



TECHNISCHE
UNIVERSITÄT
WIEN
Vienna University of Technology

DIPLOMARBEIT

Portfoliooptimierung in der Energiewirtschaft unter Unsicherheiten

Eine Standortanalyse

zur Erlangung des akademischen Grades

Diplom - Ingenieur

im Rahmen des Masterstudiums

Statistik-Wirtschaftsmathematik

eingereicht von

Tobias Forster, BSc BSc MSc

Matrikelnummer: 01525168

Durchgeführt am Institut für Stochastik und Wirtschaftsmathematik, an der Fakultät für Mathematik und Geoinformation an der Technischen Universität Wien, in Kooperation mit dem Austrian Institute of Technology.

Betreuung:

Dipl.-Ing. Dr.techn. Josef L. Haunschmied

Wien, am 17.10.2022

Kurzfassung

Durch den Anstieg des Marktanteils von Strom aus erneuerbaren Energiequellen und durch die Zunahme der Volatilität der Strompreise in Europa suchen Marktteilnehmer_innen nach Möglichkeiten ihr Portfolio durch verschiedenste Technologien zu diversifizieren. Für ein Portfolio bestehend aus Windkraftanlagen, Photovoltaikanlagen sowie einem elektrischen Stromspeicher stellt sich die Frage, welcher Anteil optimal an welchem Strommarkt vermarktet werden soll.

Daher untersuchen wir an einem bestimmten Standort in Österreich (Neusiedl an der Zaya), wie sich ein optimales Verhältnis zwischen dem Bieten auf dem Terminmarkt und dem Day-Ahead-Markt ermitteln lässt. In Anbetracht der Tatsache, dass die Verfügbarkeiten von Wind und Sonneneinstrahlung sowie zukünftige Preise am Day-Ahead-Markt unsicher sind, wird die *robuste Optimierung* herangezogen. Darüber hinaus wird in der durchgeführten zweiphasigen Optimierung die Risikoaversion mitberücksichtigt.

In der vorliegenden Arbeit wird ein_e Entscheidungsträger_in betrachtet, welche_r bestimmen muss, wie viel elektrische Energie auf dem Terminmarkt vermarktet werden soll, bevor die verbleibende Energie auf dem Day-Ahead-Markt verkauft wird. Hierfür wird ein zweiphasiges Optimierungsproblem entwickelt: Zunächst wird der Anteil, welcher am Terminmarkt verkauft werden soll, bestimmt. In der zweiten Phase wird die am Terminmarkt verkaufte Energie als gegeben angenommen und unter Berücksichtigung der neu gewonnenen Informationen wird der Rest am Day-Ahead-Markt verkauft. Mithilfe des Ausgleichsenergiepreises wird abschließend der tatsächliche Profit beziehungsweise Verlust berechnet. Schließlich können verschiedene Risikoaversionen miteinander verglichen werden. Dieser Vergleich hat zur Folge, dass eine bestimmte Risikoaversion optimal im Sinne eines Profit-Risiko-Verhältnisses ist.

Schlagwörter: Day-Ahead-Markt, Energiewirtschaft, Portfoliooptimierung, Robuste Optimierung, Sharpe-Ratio

Abstract

Due to the fact that the market share of renewable energy sources is rising in Europe and electricity prices are becoming increasingly volatile, many market participants are looking for ways to further diversify their portfolio using different technologies. For a portfolio consisting of wind turbines, a photovoltaic system, and a battery, one may ask what the optimal selling mixture on different markets is.

Therefore, we are investigating for a specific location in Austria (Neusiedl an der Zaya), how to determine an optimal mixture between selling on future markets compared to the day-ahead market. Considering the fact, that wind and solar availability, as well as day-ahead prices are uncertain, *robust optimization* is used. Furthermore, the risk aversion is considered in the two-phase optimization.

Consider the case of a decision maker that needs to determine how much energy to sell on future markets, before using the remaining energy on the day-ahead market. Consequently, we develop a two-phase optimization approach: First, we optimize the selling strategy given long-term day-ahead price forecasts and the future market. Second, the energy already sold on the future market is fixed and together with the new information, we determine the volume to be sold on the day-ahead market. After taking the imbalance prices into account, we calculate the total actual profit (or loss). Finally, we compare different risk aversions and identify the optimum which results in the highest profit to risk ratio for a given portfolio.

Keywords: Day-ahead market, Energy management, Portfolio optimization, Robust optimization, Sharpe-ratio

Danksagung

Mein Dank gilt all jenen, welche mich während der Diplomarbeit unterstützt haben. Nicht nur der fachliche Austausch, sondern auch die Unterhaltungen in der Freizeit waren für das Voranschreiten der Diplomarbeit entscheidend.

Besonderer Dank gebührt Herr Dipl.-Ing. Dr.techn. Josef L. Haunschmied, der meine Diplomarbeit betreut hat. Seine Expertise und Anmerkungen zu meinen Fortschritten waren sehr hilfreich. Zudem durfte ich durch die Arbeit einen neuen Bereich der Praxis der Optimierung kennenlernen.

Außerdem möchte ich mich beim Austrian Institute of Technology bedanken, welches die Forschung im Bereich der *robusten Optimierung* finanziell unterstützt hat. Besonderen Dank gebührt Carolin Monsberger. Durch ihr Wissen im Bereich Energiewirtschaft konnte sie mir in vielen Diskussionen weiterhelfen. Zudem war der Austausch mit Tara Esterl, Stefan Strömer sowie Philipp Ortmann bezüglich Optimierung, Programmierung und Strommärkte für das Gelingen der Diplomarbeit sehr hilfreich.

Zudem möchte ich mich bei meinen Freunden und Kommilitonen bedanken. Unzählige Übungen, deren Vorbereitungen meist in die Abende sowie Wochenenden fielen, machten aus Kommilitonen Freunde. An dieser Stelle sollte Florian Kanitschar erwähnt werden. Zwischen den Übungen und Prüfungen in unterschiedlichen Bereichen der Mathematik fand sich immer Zeit für andere Themen abseits der Mathematik. All dies lies die Freundschaft zu dem werden was sie heute ist.

Des Weiteren möchte ich mich bei all jenen für das Korrekturlesen bedanken, allen voran bei Stefanie Haid, welche über die Jahre des Studiums sowie meinen Masterarbeiten auf viele gemeinsame Aktivitäten verzichten musste.

Abschließend möchte ich mich bei Sabine und Dietmar Forster bedanken, die mir ein sorgenfreies Doppelstudium ermöglicht haben. Neben meinen Eltern hat auch meine Schwester und Mitbewohnerin, Vanessa Forster, einen großen Beitrag zu dieser Sorglosigkeit geleistet. Vielen Dank für alles.

Eidesstattliche Erklärung

Ich erkläre an Eides statt, dass ich die vorliegende Diplomarbeit selbstständig und ohne fremde Hilfe verfasst, andere als die angegebenen Quellen und Hilfsmittel nicht benutzt bzw. die wörtlich oder sinngemäß entnommenen Stellen als solche kenntlich gemacht habe.

Wien, am 17.10.2022

Tobias Forster

Abkürzungsverzeichnis

CVaR Conditional Value at Risk

DKK Dänische Krone

kW Kilowatt

kWh Kilowattstunden

Li-Ion Lithium-Ionen

MILP Mixed-Integer Linear Programming

MW Megawatt

MWh Megawattstunden

T€ Tausend €

VaR Value at Risk

€ Euro - Währung der Europäischen Wirtschafts- und Währungsunion

Mathematische Symbole:

α Risikoparameter; Wert zwischen Null und Eins

$CVaR_\alpha(X)$ Conditional Value at Risk von X zum Niveau α

$conv(\cdot)$ konvexe Hülle einer endlichen Menge

$D(m)$ $P_\alpha(m)$ abzüglich $P_B(m)$

\bar{D} Durchschnitt von $D(m)$

$hour(t)$ Funktion, die die Stunde von t angibt

$\tilde{\lambda}$ unsicherer Parametervektor

λ Kapitel 2: Parametervektor; Beobachtung von $\tilde{\lambda}$

λ Kapitel 3: Parametervektor der Day-Ahead-Preise für eine bestimmte Woche

$\lambda(t)$ Day-Ahead-Preis in der Lieferstunde t

m_j^i	Monat j im Jahr i
M	Menge, die alle Monate im Betrachtungszeitraum als Elemente besitzt
\mathbf{p}	Wahrscheinlichkeitsvektor
$P_\alpha(m)$	Profit für den Risikoparameter α im Monat m
$P_B(m)$	Profit des Benchmark-Portfolios im Monat m
$\mathbb{P}(\cdot)$	Wahrscheinlichkeitsmaß
Q_j^i	Quartal j im Jahr i
\mathbb{R}^n	n -dimensionaler reeller Vektorraum
\mathbb{R}_+	alle nichtnegativen reellen Zahlen
S	Sharpe-Ratio
σ	empirische Standardabweichung
σ_D	empirische Standardabweichung von $D(m)$
\mathcal{U}	Kapitel 2: allgemeine Unsicherheitsmenge
\mathcal{U}	Kapitel 3: Unsicherheitsmenge des Day-Ahead-Preises
$Var_\alpha(X)$	Value at Risk von X zum Niveau α ; α -Quantil der Zufallsvariable X
$\mathcal{W}(t)$	Unsicherheitsmenge der Winderzeugung in der Stunde t
$weekday(t)$	Funktion, die den Wochentag von t angibt; 0 = Montag, 6 = Sonntag
$\mathbf{x} \in \mathbb{R}^n$	Entscheidungsvektor
X	Zufallsvariable

Parameter und Variablen des zweiphasigen Optimierungsmodells:

n	Anzahl der Windkraftanlagen mit 2 MW Leistung
m	Anzahl der Photovoltaikanlagen mit 0.3 MW Leistung
\mathcal{T}	jede Lieferstunde im Betrachtungszeitraum
\mathcal{T}^P	jede Peak-Lieferstunde im Betrachtungszeitraum
$P_w^B(t)$	Produktion der Windkraftanlage für die Base-Lieferstunde t
$P_w^P(t)$	Produktion der Windkraftanlage für die Peak-Lieferstunde t
$P_w^{DA}(t)$	Produktion der Windkraftanlage für die Day-Ahead-Lieferstunde t

- $P_s^B(t)$ Produktion der Photovoltaikanlage für die Base-Lieferstunde t
 $P_s^P(t)$ Produktion der Photovoltaikanlage für die Peak-Lieferstunde t
 $P_s^{DA}(t)$ Produktion der Photovoltaikanlage für die Day-Ahead-Lieferstunde t
 P^B gesamte vermarktete Energie in einer Base-Lieferstunde
 P^P gesamte vermarktete Energie in einer Peak-Lieferstunde
 μ_1 Preis für eine Base-Lieferstunde in €/MWh
 μ_2 Preis für eine Peak-Lieferstunde in €/MWh
 $\tilde{\lambda}(t)$ unsicherer Day-Ahead-Preis in der Lieferstunde t in €/MWh
 $\tilde{P}_w(t)$ unsichere Windproduktion in der Stunde t
 $\hat{P}_s(t)$ prognostizierte Photovoltaikproduktion für die Stunde t
 C_w Kosten der Produktion mit Windkraft in €/MWh
 C_s Kosten der Produktion mit Photovoltaik in €/MWh
 P_w^r Rampenbeschränkung - Beschränkung für das Hoch- und Herunterfahren der Windkraftanlage
 $P_b^d(t)$ Entladung des elektrischen Stromspeichers in der Stunde t in MWh
 $P_b^c(t)$ Ladung des elektrischen Stromspeichers in der Stunde t in MWh
 $E_b(t)$ aktueller Stand des elektrischen Stromspeichers in der Stunde t
 $\delta(t)$ binäre Variable: 0 = laden, 1 = entladen
 C_b Kosten für das Laden und Entladen des elektrischen Stromspeichers
 C_e Energiespeicherkosten des elektrischen Stromspeichers
 η_d Entladungswirkungsgrad des elektrischen Stromspeichers
 η_c Ladungswirkungsgrad des elektrischen Stromspeichers
 s_0 Füllstand des elektrischen Stromspeichers zu Beginn sowie am Ende jedes Tages
 E_b^{min} untere Schranke des Energieniveaus des elektrischen Stromspeichers
 E_b^{max} obere Schranke des Energieniveaus des elektrischen Stromspeichers
 P_b^{max} Nennleistung des elektrischen Stromspeichers in MW

Zeitpunkte der Optimierung:

t_0 Geschäftsabschluss am Terminmarkt

t_{start} Start des Betrachtungszeitraums

t_{ende} Ende des Betrachtungszeitraums

Inhaltsverzeichnis

1	Einleitung	1
2	Methodik	5
2.1	Robuste Optimierung	5
2.2	Unsicherheitsmengen	7
2.3	Bewertungskriterium	11
2.4	Daten und Implementierung	14
3	Zweiphasiges Optimierungsproblem	15
3.1	Phase I: Terminmarkt und Day-Ahead-Markt	15
3.2	Phase II: Day-Ahead-Markt	19
4	Resultate	25
4.1	Erste Fallstudie	26
4.2	Zweite Fallstudie	30
5	Fazit und Ausblick	35

Tabellenverzeichnis

2.1	Diese Tabelle beschreibt die Einteilung der Day-Ahead-Preise in sechs Cluster. Beispielsweise ergibt der Mittelwert über die Lieferstunden 8 bis 21 aller Werktage in einer bestimmten Kalenderwoche λ_1 .	11
4.1	Die erste Zeile in dieser Tabelle beschreibt für Österreich die durchschnittlichen Day-Ahead-Preise in den unterschiedlichen Quartalen in den Jahren 2018 und 2019. Durch die Multiplikation der ersten Zeile mit 1.1 erhalten wir die zweite Zeile. Diese Preise werden in weiterer Folge als Baseload und Peakload Preise verwendet.	26
4.2	Diese Tabelle legt die Parameter, welche die Windkraftanlagen sowie die Photovoltaikanlagen betreffen, fest.	27
4.3	Diese Tabelle legt die Parameter, welche den elektrischen Stromspeicher betreffen, fest.	27
4.4	Diese Tabelle stellt die Standardabweichung des Profits in Abhängigkeit von α dar.	29
4.5	Diese Tabelle stellt die <i>Sharpe-Ratio</i> mit dem Benchmark-Portfolio α gleich 0.1 dar.	30
4.6	Diese Tabelle stellt die <i>Sharpe-Ratio</i> mit dem Benchmark-Portfolio α gleich 0.1 dar. Die Ausgleichsenergiepreise werden im Jahr 2019 um 60 % erhöht, wobei die restlichen Preise unverändert belassen werden.	30
4.7	Diese Tabelle legt die Parameter, welche die Windkraftanlagen sowie die Photovoltaikanlagen betreffen, fest.	31
4.8	Diese Tabelle legt die Parameter, die den Stromspeicher betreffen, fest.	32
4.9	Diese Tabelle stellt die Profite im Monat April im Jahr 2019 in Abhängigkeit von α dar.	32
4.10	Diese Tabelle stellt die empirische Standardabweichung des Profits in Abhängigkeit von α dar.	33

Tabellenverzeichnis

4.11 Diese Tabelle stellt die *Sharpe-Ratio* mit dem Benchmark-Portfolio α gleich 0.1 dar. 34

Abbildungsverzeichnis

2.1	Die je Wochentag gemittelten Day-Ahead-Preise über den Zeitraum vom 01.10.2018 bis zum 31.12.2018.	9
2.2	Die je Lieferstunde gemittelten Day-Ahead-Preise über den Zeitraum vom 01.10.2018 bis zum 31.12.2018.	10
2.3	Die konvexe Hülle beziehungsweise Unsicherheitsmenge für $\alpha = 0.1$ bezüglich der Datenpunkte aus den Kalenderwochen 40 bis 52 im Jahr 2018.	12
2.4	Die konvexe Hülle beziehungsweise Unsicherheitsmenge für $\alpha = 0.5$ bezüglich der Datenpunkte aus den Kalenderwochen 40 bis 52 im Jahr 2018.	12
2.5	Die konvexe Hülle beziehungsweise Unsicherheitsmenge für $\alpha = 0.9$ bezüglich der Datenpunkte aus den Kalenderwochen 40 bis 52 im Jahr 2018.	13
3.1	Diese Abbildung stellt die erste Phase der Portfoliooptimierung dar. Der Geschäftsabschluss befindet sich drei Monate vor Lieferstart. Die Lieferung, welche zwischen Lieferstart und Lieferende stattfindet, dauert einen Monat. Dieser Monat wird auch Betrachtungszeitraum genannt.	15
3.2	Diese Abbildung stellt die Optimierung für den Tag d im Betrachtungszeitraum dar. Am Vortag um 12:00 Uhr werden die noch zur Verfügung stehenden Ressourcen am Day-Ahead-Markt vermarktet.	20
4.1	Diese Abbildung beschreibt den Profit in Abhängigkeit von α . Mit steigendem α nimmt die Risikoaversion ab und führt in weiterer Folge zu einem steigenden Profit. Als Preise für μ_1 und μ_2 werden die Werte aus Tabelle 4.1 verwendet. Die restlichen Parameter sind in den Tabellen 4.2 und 4.3 dargestellt.	28
4.2	Diese Abbildung beschreibt die Kosten für die Ausgleichsenergie in Abhängigkeit von α . Mit steigendem α nimmt die Risikoaversion ab und führt in weiterer Folge zu steigenden Kosten. Als Preise für μ_1 und μ_2 werden die Werte aus Tabelle 4.1 verwendet. Die restlichen Parameter sind in den Tabellen 4.2 und 4.3 dargestellt.	29
4.3	Diese Abbildung beschreibt den Profit in Abhängigkeit von α . Als Preise für μ_1 und μ_2 werden die Werte aus Tabelle 4.1 verwendet. Die restlichen Parameter sind in den Tabellen 4.7 und 4.8 dargestellt.	33

