

FRAUNHOFER-INSTITUT FÜR ENERGIEWIRTSCHAFT UND ENERGIESYSTEMTECHNIK



Environment for Modelling and
Planning Robust Investments of
Sector-integrated Energy systems

EMPRISE FRAMEWORK – ROBUSTE AUSBAUENTSCHEIDUNGEN MITTELS STOCHASTISCHER OPTIMIERUNG

Teilbericht im Rahmen des Projektes: DeVKopSys

Dr. Philipp Härtel

Fraunhofer-Institut für Energiewirtschaft und Energiesystemtechnik (Fraunhofer IEE)

Fördergeber: Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit
Förderkennzeichen: 16EM4005-1
Förderprogramm Erneuerbar Mobil

Veröffentlichung im Juli 2021

Gefördert durch:



Bundesministerium
für Umwelt, Naturschutz
und nukleare Sicherheit

aufgrund eines Beschlusses
des Deutschen Bundestages

Inhalt

1	Einführung	4
1.1	Motivation	4
1.2	Zielsetzung.....	4
1.3	Vorüberlegungen und Prämissen.....	5
2	Planung von Energiesystemen unter Unsicherheit	6
2.1	Herausforderungen an Planungsmodelle	6
2.2	Unsicherheit und Risiko	9
2.3	Methodische Ansätze zur Entscheidungsfindung unter Unsicherheit	11
2.4	Zwei- und mehrstufige stochastische Programmierung	13
3	Methodik	15
3.1	Neuer Modellierungs- und Optimierungsansatz.....	15
3.2	Implementierung.....	18
3.3	Verteilter Progressive-Hedging-Algorithmus	19
4	Fallstudie	21
4.1	Aufbau	21
4.2	Konvergenz des verteilten Ansatzes	23
4.3	Robuste Investitionsentscheidungen	24
5	Schlussfolgerungen	25
6	Literaturverzeichnis	26

1 Einführung

1.1 Motivation

Akteure im Energiesystem sind mit einer Vielzahl an Unsicherheiten konfrontiert. Das mittlerweile breit angenommene Paradigma der Klimaneutralität bringt in diesem Kontext neue Komplexität und neue Unübersichtlichkeiten mit sich. Eine Energiewende hin zur Klimaneutralität stellt entscheidungstragende Instanzen auf übergeordneter und struktureller Ebene vor neue Herausforderungen. Zur Unterstützung und Findung robuster Entscheidungen für Investitions- und Betriebsprobleme müssen quantitative Entscheidungsmodelle daher zunehmend in der Lage sein, operative und strategische Unsicherheiten zu berücksichtigen.

Zwei- und mehrstufige stochastische Programmieransätze können hier einen entscheidenden Beitrag leisten, insbesondere gegenüber traditionell deterministischen Ansätzen. Bei der Planung von Transformationspfaden hin zu treibhausgasneutralen Energiesystemen können diese relevante Unsicherheitsinformationen wie bspw. politisch gesetzte Energie- und Klimaziele (CO₂-Preise oder -Minderungsziele), Investitions- und -Betriebskostennahmen (Wind und PV), oder Konsumentenverhalten (flexible vs. unflexibles Ladeverhalten von Elektrofahrzeugen) endogen berücksichtigen und somit Risiken von „strandet assets“ reduzieren.

1.2 Zielsetzung

Ziel dieses Teilprojekts war die Entwicklung und Implementierung eines skalierbaren methodischen Ansatzes für die gezielte Untersuchung

- (1) mehrperiodiger Kapazitätsausbauplanungsprobleme der Energiesystemanalyse
- (2) unter Berücksichtigung relevanter strategischer und operativer Unsicherheiten.

Der neue methodische Ansatz dient der Ermittlung robuster Ausbauentscheidungen durch die modellendogene Berücksichtigung entscheidender Sensitivitäten im langfristigen Energiesystem und dessen Transformation hin zur Klimaneutralität.

1.3 Vorüberlegungen und Prämissen

Für die Motivation und Bearbeitung des Projektes gab es eine Reihe von Vorüberlegungen und Prämissen, die nachfolgend aufgelistet und kurz erläutert werden.

- Im Hinblick auf die methodischen Ansätze für die Planungsprobleme in der Energiesystemanalyse gibt es eine Notwendigkeit zur Loslösung von einer deterministischen Weltsicht, denn theoretische Überlegungen zeigen, dass der beste Plan zur Absicherung gegen Unsicherheiten möglicherweise nicht wie eine der optimalen Entscheidungen aussieht, die für Planungsprobleme auf Basis einzelner Szenarien oder Parametersensitivitäten erhalten wurden [1]. Das bedeutet, dass die Gemeinsamkeiten zwischen deterministischen Lösungen, die auf perfekten Informationen basieren, nicht unbedingt eine robuste Empfehlung oder Empfehlung mit geringstem Bedauern („least-regret“) für die Entscheidungsträger darstellen [2].
- Deterministische Ansätze sind nach wie vor wichtig und wertvoll für Detailbetrachtungen und das Aufzeigen theoretisch optimaler Entwicklungen (z. B. für Referenzbetrachtungen).
- Die an die methodischen Ansätze der Energiesystemanalyse gestellten Anforderungen sind ohnehin bereits hoch. Eine Betrachtung zusätzlicher Komplexität und Unsicherheit kann zunächst nicht mit Umfang und Granularität der Systemabbildung (insb. zeitlich, räumlich, sowie auch Anzahl und Details von Systemkomponenten) deterministischer Ansätze mithalten, wie bspw. dem Modellierungs- und Optimierungs-Framework SCOPE SD. Die implizite Annahme ist daher, dass pfadabhängige Wechselwirkungen und die endogene Berücksichtigung kurz- bis langfristiger Unsicherheiten bedeutendere Effekte für die Ermittlung optimaler Systemzustände aufzeigen können.
- Der Fokus der Arbeiten lag bereits von Beginn an auf der Skalierbarkeit des neuen methodischen Ansatzes (Nutzung von Parallelisierung auf einem HPC-Cluster am Fraunhofer IEE), da andernfalls keine Problemgrößen behandelt werden können, die für die sinnvolle Beantwortung aktueller energiewirtschaftlicher Fragestellungen unbedingt notwendig sind.
- Die neue Modellierungs- und Optimierungsumgebung soll eine endogene Betrachtung von einer Auswahl relevanter Kombinationen operativer und strategischer Unsicherheiten flexibel ermöglichen – jedoch nicht aller denkbaren Unsicherheitskombinationen.
- Der neue methodische Ansatz ist als quelloffene Software entwickelt und in Python/Pyomo/PySP implementiert worden. Das hierbei entstandene „Environment for Modelling and Planning Robust Investments in Sector-integrated Energy systems (EMPRISE)“ kann in seinem jeweils aktuellen Stand unter folgendem GitHub-Repository abgerufen und unter der „GPL-3.0 License“ genutzt werden:

<https://github.com/philipphaertel/EMPRISE>

2 Planung von Energiesystemen unter Unsicherheit

2.1 Herausforderungen an Planungsmodelle

Sowohl für die angewandte Forschung im Bereich der Energiesystemanalyse als auch für die Energiewirtschaft sind quantitative Analysemodelle zentrale Werkzeuge zur Unterstützung von Investitions- und Systembetriebsentscheidungen diverser Akteure. Modellierungs- und Optimierungs-Frameworks, insbesondere auf Basis mathematischer Programmierung, sind wesentliche Bestandteile zur Bewältigung der zugrundeliegenden Planungsprobleme.

Um die Komplexität der Planungsprobleme in der Energiesystemanalyse darzulegen, werden im Folgenden die wesentlichen Anforderungen an die Systemabbildung in Modellierungs- und Optimierungs-Frameworks dargestellt. Während die hier beschriebenen Herausforderungen für alle Arten von analytischen Frameworks gelten, die zur Entscheidungsunterstützung für Planungsprobleme in aktuellen und zukünftigen Energiesystemen, werden in den folgenden Abschnitten insbesondere Probleme der Kapazitätsausbauplanung („Capacity Expansion Planning“) als Beispiel für die zugrundeliegenden Herausforderungen und Lösungen betrachtet. Diese stellen zudem den Kern des EMPRISE-Frameworks dar, das im Rahmen dieses Projekts entwickelt wurde.

Adäquate Analysemodelle zur (quantitativen) Entscheidungsunterstützung bei der Entwicklung und Transformation in Energiesystemen müssen eine Vielzahl von Anforderungen erfüllen, um eine zuverlässige Entscheidungshilfe für die Entwicklung wirtschaftlich effizienter und klimaneutraler Energiemärkte und -infrastrukturen zu liefern. Die damit verbundenen Herausforderungen führen zu großen und komplexen Systemen, die bei der Planung künftiger Investitionen eine größere betriebliche und verwaltungstechnische Flexibilität als bisher erfordern. Entscheidend ist daher, wie statische und dynamische Details der Systemkomponenten und ihrer sektorenübergreifenden Interaktion in den Analysen dargestellt werden können. Als notwendige Konsequenz nehmen der in den Modellierungs- und Optimierungs-Frameworks repräsentierte Systemumfang („scope“) und die Systemgranularität („granularity“) in deren Komplexität zwangsläufig zu [2].

