist.

Effiziente Netztransparenz durch probabilistischen Lastfluss und Netzmodelle: In dieser Arbeit wird eine fortschrittliche probabilistische Lastflussmethode als Fundament für die Netztransparenz präsentiert. Diese Methode gründet auf dem Gauss'schen Fehlerfortpflanzungsgesetz (GEP; siehe Abschnitt 4.2.2). Sie erlaubt eine präzise Bestimmung des Netzzustandes unter Berücksichtigung unsicherer Verbrauchs- oder Einspeisungswerte. Verglichen mit ähnlichen Algorithmen zeichnet sich die GEP-Methode durch eine beachtliche Recheneffizienz aus: Selbst unter Einbeziehung von Fehlerkorrekturen ist sie circa fünfmal schneller als die Weighted Least Squares (WLS) Methode. Gleichzeitig ist das Problem so formuliert, dass es effizient in Energiemanagementalgorithmen verwendet werden kann.

8.1.2 Optimierung des Betriebs verteilter Erzeuger, Speicher und Lasten

Die Nutzung von elektrischer und thermischer Speicherkapazität über die Betriebsoptimierung von Batteriespeichern und Wärmepumpen ist eine wesentliche Maßnahme zur Integration von erneuerbaren Energien ins Energiesystem. Angesichts der begrenzten Vorhersagbarkeit von Erzeugung und Last im Verteilnetz und der Vielzahl an verteilten Systemen bei den Endkunden, sind die Auswahl von geeigneten Betriebsführungs-Algorithmen hinsichtlich Robustheit und Kommunikationsaufwand zwischen den Endgeräten, sowie die Platzierung der Speicher wichtige Fragestellungen, die in der Arbeit behandelt werden.

Einführung, Bewertung und Kategorisierung von Betriebsführungs-Algorithmen: In der Arbeit wird eine eingehende Analyse der Betriebsoptimierung verteilter Energieerzeuger und Speichersysteme durchgeführt. Dieser Abschnitt zielt darauf ab, ein fundiertes Verständnis der unterschiedlichen Algorithmen zu schaffen und ihre potenziellen Rollen und Beiträge zur Betriebsoptimierung verteilter Energieerzeuger und Speicher aufzuzeigen. Es wird eine eingehende Untersuchung der einzelnen Algorithmentypen und ihrer spezifischen Anwendungen innerhalb des Energiesystems durchgeführt. Dies stellt einen bedeutenden und innovativen Aspekt der Arbeit dar, deren Untersuchung und Verständnis neue Wege für effizientere und nachhaltigere Energiemanagementstrategien eröffnen.

Effiziente adaptive Modelle zur Betriebsoptimierung: Eine Herausforderung besteht darin, das zugrundeliegende Optimierungsproblem in effizienten Optimierungsmodellen abzubilden und Lösungen zu finden, die potenziell auch auf einfacher Hardware von Gebäudeenergiemanagementsystemen im Feld eingesetzt werden können. Dazu ist es notwendig, den thermischen Energiebedarf von Gebäuden unter Berücksichtigung von Wetterbedingungen und Heizleistung realistisch abzuschätzen und in die Optimierungsalgorithmen zu integrieren. Das in Kapitel 5.2 entwickelte adaptive thermische Gebäudemodell ermöglicht eine präzise Abschätzung des Energiebedarfs und der Innentemperatur und weist bei geringerer Komplexität die gleiche Prognosegüte auf wie nicht-adaptive Modelle höherer Ordnung. Im betrachteten Fall kann die Gebäudeinnentemperatur mit einer Genauigkeit von unter $0,5\text{ °C}$ vorhergesagt werden.

Optimierter Betrieb und Vorhersageunsicherheiten: Für die Optimierung des Betriebs verteilter Energieerzeuger und Speichersysteme im Niederspannungsnetz wurden verschiedene Algorithmen

und Methoden untersucht mit dem Ziel, die Betriebsführung zu verbessern und Vorhersageunsicherheiten zu berücksichtigen. In dieser Arbeit wird dargelegt, wie die Unsicherheit in der Prognose von Last und Erzeugung das Energiemanagement beeinflusst und welche Strategien entwickelt werden können, um diese Unsicherheiten zu bewältigen und die Betriebsoptimierung zu verbessern. So stellte sich in den Untersuchungen heraus, wie einerseits Prognosefehler in der Optimierung berücksichtigt werden können und andererseits durch Batteriespeicher ausgeglichen werden können. Im Ergebnis erhöhen sich die Betriebskosten bei einer Vorhersageunsicherheit von 10 % ohne Batteriespeicher um 8 %, mit einem Batteriespeicher allerdings nur um 2 %. Die negativen Auswirkungen eines Prognosefehlers können also durch ein Batteriesystem reduziert werden. Bei hohen Genauigkeitsanforderungen bietet sich eine robuste Optimierungsstrategie an, die jedoch kostenintensiver ist und die Betriebskosten um etwa 20 % erhöht.

8.1.3 Optimaler Systemausbau zur Integration erneuerbarer Energien

Auch bei optimiertem Betrieb kann die Infrastruktur bei weiterem Zubau an erneuerbaren Energien oder beim Hinzufügen elektrischer Lasten an Ihre Grenzen kommen. Im abschließenden Teil der Arbeit wird die Optimierung des Ausbaus der Infrastruktur diskutiert, sowie die Möglichkeit durch geeignete Platzierung von zusätzlichen Komponenten den Netzausbaubedarf im Verteilnetz zu reduzieren oder zu vermeiden.

Platzierung von Messstellen: Ein bedeutender Faktor für einen sicheren und effizienten Betrieb von Verteilnetzen ist die Erhöhung der Netztransparenz durch eine korrekte Platzierung von Messstellen. Für eine effiziente Platzierung dieser Messeinrichtungen kann der in Kapitel 7.2 entwickelte Algorithmus verwendet werden. Dabei wird mit jeder zusätzlich installierten Messstelle der Zuwachs an Netztransparenz maximiert. Damit kann im Fall von zwei Messstellen durch die optimale Platzierung im Netz die Spannungsunsicherheit gegenüber der ungünstigsten Platzierung halbiert werden.

Platzierung von Batterien im Verteilnetz: In Bezug auf die optimale Platzierung von Batteriespeichersystemen wurden verschiedene Faktoren wie die Verfügbarkeit von Energieressourcen, Netzbeschränkungen und Kosten berücksichtigt. Das Zielszenario besteht darin, eine zuverlässige, kostengünstige Energieversorgungsinfrastruktur bereitzustellen, die alle Energiebedarfe deckt und gleichzeitig die Netzgrenzen berücksichtigt. Die Methode erweitert den optimierten Betrieb mit einer Optimierung des Ortes, also der Platzierung im Netz. Eine optimale Batterieplatzierung und die Berücksichtigung von Netzgrenzen und Spannungsstabilität tragen zur effizienten Nutzung erneuerbarer Energien bei. Das Ergebnis zeigt, dass unter den angenommenen Rahmenbedingungen der Einsatz von Batteriespeichersystemen günstiger sein kann als der Netzausbau.

8.2 Ausblick

Mit der rasch voranschreitenden Digitalisierung und der zunehmenden Komplexität unserer Energieinfrastrukturen steigt der Bedarf und an effizienten und effektiven Ansätzen zur Optimierung des

Energiesystems. Ein vielversprechender Ansatz ist die hierarchische Optimierung. Dieser Ansatz strukturiert Optimierungsprobleme in mehrstufige, handhabbare Teilaufgaben, die auf unterschiedlichen Hierarchieebenen bearbeitet werden. Auf diese Weise lassen sich nicht nur Rechenzeiten minimieren, sondern häufig auch qualitativ bessere oder praktikablere Lösungen erzielen.

Ein zukünftiger Forschungsschwerpunkt könnte in der maßgeschneiderten Anpassung des hierarchischen Ansatzes an spezifische Netzstrukturen liegen, wobei nicht nur das Stromnetz, sondern auch sektorübergreifende Systeme wie H₂-Netze und Wärmenetze betrachtet werden sollten. Die Integration dieser unterschiedlichen Energienetze stellt eine zusätzliche Herausforderung dar, bietet aber auch große Chancen für Synergien und eine effizientere Energienutzung. Insbesondere die Entwicklung von Dekompositionsstrategien, die auf die spezifische Architektur und die Anforderungen von Energiemanagementsystemen zugeschnitten sind, verspricht eine deutliche Steigerung der Systemeffizienz und -leistung. Obwohl der hierarchische Optimierungsansatz ein erhebliches Potenzial bietet, sind erhebliche Forschungsanstrengungen erforderlich, um ihn vollständig zu realisieren und in verschiedenen Anwendungsszenarien adaptiv zu implementieren.

Ein weiteres vielversprechendes Forschungsfeld könnte in der Differenzierung und Verfeinerung der Entscheidungsebenen innerhalb des hierarchischen Ansatzes liegen. Die Unterteilung in strategische, operative und taktische Ebenen, die lang-, mittel- und kurzfristige Entscheidungen abdecken, könnte bei integrativer Ausgestaltung zu einer optimierten Balance zwischen Energieeffizienz, Kosteneinsparung und Systemzuverlässigkeit führen. In diesem Zusammenhang sollte auch der sektorübergreifenden Optimierung und Steuerung von Energienetzen besondere Aufmerksamkeit geschenkt werden, um die Vorteile vernetzter Systeme voll auszuschöpfen.

8.2.1 Anreizbasierte Steuerung des Energiesystems

Zeitvariable Energietarife und Netzentgelte werden eine zentrale Rolle bei der Förderung von Netzstabilität und Effizienz spielen. Dadurch werden Anreiz für Verbraucher und Energieerzeuger generiert, ihre Energienutzung und -produktion an das Angebot an Strom aus erneuerbaren Energien bzw. an die jeweilige Netzbelastung anzupassen. In Zeiten hoher Netzlast könnten höhere Netzentgelte dazu beitragen, den Energieverbrauch zu dämpfen, während niedrigere Entgelte in Zeiten niedrigerer Auslastung den Verbrauch ankurbeln könnten. In ihrer Realisierung können diese Anreizsignale auch zeitweise negativ sein, um einen besonderen Anreiz für einen zeitlich begrenzten erhöhtem Verbrauch zu erzeugen. Im Durchschnitt müssen diese Anreize dann wieder genug Ertrag erwirtschaften, um die Investitionen in die Netzinfrastruktur und in die Erzeugungsstruktur abzudecken.

Die Implementierung solcher Mechanismen kann auf dieser Arbeit aufbauen und dazu beitragen, die Effizienz der Netzinfrastruktur zu verbessern, teuren Netzausbau zu verringern und die Integration erneuerbarer Energien zu unterstützen. Sie ermöglichen Verbrauchern, ihren Energieverbrauch an Zeiten mit hoher Verfügbarkeit von erneuerbaren Energien anzupassen, was zur Netzstabilität beiträgt.

A Anhang

A.1 Matrizengleichungen der Gebäudemodelle

1R1C-Modell:

$$\dot{T}_{\text{in}} = [-C_i \cdot U_{\text{ia}}] [T_{\text{in}}] + [U_{\text{ia}} C_i^{-1} \quad C_i^{-1}] \begin{bmatrix} \dot{Q}_{\text{int}} + \dot{Q}_{\text{h}} + k_{\text{sun}} \cdot \text{GHI} \\ T_{\text{a}} \end{bmatrix} \quad (\text{A.1})$$

3R2C-Modell:

$$\begin{bmatrix} \dot{T}_{\text{in}} \\ \dot{T}_{\text{w}} \end{bmatrix} = \begin{bmatrix} -C_i^{-1} (U_{\text{ia}} + U_{\text{iw}}) & C_i^{-1} U_{\text{iw}} \\ C_w^{-1} U_{\text{iw}} & -C_w^{-1} (U_{\text{wa}} + U_{\text{iw}}) \end{bmatrix} \begin{bmatrix} T_{\text{in}} \\ T_{\text{w}} \end{bmatrix} + \begin{bmatrix} C_i^{-1} & 0 & C_i^{-1} U_{\text{ia}} \\ 0 & C_i^{-1} & U_{\text{wa}} C_w^{-1} \end{bmatrix} \begin{bmatrix} \dot{Q}_{\text{int}} + \dot{Q}_{\text{h}} + k_{\text{sun}} \cdot \text{GHI} \\ k_{\text{sun}} \cdot \text{GHI} \\ T_{\text{a}} \end{bmatrix} \quad (\text{A.2})$$

A.2 Netzmodelle

In diesem Abschnitt werden die wichtigsten in der Arbeit genutzten Netzmodelle vorgestellt. Ziel war es, die entwickelten Algorithmen anhand verschiedener Netzstrukturen wie Strang-Netze, Vermaschte-Netze und Netze mit verschiedenen Spannungsebenen zu testen.