1 Einleitung

Ausgang der vorliegenden Arbeit stellen der Ausbau erneuerbarer Energiequellen und die stark steigende Volatilität der Strompreise dar. Gemäß [1] ist das Ziel der schwarz-grünen Koalition Österreich bis in das Jahr 2040 klimaneutral zu gestalten. Hierfür müssen die fossilen Energieträger durch erneuerbare Energiequellen ersetzt werden. Die erneuerbaren Energien, wie Windkraft und Photovoltaik, unterliegen aber einer hohen Unsicherheit und daher erweitern Energieanbieter_innen ihr Portfolio mit anderen Erzeugungstechnologien. Dadurch wird die gesamte Produktion unabhängiger bezüglich einer Einflussgröße, wie zum Beispiel Windaufkommen. Beispielsweise investiert ein Windpark in einen Solarpark, um die Abhängigkeit vom Windaufkommen zu verringern. Nach [2] hat ein hybrides System, bestehend aus Windkraftanlagen, Photovoltaikanlagen und einem Stromspeicher, in abgelegenen Gebieten enormes Potenzial die dort vorherrschende Nachfrage zu decken. Aber auch in den Industrienationen, wie beispielsweise in Österreich, mit einer gut ausgebauten Strominfrastruktur, bringt ein derartiges System viele Möglichkeiten mit sich und sollte in Zukunft stärker genutzt werden. Möglichkeiten sind beispielsweise das Ersetzen von konventionellen Energiequellen und das Decken der vorherrschenden Nachfrage.

In dieser Diplomarbeit wird ein Portfolio aus Windkraftanlagen, Photovoltaikanlagen und einem elektrischen Stromspeicher in der Umgebung Neusiedl an der Zaya betrachtet. Laut [3] erfolgt im östlichen Weinviertel ein starker Ausbau von erneuerbaren Energieerzeugungstechnologien, allen voran von Windkraft. Die gesamte Leistung wird im Jahr 2022 in dieser Region bis zu 1200 MW betragen und daher werden mit der Projektnummer 11-8 die Gegebenheiten geschaffen, sodass die erneuerbaren Energiequellen in das Netz eingebunden werden können. Dafür werden die Übertragungsnetzinfrastruktur sowie die Umspannwerke saniert sowie ausgebaut. Das in dieser Arbeit untersuchte Portfolio ist somit ein Repräsentant der in naher Zukunft ans Netz angeschlossenen Windkraftanlagen sowie Photovoltaikanlagen in dieser Region.

In einer zweiphasigen Optimierung wird das optimale Verhältnis zwischen dem Verkauf am Terminmarkt und Day-Ahead-Markt bestimmt. Hierfür wird als Methode die *robuste Optimierung* verwendet. Mithilfe eines Risikoparameters werden die dafür notwendigen Unsicherheitsmengen berechnet und diese haben schließlich einen Einfluss auf den resultierenden Gewinn für die beziehungsweise den Strom anbietenden. Im Zentrum der Diplomarbeit steht daher die Frage, welchen Anteil ein_e Portfoliomanager_in unter Unsicherheit am Terminmarkt verkaufen soll, bevor die Veräußerung der restlichen Energie am Day-Ahead-Markt erfolgt. Folgende Einflussfaktoren sind dabei als unsicher zu betrachten: Windaufkommen, Sonneneinstrahlung und Day-Ahead-Preise. Mithilfe eines

1 Einleitung

Risikoparameters kann bestimmt werden, wie viel Risiko mit dem Portfolio eingegangen werden möchte. Im Anschluss lässt sich durch eine Simulation a posteriori jener optimale Risikoparameter bestimmen, welcher das beste Verhältnis zwischen Gewinn und Risiko über den betrachteten Zeitraum geliefert hätte. Diesbezüglich wird eine Kennzahl aus der Finanzwirtschaft, das *Sharpe-Ratio*, herangezogen.

In den letzten Jahren hat die wissenschaftliche Forschung dem Bereich der Portfoliooptimierung in der Energiewirtschaft immer mehr Bedeutung gewidmet. Dies ist darauf zurückzuführen, dass vor allem gewisse erneuerbare Energien mit ihren hohen Unsicherheiten in der Erzeugung dafür geeignet sind, mit anderen Technologien kombiniert zu werden. Im Vergleich dazu unterliegt ein Kohlekraftwerk geringen externen Einflüssen aus der Natur. Gemäß dem soeben Beschriebenen muss eine Entscheidung getroffen werden, bevor beispielsweise das exakte Windaufkommen sowie die exakte Sonneneinstrahlung bekannt ist. In [4] wird ausgeführt, wie Risiko in der Optimierung berücksichtigt werden kann. Unter anderem wird der *Conditional Value at Risk* (CVaR) und der *Value at Risk* (VaR) beschrieben und in der Optimierung mitberücksichtigt. Neben der unsicheren Stromproduktion werden laut [5] im Energiesektor auch die Strompreise mit Unsicherheiten modelliert. Zusätzlich liefert dieses Papier einen Überblick über die bestehende Literatur und die bereits untersuchten Bereiche. In [6] wird ein Portfolio bestehend aus Windkraftanlagen und einem Pumpspeicherkraftwerk betrachtet. Für die Betreiber_innen ergibt sich ein höherer erwarteter Profit, falls die beiden Technologien (Wasserkraft und Windkraft) gemeinsam am Markt ihre Leistung anbieten, verglichen mit der getrennten Bereitstellung der Leistung. Das Ziel jener Arbeit ist eine Bieter_innenstrategie am Day-Ahead-Markt über einen Zeitraum von einer Woche zu entwickeln. Die Zielfunktion des stochastischen gemischten ganzzahligen linearen Modells besteht aus einer Konvexkombination aus Profit und dem CVaR. Bereits zuvor wurden in [7] dieselben Technologien betrachtet und eine optimale Bieter_innenstrategie am iberischen Day-Ahead-Markt gesucht. In [8] wird ein Windpark mit einem Stromspeicher gekoppelt. Die zugrunde liegende Studie versucht die optimale wirtschaftliche und technische Größe des Stromspeichers unter Berücksichtigung der Degradierung zu bestimmen, sodass der Profit maximiert wird. Dafür wird ein rollierendes 24-Stunden *Mixed-Integer Linear Programming* (MILP) Optimierungsproblem gelöst.

Die vorliegende Arbeit baut auf vielen Ansätzen, wie beispielsweise der *robusten Optimierung* und dem Optimierungsproblem, aus [9] und [10] auf. Das Portfolio, das in der zweiphasigen Optimierung betrachtet wird, besteht aus einem Windpark mit Photovoltaikmodulen und einem Energiespeicher. In [10] wird gezeigt, dass die Kombination aus einem Energiespeicher und Windkraftanlagen die Unsicherheit der Verfügbarkeit von Wind besser ausnutzt und zusätzlich durch Energiearbitrage einen wirtschaftlichen Mehrwert liefert. Falls die Vorhersagefehler für die Stromerzeugung durch Windkraft sowie für den Strompreis ausreichend groß sind, dann übertrifft in der untersuchten Fallstudie die *robuste Optimierung* den deterministischen Ansatz hinsichtlich der Wirtschaftlichkeit. Zu ähnlichen Ergebnissen führt auch die Studie in [9], wobei die Unsicher-

heitsmengen mithilfe des $CVaR$ definiert werden. Des Weiteren sind für die vorliegende Arbeit Ansätze aus [11] relevant. Hierbei wird ein Sonnenwärmekraftwerk mit einem Wärmespeicher kombiniert. Dabei wird bestimmt, welche Menge am Day-Ahead-Markt vermarktet werden soll und die restliche Menge wird als Systemdienstleistung für die Netzstabilität angeboten. Mit einer zweistufigen *robusten Optimierung* am Energiemarkt hat sich [12] beschäftigt.

Diese Arbeit ist in fünf Kapitel gegliedert. In Kapitel 2 wird die Methodik dargestellt, mit welcher die Optimierung durchgeführt wird. Des Weiteren wird das Bewertungskriterium sowie die Implementierung beschrieben. Anschließend folgt in Kapitel 3 die Beschreibung des zweiphasigen Optimierungsproblems. In Kapitel 4 wird am Standort Neusiedl an der Zaya die Portfoliooptimierung für verschiedene Parameter durchgeführt, wobei reale, historische Daten aus dem Jahr 2019 verwendet werden. Abschließend folgt in Kapitel 5 eine Schlussfolgerung und ein Ausblick.

2 Methodik

In diesem Kapitel wird zunächst die *robuste Optimierung* eingeführt. Anschließend wird eine spezielle Unsicherheitsmenge betreffend dem *CVaR*, welche im zweiphasigen Optimierungsproblem in Kapitel 3 eingeht, definiert. Des Weiteren führen wir ein Bewertungskriterium ein, das den Profit ins Verhältnis zum Risiko setzt. Abschließend folgt eine Diskussion der Implementierung.

2.1 Robuste Optimierung

In diesem Abschnitt wird, falls nichts anderes erwähnt, nach [13] vorgegangen. Ausgehend von der deterministischen linearen Optimierung werden wir an die *robuste Optimierung* herangeführt. Erstere hat folgende Form:

$$\min_{\mathbf{x}} \{ \mathbf{c}^\top \mathbf{x} + d : \mathbf{A}\mathbf{x} \leq \mathbf{b} \}. \quad (2.1)$$

Hier beschreibt $\mathbf{x} \in \mathbb{R}^n$ die Entscheidungsvariablen. Des Weiteren gilt: $\mathbf{c} \in \mathbb{R}^n$, $d \in \mathbb{R}$, $\mathbf{A} \in \mathbb{R}^{m \times n}$ und $\mathbf{b} \in \mathbb{R}^m$. Die Konstante d hat zwar keinen Einfluss auf die optimale Lösung des Problems, beeinflusst aber den Wert der Zielfunktion. Jedes deterministische Problem kann auf die Form in Gleichung 2.1 gebracht werden, da Nebenbedingungen mit $\mathbf{a}^\top \mathbf{x} \geq \text{const}$ sowie $\mathbf{a}^\top \mathbf{x} = \text{const}$ umformuliert werden können. Letztere kann durch \geq sowie \leq dargestellt werden.

In der zweiphasigen Optimierung in Kapitel 3 sind die exakten Daten erst zu einem späteren Zeitpunkt bekannt. Beispielsweise wird die von den Windkraftanlagen erzeugte Energie an den unterschiedlichen Strommärkten verkauft, bevor das tatsächlich realisierte Windaufkommen bekannt ist. Die uns vorliegenden Daten sind somit unsicher und dies werden wir in der Optimierung mitberücksichtigen. Vom deterministischen Problem aus Gleichung 2.1 ausgehend, kann daher folgendes unsichere lineare Optimierungsproblem formuliert werden

$$\left\{ \min_{\mathbf{x}} \{ \mathbf{c}^\top \mathbf{x} + d : \mathbf{A}\mathbf{x} \leq \mathbf{b} \} \right\}_{(\mathbf{c}, d, \mathbf{A}, \mathbf{b}) \in \mathcal{U}}, \quad (2.2)$$

wobei $\mathcal{U} \subseteq \mathbb{R}^{(m+1) \times (n+1)}$ die Unsicherheitsmenge der Daten beschreibt. Ein $\mathbf{x} \in \mathbb{R}^n$ wird als robuste zulässige Lösung von Gleichung 2.2 bezeichnet, falls gilt:

$$\mathbf{A}\mathbf{x} \leq \mathbf{b} \quad \forall (\mathbf{c}, d, \mathbf{A}, \mathbf{b}) \in \mathcal{U}.$$

2 Methodik

In Worten kann gesagt werden, dass die robuste zulässige Lösung für alle möglichen Realisierungen die Nebenbedingungen erfüllt. Für jenes \mathbf{x} kann der robuste Wert $\hat{r}(\mathbf{x})$ berechnet werden. Dieser beschreibt den größten Wert der Zielfunktion aus Gleichung 2.2 über alle möglichen Realisierungen aus \mathcal{U} . In anderen Worten kann gesagt werden, dass für eine robuste zulässige Lösung der *Worst Case* Fall jenem \mathbf{x} zugewiesen wird. Demzufolge gilt:

$$\hat{r}(\mathbf{x}) = \sup_{(\mathbf{c}, d, \mathbf{A}, \mathbf{b}) \in \mathcal{U}} \mathbf{c}^\top \mathbf{x} + d.$$

Durch diesen robusten Wert können alle Lösungskandidaten miteinander verglichen werden. Das robuste Pendant zu einem unsicheren linearen Optimierungsproblem der Form 2.2 kann wie folgt formuliert werden:

$$\min_{\mathbf{x}} \left\{ \hat{r}(\mathbf{x}) = \sup_{(\mathbf{c}, d, \mathbf{A}, \mathbf{b}) \in \mathcal{U}} \mathbf{c}^\top \mathbf{x} + d : \mathbf{A}\mathbf{x} \leq \mathbf{b}, \forall (\mathbf{c}, d, \mathbf{A}, \mathbf{b}) \in \mathcal{U} \right\}. \quad (2.3)$$

Die optimale Lösung zum Problem aus Gleichung 2.3 wird robuste optimale Lösung genannt und der optimale Wert dieses Problems bezeichnen wir als robusten optimalen Wert. In anderen Worten bezeichnet die robuste optimale Lösung die beste Lösung, die resistant gegenüber allen Realisierungen der Unsicherheitsmenge ist. In weiterer Folge wird \mathcal{U} als kompakt angenommen und daher kann das Supremum durch ein Maximum ersetzt werden. Dieses Min-Max-Problem kann folgendermaßen umformuliert werden:

$$\min_{\mathbf{x}, z} \left\{ z : \mathbf{c}^\top \mathbf{x} + d \leq z \wedge \mathbf{A}\mathbf{x} \leq \mathbf{b}, \forall (\mathbf{c}, d, \mathbf{A}, \mathbf{b}) \in \mathcal{U} \right\}.$$

Dadurch kann jedes Min-Max-Problem in einer Form dargestellt werden, die eine Zielfunktion mit bekannten Koeffizienten aufweist und alle Unsicherheiten in den Nebenbedingungen enthalten sind:

$$\min_{\mathbf{x}} \{ \mathbf{c}^\top \mathbf{x} + d : \mathbf{A}\mathbf{x} \leq \mathbf{b}, \forall (\mathbf{A}, \mathbf{b}) \in \mathcal{U} \}.$$

Eine weitere Eigenschaft des robusten Pendanten ist, dass die Unsicherheitsmenge \mathcal{U} erweitert werden kann, ohne die Lösung zu beeinflussen. Eine robuste zulässige Lösung muss für jede Nebenbedingung $\mathbf{a}_i^\top \mathbf{x} \leq b_i, \forall (\mathbf{a}_i, b_i) \in \mathcal{U}$ erfüllen. Hier beschreibt \mathbf{a}_i^\top die i -te Zeile der Matrix \mathbf{A} und b_i den i -ten Eintrag des Vektors \mathbf{b} . Außerdem ist \mathcal{U}_i die Projektion von \mathcal{U} auf den Unterraum der Daten aus der i -ten Nebenbedingung. Daher gilt:

$$\mathcal{U}_i = \{ (\mathbf{a}_i, b_i) : (\mathbf{A}, \mathbf{b}) \in \mathcal{U} \}.$$

Des Weiteren folgt, dass $\mathbf{a}_i^\top \mathbf{x} \leq b_i, \forall (\mathbf{a}_i, b_i) \in \mathcal{U}$ äquivalent zu $\mathbf{a}_i^\top \mathbf{x} \leq b_i, \forall (\mathbf{a}_i, b_i) \in \mathcal{U}_i$ ist. Daher ergibt sich dasselbe robuste Pendant, wenn die Unsicherheitsmenge \mathcal{U} erweitert

wird zu:

$$\hat{\mathcal{U}} = \mathcal{U}_1 \times \dots \times \mathcal{U}_m.$$

Hier beschreibt m , wie bereits oben spezifiziert, die Anzahl an Nebenbedingungen. In Anlehnung an [13] und [14] betrachten wir folgendes Beispiel

$$\begin{aligned} & \min x_1 + x_2 \\ \text{s.t. : } & x_1 \geq \xi_1 \\ & x_2 \geq \xi_2 \\ & x_1, x_2 \geq 0, \end{aligned}$$

wobei $\xi := (\xi_1, \xi_2) \in \mathcal{U} := \{\xi_1 + \xi_2 \leq 1, \xi_1, \xi_2 \geq 0\}$ gilt. Die unendlich vielen Nebenbedingungen können in der *robusten Optimierung* umgeschrieben werden zu:

$$x_1 \geq \max_{\xi \in \mathcal{U}} \xi_1 = 1, x_2 \geq \max_{\xi \in \mathcal{U}} \xi_2 = 1.$$

Daher kann die Unsicherheitsmenge \mathcal{U} erweitert werden zu $\hat{\mathcal{U}} = \mathcal{U}_1 \times \mathcal{U}_2$ mit $\mathcal{U}_1 = \{\xi_1 : 0 \leq \xi_1 \leq 1\}$ und $\mathcal{U}_2 = \{\xi_2 : 0 \leq \xi_2 \leq 1\}$. Das robuste Pendant ändert sich dadurch nicht. Dies entspricht genau den Projektionen von \mathcal{U} auf die Unterräume der Daten der jeweiligen Nebenbedingungen. Da ξ_1 und ξ_2 unterschiedliche Nebenbedingungen betreffen, wird der Zusammenhang laut \mathcal{U} nicht berücksichtigt und dies führt dazu, dass $(\xi_1, \xi_2) = (1, 1)$ nicht mehr in \mathcal{U} liegt, was den Begriff „ \mathcal{U} wird erweitert“ begründet.

