

TECHNISCHE UNIVERSITÄT MÜNCHEN



Fakultät für Architektur

Lehrstuhl für energieeffizientes und nachhaltiges Planen und Bauen

Robuste Optimierung in der Gebäudesimulation

Entwicklung einer Methode zur robusten Optimierung für die energetische Sanierung von Gebäuden unter unsicheren Randbedingungen

Johannes Maderspacher

Vollständiger Abdruck der von der Fakultät für Architektur der Technischen Universität München zur Erlangung des akademischen Grades eines

Doktor-Ingenieurs

genehmigten Dissertation.

Vorsitzender: Prof. Dr.-Ing. Frank Petzold
Prüfer der Dissertation: 1. Prof. Dr.-Ing. Werner Lang
2. Prof. Dipl.-Ing. Thomas Auer

Die Dissertation wurde am 02.05.2017 bei der Technischen Universität München eingereicht und durch die Fakultät für Architektur am 26.06.2017 angenommen.

FÜR CHRISTINE UND LUDWIG

„A bissel was geht immer“
Helmut Dietl

Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Lehrstuhl für energieeffizientes und nachhaltiges Planen und Bauen der Technischen Universität München. Dabei bildete das Projekt „Klimaschutz und grüne Infrastruktur in der Stadt“, ein vom Bayerischen Staatsministerium für Umwelt und Verbraucherschutz gefördertes Teilprojekt des „Zentrum Stadtnatur und Klimaanpassung“, den Ausgangspunkt dieser Dissertation.

Diese Arbeit wäre nicht möglich gewesen, ohne die Unterstützung einer Vielzahl von Personen. An erster Stelle möchte ich mich bei meinem Doktorvater, Herrn Prof. Werner Lang für die stete Unterstützung, die eingeräumten Freiräume und das jederzeit sehr angenehme Betreuungsverhältnis bedanken. Ein weiterer Dank gilt Herrn Prof. Thomas Auer für die Übernahme des Koreferats und die freundliche Begleitung des Promotionsvorhabens. Ein großer Dank gilt meinen Kolleginnen und Kollegen an der TU München für ein äußerst freundschaftliches und interessantes Arbeitsumfeld. Besonders bedanken möchte ich mich bei Teresa Zölch und Julia Brasche für die schöne gemeinsame Zeit und den interdisziplinären Austausch. Ein weiterer Dank geht an Herrn Prof. Philipp Geyer für die fachlichen Diskussionen in den unterschiedlichsten Stadien meiner Arbeit.

Diese Arbeit bildet den (vorläufigen) Abschluss eines fast neunjährigen Weges, welcher im Oktober 2008 mit einer Projekteinführung des „Solar Decathlon Europe 2010“ an der HS Rosenheim begann. Seither haben mich viele Personen bei meinem beruflichen Werdegang unterstützt und ich möchte mich hiermit bei Herrn Prof. Harald Krause, Prof. Mathias Wambsganz, Prof. Gerhard Zweifel, Christian Struck und vor allem bei Sven Moosberger bedanken.

Ganz besonders möchte ich mich bei meinen Eltern für die Möglichkeiten, die sie mir in meinem Leben eröffnet haben und für die fortwährende Unterstützung meinen Weg zu gehen, bedanken. Mein größter Dank gilt natürlich meiner Frau Christine, ohne dich wäre diese Arbeit und noch viel mehr im meinem Leben nicht möglich gewesen. Du und Ludwig seid mein größtes Glück.

Kurzfassung

Klimatische Veränderungen und Ressourcenknappheit zwingen zum bewussten und sparsamen Umgang mit Energie. Deshalb ist es notwendig den Energieverbrauch in allen Bereichen zu reduzieren. Einen wesentlichen Anteil am gesamten Energieverbrauch hat der Gebäudebestand. Die energetische Sanierung des Gebäudebestandes nimmt deshalb eine wichtige Rolle im Klimaschutz ein. Aktuelle Sanierungskonzepte orientieren sich in der Regel an Normen oder Richtlinien, wie z.B. der Energieeinsparverordnung. Dabei wird versucht auf Basis von Grenzwerten, wie z.B. für den Primärenergieverbrauch oder für den Wärmetransport durch Gebäudekomponenten die Treibhausgas-Emissionen zu reduzieren. Bei einer energetischen Sanierung gilt es jedoch mehrere Ziele, wie z.B. Energieeinsparungen, Kosten, Reduktion von Treibhausgas-Emissionen und Komfort zu beachten. Für die Entwicklung eines robusten Sanierungskonzeptes ist es zudem notwendig, unsichere Randbedingungen, wie z.B. die klimatischen Veränderungen oder die Energiepreisentwicklung, zu berücksichtigen. So können auch im Gebäudebetrieb die in der Planung ermittelten Kennwerte, wie z.B. für den Energieverbrauch, erzielt werden. Diese Anforderungen an ein „optimales“ Sanierungskonzept bringen aktuelle Planungsmethoden an ihre Grenzen.

In der vorliegenden Arbeit wird daher eine Methode zur robusten Optimierung für die energetische Sanierung von Gebäuden unter Berücksichtigung unsicherer Randbedingungen entwickelt. Durch diese Methode ist eine gleichzeitige Optimierung von ein oder mehreren Zielgrößen sowie eine Erhöhung ihrer Robustheit gegenüber unsicheren Randbedingungen realisierbar. Als Basis für die Analysen wird mit Hilfe der thermischen Gebäudesimulation ein detailliertes Modell eines Wohngebäudes erstellt. Die robuste Optimierung wird mit Hilfe eines Ersatzmodells, auf Basis des detaillierten Gebäudemodells, durchgeführt. Für die Auswahl eines geeigneten Ersatzmodells werden zwei Methoden aus dem Bereich des statistischen Lernens - Neuronale Netze und Support Vector Regression - miteinander verglichen. Die Unsicherheiten werden mit Hilfe einer Monte-Carlo-Simulation in die robuste Optimierung integriert. Für die Optimierung wird eine populationsbasierte Metaheuristik - „Particle Swarm Optimization (PSO)“ - verwendet. Eine erste Anwendung dieser Methode zeigt im Vergleich zu einer Sanierung nach Energieeinsparverordnung, dass für die Zielgrößen Treibhausgas-Emissionen und Kapitalwert eine deutliche Minimierung bzw. Maximierung möglich ist. Dies kann bei einer gleichzeitigen Erhöhung der Robustheit der genannten Zielgrößen gegenüber klimatischen Veränderungen und Energiepreisschwankungen erreicht werden. Die im Rahmen dieser Arbeit entwickelte Methode kann für weitere Gebäudetypen adaptiert und/oder durch unsichere Randbedingungen, wie z.B. das Nutzerverhalten, ergänzt werden. Eine Erweiterung für die Anwendung zur Planung von Neubauten oder in frühen Entwurfsphasen ist ebenfalls möglich.

Abstract

Climate change and limited resources compel a conscious and economical use of energy. Therefore it is necessary to save energy in all walks of life. The building stock comprises a significant part of the total energy consumption. Hence, the refurbishment of the building stock plays an important role in achieving climate change mitigation goals. Current strategies for a retrofit of a building is mostly based on rules and regulations. These regulations often use benchmarks for building components to achieve a "high quality" refurbishment. However, to accomplish an optimal retrofit of a building several objectives have to be taken into consideration, for example energy efficiency, cost-benefits, reduction of greenhouse gas emissions or the thermal comfort of the building. For a resilient refurbishment under uncertain boundary conditions, for example climate change or the development of energy prices, have to be considered during the planning process as well. These requirements for a sustainable refurbishment show the limits of current planning methods.

Therefore, this dissertation develops a method for a robust optimization for the retrofit of buildings under uncertain boundary conditions. This method allows for optimizing one or more objectives and increase their robustness under uncertain boundary conditions. Initially a detailed building model of a single family home is developed. The robust optimization is carried out with a so called meta model or surrogate model of the detailed building model. For the selection of a suitable surrogate model, two methods from the field of statistical learning - neural networks and support vector regression - are compared with one another. The uncertainties are integrated into the robust optimization using a Monte-Carlo-Simulation. A population based metaheuristic "Particle Swarm Optimization (PSO)" is used for the optimization. First results indicate that it is possible to minimize greenhouse gas emissions or maximize the cost-benefit in comparison to just retrofit according to current rules and regulations. It is also possible to increase the robustness of these objectives under uncertain boundary conditions like climate change or variations in energy prices, compared to a common retrofit strategy. The method presented here can be adapted for other types of buildings and/or by uncertain boundary conditions, e.g. the user behavior. An extension for an application in the planning process of new buildings or in early design phases is also possible.

Inhaltsverzeichnis

Vorwort	v
Kurzfassung	vii
Abstract	ix
I Problemstellung und Zielsetzung	1
1 Einführung	3
1.1 Klimawandel und das Potenzial des Gebäudebestandes	3
1.2 Planungsmethoden der energetischen Gebäudesanierung	4
1.3 Energetische Gebäudesanierung unter dem Einfluss des Klimawandels	6
1.4 Zusammenfassung	7
2 Zielsetzung und Vorgehen	9
2.1 Ziele der Arbeit und Forschungsfragen	9
2.2 Aufbau der Arbeit	10
2.3 Stand der Forschung	11
2.4 Zusammenfassung	15
II Einführung Fallbeispiel	17
3 Einführung	19
4 Auswahl der Klimadaten	21
4.1 Regionales Klimamodell REMO	21
4.2 Klimadaten der Region München	22
5 Auswahl des Beispielgebäudes	25
5.1 Definition des Gebäudetyps	25
5.2 Sanierungsmaßnahmen der Gebäudehülle	27
5.3 Sanierungsmaßnahmen der Anlagentechnik	28

6	Randbedingungen Kosten-Nutzen-Analyse	31
6.1	Kapitalwertmethode	31
6.2	Kosten und Preisentwicklungen	32
III	Modellauswahl	37
7	Einführung Modellentwicklung	39
7.1	Grundlagen der Modellentwicklung	39
7.2	Modelle für eine mathematische Optimierung in der Gebäudesimulation	43
7.3	Neuronale Netze und Support Vector Machines in der Gebäudesimulation	44
8	Methoden zur Modellentwicklung	49
8.1	Ablauf Modellentwicklung	49
8.2	Detailliertes Gebäudemodell	49
8.3	Monte-Carlo-Simulation und Sample-Techniken	51
8.4	Neuronale Netze	54
8.5	Support Vector Machines	61
8.6	Kreuzvalidierung und statistische Kenngrößen	66
9	Resultate und Diskussion	69
9.1	Versuchsaufbau	69
9.2	Vergleich von Sample-Techniken	70
9.3	Strukturoptimierung der Ersatzmodelle	74
9.4	Kreuzvalidierung der Ersatzmodelle	78
10	Zusammenfassung und Modellauswahl	85
IV	Robuste Optimierung	87
11	Einführung in die robuste Optimierung	89
11.1	Optimierung und Robustheit	89
11.2	Robustheit und Zuverlässigkeit	91
11.3	Robuste Optimierung in der Gebäudesimulation	92
11.4	Zusammenfassung	97
12	Methoden der robusten Optimierung	99
12.1	Unsicherheitsanalyse	99
12.2	Optimierung	105
12.3	Robuste Optimierung	117
13	Resultate und Diskussion	123
13.1	Modellentwicklung	123
13.2	Robuste Optimierung	128
14	Zusammenfassung	139

V	Robuste Optimierung in der Gebäudesimulation	141
15	Vorgehen im Rahmen der entwickelten Methode	143
15.1	Schritt 1: Erstellung der Datengrundlage	144
15.2	Schritt 2: Quantifizierung der unsicheren Randbedingungen	144
15.3	Schritt 3: Systemidentifikation mit Hilfe von Ersatzmodellen	145
15.4	Schritt 4: Robuste Optimierung auf Basis der Ersatzmodelle	146
15.5	Schritt 5: Visualisierung der Ergebnisse	147
16	Zusammenfassung	149
VI	Robuste Optimierung einer energetischen Gebäudesanierung	151
17	Randbedingungen	153
18	Resultate und Diskussion	155
18.1	Modellentwicklung	155
18.2	Robuste Optimierung der Treibhausgas-Emissionen	161
18.3	Robuste Optimierung des Kapitalwerts	165
18.4	Robuste Optimierung des Kapitalwerts und der Treibhausgas-Emissionen	171
19	Zusammenfassung	181
VII	Schlussfolgerung und Ausblick	183
20	Schlussfolgerung	185
21	Ausblick	187
	Abkürzungsverzeichnis	189
	Abbildungsverzeichnis	191
	Tabellenverzeichnis	195
	Literaturverzeichnis	197
	Glossar	211
A	Anhang	217
A.1	Fallbeispiel	217
A.2	Optimierung	225

Teil I

Problemstellung und Zielsetzung

1 | Einführung

1.1 Klimawandel und das Potenzial des Gebäudebestandes

Klimatische Veränderungen haben einen starken Einfluss auf die Natur und den Menschen. Der Klimawandel stellt daher eine der größten Herausforderungen für die heutige Gesellschaft dar (IPCC 2014, S. 8). Auswirkungen des Klimawandels sind unter anderem eine steigende Anzahl von Extremereignissen, wie z.B. Hitzewellen, Dürren, Überschwemmungen, Wirbelstürme oder Waldbrände. Diese Naturkatastrophen haben wiederum Auswirkungen auf unterschiedlichste Bereiche des menschlichen Lebens, wie z.B. Wasserversorgung, Lebensmittelproduktion, Infrastruktur, Morbidität oder Mortalität etc. (IPCC 2014, S. 21). Weitere Resultate aus den aktuellen Berichten des Intergovernmental Panel on Climate Change (IPCC) zeigen deutlich, dass die anthropogenen Treibhausgas-Emissionen einen starken Einfluss auf die Änderungen des Klimas aufweisen (IPCC 2014, S. 12). Somit ist der Mensch nicht nur Betroffener sondern auch Verursacher der klimatischen Veränderungen.

Die Klimapolitik der Industrieländer versucht auf zwei Wegen - Klimaschutz und Klimaanpassung - den Herausforderungen des Klimawandels zu begegnen. Im Bereich des Klimaschutzes gilt die Reduktion von Treibhausgas-Emissionen als oberstes Ziel. Dies soll vor allem durch den Ausbau erneuerbarer Energien und einer Steigerung der Energieeffizienz erreicht werden. Im Bereich der Energieeffizienz liegt der Schwerpunkt auf einer Verminderung des Energieverbrauches und der dadurch resultierenden Reduktion von Emissionen. Die Europäische Kommission weist in ihrem „Energy Efficiency Plan 2011“ darauf hin, dass in der Europäischen Union der Gebäudesektor das größte Energieeinsparpotenzial aufweist (Europäische Kommission 2011). Allein in Deutschland hat der Gebäudebereich einen Anteil von 40% am gesamten Endenergieverbrauch und ist für knapp 30% aller Treibhausgas-Emissionen verantwortlich (BMWi 2014).

Die energetische Sanierung des Gebäudebestandes spielt deshalb eine wesentliche Rolle bei der Umsetzung von Klimaschutzzielen. So weist die Europäische Union mit ihrer Richtlinie über die Gesamtenergieeffizienz von Gebäuden ihre Mitgliedsstaaten darauf hin, politische Instrumente zu entwickeln, welche „größere Renovierungen“ im Gebäudebestand vorantreiben (Richtlinie 2010/31/EU 2010). In Deutschland wurde im Zuge der Energiewende die „Energieeffizienzstrategie Gebäude“ entwickelt, welche einen nahezu klimaneutralen Gebäudebestand bis 2050 zum Ziel hat (BMWi 2015). Die energetische Gebäudesanierung ist dort, neben dem Einsatz erneuerbarer Energien, die zweite Säule des Konzeptes.

1.2 Planungsmethoden der energetischen Gebäudesanierung

Gebäudesimulation - Die Planung einer energetischen Gebäudesanierung ist eine komplexe Aufgabe. So können unterschiedliche Maßnahmen, wie z.B. Dämmung der Gebäudehülle, Austausch von Fenstern oder Erneuerung der Anlagentechnik in verschiedenen Ausführungen oder Kombinationen für die Erstellung eines passenden Sanierungskonzeptes ergriffen werden. Für eine Bewertung dieser Maßnahmen bestehen mehrere Kenngrößen, wie z.B. Energieeinsparung, Reduktion von Treibhausgas-Emissionen, Wirtschaftlichkeit oder thermischer Komfort im Innenraum.

Diese Anforderungen erfordern daher in der Regel eine abweichende Herangehensweise vom „traditionellen“ Vorgehen in der Planung. Die bisherigen Ansätze für die Planung von Gebäuden und Gebäudetechnik basieren meist auf statischen Berechnungsmethoden und Auslegungsszenarien, welche z.B. extreme Ereignisse mit geringer Wahrscheinlichkeit berücksichtigen. Dies ist für die Planung von energieeffizienten Gebäuden nicht mehr ausreichend (Macdonald 2002, S. 2). Eine Planung auf Basis von dynamischen Gebäudemodellen bietet hierbei Vorteile. In der Forschung ist die thermische Gebäudesimulation dabei ein entscheidendes Werkzeug. Mit Hilfe ihrer Berechnungsmethoden können z.B. Wechselwirkungen einzelner Wärmetransportvorgänge in der Außenwand abgebildet und analysiert werden (Clark 2001, S. ix). Dadurch ist es möglich, unterschiedliche Sanierungsmaßnahmen und deren Einfluss auf die Zielgrößen zu bewerten und zu vergleichen.

Optimierung - Neben den technischen Herausforderungen gibt es auch mehrere, oft konträre Ziele, welche mit einer Sanierung erreicht werden sollten. Diese Zielkonflikte entstehen durch die unterschiedlichen Erwartungen der beteiligten Stakeholder wie z.B. Eigentümer, Mieter, Planer oder Gesetzgeber. Bei einem Eigentümer einer selbstgenutzten Wohnimmobilie sind z.B. die Verbesserung des thermischen Komforts im Innenraum und die Wirtschaftlichkeit Ziele einer Sanierung (Stieß et al. 2010). Die Prioritäten der Gesetzgeber liegen dagegen meist bei einer Reduktion des Energieverbrauches und der Treibhausgas-Emissionen. Eine maximale Reduktion des Energieverbrauches ist aber nicht immer auch die wirtschaftlichste Lösung. Deshalb fordert z.B. die Europäische Kommission mit ihrer Verordnung (EU) Nr. 244/2012 (2012) eine Balance zwischen Kosteneffizienz und Mindestanforderungen an die Gesamtenergieeffizienz von Gebäuden und Gebäudekomponenten einzuhalten.

Diese Zielkonflikte sowie die hohe Komplexität in der Planung erfordern den Einsatz von Werkzeugen, die Lösungen unter Berücksichtigung aller Zielgrößen und Maßnahmenkombinationen ermöglichen. Durch den Einsatz von mathematischer Optimierungsverfahren, in Kombination mit Gebäudemodellen, ist es möglich nicht nur einzelne Zielgrößen zu optimieren, sondern auch optimale Lösungen¹ unter Berücksichtigung von mehreren Zielgrößen zu erarbeiten. In der Forschung wird die Anwendung solcher Verfahren im Bereich der energetischen Gebäudesanierung bereits erfolgreich angewandt, siehe z.B. Juan et al. (2009), Asadi et al. (2014), Penna et al. (2015) und Shao (2015).