Einfaches synthetisches Netz mit Ringschluss

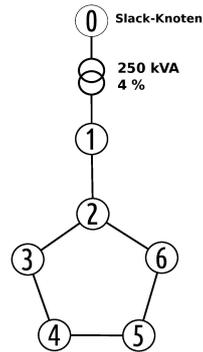


Abbildung A.1 Aufbau des einfachen Netzes

Das erste Netz ist ein einfaches Ringnetz: einen Slack-Knoten (10 kV) und sechs PQ-Knoten (0,4 kV). Der Transformator verbindet den Slack-Knoten (auch Bilanzknoten genannt) und den Knoten 1 miteinander. Die Nennscheinleistung des Transformators beträgt 0,25 MVA und die relative Kurzschlussspannung 4 %. Alle Leitungen haben dieselben Längen und sind vom gleichen Leitungstyp. Den Aufbau des Netzes zeigt Abbildung A.1.

Dorfnetz

Das untersuchte Niederspannungsnetz mit 0,4 kV basiert auf einem realen Netz, welches primär aus Strängen besteht. Gespeist wird es von einem 10 kV Mittelspannungsnetz durch einen Ortsnetztransformator mit einer Nennscheinleistung von 630 kVA. Das Netz umfasst insgesamt 106 Knoten, wobei 55 davon Anschlusspunkte für Wohngebäude sind.

Basierend auf dem Gebäudestandard wurden Annahmen über den Einsatz von Wärmepumpen getroffen und mithilfe der Dachflächen das mögliche PV-Potential bestimmt. Somit sind 32 Gebäude im Netz mit einer PV-gekoppelte Wärmepumpe ausgestattet und weitere 18 Gebäude mit einer Wärmepumpe ohne PV.

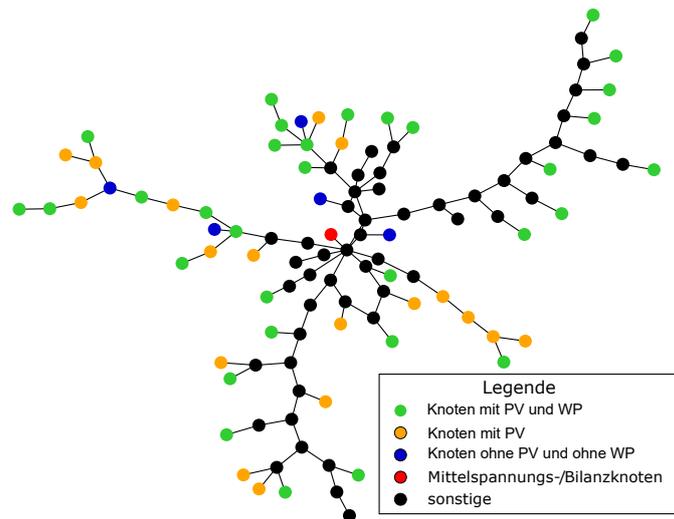


Abbildung A.2 Aufbau des Dorfnetzes aus einem Testgebiet [21, 28].

Synthetisches Netz mit mehreren Spannungsebenen

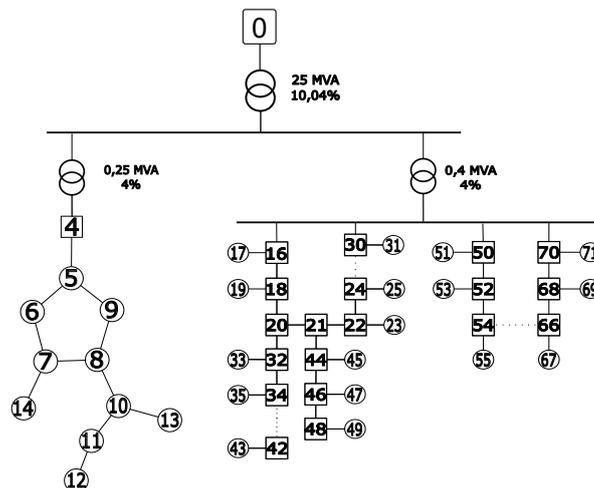


Abbildung A.3 Komplexes Netz mit mehreren Spannungsebenen

Das elektrische Netz umfasst drei Transformatoren. Der erste Transformator verbindet den Bilanzknoten (110 kV) mit der Sammelschiene (10 kV). Der zweite Transformator integriert ein kleineres Niederspannungsnetz an den Knoten 2 auf der Mittelspannungsebene. Der dritte Transformator verbindet ein größeres, vermaschtes Netz mit der Mittelspannungsebene.

Die Lastknoten und Muffen des Netzes sind jeweils durch Kreise bzw. Rechtecke gekennzeichnet. Zwei spezifische Leitungen (zwischen den Knoten 1-2 und 1-3) sind vom Typ 149-AL1/24-ST1A 10.0. Das kleinere Niederspannungsnetz besteht ausschließlich aus Leitungen des Typs NFA2X 4 x 70 mm².

Im größeren Niederspannungsnetz werden die Muffen mit den Lastknoten durch Leitungen vom Typ NAYY 4 x 50 mm² und die Muffen untereinander durch Leitungen vom Typ NAYY 4 x 150 mm² verbunden. Die Struktur des Netzes kann aus der dazugehörigen Abbildung entnommen werden.

A.3 Modellierung der Photovoltaik-Erzeugung

Berechnung der Sonnenposition

Das Direktstrahlungs- und das Diffusstrahlungsmodell benötigen als Eingangsparameter die Position der Sonne. Durch die Winkel der Sonnenhöhe γ_S und Sonnenazimut α_S ist die Position der Sonne eindeutig bestimmt. Nach DIN 5034-2 gilt für den Sonnenazimutwinkel folgende Konvention: N $\hat{=}$ 0°, O $\hat{=}$ 90°, S $\hat{=}$ 180°, W $\hat{=}$ 270°.

Die vom NREL entwickelten Algorithmen SOLPOS und SPA [183] versprechen eine höhere Genauigkeit bei der Berechnung des Sonnenstandes als der in [184] beschriebene DIN-Algorithmus. Diese Arbeit basiert auf der Berechnung der Position der Sonne mit einer Genauigkeit von 0,003 Grad unter Verwendung des SPA-Algorithmus. Die Winkeldefinition von γ_S und α_S ist sowohl für den DIN- als auch für den SPA-Algorithmus gleich.

Berechnung der Strahlung auf die geneigte Ebene

Die Strahlung auf die geneigte Ebene POA setzt sich aus der Summe der Komponenten Direktstrahlung (BI), reflektierte Strahlung REF und Diffusstrahlung (DI) auf die geneigte Ebene zusammen:

$$POA = BI + REF + DI \quad (A.3)$$

Sind γ_S und α_S bekannt, kann der Einfallswinkel des Sonnenlichtes auf eine geneigte Fläche mit dem Anstellwinkel γ_E und dem Azimutwinkel α_E berechnet werden.

$$\theta = \arccos(-\cos \gamma_S \cdot \sin \gamma_E \cdot \cos(\alpha_S - \alpha_E) + \sin \gamma_S \cdot \cos \alpha_S) \quad (A.4)$$

Stehen keine Messdaten für die Direktstrahlung (NBI, Normal Beam Irradiance) zur Verfügung, lässt sich diese aus GHI, DHI und dem Zenitwinkel θ_Z berechnen: Der Zenitwinkel θ_Z kann direkt aus der Sonnenhöhe γ_S abgeleitet werden. Die Direktstrahlung auf die geneigte Fläche BI lässt sich unmittelbar geometrisch anhand von Sonnenstand und Ausrichtung der Fläche θ berechnen.

$$\begin{aligned} NBI &= \frac{(GHI - DHI)}{\cos \theta_Z} \\ \theta_Z &= 90^\circ - \gamma_S \\ BI &= NBI \cdot \cos \theta \end{aligned} \quad (A.5)$$

Die reflektierte Strahlung auf die geneigte Fläche REF kann durch einen isotropen Ansatz berechnet werden. Der Albedowert A , welcher das Rückstrahlvermögen der Umgebung beschreibt, hat dabei den größten Einfluss auf die Berechnung der reflektierten Strahlung. Ist von einer Umgebung der Albedowert nicht bekannt, wird meist $A = 0,2$ verwendet [184].

$$REF = GHI \cdot A \cdot \frac{1}{2} \cdot (1 - \cos \gamma_E) \quad (A.6)$$

A.3.1 Diffusionsstrahlungsmodelle

Die Umrechnung der Diffusstrahlung von der horizontalen auf die geneigte Fläche stellt eine größere Herausforderung dar, denn dafür muss eine Modellannahme über die Verteilung der diffusen Himmelsstrahlung verwendet werden. Neben dem einfachsten Ansatz des isotropen Diffusstrahlungsmodell gibt es zahlreiche weitere anisotrope Modelle [185]. Diese sind im Folgenden kurz beschrieben und wurden in Python implementiert. Hierzu wurde teilweise eine frühe Version der PVlib verwendet [186].

Isotropes Diffusstrahlungsmodell

Das isotrope Diffusstrahlungsmodell geht davon aus, dass die Diffusstrahlung gleichmäßig, über den Himmelshalbraum verteilt ist. Die diffuse Strahlung auf der geneigten Ebene

$$DI = DHI \cdot \frac{1}{2} \cdot (1 + \cos \gamma_E) \quad (\text{A.7})$$

reduziert sich im Vergleich zu dem Anteil auf der Horizontalen, da ein Teil der diffusen Strahlung hinter der Ebene verschwindet.

Hay und Davies Diffusstrahlungsmodell

Das Diffusstrahlungsmodell von Hay und Davies [187] geht davon aus, dass die diffuse Strahlung im Himmelsbereich nahe der Sonnenscheibe stärker ist als im übrigen Halbraum. Daher unterscheidet es zwischen einer isotropen und einer zirkumsolaren Komponente. An klaren Tagen ist der zirkumsolare Anteil größer, als an bedeckten Tagen. Wie groß der Anteil der zirkumsolaren Strahlung ist, wird über einen Anisotropieparameter

$$A_I = \frac{NBI}{I_{\text{ex}}}, \quad (\text{A.8})$$

welcher als Verhältnis von NBI zur extraterrestrischen Strahlung I_{ex} definiert ist, bestimmt. Mit dem Anisotropieparameter wird die Diffusstrahlung auf die geneigte Ebene durch

$$DI = DHI \cdot \left(\underbrace{A_I \cdot \cos \theta}_{\text{zirkumsolarer Anteil}} + \underbrace{(1 - A_I) \cdot \frac{1}{2} \cdot (1 + \cos \gamma_E)}_{\text{diffuser Anteil}} \right) \quad (\text{A.9})$$

berechnet.

Reindl Diffusstrahlungsmodell

Das Reindl Modell ist eine Erweiterung des Modells von Hay and Davies, wobei das Modell von Reindl als zusätzliche Komponente die Horizontaufhellung berücksichtigt [188]. Die Diffusstrahlung auf die geneigte Ebene

$$DI = DHI \cdot \left(\underbrace{A_I \cdot \cos \theta}_{\text{zirkumsolarer Anteil}} + \underbrace{(1 - A_I) \cdot \frac{1}{2} \cdot (1 + \cos \gamma_E)}_{\text{isotroper Anteil}} \cdot \underbrace{\left(1 + \sqrt{\frac{NBI \cdot \cos \theta_Z}{GHI}} \cdot \sin^3 \left(\frac{\gamma_E}{2} \right) \right)}_{\text{Horizonthelligkeits-Anteil}} \right) \quad (\text{A.10})$$

berechnet sich mit dem Anisotropieparameter A_I wie er im Abschnitt Hay und Davies Diffusstrahlungsmodell definiert ist.

Klucher Diffusstrahlungsmodell

Das Modell von Klucher berücksichtigt neben der isotropen und der zirkumsolaren Strahlungskomponente, ebenso wie das Reindl Modell, noch die Zunahme der Helligkeit am Horizont. Dieses Modell verwendet einen Anisotropieparameter

$$F = 1 - \left(\frac{DHI}{GHI} \right)^2, \quad (\text{A.11})$$

welcher jedoch im Gegensatz zu dem Anisotropieparameter A_I von Hay und Davies, das Verhältnis der Diffusstrahlung zur Globalstrahlung beschreibt. Bei vollständiger Bewölkung wird $F = 0$ und die Diffusstrahlung auf die geneigte Ebene

$$DI = DHI \cdot \frac{1}{2} \cdot \underbrace{(1 + F \cdot \cos^2 \theta \cdot \cos^3 \gamma_S)}_{\text{zirkumsolarer Anteil}} \cdot \underbrace{(1 + F \cdot \sin^3 \frac{\gamma_E}{2})}_{\text{Horizonthelligkeits-Anteil}} \cdot \underbrace{(1 + \cos \gamma_E)}_{\text{isotroper Anteil}} \quad (\text{A.12})$$

besteht nur noch aus dem isotropen Anteil [189].