Während der Systemumfang die Systemgrenze der für die Analyseentscheidungen relevanten „system representation domain“ bestimmt, legt die betrachtete Granularität einer Systemabbildungsdimension den Maßstab bzw. Detaillierungsgrad der analysierten Datenmenge fest. Genauer gesagt bezieht sich die Granularität auf die kleinste Einheit, die ein Analyserahmen explizit definiert und mit der er arbeitet, z. B. in Form einer modellierten Entscheidungsvariable und den zugehörigen Nebenbedingungen.

Bei der Entwicklung eines Entscheidungsmodells für die Energiesystemanalyse müssen diverse konzeptionelle Entscheidungen für die Abbildung statischer und dynamischer Aspekte des Systems getroffen werden, die sich entlang der folgenden konzeptionellen „system representation domains“ kategorisieren lassen, siehe [2] für eine detaillierte Diskussion des jeweiligen Umfangs und der Granularität:

- „**Spatial** system representation domain“;
- „**Temporal** system representation domain“;
- „**Network** system representation domain“;
- „**Sector and market** system representation domain“;
- „**Technology** system representation domain“.

Wenngleich wünschenswert, sei an dieser Stelle angemerkt, dass es nicht immer praktikabel oder auch notwendig ist, alle oben genannten „system representation domains“ in vollem Umfang und mit voller Granularität zu abbilden, siehe z. B. [3]. Je nach Forschungsfrage und Schwerpunkt der Entscheidungsfindung und den Zielen der quantitativen Analyseaufgabe kann es sinnvoll sein, vereinfachende Annahmen zu treffen und die Komplexität des Planungsproblems zu reduzieren. Weiterhin können die genannten konzeptionellen nützlich bei der Auswahl von Aggregations- und Dekompositionsansätzen sein.

Zur Veranschaulichung zeigt Abbildung 1 die allgemeine Struktur des am Fraunhofer IEE entwickelten Modellierungs- und Optimierungs-Frameworks SCOPE Scenario Development (SD) [4]. Das lineare Optimierungsmodell wird zur Lösung des sektorenübergreifenden Kapazitätsausbauplanungsproblems („cross-sectoral capacity expansion planning“) genutzt. Es umfasst eine Vielzahl an Technologieoptionen und deren Kombinationen sowie diverser Märkte für die Szenarientwicklung und Transformationsanalyse des europäischen Strom- und Energiesystems hin zur Klimaneutralität. Zu diesem Zweck werden große Mengen an strukturellen und zeitreihenbasierten Eingangsdaten benötigt, die die resultierenden Optimierungs-probleminstanzen des vergleichsweise einfachen methodischen Ansatzes zu einer Herausforderung machen.

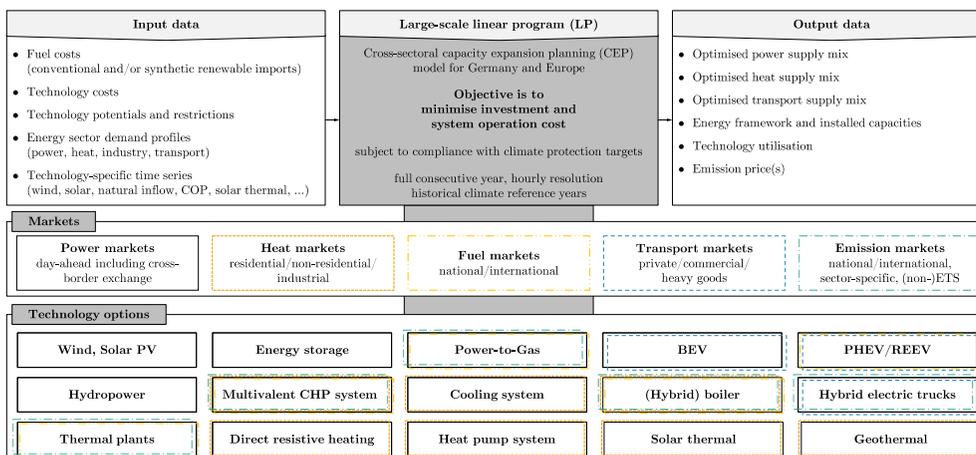


Abbildung 1: Übersicht des SCOPE-SD-Frameworks zur Modellierung und Optimierung sektoren-übergreifender Ausbau-planungsprobleme im zukünftigen europäischen Energiesystem

Quelle: eigene Darstellung basierend auf [4], [2].

Neben der Abbildung statischer und dynamischer Eigenschaften zukünftiger Strom- und Energiesysteme gibt es weitere Anforderungen an die Planungsmodelle, die eine detaillierte Auseinandersetzung während der konzeptionellen Entwicklung von Energiesystemmodellen erfordern. Nach [2] und [5] beinhalten diese unter anderem die Berücksichtigung von:

- Unvollkommenes Marktgeschehen
- Koordinierung von Investitionsentscheidungen unterschiedlicher Akteure in Energieübertragungsinfrastruktur, Energieerzeugung, Energiespeicher sowie Energieverbrauchsanwendungen und deren -technologien unter Berücksichtigung unterschiedlicher Zielfunktionen, z. B. Wohlfahrtsmaximierung vs. Profitmaximierung eines Portfoliobetreibers;
- Vorausschauendes Investitionsverhalten durch Berücksichtigung von Unsicherheit;
- Wert des Verschiebens, Erweiterns, Aufteilens oder Zurücknehmens von Entscheidungen („managerial flexibility“);
- Strategisches Verhalten zwischen Investoren (insb. hierarchische Spiele);
- Versorgungssicherheit sowie seltene und Extremereignisse.

Vorausschauendes Verhalten beim Treffen von Investitionsentscheidungen bezieht sich im Wesentlichen auf die (endogene) Berücksichtigung von Unsicherheiten als einem zentralen Treiber in Entscheidungsmodellen. Insbesondere wenn Investitionsprojekte sich durch lange Vorlaufzeiten und Lebensdauern, intensive Kapitalstrukturen sowie die potenzielle Unumkehrbarkeit von Entscheidungen auszeichnen (bspw. bei Energieinfrastrukturen wie Stromübertragungsnetzen oder Gasnetzen der Fall), besteht die Gefahr von „stranded assets“. Daher sind die dazugehörigen Planungsprobleme mit erheblichen Unsicherheiten und Risiken behaftet, die sich unter anderem aus den künftigen Kosten, Niveaus und Verläufen von Energieerzeugung und -nachfrage sowie regulatorischen Prozessen ergeben können.

2.2 Unsicherheit und Risiko

Das Verständnis des Unsicherheitsbegriffs und der Umgang bei der Planung unter Unsicherheit ist kein neuartiges Problem. In der Literatur geht die thematische Auseinandersetzung zumindest bis auf [6] zurück („Knightian uncertainty“), in der die beiden Begriffe „Risiko“ und „Unsicherheit“ voneinander abgrenzt werden.

Seitdem sind viele konzeptionelle Ansätze und Typologien zum Verständnis des Unsicherheitsbegriffs und dem Umgang mit Unsicherheiten entstanden. Geprägt durch domänenspezifisches Wissen sind in verschiedenen Disziplinen und Bereichen, darunter Betriebs- und Volkswirtschaftslehre, Finanzlehre, Sozialwissenschaften, Nachhaltigkeitslehre, sowie auch Politik und Militär, Kategorisierungs- und Konzeptualisierungsversuche unternommen worden.

Eine möglichen Verständnis der Begriffe Unsicherheit und Risiko im Kontext der Entscheidungsfindung begreift Risiken als die Folge von Unsicherheiten, und kann nach [7] wie folgt definiert werden:

- **Unsicherheit (Ursache):** ein Zustand, in dem es nicht möglich ist, den betehenden Zustand oder das zukünftige Ergebnis genau zu beschreiben;
- **Risiko (Konsequenz):** die, typischerweise negativen, Auswirkungen von Unsicherheiten in der Planung, die häufig als Gefahr wahrgenommen werden.

Für die Lösung von Planungsproblemen unter Unsicherheit müssen Ursachen und deren Zustände modelliert werden, während Risiken quantifiziert, gesteuert bzw. abgesichert werden müssen. Risiken umfassen dabei beispielsweise Kosten, volkswirtschaftlichen Nutzen, Zuverlässigkeit, umweltbedingte Externalitäten oder auch multikriterielle Maße.

Eine weiteres konzeptionelles Verständnis für die Entscheidungsfindung unter Unsicherheit ist in Abbildung 2 aufgezeigt, die mit einem Überblick zu Erwartungsstrukturen hinsichtlich der Umwelt die Begriffe Sicherheit, Unsicherheit und Risiko strukturell zueinander einordnet.