¹ In der Gebäudesimulation werden häufig sogenannte stochastische Optimierungsverfahren verwendet, welche meist kein globales Optimum garantieren, jedoch Näherungslösungen liefern können.

Unsicherheitsanalyse (UA) - Ungeachtet einer modellbasierten Planung und der Anwendung von Optimierungsverfahren können Differenzen zwischen den berechneten und den gemessenen Kenngrößen einer Gebäudesanierung auftreten. Als Beispiel kann hier der teilweise deutliche Unterschied zwischen einem berechneten Heizenergiebedarf (Q_H) und einem tatsächlichen gemessenen Heizenergieverbrauch (Q_{Hver}) von Sanierungsprojekten genannt werden (Osterhage et al. 2015). Diese Unterschiede entstehen durch Unsicherheiten in den Kenngrößen. Die Unsicherheiten können verschiedene Ursachen aufweisen, wie z.B. die Abweichung von planerischen Annahmen in der baulichen Ausführung oder Abweichungen im Gebäudebetrieb. Als Beispiele können hier die Abweichung von bauphysikalischen Größen wie dem Wärmedurchgangskoeffizient eines Bauteils, das Wetter oder der Nutzereinfluss genannt werden (Hopfe und Hensen 2011). Durch den Einsatz von stochastischen Methoden, wie z.B. der Monte-Carlo-Simulation (MCS), können mit Hilfe der Gebäudemodelle Unsicherheiten ermittelt und dargestellt werden. Häufig basieren solche Untersuchungen auf der Variation von Eingangsgrößen im Gebäudemodell, wie z.B. dem Wärmedurchgangskoeffizient der Außenwand und der Analyse der Auswirkungen auf die ausgewählte Zielgröße, z.B. dem Energiebedarf. Im Bereich der Gebäudesimulation gibt es unterschiedlichste Ansätze und Methoden, eine Unsicherheitsanalyse durchzuführen und zu bewerten siehe z.B. Macdonald (2002), Wit (2003), Hopfe (2009), Struck (2012) und Burhenne (2013).

Robuste Optimierung - Aus Sicht einer optimalen Planung gilt es jedoch Ansätze zu entwickeln, welche die Unsicherheiten von Zielgrößen nicht nur darstellen, sondern auch reduzieren. Dafür werden neue Methoden in der Gebäudeplanung benötigt, welche nicht nur den Wert einer Zielgröße, sondern auch deren Unsicherheit optimieren. Eine Möglichkeit dieses Ziel zu erreichen ist die Kombination einer mathematischen Optimierung mit einer Unsicherheitsanalyse. Dieses Verfahren wird im allgemeinen „Robuste Optimierung“ genannt und ist in anderen Ingenieurwissenschaften bereits stark verbreitet, wie z.B. in der Tragwerksplanung (Frangopol und Maute 2003) oder in der Luft- und Raumfahrt (T. Zang et al. 2002).

Die energieeffiziente Gebäudeplanung steht jedoch mit der Anwendung einer robusten Optimierung erst am Beginn, und es sind weitere Untersuchungen notwendig, um die neuen Methoden zu erforschen und zu bewerten (Nguyen et al. 2014). Ein häufiger Grund, weshalb die robuste Optimierung in der Gebäudesimulation nicht eingesetzt wird, sind die hohen Rechenzeiten, welche durch die Kopplung einer mathematischen Optimierung und einer Unsicherheitsanalyse entstehen. Nguyen et al. (2014) leitet daraus einen Forschungsbedarf im Bereich von effizienteren Optimierungsalgorithmen und dem Einsatz von reduzierten Ersatzmodellen gegenüber detaillierten Gebäudemodellen ab, um die Rechenzeiten zu reduzieren und damit die Anwendung zu erleichtern.

Im Rahmen dieser Arbeit wird deshalb, neben der Entwicklung einer ganzheitlichen Methode zur robusten Optimierung der energetischen Gebäudesanierung, auch die Anwendung von Ersatzmodellen im Bereich der thermischen Gebäudesimulation analysiert. Der Schwerpunkt liegt dabei auf der Untersuchung von Algorithmen aus dem Bereich des maschinellen Lernens. Dabei werden „Neuronale Netze“ mit einer „Support Vector Regression“ als Ersatzmodell für ein detailliertes Gebäudemodell miteinander verglichen.

1.3 Energetische Gebäudesanierung unter dem Einfluss des Klimawandels

Der Klimawandel stellt eine nicht zu vernachlässigende Ursache von Unsicherheiten in den Kenngrößen einer energetischen Gebäudesanierung dar. Die klimatischen Veränderungen haben einen deutlichen Einfluss auf den zukünftigen Energieverbrauch eines Gebäudes. Zahlreiche Veröffentlichungen zeigen, dass in Mittel- und Nordeuropa der Heizenergiebedarf in Zukunft zurückgeht und der potenzielle Kühlenergiebedarf ansteigt. Insbesondere sagen Studien z.B. aus Stockholm und Zürich eine signifikante Reduktion des Heizenergiebedarfs in Wohngebäuden von ca. 30% bis 45% im Jahr 2100 voraus (Nik und Kalagasidis 2013; Frank 2005). Andere Studien erwarten eine drastische Zunahme des Kühlenergiebedarfs in Nichtwohngebäuden auf das zwei- bis zehnfache in Verbindung mit einem Rückgang des Heizenergiebedarfs um 35% bis 60% im Jahr 2100 (Frank 2005).

In Abbildung 1.1 wird die Problematik an einem konkreten Beispiel dargestellt. Die Grafik zeigt die Entwicklung der Kenngrößen Heizenergiebedarf, Kühlenergiebedarf und Treibhausgas-Emissionen eines Hochschulgebäudes unter Einfluss des Klimawandels. Der Standort des Gebäudes ist im Südwesten Englands auf dem Gelände der Universität von Plymouth. Das „baseline“ Szenario zeigt die Ergebnisse aus dem Zeitraum 1961 bis 1990. Die Szenarien „low“, „medium“ und „high“ repräsentieren drei unterschiedliche Klimaprojektionen für die Jahre 2040 bis 2069.

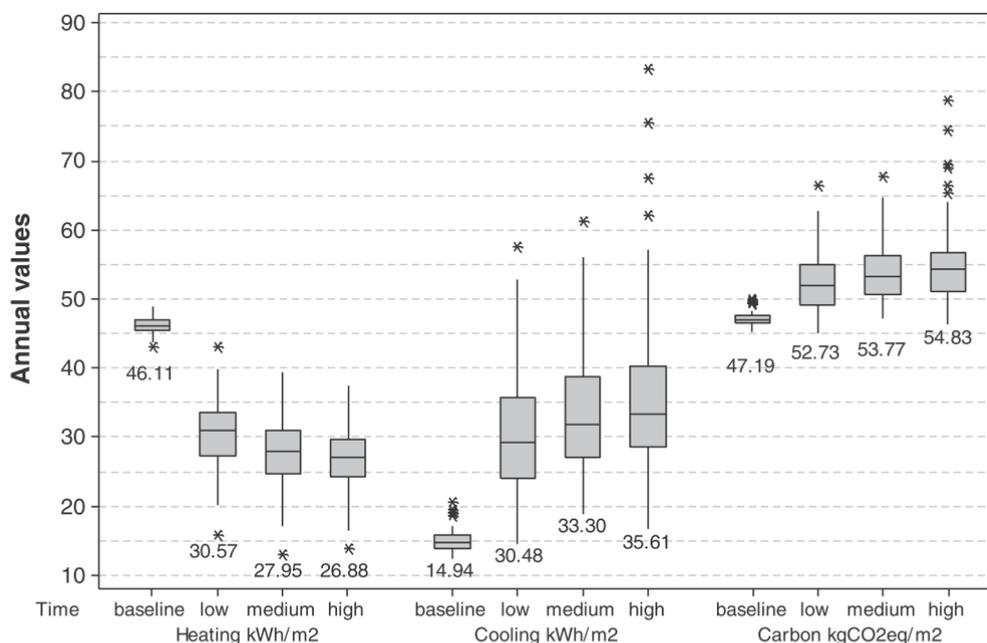


Abbildung 1.1: Entwicklung von Energiebedarf und Treibhausgas-Emissionen eines Hochschulgebäudes unter Einfluss des Klimawandels, eigene Darstellung nach Tian und Wilde (2011)

Die Resultate weisen in allen Szenarien der Klimaprojektionen („low“, „medium“, „high“) einen deutlichen Rückgang des Heizenergiebedarfes, sowie einen Anstieg des Kühlenergiebedarfes und der Treibhausgasemissionen auf. Des Weiteren ist eine Erhöhung der Unsicherheiten zu erkennen, da die Streuung der Boxplots in allen drei Kenngrößen, im Vergleich zum „baseline“ Szenario, stark ansteigt. Diese Ergebnisse zeigen, dass der Einfluss des Klimawandels bei der aktuellen Planung einer energetischen Gebäudesanierung nicht zu vernachlässigen ist. Die Länge von Sanierungszyklen, welche abhängig von den Gebäudekomponenten zwischen 30 und 55 Jahre betragen können (Hoier und Erhorn 2013), lässt die Wahrscheinlichkeit einer Veränderung von Kenngrößen durch den Klimawandel deutlich ansteigen. Die Änderungen des Energiebedarfes wirken sich ebenfalls auch auf andere Zielgrößen der Sanierung aus, wie z.B. auf die Wirtschaftlichkeit. So ist es möglich, dass z.B. eine Sanierung der Außenwand nach Passivhausstandard in Zukunft nicht mehr wirtschaftlich ist, da die klimatischen Veränderungen den Heizwärmebedarf auf „natürliche“ Weise reduzieren und so die Investition in eine verstärkte Dämmung hinfällig wird. Ein steigender Kühlbedarf kann auch zu höheren Treibhausgas-Emissionen führen, da die aktuellen Sanierungskonzepte diesen nicht berücksichtigen. Dadurch können Grenzwerte von politischen Klimaschutzziele entweder übertroffen, d.h. eine Reduktion des Heizwärmebedarfes, oder nicht eingehalten werden, d.h. ein Anstieg des zusätzlichen Kühlbedarfs.

Der Einfluss des Klimawandels wird in aktuellen Energie- oder Sanierungskonzepten aber meist nicht berücksichtigt. Nach Stand der Praxis orientiert sich ein Großteil der Sanierungen an aktuellen Richtlinien oder Normen wie z.B der Energieeinsparverordnung (EnEV) oder der DIN V 18599-1 (2011). Jedoch werden dort die Veränderungen des Klimas nicht mit einbezogen, da die Berechnungsverfahren lediglich der Nachweisführung dienen sollten.

1.4 Zusammenfassung

Aufgrund der dargestellten Problematik ist es notwendig, neue Methoden zu entwickeln, welche unsichere Randbedingungen wie den Klimawandel berücksichtigen und dadurch aussagekräftigere Planungskennwerte für die gesamte Nutzungsdauer eines Gebäudes unterstützen. Dabei gilt es bei einer energetischen Gebäudesanierung nicht nur den Wert einer Zielgröße zu optimieren, sondern auch ihre Unsicherheiten zu reduzieren. Deshalb wird im Rahmen dieser Arbeit eine ganzheitliche Methode zur robusten Optimierung für die energetische Sanierung von Gebäuden unter unsicheren Randbedingungen entwickelt. Dabei wird im Rahmen dieser Arbeit eine robuste Optimierung wie folgt definiert:

„Ziel einer robusten Optimierung ist es, ein vermeintliches Optimum der Zielfunktion zu finden, welches widerstandsfähig gegenüber unsicheren Randbedingungen ist.“

2 | Zielsetzung und Vorgehen

2.1 Ziele der Arbeit und Forschungsfragen

Ziel dieser Arbeit ist es, eine Methode zur robusten Optimierung für die energetische Sanierung von Gebäuden unter unsicheren Randbedingungen zu entwickeln. Diese Methode soll die Erstellung von Sanierungskonzepten unterstützen, welche eine höhere Belastbarkeit gegenüber herkömmlichen Planungsansätzen aufweisen. Dabei geht es nicht nur um die Optimierung von Zielgrößen einer Sanierung, sondern auch um eine Erhöhung ihrer Robustheit gegenüber unsicheren Randbedingungen.

Daraus lassen sich folgende Forschungsfragen ableiten:

- Welche Methoden der Modellbildung sind für eine robuste Optimierung in der Gebäudesimulation zweckmäßig/geeignet?
- Kann eine robuste Optimierung den Einfluss von unsicheren Randbedingungen bei einer energetischen Sanierung von Gebäuden reduzieren und gleichzeitig Kenngrößen, wie z.B. Energiebedarf oder Treibhausgas-Emissionen optimieren?
- Welche Vorteile bietet die robuste Optimierung gegenüber einer Sanierung nach aktuellem Stand der Technik?

Die Forschungshypothese lautet:

Durch die Anwendung einer robusten Optimierung können Sanierungskonzepte erstellt werden, welche nicht nur optimale Ergebnisse einzelner Zielgrößen wie z.B. Energieverbrauch oder Treibhausgas-Emissionen ermöglichen, sondern auch ihre Robustheit gegenüber unsicheren Randbedingungen erhöht.

2.2 Aufbau der Arbeit

Die vorliegende Arbeit gliedert sich in sieben Teile. Die Einführung des Themas sowie eine Darlegung der Zielsetzung und Problemstellung wird in Teil I erläutert. Dabei wird die Notwendigkeit von neuen Planungsmethoden zur robusten Optimierung für die energetische Sanierung von Gebäuden unter Berücksichtigung von unsicheren Randbedingungen beschrieben.

In Teil II wird das im Rahmen dieser Arbeit untersuchte Fallbeispiel vorgestellt. Dabei werden unsichere Randbedingungen wie die klimatischen Veränderungen und mögliche Energiepreisentwicklungen dargelegt. Des Weiteren wird ein typisches Gebäude für den deutschen und bayerischen Gebäudebestand ausgewählt, sowie Sanierungsmaßnahmen für die Gebäudehülle und Anlagentechnik definiert. Dieses Fallbeispiel wird in den Teilen III, IV und VI jeweils als Anwendungsfall herangezogen.

Teil III befasst sich mit der Modellentwicklung für die robuste Optimierung. In einem ersten Schritt wird ein detailliertes Gebäudemodell des Fallbeispiels mit Hilfe einer thermischen Gebäudesimulation erstellt. Dieses Modell bildet die Datengrundlage für die Entwicklung der Ersatzmodelle. Schwerpunkt von Teil III ist ein Vergleich von zwei Neuronalen Netzen und einer Support Vector Regression für die Anwendung als Ersatzmodell im Bereich der Gebäudesimulation.

Die robuste Optimierung wird in Teil IV eingeführt. Zu Beginn werden die einzelnen Bestandteile einer robusten Optimierung, Unsicherheitsanalyse und mathematische Optimierung vorgestellt. Anschließend wird der Ablauf einer robusten Optimierung beschrieben. Des Weiteren wird eine erste Anwendung der robusten Optimierung für die energetische Sanierung des Fallbeispiels unter Berücksichtigung klimatischer Unsicherheiten durchgeführt.

Teil V präsentiert die im Rahmen dieser Arbeit entwickelte Methode. Dabei werden die in Teil III und IV dargestellten methodischen Ansätze zu einem Vorgehen zusammengefasst und erläutert.

Eine Anwendung der entwickelten Methode wird in Teil VI durchgeführt. Für eine Bewertung der Methode werden zum Vergleich Ergebnisse aus einem herkömmlichen Planungsansatz herangezogen. Das in Teil II eingeführte Fallbeispiel wird mit Hilfe von drei Fragestellungen analysiert. In einem ersten Schritt werden die Treibhausgas-Emissionen unter Berücksichtigung klimatischer Veränderungen minimiert. Anschließend wird der Kapitalwert unter unsicheren Randbedingungen maximiert. In einem dritten Schritt werden Kapitalwert und Treibhausgas-Emissionen gemeinsam optimiert.

Teil VII fasst die wichtigsten Ergebnisse der Arbeit zusammen und formuliert in einem Ausblick mögliche weitere Forschungsfragen.

2.3 Stand der Forschung

Der folgende Abschnitt gibt einen Überblick zum Forschungsstand über die Auswirkungen des Klimawandels auf den Gebäudebereich mit dem Schwerpunkt Energiebedarf und thermischen Komfort. Vorrangig geht es hierbei um den Nachweis des tatsächlichen Bedarfs, der für eine Methode zur robusten Optimierung der energetischen Gebäudesanierung unter unsicheren Randbedingungen besteht. Dabei werden in einem ersten Schritt die potenziellen Auswirkungen des Klimawandels auf den Energiebedarf von Gebäuden dargestellt und damit die Notwendigkeit, diesen in der Planung energieeffizienter Gebäude zu berücksichtigen, betont. Anschließend werden die durch den Klimawandel verursachten planerischen Unsicherheiten mit dem Fokus auf Ermittlung und Darstellung in der Gebäudesimulation betrachtet. Hierbei werden unterschiedliche Methoden eingeführt und die zielführendste Methode für den weiteren Verlauf der Arbeit ausgewählt. Weiterhin werden unterschiedliche Ansätze für die Bewertung und Optimierung von Maßnahmen der energetischen Gebäudesanierung, unter dem Aspekt des Klimawandels, analysiert. Dabei zeigt sich, dass die mathematische Optimierung in diesem Bereich bisher kaum Anwendung findet und deshalb ein Einsatz dieser Methode zu untersuchen ist. Der Stand der Forschung zu den beiden methodischen Teilen der Arbeit, Modellbildung und robuste Optimierung, wird in den jeweiligen Kapiteln III und IV vorgestellt.

2.3.1 Einfluss des Klimawandels auf den Energiebedarf von Gebäuden

Es existieren auf mehreren Ebenen Analysen zum Einfluss des Klimawandels auf den Energiebedarf sowie den thermischen Komfort von Gebäuden. Die Ebenen können dabei nach Klimazonen, Ländern, Regionen, Städten oder Gebäuden unterschieden werden. Auf Gebäudeebene wird primär zwischen Nichtwohngebäuden und Wohngebäuden differenziert (Wilde und Coley 2012). Diese bilden deshalb den Schwerpunkt der Literaturrecherche. Es wurden auch Untersuchungen zu anderen Gebäudetypen, wie z.B. Bildungsstätten (Jenkins, Peacock, et al. 2009), Museen (Huijbregts et al. 2012) und Krankenhäusern (Lomas und Giridharan 2012; Short et al. 2012) durchgeführt, welche jedoch hier nicht weiter berücksichtigt werden.

Crawley (2008) führte als einer der Ersten eine Untersuchung über mehrere Klimazonen weltweit durch. Ein Schwerpunkt dieser Arbeit war die Reduzierung von globalen Klimaprognosen auf Klimadatensätze, welche für die thermische Gebäudesimulation verwendbar sind. Es wurden für 25 Standorte (20 Klimazonen) Wetterdaten mit unterschiedlichen Klimaszenarien bis ins Jahr 2100 erstellt. Anschließend wurde ein Bürogebäude in unterschiedlichen Energiestandards an den verschiedenen Standorten simuliert. Die Resultate zeigen, dass selbst an den Standorten in der gemäßigten Klimazone eine Reduktion des Heizenergiebedarfs von 25% und ein Anstieg des Kühlenergiebedarfs von 15% eintreten könnte. K. Wan et al. (2011) analysiert unterschiedliche Klimazonen in China. Auch hier wird der Einfluss des Klimawandels an einem Bürogebäude untersucht. Bei einem Vergleich des Referenzzeitraumes von 1971 bis 2000 mit dem Zeitraum 2071 bis 2100 ist im Norden Chinas (Harbin) eine Reduktion des Energiebedarfes um bis zu 6% erkennbar. Im Süden Chinas (Hong Kong) kann der Energiebedarf jedoch um bis zu 7,5% steigen.