King Diffusstrahlungsmodell

Das von David King an den Sandia National Laboratories entwickelte Diffusstrahlungsmodell ist ein empirisches Modell für den Standort Sandia. Speziell an diesem Standort hat dieses Modell im

Vergleich zu den anderen Modellen am Besten abgeschnitten [190] (sandia sky diffuse model). Die Diffusstrahlung auf die geneigte Ebene

$$DI = \underbrace{DHI \cdot \frac{1 + \cos \gamma_E}{2}}_{\text{isotroper Anteil}} + \underbrace{GHI \cdot \frac{(0,12\theta_Z - 0,04) \cdot (1 - \cos \gamma_E)}{2}}_{\text{empirischer Anteil}} \quad (\text{A.13})$$

berechnet sich aus dem isotropen Anteil und aus einer empirischen Korrekturformel, welche dem zirkumsolaren und dem Horionthelligkeits-Anteil Rechnung trägt.

Perez Diffusstrahlungsmodell

Richard Perez hat ein komplexeres Modell entwickelt, welches auf der empirischen Auswertung von Messungen und der Ableitung von Koeffizienten aus den Messergebnissen basiert. Die Messungen wurden größtenteils in den USA, aber auch in der Schweiz und Frankreich durchgeführt [191–193]. Bei der Berechnung der Diffusstrahlung auf die geneigte Ebene

$$DI = DHI \cdot \left(\underbrace{\frac{1}{2} \cdot (1 + \cos \gamma_E) \cdot (1 - F_1)}_{\text{isotroper Anteil}} + \underbrace{\frac{a}{b} \cdot F_1}_{\text{Horionthelligkeits-Anteil}} + \underbrace{\sin \gamma_E \cdot F_2}_{\text{zirkumsolarer Anteil}} \right) \quad (\text{A.14})$$

gewichtet der Horionthelligkeitsindex F_1 den Horionthelligkeits-Anteil und der Sonnenumgebungs-helligkeitsindex F_2 den zirkumsolarer Diffusstrahlungsanteil.

$$\begin{aligned} F_1 &= F_{11}(\varepsilon) + F_{12}(\varepsilon)\Xi + F_{13}(\varepsilon)\theta_Z \\ F_2 &= F_{21}(\varepsilon) + F_{22}(\varepsilon)\Xi + F_{23}(\varepsilon)\theta_Z \end{aligned} \quad (\text{A.15})$$

Der Parameter $a = \max(0; \cos \theta)$ stellt sicher, dass der Wert für den Einfallswinkel des Sonnenlichts θ nicht größer als 90° ist. Der Parameter $b = \max(0,087; \sin \gamma_S)$ lässt den Wert für die Sonnenhöhe nicht kleiner als 5° werden.

Mit der Air Mass

$$AM = \frac{1}{\sin \gamma_S}, \quad (\text{A.16})$$

welche ein relatives Maß für die Länge des Weges, den das Sonnenlicht durch die Atmosphäre bis zum Erdboden zurücklegt, ist, lässt sich der Helligkeitsindex

$$\Xi = AM \cdot \frac{DHI}{I_{\text{ex}}} \quad (\text{A.17})$$

mit der extraterrestrischen Strahlung I_{ex} berechnen.

Die durchlässigkeit der Atmosphäre ist anhand von Himmelsklarheitsklassen (ε -Klasse) definiert. Die Himmelsklarheitsklassen reichen von stark bewölkt ($\varepsilon = 1$) bis klar ($\varepsilon = 8$).

Tabelle A.1 zeigt die Himmelsklarheitsklassen aus [193], welche abhängig von der ε -Klasse die Koeffizienten F_{11} - F_{23} ausgibt, mit welchen wiederum F_1 und F_2 berechnet werden können. ε ist der Himmelsklarheitsindex. Dabei ist die Konstante $\kappa = 1,041$ und der Sonnenzenitwinkel θ_Z in rad gemessenen.

$$\varepsilon = \frac{\frac{\text{DHI} + \text{NBI} \cdot \sin^{-1} \gamma_S}{\text{DHI}} + \kappa \cdot \theta_Z^3}{1 + \kappa \cdot \theta_Z^3} \quad (\text{A.18})$$

A.3.2 Schätzung der Direktstrahlung aus der Globalstrahlung

Um die Direktstrahlung NBI oder die Diffusstrahlung DHI zu ermitteln, kann die Globalstrahlung GHI mit verschiedenen Modellen berechnet werden. Das DISC-Modell von E. L. Maxwell [194] schätzt die Direktstrahlung NBI direkt aus der Globalstrahlung GHI und der Sonnenposition. Die extraterrestrische Strahlung in der Horizontalen und die Globalstrahlung in der Globalstrahlung GHI bestimmen den Faktor Kt .

$$Kt = \frac{\text{GHI}}{I_{\text{exh}}} \quad (\text{A.19})$$

Für $Kt \leq 0,6$ gilt:

$$\begin{aligned} a_{Kt} &= 0,512 - 1,56 \cdot Kt + 2,286 \cdot Kt^2 - 2,222 \cdot Kt^3 \\ b_{Kt} &= 0,37 + 0,962 \cdot Kt \\ c_{Kt} &= -0,28 + 0,932 \cdot Kt - 2,048 \cdot Kt^2 \end{aligned} \quad (\text{A.20})$$

und für $Kt > 0,6$ gilt:

$$\begin{aligned} a_{Kt} &= -5,743 + 21,77 \cdot Kt - 27,49 \cdot Kt^2 + 11,56 \cdot Kt^3 \\ b_{Kt} &= 41,40 - 118,5 \cdot Kt + 66,05 \cdot Kt^2 + 31,9 \cdot Kt^3 \\ c_{Kt} &= -47,01 + 184,2 \cdot Kt - 222 \cdot Kt^2 + 73,81 \cdot Kt^3 \end{aligned} \quad (\text{A.21})$$

Der Faktor Kn_c ist ein Maß für die Transmission der Direktstrahlung an einem klaren Tag ist. Mit diesem kann der Faktor für die Transmission der Direktstrahlung abhängig vom aktuellen Bewölkungsgrad α und damit die Direktstrahlung senkrecht zur Sonneneinstrahlung NBI ermittelt werden:

$$\alpha = a_{Kt} + b_{Kt} \cdot \exp(c_{Kt} \cdot AM) \quad (\text{A.22})$$

$$\beta = 0,866 - 0,122 \cdot AM + 0,0121 \cdot AM^2 - 0,000653 \cdot AM^3 + 1,4e^{-5} \cdot AM^4$$

$$\text{NBI} = (\alpha - \beta) \cdot I_{\text{ex}}$$

Tabelle A.1: Konstanten zur Bestimmung von F_1 und F_2 in Abhängigkeit von ε [193].

ε -Klasse	1	2	3	4	5	6	7	8
ε	1,000- 1,065	1,065- 1,230	1,230- 1,500	1,500- 1,950	1,950- 2,800	2,800- 4,500	4,500- 6,200	6,200- ∞
F_{11}	-0,008	0,130	0,330	0,568	0,873	1,132	1,060	0,678
F_{12}	0,588	0,683	0,487	0,187	-0,392	-1,237	-1,600	-0,327
F_{13}	-0,062	-0,151	-0,221	-0,295	-0,362	-0,412	-0,359	-0,250
F_{21}	-0,060	-0,019	0,055	0,109	0,226	0,288	0,264	0,156
F_{22}	0,072	0,066	-0,064	-0,152	-0,462	-0,823	-1,127	-1,377
F_{23}	-0,022	-0,029	-0,026	-0,014	0,001	0,056	0,131	0,251

A.3.3 PV-Modul Modellierung

Tabelle A.2: Koeffizienten zur Berechnung des relativen Modulwirkungsgrades [38]

	k_1	k_2	k_3 [K^{-1}]	k_4 [K^{-1}]	k_5 [K^{-1}]	k_6 [K^{-2}]
c-Si	-0,017162	-0,040289	-0,004681	0,000148	0,000169	0,000005
CIS	-0,005521	-0,038492	-0,003701	-0,000899	-0,001248	0,000001
CdTe	-0,103251	-0,040446	-0,001667	-0,002075	-0,001445	-0,000023

Tabelle A.3: Temperaturkoeffizient c_{temp} zur Berechnung der Modultemperatur [40].

Montageart	c_{temp}
Freiflächenanlagen	0,020
Anlagen auf geneigten Dächern; Abstand > 10 cm	0,027
Anlagen auf geneigten Dächern; Abstand < 10 cm	0,036
dachintegrierte Anlagen	0,058

Tabelle A.4: Temperaturkoeffizienten a und b zur Berechnung der Modultemperatur [39].

Modultyp	Montageart	a	b
Glas/Zelle/Glas	Freilandfläche	-3,47	-0,0594
Glas/Zelle/Glas	Dachanlage	-2,98	-0,0471
Glas/Zelle/Polymer	Freilandfläche	-3,56	-0,075
Glas/Zelle/Polymer	Gebäudeintegriert	-2,81	-0,0455
Polymer/Dünnschicht/Stahl	Freilandfläche	-3,58	-0,113
22 x Linearer Konzentrator	Tracker	-3,23	-0,13

Tabelle A.5: Koeffizienten zur Berechnung des Wechselrichterwirkungsgrades [41].

Dimensionierung [$P_{\text{Nenn_PV}}/P_{\text{Nenn_WR}}$]	k_0	k_1	k_2
1,00	0,0079	0,0411	0,0500

A.4 Alternating Direction Method of Multipliers (ADMM)

A.4.1 Szenario

Tabelle A.6: Simulationsszenario ADMM. Die Überlinie (⌊) stellt jeweils das obere Limit dar, die Unterlinie (⌋) das untere Limit.

Anzahl der Anlagen	3
Δt	900 s
t_h (MPC-Vorhersagehorizont)	24 h / 96 Zeitschritte
Last- und Erzeugungsprofile	gemessene Profile
α -ADMM-Strafparameter	variabel
α -ADMM max. Iterationen	variabel
Energiekosten	variabel
μ	200
τ^{dec}	10
τ^{inc}	2
ϵ_{ADMM}	10^{-3}
\bar{P}_{RES}	30 kW
\bar{P}_{demand}	50 kW
\bar{P}_{grid}	10 kW
C_{batt}	20 kW h
\bar{P}_{batt}	20 kW
Δt_{opt}	15 min
$\bar{v}_{grid, EC}$	variabel

A.4.2 Beschreibung des ADMM-Algorithmus

ADMM steht für „Alternating Direction Method of Multipliers“. Es handelt sich dabei um einen Algorithmus, der Optimierungsprobleme löst, die aus mehreren, über Nebenbedingungen gekoppelten Zielfunktionen bestehen.

In allgemeiner Form kann ein solches Optimierungsproblem folgendermaßen aussehen [147]:

$$\begin{aligned} \arg \min_{x,z} \quad & f(\mathbf{x}) + g(\mathbf{z}) \\ \text{s.t.} \quad & \mathbf{Ax} + \mathbf{Bz} = \mathbf{c} \end{aligned} \quad (\text{A.23})$$

mit den Variablen $\mathbf{x} \in \mathbb{R}^n$, $\mathbf{z} \in \mathbb{R}^m$ und den Matrizen $\mathbf{A} \in \mathbb{R}^{p \times n}$, $\mathbf{B} \in \mathbb{R}^{p \times m}$ zu lösen.

Um dieses Problem zu lösen, verwendet ADMM eine Hilfsfunktion, die als Lagrange Funktion bezeichnet wird. Diese Funktion L_ρ sieht folgendermaßen aus:

$$L_\rho(x, z, \lambda) = f(x) + g(z) + \lambda^T (Ax + Bz - c) + \frac{\rho}{2} \|Ax + Bz - c\|_2^2 \quad (\text{A.24})$$

Dabei sind f und g die Zielfunktionen, A , B und c definieren die Nebenbedingungen, λ sind die Lagrange-Multiplikatoren und ρ ist ein Skalar, der als Strafterm oder Regularisierungsparameter dient.