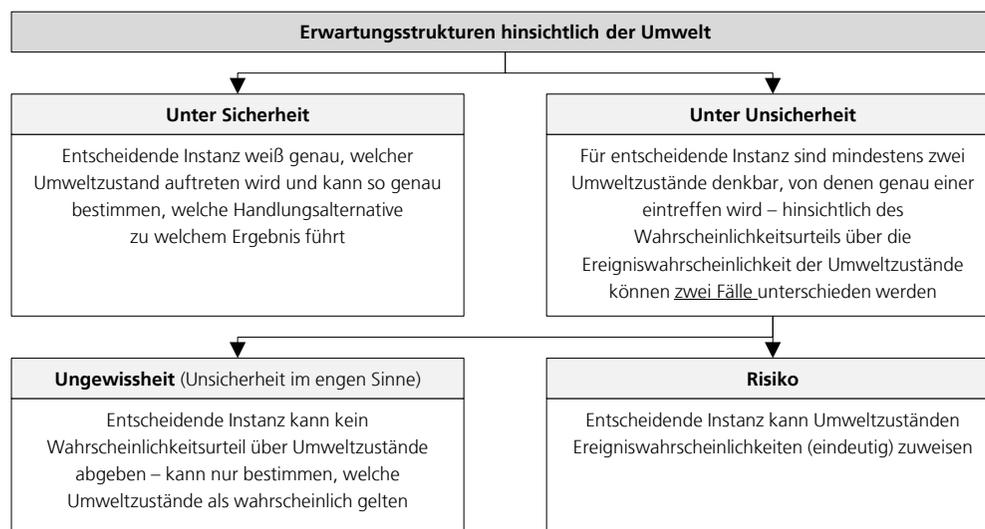


Abbildung 2: Überblick zu Erwartungsstrukturen hinsichtlich der Umwelt bei der Entscheidungsfindung

Quelle: eigene Darstellung.

Operative Unsicherheiten	Strategische Unsicherheiten		
Technisch-Physikalisch	Ökonomisch	Sozial-Ökologisch	Regulatorisch-Geopolitisch
<p>Unsicherheiten beeinflussen physikalische Infrastruktur des Energiesystems direkt und sind nicht kontrollierbar</p> <p>Modellierung häufig durch Zeitreihen und Wahrscheinlichkeitsverteilungen</p>	<p>Unsicherheiten sind das Ergebnis von ökonomischen Prozessen (Markträumung, Gleichgewicht)</p> <p>Modellierung häufig durch Zeitreihen und stochastische Prozesse bzw. Markov-Ketten</p>	<p>Unsicherheiten resultieren zumeist aus komplexen gesellschaftlichen Prozessen</p> <p>Modellierung häufig durch strategische Szenarien und Fallunterscheidungen</p>	<p>Unsicherheiten resultieren zumeist aus komplexen politischen Prozessen</p> <p>Modellierung häufig durch strategische Szenarien und Fallunterscheidungen</p>

Abbildung 3: Quellen von Unsicherheiten und Eingruppierung nach deren Auswirkung auf die Planung von Energiesystemen

Quelle: eigene Darstellung basierend auf [7].

Zur Berücksichtigung in Energiesystemmodellen ist eine Unterscheidung der Unsicherheiten hinsichtlich ihrer jeweiligen Quellen zielführend, wobei eine Zuordnung der Unsicherheiten nicht notwendigerweise trennscharf sein muss.

2.3 Methodische Ansätze zur Entscheidungsfindung unter Unsicherheit

Um beispielsweise vorausschauendes Investitionsverhalten in die Energiesystemplanungsprobleme einzubeziehen, müssen die quantitativen Entscheidungsmodelle und deren Modellierungsansätze die Unsicherheiten in expliziter Form berücksichtigen [2]. Im Allgemeinen gibt es mehrere Optimierungsansätze zum Umgang mit Unsicherheit in mathematischen Programmiermodellen, siehe z. B. [8], [9], [10], [11], [12], [7]:

- **(Deterministic Programming):** Fokus auf aleatorische Unsicherheit, d. h. die explizite und detaillierte Darstellung von Variationen, die großen und langlaufenden Zeitreihendatensätzen innewohnen;
- **Stochastic Programming** (zwei- oder mehrstufige Kompensation): primärer Fokus auf aleatorischer Unsicherheit, d. h. Darstellung von Zufallsparametern mit bekannten Wahrscheinlichkeitsverteilungen, die üblicherweise in Szenario-bäumen diskretisiert werden;
- **Robust Programming Programming** (mini-max oder regret): primärer Fokus auf epistemischer Unsicherheit, d. h. Darstellung zufälliger Parametern innerhalb bestimmter Grenzen (Unsicherheitsmenge) anstelle gut beschreibbarer Verteilungen;
- **Chance-constrained Programming:** im Vordergrund steht der Kompromiss zwischen Kosten und Robustheit, d. h. mit einer bestimmten Wahrscheinlichkeit, dass die gewählte Lösung machbar ist;
- **Fuzzy Programming:** primärer Fokus auf epistemischer Unsicherheit, d. h. Darstellung von Mehrdeutigkeit und Unklarheit;
- **Dynamic programming** (Realloptionsanalyse): primärer Fokus liegt auf der dynamischen Entscheidungsfindung unter Ungewissheit, bei der Entscheidungen sequenziell in der Zeit getroffen oder aktualisiert werden, wenn neue Informationen auftauchen.

Streng genommen können deterministische Programmierungsansätze Unsicherheit nicht direkt modellieren. Jedoch können deterministische Entscheidungsmodelle durch die explizite Einbeziehung umfangreicher Eingangsdatensätze in großer Detailtiefe eine Vielzahl an Systembetriebszuständen widerzuspiegeln, die in einem der anderen Ansätze lediglich als Zufallsparameter betrachtet werden können.

Stochastische Programmierungsansätze sind in vielen Anwendungsbereichen etabliert. Hierzu zählen unter anderem die Anwendungsfelder Energie, natürliche Ressourcen, Gesundheitswesen, Logistik, Telekommunikation oder das Finanzwesen. Im Rahmen dieses Projekts wurde sich für einen stochastischen Programmierungsansatz entschieden, wofür es zwei Gründe gibt. Erstens bieten diese mit zwei- und mehrstufigen Ansätzen flexible Möglichkeiten zur Implementierung unterschiedlicher Fragestellungen, deren Unsicherheiten und Entscheidungsdynamiken. Durch freie Wahl von Eintrittswahrscheinlichkeiten lassen sich hiermit auch Szenariostrukturen erstellen, die einem robusten Programmierungsansatz nahekommen können. Zweitens existieren bereits algebraische Modellierungsumgebungen für die effiziente Umsetzung stochastischer Programmierungsansätze, die zusammen mit den Anforderungen an die quelloffene Verwertung ein gewichtiges Entscheidungskriterium darstellen.

Entscheidungsmodelle zur Optimierung von Planungsproblemen unter Unsicherheit basieren häufig auf stochastischen Programmierungsansätzen. Aufgrund der hohen Rechenkomplexität sind viele der bisherigen Implementierungen, insbesondere für mehrstufige stochastische Entscheidungsprobleme, jedoch nur demonstrativ und wurden nur auf kleine Testsysteme angewendet [13]. Die gleichzeitige Entwicklung eines skalierbaren Lösungsansatzes für das neue Planungsmodell ist daher unbedingt notwendig, um Probleminstanzen realer Entscheidungsprobleme effizient behandeln und lösen zu können.

2.4 Zwei- und mehrstufige stochastische Programmierung

Das Hauptziel der stochastischen Programmierung ist es, optimale Entscheidungen in Problemen zu finden, die unsichere Eingangsparameter beinhalten, wobei ein sequentieller Prozess durch den Wechsel zwischen zu treffenden Entscheidungen und der Offenbarung unsicherer Informationen definiert ist [14]. Stochastische Programmierungsansätze können zudem mit unterschiedlichen Risikomaßen genutzt werden, d. h. in der Regel ein Erwartungswertansatz oder der „Conditional Value at Risk“ (CVaR).

Bei den stochastischen Optimierungsansätzen wird in der Regel zwischen zwei- und mehrstufigen Modellen unterschieden. Hierbei ist zu beachten, dass die Anzahl der Stufen von der Entscheidungsdynamik abhängt und nicht zwingend von der Anzahl der betrachteten Zeitperioden. Stochastische Programmierungsansätze mit Möglichkeit zur Kompensation („recourse“) können die Kompensationsabfolge

Entscheidung \Rightarrow Offenbarung von Unsicherheit \Rightarrow Reaktion bzw. Kompensation

demnach entweder einmalig (zweistufig) oder mehrfach (mehrstufig) beinhalten [15]. Alle Entscheidungsmodelle auf Basis zwei- oder mehrstufig stochastischer Ansätze erfordern die Wahl der Kompensationsentscheidungen („recourse decisions“), d. h. die Variablenklärung von „here-and-now“-Entscheidungen (erste Stufe) und „wait-and-see“-Entscheidungen (zweite oder weitere Stufe). Während die Entscheidungen der ersten Stufe vor der Offenbarung der Unsicherheiten getätigt werden müssen, können sich die Entscheidungen der nächsten Stufe ändern nachdem die unsicheren Parameter bekannt werden.