Für Europa analysiert eine Studie aus Großbritannien den zukünftigen Gasbedarf für das Beheizen des Gebäudebestandes. Diese zeigt, dass bis ins Jahr 2050 alleine durch den Klimawandel eine Reduktion des Heizenergiebedarfes um 20% erfolgt (Collins et al. 2010). Ein weiteres Projekt aus Stockholm befasst sich mit dem zukünftigen Energiebedarf des Gebäudebestandes der Stadt (Nik und Kalagasidis 2013). Für die Analyse wurden 153 Bestandsgebäude statistisch ausgewählt. Der Untersuchungszeitraum liegt zwischen 1961 bis 2100. Als Resultat zeigt sich eine Reduktion des Heizenergiebedarfes von 30% im Jahr 2100 bezogen auf das Basisjahr 2011. Eine Analyse am Standort Zürich zeigt einen Rückgang des Heizenergiebedarfes im Wohnungsbau von 33% bis 44% in der Periode 2050 bis 2100 gegenüber dem Zeitraum 1961 bis 1990. Im Nichtwohnungsbau wird ein Anstieg des Kühlenergiebedarfes auf das Zwei- bis Zehnfache prognostiziert während der Heizenergiebedarf um 35% bis 60% sinkt (Frank 2005).

Diese exemplarischen Ergebnisse zeigen deutlich den Einfluss der klimatischen Veränderung auf den potenziellen Energiebedarf von Gebäuden. Bisherige Planungsansätze für die energetische Gebäudesanierung, z.B. eine Sanierung nach EnEV, berücksichtigen diese Veränderung jedoch nicht. Deshalb ist die Entwicklung von neuen Planungsmethoden zur Integration des Klimawandels wichtig. Dieser Aufgabe nimmt sich diese Arbeit an und entwickelt eine Methode, welche die klimatischen Änderungen bei einer energetischen Gebäudesanierung als unsichere Randbedingungen berücksichtigt.

2.3.2 Planerische Unsicherheiten des Klimawandels

Da es nahezu unmöglich ist, genaue Projektionen für das zukünftige Klima zu erstellen, ist bei der Analyse von Zukunftsprognosen, wie z.B. dem Klimawandel, eine Untersuchung und Darstellung von Unsicherheiten ein entscheidender Faktor. Wilde und Tian (2011) unterscheiden in den Analysen zum Klimawandel im Bereich der Gebäudesimulation zwischen einem deterministischen und einem probabilistischen Ansatz der Unsicherheitsbetrachtung.

Bei einer *deterministischen*¹ Darstellung der Unsicherheiten des Energiebedarfes wird meist das Ergebnis eines Klimaszenarios mit niedrigen THG-Emissionen mit dem Bedarf eines Szenarios mit vermeidlich höheren THG-Emissionen verglichen. Aus der Differenz der jeweiligen Energieverbräuche wird eine Unsicherheit abgeleitet. Für die Betrachtung der Unsicherheiten des Klimawandels mit Hilfe der deterministischen Szenarioanalyse existiert eine Bandbreite von Untersuchungen. Eine häufige Anwendung ist der Vergleich von Ergebnissen einer Gebäudesimulation mit unterschiedlichen Jahreswetterdatensätzen zum aktuellen und zukünftigen Klima. Gaterell und McEvoy (2005) stellen z.B. die Resultate eines Wetterdatensatzes des Jahres 2003 einem für das Jahr 2050 gegenüber. Für die Darstellung der Unsicherheiten werden für das Jahr 2050 zwei Emissionsszenarien in Betracht gezogen.

In Crawley (2008) werden vier Klimaszenarien (A1FI, A2, B2 und B1 (IPCC 2000)) analysiert. Diese Szenarien werden jeweils in drei Wetterdatensätze unterteilt. Diese stehen exemplarisch für einen niedrigen, mittleren oder hohen Energiebedarf. Die Unsicherheiten des Klimawandels

¹ Ein deterministisches System/Modell liefert unter gleichen Randbedingungen/Eingangsvariablen immer das gleiche Ergebnis, d.h. die Resultate sind reproduzierbar (Reddy 2011).

gehen aus den unterschiedlichen Ergebnissen der Wetterdatensätze hervor. Nik und Kalagaidis (2013) unterscheiden zwischen vier Ursachen für die Unsicherheit des Klimas. Diese werden differenziert in Unsicherheiten durch globale Klimamodelle, regionale Klimamodelle, Emissionsszenarien und Startbedingungen der Klimamodelle. Für die Untersuchung wird ein Zeitraum von 1960 bis 2100 in Perioden von 20 Jahren aufgeteilt. Für die zu analysierenden Klimamodelle und Emissionsszenarien wird für jede Periode ein repräsentativer Jahreswetterdatensatz ermittelt. Die Resultate aus den Simulationen der Wetterdatensätze bilden die Grundlage der Unsicherheitsbetrachtungen.

Bei einer *probabilistischen*² Darstellung der Unsicherheiten wird eine Wahrscheinlichkeitsverteilung der Zielgrößen, wie z.B. Energiebedarf, erstellt und analysiert. Im Gegensatz zur deterministischen Szenarioanalyse können so auch Unsicherheiten innerhalb eines Klimaszenarios, und nicht nur im Vergleich mit einem anderen Szenario, abgebildet werden. Als Maß für die Unsicherheit dienen die Kennwerte der Wahrscheinlichkeitsverteilung wie beispielsweise die Standardabweichung σ oder Varianz σ^2 bei einer Normalverteilung.

Kershaw et al. (2011) und Jenkins, Patidar, et al. (2011) verwenden zufällig erzeugte Wetterdatensätze aus einem „Wettergenerator“ der Universität Newcastle (Jones et al. 2009), um eine Wahrscheinlichkeitsverteilung der Unsicherheiten zu erzeugen. Dieser Generator erstellt, basierend auf den Klimaprojektionen für Großbritannien (UKCP09 2016), bis zu 100 Datensätze für eine Periode von 30 Jahren mit stündlich aufgelösten Wetterdaten. Dies entspricht einer Anzahl von 3.000 Jahreswetterdatensätzen. Bei den Eingabeparametern kann zwischen drei Klimaszenarien (A1B, A1FI und B2), der Periode und dem Standort in Großbritannien ausgewählt werden. Kershaw et al. (2011) verwendet 3.000 Datensätze für das Szenario A1B und die Periode von 2040 bis 2069 am Standort Plymouth um die Wahrscheinlichkeitsverteilungen verschiedener Zielgrößen eines Bürogebäudes in leichter und schwerer Bauweise zu untersuchen. Jenkins, Patidar, et al. (2011) analysieren das Überhitzungspotenzial von Wohnungen am Standort London für die Periode 2020 bis 2049. Zur Erstellung der Verteilung für die Zielgröße werden 100 Wetterdatensätze verwendet. Mit Hilfe von kumulativen Verteilungsfunktionen werden die Unsicherheiten abgebildet und unterschiedliche Maßnahmen gegen die Überhitzung miteinander verglichen.

Tian und Wilde (2011) erweitern die Unsicherheitsanalyse des Klimawandels mit Unsicherheiten von Gebäudeparametern (z.B. Wärmedurchgangskoeffizient der Außenwand) oder der Gebäudetechnik (z.B. Leistungszahl der Kühlanlage). Dabei werden vier energetische Standards eines Universitätsgebäudes für die Perioden 1961 bis 1990 und 2040 bis 2069 analysiert. Die Wetterdatensätze stammen aus dem „Wettergenerator“ der Universität Newcastle (Jones et al. 2009). Die Darstellung der Unsicherheiten geschieht über Boxplots für den jeweiligen energetischen Standard und Wetterperiode. In Wilde und Tian (2012) wird dieser Ansatz auf ein Bürogebäude, Einfamilienhaus und einen Supermarkt erweitert.

² Für eine probabilistische Analyse wird ein stochastisches System/Modell verwendet. Dieses liefert als Ergebnis eine Wahrscheinlichkeitsverteilung der Zielgrößen. Die Varianz der Resultate wird meist durch die Zufälligkeit der Randbedingungen/Eingangsparameter verursacht (Reddy 2011).

Wilde und Tian (2011) kommen zu dem Schluss, dass ein Großteil der bisherigen Unsicherheitsanalysen meist auf Basis einer deterministischen Szenarioanalyse durchgeführt werden. Die verwendeten Klimaprojektionen, für die durchgeführten Szenarioanalysen, weisen jedoch selbst eine hohe Unsicherheit auf. Dadurch kann selbst die Unsicherheit in einem Szenario eine beträchtliche Streuung der Ergebnisse verursachen. Deshalb empfehlen Wilde und Tian (2011) für Analysen mit Klimaprojektionen einen probabilistischen Ansatz zu verwenden. Dies wird in der aktuellen Forschung jedoch noch nicht konsequent umgesetzt. In der im Rahmen dieser Arbeit entwickelte Methode werden deshalb die Unsicherheiten klimatischer Veränderungen mit einem probabilistischen Ansatz berücksichtigt.

2.3.3 Bewertung und Optimierung von Energieeffizienzmaßnahmen unter Einfluss des Klimawandels

Eine Möglichkeit der Bewertung und Optimierung von Maßnahmen ist die Untersuchung von unterschiedlichen Varianten und Kombinationen einzelner Maßnahmen mit Hilfe einer Variantenstudie. Gaterell und McEvoy (2005) analysieren den Einfluss des Klimawandels auf die Energieeinsparungen durch Dämmung der Gebäudehülle sowie den Austausch von Fenstern am Beispiel einer Wohnung im Südosten Englands. Dabei werden zwei Varianten für die Dämmung von Gebäudekomponenten und den Fenstern analysiert. In Holmes und Hacker (2007) werden unterschiedliche Lüftungskonzepte wie z.B. natürliche Lüftung, maschinelle Lüftung oder eine Kombination wie die hybride Lüftung zur Reduktion eines potenziellen Kühlbedarfes durch Überhitzung untersucht. Die Konzepte werden in verschiedene Gebäudetypen, wie z.B. Schule oder Büro integriert. Dabei wird die Bewertung der Maßnahmen auf mehrere Einsatzmöglichkeiten erweitert, wie beispielsweise unterschiedliche Nutzungsarten der Gebäude.

In Hacker et al. (2008) werden vier unterschiedliche Varianten der thermischen Masse eines Einfamilienhauses analysiert. Ziel der Untersuchung ist es, den Einfluss der Maßnahme auf die Klimawandelauswirkungen zu bewerten bzw. zu optimieren. Als Zielgröße der Analyse wird die sommerliche Überhitzung verwendet. Der Untersuchungszeitraum liegt in den Jahren 2000 bis 2100.

Eine Weiterentwicklung der bisherigen Variantenstudien ist die Einführung neuer Kennwerte zur Bewertung von Energieeffizienzmaßnahmen wie z.B. der Robustheit gegenüber dem Klimawandel. Nik et al. (2015) untersuchen die Robustheit einer Gebäudehüllensanierung in fünf Klimaszenarien in einem Zeitraum von 1961 bis 2100. Für die Robustheit wird eine Kenngröße definiert, welche in einem relativen Vergleich der Ergebnisse eines „sanierten“ Gebäudes mit einem „unsanierten Gebäude“ ermittelt wird. Des Weiteren wird die Robustheit in unterschiedlichen Zeitabschnitten (Stunde, Tag, Monat und 20 Jahre) bewertet. In einer weiteren Arbeit von Nik et al. (2016) werden unterschiedliche Sanierungsmaßnahmen zusammengeführt, um eine robuste Kombination von Maßnahmen zu erhalten. Dies passiert jedoch weiterhin über eine Variantenstudie und ist daher auf wenige Kombinationen beschränkt.

Die exemplarische Recherche zeigt, dass zur Bewertung und Optimierung von Energieeffizienzmaßnahmen unter Einfluss des Klimawandels die Methode der Variantenstudie am häufigsten verwendet wird. Jedoch weisen die Ergebnisse dieses Vorgehens, im Vergleich zu den Resultaten einer mathematischen Optimierung, meist eine größere Differenz zu einer globalen optimalen Lösung (vgl. Kapitel 12.2) auf. Auch wird der Lösungsraum aller möglichen Maßnahmenkombinationen nur begrenzt untersucht, da dies bei einer Variantenstudie in der Regel aus zeitlichen bzw. Kostengründen nicht möglich ist. Der Einsatz einer mathematischen Optimierung mit ein oder mehreren Zielgrößen ist in den Analysen über die Auswirkungen des Klimawandels nicht weit verbreitet. Obwohl die generellen Vorteile dieser Methode bei einer energetischen Gebäudesanierung bereits in zahlreichen Veröffentlichungen dargestellt wurden (Juan et al. 2009; Asadi et al. 2014; Penna et al. 2015; Shao 2015).

Aufgrund der Vorteile einer mathematischen Optimierung wird im Rahmen dieser Arbeit untersucht ob und wie diese Methode auch für die Optimierung unter Einfluss des Klimawandels einzusetzen ist.

2.4 Zusammenfassung

Der Einfluss des Klimawandels auf den zukünftigen Energiebedarf von Gebäuden ist deutlich zu erkennen. Deshalb ist es notwendig, die klimatischen Veränderungen in Konzepte oder Maßnahmen für die energetische Gebäudesanierung zu integrieren. Ein weiterer wichtiger Punkt ist die Darstellung und Berücksichtigung der durch den Klimawandel verursachten Unsicherheiten. Dabei sollte eine probabilistische Unsicherheitsanalyse einer deterministischen vorgezogen werden, da Klimaprojektionen selbst eine hohe Unsicherheit aufweisen. Dadurch kann bei einer deterministischen Szenarioanalyse die Unsicherheit der Klimaprojektion in einem Szenario eine beträchtliche Streuung der Ergebnisse verursachen. Die Optimierung von Energieeffizienzmaßnahmen unter Einfluss des Klimawandels geschieht meist über eine Variantenstudie. Der Einsatz einer mathematischen Optimierung in diesem Bereich ist zu untersuchen.

Aufgrund der dargestellten Problematik ist es notwendig neue Methoden zu entwickeln, welche unsichere Randbedingungen, wie z.B. den Klimawandel, bei der Optimierung einer energetischen Gebäudesanierung berücksichtigen. Deshalb wird im Rahmen dieser Arbeit eine Methode zur robusten Optimierung der energetischen Gebäudesanierung unter Berücksichtigung unsicherer Randbedingungen entwickelt.

Teil II

Einführung Fallbeispiel

3 | Einführung

Diese Dissertation entstand in Verbindung mit dem Projekt „Klimaschutz und grüne Infrastruktur in der Stadt“. Dies ist ein Teilprojekt des „Zentrum Stadtnatur und Klimaanpassung“, welches durch das Bayerische Staatsministerium für Umwelt und Verbraucherschutz gefördert wurde. Ein Schwerpunkt des Projektes waren daher Analysen zum Einfluss des Klimawandels auf die Energieeffizienz des Gebäudebestandes von bayerischen Städten. Für die Nutzung möglicher Synergien wurden Randbedingungen aus dem Projekt für das Fallbeispiel verwendet, wie z.B. der Standort eines Gebäudes in der Landeshauptstadt München. Ebenso wurden konkrete Kennwerte für das Beispielgebäude aus einem der drei Modellquartiere des Projektes abgeleitet.

Im Rahmen dieser Arbeit wird eine Methode zur robusten Optimierung der energetischen Sanierung von Gebäuden unter unsicheren Randbedingungen entwickelt. Für eine Bewertung der Methode wird sie mit einem Vorgehen nach aktuellem Stand der Technik verglichen. Als aktuelles Vorgehen wird eine Sanierung der Gebäudehülle nach Kennwerten der Energieeinsparverordnung aus dem Jahr 2014 herangezogen. Für den Vergleich der beiden Methoden wird ein Fallbeispiel entwickelt.

Das folgende Kapitel beschäftigt sich mit der Definition eines Beispielgebäudes und dessen Spezifikation für die thermische Gebäudesimulation. Als unsichere Randbedingungen werden Klimadaten aus einem regionalem Klimamodell und Energiepreisentwicklung vorgestellt. Die ausgewählten Sanierungsmaßnahmen für die Gebäudehülle und die Anlagentechnik werden ebenfalls dargestellt.

4 | Auswahl der Klimadaten

Die möglichen Auswirkungen des Klimawandels werden auf Basis von sogenannten Klimaprojektionen dargestellt. Diese Klimaprojektionen sind das Resultat von Globalen Klimamodellen, welche mit Hilfe von definierten Szenarien über die zukünftige Treibhausgaskonzentration in der Atmosphäre die Entwicklung des Klimas simulieren. Das Intergovernmental Panel on Climate Change (IPCC) stellt regelmäßig überarbeitete Definitionen von globalen Klimaszenarien bereit, wie z.B. die SRES-Szenarien (A1FI, A1T, A1B, A2, B1, B2) (IPCC 2000) oder die RCP-Szenarien (RCP 2.6, RCP 4.5, RCP 6.0, RCP 8.5) (IPCC 2014).

Die Globalen Klimamodelle (General Circulation Models (GCMs)) setzen sich meist aus unterschiedlichen Klimamodell-Komponenten wie Atmosphäre, Ozean, Kryosphäre und Biosphäre zusammen. Sie bestehen aus einem 3-dimensionalen Gitter, welches den gesamten Erdball umspannt. Für jeden Gitterpunkt werden Ergebnisse der einzelnen Modellvariablen errechnet. Aktuelle Modelle verwenden eine räumliche Auflösung der Gitterpunkte zwischen 200 x 200 km oder 100 x 100 km (Foltyn et al. 2014). Für die Analyse von regionalen Einflüssen gibt es sogenannte Regionale Klimamodelle, welche eine Rastergröße von 50 x 50 km bis 10 x 10 km besitzen. In den Regionalen Klimamodellen werden meist die Ergebnisse von Globalen Klimamodellen als Rand- bzw. Startbedingungen verwendet (Jacob, Bülow, et al. 2012).

4.1 Regionales Klimamodell REMO

Für Deutschland existieren mehrere Regionale Klimamodelle wie z.B. STAR, WETTREG, CLM oder REMO (Jacob, Bülow, et al. 2012, S. 23). Diese Modelle können in statistische und in dynamische Modelle unterteilt werden. Statistische Modelle verwenden die Aufzeichnungen von vorhandenen Klimastationen und adaptieren diese, in Anlehnung an die Ergebnisse von Globalen Klimamodellen, für zukünftige Klimaprojektionen. Die Basis dieser Modelle sind Messdaten. Bei dynamischen Modellen werden physikalische Zusammenhänge der Atmosphäre, Landoberfläche und Ozeane beschrieben und simuliert, ähnlich wie bei den Globalen Klimamodellen (LfU 2016).