2.2 Unsicherheitsmengen

In Kapitel 3 werden wir für die *robuste Optimierung* Unsicherheitsmengen benötigen. Daher werden in diesem Unterabschnitt unterschiedliche Modellierungsmöglichkeiten dargestellt.

Unsicherheitsmenge betreffend CVaR

Laut [4] ist für $\alpha \in (0, 1)$ der *VaR* das α -Quantil der Zufallsvariable X und demnach gilt:

$$VaR_\alpha(X) := q_\alpha(X) = \min_z \{z : \mathbb{P}(X \leq z) \geq \alpha\}. \quad (2.4)$$

Laut [15] kann der *VaR* folgendermaßen interpretiert werden, wobei als Beispiel der unsichere Preis an den Day-Ahead-Märkten betrachtet wird:

- Der $VaR_\alpha(X)$ ist das α -Quantil der Verteilung von X .
- Der $VaR_\alpha(X)$ beschreibt den niedrigsten Preis der $(1 - \alpha) \cdot 100$ % der höchsten Preise.

2 Methodik

- Der $VaR_\alpha(X)$ kennzeichnet den höchsten Preis der $\alpha \cdot 100\%$ der niedrigsten Preise.

Davon abgeleitet werden kann der $CVaR$. Für eine Zufallsvariable X und $\alpha \in (0, 1)$ wird dieses Risikomaß wie folgt definiert:

$$CVaR_\alpha(X) := \mathbb{E}[X | X \leq VaR_\alpha(X)]. \quad (2.5)$$

Für $\alpha \rightarrow 0$ konvergiert der $CVaR_\alpha(X)$ gegen die kleinste Realisierung von X . Andererseits gilt für $\alpha \rightarrow 1$, dass der $CVaR_\alpha(X)$ gegen den Erwartungswert der Zufallsvariable X strebt. Demnach entspricht ein kleines α einem risikoaversen Individuum. Da der $CVaR_\alpha(X)$ wie in Gleichung 2.5 definiert ist, kann dieser nie größer als der Erwartungswert der Zufallsvariable X werden.

Da der $CVaR$ die Risikoaversion abbildet, führen wir die Unsicherheitsmenge betreffend dem $CVaR$ wie in [16] ein. Im Folgenden beschreibt \mathbf{e} den Einheitsvektor mit der Länge N . Des Weiteren sei Δ^N folgender N -dimensionale Simplex:

$$\Delta^N := \{\mathbf{p} \in \mathbb{R}_+^N : \mathbf{e}^\top \mathbf{p} = 1\}.$$

In der Praxis ist oftmals die genaue Verteilung eines unsicheren Parametervektors $\tilde{\boldsymbol{\lambda}}$ nicht bekannt, jedoch liegen meist endlich viele Beobachtungen $\{\boldsymbol{\lambda}_1, \dots, \boldsymbol{\lambda}_N\}$ vor. Für den $CVaR$ und dessen erzeugende Familie $\mathcal{Q} = \{\mathbf{q} \in \Delta^N : q_i \leq \frac{p_i}{1-\alpha}\}$ ergibt sich laut [16] folgende Unsicherheitsmenge:

$$\begin{aligned} \mathcal{U}_1 = \text{conv} \left(\left\{ \frac{1}{1-\alpha} \sum_{i \in I} p_i \boldsymbol{\lambda}_i + \left(1 - \frac{1}{1-\alpha} \sum_{i \in I} p_i \right) \boldsymbol{\lambda}_j : \right. \right. \\ \left. \left. I \subseteq \{1, \dots, N\}, j \in \{1, \dots, N\} \setminus I, \sum_{i \in I} p_i \leq 1 - \alpha \right\} \right). \end{aligned} \quad (2.6)$$

Hier beschreibt $\text{conv}(\cdot)$ die konvexe Hülle der endlichen Menge. Für historische Daten und ein α ergibt sich somit eine Unsicherheitsmenge. Mit der Wahl von α wird, wie oben beschrieben, die Risikoaversion festgelegt, welche einen Einfluss auf die Größe der Unsicherheitsmenge hat. Es gilt: Je kleiner das α desto risikoaverser und größer die Unsicherheitsmenge. Dieser Zusammenhang wird in diesem Kapitel in einem Beispiel veranschaulicht.

Intervall als Unsicherheitsmenge

In der *robusten Optimierung* kann auch ein abgeschlossenes Intervall als Unsicherheitsmenge für den Parameter $\tilde{a} \in \mathbb{R}$ verwendet werden. Für $b \leq c$ folgt demnach:

$$\mathcal{U}_2 = [b, c]. \quad (2.7)$$

In Kapitel 3 wird die untere Schranke vom Risikoparameter α abhängen und somit gilt $b = b(\alpha)$. Durch diese Abhängigkeit fließt, wie auch in Gleichung 2.6, die Risikoaversion

in die Unsicherheitsmenge \mathcal{U}_2 mit ein.

Beispiel

In Kapitel 3 werden für die Optimierung unter anderem die Day-Ahead-Preise benötigt. Diese beziehen sich jeweils auf eine Lieferstunde und unterliegen starken Preisschwankungen. Falls wir die Unsicherheitsmenge für die Day-Ahead-Preise wie in Gleichung 2.6 berechnen wollen, ist der Parametervektor $\tilde{\lambda}$ ein 24-dimensionaler Vektor. Hierbei bezieht sich der i -te Eintrag auf die i -te Lieferstunde eines bestimmten Tages. Die Funktion *ConvexHull* von *scipy* benötigt für die Berechnung der konvexen Hülle einer Menge, deren Elemente 24-dimensionale Vektoren sind, mindestens 25 Beobachtungen (d.h. $N=25$). In Gleichung 2.6 ist ersichtlich, dass die Potenzmenge von $\{1, \dots, N\}$ berechnet werden muss und aus Gründen der Laufzeit wird davon Abstand genommen.

Für die vorliegende Arbeit wird folgende Konvention verwendet: Der Zeitstempel, welcher ein Zeitfenster beschreibt, befindet sich immer am Ende des Intervalls. Falls eine Lieferstunde von 13:00 Uhr bis 14:00 Uhr beschrieben werden soll, dann kennzeichnet die Lieferstunde 14:00 Uhr an diesem gewissen Tag dieses Intervall. Dies entspricht der Ziffer 14.

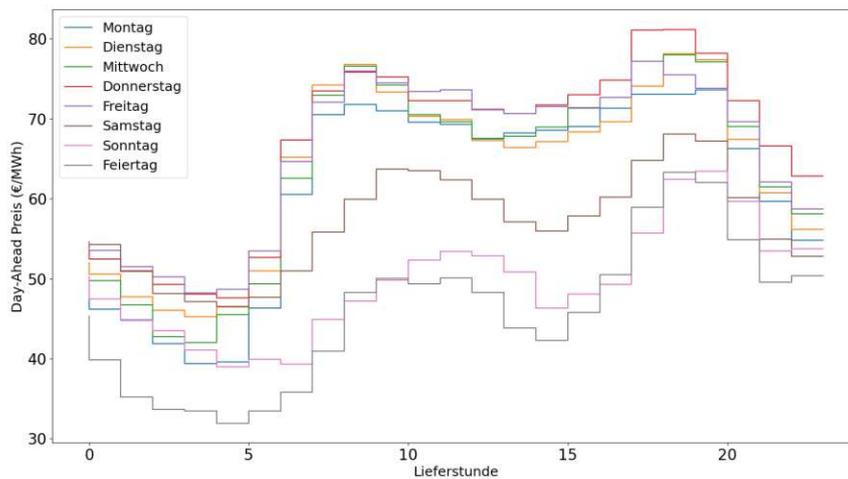


Abbildung 2.1: Die je Wochentag gemittelten Day-Ahead-Preise über den Zeitraum vom 01.10.2018 bis zum 31.12.2018.

Um das Problem der Laufzeit zu umgehen, betrachten wir zunächst die Struktur der Day-Ahead-Preise über die einzelnen Wochentage. In Abbildung 2.1 sind die gemittelten Day-Ahead-Preise je Wochentag für jede Lieferstunde dargestellt. Demnach ist zu

2 Methodik

erkennen, dass sich die Werktage von den restlichen Tagen unterscheiden.¹ Des Weiteren ist ersichtlich, dass gewisse Lieferstunden ähnliche Day-Ahead-Preise haben, da aufeinanderfolgende Stunden in engem Zusammenhang stehen.

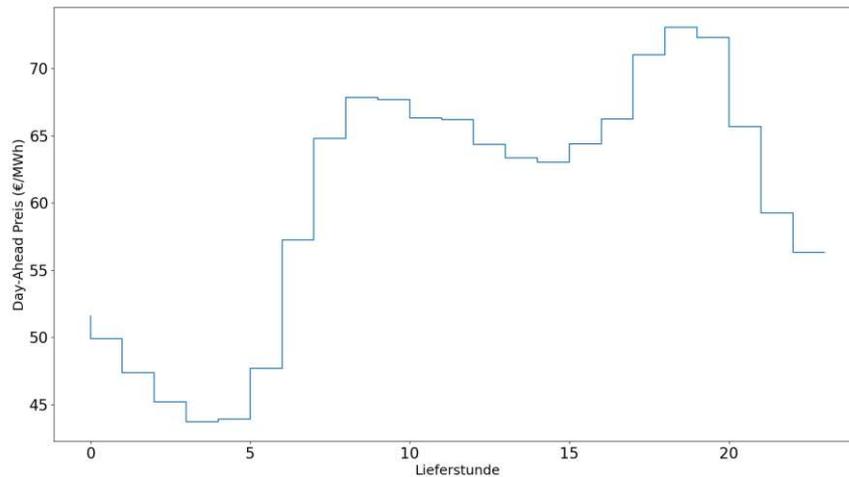


Abbildung 2.2: Die je Lieferstunde gemittelten Day-Ahead-Preise über den Zeitraum vom 01.10.2018 bis zum 31.12.2018.

Damit die Lieferstunden zu Clustern zusammengefasst werden können, wird zunächst in Abbildung 2.2 das tägliche Muster der Day-Ahead-Preise betrachtet. Für diese Abbildung werden die Daten vom 01.10.2018 bis zum 31.12.2018 verwendet. Um den i -ten Datenpunkt in dieser Abbildung zu erhalten, werden alle i -ten Lieferstunden aller Tage in diesem Intervall gemittelt. Laut Abbildung 2.2 ergeben sich zwei Spitzen - eine am Vormittag und eine am Nachmittag. In der Nacht ist der Preis am Day-Ahead-Markt im Vergleich zu den restlichen Stunden tiefer.

Mithilfe des *KMeans* von *scikit-learn* werden die Lieferstunden in drei Cluster unterteilt. Das erste Cluster beinhaltet die Lieferstunden 8 bis 21 und hat das Clusterzentrum bei 66.88 €/MWh. Die Lieferstunden 0 bis 6 sind Elemente des zweiten Clusters mit Clusterzentrum 47.06 €/MWh. Für das dritte Cluster ergeben sich die folgenden Lieferstunden: 7, 22 und 23. Das Clusterzentrum liegt für jenes Cluster bei 57.61 €/MWh.

Des Weiteren unterscheiden wir, wie oben bereits beschrieben, zwischen Werktagen sowie den restlichen Tagen. Wird dieses kombiniert mit den drei Clustern, ergibt sich Tabelle 2.1. An dieser Stelle sollte abermals angemerkt werden, dass die Lieferstunde

¹In dieser Arbeit werden unter *restliche Tage* die Folgenden verstanden: Samstage, Sonntage und Feiertage. Die Werktage sind die komplementären Tage dazu.

Tabelle 2.1: Diese Tabelle beschreibt die Einteilung der Day-Ahead-Preise in sechs Cluster. Beispielsweise ergibt der Mittelwert über die Lieferstunden 8 bis 21 aller Werktage in einer bestimmten Kalenderwoche λ_1 .

Notation	Lieferstunden	Werktag (ja/nein)
λ_1	8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21	ja
λ_2	0, 1, 2, 3, 4, 5, 6	ja
λ_3	7, 22, 23	ja
λ_4	8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21	nein
λ_5	0, 1, 2, 3, 4, 5, 6	nein
λ_6	7, 22, 23	nein

1 eines Tages von 00:00 Uhr bis 01:00 Uhr reicht. In Tabelle 2.1 beschreibt λ_1 in einer gewissen Kalenderwoche den Mittelwert über alle Preise der Lieferstunden 8 bis 21 an Werktagen. Daher charakterisiert $\lambda = (\lambda_1, \dots, \lambda_6)^\top$ die gemittelten Day-Ahead-Preise in einer Kalenderwoche.

Für die Kalenderwochen 40 bis 52 im Jahr 2018 ergeben sich 13 Wochen und somit 13 Datenpunkte. Diese Datenpunkte stellen in Abbildung 2.3, 2.4 und 2.5 die schwarzen Punkte dar, wobei nur λ_2 sowie λ_5 betrachtet werden. Die roten kleinen Punkte sind die Elemente der Menge in Gleichung 2.6, von welcher die konvexe Hülle gebildet wird. In den Abbildungen 2.3, 2.4 und 2.5 ist zu erkennen, dass mit zunehmendem Parameter α die konvexe Hülle und somit die Unsicherheitsmenge kleiner wird. In anderen Worten kann gesagt werden, dass mit abnehmender Risikoaversion (steigendem Parameter α) die Unsicherheitsmenge kleiner wird.

2.3 Bewertungskriterium

Ein Portfolio bestehend aus Windkraftanlagen, Photovoltaikanlagen sowie einem elektrischen Stromspeicher kann unterschiedlich riskant an den Strommärkten vermarktet werden. Abhängig vom Risiko erwirtschaftet dieses Portfolio unterschiedlich viel und wir wollen in weiterer Folge die Ergebnisse bewerten. Hierfür verwenden wir die *Sharpe-Ratio* wie in [17] ausgeführt. Diese dient der Bewertung von Geldanlagen im Vergleich mit einem Benchmark-Portfolio. In dieser Arbeit besitzen die zu vergleichenden Portfolios jeweils die gleichen Vermögenswerte (gleiche Anzahl und Größe an Windkraftanlagen, Photovoltaikmodulen sowie Stromspeichern), unterscheiden sich jedoch im eingegangenen Risiko.