Der ADMM teilt das Optimierungsproblem auf in leichter zu lösende Subprobleme, die dann iterativ gelöst werden. Die Hauptidee des ADMM ist, das ursprüngliche Problem iterativ zu lösen, indem abwechselnd über x und z minimiert und danach die Lagrange-Multiplikatoren λ aktualisiert werden:

$$\begin{aligned} x_{k+1} &= \arg \min_x L_\rho(x, z_k, \lambda_k) \\ z_{k+1} &= \arg \min_z L_\rho(x_{k+1}, z, \lambda_k) \\ \lambda_{k+1} &= \lambda_k + \rho(Ax_{k+1} + Bz_{k+1} - c) \end{aligned} \quad (\text{A.25})$$

Jeder Schritt minimiert L_ρ in Bezug auf eine Variable, während die anderen Variablen auf ihren aktuellen Werten gehalten werden. Die Konvergenz des Algorithmus wird durch die Überwachung der primäre (r) und duale Residuen (s) sichergestellt:

$$\begin{aligned} r_{k+1} &= Ax_{k+1} + Bz_{k+1} - c \\ s_{k+1} &= \rho A^T B(z_{k+1} - z_k) \end{aligned} \quad (\text{A.26})$$

Der Algorithmus wird beendet, wenn die Bedingungen für die primären und dualen Residuen erfüllt sind:

$$\begin{aligned} \|r_k\|_2 &\leq \epsilon_{\text{ADMM}} \cdot \max\{\|Ax_k\|_2, \|Bz_k\|_2, \|c\|_2\} \\ \|s_k\|_2 &\leq \epsilon_{\text{ADMM}} \cdot \|\rho A^T \lambda_k\|_2 \end{aligned} \quad (\text{A.27})$$

Adaptive ADMM (a-ADMM)

Die Wahl des Regularisierungsparameters ρ kann kritisch sein und beeinflusst sowohl die Konvergenzgeschwindigkeit als auch die Qualität der Lösung. Eine Strategie besteht darin, den Strafterm ρ in jeder Iteration anzupassen, wodurch der a-ADMM entsteht [147]. Das Anpassungsschema ist wie folgt:

$$\rho_{k+1} = \begin{cases} \tau_{\text{incr}} \rho_k & \text{wenn } \|r_k\|_2 > \mu \|s_k\|_2 \\ \frac{\rho_k}{\tau_{\text{decr}}} & \text{wenn } \|s_k\|_2 > \mu \|r_k\|_2 \\ \rho_k & \text{sonst} \end{cases} \quad (\text{A.28})$$

Abbildungsverzeichnis

1.1	Funktionaler Zusammenhang und Aufbau der Arbeit, angelehnt an ein Flussdiagramm.	5
2.1	MPC Diagramm	10
2.2	Übersicht über die Netzebenen (in Anlehnung an [10]).	11
3.1	Funktionaler Aufbau des Simulationsmodells.	16
3.2	Modell des Referenzgebäudes	17
3.3	Temperaturverteilung im thermischen Schichtspeicher.	18
3.4	Schema einer Wärmepumpe mit eingezeichneten Teilkreisen	18
3.5	Berechnung des Wärmepumpen-Wirkungsgrades.	19
3.6	Vergleich des Modells [21] und der Referenzkennlinie [34] über die Teillastbereiche.	22
3.7	Batterie Systemwirkungsgrad für verschiedene Entladetiefen.	24
3.8	Validation des Batteriemodells für hohe SOC Bereiche.	24
3.9	Vergleich der Strahlungsmodelle	27
3.10	Abschätzung der PV-Erzeugung aus Satellitendaten	28
4.1	Leitungsmodell für das Niederspannungsnetz	34
4.2	Phasendiagramm der Niederspannungsnetz-Approximation	34
4.3	Ein kleines illustratives Netz als Beispiel für die Berechnung der Strommatrix M_I [46].	35
4.4	Verteilung der Kreuzkorrelation r zwischen verschiedenen Haushaltslastprofilen. . .	40
4.5	Schätzfehler der Standardabweichung beim probabilistischen Lastfluss.	40
4.6	Vergleich der probabilistischen Lastflussmethoden.	41
5.1	Vergleich zwischen vereinfachtem Tankmodell und Knotenmodell	50
5.2	Strukturelle Darstellung der thermischen Gebäudemodelle	50
5.3	Vergleich der Temperaturzeitreihen von RC-Modellen über unterschiedliche Zeiträume.	51
5.4	Vergleich der thermischen Gebäudemodelle	52
5.5	Konvergenz der Parameter eines synthetischen 1R1C-Modells	55
5.6	Konvergenz des 1R1C-Temperaturmodells.	56
5.7	Vergleich der T_{in} -Vorhersagegenauigkeit des adaptiven 1R1C-Modells und des 3R2C-Modells.	56
6.1	Einordnung von Energiemanagement Algorithmen in verschiedene Klassen bezüglich zentrale und dezentrale Algorithmen.	62
6.2	Beispiel einer kombinierten deterministischen und probabilistischen Vorhersage. . .	65
6.3	Regelbasierte Verfahren [124].	67
6.4	Beispiel eines zeitvariablen Stromtarifs.	68
6.5	Eigenverbrauchs-niveau versus Windenergienutzung bei variablen Strompreisen. . . .	69
6.6	Szenarienerstellung zur Optimierung unter Vorhersageunsicherheiten.	72
6.7	Skizze des virtuellen Kraftwerks.	73

6.8	Darstellung der Szenarien zur Bewertung verschiedener Vorhersageunsicherheiten	
	ϵ_{pred} [53].	74
6.9	Einfluss von Vorhersagefehlern für verschiedene Fehlerszenarien.	76
6.10	Vergleich der relativen Kosten pro Einheit für den Fall ohne Batterie.	77
6.11	Einfluss des Vorhersagefehlers anhand der relativen Kosten pro Einheit.	78
6.12	Topologie des SCC mit drei VPPs.	80
6.13	Dezentrales Energiemanagement in einer Energiegemeinschaft.	81
6.14	Konvergenzverhalten des dezentralen Algorithmus.	82
7.1	PV Jahresertrag und Abregelung in Abhängigkeit der Ausrichtung.	86
7.2	Anteil der abgeregelten Energie in Abhängigkeit von der Einspeisegrenze für verschiedene Szenarien.	87
7.3	Abbildung der Kostenfunktion zur Smart-Meter-Platzierung.	89
7.4	Vergleich der Smart-Meter Platzierungen abhängig von der Kostenfunktion.	89
7.5	Vergleich der Standardabweichung der Spannungsschätzung im Netz.	90
7.6	Ergebnisse der optimierungsbasierten Platzierung für 5 intelligente Zähler.	91
7.7	Flussdiagramm des heuristischen Netzausbaualgorithmus.	95
7.8	Spannungsverteilungen in einem Verteilnetz mit und ohne Energiemanagement.	96
7.9	Optimale Batterieplatzierung für die Spannungsstabilität innerhalb des Testnetzes.	96
A.1	Aufbau des einfachen Netzes	104
A.2	Aufbau des Dorfnetzes aus einem Testgebiet [21, 28].	105
A.3	Komplexes Netz mit mehreren Spannungsebenen	105

Tabellenverzeichnis

3.1	Komponenten des Wärmepumpenmodells, aufgeteilt nach den drei Teilkreisen. . . .	21
3.2	Systemwirkungsgrade des Batteriespeichersystems für verschiedene Leistungen, gemessen an einem Vollzyklus.	23
3.3	Sonstige Verlustquellen des PV-Modells	25
4.1	Vergleich der Monte-Carlo-Methoden zur Spannungsschätzung	44
4.2	RMSE der Spannungsschätzmethoden	44
4.3	Rechenzeit der probabilistischen Lastfluss-Methoden für das Dorfnetz.	45
6.1	Simulationsszenario und Randbedingungen [53].	73
6.2	Für das Optimierungsmodell verwendete Kosten [53].	76
7.1	Batterieinstallationskosten für 2019 [151].	93
7.2	Netzausbaukosten für den automatisierten Netzausbau [151].	94
7.3	Größe, maximale Leistung und Lage der Batterien [151].	97
7.4	Gesamtkosten für die untersuchten Szenarien [151].	97
7.5	Jährlicher Kostenvergleich (angenommene Lebensdauer: Batterie=10 yr, Kabel=40 yr) [151].	97
A.1	Konstanten zur Bestimmung von F_1 und F_2 in Abhängigkeit von ε [193].	111
A.2	Koeffizienten zur Berechnung des relativen Modulwirkungsgrades	111
A.3	Temperaturkoeffizienten für lineares Temperaturmodell	111
A.4	Temperaturkoeffizienten für das PV-Modell	112
A.5	Koeffizienten zur Berechnung des Wechselrichterwirkungsgrades	112
A.6	Simulationsszenario ADMM	113

Eigene Veröffentlichungen

Im Rahmen der durchgeführten Forschungsarbeiten wurden zahlreiche Veröffentlichungen erstellt, die in diesem Kapitel aufgelistet sind. Ein aktueller Überblick über alle Veröffentlichungen kann unter folgendem Link gefunden werden: <https://scholar.google.de/citations?user=GImASp4AAAAAJ>.

Journalartikel

- [151] Benjamin Matthiss, Arghavan Momenifarahani und Jann Binder. „Storage Placement and Sizing in a Distribution Grid with High PV Generation“. In: *Energies* 14.2 (8. Jan. 2021), S. 303 (siehe S. 85, 93–97).

Konferenzbeiträge

- [46] Benjamin Matthiss, Matthias Kraft und Jann Binder. „Fast Probabilistic Load Flow for Non-Radial Distribution Grids“. In: IEEE International Conference on Environment and Electrical Engineering and IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe). Palermo, Italy: IEEE, Juni 2018, S. 1–6 (siehe S. 33–35, 94).
- [47] Benjamin Matthiss, Patrick Gaedke, Martin Felder und Jann Binder. „Probabilistic Loadflow Methods for Energy Management Schemes in Distribution Grids“. In: IEEE International Conference on Environment and Electrical Engineering and IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe). Milan, Italy: IEEE, Juni 2017, S. 1–5 (siehe S. 33, 38, 40, 41, 44).
- [48] Benjamin Matthiss, Jonathan Erb und Jann Binder. „Using Smart Meters for Distribution Grid State Estimation“. In: 2019 International Conference on Smart Energy Systems and Technologies (SEST). Porto, Portugal: IEEE, 2019, S. 1–5 (siehe S. 33, 87, 89, 91).
- [53] B. Matthiss, A. Momenifarahani, K. Ohnmeiss und M. Felder. „Influence of Demand and Generation Uncertainty on the Operational Efficiency of Smart Grids“. In: 7th International Conference on Renewable Energy Research and Applications (ICRERA). Paris, France: IEEE, Okt. 2018, S. 751–756 (siehe S. 33, 70, 73, 74, 76–78, 94).
- [93] Benjamin Matthiss, Abdul Azzam und Jann Binder. „Thermal Building Models for Energy Management Systems“. In: IEEE International Conference on Environment and Electrical Engineering. 2023 (siehe S. 50–52, 55, 56).

- [124] Benjamin Matthiss, Daniel Müller, Jann Binder und Dirk Pietruschka. „Model Predictive Control Schemes for PV Storage Systems to Increase Grid Compatibility and Optimize Energy Costs“. In: *EU PVSEC Proceedings. 29th European Photovoltaic Solar Energy Conference and Exhibition*. Amsterdam: VIP, 25. Sep. 2014, S. 3581–3586 (siehe S. 67–69).
- [125] Benjamin Matthiss, Jann Binder und Michael A. Danzer. „Model Predictive Control Schemes for PV-Storage Systems with Grid Voltage Feedback to Increase Grid Compatibility and Self-Consumption“. In: *Ulm Electro-Chemical Talks*. Ulm, 2014 (siehe S. 67).
- [152] Benjamin Matthiss, Dirk Stellbogen, Maria Eberspächer und Jann Binder. „Curtailed Energy of PV Systems – Dependency on Grid Loading Limit, Orientation and Local Energy Demand“. In: *30th European Photovoltaic Solar Energy Conference*. Bd. 30. Hamburg, Germany, 2015 (siehe S. 86, 87).
- [195] Benjamin Matthiss, Christopher Williams, Jann Binder, Michael Danzer und Benjamin Schott. „Analysis and Comparison of Battery Charge Control Algorithms for Increased Grid Compatibility of Decentralized PV Systems“. In: *IRES*. Berlin, 2013.
- [196] Benjamin Matthiss, Ruben Rongstock, Andreas Siebenlist, Florian Gutekunst, Maximilian Schneider und Dirk Pietruschka. „Dezentrale Photovoltaik- und Windeinspeisung: Der Einsatz von Quartierspeichern Am Beispiel Einer Plusenergiegemeinde“. In: *Symposium Photovoltaische Solarenergie*. Bad Staffelstein, März 2016.
- [197] Benjamin Matthiss, Jann Binder und Benjamin Schott. „Reduzierte Netzbelastung Und Optimierter Eigenverbrauch von Dezentralen PV-Speichersystemen Durch Modellprädiktive Betriebsführung von Speichern“. In: *Zukünftige Stromnetze Für Erneuerbare Energien*. Berlin: Otti, 30. Jan. 2014, S. 230–235.
- [198] Dirk Pietruschka, Marcus Brennenstuhl, Benjamin Matthiss und Jann Binder. „Decentralised Heat Pumps and Small Electricity Storages as Active Components in a Virtual Power Plant for Smart Grid Services“. In: *2015 IEEE 15th International Conference on Environment and Electrical Engineering (EEEIC)*. 2015 IEEE 15th International Conference on Environment and Electrical Engineering (EEEIC). Juni 2015, S. 737–741.
- [199] Dirk Stellbogen, Benjamin Matthiss, Maria Eberspächer und Jann Binder. „Abgeregelte Energie von PV-Anlagen - Abhängigkeit von Einspeisegrenze, Ausrichtung Und Lokalem Bedarfsprofil“. In: *30. Symposium Photovoltaische Solarenergie*. Bad Staffelstein, 3. Apr. 2015.
- [200] Joel Wenske, Paul Himpel, Benjamin Matthiss, Jann Binder, Thomas Speidel, Volkmar Klausser und Michael Klesse. „Hot-Spot Scenarios of Electrical-Vehicles on the Low Voltage Grid“. In: *E-Mobility Power System Integration Symposium*. Stockholm, Sweden, 2018.