Als Grundlage für diese Arbeit wurde das dynamische REgional MOdell (REMO) ausgewählt (Jacob und Podzun 1997). Es bot zu Beginn der Dissertation, im Jahr 2014, als einziges Regionales Klimamodell im deutschsprachigen Raum einen kontinuierlichen zeitlichen Verlauf mit einer stundenbasierten Auflösung. Die stündliche Auflösung ist für die Verwendung in der thermischen Gebäudesimulation ein entscheidender Vorteil. Detaillierte Informationen zur Funktionsweise von REMO können aus Jacob und Podzun (1997), Jacob (2001), Jacob, Andrae, et al. (2001), Jacob, Barring, et al. (2007) und Jacob, Bülow, et al. (2012) entnommen werden.

Die verwendeten Klimaprojektionen stammen aus den Simulationen für das Umweltbundesamt (Jacob, Göttel, et al. 2008). Für diese Berechnungen wurden die drei SRES-Szenarien A2, A1B und B1 als Randbedingung angenommen. In dieser Studie wurde ebenfalls ein Kontrolllauf zur Validierung des Modells durchgeführt. Tabelle 4.1 zeigt die Eckdaten des Regionalen Klimamodells für die Klimaprojektionen im Auftrag des Umweltbundesamtes.

Tabelle 4.1: Eckdaten des Regionalen Klimamodells REMO für die Klimaprojektionen im Auftrag des Umweltbundesamtes (Jacob, Göttel, et al. 2008)

Globale Modelle	ECHAM5, MPI-OM
Modelltyp	Dynamisch
Auflösung	10 x 10 km, ca. 732 Gitterpunkte
Gebiet	Deutschland, Österreich und Schweiz
Zeiträume/Szenarien	1951-2000 (C20); 2001-2100 (A2, A1B, B1)
Zeitliche Auflösung	Stündlich

4.2 Klimadaten der Region München

Durch die Verbindung mit dem genannten Projekt „Klimaschutz und grüne Infrastruktur in der Stadt“ wurde ein Standort für das Beispielgebäude in der Landeshauptstadt München festgelegt. Abbildung 4.1 zeigt die ausgewählten Gitterpunkte aus dem Regionalen Klimamodell für die Region München. Für eine optimale Darstellung der Klimaprojektionen wird für alle verwendeten Variablen des Klimamodells ein Mittelwert über die zwölf Gitterpunkte gebildet. Der rote Punkt markiert den Standort des Beispielgebäudes im Modellquartier Neuaubing-Westkreuz.

Abbildung 4.2a stellt die Änderungen der Jahresmitteltemperaturen für die IPCC-Szenarien A2, A1B und B1 in der Region München dar. Die Abweichungen der Jahresmitteltemperaturen werden auf Basis der Periode von 1961 bis 1990 errechnet. Bis ins Jahr 2100 ist ein Anstieg der mittleren Jahrestemperatur, abhängig vom Klimaszenario, von bis zu 6 °C zu erwarten. Für die weiteren Untersuchungen wird das SRES-Szenario A1B ausgewählt. Dieses Szenario steht für eine ausbalancierte Energieversorgung aus fossilen und erneuerbaren Energieträgern und kann als „mittleres“ SRES-Szenario angesehen werden (IPCC 2000).

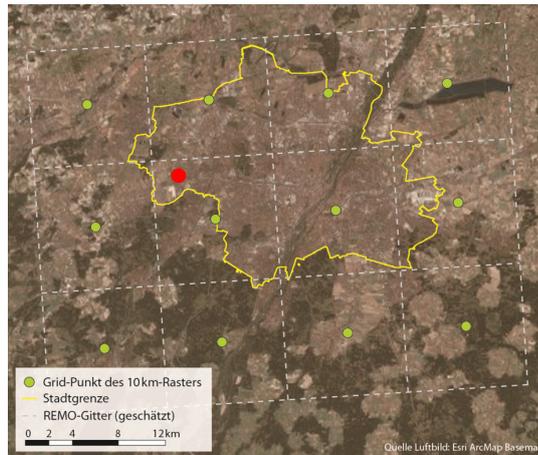
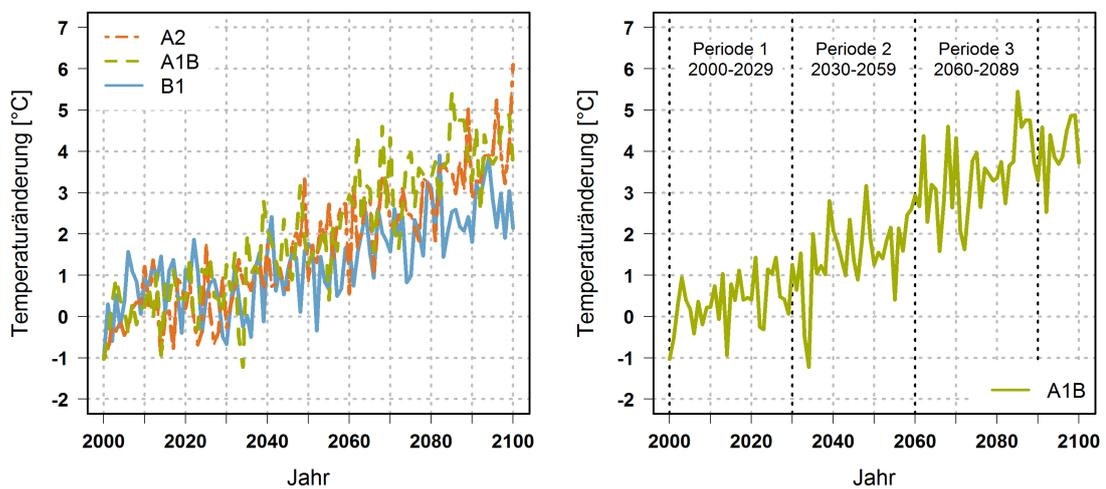


Abbildung 4.1: Gitterpunkte des Regionalen Klimamodells für die Region München

Eine Berücksichtigung von unterschiedlichen Entwicklungen des Klimas wird über eine Einteilung der Klimaprojektion A1B in drei Perioden umgesetzt. Abbildung 4.2b zeigt die Einteilung in drei Perioden von jeweils 30 Jahren. Der Zeitraum von 30 Jahren entspricht einer Klimaperiode und ermöglicht so die Analyse von klimatischen Veränderungen. Im weiteren Verlauf der Arbeit stehen die drei Perioden exemplarisch für unterschiedliche Ausprägungen des Klimawandels. Dabei wird Periode 1 repräsentativ für einen „geringen“, Periode 2 für einen „mittleren“ und Periode 3 für einen „starken“ Anstieg der Klimaerwärmung verwendet.



(a) Änderungen der Jahresmitteltemperaturen in den Klimaszenarien A2, A1B und B1

(b) Änderungen der Jahresmitteltemperaturen im Klimaszenario A1B

Abbildung 4.2: Änderungen der Jahresmitteltemperaturen in Abhängigkeit des Klimaszenarios der Region München. Als Vergleichsbasis wird die durchschnittliche Jahresmitteltemperatur der Periode 1961 bis 1990 herangezogen.

5 | Auswahl des Beispielgebäudes

Wie in Teil I beschrieben, ist die energetische Sanierung des Gebäudebestandes eine wichtige Säule im Bereich des Klimaschutzes. Daher ist es wichtig, für die Aussagekraft dieser Studie einen repräsentativen Gebäudetyp auszuwählen. In Deutschland hat der Gebäudebereich ca. 40% Anteil am gesamten Endenergieverbrauch. Davon verbrauchen die Wohngebäude mehr als die Hälfte, gefolgt vom Sektor Gewerbe, Handel, Dienstleistung (GHD) (BMW 2014). Aufgrund des hohen Anteils am Endenergieverbrauch wird die Auswahl des Beispielgebäudes auf den Wohngebäudebestand begrenzt.

5.1 Definition des Gebäudetyps

Der deutsche Wohngebäudebestand kann in die Gebäudetypen Einfamilienhaus (EFH), Reihenhäuser (RH), Mehrfamilienhaus (MFH) und Großes Mehrfamilienhaus (GMH) eingeteilt werden (Diefenbach 2013). Dabei stellen die Einfamilienhäuser ca. 41% der gesamten Wohnfläche dar und sind der am häufigsten vorkommende Gebäudetyp. Die Baualtersklassen von 1958 bis 1968 und 1969 bis 1978 repräsentieren ca. 30% des Einfamilienhausbestandes und bilden dadurch die größte Gruppe im Zeitraum von 1860 bis 2009 (Diefenbach 2013).

Im bayerischen Wohngebäudebestand ist ebenfalls das Einfamilienhaus, in Bezug auf die Wohnfläche, der weit verbreitetste Gebäudetyp. Auch dort dominieren die Baualtersklassen von 1958 bis 1968 und 1969 bis 1978 mit ca. 31% den Einfamilienhausbestand (BayLfStad 2011). Der Gebäudetyp „Einfamilienhaus“ repräsentiert einen großen Teil des deutschen sowie auch des bayerischen Wohngebäudebestandes und wird deshalb als Beispielgebäude für die weiteren Analysen verwendet.

Für die Ermittlung von konkreten Kennwerten, wie z.B. der Geometrie, wird eine statistische Auswertung aller Einfamilienhäuser des Modellquartiers Neuaußing-Westkreuz aus dem Projekt „Klimaschutz und grüne Infrastruktur in der Stadt“ durchgeführt. Anhand dieser Auswertung wird ein konkretes Gebäude für das Fallbeispiel definiert. Detaillierte Ergebnisse der statistischen Analyse sind im Anhang A.1.1 aufgeführt. In Abbildung 5.1 sind die Ansichten des erstellten Einfamilienhauses dargestellt.

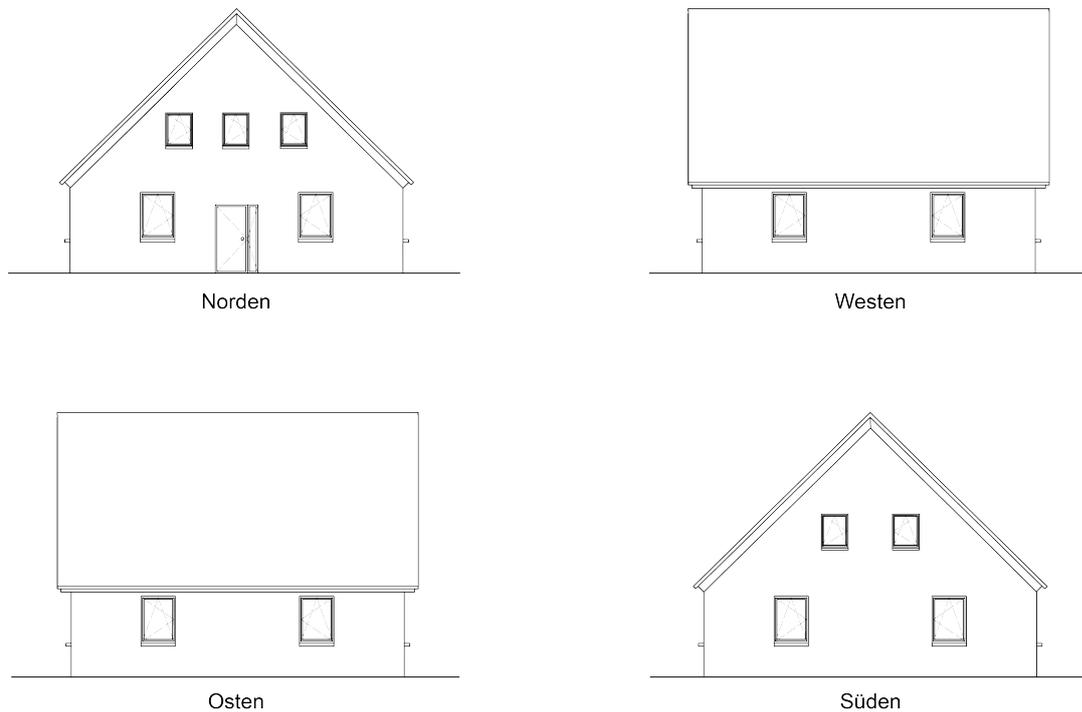


Abbildung 5.1: Ansichten des Beispielgebäudes

5.1.1 Spezifikation der Gebäudeparameter

Die Grundlage der weiteren Analysen bilden Simulationsmodelle des definierten Beispielgebäudes. Die Erstellung eines Modells für die thermische Gebäudesimulation benötigt neben der Geometrie noch weitere Kennwerte und Spezifikationen. So werden z.B. auf Basis der Baualtersklasse mit Hilfe von Hinz (2006) und Loga et al. (2011) die Aufbauten und bauphysikalischen Eigenschaften von Gebäudekomponenten definiert. Die konkreten Aufbauten für das Gebäudemodell können aus Tabelle A.1 im Anhang entnommen werden. Die Tabelle 5.1 zeigt die daraus resultierenden Wärmedurchgangskoeffizienten für die Gebäudehülle des ermittelten Bestandsgebäudes.

Tabelle 5.1: Wärmedurchgangskoeffizienten Gebäudehülle

Parameter	Wert	Einheit
U-Wert Außenwand	1,47	[W/m ² K]
U-Wert Dach	1,10	[W/m ² K]
U-Wert Boden	1,10	[W/m ² K]
U-Wert Fenster	3,50	[W/m ² K]
Ü-Wert Gebäudehülle	1,18	[W/m ² K]

Als Luftwechselrate wird im Simulationsmodell ein Wert für nicht luftdichtheitsgeprüfte Gebäude von $0,7 \text{ [h}^{-1}\text{]}$ gemäß (DIN V 4108-6 2003) angenommen. Des Weiteren wird eine Fensterlüftung im Zeitraum von Mitte Mai bis Mitte September zwischen 7:00 bis 7:30 Uhr und 21:00 bis 23:00 Uhr definiert, um das zusätzliche Lüften eines Nutzers abzubilden. Als interne Lasten werden $4,16 \text{ W/m}^2$ festgelegt (DIN 4108-2 2013, S. 29). Die Verschattung der Fenster wird über einen außenliegenden Sonnenschutz gewährleistet. Der Sonnenschutz wird als Raffstoren definiert und weist einen Fc-Wert von 0,25 auf. Die Regelung erfolgt nach Kennwerten der DIN 4108-2 (2013, S. 31). In Tabelle 5.2 werden weitere Gebäudeparameter zusammengefasst.

Tabelle 5.2: Ausgewählte Gebäudeparameter

Parameter	Wert	Einheit
Baualterklasse	1958 - 1968	[-]
Wohnfläche	138,20	$[\text{m}^2]$
A/V (Gebäudehülle zu Volumen)	0,84	$[\text{m}^2/\text{m}^3]$
V_e (Beheiztes Volumen)	388,96	$[\text{m}^3]$
A_{Fe} (Fensterfläche)	15,20	$[\text{m}^2]$

5.2 Sanierungsmaßnahmen der Gebäudehülle

Für einen Vergleich der im Rahmen dieser Arbeit entwickelten Methode mit Ergebnissen aus aktuellen Sanierungskonzepten werden die Sanierungsmaßnahmen für die Gebäudehülle von bestehenden Konzepten aus Loga et al. (2011) abgeleitet. Tabelle 5.3 zeigt die einzelnen Maßnahmen und ihren Wertebereich für die Optimierung im weiteren Verlauf der Arbeit. Die Dämmung der opaken Bauteile des Gebäudes und der Austausch der Fenster repräsentieren die Maßnahmen nach aktuellem Stand der Technik. Der Sonnenschutz wird als zusätzliche Sanierungsmaßnahme definiert, um eine weitere Regulierung der sommerlichen Überhitzung im Modell zu ermöglichen. Dies ist aufgrund der klimatischen Veränderungen notwendig (siehe Teil VI).

Tabelle 5.3: Sanierungsmaßnahmen der Gebäudehülle

Maßnahme	Kennwert	Anwendungsbereich	Einheit
Dämmung Außenwand	U-Wert	U(0,10;1,40)	$[\text{W}/\text{m}^2\text{K}]$
Dämmung Dach	U-Wert	U(0,10;1,10)	$[\text{W}/\text{m}^2\text{K}]$
Dämmung Boden	U-Wert	U(0,10;1,10)	$[\text{W}/\text{m}^2\text{K}]$
Austausch Fenster	U-Wert	U(0,60;3,50)	$[\text{W}/\text{m}^2\text{K}]$
	g-Wert	U(0,30;0,75)	[-]
Installation Sonnenschutz	Fc-Wert	U(0,25;1,00)	[-]

Für einen Vergleich der im Rahmen dieser Arbeit entwickelten Methode wird ein weiteres Gebäudemodell mit Kennwerten der EnEV (2014) erstellt. Tabelle 5.4 fasst die angepassten Kennwerte, im Vergleich zum Modell des Bestandsgebäudes, für das Modell „EnEV“ zusammen. Eine Sanierung nach EnEV 2014 wird im weiteren Verlauf der Arbeit als „herkömmlicher Planungsansatz“ bzw. als „Planung nach Stand der Technik“ herangezogen.

Tabelle 5.4: Kennwerte des Modells „EnEV“

Parameter	Wert	Einheit
U-Wert Außenwand	0,24	[W/m ² K]
U-Wert Dach	0,24	[W/m ² K]
U-Wert Boden	0,30	[W/m ² K]
U-Wert Fenster	1,30	[W/m ² K]
g-Wert Verglasung	0,60	[-]
Luftwechselrate	0,60	[h ⁻¹]

5.3 Sanierungsmaßnahmen der Anlagentechnik

Für die Analysen einer energetischen Sanierung der Anlagentechnik werden unterschiedliche Gebäudemodelle entwickelt. Dabei wird in dieser Arbeit ein Modell des definierten Gebäudes mit einer Heizung und ein weiteres Modell mit einer Heizung und Kühlung erstellt. Die Implementierung einer Kühlung dient zur Quantifizierung eines potenziellen Kühlbedarfes, verursacht durch die klimatischen Veränderungen. Für die Ermittlung des Energiebedarfes im Simulationsmodell wird eine ideale Heizung und Kühlung verwendet. Der Komfortbereich für das Innenraumklima wird nach DIN EN 15251 (2007) Kategorie II festgelegt. Dabei ist der Mindestwert für die Heizperiode 20,0 °C und der Höchstwert für die Kühlperiode 26,0 °C.

Für die Bewertung von Zielgrößen, wie z.B. Treibhausgas-Emissionen, werden Informationen über die Erzeugung des Energiebedarfes benötigt. Dafür werden zwei Szenarien für die Sanierung der technische Gebäudeausrüstung definiert. Ein Ziel der beiden Szenarien ist es, den Einfluss der Kühlung auf die Treibhausgas-Emissionen zu quantifizieren. Das Szenario „Moderat“ repräsentiert eine Sanierung der Heizungsanlage und die Implementierung einer „ineffizienten“ Kühlung. Dieses Szenario repräsentiert eine energetische Sanierung die ausschließlich auf die Reduktion des Heizwärmebedarfes fokussiert ist. Die Kühlung wird dabei vernachlässigt. Aufgrund der sommerlichen Überhitzung wird jedoch angenommen, dass vom Nutzer nachträglich eine ineffiziente Kühlung installiert wird (siehe Tabelle 5.5).