Wir gehen angelehnt an [17] vor. Sei $P_\alpha(m)$ der Profit hinsichtlich dem Risikoparameter α im Monat m .² Zudem wird mit $P_B(m)$ der Profit eines Benchmark-Portfolios im selben

²In [17] wird die *Sharpe-Ratio* nicht für den Profit, sondern für die Rendite formuliert.

2 Methodik

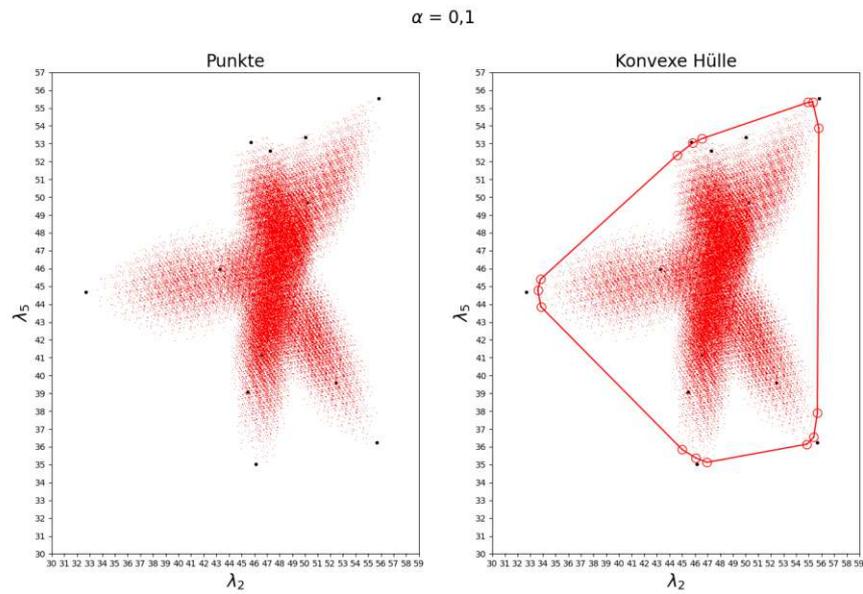


Abbildung 2.3: Die konvexe Hülle beziehungsweise Unsicherheitsmenge für $\alpha = 0,1$ bezüglich der Datenpunkte aus den Kalenderwochen 40 bis 52 im Jahr 2018.

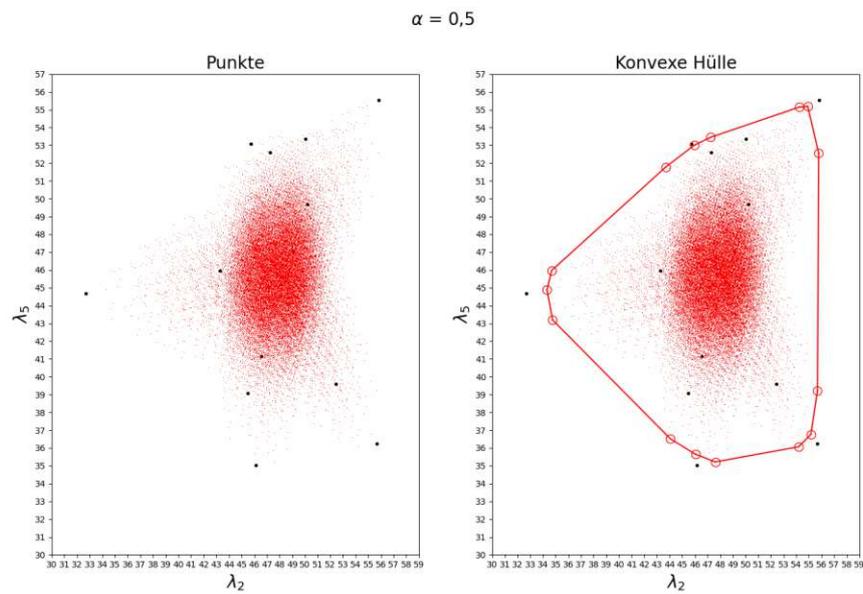


Abbildung 2.4: Die konvexe Hülle beziehungsweise Unsicherheitsmenge für $\alpha = 0,5$ bezüglich der Datenpunkte aus den Kalenderwochen 40 bis 52 im Jahr 2018.

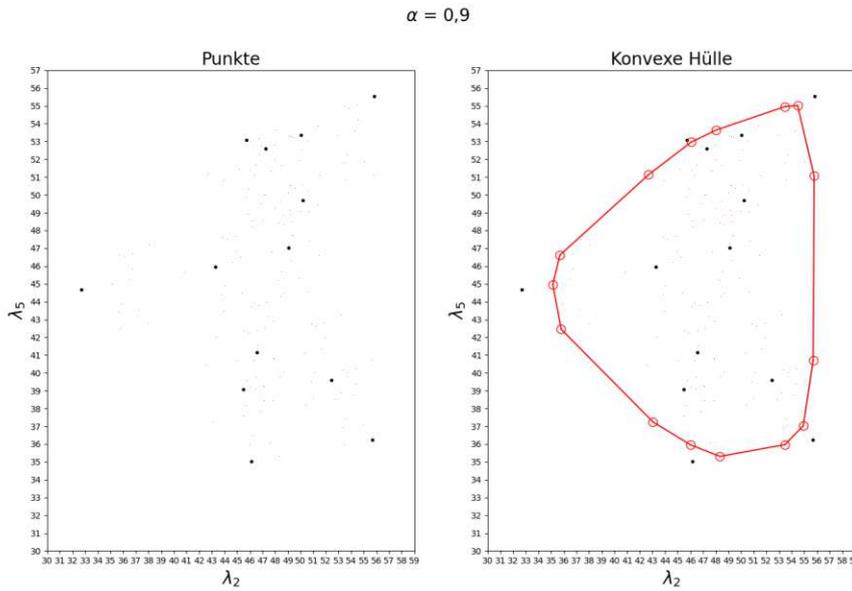


Abbildung 2.5: Die konvexe Hülle beziehungsweise Unsicherheitsmenge für $\alpha = 0.9$ bezüglich der Datenpunkte aus den Kalenderwochen 40 bis 52 im Jahr 2018.

Monat m definiert. In dieser Arbeit stellt das Benchmark-Portfolio ein festes α dar. In weiterer Folge betrachten wir in jedem Monat m die Differenz zum Benchmark-Portfolio und daher gilt:

$$D(m) := P_\alpha(m) - P_B(m).$$

Sei \bar{D} der Durchschnitt von $D(m)$ über alle Monate M und demnach folgt

$$\bar{D} := \frac{1}{|M|} \sum_{m \in M} D(m), \tag{2.8}$$

wobei $|\cdot|$ der Kardinalität der Menge M entspricht. Ferner beschreibt σ_D die empirische Standardabweichung über alle Monate M und daher gilt:

$$\sigma_D = \sqrt{\frac{1}{|M| - 1} \sum_{m \in M} (D(m) - \bar{D})^2}. \tag{2.9}$$

Mit Gleichung 2.8 und 2.9 folgt die *Sharpe-Ratio*:

$$S := \frac{\bar{D}}{\sigma_D}.$$

2 Methodik

Dieses Bewertungskriterium beschreibt die durchschnittliche historische Differenz der Profite zu jenen eines Benchmark-Portfolios pro Einheit der historischen Variabilität derselben. Je höher die Profite im Vergleich zu jenen des Benchmark-Portfolios sind, desto größer ist S . Entsprechend steigt S , falls σ_D geringer ausfällt. Ein risikoaverser Investor in präferiert unter gleichbleibendem Profit gerade jene Anlage, die geringere Schwankungen aufweist. Demnach ist jenes Portfolio zu bevorzugen, welches die größte *Sharpe-Ratio* liefert.

2.4 Daten und Implementierung

In dieser Arbeit werden alle Berechnungen auf einem i7 Prozessor von Intel mit 2.7 GHz und 16 GB RAM durchgeführt. Aufgrund von umfangreichen Paketen wird auf die Programmiersprache Python in der Version 3.9 zurückgegriffen. Des Weiteren wird als Entwicklungsumgebung die Python-IDE PyCharm verwendet (siehe [18]).

Für die Optimierung wird das Python Paket *romodel*, das in [19] eingeführt wird, verwendet und eine akademische Lizenz von Gurobi wird zum Lösen des Modells benutzt.³ *Romodel* erweitert *pyomo*, das Open Source zugänglich ist und in Python für das Lösen von Optimierungsproblemen entwickelt wurde. Nähere Details zu *pyomo* sind in [20] zu finden. Für das Clustern der Lieferstunden wird *scikit-learn* verwendet, welches unterschiedlichste Machine Learning Algorithmen, wie beispielsweise *KMeans*, implementiert hat. Nähere Details zu *scikit-learn* sind in [21] zu finden. Für die Berechnung der konvexen Hülle wird *scipy* von [22] verwendet. Zusätzlich werden folgende Pakete herangezogen: *datetime*, *holidays*, *matplotlib*, *numpy*, *pandas* und *plotly*.

Für den Standort Neusiedl an der Zaya werden die Daten für die Windkraftanlagen und Photovoltaikanlagen von Renewables.ninja (siehe [23]) bezogen. Als Breite (*engl.: Latitude*) und Länge (*engl.: Longitude*) werden 48.60 sowie 16.79 verwendet. Für die Windkraftanlagen werden die Charakteristika der Turbinen Gamesa G90 2000 in der Höhe von 90 m verwendet. Hinsichtlich des Photovoltaikmoduls wird ein Systemverlust von 10 % angenommen. Für die restlichen Parameter wird die Standardeinstellung verwendet. Nähere Details zu dieser Datenquelle sind in [24] und [25] zu finden. Die Day-Ahead-Preise, die Ausgleichsenergiepreise sowie die Wind- und Photovoltaikerzeugung für ganz Österreich stammen von der ENTSO-E Transparency Plattform [26].

Der Code, der das zweiphasige Optimierungsproblem laut Kapitel 3 darstellt, ist online unter https://gitlab.com/foto1996/mathe_thesis zu finden. An dieser Stelle kann angemerkt werden, dass für einen bestimmten Parameter α und für den Betrachtungszeitraum von einem Monat ein Durchlauf inklusive Optimierung einige Minuten dauert.

³Die Lizenz kann unter <https://www.gurobi.com/downloads/end-user-license-agreement-academic/> erhalten werden.

3 Zweiphasiges Optimierungsproblem

In diesem Kapitel werden die zwei Phasen der Portfoliooptimierung beschrieben. Jeweils für einen gesamten Monat wird das Portfolio bestehend aus Windkraftanlagen, Photovoltaikanlagen und einem elektrischen Stromspeicher optimiert. In einer ersten Phase (siehe Kapitel 3.1) wird ein Teil der zur Verfügung stehenden Ressourcen am Terminmarkt vermarktet und der verbleibende Anteil wird später am Day-Ahead-Markt verkauft. In der zweiten Phase wird unter Berücksichtigung der verkauften Energie am Terminmarkt und den neu gewonnen Informationen am Tag vor der Lieferung die überschüssige Energie am Day-Ahead-Markt veräußert (siehe Kapitel 3.2). Im Folgenden werden die beiden MILP Optimierungsprobleme formuliert.

3.1 Phase I: Terminmarkt und Day-Ahead-Markt

Am Terminmarkt kann sowohl die Grundlast (Base) als auch die Spitzenlast (Peak) vermarktet werden. Die Monatswerte eines österreichischen Strompreisindex - dem ÖSPI - sind in [27] zu finden. Demnach wird von Spitzenlast gesprochen, falls die Lieferung zwischen 8:00 Uhr und 20:00 Uhr unter der Woche stattfindet (Montag bis Freitag).

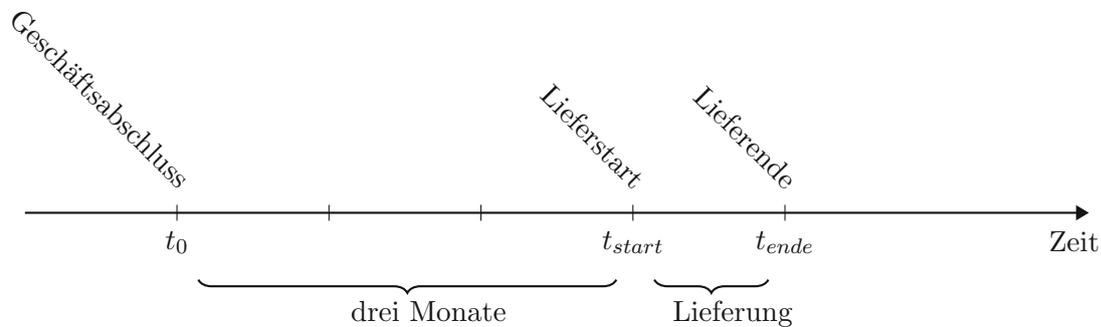


Abbildung 3.1: Diese Abbildung stellt die erste Phase der Portfoliooptimierung dar. Der Geschäftsabschluss befindet sich drei Monate vor Lieferstart. Die Lieferung, welche zwischen Lieferstart und Lieferende stattfindet, dauert einen Monat. Dieser Monat wird auch Betrachtungszeitraum genannt.

Wie in Abbildung 3.1 ersichtlich, dauert die Lieferung einen Monat und beginnt ab dem Geschäftsabschluss t_0 in drei Monaten. Jede Lieferstunde in diesem Monat wird mit

3 Zweiphasiges Optimierungsproblem

einem Zeitstempel versehen, welcher der Konvention dieser Arbeit folgend, am Ende der Lieferstunde ist. Diese Menge notieren wir in weiterer Folge mit \mathcal{T} . Die Lieferstunden, die an einem Montag bis Freitag zwischen 8:00 Uhr und 20:00 Uhr stattfinden, befinden sich in der Menge \mathcal{T}^P und beschreiben die Peak-Lieferstunden. Demzufolge gilt $\mathcal{T}^P \subseteq \mathcal{T}$.

Unsicherheiten

In der ersten Phase der Portfoliooptimierung liegen uns drei Unsicherheiten vor. Diese sind Day-Ahead-Preise, Windstärke und Sonneneinstrahlung. Für die unsicheren Day-Ahead-Preise wird als Unsicherheitsmenge \mathcal{U} Gleichung 2.6 verwendet. Dies bedeutet, dass aus den endlich vielen Beobachtungen $\{\lambda_1, \dots, \lambda_N\}$ die Menge \mathcal{U}_1 berechnet wird. Wir werden in weiterer Folge $N = 12$ wählen. Daraus folgt, dass die letzten zwölf Wochen vor t_0 laut Abbildung 3.1 als Datengrundlage verwendet werden. Für jene Wochen werden die Preise nach Tabelle 2.1 berechnet und demnach entspricht $\{\lambda_1, \dots, \lambda_{12}\}$ 6-dimensionalen Vektoren. In jenem Fall beschreibt λ_i für $i \in \{1, \dots, 12\}$ die Day-Ahead-Preise für eine bestimmte Woche. Für eine detailliertere Beschreibung siehe Kapitel 2.2.

Für die Unsicherheitsmenge der Stromproduktion aus Windkraft wird wie folgt vorgegangen: Drei Monate im Voraus ist das Windaufkommen sehr schwer abschätzbar. Einzig die Jahreszeit ist wegen den Saisonalitäten von enormer Bedeutung. Um dennoch eine gute Näherung zu erhalten, werden die ENTSO-E Daten (siehe [26]) als Datengrundlage herangezogen. Die Daten für Österreich aus dem Vorjahr sind bekannt und daher können wir die Winddaten aus folgendem Intervall verwenden

$$[t_{ende} - 365 \text{ Tage} - 84 \text{ Tage}, t_{ende} - 365 \text{ Tage}),$$

wobei sich t_{ende} laut Abbildung 3.1 auf das Lieferende bezieht. Dieses Intervall entspricht abermals zwölf Wochen. Mithilfe der installierten Windkraftleistung im Jahr 2018 kann der Wochennutzungsgrad aller Windturbinen in Österreich in Prozent berechnet werden.¹ Laut [28] ist die installierte Windkraftleistung im Jahr 2018 gleich 3039 MW. Aus diesen zwölf Werten w_1, \dots, w_{12} wird zunächst das α -Quantil (siehe Gleichung 2.4) und anschließend der $CVaR_\alpha$ laut Gleichung 2.5 ermittelt. Da wir Windturbinen mit maximalen Leistungen von 2 MW betrachten, stammt die unsichere Erzeugung für jede Lieferstunde $t \in \mathcal{T}$ aus folgendem Intervall:

$$\mathcal{W} = [2 \cdot CVaR_\alpha(\{w_1, \dots, w_{12}\}), 2].$$

Diese Unsicherheitsmenge entspricht jener aus Gleichung 2.7. Hier sollte angemerkt werden, dass für ein festes α sowie feste Werte w_1, \dots, w_{12} die Unsicherheitsmenge \mathcal{W} für alle Lieferstunden in \mathcal{T} gleich ist.