Andere Veröffentlichungen

- [21] Benjamin Matthiss, Katharina Strecker, Abdul Azzam und Jann Binder. *NEMoGrid - New Energy Business Models in the Distribution Grid Abschlussbericht ZSW: Entwicklung, Simulation und Validierung relevanter Geschäftsmodelle*. FKZ: 0350016A (siehe S. 17–19, 22, 65, 82, 105).
- [42] Benjamin Matthiss, Martin Felder und Dirk Stellbogen. „Comparison and Validation of System and Irradiance Models for Yield Estimation“. In: PV Performance Modelling Workshop. Cologne, 23. Okt. 2015 (siehe S. 27, 28).
- [153] Benjamin Matthiss. „PV Storage Systems – Sizing and Operation to Serve Owner and Grid“. In: World of Energy Solutions, Stuttgart. 2015 (siehe S. 87).
- [180] Benjamin Schott, Jann Binder, Martin Felder, Benjamin Matthiss, Michael Capota, Michael Danzer, Gerd Heilscher, Holger Ruf, Konstantin Ditz und Daniel Funk. *Optimierung Der Systemintegration Fluktuierender Stromerzeugung Aus Erneuerbaren Energien Am Beispiel Der Photovoltaik Auf Niederspannungsebene* (siehe S. 94).

Literatur

- [1] *EU-Klimaschutzpaket Fit For 55 | Bundesregierung*. Die Bundesregierung informiert | Startseite. 25. Apr. 2023. URL: <https://www.bundesregierung.de/breg-de/schwerpunkte/europa/fit-for-55-eu-1942402> (besucht am 05. 08. 2023) (siehe S. 1).
- [2] BMWK-Bundesministerium für Wirtschaft und Klimaschutz. *Durchbruch für ambitionierten Ausbau erneuerbarer Energien bis 2030: neue EU-Richtlinie für erneuerbare Energien beschlossen*. URL: <https://www.bmwk.de/Redaktion/DE/Pressemitteilungen/2023/03/20230330-durchbruch-fur-ambitionierten-ausbau-erneuerbarer-energien-bis-2030.html> (besucht am 05. 08. 2023) (siehe S. 1).
- [3] Umweltbundesamt. „Erneuerbare Energien in Deutschland. Daten zur Entwicklung im Jahr 2021“. In: (2022) (siehe S. 1).
- [4] Agora Energiewende, Prognos, Consentec. *Klimaneutrales Stromsystem 2035 - Wie Der Deutsche Stromsektor Bis Zum Jahr 2035 Klimaneutral Werden Kann*. Agora Energiewende, Prognos, Consentec, 2023 (siehe S. 1).
- [5] Julian Brandes, Markus Haun, Daniel Wrede, Patrick Jürgens, Christoph Kost und Hans-Martin Henning. *Wege Zu Einem Klimaneutralen Energiesystem - Die Deutsche Energiewende Im Kontext Gesellschaftlicher Verhaltensweisen, Update November 2021: Klimaneutralität 2045*. Fraunhofer-Institut für Solare Energiesysteme ISE, 2021 (siehe S. 1).
- [6] Adolf J. Schwab. „Elektroenergiesysteme: Smarte Stromversorgung im Zeitalter der Energiewende“. Berlin, Heidelberg: Springer, 2022 (siehe S. 1, 12, 13).
- [7] X. Fang, S. Misra, G. Xue und D. Yang. „Smart Grid — the New and Improved Power Grid: A Survey“. In: *IEEE Communications Surveys & Tutorials* 14.4 (2012), S. 944–980 (siehe S. 2).
- [8] David I. Wilson. „Advanced Control Using Matlab or Stabilising the Unstabilisable“. Auckland University of Technology, 2013 (siehe S. 10).
- [9] Alexander Probst. „Auswirkungen von Elektromobilität Auf Energieversorgungsnetze Analysiert Auf Basis Probabilistischer Netzplanung“. Universität Stuttgart, 2014 (siehe S. 11).
- [10] Wikipedia. *Stromnetz — Wikipedia, Die Freie Enzyklopädie*. 2023 (siehe S. 11).
- [11] *VDE-AR-N 4105 Anwendungsregel:2018-11 - Normen - VDE VERLAG*. URL: <https://www.vde-verlag.de/normen/0100492/vde-ar-n-4105-anwendungsregel-2018-11.html> (besucht am 31. 05. 2023) (siehe S. 11).

- [12] BMWK-Bundesministerium für Wirtschaft und Klimaschutz. *Ein Stromnetz für die Energiewende*. URL: <https://www.bmwk.de/Redaktion/DE/Dossier/netze-und-netzausbau.html> (besucht am 31.05.2023) (siehe S. 11).
- [13] *Entsoe*. URL: <https://www.entsoe.eu/> (besucht am 31.05.2023) (siehe S. 12).
- [14] *Stromnetz Transport | EnBW*. Stromnetz Transport. URL: <https://www.enbw.com/energie-entdecken/verteilung-und-transport/stromnetz/> (besucht am 31.05.2023) (siehe S. 12).
- [15] Drury B. Crawley, Linda K. Lawrie, Frederick C. Winkelmann, W. F. Buhl, Y. Joe Huang, Curtis O. Pedersen, Richard K. Strand, Richard J. Liesen, Daniel E. Fisher, Michael J. Witte und Jason Glazer. „EnergyPlus: Creating a New-Generation Building Energy Simulation Program“. In: *Energy and Buildings*. Special Issue: BUILDING SIMULATION'99 33.4 (1. Apr. 2001), S. 319–331 (siehe S. 16).
- [16] Drury Crawley, Curtis Pedersen, Linda Lawrie und Frederick Winkelmann. „EnergyPlus: Energy Simulation Program“. In: *Ashrae Journal* 42 (1. Apr. 2000), S. 49–56 (siehe S. 16).
- [17] Ali Al-janabi, Miroslava Kavacic, Ali Mohammadzadeh und Afaf Azzouz. „Comparison of EnergyPlus and IES to Model a Complex University Building Using Three Scenarios: Free-floating, Ideal Air Load System, and Detailed“. In: *Journal of Building Engineering* 22 (1. März 2019), S. 262–280 (siehe S. 16).
- [18] Azhaili Baharun, Siti Halipah Ibrahim, Mohammad Omar Abdullah und Ooi Koon Beng. „Experimental Validation of EnergyPlus® Simulation of a Single Storey Building“. In: *Journal of Civil Engineering* (2016), S. 6 (siehe S. 16).
- [19] Gabriela Bastos Porsani, Kattalin Del Valle de Lersundi, Ana Sánchez-Ostiz Gutiérrez und Carlos Fernández Bandera. „Interoperability between Building Information Modelling (BIM) and Building Energy Model (BEM)“. In: *Applied Sciences* 11.5 (5 Jan. 2021), S. 2167 (siehe S. 16).
- [20] Sullivan Royer, Michael Bressan, Stephane Thil und Thierry Talbert. „Modelling of a Multi-Zone Building and Assessment of Its Thermal Behaviour Using an Energy Simulation Software“. In: *2013 IEEE International Conference on Automation Science and Engineering (CASE)*. 2013 IEEE International Conference on Automation Science and Engineering (CASE 2013). Madison, WI, USA: IEEE, Aug. 2013, S. 735–740 (siehe S. 16).
- [22] Eberhard Markus Kleinbach, WA Beckman und SA Klein. „Performance Study of One-Dimensional Models for Stratified Thermal Storage Tanks“. In: *Solar energy* 50.2 (1993), S. 155–166 (siehe S. 17).
- [23] Seung-Hyo Baek, Hyun-Min Nam, Myoung-Souk Yeo und Kwang-Woo Kim. „Development of a Zonal Model to Analyze a Thermal Storage Tank with an Electric Heater“. In: *Asia Conference of International Building Performance Simulation Association (ASIM)*. Shanghai, China, 2012 (siehe S. 17).

- [24] Mi-Soo Shin, Hey-Suk Kim, Dong-Soon Jang, Sang-Nam Lee, Young-Soo Lee und Hyung-Gi Yoon. „Numerical and Experimental Study on the Design of a Stratified Thermal Storage System“. In: *Applied Thermal Engineering* 24.1 (Jan. 2004), S. 17–27 (siehe S. 17).
- [25] Stefan Falkner. „Modellierung Und Simulation von Thermischen Speichern“. TU-Wien, 2014 (siehe S. 17).
- [26] Jesus Lago, Fjo De Ridder, Wiet Mazairac und Bart De Schutter. „A 1-Dimensional Continuous and Smooth Model for Thermally Stratified Storage Tanks Including Mixing and Buoyancy“. In: *Applied Energy* 248 (Aug. 2019), S. 640–655 (siehe S. 17).
- [27] Joseph Rendall, Fernando Karg Bulnes, Kyle Gluesenkamp, Ahmad Abu-Heiba, William Worek und Kashif Nawaz. „A Flow Rate Dependent 1D Model for Thermally Stratified Hot-Water Energy Storage“. In: *Energies* 14.9 (9 Jan. 2021), S. 2611 (siehe S. 17).
- [28] Dominik Keiner. „Analyse Der Auswirkung von Betriebsstrategien Für PV-Batteriespeicher Und Wärmepumpen Auf Das Niederspannungsnetz“. Forschungsarbeit. ZSW, 2019 (siehe S. 19, 105).
- [29] Bundesamt für Wirtschaft und Ausfuhrkontrolle (BAFA). „Wärmepumpen Mit Prüf- / Effizienznachweis“. In: Eschborn, Apr. 2019 (siehe S. 20).
- [30] Francesco Witte. *TESPy: Thermal Engineering Systems in Python*. Version v0.4.3-005. Zenodo, 18. Mai 2021 (siehe S. 21).
- [31] Mads Pagh Nielsen und Kim Sørensen. „Dynamic Modeling of Heat Pumps for Ancillary Services in Local District Heating Concepts“. In: *61st SIMS Conference on Simulation and Modelling SIMS 2020*. Linköping University Electronic Press, 2021, S. 39–46 (siehe S. 21).
- [32] Umer Khalid Awan. „Experimental Analysis of Variable Capacity Heat Pump System Equipped with Vapour Injection and Permanent Magnet Motor“. 2012 (siehe S. 21).
- [33] Hatem Madani, Navid Ahmadi, Joachim Claesson und Per Lundqvist. „Experimental Analysis of a Variable Capacity Heat Pump System Focusing on the Compressor and Inverter Loss Behavior“. In: (2010), S. 10 (siehe S. 21).
- [34] *Effiziente Luft_Wasser-Wärmepumpen Durch Kontinuierliche Leistungsregelung.Pdf* (siehe S. 21, 22).
- [35] Dr Armin U. Schmiegel, Holger Schuh, Uwe Thomas, Markus Landau, Jann Binder und Dirk Magnor. „Sol-Ion: Netzgekoppelte PV-System Mit Lithium-Ionen Basierten Speichern Zur Verbesserung Der Integration von Erneuerbaren Energien in Das Öffentliche Stromnetz ; Abschlussbericht, ZE: 0325044A“. In: (2013). Hrsg. von Bosch Power Tec GmbH (siehe S. 24).
- [36] Andreas Jossen. *Life Time Model of a Lithium-Ion Battery*. Zentrum für Sonnenenergie-und Wasserstoff-Forschung Baden-Württemberg, 2009 (siehe S. 24).
- [37] Wahiba Yaici, Evgueniy Entchev, Michela Longo, Morris Brenna und Federica Foadelli. „Artificial Neural Network Modelling for Performance Prediction of Solar Energy System“. In: *2015 International Conference on Renewable Energy Research and Applications (ICRERA)*.