Das Szenario „Ambitioniert“ spiegelt eine Sanierung unter planerischer Berücksichtigung des Heiz- und Kühlbedarfes wider. In dieser Variante wird eine „effiziente“ Kühlung integriert. Zusätzlich werden 60% des Strombedarfes für die Kühlung aus erneuerbaren Energien gedeckt. Dieser Anteil an erneuerbaren Energien entspricht auch den Zielen der Bundesregierung bis ins Jahr 2040 (BMW i 2010). In Tabelle 5.5 sind die Eckdaten der Szenarien zusammengefasst.

Die Kennwerte für die Anlagentechnik wurden aus Pistohl (2007) und für die Treibhausgas-Emissionen aus Großklos (2014) entnommen. Für einen Vergleich der Sanierungskonzepte wird im Modell des Bestandsgebäudes ebenfalls eine Kühlung implementiert. Dadurch kann eine Bewertung der Entwicklung des Kühlbedarfs erfolgen.

Tabelle 5.5: Eckdaten der Gebäudetechnik

Bestand	Heizen	Kühlen
Erzeuger	Ölkessel	Wärmepumpe (Luft/Luft)
Wirkungsgrad	$\eta = 0,80$	JAZ = 2,5
THG-Emission	313 [g/kWh _{End}]	617 [g/kWh _{End}]
Moderat	Heizen	Kühlen
Erzeuger	Holzpellets-Heizkessel	Wärmepumpe (Luft/Luft)
Wirkungsgrad	$\eta = 0,90$	JAZ = 2,5
THG-Emission	18 [g/kWh _{End}]	617 [g/kWh _{End}]
Ambitioniert	Heizen	Kühlen
Erzeuger	Holzpellets-Heizkessel	Wärmepumpe (Sole/Wasser)
Wirkungsgrad	$\eta = 0,90$	JAZ = 4,5
THG-Emission	18 [g/kWh _{End}]	617 [g/kWh _{End}]
60% Deckung des Strombedarfs für die Kühlung durch erneuerbare Energien		

6 | Randbedingungen Kosten-Nutzen-Analyse

Die Kosten einer energetischen Gebäudesanierung sind eine Zielgröße, welche bei der Erstellung von Sanierungskonzepten berücksichtigt werden muss. Aufgrund der Baualtersklasse des Fallbeispiels wird im Rahmen dieser Arbeit davon ausgegangen, dass für das Gebäude „sowie-so“ eine technische Sanierung ansteht. Die Kosten-Nutzen-Analyse beschränkt sich deshalb auf die zusätzlichen Kosten, bzw. die Kostendifferenz zu einer rein technischen Sanierung, welche für die Maßnahmen der energetischen Sanierung entstehen. Diese werden im weiteren Verlauf als „energiebedingte Mehrkosten“ bezeichnet. Für die Durchführung der Kosten-Nutzen-Analyse wird die Kapitalwertmethode herangezogen. Des Weiteren werden für die Anwendung der robusten Optimierung in Teil VI Eingangsparameter der Kapitalwertmethode als unsichere Randbedingungen, zusätzlich zu den klimatischen Veränderungen, definiert. In den folgenden Abschnitten wird auf die Kapitalwertmethode, sowie auf verwendete Kostenfunktionen der einzelnen Sanierungsmaßnahmen eingegangen. Dabei werden auch Prognosen für die zukünftige Preisentwicklung von unterschiedlichen Energieträgern vorgestellt.

6.1 Kapitalwertmethode

Die Kapitalwertmethode gehört in den Bereich der dynamischen Investitionsrechnung und ermöglicht die Bewertung der Wirtschaftlichkeit von Investitionen. Ein positiver Kapitalwert bedeutet, dass eine Investition wirtschaftlich ist (absolute Wirtschaftlichkeit). Bei einem Vergleich von mehreren Investitionsalternativen ist die mit dem höheren Kapitalwert die wirtschaftlichste Lösung (relative Wirtschaftlichkeit). Weitere Informationen über die Kapitalwertmethode können aus Konstantin (2013) entnommen werden. Gleichung 6.1 zeigt die Grundform der Kapitalwertmethode.

$$KW_0 = \sum_{t=1}^n \frac{E_t - A_t}{(1+i)^t} - I_0 \quad (6.1)$$

Dabei repräsentiert KW_0 den Kapitalwert zum Zeitpunkt $t = 0$. E_t sind die Einnahmen am Ende des Jahres t in EUR/a und A_t die Ausgaben des jeweiligen Jahres. Die Investitionskosten für die Maßnahmen werden durch I_0 dargestellt, n ist die Nutzungsdauer und i ist der kalkulatorische Zinssatz. Die „Einnahmen“ durch Energieeinsparungen werden in dieser Arbeit durch die Gleichungen 6.2, 6.3 und 6.4 ermittelt. Als Basis für die Berechnung der Einnahmen werden die Kosten für den Endenergiebedarf des Bestandsgebäudes herangezogen.

$$E_{Q_{H_t}} = Q_{H_{Bestand}} K_{\text{Öl}} - Q_{H_{RobOpt}} K_{\text{Pellets}} \quad (6.2)$$

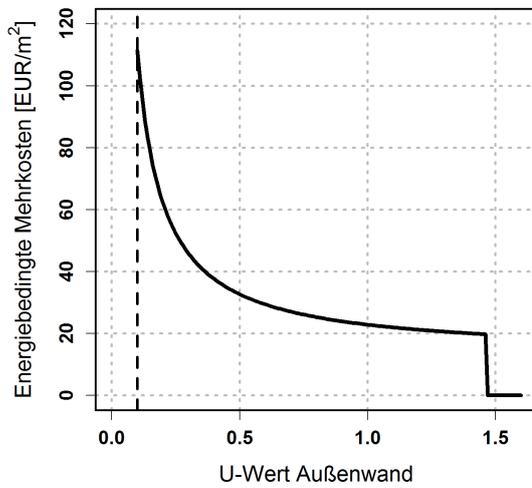
$$E_{Q_{C_t}} = Q_{C_{Bestand}} K_{\text{Strom}} - Q_{C_{RobOpt}} K_{\text{Strom}} \quad (6.3)$$

$$E_t = E_{Q_{H_t}} + E_{Q_{C_t}} \quad (6.4)$$

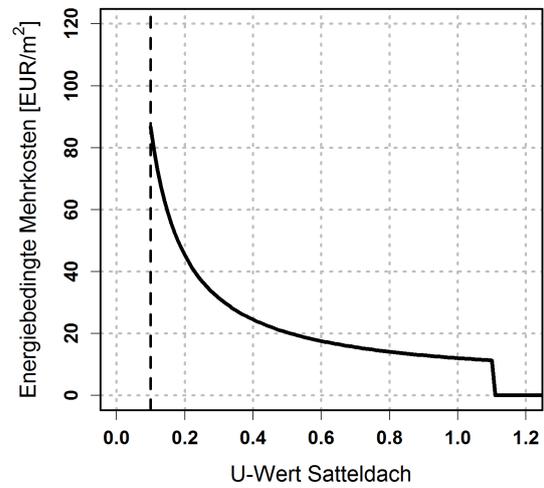
Die Größe Q_H repräsentiert den Endenergiebedarf für das Heizen und Q_C den Endenergiebedarf für das Kühlen. Der Endenergiebedarf wird über die Simulationsergebnisse des Gebäudemodells und den Faktoren aus Tabelle 5.5 ermittelt. Die Kosten für den Bedarf werden, in Abhängigkeit des Energieträgers, mit Hilfe der Funktionen $K_{\text{Öl}}$, K_{Pellets} und K_{Strom} errechnet. Die Kostenfunktionen der Energieträger werden in Abbildung 6.2 unter Berücksichtigung eines Prognosebereiches dargestellt.

6.2 Kosten und Preisentwicklungen

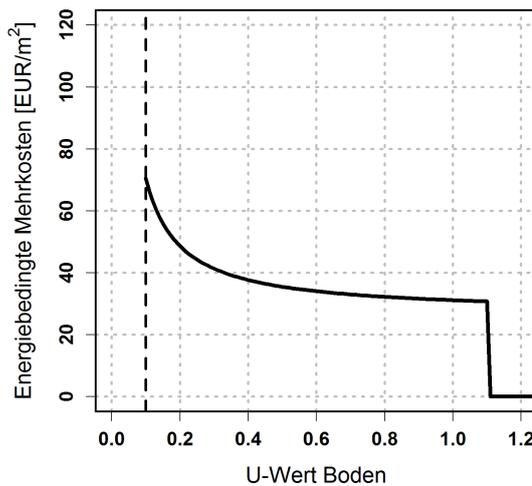
Die Grundlagen für die Ermittlung der energiebedingten Mehrkosten für die Maßnahmen an der Gebäudehülle und der technischen Gebäudeausrüstung werden aus den beiden Studien Hinz (2012) und Hinz (2015) entnommen. In Abbildung 6.1 sind die Funktionen der energiebedingten Mehrkosten für die Maßnahmen an der Gebäudehülle dargestellt. Dabei werden die Kosten lediglich im Optimierungsbereich der Maßnahmen berücksichtigt. So repräsentiert bei der Dämmung der Außenwand, des Daches sowie dem Boden der Wärmedurchgangskoeffizient des Bestandsgebäudes die Kosten von 0,00 EUR. Die Maximalen Kosten werden bei einem Wärmedurchgangskoeffizient (U-Wert) von 0,10 W/m²K fixiert. Für den Austausch der Fenster wird ein Wärmedurchgangskoeffizient von 1,30 W/m²K als Stand der Technik angenommen und somit mit 0,00 EUR definiert. Als Minimum wird ein U-Wert von 0,60 W/m²K festgelegt.



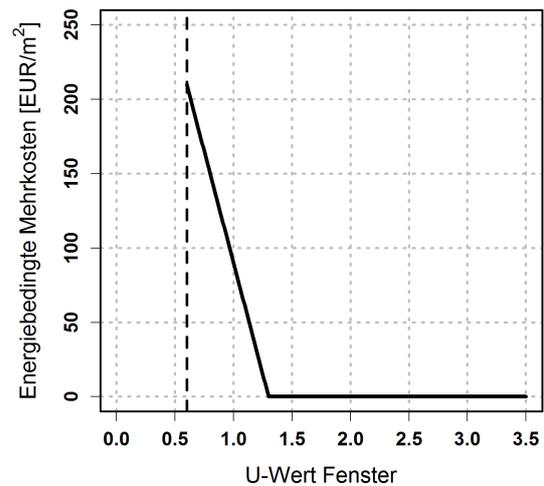
(a) Funktion der energiebedingten Mehrkosten für die Außenwanddämmung



(b) Funktion der energiebedingten Mehrkosten für die Dämmung des Satteldaches



(c) Funktion der energiebedingten Mehrkosten für die Dämmung des Bodens



(d) Funktion der energiebedingten Mehrkosten für den Austausch der Fenster

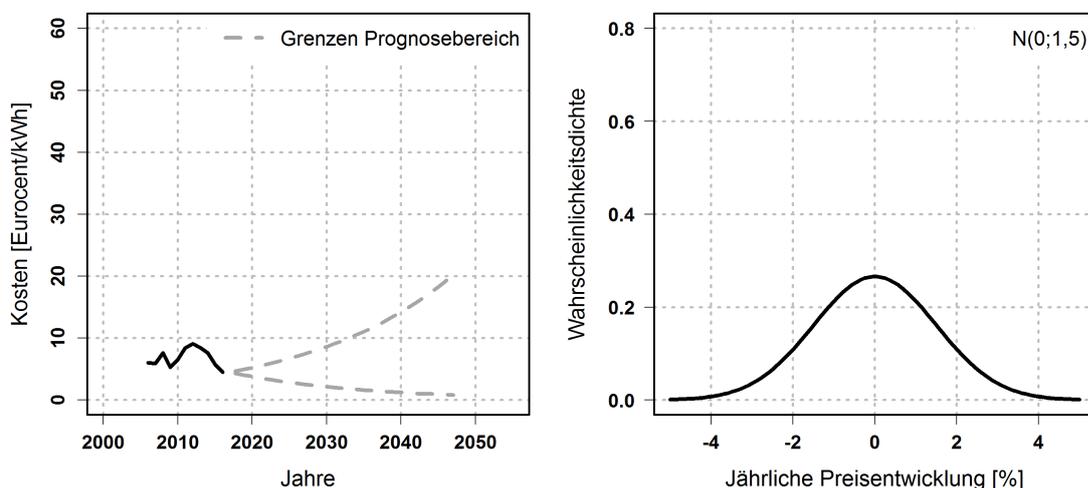
Abbildung 6.1: Funktionen für die energiebedingten Mehrkosten der unterschiedlichen Sanierungsmaßnahmen der Gebäudehülle

Die Kosten der technische Gebäudeausrüstung sind in Tabelle 6.1 zusammengefasst. Dabei repräsentiert die Anlagentechnik des Bestandsgebäudes die „Sowiesokosten“, welche im Falle einer Sanierung entstehen. Für einen besseren Vergleich des aktuellen und zukünftigen Energiebedarfes wird angenommen, dass auch im Bestand eine Kühlung installiert ist. Die energiebedingten Mehrkosten einer Sanierung der Anlagentechnik werden auf Basis des Ölkessels und der Wärmepumpe (Luft/Luft) ermittelt.

Tabelle 6.1: Kosten für die technische Gebäudeausrüstung

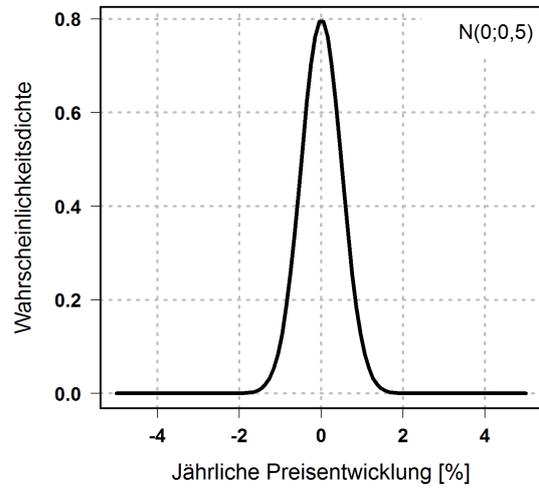
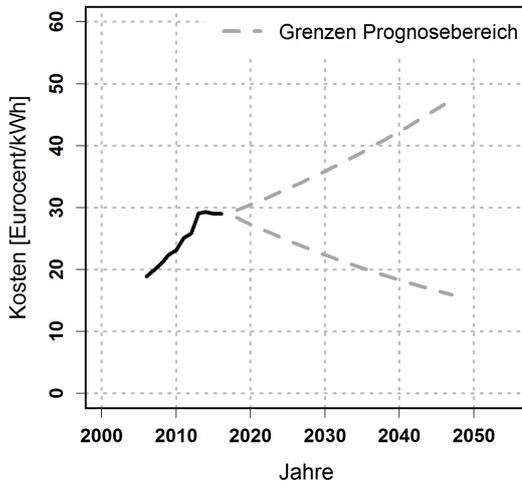
Maßnahme	Kosten [EUR]	Energiebedingte Mehrkosten [EUR]
Ölkessel	11.900,00	0,00
Pelletkessel	19.500,00	7.600,00
Wärmepumpe (Luft/Luft)	18.500,00	0,00
Wärmepumpe (Sole/Wasser)	28.800,00	10.300,00

In Abbildung 6.2 sind unterschiedliche Prognosen zur Preisentwicklung der verwendeten Energieträger und Energieformen dargestellt. Die Grundlage der Prognosen stellt die Preisentwicklung aus den Jahren 2005 bis 2015 dar, welche in den Grafiken durch die schwarze Linie gekennzeichnet ist. Als Referenzen für die Preisentwicklung in den Jahren 2005 bis 2015 dienen folgende Studien: BNetzA (2016), DEPV (2016) und DEPV (2016). Der Prognosebereich ab dem Jahr 2015 wird vom Autor definiert und mit Hilfe eines jährlichen prozentualen Anstiegs oder Rückgangs der Preise umgesetzt. Diese unterschiedlichen Preisentwicklungen werden im Anwendungsbeispiel in Teil VI als unsichere Randbedingungen herangezogen. Die Unsicherheiten werden auf Basis von Wahrscheinlichkeitsverteilungen der jährlichen Preisentwicklungen, welche in den Grafiken 6.2b, 6.2d und 6.2f abgebildet sind, erstellt. Ziel dieser Prognosen ist nicht die exakte Abbildung eines realitätsnahen Prognosebereiches, es geht vielmehr um Bereitstellen einer weiteren plausiblen unsicheren Randbedingung für die Anwendung der im Rahmen dieser Arbeit entwickelten Methode.



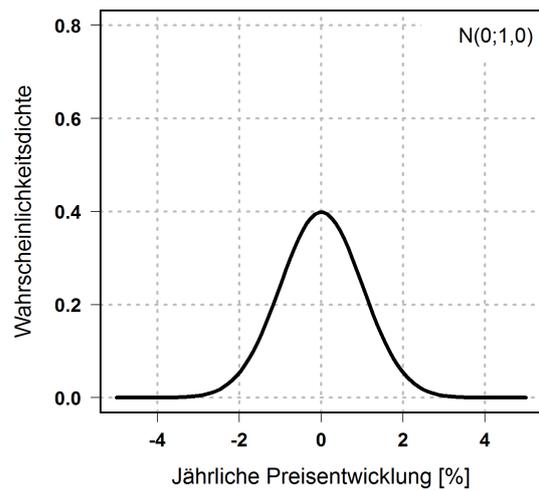
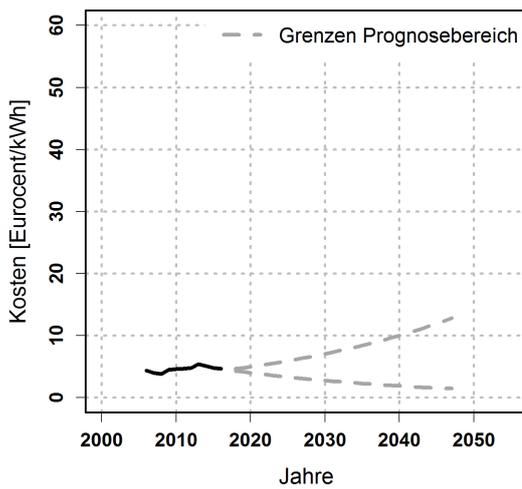
(a) Prognosebereich für die Entwicklung des Heizölpreises

(b) Wahrscheinlichkeitsverteilung der jährlichen Preisentwicklungen für Heizöl



(c) Prognosebereich für die Entwicklung der Kosten für Haushaltsstrom

(d) Wahrscheinlichkeitsverteilung der jährlichen Preisentwicklungen für Haushaltsstrom



(e) Prognosebereich für die Entwicklung der Pelletpreise

(f) Wahrscheinlichkeitsverteilung der jährlichen Preisentwicklungen für Pellets

Abbildung 6.2: Prognosen für die jährlichen Preisentwicklungen von Heizöl, Pellets und Haushaltsstrom

Teil III

Modellauswahl

7 | Einführung Modellentwicklung

Die Anwendung einer robusten Optimierung bei der energetischen Gebäudesanierung erfordert ein Simulationsmodell des Gebäudes. Es existieren unterschiedliche Arten von Modellen, welche als Grundlage einer Gebäudeoptimierung verwendet werden können. In den folgenden Abschnitten werden einige grundsätzliche Modelltypen vorgestellt. Des Weiteren wird die Anwendung von Neuronalen Netzen und Support Vector Machines als Ersatzmodell für ein detailliertes Gebäudemodell diskutiert. Ziel des Teils „Modellauswahl“ ist die Analyse, Bewertung und Auswahl geeigneter Modellierungsverfahren für die Entwicklung der genannten Ersatzmodelle.