Des Weiteren gehen wir bezüglich der unsicheren Stromerzeugung durch Photovoltaik-

¹Analog zu der Berechnung vom Jahresnutzungsgrad wird der Wochennutzungsgrad berechnet und ist ein Wert zwischen Null und Eins.

anlagen wie folgt vor: Drei Monate im Voraus ist von Bedeutung, dass die täglichen Saisonalitäten durch die Prognose abgebildet werden. Daher werden abermals die ENTSO-E Daten herangezogen. Alle Stunden im Zeitfenster $[t_{start} - 365 \text{ Tage}, t_{ende} - 365 \text{ Tage})$ werden durch die installierte Photovoltaikleistung in Österreich im Jahr 2018 dividiert. Laut [29] beträgt die installierte Photovoltaikleistung im Jahr 2018 gesamt 1455 MW. Jene Werte werden anschließend mit der maximalen Leistung von 0.3 MW je Photovoltaikanlage multipliziert. In dieser Arbeit werden unter dem Begriff Photovoltaikanlage mehrere Module zusammengefasst und daher ist eine maximale Leistung von 0.3 MW möglich. Die resultierenden Werte werden in der Optimierung als deterministisch angenommen. Jedoch kann die tatsächliche Erzeugung in einer gewissen Stunde stark von dieser Prognose abweichen.

Formulierung

In diesem Abschnitt formulieren wir das Modell, welches die am Terminmarkt sowie am Day-Ahead-Markt zu verkaufende Energie bestimmt. Als Preisnehmer_in werden die Ressourcen auf Grundlage unserer Informationen über den verfügbaren Wind, der verfügbaren Sonneneinstrahlung sowie der Preise veräußert. Als Entscheidungsvariablen dienen uns die folgenden Variablen: P_w^B , P_w^P , P_w^{DA} , P_s^B , P_s^P und P_s^{DA} . Diese stellen die produzierten Einheiten einer Windkraftanlage (2 MW) sowie einer Photovoltaikanlage (0.3 MW) dar. Hier steht B für Base, P für Peak und DA für Day-Ahead. Des Weiteren beschreibt n die Anzahl der Windkraftanlagen und m die Anzahl der Photovoltaikanlagen. Für eine Base-Lieferstunde t bestimmt $nP_w^B(t) + mP_s^B(t)$ die gesamte vermarktete Energie in dieser Stunde am Terminmarkt und diese notieren wir mit P^B . Für die Dauer des Kontraktes muss in jeder Base-Lieferstunde die gleiche Menge geliefert werden. Analoges gilt für eine Peak-Lieferstunde t und daher gilt: $nP_w^P(t) + mP_s^P(t) = P^P$. Der Preis für die Base-Lieferstunden wird mit μ_1 notiert und jener für die Peak-Lieferstunden mit μ_2 .

Zielfunktion

Da der Profit maximiert werden soll, muss der Erlös sowie die Kosten über den betrachteten Zeitraum berechnet werden. Der Erlös E aus der verkauften Energie ergibt sich wie folgt:

$$E = |\mathcal{T}| \mu_1 P^B + |\mathcal{T}^P| \mu_2 P^P + \sum_{t \in \mathcal{T}} \tilde{\lambda}(t) (nP_w^{DA}(t) + mP_s^{DA}(t)). \quad (3.1)$$

Mit $\tilde{\lambda}(t)$ wird der unsichere Day-Ahead-Preis in der Lieferstunde t beschrieben. Des Weiteren kennzeichnet $|\cdot|$ die Kardinalität einer Menge. Da mit dem Betreiben der Windkraftanlagen sowie Photovoltaikanlagen Kosten K einhergehen, können diese wie folgt

3 Zweiphasiges Optimierungsproblem

berechnet werden:

$$K = \sum_{t \in \mathcal{T}} C_w n(P_w^B(t) + P_w^P(t) + P_w^{DA}(t)) + C_s m(P_s^B(t) + P_s^P(t) + P_s^{DA}(t)). \quad (3.2)$$

Hier beschreiben C_w und C_s die Kosten der Produktion mit Windkraft sowie Photovoltaik in €/MWh. Mithilfe der Gleichungen 3.1 und 3.2 ergibt sich die Zielfunktion $E - K$. Da das Maximieren des Profits äquivalent zum Minimieren des negativen Profits ist, kann das Optimierungsproblem folgendermaßen formuliert werden:

$$\min_{P_w^B(t), P_w^P(t), P_w^{DA}(t), P_s^B(t), P_s^P(t), P_s^{DA}(t)} \max_{\tilde{\lambda}(t) \in \mathcal{U}, \tilde{P}_w(t) \in \mathcal{W}} -E + K.$$

An dieser Stelle sollte angemerkt werden, dass $\mathcal{U} \subseteq \mathbb{R}^6$ gilt. In weiterer Folge muss bestimmt werden, auf welchen Eintrag von $\tilde{\lambda}$ sich $\tilde{\lambda}(t)$ bezieht. Dafür benötigen wir für eine Lieferstunde t den Wochentag ($weekday(t)$) und die Stunde des Tages ($hour(t)$), welche mit $\{0, \dots, 6\}$ sowie $\{0, \dots, 23\}$ kodiert sind. Bezüglich Ersterem beschreibt 0 den Montag und hinsichtlich Zweiterem wird unter 1 die erste Stunde eines Tages verstanden.² Alle österreichischen Feiertage werden wie Sonntage (entspricht der Ziffer 6) behandelt. Aufgrund der Eigenschaften der Lieferstunde t ($hour(t)$ und $weekday(t)$) wird mit obestehender Tabelle 2.1 der Eintrag bestimmt.

Nebenbedingungen

Wie bereits weiter oben beschrieben, muss in jeder Base-Lieferstunde gleich viel vermarktet werden. Die Produktionsmenge P_w^B und P_s^B der n Windkraftanlagen und m Photovoltaikanlagen muss das Folgende erfüllen:

$$nP_w^B(t) + mP_s^B(t) = P^B \quad \forall t \in \mathcal{T}.$$

Für die Peak-Lieferstunden gilt:

$$\begin{aligned} nP_w^P(t) + mP_s^P(t) &= P^P & \forall t \in \mathcal{T}^P, \\ nP_w^P(t) + mP_s^P(t) &= 0 & \forall t \in \mathcal{T} \setminus \mathcal{T}^P. \end{aligned}$$

Da die Produktion einer Windkraftanlage nur positiv sein kann und zusätzlich durch den auftretenden Wind beschränkt ist, ergibt sich folgende Nebenbedingung:

$$0 \leq P_w^B(t) + P_w^P(t) + P_w^{DA}(t) \leq \tilde{P}_w(t) \quad \forall t \in \mathcal{T}. \quad (3.3)$$

Hier beschreibt $\tilde{P}_w(t)$ die unsichere Windkraftleistung zum Zeitpunkt t . Ähnliche Restriktionen treten bei einer Photovoltaikanlage auf, wobei hier die prognostizierte Pho-

²Demnach beschreibt 0 die letzte Stunde eines Tages, da sich der Zeitstempel am Ende des Intervalls befindet.

tovoltaikleistung $\hat{P}_s(t)$ die obere Schranke darstellt. Daher gilt:

$$0 \leq P_s^B(t) + P_s^P(t) + P_s^{DA}(t) \leq \hat{P}_s(t) \quad \forall t \in \mathcal{T}. \quad (3.4)$$

Da eine Windkraftanlage im Hoch- und Herunterfahren beschränkt ist, ergibt sich $\forall t \in \mathcal{T}$ folgende zusätzliche Nebenbedingung

$$-P_w^r \leq P_w^B(t) + P_w^P(t) + P_w^{DA}(t) - P_w^B(t-1) - P_w^P(t-1) - P_w^{DA}(t-1) \leq P_w^r, \quad (3.5)$$

wobei davon ausgegangen wird, dass vor dem Lieferstart t_{start} die Windkraftanlage nicht in Betrieb ist. Daher gilt:

$$P_w^B(t_{start}) + P_w^P(t_{start}) + P_w^{DA}(t_{start}) = 0.$$

Die Nebenbedingung in 3.5 ergibt bei Zeitintervallen von einer Stunde wenig Sinn - bei feinerer Granularität wird sie jedoch benötigt. Des Weiteren muss für einige Entscheidungsvariablen folgende Nichtnegativitätsbedingung gelten:

$$P_w^B(t), P_w^P(t), P_s^B(t), P_s^P(t) \geq 0 \quad \forall t \in \mathcal{T}.$$

Die Variablen P_w^{DA} und P_s^{DA} können auch negativ sein, da wir zulassen, dass am Day-Ahead-Markt eingekauft werden kann. Dennoch sind diese Variablen durch die Nebenbedingungen 3.3 und 3.4 beschränkt. Des Weiteren führen wir eine obere Schranke für die Variablen $P_w^B(t), P_w^P(t), P_s^B(t)$ und $P_s^P(t)$ ein, da nicht mehr am Terminmarkt verkauft werden soll, als gesamt produziert werden kann. Diese Nebenbedingung lautet:

$$P^B + P^P \leq 2n + 0.3m.$$

3.2 Phase II: Day-Ahead-Markt

In Anlehnung an [9] und [10] wird das der zweiten Phase zugrunde liegende Modell eingeführt. Die verkauften Einheiten am Terminmarkt werden hierfür als gegeben angenommen. Laut EPEX SPOT (siehe [30]) findet täglich um 12:00 Uhr für Österreich die gekoppelte Day-Ahead-Auktion für die 24 Lieferstunden am kommenden Tag statt. Somit werden wir rollierend für jeden Tag im betrachteten Zeitraum wie in Abbildung 3.2 vorgehen.

In Abschnitt 3.1 wurde ein elektrischer Stromspeicher noch außer Acht gelassen. Dies resultiert aus der Tatsache, dass ein Fahrplan für einen kleinen Speicher unter den angenommenen Unsicherheiten und der zeitlichen Dimension keinen Mehrwert mit sich bringt. In der zweiten Phase werden wir den elektrischen Stromspeicher jedoch im Modell mitberücksichtigen, da die Optimierung kurz vor Lieferung stattfindet.

3 Zweiphasiges Optimierungsproblem

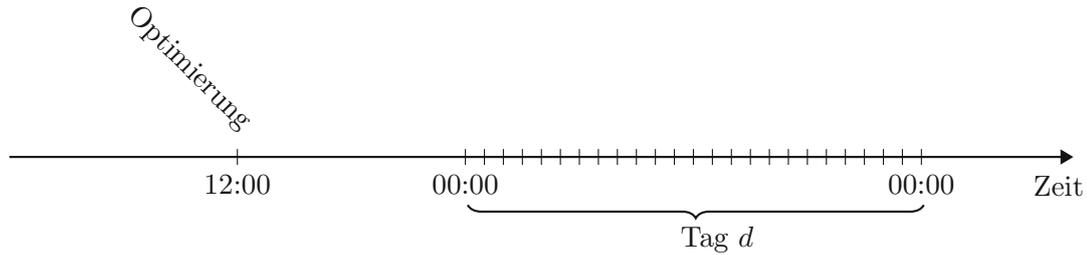


Abbildung 3.2: Diese Abbildung stellt die Optimierung für den Tag d im Betrachtungszeitraum dar. Am Vortag um 12:00 Uhr werden die noch zur Verfügung stehenden Ressourcen am Day-Ahead-Markt vermarktet.

Unsicherheiten

Wie bereits in Abschnitt 3.1 verwenden wir für den unsicheren Day-Ahead-Preis hinsichtlich einer Lieferstunde t die Unsicherheitsmenge \mathcal{U} aus Gleichung 2.6. Abermals wird $N = 12$ gesetzt und als Datengrundlage dienen uns alle Day-Ahead-Preise in folgendem Zeitfenster:

$$[t_{start} - 84 \text{ Tage}, t_{start}). \quad (3.6)$$

Hier bezieht sich t_{start} , wie in Abbildung 3.1, auf den Beginn unseres Betrachtungszeitraums. Alle Day-Ahead-Preise im Intervall in Gleichung 3.6 sind während jeder Optimierung laut Abbildung 3.2 bekannt. Aus den Preisen in diesem Intervall wird $\{\lambda_1, \dots, \lambda_{12}\}$ berechnet, wobei λ_i für $i \in \{1, \dots, 12\}$ die Day-Ahead-Preise für die i -te Woche beschreibt. Abermals ist λ_i ein 6-dimensionaler Vektor, welcher Einträge gemäß Tabelle 2.1 hat.

Für die unsichere Stromproduktion aus Windkraft in der Lieferstunde t - dies notieren wir mit $\tilde{P}_w(t)$ - kann die Unsicherheitsmenge wie folgt formuliert werden:

$$\mathcal{W}(t) = [2 \cdot CVaR_\alpha(\{w_1, \dots, w_{24}\}), 2].$$

Als Datengrundlage werden, wie in Abschnitt 3.1, die ENTSO-E Daten und die installierte Windkraftleistung im Jahr 2019 verwendet. An dieser Stelle beschreibt w_1, \dots, w_{24} den Stundennutzungsgrad in Prozent aller Windturbinen in Österreich in den 24 Stunden vor der Day-Ahead-Markt Optimierung.³ Laut [28] ist die installierte Windkraftleistung im Jahr 2019 in Österreich gleich 3159 MW. Daraus ergibt sich, dass für alle Lieferstunden am Tag d dieselbe Unsicherheitsmenge verwendet wird.

Betreffend der unsicheren Photovoltaikerzeugung wird wie folgt vorgegangen: Falls wir den Tag d optimieren, werden die ENTSO-E Solardaten vom Tag $d - 2$ verwendet.

³Analog zu der Berechnung vom Jahresnutzungsgrad wird der Stundennutzungsgrad berechnet. Dieser ist ein Wert zwischen Null und Eins.

Diese sind zum Zeitpunkt der jeweiligen Optimierung bekannt. Mithilfe der installierten Photovoltaikleistung im Jahr 2019 wird der Stundennutzungsgrad berechnet. Laut [29] beträgt die installierte Photovoltaikleistung in Österreich im Jahr 2019 gleich 1702 MW. Jener Stundennutzungsgrad wird anschließend mit der maximalen Leistung von 0.3 MW multipliziert. Auf diese Art erhalten wir für den Tag d und die Lieferstunde t die naive Punktprognose $\hat{P}_s(t)$, welche die täglichen Saisonalitäten mitberücksichtigt.

Formulierung

Wie bereits angemerkt, wird zusätzlich ein Stromspeicher berücksichtigt und daher werden folgende Variablen eingeführt: P_b^d , P_b^c , E_b und δ . Diese stehen für das Entladen, das Laden sowie den aktuellen Stand des Stromspeichers. Letztere ist eine binäre Variable und bestimmt, ob geladen oder entladen wird. Die restlichen Variablen werden analog zu Abschnitt 3.1 notiert.

Zielfunktion

Wie bereits in Abschnitt 3.1 wird unter den vorliegenden Informationen der Profit maximiert. Der Erlös E aus der Vermarktung am Day-Ahead-Markt wird wie folgt berechnet:

$$E = \sum_{t \in \mathcal{T}} \tilde{\lambda}(t) (nP_w^{DA}(t) + mP_s^{DA}(t) + P_b^d(t) - P_b^c(t)).$$

Auch in dieser Phase müssen die Kosten K für das Betreiben der Windkraftanlagen, der Photovoltaikanlagen sowie des Stromspeichers mitberücksichtigt werden. Für die am Day-Ahead-Markt verkauften Mengen ergibt sich:

$$K = \sum_{t \in \mathcal{T}} C_w n P_w^{DA}(t) + C_s m P_s^{DA}(t) + C_b (P_b^d(t) + P_b^c(t)) + C_e E_b(t).$$

Hier beschreibt C_b die Kosten für das Laden und Entladen des elektrischen Stromspeichers und C_e die Energiespeicherkosten. Die Zielfunktion des Optimierungsproblems von Phase II kann wie folgt formuliert werden:

$$\min_{P_w^{DA}(t), P_s^{DA}(t), P_b^d(t), P_b^c(t), E_b(t), \delta(t)} \max_{\tilde{\lambda}(t) \in \mathcal{U}, \tilde{P}_w(t) \in \mathcal{W}(t)} -E + K.$$

Nebenbedingungen

In Abschnitt 3.1 wurde die am Terminmarkt verkaufte Energie je Windkraftanlage und Photovoltaikanlage bestimmt. Dies muss in der zweiten Phase mitberücksichtigt werden. Demnach gilt:

$$\begin{aligned} P_w^{DA}(t) &\leq \tilde{P}_w(t) - P_w^B(t) - P_w^P(t) && \forall t \in \mathcal{T}, \\ P_s^{DA}(t) &\leq \hat{P}_s(t) - P_s^B(t) - P_s^P(t) && \forall t \in \mathcal{T}. \end{aligned}$$

3 Zweiphasiges Optimierungsproblem

Hier sollte angemerkt werden, dass sowohl $P_w^{DA}(t)$ als auch $P_s^{DA}(t)$ für eine Lieferstunde t negativ werden kann. Aus ökonomischer Sicht wird in jenem Fall am Day-Ahead-Markt Energie gekauft. Darüber hinaus sind $P_w^B(t)$, $P_w^P(t)$, $P_s^B(t)$ und $P_s^P(t)$ in dieser Phase fix und somit keine Entscheidungsvariablen.