- 2015 International Conference on Renewable Energy Research and Applications (ICRERA). Palermo, Italy: IEEE, Nov. 2015, S. 1147–1151 (siehe S. 25).
- [38] Thomas Huld, Ralph Gottschalg, Hans Georg Beyer und Marko Topič. „Mapping the Performance of PV Modules, Effects of Module Type and Data Averaging“. In: *Solar Energy* 84.2 (Feb. 2010), S. 324–338 (siehe S. 25, 26, 111).
- [39] David L King, Jay A Kratochvil und William Earl Boyson. *Photovoltaic Array Performance Model*. SANDIA REPORT SAND2004-3535. United States. Department of Energy, 2004, S. 43 (siehe S. 25, 26, 112).
- [40] A. Drews, A.C. de Keizer, H.G. Beyer, E. Lorenz, J. Betcke, W.G.J.H.M. van Sark, W. Heydenreich, E. Wiemken, S. Stettler, P. Toggweiler, S. Bofinger, M. Schneider, G. Heilscher und D. Heinemann. „Monitoring and Remote Failure Detection of Grid-Connected PV Systems Based on Satellite Observations“. In: *Solar Energy* 81.4 (Apr. 2007), S. 548–564 (siehe S. 26, 111).
- [41] WN Macedo und R Zilles. „Operational Results of Grid-Connected Photovoltaic System with Different Inverter’s Sizing Factors (ISF)“. In: *Progress in Photovoltaics: Research and Applications* 15.4 (2007), S. 337–352 (siehe S. 27, 112).
- [43] Claire Thomas, Lucien Wald, Etienne Wey, Laurent Saboret und Philippe Blanc. *HelioClim-4, or How to Build a Successful and Sustainable Business Service Based on CAMS Radiation Service*. Juni 2017 (siehe S. 28).
- [44] Richard Lincoln. *PYPOWER*. GitHub. URL: <https://github.com/rwl/PYPOWER> (besucht am 20. 04. 2017) (siehe S. 29, 31).
- [45] Michael Knorrenschild. „Numerische Mathematik“. In: *Numerische Mathematik*. Carl Hanser Verlag GmbH & Co. KG, 17. Jan. 2013, S. 1–8 (siehe S. 29).
- [49] Matthias P. Nowak und Werner Römisch. „Stochastic Lagrangian Relaxation Applied to Power Scheduling in a Hydro-Thermal System under Uncertainty“. In: *Annals of Operations Research* 100.1 (1. Dez. 2000), S. 251–272 (siehe S. 33).
- [50] J.F. Dopazo, O.A. Klitin und A.M. Sasson. „Stochastic Load Flows“. In: *IEEE Transactions on Power Apparatus and Systems* 94.2 (März 1975), S. 299–309 (siehe S. 33, 37).
- [51] Tillmann Muhlfordt, Timm Faulwasser und Veit Hagenmeyer. „Solving Stochastic AC Power Flow via Polynomial Chaos Expansion“. In: *IEEE*, Sep. 2016, S. 70–76 (siehe S. 33, 37).
- [52] Jeremias Schmidli, Line Roald, Spyros Chatzivasileiadis und Goran Andersson. „Stochastic AC Optimal Power Flow with Approximate Chance-Constraints“. In: *IEEE*, Juli 2016, S. 1–5 (siehe S. 33).
- [54] Peter Florian Krasselt. „Optimierte Netzverträglichkeit von Gleichstrom-Schnellladesystemen Durch Aktive Netzbeeinflussung“. 2016 (siehe S. 33).
- [55] W.C. Briceno Vicente, R. Caire und N. Hadjsaid. „Probabilistic Load Flow for Voltage Assessment in Radial Systems with Wind Power“. In: *International Journal of Electrical Power & Energy Systems* 41.1 (Okt. 2012), S. 27–33 (siehe S. 34, 37).

- [56] G.J. Anders. „Probability Concepts in Electric Power Systems“. United States, 1989 (siehe S. 37).
- [57] Alejandro Marano-Marcolini, Florin Capitanescu, Jose Luis Martinez-Ramos und Louis Wehenkel. „Exploiting the Use of DC SCOPF Approximation to Improve Iterative AC SCOPF Algorithms“. In: *IEEE Transactions on Power Systems* 27.3 (Aug. 2012), S. 1459–1466 (siehe S. 37).
- [58] F.J. Ruiz-Rodriguez, J.C. Hernández und F. Jurado. „Probabilistic Load Flow for Radial Distribution Networks with Photovoltaic Generators“. In: *IET Renewable Power Generation* 6.2 (2012), S. 110 (siehe S. 37, 38).
- [59] R.N. Allan, A.m. Da Silva und R.C. Burchett. „Evaluation Methods and Accuracy in Probabilistic Load Flow Solutions“. In: *IEEE Transactions on Power Apparatus and Systems* PAS-100.5 (Mai 1981), S. 2539–2546 (siehe S. 37, 38).
- [60] M. Brucoli, F. Torelli und R. Napoli. „Quadratic Probabilistic Load Flow with Linearly Modelled Dispatch“. In: *International Journal of Electrical Power & Energy Systems* 7.3 (Juli 1985), S. 138–146 (siehe S. 37).
- [61] P. Chen, Z. Chen und B. Bak-Jensen. „Probabilistic Load Flow: A Review“. In: IEEE, Apr. 2008, S. 1586–1591 (siehe S. 37).
- [62] Killian Dallmer-Zerbe und Bernhard Wille-Hausmann. „Incorporating Multiple Uncertainties into Iterative Probabilistic Load Flow“. In: 4th International Workshop on Integration of Solar into Power Systems. Berlin, 2014 (siehe S. 37).
- [63] Miao Fan, Vijay Vittal, Gerald Thomas Heydt und Raja Ayyanar. „Probabilistic Power Flow Studies for Transmission Systems With Photovoltaic Generation Using Cumulants“. In: *IEEE Transactions on Power Systems* 27.4 (Nov. 2012), S. 2251–2261 (siehe S. 37).
- [64] Z. Hu und X. Wang. „A Probabilistic Load Flow Method Considering Branch Outages“. In: *IEEE Transactions on Power Systems* 21.2 (Mai 2006), S. 507–514 (siehe S. 37).
- [65] Dinh Duong Le, Nhi Thi Ai Nguyen, Van Duong Ngo und Alberto Berizzi. „Advanced Probabilistic Power Flow Methodology for Power Systems with Renewable Resources“. In: *TURKISH JOURNAL OF ELECTRICAL ENGINEERING & COMPUTER SCIENCES* 25 (2017), S. 1154–1162 (siehe S. 37).
- [66] D. D. Le, A. Berizzi, C. Bovo, E. Ciapessoni, D. Cirio, A. Pitto und G. Gross. „A Probabilistic Approach to Power System Security Assessment under Uncertainty“. In: IEEE, Aug. 2013, S. 1–7 (siehe S. 37).
- [67] A.P.S. Meliopoulos, G.J. Cokkinides und X.Y. Chao. „A New Probabilistic Power Flow Analysis Method“. In: *IEEE Transactions on Power Systems* 5.1 (1990), S. 182–190 (siehe S. 37).
- [68] Zhouyang Ren, Wei Yan, Xia Zhao, Xueqian Zhao und Juan Yu. „Probabilistic Power Flow Studies Incorporating Correlations of PV Generation for Distribution Networks“. In: *Journal of Electrical Engineering and Technology* 9.2 (1. März 2014), S. 461–470 (siehe S. 37).

- [69] Johannes Schwippe, Olav Krause und Christian Rehtanz. „Extension of a Probabilistic Load Flow Calculation for the Consideration of Interdependencies“. In: *Proceedings 17th Power Systems Computation Conference*. Bd. 1. 2011, S. 677–684 (siehe S. 37).
- [70] J. Schwippe, O. Krause und C. Rehtanz. „Probabilistic Load Flow Calculation Based on an Enhanced Convolution Technique“. In: IEEE, Juni 2009, S. 1–6 (siehe S. 37).
- [71] J. Usaola. „Probabilistic Load Flow in Systems with Wind Generation“. In: *IET Generation, Transmission & Distribution* 3.12 (2009), S. 1031 (siehe S. 37).
- [72] Y. Yuan, J. Zhou, P. Ju und J. Feuchtwang. „Probabilistic Load Flow Computation of a Power System Containing Wind Farms Using the Method of Combined Cumulants and Gram–Charlier Expansion“. In: *IET Renewable Power Generation* 5.6 (2011), S. 448 (siehe S. 37).
- [73] Barbara Borkowska. „Probabilistic Load Flow“. In: *IEEE Transactions on Power Apparatus and Systems* PAS-93.3 (Mai 1974), S. 752–759 (siehe S. 37).
- [74] Quan Li, Xin Wang und Shuaiang Rong. „Probabilistic Load Flow Method Based on Modified Latin Hypercube-Important Sampling“. In: *Energies* 11.11 (15. Nov. 2018), S. 3171 (siehe S. 37).
- [75] P. Zhang und S.T. Lee. „Probabilistic Load Flow Computation Using the Method of Combined Cumulants and Gram-Charlier Expansion“. In: *IEEE Transactions on Power Systems* 19.1 (Feb. 2004), S. 676–682 (siehe S. 37).
- [76] H. H. Ku. „Notes on the Use of Propagation of Error Formulas“. In: *Journal of Research of the National Bureau of Standards. Section C: Engineering and Instrumentation* 70C.4 (Okt. 1966), S. 263–273 (siehe S. 38).
- [77] Kai Oliver Arras. *An Introduction To Error Propagation: Derivation, Meaning and Examples*. EPFL-ASL-TR-98-01 R3. Lausanne: Swiss Federal Institute of Technology Lausanne (EPFL), Sep. 1998 (siehe S. 39).
- [78] A. A. Clifford. „Multivariate Error Analysis; a Handbook of Error Propagation and Calculation in Many-Parameter Systems“. New York: Wiley, 1973. 112 S. (siehe S. 39).
- [79] Martin Vermeer. *Statistical Uncertainty and Error Propagation*. 2014 (siehe S. 39).
- [80] Ali Abur und Antonio Gomez Exposito. „Power System State Estimation: Theory and Implementation“. Marcel Dekker, 2004 (siehe S. 42).
- [81] Fred Schweppe und J. Wildes. „Power System Static-State Estimation, Part I: Exact Model“. In: *IEEE Transactions on Power Apparatus and Systems* PAS-89.1 (Jan. 1970), S. 120–125 (siehe S. 42).
- [82] A. Monticelli und Felix Wu. „Network Observability: Identification of Observable Islands and Measurement Placement“. In: *IEEE Transactions on Power Apparatus and Systems* PAS-104.5 (Mai 1985), S. 1035–1041 (siehe S. 42).
- [83] Georg Kerber. „Aufnahmefähigkeit von Niederspannungsverteilsystemen Für Die Einspeisung Aus Photovoltaikkleinanlagen“. Technische Universität München, 2011 (siehe S. 43, 44).

- [84] K. Heussen, S. Koch, A. Ulbig und G. Andersson. „Energy Storage in Power System Operation: The Power Nodes Modeling Framework“. In: *Innovative Smart Grid Technologies Conference Europe (ISGT Europe)*. 2010, S. 1–8 (siehe S. 48, 80).
- [85] Akshay Agrawal, Robin Verschueren, Steven Diamond und Stephen Boyd. *A Rewriting System for Convex Optimization Problems*. 21. Jan. 2019. arXiv: 1709.04494 [cs, math]. URL: <http://arxiv.org/abs/1709.04494> (besucht am 06.08.2023). preprint (siehe S. 48).
- [86] Steven Diamond und Stephen Boyd. „CVXPY: A Python-Embedded Modeling Language for Convex Optimization“. In: *Journal of Machine Learning Research* 17.83 (2016), S. 1–5 (siehe S. 48).
- [87] Weixiong Zhang. *Branch-and-Bound Search Algorithms and Their Computational Complexity*. DTIC Document, 1996 (siehe S. 49).
- [88] T.O. Ting, M.V.C. Rao und C.K. Loo. „A Novel Approach for Unit Commitment Problem via an Effective Hybrid Particle Swarm Optimization“. In: *IEEE Transactions on Power Systems* 21.1 (Feb. 2006), S. 411–418 (siehe S. 49).
- [89] Kenneth Van den Bergh, Kenneth Bruninx, Erik Delarue und William D’haeseleer. „A Mixed-Integer Linear Formulation of the Unit Commitment Problem“. In: *WP EN2014-07* (2014) (siehe S. 49).
- [90] Ana Viana und João Pedro Pedroso. „A New MILP-based Approach for Unit Commitment in Power Production Planning“. In: *International Journal of Electrical Power & Energy Systems* 44.1 (Jan. 2013), S. 997–1005 (siehe S. 49).
- [91] Michael J. Todd. „The Many Facets of Linear Programming“. In: *Mathematical Programming* 91.3 (Feb. 2002), S. 417–436 (siehe S. 49).
- [92] Robert J Vanderbei. „Linear Programming, Foundation and Extensions“ (siehe S. 49).
- [94] Dae Ki Kim, Kyu Chul Lee, Sung Hyun Yoo, Jung Hoon Kim und Myotaeg Lim. „Thermal Model Parameter Estimation for HVAC Facility Using Recursive Least Square Method“. In: *International Conference on Mechanics, Materials and Structural Engineering (ICMMSE 2016)*. Atlantis Press, März 2016, S. 314–318 (siehe S. 54).
- [95] Rodrigo A. Ricco und Bruno O. S. Teixeira. „Least-Squares Parameter Estimation for State-Space Models with State Equality Constraints“. In: *International Journal of Systems Science* 53.1 (2. Jan. 2022), S. 1–13 (siehe S. 54).
- [96] Simon S Haykin. „Kalman Filtering and Neural Networks“. New York: Wiley, 2001 (siehe S. 55).
- [97] Shahrokh Akhlaghi, Ning Zhou und Zhenyu Huang. „Adaptive Adjustment of Noise Covariance in Kalman Filter for Dynamic State Estimation“. In: *2017 IEEE Power & Energy Society General Meeting*. 2017 IEEE Power & Energy Society General Meeting (PESGM). Chicago, IL: IEEE, Juli 2017, S. 1–5 (siehe S. 55).
- [98] P. Baran. „On Distributed Communications Networks“. In: *IEEE Transactions on Communications Systems* 12.1 (März 1964), S. 1–9 (siehe S. 60, 61).