7.1 Grundlagen der Modellentwicklung

Das Erstellen und die Anwendung von Modellen, wie z.B. für die Entscheidungsfindung in einem Unternehmen oder für die Entwicklung von technischen Systemen, ist vielseitig und weitverbreitet. Deshalb ist die Definition eines Modells von dessen Einsatzbereich abhängig. Ein „Modell“ in den Wirtschaftswissenschaften kann sich durchaus stark von einem „Modell“ in den Ingenieurwissenschaften unterscheiden. Im Rahmen dieser Arbeit wird eine Definition nach Reddy (2011, S. 4-5) verwendet:

„Ein Modell ist eine vereinfachte Abbildung eines realen (technischen) Systems mit dessen Hilfe das Verhalten unter verschiedenen Randbedingungen vorhergesagt werden kann.“

Dabei kann zwischen drei grundlegenden Typen von Modellen unterschieden werden (Reddy 2011, S. 5).

- i) *Intuitive Modelle* oder auch qualitative oder beschreibende Modelle genannt. Bei dieser Art von Modellen wird das Verhalten des realen Systems nur qualitativ beschrieben. Diese Modelle werden häufig in den Sozial- und Geisteswissenschaften verwendet.
- ii) *Empirische Modelle* verwenden gemessene Daten von realen Systemen, um ein mathematisches Modell zu erstellen. Dazu werden die Beziehungen der gemessenen Ein- und Ausgangsvariablen des Systems mit Hilfe unterschiedlichster Techniken z.B. Regression analysiert. Die Struktur des realen Systems stimmt mit der Struktur des empirischen Modells nicht überein. Deshalb spricht man auch von „**Black-Box-Modellen**“, da lediglich das Verhalten der Ein- und Ausgangsvariablen mit dem realen System identisch ist.

- iii) *Strukturmodelle* sind möglich, wenn der Aufbau und die Zusammenhänge des realen Systems bekannt sind. Dies gilt, z.B. bei physikalischen Modellen wie in der Thermodynamik. Dabei wird versucht, die Struktur des Modells mit Hilfe mathematischer Gleichungen, wie z.B. gewöhnlicher oder partieller Differentialgleichungen, abzubilden. Diese Modelle werden auch „**White-Box-Modelle**“ genannt, da das „Innere“ des Systems, im Vergleich zu empirischen Modellen, bekannt ist.

Des Weiteren existiert eine Kategorie zwischen einem rein empirischen und einem rein strukturellen Modell. Diese Modelle setzen sich meist aus einer physikalischen und einer empirischen Komponente zusammen. So kann z.B. die Struktur des Modells aufgrund physikalischer Gesetze bekannt sein, aber einzelne Parameter werden empirisch ermittelt. Diese Modelle werden als „**Grey-Box-Modelle**“ bezeichnet (Reddy 2011, S. 10).

In der Gebäudesimulation werden abhängig von der zu beantwortenden Fragestellung White, Grey oder Black-Box-Modelle angewendet (Z. Li et al. 2014). Diese drei Modelltypen können unter anderem in die zwei Kategorien „Forward models“ und „Inverse models“ aufgeteilt werden. Die Kategorie „Forward models“ steht für die Modellierung oder Simulation von noch nicht existierenden Systemen bzw. Gebäuden. Diese Art von Modellen wird häufig in der Planungsphase von Gebäuden verwendet, wenn unterschiedlichste Konzepte geprüft werden. Die Gruppe „Inverse models“ beschreibt die Modellierung von bereits existierenden Systemen bzw. Gebäuden. Diese Modelle dienen zur Analyse, Vorhersage oder Steuerung von bestehenden Systemen (Reddy 2011; Henze und Neumann 2011). In Abbildung 7.1 ist eine Übersicht und Einteilung der unterschiedlichen Kategorien und Modelltypen dargestellt. In den nächsten Abschnitten werden die Modellkategorien White- und Black-Box und deren Anwendung in der Gebäudesimulation detaillierter beschrieben, da diese im weiteren Verlauf der Arbeit verwendet werden.

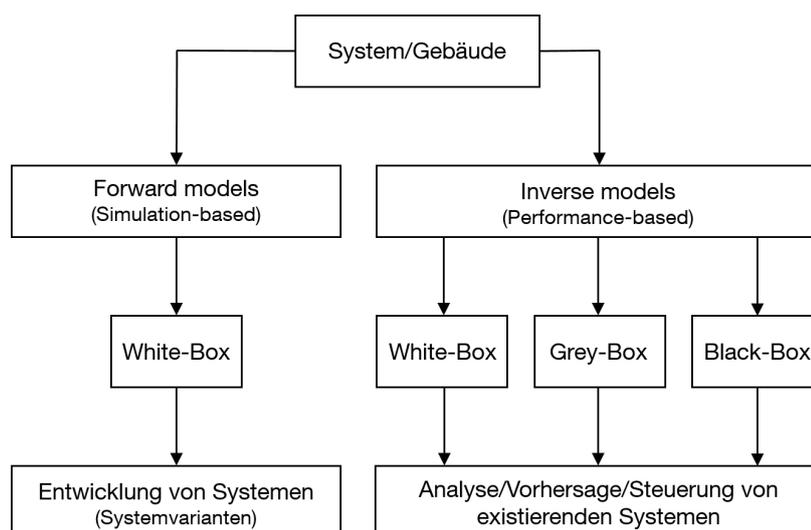


Abbildung 7.1: Differenzierung unterschiedlicher Modelltypen, eigene Darstellung nach Reddy (2011)

7.1.1 White-Box-Modelle

White-Box-Modelle basieren meist auf physikalischen Gesetzen und erlauben exakte Analysen für z.B. die Wärmeübertragung oder den Massenstrom eines Fluides. Für die Erstellung eines solchen Modells ist eine detaillierte Kenntnis der physikalischen Grundlagen, sowie aller Parameter des Systems notwendig (Reddy 2011).

Der Detaillierungsgrad von White-Box-Modellen kann stark variieren. Dieser ist von den jeweiligen physikalischen Zusammenhängen abhängig, welche mit dem Modell abgebildet werden. Wenn für ein Gebäude alle relevanten physikalischen Phänomene modelliert werden, kann die Anzahl der nötigen Parameter und Variablen kurzerhand auf mehrere hundert ansteigen. Bei einer Erweiterung eines einfachen Zonenmodells zur Simulation, z.B. von Raumluftströmungen oder der Gebäudetechnik, steigt die Anzahl von Gleichungen im Modell auf mehrere tausend an. Dabei erhöht sich zwar die Einsatzmöglichkeit des Modells, jedoch aber auch der Aufwand für die Modellbildung, Lösung der Gleichungssysteme und Auswertung der Ergebnisse (Henze und Neumann 2011).

Im Bereich der thermischen Gebäudesimulation existieren aufbauend auf White-Box-Ansätzen spezielle Simulationsprogramme. Typische Beispiele¹ sind „EnergyPlus“², „ESP-r“³ oder „IDA-ICE“⁴. Viele dieser Programme weisen einen mittleren bis hohen Detaillierungsgrad auf. So können diese meist den Wärmetransport, vereinfachte Raumluftströmungen, den Einfluss von Solarstrahlung, interne Quellen wie Personen oder Geräte, die Gebäudetechnik und deren Regelung von einem oder mehreren Räumen berechnen (Henze und Neumann 2011). Der Vorteil dieser Programme oder White-Box-Modelle ist, im Gegensatz zu einem Black-Box-Modell, dass sie bereits bei der Planung eines Gebäudes verwendet werden können. Als Grundlage für die Modellerstellung können bereits Parameter aus dem Planungsprozess wie z.B. die Geometrie des Gebäudes oder bauphysikalischen Kennwerten der Baumaterialien herangezogen werden.

7.1.2 Black-Box-Modelle

Zur Erstellung eines Black-Box-Modells werden in der Regel gemessene Daten von Ein- und Ausgangsgrößen eines Systems verwendet. Mit Hilfe unterschiedlicher Verfahren kann, abhängig von der Beschaffenheit des Systems z.B. linear oder nichtlinear, über die Korrelation von Ein- und Ausgangsgrößen das Modell erstellt werden. Die Struktur von einem Black-Box-Modell spiegelt nicht die (physikalische) Struktur des abzubildenden Systems bzw. Gebäudes wider. Deshalb weisen Black-Box-Modelle, im Vergleich zu White-Box-Modellen, keine physikalischen Parameter im „Inneren“ des Modells auf (Henze und Neumann 2011).

¹ Die „International Building Performance Simulation Association“ (IBPSA) führt eine Webseite mit einer Übersicht aller aktuellen Gebäudesimulationsprogrammen (IBPSA-USA 2016).

² <http://apps1.eere.energy.gov/buildings/energyplus/>.

³ <http://www.esru.strath.ac.uk/Programs/ESP-r.htm>.

Diese Art von Modellen bezieht somit alle Informationen über das abzubildende Gebäude aus bereits vorhandenen Daten. Diese Daten werden mit Messungen erhoben oder von detaillierteren Gebäudemodellen, wie z.B. White-Box-Modellen, bereitgestellt. Diese Daten werden auch *Trainingsdaten*, *Sample-Daten* oder *Stichproben* genannt. Die Güte dieser Daten ist maßgebend für die Genauigkeit bzw. Qualität eines Black-Box-Modells verantwortlich (Endisch 2009).

Bei der Anwendung von Black-Box-Modellen in der Gebäudesimulation können zwei Kategorien unterschieden werden. Henze und Neumann (2011) differenzieren dabei zwischen statischen und dynamischen Modelltypen, die wiederum in linear und nichtlinear eingeteilt sind. Für Systeme mit geringer Komplexität eignen sich meist statisch lineare Modelle. Der Vorteil von dynamisch nichtlinearen Modellen liegt in der breiten Anwendungsmöglichkeit. Im Gebäudebereich können dadurch fast alle realen Systeme dargestellt werden (Henze und Neumann 2011).

Im Bereich der Gebäudesimulation werden Black-Box-Modelle häufig in der Fehlererkennung (Henze und Neumann 2011) oder für die prädiktive Regelung eines Gebäudes (Jungwirth 2015) verwendet. Bei der Fehlererkennung werden meist Daten aus der Gebäudeleittechnik eingesetzt, um ein Modell zu erstellen. Anschließend wird anhand dieses Modells eine Analyse von Unregelmäßigkeiten in den weiteren Messdaten durchgeführt. Im Bereich der vorhersagenbasierten Regelung wird ebenfalls ein Black-Box-Modell aus vorhandenen Messdaten abgeleitet und für die Ermittlung optimaler Regelparameter angewandt.

Der Einsatz von einem Black-Box-Modell in einer frühen Phase der Gebäudeplanung ist aufgrund der benötigten Trainingsdaten nur schwer oder in Kombination mit einem White-Box-Modell möglich, da zu diesem Zeitpunkt keine Informationen über Ausgangsgrößen wie z.B. Energieverbrauch, Raumtemperaturen etc. vorhanden sind. Der Vorteil von Black-Box-Modellen gegenüber White-Box-Modellen ist der geringe Aufwand für die Modellerstellung, sowie die geringen Rechenzeiten. Nachteile sind die Anzahl der benötigten Trainingsdaten zum Erstellen des Modells und die beschränkte Gültigkeit auf den Wertebereich dieser Daten. Tabelle 7.1 fasst die Vor- und Nachteile der beiden Modelltypen zusammen.

Tabelle 7.1: Zusammenfassung von Vor- (+) und Nachteilen (-) der verschiedenen Modellarten, eigene Darstellung nach Henze und Neumann (2011, S. 422)

Eigenschaften	White-Box	Black-Box
Einblick in physikalische Zusammenhänge	+	-
Anzahl benötigter Parameter	-	+
Aufwand der Modellerstellung	-	+
Rechenzeit	-	+
Anzahl von Trainingsdaten	+	-
Komplexität der Kalibrierung	-	+
Anwendungsbereich des Modells	+	-

7.2 Modelle für eine mathematische Optimierung in der Gebäudesimulation

White-Box-Modelle in Form von spezieller Gebäudesimulationssoftware (z.B. EnergyPlus) werden bei einer mathematischen Optimierung im Gebäudebereich am häufigsten verwendet (Nguyen et al. 2014). Diese Art von Modellen können aber aufgrund der hohen Komplexität eine erhöhte Simulationszeit aufweisen. Die Anwendung einer mathematischen Optimierung erfordert teilweise eine tausendfache Wiederholung von Simulationen um eine vermeintlich optimale Lösung zu finden (Jacob 2012). Dadurch kann die Dauer der Berechnungen um ein Vielfaches ansteigen. Diese erhöhten Rechenzeiten können ein Ausschlusskriterium für die Anwendung einer mathematischen Optimierung darstellen (Eisenhower et al. 2012). Besonders gilt dies bei einer robusten Optimierung, bei der eine mathematische Optimierung um eine Unsicherheitsanalyse (UA) erweitert wird (Nguyen et al. 2014). Denn eine UA basiert meist ebenfalls auf einer häufigen Wiederholung von Simulationen mit variierenden Eingangsgrößen.

Eine Möglichkeit die Rechenzeit für eine robuste Optimierung zu reduzieren, ist die Verwendung eines Ersatzmodells bzw. Metamodells (Nguyen et al. 2014). Tabelle 7.1 zeigt, dass Black-Box-Modelle gute Eigenschaften im Bereich der Rechenzeit, sowie einen geringen Aufwand für die Modellerstellung aufweisen und sich deshalb für die Entwicklung von Ersatzmodellen eignen. Zur Bereitstellung der Trainingsdaten für das Ersatzmodell kann in der Praxis, je nach Anwendungsbereich, entweder ein detailliertes Gebäudemodell erstellt oder auf reale Messdaten zurückgegriffen werden. Im Rahmen dieser Arbeit wird zur Bereitstellung der Datengrundlage ein detailliertes Gebäudemodell verwendet, da in der Praxis für den Anwendungsfall einer energetischen Gebäudesanierung im Wohngebäudebestand meist keine Messdaten vorhanden sind. Dies könnte sich durch die Digitalisierung im Bauwesen ändern, da mit Einsatz von Smart-Meter oder Smart-Home Anwendungen Daten über Energieverbrauch oder Raumtemperaturen vorhanden sind. Dadurch erschließt sich im Wohngebäudebestand ein neues Einsatzgebiet von empirischen Black-Box-Modellen.

Aktuell stehen zwei Typen von Black-Box-Modellen, Neuronales Netz (NN) und Support Vector Machine (SVM), für die Anwendung in der Gebäudesimulation im Fokus der Forschung (Zhao und Magoulès 2012). Die Vorteile eines Neuronalen Netzes und einer Support Vector Machine sind, dass beide Techniken prinzipiell jedes nichtlineare dynamische System mit einem akzeptablen Rechenaufwand abbilden können (Henze und Neumann 2011). Deshalb wird im weiteren Verlauf der Arbeit die Anwendung dieser beiden Methoden für den Einsatz bei einer robusten Optimierung untersucht.

In Tabelle 7.2 wird die Problematik des Rechenaufwandes für eine mathematische Optimierung verdeutlicht. Die Tabelle zeigt den Rechenaufwand einer mathematischen Optimierung für ein detailliertes Gebäudemodell und einem vergleichbaren Neuronalen Netz. Dabei werden für die Optimierung mit einem genetischen Algorithmus 25.000 Simulationen benötigt, um ein vermeintliches Optimum zu finden. Dies entspricht ca. 3 Wochen Simulationszeit mit einem detaillierten Gebäudemodell.

Das Neuronale Netz benötigt für dieselbe Anzahl von Simulationen lediglich 79 Sekunden. Der zusätzliche Arbeitsaufwand für die Erstellung des Ersatzmodells beträgt ca. fünf Tage. Bei einer belastbaren Analyse werden meist mehrere Optimierung durchgeführt. Dadurch ist der zusätzliche Arbeitsaufwand für das Ersatzmodell zu vernachlässigen (Maderspacher et al. 2016).

Tabelle 7.2: Vergleich des benötigten Rechenaufwands für eine mathematischen Optimierung, eigene Darstellung nach (Maderspacher et al. 2016)

Modell	Anzahl Simulationen	Rechenaufwand [s]
Gebäudemodell	1	86
Neuronales Netz	1	$3,16 \cdot 10^{-3}$
Gebäudemodell	25.000	$21,5 \cdot 10^5$
Neuronales Netz	25.000	79

7.3 Neuronale Netze und Support Vector Machines in der Gebäudesimulation

Der folgende Abschnitt gibt einen exemplarischen Überblick über die Anwendung von Neuronalen Netzen und Support Vector Machines im Bereich der Gebäudesimulation. In einem ersten Schritt werden Anwendungen für unterschiedliche Fragestellungen und Zielgrößen im Gebäudebereich dargestellt. Der Schwerpunkt liegt dabei auf der Vorhersage des Energiebedarfs und Lastverlaufs von Gebäuden für Heizen und Kühlen, da diese Kenngrößen auch im weiteren Verlauf der Arbeit verwendet werden. Anschließend werden erste Veröffentlichungen über die Verwendung der beiden Techniken für die mathematische Optimierung in der Gebäudesimulation diskutiert.

7.3.1 Vorhersage des Energie- oder Lastbedarfs für Heizen und Kühlen mit Hilfe von Neuronalen Netzen und Support Vector Machines

7.3.1.1 Neuronale Netze

Erste Analysen zum Einsatz von Neuronalen Netzen (NN) für die Vorhersage des Energiebedarfs von Gebäuden sind von Kreider und X. A. Wan (1991) und Anstett und Kreider (1993) durchgeführt worden. In Anstett und Kreider (1993) wird auf Basis von Messdaten ein Neuronales Netz erstellt und damit der zukünftige Energiebedarf eines Hochschulgebäudes prognostiziert. Dabei werden das Wetter, die Belegung des Gebäudes sowie die Aktivitäten der Nutzer als Eingangsgrößen verwendet. Als Modellstruktur wird ein „Feedforward-Netz“⁵ untersucht und ein „Backpropagation“⁵ Algorithmus für das Lernen des Netzes angewandt.

⁵ Eine detaillierte Einführung erfolgt Kapitel 8.4

In Kreider, Claridge, et al. (1995) wird ein sogenanntes „Recurrent Neural Network“⁵ für die Prognose des Heiz- und Kühlbedarfes eines Hochschulgebäudes analysiert. Als Eingangsgrößen werden lediglich das Wetter und die Tageszeit angenommen. Das Netz funktioniert ohne Informationen über den Energieverbrauch in der jüngsten Vergangenheit. Mit derselben Netztypologie werden außerdem Kennwerte für die thermische Speicherkapazität und Wärmeleitfähigkeit der Gebäudebauteile ermittelt.