Des Weiteren kann die Produktion einer Windkraftanlage sowie einer Photovoltaikanlage niemals negativ sein und daher muss gelten:

$$\begin{aligned} 0 &\leq P_w^B(t) + P_w^P(t) + P_w^{DA}(t) && \forall t \in \mathcal{T}, \\ 0 &\leq P_s^B(t) + P_s^P(t) + P_s^{DA}(t) && \forall t \in \mathcal{T}. \end{aligned}$$

Wie in Abschnitt 3.1 wird eine Nebenbedingung für das Hoch- und Herunterfahren der Windkraftanlage verwendet. Für $\forall t \in \mathcal{T}$ gilt

$$-P_w^r \leq P_w^B(t) + P_w^P(t) + P_w^{DA}(t) - P_w^B(t-1) - P_w^P(t-1) - P_w^{DA}(t-1) \leq P_w^r,$$

wobei angenommen wird, dass die Windkraftanlage zu Beginn des Betrachtungszeitraums stillsteht. Laut Abbildung 3.1 stellt t_{start} den Beginn dar und demnach folgt:

$$P_w^B(t_{start}) + P_w^P(t_{start}) + P_w^{DA}(t_{start}) = 0.$$

Durch das Laden ($P_b^c(t)$) und Entladen ($P_b^d(t)$) des elektrischen Stromspeichers ergibt sich eine Speicherdynamik, welche folgendermaßen beschrieben werden kann:

$$E_b(t) = E_b(t-1) - \frac{1}{\eta_d} P_b^d(t) + \eta_c P_b^c(t) \quad \forall t \in \mathcal{T}.$$

Hier drückt η_d und η_c den Entladungswirkungsgrad sowie den Ladungswirkungsgrad des Stromspeichers aus. Zusätzlich gilt

$$E_b(t_{start}) = s_0, \tag{3.7}$$

wobei s_0 den Füllstand zu Beginn des Betrachtungszeitraums beschreibt. Da ein Stromspeicher eine untere und obere Schranke hinsichtlich des Energieniveaus hat, gilt:

$$E_b^{min} \leq E_b(t) \leq E_b^{max} \quad \forall t \in \mathcal{T}.$$

Diese Schranken sind jeweils in MWh. Wie oben beschrieben, wird über den Betrachtungszeitraum rollierend am Day-Ahead-Markt optimiert. Daher treffen wir die Annahme, dass neben der Anfangsbedingung in Gleichung 3.7 zusätzlich am Ende jedes Tages der Stromspeicher den Füllstand s_0 annehmen muss. Daher gilt mit $hour(t)$ wie in Abschnitt 3.1 Folgendes:

$$E_b(t) = s_0 \quad \forall t \in \{t' \in \mathcal{T} : hour(t') = 0\}.$$

Die Ziffer 0 beschreibt die letzte Stunde jeden Tages. Des Weiteren kann der Stromspei-

cher zu einem Zeitpunkt t nicht gleichzeitig laden und entladen. Mithilfe der binären Variable $\delta(t)$ gilt:⁴

$$\begin{aligned} 0 \leq P_b^c(t) \leq P_b^{max}(1 - \delta(t)) & \quad \forall t \in \mathcal{T}, \\ 0 \leq P_b^d(t) \leq P_b^{max}\delta(t) & \quad \forall t \in \mathcal{T}. \end{aligned}$$

Hier beschreibt P_b^{max} die Nennleistung des elektrischen Stromspeichers in MW.

⁴Falls $\delta(t) = 0$ gilt, kann zum Zeitpunkt t der Stromspeicher geladen werden. Für $\delta(t) = 1$ ist demnach das Entladen möglich.

4 Resultate

Um den Profit für den Betrachtungszeitraum zu berechnen, werden die tatsächlichen Windstärken sowie Sonneneinstrahlungen am Standort Neusiedl an der Zaya benötigt. Zudem sind folgende Fälle für die Berechnung des Profits zu unterscheiden:

- Falls mehr Energie verkauft wurde als mit dem tatsächlichen Wind sowie der Sonneneinstrahlung in der Stunde t produziert werden kann, muss dafür der Ausgleichsenergiepreis bezahlt werden.
- Sofern mehr produziert werden könnte, als verkauft wurde, wird angenommen, dass die Windturbinen sowie Photovoltaikanlagen abgeregelt werden.

Um den Profit zu berechnen, müssen wir zuerst die Parameter der Optimierungsmodelle bestimmen. Für den Terminmarkt wird laut Kapitel 3 für jeden Monat im Betrachtungszeitraum ein Preis μ_1 für die Base-Lieferstunden und ein Preis μ_2 für die Peak-Lieferstunden benötigt. Da laut [31] die historischen Baseload sowie Peakload Monatsprodukte für das Jahr 2019 zum Zeitpunkt des Verfassens der Arbeit nicht mehr zur Verfügung stehen, werden diese künstlich erzeugt. Dies resultiert aus der Tatsache, dass wir nur Daten beziehungsweise Preise verwenden wollen, welche öffentlich zugänglich sind. Die Monate m_1^i, \dots, m_{12}^i eines Jahres i werden zu Quartalen zusammengefasst. Demnach beschreibt m_1^i den Monat Jänner im Jahr i und diese Menge hat Kardinalität $31 \cdot 24$ (Tage des Monats mal Stunden eines Tages). Somit gilt:

$$\begin{aligned}
 Q_1^i &= \{m_1^i, m_2^i, m_3^i\}, \\
 Q_2^i &= \{m_4^i, m_5^i, m_6^i\}, \\
 Q_3^i &= \{m_7^i, m_8^i, m_9^i\}, \\
 Q_4^i &= \{m_{10}^i, m_{11}^i, m_{12}^i\}.
 \end{aligned}$$

Darüber hinaus wird der gemittelte Day-Ahead-Preis für jedes Quartal berechnet und diese Mittelwerte verwenden wir als Preise für die Baseload Monatsprodukte. Somit folgt für $i \in \{2018, 2019\}$

$$\mu_1(Q_j^i) = \frac{1}{|Q_j^i|} \sum_{t \in Q_j^i} \lambda(t) \quad \forall j \in \{1, 2, 3, 4\}, \quad (4.1)$$

wobei $|\cdot|$ der Kardinalität der Stunden in der Menge Q_j^i entspricht. Der Notation dieser Arbeit folgend, beschreibt $\lambda(t)$ den Day-Ahead-Preis für die Lieferstunde t . Folglich ergeben sich die Preise in Tabelle 4.1 für die unterschiedlichen Quartale. Für die Preise der Peak-Lieferstunden multiplizieren wir die erste Zeile in dieser Tabelle mit 1.1,

4 Resultate

da anzunehmen ist, dass die Peakload Monatsprodukte teurer sind als die Baseload Monatsprodukte. Diese Annahme entstammt einem Vergleich der Preise aus [31]. Zusätzlich sollte angemerkt werden, dass Anfang Oktober 2018 die Strompreiszone Österreich-Deutschland aufgeteilt wurde (siehe [32]). Daher existieren die Day-Ahead-Preise für Österreich im Jahr 2018 nur im vierten Quartal.

Tabelle 4.1: Die erste Zeile in dieser Tabelle beschreibt für Österreich die durchschnittlichen Day-Ahead-Preise in den unterschiedlichen Quartalen in den Jahren 2018 und 2019. Durch die Multiplikation der ersten Zeile mit 1.1 erhalten wir die zweite Zeile. Diese Preise werden in weiterer Folge als Baseload und Peakload Preise verwendet.

€/MWh	Q_4^{2018}	Q_1^{2019}	Q_2^{2019}	Q_3^{2019}	Q_4^{2019}
Base	59.93	45.02	36.77	38.61	39.91
Peak	65.93	49.52	40.44	42.47	43.91

Laut Abbildung 3.1 vermarkten wir zum Zeitpunkt t_0 für den in drei Monaten beginnenden Monat die Energie. Dieser Monat fällt in ein gewisses Quartal. Bezüglich dieses Quartals kennen wir alle Day-Ahead-Preise aus dem vor dem vorherigem Quartal. Beispielsweise vermarkten wir für den Monat m_7^{2019} die Energie. Zum Zeitpunkt t_0 sind uns die Preise aus Q_1^{2019} bereits bekannt. Diese Preise werden in weiterer Folge als Preise μ_1 und μ_2 angenommen. Ökonomisch kann diese Annahme wie folgt verstanden werden: Am Terminmarkt besteht die Möglichkeit einen Kontrakt zu unterzeichnen, welcher für ein Quartal die Preise aus dem vor dem vorherigen Quartal verwendet. Dies bedeutet, dass die Vertragspartner:innen sehr naive Vorstellungen hinsichtlich der Preisentwicklung haben und daher einen gleichbleibenden Preis annehmen.

In diesem Kapitel werden die restlichen Parameter unterschiedlich gewählt und daher folgen nun zwei Beispiele. Vorweg kann gesagt werden, dass die Parameter sehr unterschiedlich festgelegt werden und somit zu unterschiedlichen Ergebnissen führen.

4.1 Erste Fallstudie

Die restlichen Parameter wählen wir wie in Tabelle 4.2 und 4.3 dargestellt. Erneuerbare Energien, wie Photovoltaik und Windenergie, haben Grenzkosten nahe Null, da Wind und Sonne im Vergleich zu fossilen Brennstoffen unentgeltlich verbraucht werden können. Jedoch sind Kosten für die Wartung mitzuberücksichtigen. In diesem Abschnitt orientieren wir uns an [9] und nehmen somit 0.7 €/MWh für C_w und C_s an. Der Parameter P_w^r wird für das Hoch- und Herunterfahren der Windkraftanlagen benötigt. Da stündliche Zeitschritte betrachtet werden, wird P_w^r gleich der Leistung der Windkraftanlage gesetzt.

Tabelle 4.2: Diese Tabelle legt die Parameter, welche die Windkraftanlagen sowie die Photovoltaikanlagen betreffen, fest.

Variable	C_w	C_s	P_w^r	n	m
Wert	0.7	0.7	2	15	10
Einheit	€/MWh	€/MWh	MW	Stück	Stück

In Tabelle 4.3 sind alle Parameter dargestellt, welche sich auf den elektrischen Stromspeicher beziehen. Dem Portfolio aus Windkraft und Photovoltaik wird ein Stromspeicher mit einer installierten Leistung von 1 MW hinzugefügt. Wir nehmen eine Batteriekapazität von 4 MWh an, jedoch wird der Stromspeicher nie ganz leer beziehungsweise ganz voll geladen.¹ Daher werden für E_b^{min} und E_b^{max} die Werte 0.25 beziehungsweise 3.75 angenommen. Zudem beträgt der Füllstand zu Beginn 2 MWh - der Stromspeicher ist somit halbvoll. Bezüglich Kosten für das Laden und Entladen (C_b) sowie den Energiespeicherkosten (C_e) des elektrischen Stromspeichers orientieren wir uns an [9] und setzen diese gleich 0.2 €/MWh sowie 0.13 €/MWh.² Eine Alternative Wahl dieser Parameter folgt in einem späteren Beispiel, da wir der Ansicht sind, dass die Zykluskosten ein Vielfaches sein sollten. Hinsichtlich des Entladungswirkungsgrads (η_d) sowie des Ladungswirkungsgrads (η_c) orientieren wir uns an [9] und nehmen jeweils 95 % an.

Tabelle 4.3: Diese Tabelle legt die Parameter, welche den elektrischen Stromspeicher betreffen, fest.

Variable	s_0	E_b^{min}	E_b^{max}	P_b^{max}	C_b	C_e	η_d	η_c
Wert	2	0.25	3.75	1	0.2	0.13	95	95
Einheit	MWh	MWh	MWh	MW	€/MWh	€/MWh	%	%

Wird, wie in Kapitel 3 beschrieben, über die Monate m_4^{2019} bis m_{12}^{2019} das zweiphasige Optimierungsproblem durchgeführt, ergibt sich für unterschiedliche Risikoparameter α Abbildung 4.1. Demnach steigt der Profit mit abnehmender Risikoaversion an. Hier sollte abermals angemerkt werden, dass mit $\alpha \rightarrow 1$ der $CVaR_\alpha(X)$ gegen den Erwartungswert der Zufallsvariable X strebt. Demzufolge ist eine Vermarktung nahe dem Erwartungswert profitabler als eine Vermarktung nahe dem *Worst Case* Fall. Des Weiteren ist ersichtlich, dass in den Sommermonaten (m_7^{2019} und m_8^{2019}) das Portfolio weniger Profit generiert als in den restlichen Monaten. Dies ist auf das niedrigere Windaufkommen im Sommer zurückzuführen. Diesem Effekt wirkt die Erzeugung durch Solarenergie entgegen, welche in den Sommermonaten stärker ausfällt als in den Wintermonaten. Letzterer Effekt kann jedoch ersteren nicht gänzlich ausgleichen. Dies ist darauf zurückzuführen, dass die installierte Leistung hinsichtlich Windkraft 30 MW (15 Stück multipliziert mit

¹An dieser Stelle kann angemerkt werden, dass die Kapazität über die Lebensdauer abnimmt. Dies wird in dieser Arbeit nicht berücksichtigt.

²Hierfür sollte angemerkt werden, dass ein Wechselkurs von einer DKK in 0.13 € angenommen wird.

4 Resultate

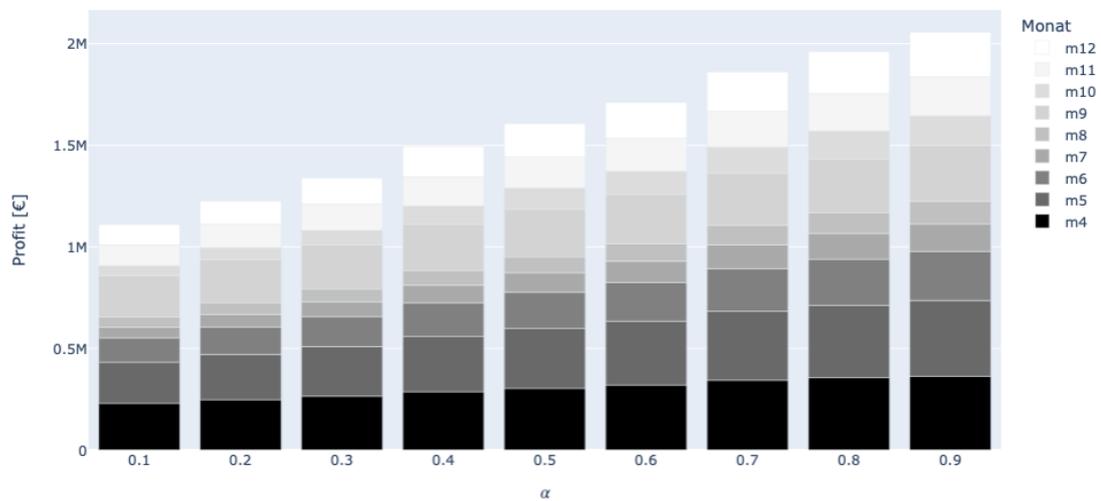


Abbildung 4.1: Diese Abbildung beschreibt den Profit in Abhängigkeit von α . Mit steigendem α nimmt die Risikoaversion ab und führt in weiterer Folge zu einem steigenden Profit. Als Preise für μ_1 und μ_2 werden die Werte aus Tabelle 4.1 verwendet. Die restlichen Parameter sind in den Tabellen 4.2 und 4.3 dargestellt.

2 MW Leistung) und die installierte Leistung bezüglich Photovoltaik 3 MW (10 Stück multipliziert mit 0.3 MW Leistung) beträgt.