- [99] JP Vergne. „Decentralized vs. Distributed Organization: Blockchain, Machine Learning and the Future of the Digital Platform“. In: *Organization Theory* 1.4 (1. Okt. 2020), S. 2631787720977052 (siehe S. 60).
- [100] R. Khare und R.N. Taylor. „Extending the Representational State Transfer (REST) Architectural Style for Decentralized Systems“. In: *Proceedings. 26th International Conference on Software Engineering*. Proceedings. 26th International Conference on Software Engineering. Edinburgh, UK: IEEE Comput. Soc, 2004, S. 428–437 (siehe S. 60).
- [101] J Fischer und A Lynch. „Impossibility of Distributed Consensuswith One Faulty Process“. In: () (siehe S. 60).
- [102] Vitalik Buterin. *The Meaning of Decentralization*. Medium. 6. Feb. 2017. URL: <https://medium.com/@VitalikButerin/the-meaning-of-decentralization-a0c92b76a274> (besucht am 14. 05. 2023) (siehe S. 60).
- [103] R. Baños, F. Manzano-Agugliaro, F.G. Montoya, C. Gil, A. Alcayde und J. Gómez. „Optimization Methods Applied to Renewable and Sustainable Energy: A Review“. In: *Renewable and Sustainable Energy Reviews* 15.4 (2011), S. 1753–1766 (siehe S. 63).
- [104] M. Cannon und B. Kouvaritakis. „Optimizing Prediction Dynamics for Robust MPC“. In: *IEEE Transactions on Automatic Control* 50.11 (Nov. 2005), S. 1892–1897 (siehe S. 63).
- [105] Mohamed A. Abu-El-Magd und Naresh K. Sinha. „Short-Term Load Demand Modeling and Forecasting: A Review“. In: *IEEE Transactions on Systems, Man, and Cybernetics* 12.3 (Mai 1982), S. 370–382 (siehe S. 63).
- [106] Sana BuHamra, Nejib Smaoui und Mahmoud Gabr. „The Box–Jenkins Analysis and Neural Networks: Prediction and Time Series Modelling“. In: *Applied Mathematical Modelling* 27.10 (1. Okt. 2003), S. 805–815 (siehe S. 63).
- [107] L.C.M de Andrade und I.N da Silva. „Very Short-Term Load Forecasting Based on ARIMA Model and Intelligent Systems“. In: *2009 15th International Conference on Intelligent System Applications to Power Systems (ISAP)*. 2009, S. 1–6 (siehe S. 63).
- [108] M.Y Cho, J.C Hwang und C.S Chen. „Customer Short Term Load Forecasting by Using ARIMA Transfer Function Model“. In: *1995 International Conference on Energy Management and Power Delivery EMPD '95*. 1995, S. 317–322 (siehe S. 63).
- [109] Romuald Boné und Michel Crucianu. „Multi-Step-Ahead Prediction with Neural Networks“. In: *European Journal of Economic and Social Systems* 17.1-2 (2004), S. 85–98 (siehe S. 64).
- [110] G. Kourtis, Ioannis Hadjipaschalis und A. Poullikkas. „An Overview of Load Demand and Price Forecasting Methodologies“. In: 2010 (siehe S. 64).
- [111] Dhruv Upadhaya, Ritula Thakur und Navneet Kumar Singh. „A Systematic Review on the Methods of Short Term Load Forecasting“. In: *2019 2nd International Conference on Power Energy, Environment and Intelligent Control (PEEIC)*. 2019 2nd International Conference on Power Energy, Environment and Intelligent Control (PEEIC). Okt. 2019, S. 6–11 (siehe S. 64).

- [112] Naqash Ahmad, Yazeed Ghadi, Muhammad Adnan und Mansoor Ali. „Load Forecasting Techniques for Power System: Research Challenges and Survey“. In: *IEEE Access* 10 (2022), S. 71054–71090 (siehe S. 64).
- [113] Tianhui Zhao, Jianxue Wang und Yao Zhang. „Day-Ahead Hierarchical Probabilistic Load Forecasting With Linear Quantile Regression and Empirical Copulas“. In: *IEEE Access* 7 (2019), S. 80969–80979 (siehe S. 64).
- [114] D. Gan, Y. Wang, S. Yang und C. Kang. „Embedding Based Quantile Regression Neural Network for Probabilistic Load Forecasting“. In: *Journal of Modern Power Systems and Clean Energy* 6.2 (2018), S. 244–254 (siehe S. 64).
- [115] Mir Hadi Athari und Zhifang Wang. „Modeling the Uncertainties in Renewable Generation and Smart Grid Loads for the Study of the Grid Vulnerability“. In: (Sep. 2016), S. 1–5 (siehe S. 64).
- [116] Alessandro Brusaferrri, Matteo Matteucci, Stefano Spinelli und Andrea Vitali. *Probabilistic Electric Load Forecasting through Bayesian Mixture Density Networks*. 11. Jan. 2021. arXiv: 2012.14389 [cs, eess]. URL: <http://arxiv.org/abs/2012.14389> (besucht am 03.07.2023). preprint (siehe S. 64).
- [117] Qicheng Chang, Yishen Wang, Xiao Lu, Di Shi, Haifeng Li, Jiajun Duan und Zhiwei Wang. „Probabilistic Load Forecasting via Point Forecast Feature Integration“. In: *2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia)*. 2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia). Mai 2019, S. 99–104 (siehe S. 64).
- [118] Honglin Wen, Jie Gu, Jinghuan Ma, Lyuzerui Yuan und Zhijian Jin. „Probabilistic Load Forecasting via Neural Basis Expansion Model Based Prediction Intervals“. In: *IEEE Transactions on Smart Grid* 12.4 (Juli 2021), S. 3648–3660 (siehe S. 64).
- [119] Martin Felder, Frank Sehnke, Kay Ohnmeiß, Leon Schröder, Constantin Junk und Anton Kaifel. „Probabilistic Short Term Wind Power Forecasts Using Deep Neural Networks with Discrete Target Classes“. In: *Advances in Geosciences* 45 (19. Juli 2018), S. 13–17 (siehe S. 65).
- [120] Martin Felder, Anton Kaifel und Alex Graves. „Wind Power Prediction Using Mixture Density Recurrent Neural Networks“. In: European Wind Energy Conference and Exhibition. 2010 (siehe S. 65).
- [121] K. P. Dahal, J. R. McDonald und G. M. Burt. „Modern Heuristic Techniques for Scheduling Generator Maintenance in Power Systems“. In: *Transactions of the Institute of Measurement and Control* 22.2 (Juni 2000), S. 179–194 (siehe S. 66).
- [122] M. Carrion und J.M. Arroyo. „A Computationally Efficient Mixed-Integer Linear Formulation for the Thermal Unit Commitment Problem“. In: *IEEE Transactions on Power Systems* 21.3 (Aug. 2006), S. 1371–1378 (siehe S. 66).

- [123] Guanglin Zhang, Yu Cao, Yongsheng Cao, Demin Li und Lin Wang. „Optimal Energy Management for Microgrids with Combined Heat and Power (CHP) Generation, Energy Storages, and Renewable Energy Sources“. In: *Energies* 10.9 (29. Aug. 2017), S. 1288 (siehe S. 66).
- [126] J.M. Arroyo und A.J. Conejo. „Optimal Response of a Thermal Unit to an Electricity Spot Market“. In: *IEEE Transactions on Power Systems* 15.3 (Aug. 2000), S. 1098–1104 (siehe S. 68).
- [127] Cherrelle Eid, Elta Koliou, Mercedes Valles, Javier Reneses und Rudi Hakvoort. „Time-Based Pricing and Electricity Demand Response: Existing Barriers and next Steps“. In: *Utilities Policy* 40 (Juni 2016), S. 15–25 (siehe S. 68).
- [128] Christoph M. Flath und Sebastian Gottwalt. „Price-Based Load Coordination Revisited: Augmenting Open-Loop Coordination Approaches“. In: *Business Research* 9.1 (1. Apr. 2016), S. 157–178 (siehe S. 68, 92).
- [129] Hao Liang und Weihua Zhuang. „Stochastic Modeling and Optimization in a Microgrid: A Survey“. In: *Energies* 7.4 (31. März 2014), S. 2027–2050 (siehe S. 70).
- [130] Ren-Shiou Liu und Yu-Feng Hsu. „A Scalable and Robust Approach to Demand Side Management for Smart Grids with Uncertain Renewable Power Generation and Bi-Directional Energy Trading“. In: *International Journal of Electrical Power & Energy Systems* 97 (Apr. 2018), S. 396–407 (siehe S. 70).
- [131] Hossein Lotfi und Amin Khodaei. „An Efficient Preprocessing Approach for Uncertainty Consideration in Microgrids“. In: (Mai 2016), S. 1–5 (siehe S. 70).
- [132] Warren B. Powell, Abraham George, Hugo Simão, Warren Scott, Alan Lamont und Jeffrey Stewart. „SMART: A Stochastic Multiscale Model for the Analysis of Energy Resources, Technology, and Policy“. In: *INFORMS Journal on Computing* 24.4 (Nov. 2012), S. 665–682 (siehe S. 70).
- [133] Farhad Samadi Gazijahani und Javad Salehi. „An Efficient Scenario-Based Stochastic Model for Dynamic Operational Scheduling of Community Microgrids with High Penetration Renewables“. 11. Nov. 2017 (siehe S. 70).
- [134] S. Armagan Tarim, Suresh Manandhar und Toby Walsh. „Stochastic Constraint Programming: A Scenario-Based Approach“. In: *Constraints* 11.1 (Jan. 2006), S. 53–80 (siehe S. 70).
- [135] Matt Wytock, Nicholas Moehle und Stephen Boyd. „Dynamic Energy Management with Scenario-Based Robust MPC“. In: *IEEE*, Mai 2017, S. 2042–2047 (siehe S. 70).
- [136] Qipeng P. Zheng, Jianhui Wang und Andrew L. Liu. „Stochastic Optimization for Unit Commitment - A Review“. In: *IEEE Transactions on Power Systems* 30.4 (Juli 2015), S. 1913–1924 (siehe S. 70).
- [137] Pierre Pinson, Henrik Madsen, Henrik Aa. Nielsen, George Papaefthymiou und Bernd Klöckl. „From Probabilistic Forecasts to Statistical Scenarios of Short-Term Wind Power Production“. In: *Wind Energy* 12.1 (Jan. 2009), S. 51–62 (siehe S. 71).