Zwei- und mehrstufige stochastische Planungsansätze können somit für unterschiedliche Zwecke genutzt werden. Die Wahl des Ansatzes hängt von der für die Forschungsfrage notwendigen Entscheidungsdynamik ab, d. h. konkret davon, in wie vielen Entscheidungsstufen sich Unsicherheit im Ansatz offenbaren soll. In folgender Abbildung 4 wird exemplarisch ein zweistufig stochastischer Szenarioaufbau für ein mehrperiodiges Kapazitätsausbauplanungsproblem mit zwei Entscheidungsstufen dargestellt. Hierbei wird deutlich, dass die optimierten Investitionsentscheidungen für die gezeigten Stützjahre 2020 und 2030 in der ersten Entscheidungsstufe („Stage I“) getroffen werden, d. h. vor Offenbarung der operativen Unsicherheit in der zweiten Entscheidungsstufe („Stage II“). Im Ergebnis führt dieser Aufbau zu einem „normativen“ Szenariopfad, der alle Investitionsentscheidungen für den gesamten Planungshorizont ermitteln würde.

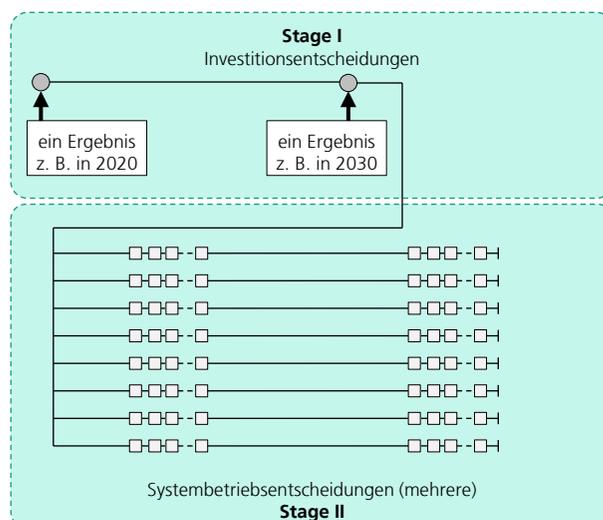


Abbildung 4: Exemplarischer zweistufig stochastischer Szenarioaufbau für mehrperiodige Kapazitätsausbauplanungsprobleme

Quelle: eigene Darstellung.

Im Vergleich zu Abbildung 4 zeigt Abbildung 5 einen exemplarischen mehrstufig stochastischen Szenarioaufbau eines mehrperiodigen Kapazitätsausbauplanungsproblems mit insgesamt drei Entscheidungsstufen („Stage I-III“).

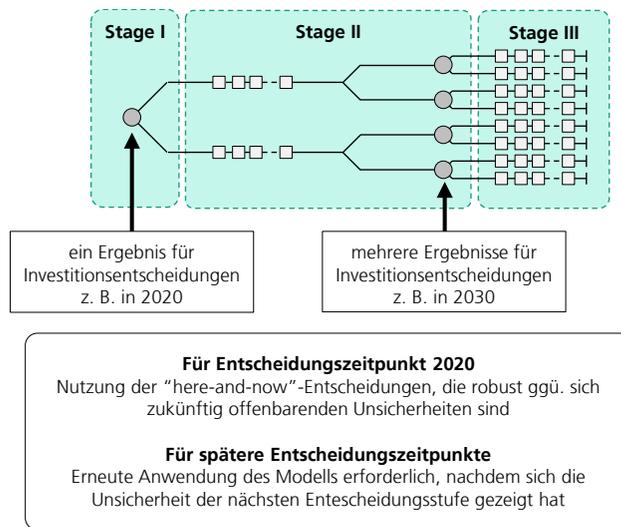


Abbildung 5: Exemplarischer mehrstufig stochastischer Szenarioaufbau für mehrperiodige Kapazitätsausbauplanungsprobleme

Quelle: eigene Darstellung.

Hinsichtlich der getroffenen Investitionsentscheidungen wird deutlich, dass dieser Ansatz auf Basis der strategischen und operativen Unsicherheiten nur eine „here-and-now“-Entscheidung für die Planungsperiode in 2020 ermittelt, und für die spätere Planungsperiode mehrere optimale Ergebnisse in Abhängigkeit der sich in der zweiten Entscheidungsstufe („Stage II“) offenbarenden Unsicherheit erhält.

3 Methodik

3.1 Neuer Modellierungs- und Optimierungsansatz

Der neu entwickelte Modellierungs- und Optimierungsansatz verfolgt die Ermittlung robuster Transformationspfade zu einem klimaneutralen Zielsystem unter Berücksichtigung strategischer und operativer Unsicherheiten. Hieraus leiten sich neben den bekannten Herausforderungen von sektorenintegrierten Energiesystemen zwei zentrale Aufgaben für die Entwicklung des Modellierungs- und Optimierungsansatzes ab:

- (1) Konsistente Ansätze für die Berücksichtigung mehrperiodiger Kapazitätsaus- und rückbauplanungsentscheidungen für das betrachtete Energiesystem,
- (2) Ansätze zur flexiblen Berücksichtigung relevanter strategischer und operativer Unsicherheiten sowie schnell individualisierbarer Entscheidungsdynamiken.

Zur Illustration der für die Ermittlung robuster Transformationspfade relevanten Investitions- und etwaiger Rückbauentscheidungen werden in Abbildung 6 die in EMPRISE berücksichtigten Eingangsdatenparameter und die vom Investitionszeitpunkt abhängig bestimmten Kostenkomponenten exemplarisch für eine Technologie und vier Planungsperioden dargestellt. Durch das dynamische Planungsproblem müssen hierbei Nettobarwerte einzelner Technologie(re)investitionen zu bestimmten Zeitpunkten und Betriebsperioden sowie der Zeitwert des Geldes (ZwdG) inklusive der ewigen Rente („perpetuity“) über den gesamten Planungshorizont berücksichtigt werden.

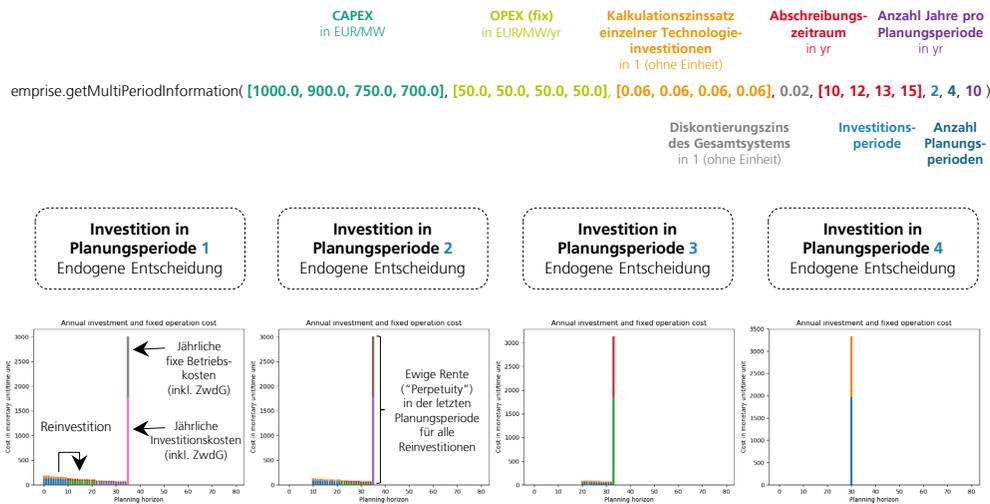


Abbildung 6: Eingangsdaten und Kostenkomponenten für die Ermittlung endogener Investitions- und Rückbauentscheidungen

Quelle: eigene Darstellung auf Basis eigener Berechnungen.

In Abbildung 7 sind die für die pfadabhängigen Aus- und Rückbauentscheidungen einzelner Technologieoptionen berücksichtigten Entscheidungsvariablen für ein mehrperiodiges Planungsproblem mit vier Investitions- und Systembetriebsperioden dargestellt. Diese sind entsprechend der in Abbildung 6 gezeigten Komponenten und Beziehungen mit Kosten- und Kompensationskoeffizienten in der Zielfunktion des Modellansatzes gewichtet.