In weiterer Folge betrachten wir die Variabilität des Profits in Abhängigkeit von α . Um die Variabilität zu messen, wird die Standardabweichung für verschiedene Werte von α berechnet. Für ein festes α und $i = 2019$ wird der Profit der jeweiligen Monate mit $\{P_\alpha(m_4^i), \dots, P_\alpha(m_{12}^i)\}$ notiert. Demzufolge berechnet sich die empirische Standardabweichung über die neun Monate folgendermaßen

$$\sigma = \sqrt{\frac{1}{9-1} \sum_{j=1}^9 \left(P_\alpha(m_{j+3}^i) - \overline{P_\alpha} \right)^2}, \quad (4.2)$$

wobei $\overline{P_\alpha}$ der Durchschnitt der Werte $\{P_\alpha(m_4^i), \dots, P_\alpha(m_{12}^i)\}$ definiert. In Tabelle 4.4 ist die empirische Standardabweichung dargestellt. Mit abnehmender Risikoaversion steigt die Standardabweichung an. Außerdem ist ersichtlich, dass selbst bei α gleich 0.1 eine hohe Standardabweichung vorliegt. Dies ist darauf zurückzuführen, dass das Windaufkommen sowie die Sonnenstunden starke Saisonalitäten aufweisen.

Darüber hinaus wird mit abnehmender Risikoaversion mehr Energie am Terminmarkt

Tabelle 4.4: Diese Tabelle stellt die Standardabweichung des Profits in Abhängigkeit von α dar.

α	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
σ (in T€)	71.90	73.99	76.51	79.78	83.43	86.64	90.97	93.34	94.70

sowie am Day-Ahead-Markt vermarktet. Laut Abbildung 4.1 geht die Vermarktung von mehr Energie mit steigendem Profit einher. Dadurch nimmt die Wahrscheinlichkeit, dass der tatsächlich auftretende Wind beziehungsweise die tatsächlich auftretende Sonneneinstrahlung nicht ausreicht die bereits vermarktete Energie zu erzeugen, zu. Dies hat zur Folge, dass die nicht produzierten Einheiten von der Regelenergie ausbalanciert werden, damit das Gleichgewicht im Netz wiederhergestellt ist. Die Kosten, welche durch das Glattstellen entstehen, sind in Abbildung 4.2 dargestellt. Im Vergleich mit Abbildung 4.1 ist in Abbildung 4.2 ersichtlich, dass die Kosten mit steigendem Parameter α stärker ansteigen als der Profit. Von $\alpha = 0.1$ auf $\alpha = 0.9$ kann gesagt werden, dass sich der Profit verdoppelt, während sich die Kosten für die Ausgleichsenergie verdreifachen.

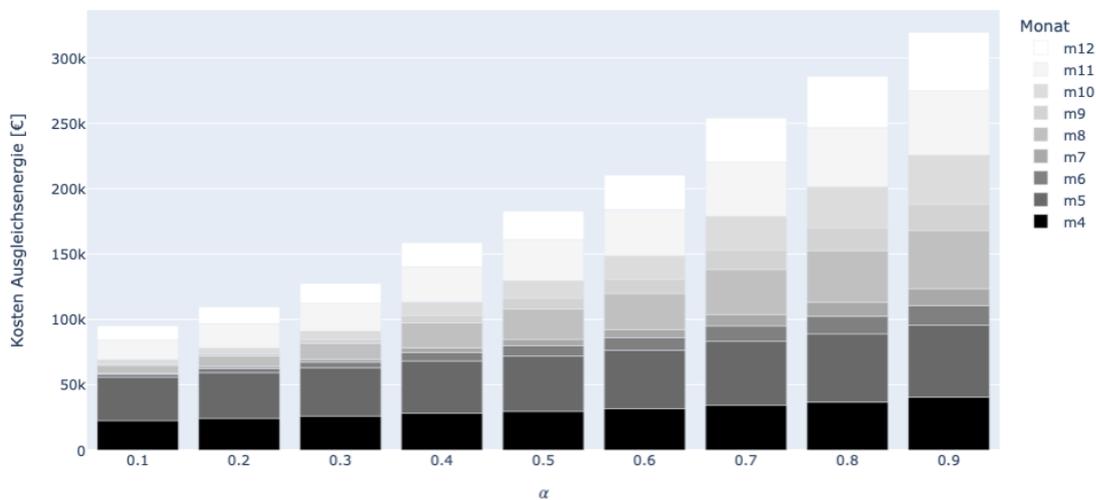


Abbildung 4.2: Diese Abbildung beschreibt die Kosten für die Ausgleichsenergie in Abhängigkeit von α . Mit steigendem α nimmt die Risikoaversion ab und führt in weiterer Folge zu steigenden Kosten. Als Preise für μ_1 und μ_2 werden die Werte aus Tabelle 4.1 verwendet. Die restlichen Parameter sind in den Tabellen 4.2 und 4.3 dargestellt.

4 Resultate

Alternativ zum Profit kann ein anderes Bewertungskriterium herangezogen werden, welches den Profit im Verhältnis zum Risiko betrachtet. Hierfür wird die in Kapitel 2.3 definierte *Sharpe-Ratio* verwendet. Als Benchmark-Portfolio wird der Risikoparameter α gleich 0.1 gewählt, da mit jenem Parameter der geringste Profit laut Abbildung 4.1 erreicht wird. In Tabelle 4.5 sind die Werte bezüglich *Sharpe-Ratio* dargestellt. Abermals ist der Parameter α gleich 0.9 besser als die restlichen Werte. Demzufolge ist selbst unter Berücksichtigung des Risikos eine sehr risikoaverse Vermarktungsstrategie zu vermeiden.

Tabelle 4.5: Diese Tabelle stellt die *Sharpe-Ratio* mit dem Benchmark-Portfolio α gleich 0.1 dar.

α	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
S	2.67	2.65	2.75	2.73	2.76	2.86	2.93	3.04

Falls sich die Ausgleichsenergiepreise um 60 % erhöhen und die restlichen Preise unverändert bleiben, ergibt sich Tabelle 4.6. Ein Anstieg der Ausgleichsenergiepreise kann beispielsweise darauf zurückzuführen sein, dass sich das Ausgleichsenergieregime mit der Zeit ändert. Des Weiteren hat der Ausbau von Windkraft und Photovoltaik zur Folge, dass vermehrt Abweichungen von der prognostizierten Erzeugung eintreten. Da steigende Abweichungen die Kosten für die Regelenergie in die Höhe treiben, könnten in Zukunft diese Abweichungen stärker bestraft werden, als dies gegenwärtig der Fall ist.

Tabelle 4.6: Diese Tabelle stellt die *Sharpe-Ratio* mit dem Benchmark-Portfolio α gleich 0.1 dar. Die Ausgleichsenergiepreise werden im Jahr 2019 um 60 % erhöht, wobei die restlichen Preise unverändert belassen werden.

α	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
S	2.50	2.41	2.39	2.34	2.33	2.37	2.39	2.45

Wird Tabelle 4.5 mit Tabelle 4.6 verglichen, ist je Tabelle ein unterschiedliches α hinsichtlich *Sharpe-Ratio* optimal. Laut Tabelle 4.6 präferieren wir α gleich 0.2 gegenüber den restlichen Werten. Durch die Erhöhung des Ausgleichsenergiepreises steigt der Profit dennoch mit steigendem α an. Jedoch wird das zusätzlich eingegangene Risiko nicht ausreichend honoriert und hat zur Folge, dass die *Sharpe-Ratio* bei α gleich 0.2 optimal ist.

4.2 Zweite Fallstudie

In der zweiten Fallstudie wird das analoge Portfolio zu Abschnitt 4.1 betrachtet. Demnach besteht dieses aus 15 Windkraftanlagen mit 2 MW Leistung und 10 Photovoltaikmodulen mit 0.3 MW Leistung. Jedoch werden die restlichen Parameter nicht aus [9]

übernommen, sondern aus verschiedenen Quellen zusammengetragen.

Die Werte für die Parameter C_w sowie C_s entnehmen wir [33]. Demnach betragen die Stromgestehungskosten für eine große neue Photovoltaikanlage 20 bis 60 €/MWh. Für eine Windkraftanlage am Festland betragen die Stromgestehungskosten 40 bis 80 €/MWh. An dieser Stelle sollte angemerkt werden, dass in diesem Abschnitt im Vergleich mit Abschnitt 4.1, nicht die Grenzkosten sondern die durchschnittlichen Stromgestehungskosten verwendet werden. Diese berücksichtigen die Lebensdauer, die Errichtungskosten, die Betriebskosten sowie die produzierten Energiemengen des Kraftwerks. Für eine detaillierte Berechnung siehe [34]. Den Parameter P_w^r wählen wir analog zu Abschnitt 4.1 gleich 2 MW.

Tabelle 4.7: Diese Tabelle legt die Parameter, welche die Windkraftanlagen sowie die Photovoltaikanlagen betreffen, fest.

Variable	C_w	C_s	P_w^r	n	m
Wert	40	20	2	15	10
Einheit	€/MWh	€/MWh	MW	Stück	Stück

In Tabelle 4.8 sind die Parameter dargestellt, die sich auf den Stromspeicher beziehen. In diesem Abschnitt wird wieder eine Batteriekapazität von 4 MWh und eine Leistung von 1 MW betrachtet. Die Parameter E_b^{min} und E_b^{max} sind 0.25 beziehungsweise 3.75, da der Stromspeicher nie ganz leer beziehungsweise voll geladen wird. Zusätzlich beträgt der Füllstand zu Beginn sowie am Ende jedes Tages 2 MWh. Bezüglich den Stromspeicherkosten orientieren wir uns an [35] sowie [36]. Demnach können die Kosten pro Zyklus wie folgt berechnet werden:

$$K_{Zyklus}[\text{€/MWh}] = \frac{90 \text{ €/kW} \cdot P + 475 \text{ €/kWh} \cdot E}{n_{Zyklus} \cdot E} \cdot 1000.$$

Hier steht P (in MW) für die Nennleistung des Stromspeichers und E für die Batteriekapazität (in MWh). Darüber hinaus definiert n_{Zyklus} die maximale Anzahl an Zyklen. Wie oben bereits erwähnt wird ein Stromspeicher mit der Leistung von 1 MW und der Batteriekapazität von 4 MWh gewählt. Laut [36] kann für eine Li-Ion Batterie n_{Zyklus} bis 15000 angenommen werden. Wir wählen die obere Schranke und erhalten demnach 33.17 €/MWh an Zykluskosten. Ein Zyklus entspricht demnach dem einmaligen Laden und Entladen unter der Nutzung der gesamten Kapazität des elektrischen Stromspeichers.

Da C_b den Kosten für das Laden und Entladen entspricht, müssen die Zykluskosten halbiert werden. Aus diesem Grund werden wir den Wert für C_b auf 17 €/MWh setzen. Zusätzlich sind wir der Ansicht, dass der Füllstand des Stromspeichers keine Kosten verursacht und demnach wird C_e auf Null gesetzt. Darüber hinaus beträgt laut [36] für

4 Resultate

Tabelle 4.8: Diese Tabelle legt die Parameter, die den Stromspeicher betreffen, fest.

Variable	s_0	E_b^{min}	E_b^{max}	P_b^{max}	C_b	C_e	η_d	η_c
Wert	2	0.25	3.75	1	17	0	95	95
Einheit	MWh	MWh	MWh	MW	€/MWh	€/MWh	%	%

eine Li-Ion Batterie der Wirkungsgrad 85 % bis 95 %. Wir nehmen daher in diesem Abschnitt, wie bereits zuvor, einen Entladungswirkungsgrad sowie Ladungswirkungsgrad von 95 % an.

In Abbildung 4.3 ist der Profit für das Portfolio dargestellt. Falls Abbildung 4.3 mit Abbildung 4.1 verglichen wird, ist zu erkennen, dass einzelne Monate auch negative Profite liefern. In jenem Fall ist eine hohe Risikoaversion zu bevorzugen, da dies zu geringeren Verlusten führt. Zudem ist in dieser Fallstudie auch bei positiven Profiten das optimale α nicht immer bei 0.9. Beispielsweise liefert der Monat m_4^i für $i = 2019$ die Profite laut Tabelle 4.9. Demnach steigt der Profit bis α gleich 0.8 an und nimmt anschließend wieder ab. Demnach liegt kein Randoptimum vor, sondern ein inneres Optimum. Zusammenfassend lässt sich sagen, dass nicht nur Randoptima (0.1 sowie 0.9) zu den maximalen Profiten führen, sondern auch innere Optima vorliegen können. A posteriori kann gesagt werden, dass eine Änderung von α in jedem Monat den maximalen Profit von Anfang April 2019 bis Ende Dezember 2019 geliefert hätte. Anhand dieser Beobachtung wird deutlich, dass die *robuste Optimierung* für die Allokation von Energie am Terminmarkt und Day-Ahead-Markt von Bedeutung ist.

Für den Monat m_4^{2019} wird für α gleich 0.5 an zehn Tagen in einzelnen Stunden der elektrische Stromspeicher entladen sowie geladen. Dies ist darauf zurückzuführen, dass der Parameter C_b mit 17 €/MWh sehr hoch angesetzt wurde. Durch diese Beobachtung kann geschlossen werden, dass das Preisniveau, welches im Jahr 2019 in Österreich am Day-Ahead-Markt vorgeherrscht hat, für einen Stromspeicher zu niedrig war. In anderen Worten kann gesagt werden, dass die täglichen Schwankungen der Preise zu gering waren, da ein elektrischer Stromspeicher in den günstigen Stunden lädt/kauft und in den teuren Stunden entlädt/verkauft. Laut Abbildung 2.1 sind die günstigen Stunden jene in der Nacht und die teuren Stunden jene unter Tags. Diese Tatsache kann in den Daten beziehungsweise in den Entscheidungsvariablen beobachtet werden.

Tabelle 4.9: Diese Tabelle stellt die Profite im Monat April im Jahr 2019 in Abhängigkeit von α dar.

α	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
$P_\alpha(m_4^{2019})$ (in T€)	74.60	76.17	81.42	84.19	87.98	92.69	97.66	97.90	95.41

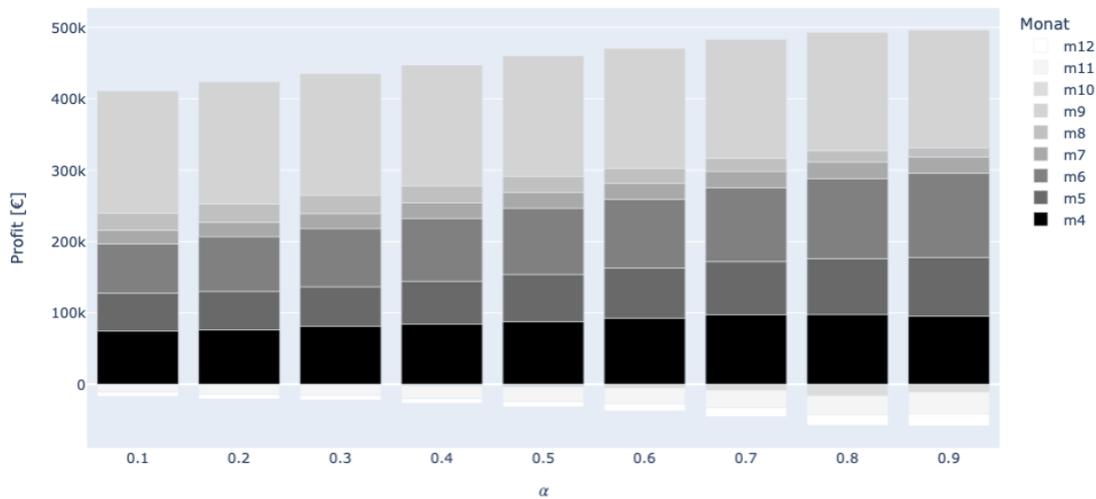


Abbildung 4.3: Diese Abbildung beschreibt den Profit in Abhängigkeit von α . Als Preise für μ_1 und μ_2 werden die Werte aus Tabelle 4.1 verwendet. Die restlichen Parameter sind in den Tabellen 4.7 und 4.8 dargestellt.

Analog zu Abschnitt 4.1 betrachten wir die empirische Standardabweichung des Profits in Abhängigkeit von α . Die Werte sind in Tabelle 4.10 dargestellt. Demnach steigt die empirische Standardabweichung, wie bereits zuvor, mit steigendem α an. Der Anstieg der empirischen Standardabweichung von α gleich 0.1 auf 0.9 ist nicht derart steil, verglichen mit der Fallstudie in Abschnitt 4.1.

Tabelle 4.10: Diese Tabelle stellt die empirische Standardabweichung des Profits in Abhängigkeit von α dar.