Olofsson und Andersson (1998) verwenden ebenfalls ein „Feedforward-Netz“ in Kombination mit einem „Backpropagation“ Algorithmus zur Vorhersage des Heizenergiebedarfs von Einfamilienhäusern in Schweden. In einer weiteren Analyse zeigen Olofsson und Andersson (2001), dass ein Neuronales Netz, welches mit Messdaten aus einem Zeitraum zwischen zwei und fünf Wochen erstellt wird, den Jahresenergiebedarf von Einfamilienhäusern in einer angemessenen Genauigkeit prognostizieren kann.

In Karatasou et al. (2006) werden Daten eines Bürogebäudes aus Athen sowie dem „Great Building Energy Predictor Shootout I“ (Kreider und Haberl 1994) als Grundlage für die Modellentwicklung herangezogen. Als Netztypologie wird ein „Feedforward-Netz“ für die Vorhersage des Energiebedarfes angewendet. Bei der Modellerstellung wird eine Parameterstudie für die freien Parameter des Neuronalen Netzes, Anzahl der Neuronen sowie die Anzahl der Layer durchgeführt. Die Analysen zeigen, dass die Auswahl der freien Parameter einen deutlichen Einfluss auf die Güte des Modells aufweist.

Auch für die Vorhersage von Innenraumtemperaturen und relativer Feuchte werden Neuronale Netze erfolgreich angewendet. In Lu und Viljanen (2009) wird ein rückgekoppeltes Netz mit externen Eingangsgrößen „NNARX“⁵ für die Prognose von Innenraumtemperatur und relativer Feuchte in einem Versuchsgebäude untersucht. Mustafaraj et al. (2011) zeigt ebenfalls eine erfolgreiche Anwendung von Neuronalen Netzen für die Vorhersage der Raumtemperatur und der relativen Feuchte in einem Bürogebäude. Für die Modellerstellung werden Messdaten der Außen- und Innentemperatur über einen Zeitraum von drei Monaten herangezogen. Der Prognosezeitraum der Netze beträgt zwischen 30 Minuten und drei Stunden.

7.3.1.2 Support Vector Machines

Im Vergleich zur Anwendung von Neuronalen Netzen ist der Einsatz von Support Vector Machines in der Gebäudesimulation weniger stark verbreitet. Jedoch existiert auch hier eine Vielzahl von Veröffentlichungen zur Prognose des Heiz- und Kühlbedarfes von Gebäuden, welche nachfolgend anhand von Beispielen exemplarisch vorgestellt werden. Des Weiteren ist eine deutliche Zunahme von Untersuchungen zum Einsatz von SVMs in der Gebäudesimulation in den letzten fünf Jahren zu erkennen (Magoules und Zhao 2016).

In Q. Li et al. (2009) wird mit Hilfe einer SVM die Vorhersage des stündlichen Kühlbedarfes eines Bürogebäudes im Südosten Chinas analysiert. Zur Verbesserung der Modellgüte wird eine Parameterstudie für die freien Parameter der SVM durchgeführt. Für die Bewertung der Modellqualität wird der Root Mean Squared Error (RMSE) herangezogen.

Jinhu et al. (2010) verwenden verschiedene Ansätze von SVMs zur Prognose der Kühllast eines Hochschulgebäudes in Guangzhou, China. Die Eingangsgrößen der SVMs sind Datum, Wetterdaten sowie minimale, mittlere und maximale Tagestemperaturen. Auch in dieser Analyse zeigt sich, dass die Auswahl der freien Parameter der SVM einen starken Einfluss auf die Modellgüte aufweist.

Zhang und Qi (2009) zeigen, dass eine SVM auch bei der Vorhersage der Heizleistung belastbare Resultate liefert. Als Anwendungsfall wird eine Heizstation eines Nahwärmenetzes in Daqing im Norden Chinas untersucht. Als Trainingsdaten und zur Validierung des Modells werden Messungen von jeweils 40 Tagen während der Heizperiode 2007/2008 herangezogen.

7.3.1.3 Fazit

Der exemplarische Überblick zeigt eine erfolgreiche Anwendung von NN und SVM für die Vorhersage des Energie- oder Lastbedarfes von Gebäuden. Des Weiteren wird der Einfluss einer optimalen Parameterauswahl für die freien Parameter von Neuronalen Netzen und Support Vector Machines auf die Modellgüte deutlich. Auch die Abhängigkeit der Modellqualität von den Trainingsdaten wird, speziell in Karatasou et al. (2006), sichtbar. Weitere Informationen über die Anwendungen von Neuronalen Netzen und Support Vector Machines in der Gebäudesimulation können z.B. aus den Veröffentlichungen Zhao und Magoulès (2012), Kumar et al. (2013), Ahmad et al. (2014), Magoules und Zhao (2016) und Wang und Srinivasan (2016) entnommen werden.

7.3.2 Mathematische Optimierung von Energieeffizienzmaßnahmen im Gebäudebereich auf Basis von NN und SVM

Neuronale Netze und Support Vector Machines können auf Basis eines detaillierten Gebäudemodells für die mathematische Optimierung von Gebäuden angewandt werden. Häufiges Ziel des Einsatzes solcher Ersatzmodelle ist dabei die Reduktion der Rechenzeit für die Optimierung.

Magnier und Haghghat (2010) verwenden ein NN in Kombination mit einem detaillierten Gebäudesimulationsmodell für die Optimierung des thermischen Komforts und des Energiebedarfs eines Wohngebäudes. Bei der Erstellung des NN werden 450 Jahressimulationen als Trainingsdaten herangezogen. Als Eingangsgrößen für das NN dienen z.B. die Maße einzelner Fenster, Sollwerte für Heizen und Kühlen sowie die Luftwechselrate. Der mittlere Prognosefehler des NN gegenüber dem detaillierten Modell liegt beim Energieverbrauch unter 1% und für den Kennwert des thermischen Komforts bei ca. 4%. Diese Ergebnisse lassen eine Eignung des NN als Ersatzmodell erkennen. Zur Bereitstellung der Trainingsdaten des NN entsteht ein zusätzlicher Simulationsaufwand von drei Wochen. Jedoch dauert ein Optimierungszyklus mit dem NN lediglich sieben Minuten, wohingegen dieselbe Untersuchung mit dem detaillierten Gebäudemodell mehr als zehn Jahre benötigen würde (Magnier und Haghghat 2010).

In Asadi et al. (2014) wird ebenfalls eine Kombination aus NN und detailliertem Gebäudemodell für eine mathematische Optimierung angewandt. Als Fallbeispiel der Untersuchung dient eine Schule. Die Zielgrößen der Optimierung sind Energiebedarf, Sanierungskosten und der thermische Komfort. Die Eingangsgrößen des NN sind der Wärmedurchgangskoeffizient für Außenwand und Dach sowie Indizes für unterschiedliche Systeme von Solarkollektoren und Gebäudetechnik. Die Anzahl der Trainingsdaten beträgt 950 Jahressimulationen. Der mittlere Prognosefehler des NN ist für den Heizenergiebedarf ca. 1,4%, für den Kühlenergiebedarf ca. 0,5% und für den Kennwert des thermischen Komforts ca. 2,5%. Der Arbeitsaufwand für die Erstellung des NN und der Analyse des Fallbeispiels durch die mathematische Optimierung beträgt drei Tage. Dabei dauert eine Optimierung mit dem NN neun Minuten. Mit einem detaillierten Gebäudemodell würde die Untersuchung jedoch mehr als 75 Tage dauern. Aus Planungsperspektive wäre die Anwendung einer mathematischen Optimierung dadurch impraktikabel (Asadi et al. 2014).

Eisenhower et al. (2012) analysieren den Einsatz von SVM für eine mathematische Gebäudeoptimierung. Die SVM wird auf Basis eines detaillierten Gebäudemodells entwickelt. Ziel der Untersuchung ist die Optimierung eines Schulgebäudes mit den Zielgrößen thermischer Komfort und die Summe des Energiebedarfs für Heizen, Kühlen und elektrischer Verbraucher. Die Anzahl der Eingangsgrößen für die SVM beträgt über 1.000 Parameter. Dadurch soll die Entwicklung eines „vollständigen“ Ersatzmodells erreicht werden. Für die Erstellung der SVM werden 5.000 Jahressimulationen des detaillierten Gebäudemodells als Trainingsdaten verwendet. Der mittlere Prognosefehler für den gesamten Energiebedarf beträgt ca. 0,02% und für den Kennwert des thermischen Komforts ca. 2,15%. Diese Ergebnisse zeigen, dass auch der Einsatz einer SVM als Ersatzmodell für eine mathematische Optimierung belastbare Aussagen ermöglicht.

7.3.3 Zusammenfassung

Neuronale Netze und Support Vector Machines werden erfolgreich für die Vorhersage des Energiebedarfs und Lastverlaufs sowie des thermischen Komforts von Gebäuden angewandt. Auch der effiziente Einsatz von NN und SVM bei der mathematischen Optimierung auf Basis eines detaillierten Gebäudemodells zeigt belastbare Ergebnisse. Jedoch werden für die dargestellten Untersuchungen, je nach Anwendungsfall, unterschiedliche Arten von NN und SVM verwendet. Aus den bisherigen Veröffentlichungen lässt sich keine allgemeingültige Methode für die Anwendung eines NN oder SVM im Gebäudebereich ableiten. Deshalb wird in den folgenden Abschnitten der Einsatz von zwei Neuronalen Netzen und einer Support Vector Machine als Ersatzmodell für das im Rahmen dieser Arbeit durchgeführte Fallbeispiel untersucht und bewertet.

8 | Methoden zur Modellentwicklung

8.1 Ablauf Modellentwicklung

Aufgrund der in Kapitel 7 beschriebenen Problematik wird für die Analysen in dieser Arbeit zuerst ein detailliertes Gebäudemodell erstellt und darauf aufbauend ein Ersatzmodell für die Anwendung einer robusten Optimierung entwickelt. Hierzu wird in einem ersten Schritt ein detailliertes Gebäudesimulationsmodell des in Kapitel 5 eingeführten Fallbeispiels erstellt. Anschließend werden mit Hilfe einer Monte-Carlo-Simulation (MCS) Trainings- und Validierungsdaten, auf Basis des detaillierten Modells, für die Entwicklung des Ersatzmodells erzeugt. In einem weiteren Schritt werden die Struktur und die freien Parameter des Ersatzmodells optimiert. Die Güte des Ersatzmodells wird durch eine Kreuzvalidierung analysiert und mit Hilfe statistischer Kennzahlen bewertet. In Abbildung 8.1 ist der schematische Ablauf der Modellentwicklung zusammengefasst. Das detailliertere Vorgehen kann den folgenden Abschnitten entnommen werden. Der Schwerpunkt liegt dabei auf der Bereitstellung der Trainingsdaten mit unterschiedlichen Sample-Techniken und dem Vergleich von zwei Neuronalen Netzen und einer Support Vector Machine als Ersatzmodell.

8.2 Detailliertes Gebäudemodell

Als Basis für die weiteren Untersuchungen wird ein detailliertes Modell des in Kapitel 5 beschriebenen Einfamilienhauses erstellt. Für den Aufbau des Modells wird die kommerzielle Software „IDA Indoor Climate and Energy (IDA ICE)“ (Sahlin et al. 2004) eingesetzt. Dieses Programm gehört zur Kategorie der White-Box-Modelle und wird speziell in der thermischen Gebäudesimulation angewandt (siehe Kapitel 7).

Mit IDA ICE können detaillierte dynamische Simulationen von einzelnen Räumen/Zonen bis hin zu gesamten Gebäuden durchgeführt werden. Die Software berechnet den korrekten zeitlichen Verlauf von Energieflüssen und Komfortvariablen in den vom Anwender definierten Räumen. Dabei stehen die Zonen im Kontakt zu ihrer Umgebung, angrenzenden Bauteilen sowie den Personen, Geräten und Gegenständen welche sich in dem jeweiligen Raum befinden. Dadurch ist es möglich, die dynamische Wechselwirkung zwischen Gebäude, Gebäudetechnik, Klima und Benutzer zu berechnen. Das Programm arbeitet objektorientiert und gleichungsbasiert. Dies bedeutet, dass Komponenten des Systems, wie z.B. Fenster oder Wand, als einzelne Objekte behandelt werden.

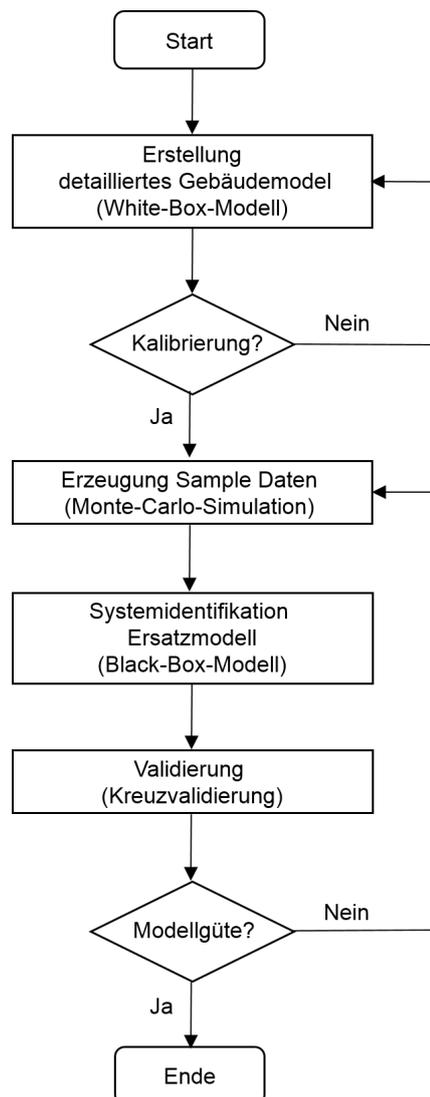


Abbildung 8.1: Schematischer Ablauf der Modellentwicklung

Dadurch wird eine gute Übersicht im Modell und eine rasche Anpassung und Änderung des Quellcodes in der Modellersprache Neutral Model Format (NMF) ermöglicht (Sahlin 1996). Auch die Entwicklung und Implementierung von neuen Modellen/Objekten kann so realisiert werden. Die Simulationsumgebung von IDA ICE besteht im Wesentlichen aus drei Hauptkomponenten. Der „IDA Modeler“ entspricht der Programmoberfläche. Auf dieser Oberfläche können Gebäudegeometrien erstellt, Modelle verbunden und Parameter definiert und eingegeben werden. Die zweite Komponente ist der „NMF-Translator“, dort werden die einzelnen Objekte des Modells angepasst oder neu erstellt. Die dritte Komponente ist der „IDA Solver“, in diesem werden die Gleichungssysteme aller Objekte gelöst und als Simulationsergebnisse ausgegeben. Abbildung 8.2 zeigt zusammenfassend einen schematischen Überblick über die Simulationsumgebung von IDA ICE.

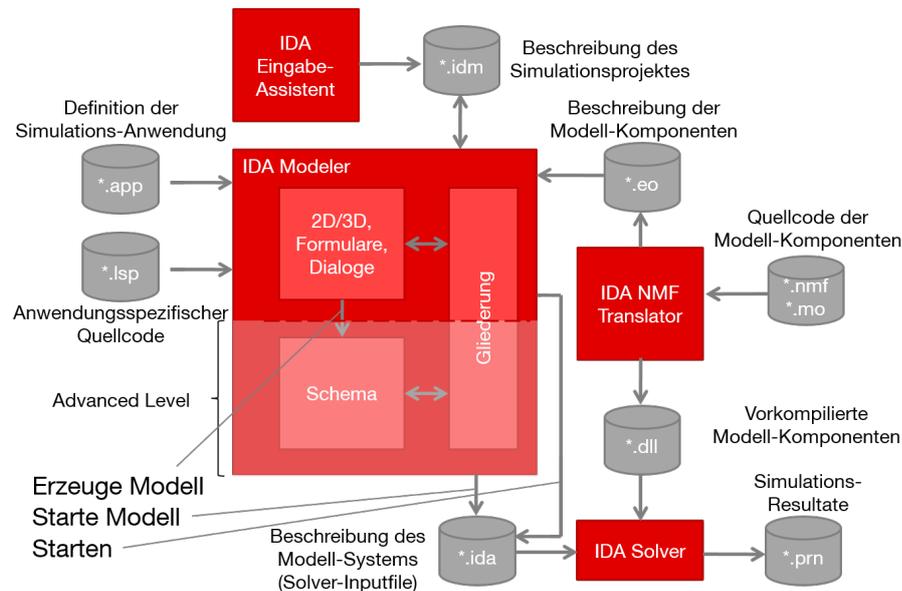


Abbildung 8.2: Simulationsumgebung von IDA Indoor Climate and Energy, eigene Darstellung nach (EQUA 2016)

8.3 Monte-Carlo-Simulation und Sample-Techniken

Die Erstellung der Trainings- und Validierungsdaten für das Ersatzmodell wird mit einer Monte-Carlo-Simulation (MCS) durchgeführt. Die MCS ist ein Verfahren aus der Stochastik und basiert auf der häufigen Wiederholung von gleichartigen Zufallsexperimenten. Eine weitverbreitete Anwendung der MCS ist die modellbasierte Unsicherheitsanalyse (UA). Ziel einer solchen Analyse ist die Quantifizierung der Unsicherheiten eines Modells, welche durch Änderungen in den Eingangsgrößen entstehen. Zu diesem Zweck wird eine häufige Wiederholung der Simulation eines Modells mit zufällig ausgewählten Werten der Eingangsgrößen vollzogen (Campolongo et al. 2000, S. 20). Das Vorgehen bei einer MCS gestützten UA kann ebenfalls für die Erstellung von Trainings- und Validierungsdaten eines Ersatzmodells verwendet werden (Eisenhower et al. 2012). Die Vorgehensweise für die Generierung der Trainingsdaten beinhaltet folgende Schritte analog zu einer MCS basierten UA (Campolongo et al. 2000, S. 20-24):

- i) Auswahl der Eingangsgrößen für das Ersatzmodell z.B. $x_1, x_2 \dots x_j$.
- ii) Definition einer Wahrscheinlichkeitsverteilung für die Eingangsgrößen z.B. eine Normalverteilung $X_1 \sim \mathcal{N}(\mu, \sigma^2)$ oder eine Gleichverteilung $X_j \sim U(a, b)$.
- iii) N -fache Auswahl (Sampling) einer Stichprobe aus den jeweiligen Wahrscheinlichkeitsverteilungen z.B. $x_1^{(1)}, x_2^{(1)} \dots x_j^{(1)}$ und Erstellung einer Samplematrix.
- iv) N -fache Simulation des detaillierten Modells unter Verwendung von $x_1^{(1)}, x_2^{(1)} \dots x_j^{(1)}$ als Eingangsdaten.

Abbildung 8.3 stellt den schematischen Ablauf der Datenerzeugung mit Hilfe einer MCS dar. Dabei werden Wahrscheinlichkeitsverteilungen für die Eingangsgrößen $X_1 \dots X_j$ definiert und mit Hilfe von Sample-Techniken Stichproben $x_1^{(1)} \dots x_j^{(1)}$ ausgewählt und zu einer Samplematrix zusammengefasst. Anschließend wird das Modell N -fach simuliert und die Ergebnisse der Ausgangsgröße(n) $y^{(1)} \dots y^{(N)}$ erfasst.