		Operational period			
		1	2	3	4
Investment period	1	Capacity (1,1) New capacity (1)	Capacity (1,2) Decommissioned capacity (1,2)	Capacity (1,3) Decommissioned capacity (1,3)	Capacity (1,4) Decommissioned capacity (1,4)
	2		Capacity (2,2) New capacity (2)	Capacity (2,3) Decommissioned capacity (2,3)	Capacity (3,3) Decommissioned capacity (2,4)
	3			Capacity (3,3) New capacity (3)	Capacity (3,3) Decommissioned capacity (3,4)
	4				Capacity (4,4) New capacity (4)

Abbildung 7: Mehrperiodische Aus- und Rückbauentscheidungen in den einzelnen Planungsperioden und deren Entscheidungsvariablen

Quelle: eigene Darstellung.

Zur flexiblen Berücksichtigung relevanter strategischer und operativer Unsicherheiten sowie schnell individualisierbarer Entscheidungsdynamiken erlaubt der neu entwickelte Modellierungsansatz die individualisierte und automatische Erzeugung von Szenariobäumen zur Analyse mehrstufig stochastischer Entscheidungsprobleme. In Abbildung 8 wird ein möglicher mehrstufig stochastischer Szenariobaum aufbau für ein mehrperiodiges Entscheidungsproblem unter Unsicherheit gezeigt.

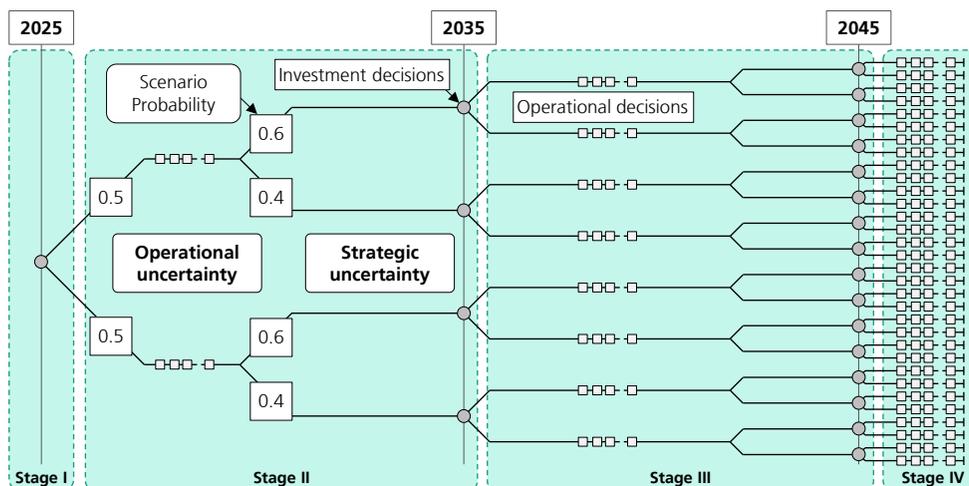


Abbildung 8: Exemplarischer mehrstufig stochastischer Szenarioaufbau für mehrperiodige Kapazitätsausbauplanungsprobleme

Quelle: eigene Darstellung.

Die Repräsentation von drei Planungsperioden mit sich nacheinander offenbarenden strategischen und operativen Unsicherheiten erfordert im gezeigten Beispiel die Berücksichtigung von drei Entscheidungsstufen, die mit den gezeigten zwei operativen Unsicherheitsszenarien (z. B. meteorologische Referenzjahre) und zwei strategischen Unsicherheitsszenarien (z. B. CO₂-Preisentwicklungspfade) zu insgesamt 32 Szenariopfaden im Szenariobaum führen.

Aus dem mehrstufig stochastischen Programmierungsansatz lässt sich die Zielfunktion mit Erwartungswertansatz in seiner generischen Form wie in Abbildung 7 darstellen:

$$\min_{(x_1, y_1) \in X_1} \left\{ f_1(x_1, y_1) + \mathbb{E} \left[\min_{(x_2, y_2) \in X_2(x_1)} \left\{ f_2(x_2, y_2) + \dots + \mathbb{E} \left[\min_{(x_T, y_T) \in X_T(x_{T-1})} \{ f_T(x_T, y_T) \} \right] \right\} \right] \right\}$$

Investitionskosten + Rückbaukompensation + Systembetriebskosten	Investitionskosten + Rückbaukompensation + Systembetriebskosten	Investitionskosten + Rückbaukompensation + Systembetriebskosten
---	---	---

Abbildung 9: Zielfunktion des mehrstufig stochastischen Planungsmodells im EMPRISE-Framework

Quelle: eigene Darstellung.

In jeder Entscheidungsstufe können – müssen aber nicht notwendigerweise – die Kosten- und Kompensationskomponenten der Investitions-, Rückbau- und Systembetriebsentscheidungen berücksichtigt sein. Diese Gesamtsystemkosten werden minimiert.

3.2 Implementierung



Environment for Modelling and
Planning Robust Investments of
Sector-integrated Energy systems

**Abbildung 10: Name und
aktuelles Logo des
EMPRISE-Frameworks**

Quelle: eigene Darstellung.

Der neue methodische Ansatz ist als quelloffene Software entwickelt und in Python sowie im Speziellen den Software-Paketen Pyomo [16] [17] und PySP [18] implementiert worden. Das hierbei entstandene „Environment for Modelling and Planning Robust Investments in Sector-integrated Energy systems (EMPRISE)“ (siehe Abbildung 10) kann in seinem jeweils aktuellen Stand unter folgendem GitHub-Repository abgerufen und unter der „GPL-3.0 License“ genutzt werden:

<https://github.com/philipphaertel/EMPRISE>

Zur Lösung der stochastischen Optimierungsprobleminstanzen wird die Funktionalität des Python-Package PySP [18] verwendet, welches das Lösen mehrstufig stochastischer Programme auf Basis von in Szenarien diskretisierten Unsicherheiten unterstützt. Die in PySP enthaltenen Bibliotheken vereinfachen den Prozess der algebraischen Formulierung stochastischer Programme durch die Automatisierung der Verwaltungs- und Modellkonstruktionsprozesse. Diese können im Wesentlichen auf die folgenden vier Schritte reduziert werden:

- (1) Formulierung des deterministischen Modells,
- (2) Spezifizierung der deterministischen Modelldaten,
- (3) Definition des Szenariobaums,
- (4) Spezifizierung der Szenarioinstanzdaten.

Aufgrund der Struktur mehrstufig stochastischer Szenariobäume wächst die Problemgröße exponentiell mit der Anzahl an Entscheidungsstufen. Daher wird die Lösung großer mehrstufig stochastischer Probleminstanzen schnell nicht mehr praktisch realisierbar. Die Probleme werden zu groß, um sie in ihrer monolithischen „extensive form“ lösen zu können. Neben zweistufig stochastischen Approximationen auf Basis eines rollierenden Optimierungszeithorizonts gibt es zwei wesentliche Dekompositionsansätze:

- **Szenario-Dekomposition** („scenario decomposition“): ermöglicht die Nutzung von „Progressive Hedging“-Verfahren;
- **Stufenweise Dekomposition** („stagewise decomposition“): ermöglicht die Nutzung von „Stochastic Dual Dynamic Programming“-Verfahren oder „Nested Benders“-Verfahren.

Für das EMPRISE-Framework wurde für die Nutzung eines Progressive-Hedging-Algorithmus auf Basis der Szenariodekomposition implementiert, der im nächsten Abschnitt näher beschrieben wird.

Um die Gesamtproblemgröße zusätzlich durch eine mögliche Beschränkung der endogen betrachteten Systembetriebszustände zu kontrollieren, wurde basierend auf den Erkenntnissen in [19] darüber hinaus ein hierarchisches Clustering-Verfahren implementiert, das der Identifikation repräsentativer Perioden dient.

3.3 Verteilter Progressive-Hedging-Algorithmus

Dieser Abschnitt beschreibt einen Lösungsansatz zur Lösung der stochastischen Optimierungsprobleminstanzen des EMPRISE-Frameworks. Der methodische Ansatz basiert auf dem in [20] entwickelten Progressive-Hedging-Algorithmus (PHA) für mehrstufig stochastische Optimierungsprobleme.

Wie in Abbildung 11 dargestellt, erlaubt die Dekomposition einzelner Szenarien (oder Bündel von Szenarien) die Zerlegung des monolithischen Problems in kleinere Teilprobleme durch die Relaxierung der sogenannten „non-anticipativity constraints“ (NACs) des Originalproblems (orange eingefärbt). Diese sorgen im mehrstufig stochastischen Fall dafür, dass das mathematische Modell in einer Entscheidungsstufe keine Informationen aus späteren Entscheidungsstufen verwendet, die erst nach der aktuellen Entscheidungsstufe offenbart werden und genutzt werden dürfen. Durch das Fallenlassen dieser Nebenbedingungen zerfällt der mehrstufige Szenariobaum in einzelne Szenariopfade oder -bündel. Die Konvergenz wird mittels des Progressive-Hedging-Algorithmus erreicht und durch das Zerfallen in unabhängige Teilprobleme kann das Verfahren auch auf verteilter Recheninfrastruktur (wie den am Fraunhofer IEE verfügbaren medium-range HPC-Cluster) parallelisiert werden.