α	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
σ (in T€)	57.30	58.13	58.95	60.12	61.54	62.97	65.15	67.63	68.54

Wie bereits in Abschnitt 4.1 wird als anderes Bewertungskriterium die *Sharpe-Ratio* herangezogen. Abermals wird als Benchmark-Portfolio der Risikoparameter α gleich 0.1 gewählt. In Tabelle 4.11 sind die Ergebnisse dargestellt. Demnach liegt die größte *Sharpe-Ratio* bei α gleich 0.3. Zusätzlich ist die *Sharpe-Ratio* für alle α positiv. Im Vergleich mit Tabelle 4.5 ist die *Sharpe-Ratio* sehr gering. Dies ist auf die unterschiedlichen Annahmen hinsichtlich Kosten zurückzuführen.

Durch die Anpassung der Kostenparameter kann in diesem Abschnitt gezeigt werden, dass ein_e sehr risikofreudige_r Marktteilnehmer_in hinsichtlich der *Sharpe-Ratio* nicht

4 Resultate

Tabelle 4.11: Diese Tabelle stellt die *Sharpe-Ratio* mit dem Benchmark-Portfolio α gleich 0.1 dar.

α	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
S	0.36	0.43	0.37	0.36	0.33	0.28	0.22	0.21

optimal handelt. Außerdem hat diese Fallstudie gezeigt, dass in verlustreichen Monaten eine sehr risikoaverse Allokation zu geringeren Verlusten führt. Dagegen ist kritisch einzuwenden, dass die verlustreichen Monate a priori nicht identifiziert werden können. Zudem hat die Fallstudie gezeigt, dass hinsichtlich des Risikoparameters α nicht nur Randoptima vorliegen.

5 Fazit und Ausblick

Durch den Ausbau von Windkraft und Photovoltaik, die hohen Unsicherheiten hinsichtlich der Stromerzeugung unterliegen, wird Risikomanagement ein immer bedeutenderer Bestandteil der Vermarktung. Aktuelle Ereignisse um verschiedenste Energieanbieter zeigen, dass dieses Thema am Puls der Zeit ist. Damit geht die Frage einher, wie das optimale Verhältnis des Stromverkaufs zwischen Terminmarkt und Day-Ahead-Markt bestimmt werden kann. In anderen Worten kann das Ziel dieser Diplomarbeit wie folgt formuliert werden: Welcher Anteil soll am Terminmarkt verkauft werden, bevor die restliche Energie am Day-Ahead-Markt vermarktet wird? In dem neu entwickelten zweiphasigen Optimierungsproblem bestimmen wir mithilfe eines Risikoparameters dieses optimale Verhältnis und dessen Auswirkung auf den Profit sowie andere Bewertungskriterien, wie die *Sharpe-Ratio*.

Durch das zweiphasige Optimierungsproblem, das vollständig implementiert wurde¹, haben sich aus zwei Fallstudien folgende Erkenntnisse ergeben:

- Die Untersuchungsergebnisse zeigen, dass ein_e sehr risikofreudige_r Marktteilnehmer_in zwar hohe Profite lukrieren kann, jedoch hinsichtlich *Sharpe-Ratio* nicht immer optimal handelt. Demnach kann für die Allokation der Ressource Energie auf den unterschiedlichen Strommärkten auf die *robuste Optimierung* zurückgegriffen werden.
- Die zweite Fallstudie hat ergeben, dass in einzelnen Monaten Verluste eingefahren werden. In jenen Monaten ist eine sehr risikoaverse Veranlagung verlustschonender. Jedoch ist dagegen kritisch einzuwenden, dass diese Monate im Vorhinein nicht bekannt sind.
- Durch Abnahme der Risikoaversion stieg die Standardabweichung des Profits in beiden Fallstudien an. Falls die Standardabweichung als Risikomaß verwendet wird, führt dies zu folgender trivialen Beobachtung: Mit abnehmender Risikoaversion steigt das eingegangene Risiko. An dieser Stelle sollte kritisch angemerkt werden, dass die Standardabweichung positive und negative Abweichungen des Profits um den Erwartungswert im gleichen Ausmaß beurteilt. Alternativ würde eine andere Kennziffer zusätzlichen Aufschluss liefern, wie beispielsweise die *Downside Deviation*.
- Falls nur die Resultate aus der ersten Fallstudie betrachtet werden, könnte behauptet werden, dass hinsichtlich Profit eine hohe Risikoaversion von Nachteil ist.

¹Der Code ist unter https://gitlab.com/foto1996/mathe_thesis abrufbar.

5 Fazit und Ausblick

Jüngste Ereignisse zeigen uns jedoch, dass Preise am Strommarkt stark ansteigen können. In jenem Fall steigen die Ausgleichsenergiepreise ebenfalls an und verursachen für das gesamte Portfolio über den Betrachtungszeitraum höhere Kosten. Falls zudem sehr viel Energie am Terminmarkt günstig verkauft wurde und anschließend zu wenig produziert werden kann, muss teuer am Day-Ahead-Markt nachgekauft werden. Auch dies schmälert den Profit und kann dazu führen, dass die Beobachtung in der ersten Fallstudie über einen anderen Betrachtungszeitraum trotz selben Kostenparametern zu einem anderen Ergebnis führt.

- Während sich der Profit von der maximalen Risikoaversion hin zur minimalen Risikoaversion verdoppelte, wurde beobachtet, dass sich die Kosten für die Ausgleichsenergie verdreifachen.
- Durch den starken Anstieg der Strompreise im Jahr 2021 und 2022 wären aktuellere Daten für die Fallstudien von Interesse. Aufgrund der nicht vorhandenen Windkraft- und Photovoltaikdaten am Standort Neusiedl an der Zaya war diese Untersuchung innerhalb der vorliegenden Arbeit nicht möglich.
- Die zweite Fallstudie hat gezeigt, dass für einzelne Monate der Risikoparameter nicht am Rand liegen muss, um den höchsten Profit zu erzeugen. In jenen Fällen ist weder die höchste noch die niedrigste Risikoaversion optimal. Diese Beobachtungen bekräftigen die Verwendung der *robusten Optimierung*.
- Eine Erhöhung der Ausgleichsenergiepreise in der ersten Fallstudie verschiebt (*ceteris paribus*) den optimalen Risikoparameter hinsichtlich *Sharpe-Ratio* vom rechten Intervallrand (niedrige Risikoaversion) zum linken Intervallrand (hohe Risikoaversion).
- In dieser Arbeit kann keine endgültige Antwort hinsichtlich optimaler Wahl eines Risikoparameter gegeben werden, da diese von individuellen Präferenzen sowie technologischen Gegebenheiten abhängt.

In Anbetracht der Tatsache, dass das neu entwickelte zweiphasige Optimierungsproblem das optimale Verhältnis zwischen Terminmarkt und Day-Ahead-Markt bestimmen kann, ergeben sich weitere Fragestellungen. In dieser Arbeit wurden zwei Fallstudien über die Monate April bis Dezember 2019 betrachtet. An dieser Stelle empfiehlt sich eine weitere Untersuchung mit (möglicherweise) anderen Kostenparametern und aktuelleren Strompreisdaten. Außerdem wurde nur der Terminmarkt und der Day-Ahead-Markt betrachtet. Diese Märkte könnten beispielsweise erweitert werden um den Intraday-Markt, welcher zunehmend an Bedeutung gewinnt. Weiters wäre eine Erhöhung der Granularität von einer Stunde auf 15 Minuten vorteilhaft, um auch einen Handel der 15-Minuten Kontrakte am Intraday-Markt zu ermöglichen. Dies sind nur einige mögliche Verbesserungen, die in zukünftigen Arbeiten vorgenommen werden könnten.

Literaturverzeichnis

- [1] BMK, “Energie in Österreich. Zahlen, Daten, Fakten,” 2021. https://www.bmk.gv.at/dam/jcr:bbe5cd73-a161-46fc-8c80-2eb5fc500acb/Energie_in_0E2021_UA.pdf, letzter Zugriff: 14.09.2022.
- [2] Y. Sawle, S. Gupta, und A. Kumar Bohre, “PV-wind hybrid system: A review with case study,” *Cogent Engineering*, Jhg. 3, Nr. 1, S. 1–31, 2016.
- [3] APG und Vorarlberger Übertragungsnetz, “Netzentwicklungsplan 2021,” 2021. https://pb1-medien.apg.at/im/dl/pboxx-pixelboxx-10661/f,p/APG_Netzentwicklungsplan%202021.pdf?width=0, letzter Zugriff: 14.09.2022.
- [4] R. T. Rockafellar, “Coherent approaches to risk in optimization under uncertainty,” in *OR Tools and Applications: Glimpses of Future Technologies*, S. 38–61, Informs, 2007.
- [5] C. Filippi, G. Guastaroba, und M. Speranza, “Conditional value-at-risk beyond finance: A survey,” *International Transactions in Operational Research*, Jhg. 27, Nr. 3, S. 1277–1319, 2020.
- [6] A. A. Sanchez de la Nieta, J. Contreras, J. I. Munoz, und J. P. S. Catalao, “Optimal wind reversible hydro offering strategies for midterm planning,” *IEEE Transactions on Sustainable Energy*, Jhg. 6, Nr. 4, S. 1356–1366, 2015.
- [7] A. A. Sanchez de la Nieta, J. Contreras, und J. I. Munoz, “Optimal coordinated wind-hydro bidding strategies in day-ahead markets,” *IEEE Transactions on Power Systems*, Jhg. 28, Nr. 2, S. 798–809, 2013.
- [8] G. F. Frate, P. P. Carro, L. Ferrari, und U. Desideri, “Techno-economic sizing of a battery energy storage coupled to a wind farm: An Italian case study,” *Energy Procedia*, Jhg. 148, S. 447–454, 2018.
- [9] A. A. Thatte, L. Xie, D. E. Viassolo, und S. Singh, “Risk measure based robust bidding strategy for arbitrage using a wind farm and energy storage,” *IEEE Transactions on Smart Grid*, Jhg. 4, Nr. 4, S. 2191–2199, 2013.
- [10] A. A. Thatte, D. E. Viassolo, und L. Xie, “Robust bidding strategy for wind power plants and energy storage in electricity markets,” in *2012 IEEE Power and Energy Society General Meeting*, S. 1–7, IEEE, 2012.

- [11] G. He, Q. Chen, C. Kang, und Q. Xia, “Optimal offering strategy for concentrating solar power plants in joint energy, reserve and regulation markets,” *IEEE Transactions on Sustainable Energy*, Jhg. 7, Nr. 3, S. 1245–1254, 2016.
- [12] Y. An und B. Zeng, “Exploring the modeling capacity of two-stage robust optimization: Variants of robust unit commitment model,” *IEEE Transactions on Power Systems*, Jhg. 30, Nr. 1, S. 109–122, 2015.
- [13] A. Ben-Tal, L. E. Ghaoui, und A. Nemirovski, *Robust optimization*. Princeton Series in Applied Mathematics, Princeton: Princeton University Press, 2009.
- [14] A. Ben-Tal und A. Nemirovski, “Robust solutions of uncertain linear programs,” *Operations Research Letters*, Jhg. 25, Nr. 1, S. 1–13, 1999.
- [15] J. Kisiala, “Conditional value-at-risk: Theory and applications,” *arXiv*, S. 1–96, 2015.
- [16] D. Bertsimas und D. B. Brown, “Constructing uncertainty sets for robust linear optimization,” *Operations Research*, Jhg. 57, Nr. 6, S. 1483–1495, 2009.
- [17] W. F. Sharpe, “The sharpe ratio,” *The Journal of Portfolio Management*, Jhg. 21, Nr. 1, S. 49–58, 1994.
- [18] JetBrains, “PyCharm community edition: v2021.2.4,” 2021. <https://www.jetbrains.com/de-de/pycharm/>, letzter Zugriff: 14.09.2022.
- [19] J. Wiebe und R. Misener, “Romodel: Modeling robust optimization problems in pyomo,” *Optimization and Engineering*, S. 1–22, 2021.
- [20] W. E. Hart, J.-P. Watson, und D. L. Woodruff, “Pyomo: Modeling and solving mathematical programs in python,” *Mathematical Programming Computation*, Jhg. 3, Nr. 3, S. 219–260, 2011.
- [21] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, und E. Duchesnay, “Scikit-learn: Machine learning in python,” *Journal of Machine Learning Research*, Jhg. 12, S. 2825–2830, 2011.
- [22] P. Virtanen, R. Gommers, T. E. Oliphant, M. Haberland, T. Reddy, D. Cournapeau, E. Burovski, P. Peterson, W. Weckesser, J. Bright, S. J. van der Walt, M. Brett, J. Wilson, K. J. Millman, N. Mayorov, A. R. J. Nelson, E. Jones, R. Kern, E. Larson, C. J. Carey, Í. Polat, Y. Feng, E. W. Moore, J. VanderPlas, D. Laxalde, J. Perktold, R. Cimrman, I. Henriksen, E. A. Quintero, C. R. Harris, A. M. Archibald, A. H. Ribeiro, F. Pedregosa, P. van Mulbregt, und SciPy 1.0 Contributors, “SciPy 1.0: Fundamental algorithms for scientific computing in python,” *Nature Methods*, Jhg. 17, S. 261–272, 2020.

- [23] S. Pfenninger und I. Staffell, “Renewables.ninja,” 2022. <https://www.renewables.ninja>, letzter Zugriff: 14.09.2022.
- [24] I. Staffell und S. Pfenninger, “Using bias-corrected reanalysis to simulate current and future wind power output,” *Energy*, Jhg. 114, S. 1224–1239, 2016.
- [25] S. Pfenninger und I. Staffell, “Long-term patterns of european pv output using 30 years of validated hourly reanalysis and satellite data,” *Energy*, Jhg. 114, S. 1251–1265, 2016.
- [26] ENTSO-E, “ENTSO-E transparency platform,” 2022. <https://transparency.entsoe.eu>, letzter Zugriff: 14.09.2022.
- [27] Austrian Energy Agency, “Entwicklung des ÖSPI - Monatswerte,” 2022. https://www.energyagency.at/fileadmin/1_energyagency/presseaussendungen/strompreisindex/oespi_downloads/oespi_monatswerte.pdf, letzter Zugriff: 14.09.2022.
- [28] Wien Energie, “Windkraftleistung in Österreich,” 2021. <https://positionen.wienenergie.at/wp-content/uploads/2021/03/windkraft-leistung-statistik-oesterreich-2020-1.png>, letzter Zugriff: 14.09.2022.
- [29] Wien Energie, “Photovoltaik-Ausbau in Österreich,” 2021. <https://positionen.wienenergie.at/grafiken/photovoltaik-ausbau-in-oesterreich/>, letzter Zugriff: 14.09.2022.
- [30] EPEX SPOT, “Trading at EPEX SPOT,” 2022. https://www.epexspot.com/sites/default/files/download_center_files/21-03-09_Trading%20Brochure.pdf, letzter Zugriff: 14.09.2022.
- [31] EEX, “Futures,” 2022. <https://www.eex.com/de/marktdaten/strom/futures>, letzter Zugriff: 14.09.2022.
- [32] E-Control, “Trennung der deutsch-österreichischen Strompreiszone,” 2018. https://www.e-control.at/presseaussendungen-2018/-/asset_publisher/Da0W8QKmR58A/content/trennung-der-deutsch-osterreichischen-strompreiszone, letzter Zugriff: 14.09.2022.
- [33] Wien Energie, “Kosten der Stromerzeugung in der EU,” 2020. <https://positionen.wienenergie.at/grafiken/stromgestehungskosten-in-der-eu/#:~:text=In%20der%20EU%20liegen%20die,bis%20acht%20Cent%20je%20kWh.>, letzter Zugriff: 14.09.2022.
- [34] C. Kost, S. Shammugam, V. Fluri, D. Peper, A. D. Memar, und T. Schlegl, “Stromgestehungskosten erneuerbare Energien,” 2021. <https://www.ise.fraunhofer>.

Literaturverzeichnis

- de/content/dam/ise/de/documents/publications/studies/DE2021_ISE_Studie_Stromgestehungskosten_Erneuerbare_Energien.pdf, letzter Zugriff: 14.09.2022.
- [35] K. Poplavska und F. Leimgruber, “Analysis of the Swedish FCR-N market design. Effects of transition to marginal pricing and free bidding,” 2021. https://www.svk.se/contentassets/22a7164df5c2415d9c2a8f69c08498f8/svk_report_analysis_of_fcr-n_market_design.pdf, letzter Zugriff: 14.09.2022.
- [36] LEA, “FeldBatt. Feldbacher Batteriespeichersystem zur Steigerung des lokalen Eigenverbrauchs erneuerbarer Energie,” 2021. https://smartcities.at/wp-content/uploads/sites/3/BGR9_2021_FeldBatt.pdf, letzter Zugriff: 14.09.2022.