- [138] N. Growe-Kuska, H. Heitsch und W. Romisch. „Scenario Reduction and Scenario Tree Construction for Power Management Problems“. In: Bd. 3. IEEE, 2003, S. 152–158 (siehe S. 71).
- [139] C. Gentile, G. Morales-España und A. Ramos. „A Tight MIP Formulation of the Unit Commitment Problem with Start-up and Shut-down Constraints“. In: *EURO Journal on Computational Optimization* 5.1 (März 2017), S. 177–201 (siehe S. 73).
- [140] Jiaming Li, Xiaomeng Ai und Jinyu Wen. „Constraints of Wind Power Ramp Event in Robust Unit Commitment“. In: IEEE, Juli 2016, S. 1–5 (siehe S. 73).
- [141] Deepak Rajan und Samer Takriti. *Minimum Up/Down Polytopes of the Unit Commitment Problem with Start-Up Cost*. IBM Research Report. IBM, 2005, S. 14 (siehe S. 73).
- [142] *LAZARD 's Levelized Cost of Storage Analysis – Version 3.0*. 3. New York, NY, USA: Lazard, Nov. 2017 (siehe S. 75).
- [143] Tien Nguyen, Jacob Spendelow und Robert Margolis. *Levelized Costs of Electricity from CHP and PV*. Department of Energy, März 2014 (siehe S. 75).
- [144] Christoph Kost und Thomas Schlegl. *Levelized Cost of Electricity- Renewable Energy Technologies*. Fraunhofer ISE, März 2018 (siehe S. 75).
- [145] Bram L. Gorissen, İhsan Yanıkoğlu und Dick den Hertog. „A Practical Guide to Robust Optimization“. In: *Omega* 53 (Juni 2015), S. 124–137 (siehe S. 77).
- [146] Mayuresh V. Kothare, Venkataramanan Balakrishnan und Manfred Morari. „Robust Constrained Model Predictive Control Using Linear Matrix Inequalities“. In: *Automatica* 32.10 (Okt. 1996), S. 1361–1379 (siehe S. 77).
- [147] Stephen Boyd. „Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers“. In: *Foundations and Trends® in Machine Learning* 3.1 (2010), S. 1–122 (siehe S. 80, 83, 84, 113, 114).
- [148] Hao Chen, Yu Ye, Ming Xiao, Mikael Skoglund und H. Vincent Poor. *Coded Stochastic ADMM for Decentralized Consensus Optimization with Edge Computing*. 2. Okt. 2020. arXiv: 2010.00914 [cs]. URL: <http://arxiv.org/abs/2010.00914> (besucht am 21.01.2023). preprint (siehe S. 80).
- [149] Meng Ma, Athanasios N. Nikolakopoulos und Georgios B. Giannakis. „Hybrid ADMM: A Unifying and Fast Approach to Decentralized Optimization“. In: *EURASIP Journal on Advances in Signal Processing* 2018.1 (Dez. 2018), S. 73 (siehe S. 80).
- [150] T. Zhang und Z. Shen. „A Fundamental Proof of Convergence of Alternating Direction Method of Multipliers for Weakly Convex Optimization“. In: *Journal of Inequalities and Applications* 2019.1 (2019) (siehe S. 82).
- [154] A. Shafiu, N. Jenkins und G. Strbac. „Measurement Location for State Estimation of Distribution Networks with Generation“. In: *IEE Proceedings - Generation, Transmission and Distribution* 152.2 (2005), S. 240 (siehe S. 87).
- [155] Department of Energy. *Factors Affecting PMU Installation Costs*. 2014 (siehe S. 88).

- [156] Frank Sehnke, Christian Osendorfer, Thomas Rückstieß, Alex Graves, Jan Peters und Jürgen Schmidhuber. „Parameter-Exploring Policy Gradients“. In: *Neural Networks* 23.4 (Mai 2010), S. 551–559 (siehe S. 89).
- [157] S.K Aditya und D Das. „Battery Energy Storage for Load Frequency Control of an Interconnected Power System“. In: *Electric Power Systems Research* 58.3 (Juli 2001), S. 179–185 (siehe S. 91).
- [158] Alexandre Oudalov, Daniel Chartouni und Christian Ohler. „Optimizing a Battery Energy Storage System for Primary Frequency Control“. In: *IEEE Transactions on Power Systems* 22.3 (Aug. 2007), S. 1259–1266 (siehe S. 91).
- [159] Marc Beaudin, Hamidreza Zareipour, Anthony Schellenberglabe und William Rosehart. „Energy Storage for Mitigating the Variability of Renewable Electricity Sources: An Updated Review“. In: *Energy for Sustainable Development* 14.4 (1. Dez. 2010), S. 302–314 (siehe S. 91).
- [160] K.C. Divya und Jacob Østergaard. „Battery Energy Storage Technology for Power Systems—An Overview“. In: *Electric Power Systems Research* 79.4 (Apr. 2009), S. 511–520 (siehe S. 91).
- [161] Helder Lopes Ferreira, Raquel Garde, Gianluca Fulli, Wil Kling und Joao Pecas Lopes. „Characterisation of Electrical Energy Storage Technologies“. In: *Energy* 53 (1. Mai 2013), S. 288–298 (siehe S. 91).
- [162] Carlos Mateo, Álvaro Sánchez, Pablo Frías, Andrea Rodriguez-Calvo und Javier Reneses. „Cost–Benefit Analysis of Battery Storage in Medium-Voltage Distribution Networks“. In: *IET Generation, Transmission & Distribution* 10.3 (18. Feb. 2016), S. 815–821 (siehe S. 91).
- [163] P. Lazzeroni und M. Repetto. „Optimal Planning of Battery Systems for Power Losses Reduction in Distribution Grids“. In: *Electric Power Systems Research* 167 (Feb. 2019), S. 94–112 (siehe S. 91).
- [164] Etta Grover-Silva, Robin Girard und George Kariniotakis. „Optimal Sizing and Placement of Distribution Grid Connected Battery Systems through an SOCP Optimal Power Flow Algorithm“. In: *Applied Energy* 219 (Juni 2018), S. 385–393 (siehe S. 91, 92).
- [165] Subhonmesh Bose, Dennice F. Gayme, Ufuk Topcu und K. Mani Chandy. „Optimal Placement of Energy Storage in the Grid“. In: *2012 IEEE 51st IEEE Conference on Decision and Control (CDC)*. 2012 IEEE 51st Annual Conference on Decision and Control (CDC). Maui, HI, USA: IEEE, Dez. 2012, S. 5605–5612 (siehe S. 92).
- [166] Tuba Gözel und M. Hakan Hocaoglu. „An Analytical Method for the Sizing and Siting of Distributed Generators in Radial Systems“. In: *Electric Power Systems Research* 79.6 (Juni 2009), S. 912–918 (siehe S. 92).
- [167] Prem Prakash und Dheeraj K. Khatod. „Optimal Sizing and Siting Techniques for Distributed Generation in Distribution Systems: A Review“. In: *Renewable and Sustainable Energy Reviews* 57 (Mai 2016), S. 111–130 (siehe S. 92).

- [168] Mahdi Motalleb, Ehsan Reihani und Reza Ghorbani. „Optimal Placement and Sizing of the Storage Supporting Transmission and Distribution Networks“. In: *Renewable Energy* 94 (Aug. 2016), S. 651–659 (siehe S. 92).
- [169] Juan P. Fossati, Ainhoa Galarza, Ander Martín-Villate und Luis Fontán. „A Method for Optimal Sizing Energy Storage Systems for Microgrids“. In: *Renewable Energy* 77 (Mai 2015), S. 539–549 (siehe S. 92).
- [170] Ali Ahmadian, Mahdi Sedghi, Masoud Aliakbar-Golkar, Ali Elkamel und Michael Fowler. „Optimal Probabilistic Based Storage Planning in Tap-Changer Equipped Distribution Network Including PEVs, Capacitor Banks and WDGs: A Case Study for Iran“. In: *Energy* 112 (Okt. 2016), S. 984–997 (siehe S. 92).
- [171] Amirsaman Arabali, Mahmoud Ghofrani und Mehdi Etezadi-Amoli. „Cost Analysis of a Power System Using Probabilistic Optimal Power Flow with Energy Storage Integration and Wind Generation“. In: *International Journal of Electrical Power & Energy Systems* 53 (Dez. 2013), S. 832–841 (siehe S. 92).
- [172] Thongchart Kerdphol, Yaser Qudaih und Yasunori Mitani. „Battery Energy Storage System Size Optimization in Microgrid Using Particle Swarm Optimization“. In: *IEEE PES Innovative Smart Grid Technologies, Europe. 2014 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)*. Istanbul, Turkey: IEEE, Okt. 2014, S. 1–6 (siehe S. 92).
- [173] Ling Ai Wong, Vigna K. Ramachandaramurthy, Phil Taylor, J.B. Ekanayake, Sara L. Walker und Sanjeevikumar Padmanaban. „Review on the Optimal Placement, Sizing and Control of an Energy Storage System in the Distribution Network“. In: *Journal of Energy Storage* 21 (Feb. 2019), S. 489–504 (siehe S. 92).
- [174] Pavithra Harsha und Munther Dahleh. „Optimal Management and Sizing of Energy Storage Under Dynamic Pricing for the Efficient Integration of Renewable Energy“. In: *IEEE Transactions on Power Systems* 30.3 (Mai 2015), S. 1164–1181 (siehe S. 92).
- [175] Marcus Müller, Lorenz Viernstein, Cong Nam Truong, Andreas Eiting, Holger C. Hesse, Rolf Witzmann und Andreas Jossen. „Evaluation of Grid-Level Adaptability for Stationary Battery Energy Storage System Applications in Europe“. In: *Journal of Energy Storage* 9 (Feb. 2017), S. 1–11 (siehe S. 93).
- [176] Vikas Bansal. „Building a Bankable Solar + Energy Storage Project“. In: *PV-Magazine* (2018) (siehe S. 93).
- [177] Linda Rupp, Marc Brunner und Stefan Tenbohlen. „Einfluss dezentraler Wärmepumpen auf die Netzausbaukosten des Niederspannungsnetzes“. In: (14. Jan. 2015). Unter Mitarb. von Technische Universität Dortmund, Technische Universität Dortmund, Andreas Kubis, Christian Rehtanz, Anton Shapovalov, Dominik Hilbrich und Ewa Plota (siehe S. 93).
- [178] Hofman und Oswald. *Vergleich Erdkabel – Freileitung Im 110-kV-hochspannungsbereich*. 2010 (siehe S. 94).

- [179] Klaus Heuck, Klaus-Dieter Dettmann und Detlef Schulz. „Elektrische Energieversorgung“. Wiesbaden: Vieweg+Teubner, 2010 (siehe S. 94).
- [181] Rodrigo Martins, Petr Musilek, Holger C Hesse, Johanna Jungbauer, Thomas Vorbuchner und Andreas Jossen. „Linear Battery Aging Model for Industrial Peak Shaving Applications“. In: *2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)*. IEEE, 2018, S. 1–6 (siehe S. 98).
- [182] Michael Koller, Theodor Borsche, Andreas Ulbig und Goran Andersson. „Defining a Degradation Cost Function for Optimal Control of a Battery Energy Storage System“. In: IEEE, Juni 2013, S. 1–6 (siehe S. 98).
- [183] Ibrahim Reda und Afshin Andreas. „Solar Position Algorithm for Solar Radiation Applications“. In: *Solar Energy* 76.5 (2004), S. 577–589 (siehe S. 106).
- [184] Volker Quaschnig. „Regenerative Energiesysteme: Technologie-berechnung-simulation“. Carl Hanser Verlag GmbH Co KG, 2013 (siehe S. 106).
- [185] Maria Magdalena Eberspächer. „Methoden Zur PV-Ertragsberechnung Aus Einstrahlungsdaten“. Forschungsarbeit. Universität Stuttgart, 2015 (siehe S. 107).
- [186] Robert W. Andrews, Joshua S. Stein, Clifford Hansen und Daniel Riley. „Introduction to the Open Source PV LIB for Python Photovoltaic System Modelling Package“. In: *2014 IEEE 40th Photovoltaic Specialist Conference (PVSC)*. 2014 IEEE 40th Photovoltaic Specialists Conference (PVSC). Denver, CO, USA: IEEE, Juni 2014, S. 0170–0174 (siehe S. 107).
- [187] John E Hay und John A Davies. „Calculation of the Solar Radiation Incident on an Inclined Surface“. In: *Proc. of First Canadian Solar Radiation Data Workshop (Eds: JE Hay and TK Won), Ministry of Supply and Services Canada*. Bd. 59. 1980 (siehe S. 107).
- [188] DT Reindl, WA Beckman und JA Duffie. „Evaluation of Hourly Tilted Surface Radiation Models“. In: *Solar Energy* 45.1 (1990), S. 9–17 (siehe S. 108).
- [189] Thomas M Klucher. „Evaluation of Models to Predict Insolation on Tilted Surfaces“. In: *Solar Energy* 23.2 (1979), S. 111–114 (siehe S. 108).
- [190] PV Performance Modeling Collaborative. *Simple Sandia Sky Diffuse Model*. Jan. 2015 (siehe S. 109).
- [191] Richard Perez, Robert Seals, Pierre Ineichen, Ronald Stewart und David Menicucci. „A New Simplified Version of the Perez Diffuse Irradiance Model for Tilted Surfaces“. In: *Solar Energy* 39.3 (1987), S. 221–231 (siehe S. 109).
- [192] R. Perez, R. Stewart, R. Seals und T. Guertin. „The Development and Verification of the Perez Diffuse Radiation Model“. In: *SANDIA Report SAND88-7030* (1988) (siehe S. 109).
- [193] Richard Perez, Pierre Ineichen, Robert Seals, Joseph Michalsky und Ronald Stewart. „Modeling Daylight Availability and Irradiance Components from Direct and Global Irradiance“. In: *Solar Energy* 44.5 (1990), S. 271–289 (siehe S. 109–111).

- [194] Eugene L Maxwell. *A Quasi-Physical Model for Converting Hourly Global Horizontal to Direct Normal Insolation*. Solar Energy Research Inst., Golden, CO (USA), 1987 (siehe S. 110).