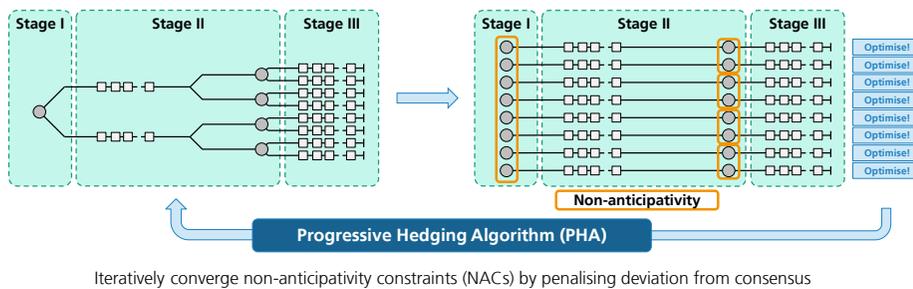


Abbildung 11: Schematische Darstellung des Progressive-Hedging-Algorithmus (PHA)

Quelle: eigene Darstellung auf Basis von [20].

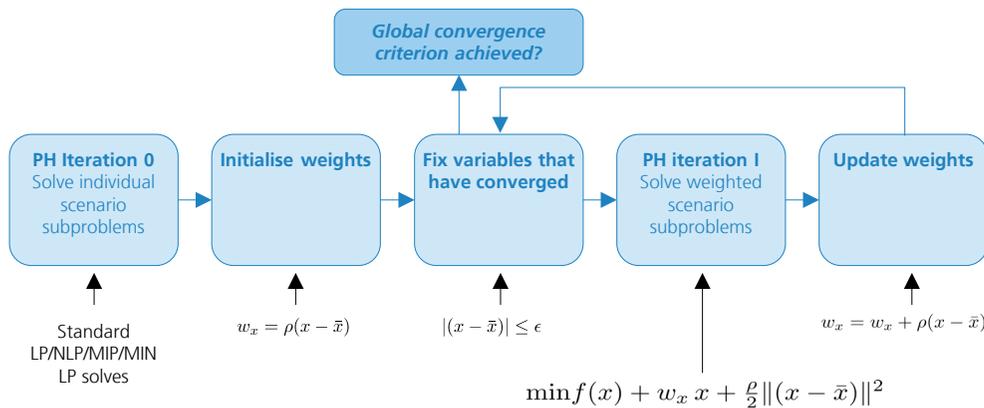


Abbildung 12: Übersicht der Schritte im Progressive-Hedging-Algorithmus (PHA)

Quelle: eigene Darstellung auf Basis von [18].

Die Prozedur des PHA wird in Abbildung 12 weiter veranschaulicht und zeigt dabei die quadratischen Bestrafungsterme der „Augmented Lagrangian Dual Function“, die iterativ und in Abhängigkeit von dem ρ -Parameter angepasst werden.

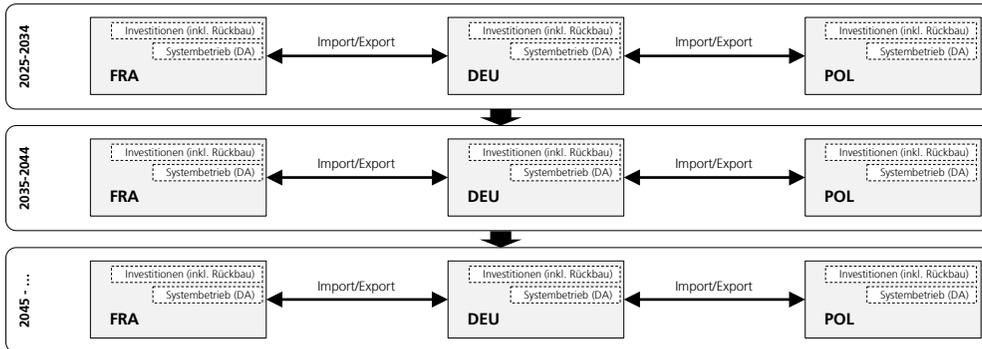
Der PHA kann dabei auch als eine Anwendung der „alternating direction method of multipliers“ (ADMM) [21] auf die Szenarioformulierung des mehrstufig stochastischen Optimierungsproblems verstanden werden. Unter leichten Annahmen gilt, dass die Folge primaler und dualer Lösungen zu einer optimalen Lösung der Szenarioformulierung kon-

vergieren. In jeder Iteration stellen die Variablen an den Knoten einen zulässigen Zustandsvektor dar, der zusammen mit den entsprechend berechneten lokalen Variablen eine zulässige Lösung des Problems darstellen.

4 Fallstudie

4.1 Aufbau

Zur Veranschaulichung der Einsatzmöglichkeiten des neu entwickelten EMPRISE-Frameworks zeigt Abbildung 13 ein Anwendungsbeispiel. Die Fallstudie umfasst drei wichtige Marktgebiete im europäischen Energiesystem und plant deren Transformation von 2025 bis 2045 in drei Planungsperioden, die jeweils zehn Jahre repräsentieren.

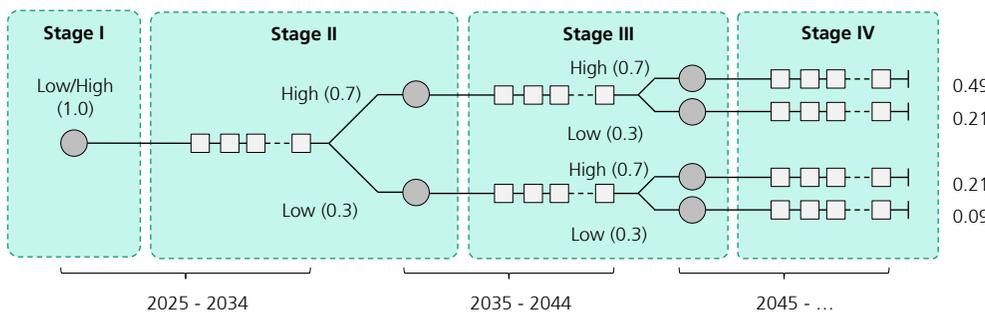


Technologieoptionen (inkl. zeitlicher Entwicklung): Onshore Wind, Offshore Wind, Solar PV Rooftop, Solar PV Utility, OCGT, CCGT, Nuclear ST, Li-Ionen-Batteriespeicher
Klimaschutzinstrument: Emissionspreis

Abbildung 13: Aufbau der Fallstudie mit seinen Technologieoptionen und dem Klimaschutzinstrument

Quelle: eigene Darstellung.

Das Fallstudienbeispiel besitzt eine mehrstufig stochastische Struktur des Entscheidungsproblems und betrachtet die CO₂-Preisentwicklung im System als strategische Unsicherheit in zwei Entwicklungspfaden („High“ und „Low“) mit unterschiedlichen Eintrittswahrscheinlichkeiten. Aus Gründen der übersichtlichen Darstellung wird nur ein operatives Szenario (meteorologisches Referenzjahr 2010) betrachtet, das heißt es gibt abgesehen von der operativen Unsicherheit in Form der deterministischen Zeitreiheninformatio kein zusätzliches explizites operatives Unsicherheitszenario.



CO ₂ -Preis in EUR/toCO ₂ -eq.	2025 - 2034	2035 - 2044	2045 - ...
High	70	100	200
Low	70	70	70

Abbildung 14: Fallstudie mit zwei CO₂-Preispfaden als strategische Unsicherheit und der dazugehörige mehrstufig stochastische Szenariobaum inklusive der Eintrittswahrscheinlichkeiten

Quelle: eigene Darstellung.

In Abbildung 15 wird der mit Abbildung 14 in Verbindung stehende Szenariobaum dargestellt, der intern im EMPRISE-Framework erstellt und potenziell für die Parallelisierung

genutzt wird. Im Vergleich zu den in der vorherigen Abbildung gezeigten Einzel- und Gesamtwahrscheinlichkeiten werden an den Kanten des Graphen die Übergänge zwischen den Entscheidungsstufen und die dazugehörigen Einzelwahrscheinlichkeiten der Unsicherheitsszenarien veranschaulicht.

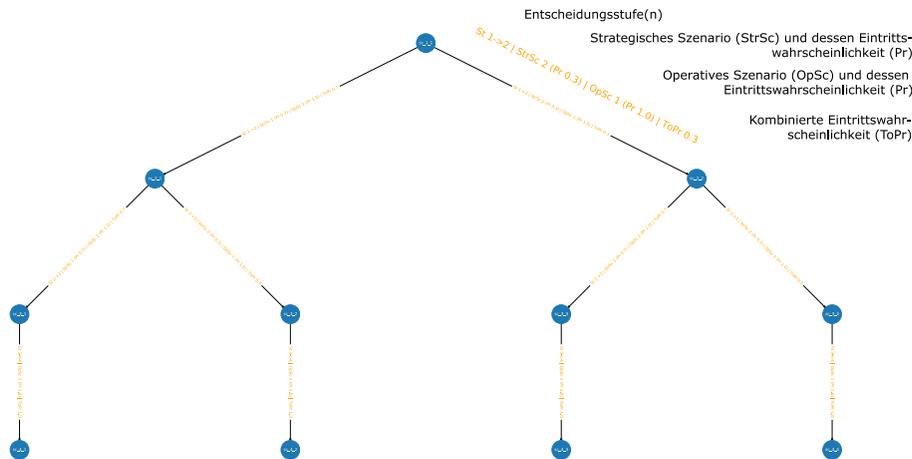


Abbildung 15: Beispielhafter Aufbau eines mehrstufig stochastischen Szenariobaums mit einem operativen (OpSc) und zwei strategischen (StrSc) Unsicherheiten

Quelle: eigene Darstellung auf Basis des EMPRISE-Frameworks.

Zum Vergleich wird in Abbildung 16 ein beispielhafter mehrstufig stochastischer Szenariobaum für die simultane Berücksichtigung von zwei operativen Unsicherheitsszenarien (meteorologische 2010 und 2012) und zwei strategischen Unsicherheitsszenarien (siehe Abbildung 14) dargestellt. Es wird deutlich, dass die Berücksichtigung eines zusätzlichen operativen Unsicherheitsszenarios die Anzahl der Gesamtszenarien von vier auf 32 erhöht.

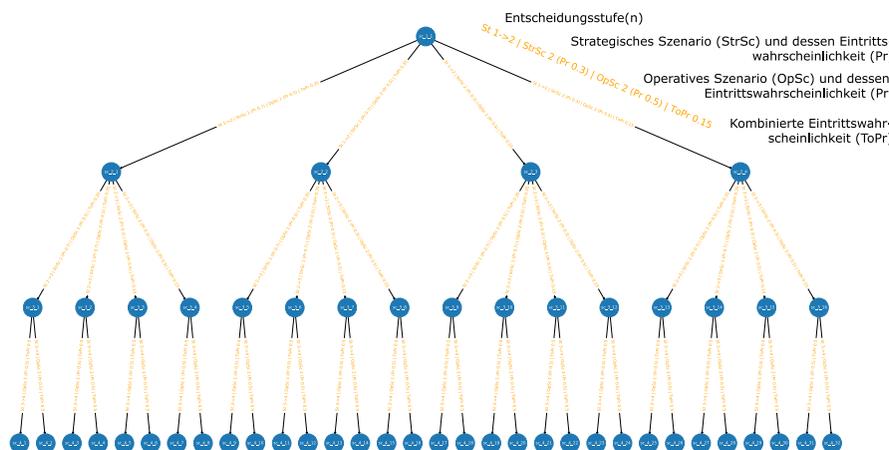


Abbildung 16: Beispielhafter Aufbau eines mehrstufig stochastischen Szenariobaums mit zwei operativen (OpSc) und zwei strategischen (StrSc) Unsicherheiten

Quelle: eigene Darstellung auf Basis des EMPRISE-Frameworks.

4.2 Konvergenz des verteilten Ansatzes

Im Rahmen der Fallstudie wurden insbesondere auch Analysen des Konvergenzverhaltens für den skalierbaren Lösungsansatz des EMPRISE-Frameworks durchgeführt. Die hinreichende Erfüllung der Gütekriterien ist für die Auswertbarkeit und Interpretation der erhaltenen Lösungen unbedingt erforderlich.

Da der ρ -Parameter des PHA insbesondere durch den quadratischen Bestrafungsterm eine gewichtige Rolle in der dualen Zielfunktion des relaxierten Problems spielt und in Wechselwirkung mit Zielfunktionswerten des primalen Problems steht, kann das Konvergenzverhalten des PHA entscheidend durch die Wahl des Parameters beeinflusst werden. Zu diesem Zweck wurden diverse Sensitivitätsanalysen für den ρ -Parameter durchgeführt, deren Ergebnisse in der nachfolgenden Abbildung 17 dargestellt sind.

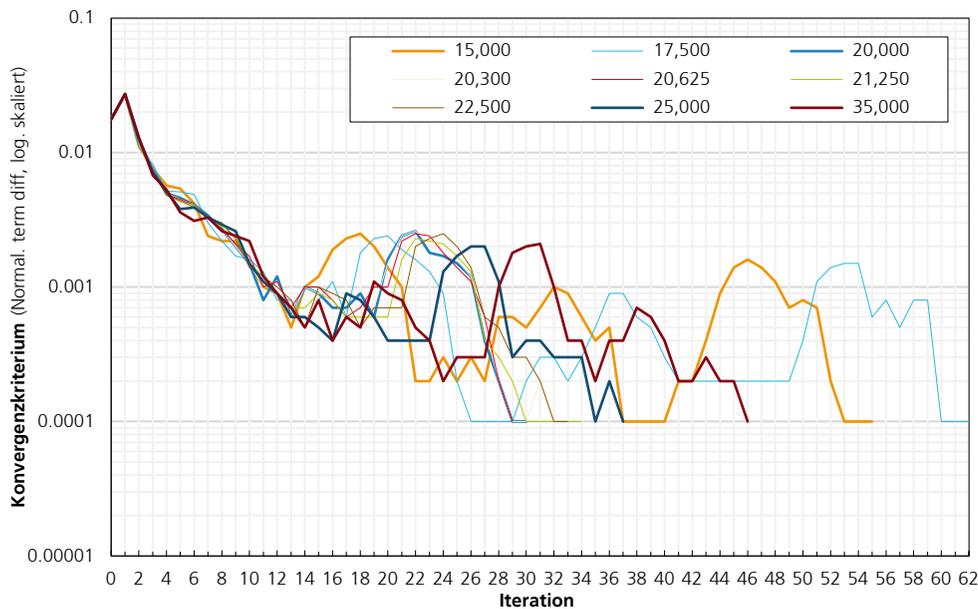


Abbildung 17: Konvergenzverhalten für verschiedene ρ -Parameter des Progressive-Hedging-Algorithmus (PHA)

Quelle: eigene Darstellung auf Basis eigener Berechnungen mit dem EMPRISE-Framework.

Wie in dem Konvergenzverhalten bis zu einer Toleranz von 0.0001 erkennbar ist, hat die Wahl des ρ -Parameters einen klaren Einfluss auf die Anzahl der Iterationen des PHA. Darüber hinaus wird aber auch deutlich, dass viele der gewählten Parameter nach etwa 22 Iterationen in einen Toleranzbereich von 0.0002 bis 0.0003 gelangen, was für manche Fragestellungen bereits ausreichend sein kann. Ein wichtiges Kriterium hierfür ist insbesondere die Zulässigkeit der Konsensentscheidungen (siehe NACs in Abschnitt 3.3) für die Ermittlung der optimalen lokalen Entscheidungen, d. h. insbesondere die Systembetriebsentscheidungen.

4.3 Robuste Investitionsentscheidungen

Zum Aufzeigen des Mehrwertes sollen hier exemplarisch die Unterschiede zwischen dem klassisch deterministischen Ansatz und dem neuen Entscheidungsmodell veranschaulicht werden. Hierbei ist zu beachten, dass die deterministischen Planungsprobleminstanzen den einfachsten Fall des mehrstufig stochastischen Aufbaus darstellen und ebenfalls mit diesem Modell gelöst werden können. Für Onshore-Windinvestitionen in Frankreich zeigt Abbildung 18 die für die Fallstudie ermittelten optimalen Lösungen des mehrstufig stochastischen Planungsproblems (siehe Szenariobaum in Abbildung 14) sowie die dazugehörigen deterministischen Ergebnisse für die „Low/Low“- und „High/High“-Szenariopfade.

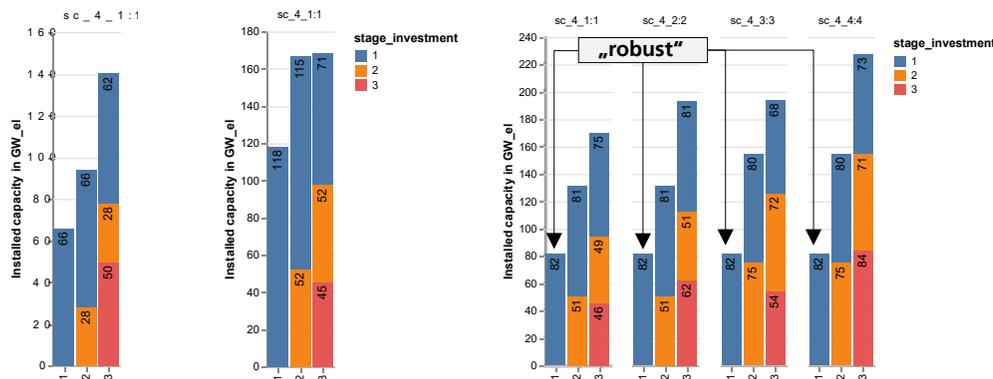


Abbildung 18: Vergleich pfadabhängiger Onshore-Windinvestitionen deterministischer und mehrstufig stochastischer Planungsmodellrechnungen

Quelle: eigene Darstellung auf Basis eigener Berechnungen.

Die Investitionsentscheidungen verdeutlichen, dass der mehrstufig stochastische Ansatz des EMPRISE-Frameworks in der Lage ist, robuste „here-and-now“-Entscheidungen (82 GW_{el} in Entscheidungsstufe 1) zu treffen, die sich von beiden deterministischen Szenarien deutlich unterscheiden. Auch deutlich wird, dass die kumulierten Investitionsentscheidungen in der letzten Stufe signifikant anders sind als die Entscheidungen für die einzeln betrachteten deterministischen Szenariopfade.

Zudem wird sichtbar, dass der stochastische Ansatz für die nachfolgenden Entscheidungsstufen durchaus Investitionsentscheidungen ermittelt, diese aber entsprechend der NACs nur noch für Teilbäume des gesamten Szenariobaums identisch sein müssen (z. B. Szenarien „sc_4_1:1“ und „sc_4_2:2“ in Entscheidungsstufe 2). Da die lokalen Entscheidungen die Systembetriebsentscheidungen beinhalten, können somit auch weitere Indikatoren und Prognosen wie bspw. Approximationen von Strompreisen für die jeweiligen späteren Stufen ermittelt werden.

5 Schlussfolgerungen

Im Rahmen des Projekts wurde das neue Modellierungs- und Optimierungsframework „Environment for Modelling and Planning Robust Investments in Sector-integrated Energy systems (EMPRISE)“ für die Lösung von Planungsproblemen in der Energiesystemanalyse entwickelt. Im Vordergrund standen hierbei vor allem die Entwicklung konsistenter Ansätze zur Berücksichtigung mehrperiodiger Kapazitätsaus- und rückbauplanungsentscheidungen für das betrachtete Energiesystem sowie konzeptionelle Ansätze zur flexiblen Berücksichtigung relevanter strategischer und operativer Unsicherheiten als auch die Implementierung schnell individualisierbarer Entscheidungsdynamiken. Das EMPRISE-Framework und sein neuer methodischer Ansatz sind als quelloffene Software entwickelt worden.

Dass Fallbeispiel hat exemplarisch gezeigt, dass mit dem neuen methodischen Ansatz gegenüber klassisch deterministischen Ansätzen robustere Aussagen getroffen werden können, insbesondere, wenn gleichzeitig Pfadabhängigkeiten sowie strategische und operative Unsicherheiten endogen abgebildet werden. Vor allem kann der neue methodische Ansatz dabei helfen, Grundsatz- oder besonders wichtige Einzelentscheidungen zu treffen – bspw. welche Technologie ist wann sinnvoll oder bei welchen Investitionsoptionen besteht möglicherweise die Gefahr, ein „stranded asset“ zu werden. Das EMPRISE-Framework bietet darüber hinaus vielseitige Anwendbarkeit durch die zwei- und mehrstufig stochastischen Strukturen der Entscheidungsprobleme (normative Szenarien vs. echt-robuste Entscheidungen im Hier und Jetzt).

Der Fokus der Arbeiten war zunächst auf der Entwicklung der Grundlagen und der Skalierbarkeit sowie der Bewertung der Bedeutung des neuen Ansatzes – letztere ist aufgrund der neuen Komplexitäten und Unübersichtlichkeiten im klimaneutralen Energiesystem grundsätzlich hoch. Unsicherheiten hinsichtlich der Entwicklung von Energieverbräuchen, der Verfügbarkeit und Rolle von Wasserstoff- bzw. PtX-Importen versus die Produktion in Heimatmärkten, sowie bereits vorhandene und noch realisierbare Systemflexibilität in zukünftig stärker sektorenintegrierten Energiesystemen werfen dabei zentrale Fragestellungen für weitere Untersuchungen auf.

6 Literaturverzeichnis

- [1] S. W. Wallace, „Decision Making Under Uncertainty: Is Sensitivity Analysis of Any Use?,“ *Operations Research*, Bd. 48, Nr. 1, pp. 20-25, 2000.
- [2] P. Härtel, *Offshore Grids in Low-Carbon Energy Systems: Long-Term Transmission Expansion Planning in Energy Systems with Cross-Sectoral Integration using Decomposition Algorithms and Aggregation Methods for Large-Scale Optimisation Problems*, Stuttgart: Fraunhofer Verlag, 2021.
- [3] Q. Xu und B. F. Hobbs, „Value of model enhancements: quantifying the benefit of improved transmission planning models,“ *IET Generation, Transmission & Distribution*, Bd. 13, Nr. 13, pp. 2836-2845, 2019.
- [4] Fraunhofer IEE, „SCOPE: Cross-sector optimisation of dispatch and investment for analysis of future energy supply systems,“ Fraunhofer IEE, Kassel, 2019.
- [5] M. Kristiansen, *Multinational transmission expansion planning: Exploring engineering-economic decision support for a future North Sea offshore grid*, Trondheim: NTNU, 2019.
- [6] F. H. Knight, *Risk, Uncertainty, and Profit*, Boston and New York: Houghton Mifflin Co., The Riverside Press Cambridge, 1921.
- [7] C. Velásquez, D. Watts, H. Rudnick und C. Bustos, „A Framework for Transmission Expansion Planning: A Complex Problem Clouded by Uncertainty,“ *IEEE Power and Energy Mag. (IEEE Power and Energy Magazine)*, Bd. 14, Nr. 4, pp. 20-29, 2016.
- [8] Y. Liu, R. Sioshansi und A. J. Conejo, „Hierarchical Clustering to Find Representative Operating Periods for Capacity-Expansion Modeling,“ *IEEE Trans. Power Syst. (IEEE Transactions on Power Systems)*, Bd. 33, Nr. 3, pp. 3029-3039, 2018.
- [9] K. Govindan und T. Cheng, „Advances in stochastic programming and robust optimization for supply chain planning,“ *Computers & Operations Research*, Bd. 100, pp. 262-269, 2018.
- [10] M. Kendzioriski, M. Setje-Eilers und F. Kunz, „Generation expansion planning under uncertainty,“ in *International Conference on the European Energy Market, EEM 2017 – 2017 14th International Conference*, Dresden, 2017.
- [11] B. Chen, J. Wang, L. Wang, Y. He und Z. Wang, „Robust Optimization for Transmission Expansion Planning: Minimax Cost vs. Minimax Regret,“ *IEEE Trans. Power Syst. (IEEE Transactions on Power Systems)*, Bd. 29, Nr. 6, pp. 3069-3077, 2014.
- [12] M. S. Pishvaei und M. Fazli Khalaf, „Novel robust fuzzy mathematical programming methods,“ *Applied Mathematical Modelling*, Bd. 40, Nr. 1, pp. 407-418, 2016.
- [13] F. D. Munoz und J.-P. Watson, „A scalable solution framework for stochastic transmission and generation planning problems,“ *Comput Manag Sci (Computational Management Science)*, Bd. 12, Nr. 4, pp. 491-518, 2015.
- [14] J. R. Birge und F. Louveaux, *Introduction to stochastic programming*, 2 Hrsg., New York, NY: Springer, 2011.

- [15] A. J. Conejo, L. Baringo Morales, S. J. Kazempour und A. S. Siddiqui, *Investment in Electricity Generation and Transmission*, Cham: Springer International Publishing, 2016.
- [16] W. E. Hart, J.-P. Watson und D. L. Woodruff, „Pyomo: modeling and solving mathematical programs in Python,“ *Math. Prog. Comp. (Mathematical Programming Computation)*, Bd. 3, Nr. 3, pp. 219-260, 2011.
- [17] W. E. Hart, C. D. Laird, J.-P. Watson, D. L. Woodruff, G. A. Hackebeil, B. L. Nicholson und J. D. Siirola, *Pyomo — Optimization Modeling in Python*, Cham: Springer International Publishing, 2017.
- [18] J.-P. Watson, D. L. Woodruff und W. E. Hart, „PySP: Modeling and solving stochastic programs in Python,“ *Math. Prog. Comp. (Mathematical Programming Computation)*, Bd. 4, Nr. 2, pp. 109-149, 2012.
- [19] P. Härtel, M. Kristiansen und M. Korpås, „Assessing the impact of sampling and clustering techniques on offshore grid expansion planning,“ *Energy Procedia*, Bd. 137, p. 152–161, 2017.
- [20] R. T. Rockafellar und R. J.-B. Wets, „Scenarios and Policy Aggregation in Optimization Under Uncertainty,“ *Mathematics of OR (Mathematics of Operations Research)*, Bd. 16, Nr. 1, pp. 119-147, 1991.
- [21] M. R. Hestenes, „Multiplier and gradient methods,“ *J Optim Theory Appl (Journal of Optimization Theory and Applications)*, Bd. 4, Nr. 5, pp. 303-320, 1969.