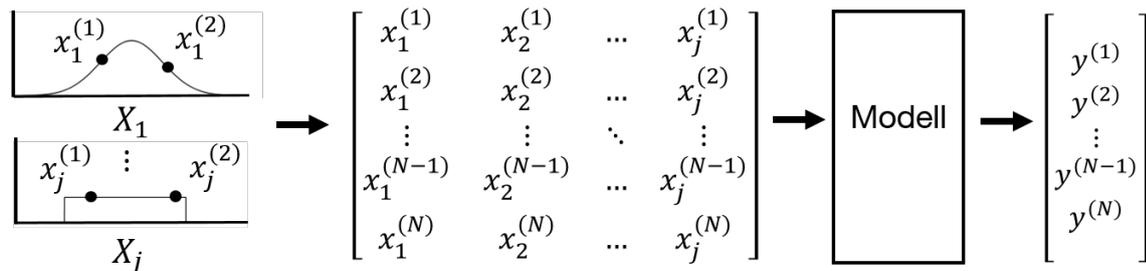


Abbildung 8.3: Schematischer Ablauf der Datenerzeugung mit einer Monte-Carlo-Simulation

Die verwendete Sample-Technik bei einer MCS hat einen großen Einfluss auf die Güte der Trainingsdaten, sowie auf die benötigte Rechenzeit des gesamten Prozesses. Ziel einer Sample-Technik ist es, mit möglichst geringer Stichprobenanzahl N die Wahrscheinlichkeitsverteilung repräsentativ abzubilden. Die Anzahl der Stichproben N bestimmt den benötigten Rechenaufwand, da N die Anzahl der notwendigen Modellsimulationen darstellt (Burhenne 2013, S. 37). Im Folgenden werden drei Sample-Techniken vorgestellt (Campolongo et al. 2000, S. 21-22):

Random Sampling - Beim Random Sampling werden die Stichproben mit Hilfe sogenannter Pseudozufallszahlen ausgewählt. Diese können mit einem Zufallsgenerator erzeugt werden, welcher standardmäßig in fast allen Programmiersprachen vorhanden ist.

Latin Hypercube Sampling (LHS) - Die Methode des Latin Hypercube Sampling ist ein Spezialfall des Stratified Samplings (Campolongo et al. 2000, S. 22). Die Basis der Methode bilden ebenfalls Pseudozufallszahlen. Jedoch wird die abzubildende Verteilung in N Bereiche mit gleicher Wahrscheinlichkeitsdichte eingeteilt. Dabei wird für jeden Bereich nur eine Stichprobe erzeugt. Dies reduziert die Clusterbildung von Stichproben, welche beim Random Sampling auftreten können.

Sobol Sequenzen - Die Grundlagen der Sobol Sequenzen bilden sogenannte Quasizufallszahlen. Diese werden, im Vergleich zu Pseudozufallszahlen, nicht unabhängig erzeugt, sondern unter Berücksichtigung der vorherigen Stichprobe systematisch konstruiert (Burhenne 2013, S. 42). Dadurch ist eine gleichmäßigere Abbildung der Wahrscheinlichkeitsverteilung mit geringerer Anzahl von Stichproben möglich.

Abbildung 8.4 zeigt einen Vergleich der drei vorgestellten Sample-Techniken bei der Abbildung einer Normalverteilung mit einer Stichprobenanzahl von $N=20$. Es wird deutlich, dass die Techniken LHS und Sobol die Normalverteilung besser wiedergeben als die Stichproben mit einem Random Sampling. Detailliertere Ergebnisse eines Vergleichs der drei Techniken werden in Kapitel 9 vorgestellt.

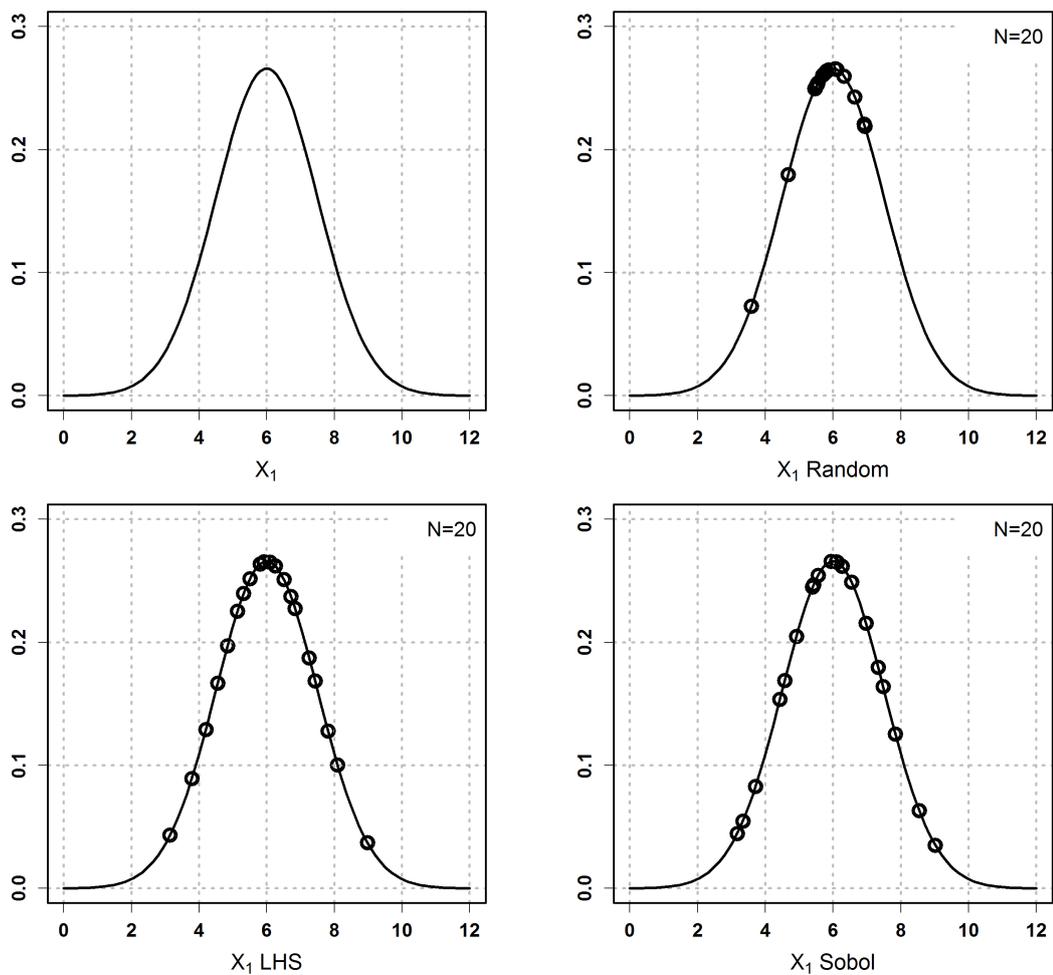


Abbildung 8.4: Vergleich von unterschiedlichen Sample-Techniken anhand einer Normalverteilung

8.4 Neuronale Netze

Das menschliche Gehirn besteht aus einzelnen Neuronen, die zu einem Netzwerk verbunden sind. Einem künstlichen Neuronalen Netz dient diese „Struktur“ als Vorlage, um dadurch empirische Modelle zu entwickeln. Der typische Aufbau eines künstlichen Neuronalen Netzwerks besteht ebenfalls aus einzelnen Neuronen, welche miteinander in Verbindung stehen. Dabei empfangen die einzelnen Neuronen Informationen und geben diese in modifizierter Form weiter (Magoules und Zhao 2016). Neuronale Netze gehören zu Kategorie der Black-Box-Modelle (Nelles 2001). Eine häufige Anwendung ist die Modellbildung im Bereich der nichtlinearen Regression oder Klassifizierung (Kuhn und Johnson 2013). Die Aufgabenstellung im Rahmen dieser Arbeit gehört in den Bereich der nichtlinearen Regression. Deshalb liegt der Schwerpunkt in den folgenden Abschnitten auf dem Anwendungsfall Regression.

Eine der ersten Arbeiten im Bereich der Neuronalen Netze aus dem Jahr 1943 untersuchte ein einzelnes Neuron, welches mehrere Eingangssignale addiert und abhängig von einem Schwellwert in ein binäres Signal $[0,1]$ umwandelt (McCulloch und Pitts 1943). Der Durchbruch der Neuronalen Netze gelang 1986 mit der Entwicklung des sogenannten Backpropagation-Verfahrens (Rumelhart und McClelland 1986). Mit Hilfe dieses Verfahrens ist eine effiziente Optimierung der Verbindungsgewichte und somit auch eine effiziente Erstellung des Neuronalen Netzes möglich. Durch das sogenannte „Deep Learning“ erlebt das Gebiet aktuell wieder starke Aufmerksamkeit (Silver et al. 2016). Dabei können durch eine Aneinanderreihung von mehreren Netzen komplexere Modelle mit einer höheren Güte erstellt werden. Der erfolgreiche Einsatz des Deep Learning kann vor allem auf die rasante Entwicklung der Rechenleistung von z.B. „Cloud Computing“ zurückgeführt werden (Moore 1965).

8.4.1 Systemidentifikation mit Neuronalen Netzen

Die Systemidentifikation/Modellbildung mit einem Neuronalen Netz basiert auf der Analyse der Ein- und Ausgangssignale des abzubildenden Systems. Im Rahmen dieser Arbeit wird als System das detaillierte Gebäudemodell herangezogen. In Abbildung 8.5 ist der schematische Ablauf der Systemidentifikation mit einem Neuronalen Netz dargestellt. Dabei reagiert das System auf das Eingangssignal p mit einem Ausgangssignal y . Im Rahmen dieser Arbeit werden das Ein- und Ausgangssignal mit Hilfe einer Monte-Carlo-Simulation erstellt (siehe Kapitel 8.3). Das Neuronale Netz erhält ebenfalls das Eingangssignal p und berechnet dafür, in Abhängigkeit von der definierten Struktur und den Verbindungsgewichten, das Ausgangssignal \hat{y} . Aus dem Modellfehler $e = y - \hat{y}$ ermittelt sich die Kostenfunktion (Gleichung 8.5), welche als Maß für die Modellgüte verwendet wird. Ziel der Modellbildung ist es, die Struktur und die Verbindungsgewichte (Parameteroptimierung) des Neuronalen Netzes so zu optimieren, dass der Kostenfunktionswert möglichst gering wird (Endisch 2009).

Die Systemidentifikation kann in die Phasen „Lernen“ und „Testen“ eingeteilt werden. Dabei werden die Ein- und Ausgangsdaten des abzubildenden Systems in Trainingsdaten und Validierungsdaten (Testdaten) unterschieden. In der Lernphase sind dem Neuronalen Netz die Ein- und Ausgangssignale bekannt. In dieser Phase verändert ein Optimierungsalgorithmus die Parameter (Verbindungsgewichte) im Modell, um einen möglichst geringen Modellfehler zu erreichen. Die Abweichungen werden als Trainingsfehler bezeichnet. Während der Test- bzw. Validierungsphase werden dem bereits „trainierten“ Netzwerk mit einer zweiten unabhängigen Datenmenge lediglich die Eingangsdaten des Systems zur Verfügung gestellt. Die daraus resultierenden Ausgangssignale des gelernten Neuronalen Netzes können anschließend mit denen des Systems verglichen (Kreuzvalidierung) und der Validierungsfehler ermittelt werden. Dieser Validierungsfehler charakterisiert die Generalisierungsfähigkeit des trainierten Netzwerks, da dieser mit einem zu den Trainingsdaten unabhängigen Datensatz errechnet wird (Endisch 2009).

Im Rahmen dieser Arbeit wird bei der Systemidentifikation mit den Ersatzmodellen des Weiteren zwischen einer internen Optimierung (Abbildung 8.5 dunkelgrauer Bereich) und externen Optimierung (Abbildung 8.5 hellgrauer Bereich) unterschieden. Die interne Optimierung (Parameteroptimierung) spiegelt die Anwendung eines Algorithmus wider, welcher ohne Einfluss des Anwenders arbeitet. Die externe Optimierung (Strukturoptimierung) wird in dieser Arbeit hauptsächlich vom Anwender durchgeführt.

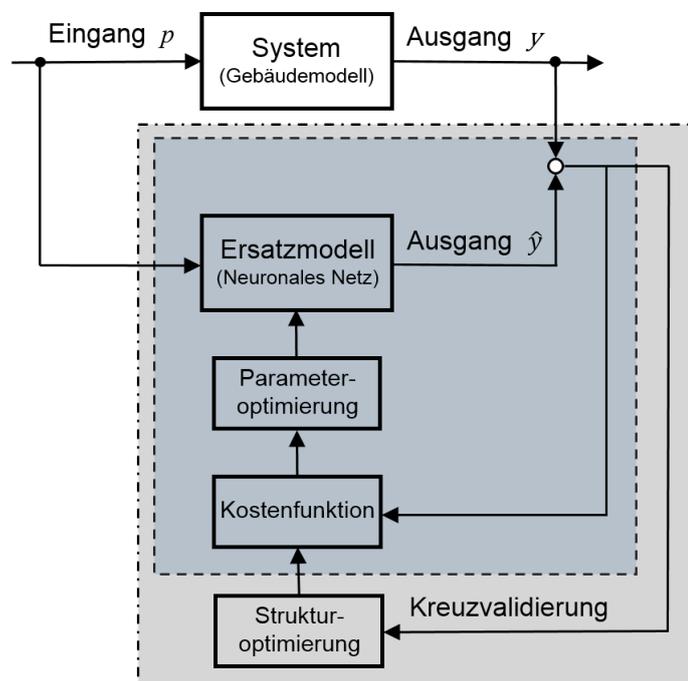


Abbildung 8.5: Schematischer Ablauf der Systemidentifikation mit einem Neuronales Netz, eigene Darstellung nach (Endisch 2009)

8.4.2 Unterschiedliche Modelle Neuronaler Netze

Es existieren eine Vielzahl unterschiedlicher Modellansätze im Bereich der Neuronalen Netze. Diese können vereinfacht in statische und dynamische Modelle unterteilt werden. In einem statischen Netz besitzen die Neuronen keine rückwärts gerichteten Verbindungen bzw. Rückkopplungen und auch keine Verzögerungen des Eingangssignals. Deshalb berechnet sich auch der Modellausgang direkt aus den aktuellen Eingangssignalen. Diese Art von Netzen wird auch „Feedforward-Netz“ genannt (siehe Kapitel 7.3.1). Bei dynamischen Netzen hingegen existieren „Zustände“ im Modell. Der Modellausgang ist nicht nur vom aktuellen Eingangssignal abhängig, sondern auch von verzögerten Eingangssignalen oder Rückkopplungen (Endisch 2009). Die Verwendung der jeweiligen Kategorie hängt stark vom abzubildenden System und dessen Ausgangsgrößen ab. Bei einer Anwendung in der Gebäudesimulation lässt sich aus der Literatur ableiten, dass bei Ausgangssignalen, welche eine starke zeitliche Abhängigkeit besitzen, wie z.B. der Lastverlauf oder die Raumtemperatur, ein dynamisches Netzwerk bessere Resultate erzielt (Kreider, Claridge, et al. 1995; Lu und Viljanen 2009; Maderspacher et al. 2015). Bei Ausgangssignalen, welche zeitlich weniger abhängig sind, wie z.B. der Energiebedarf pro Jahr, kann auch mit statischen Netzen eine belastbare Modellgüte erzielt werden (Olofsson und Andersson 2001; Maderspacher et al. 2016).

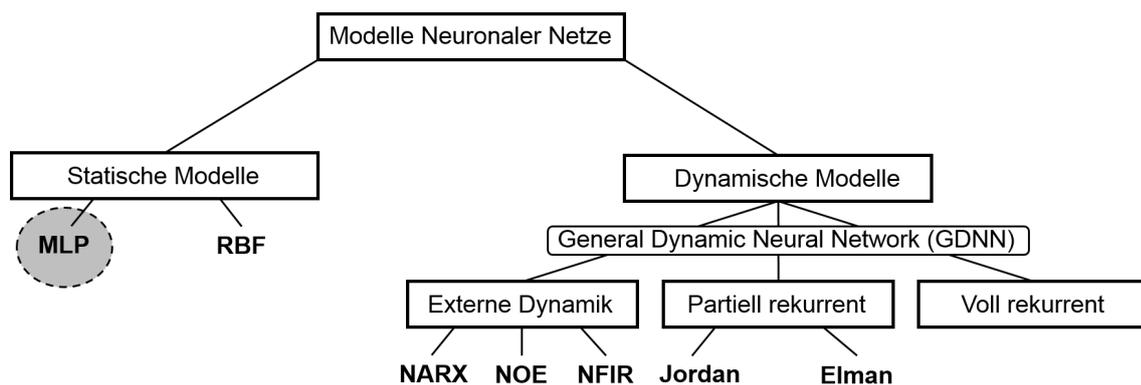


Abbildung 8.6: Übersicht der Modellarten Neuronaler Netze, eigene Darstellung nach (Endisch 2009)

Im weiteren Verlauf der Arbeit wird der Energiebedarf für das Heizen und Kühlen in kWh/m²a sowie die Übertemperaturgradstunden in Kh/a¹ als Ausgangssignal verwendet. Diese Größen haben untereinander eine geringe zeitliche Abhängigkeit, da z.B. der Energiebedarf eines Jahres nur indirekt mit einem Energiebedarf eines anderen Jahres zusammenhängt. Deshalb wird ein statisches Modell - Multi Layer Perceptron (MLP) - für die Analysen ausgewählt (Abbildung 8.6). Des Weiteren hat sich der Autor bei den Vorarbeiten zu dieser Arbeit mit einem dynamischen Netzwerk (GDNN) in Maderspacher et al. (2015) und einem statischen Netzwerk (MLP) in Maderspacher et al. (2016) auseinandergesetzt und leitet daraus die Verwendung des Multi Layer Perceptron für die Aufgabenstellung der Dissertation ab.

¹ Übertemperaturgradstunden sind ein Maß für die sommerliche Überhitzung von Gebäuden. Im Rahmen dieser Arbeit wird ein Grenzwert aus der (DIN 4108-2 2013) herangezogen.

8.4.3 Aufbau eines Multi Layer Perceptron

Ein MLP-Netz besitzt in der Regel nur vorwärts verbundene Neuronen und gehört deshalb zur Kategorie der statischen Modelle. Der Aufbau eines MLP besteht aus drei verschiedenen Typen von Schichten in denen sich die einzelnen Neuronen befinden. Diese Schichten werden „Eingangsschicht“, „Verdeckte Schicht“ und „Ausgangsschicht“ genannt (Abbildung 8.8), wobei die Anzahl der verdeckten Schichten beliebig hoch sein kann (Endisch 2009). Die Anzahl der Neuronen pro Schicht kann ebenfalls frei gewählt werden. Somit bilden die Anzahl der Neuronen, Eingangssignale, Ausgangssignale und der verdeckten Schichten die „Freien Parameter“ eines Neuronalen Netzwerks und sind die Grundlage der Strukturoptimierung.

Die kleinste Recheneinheit eines MLP und eines Neuronalen Netzes im Allgemeinen ist das Neuron (siehe Abbildung 8.7a). Die Eingangssignale p_1 bis p_k werden zunächst mit den sogenannten Verbindungsgewichten w_1 bis w_k multipliziert und anschließend mit einem Faktor b für die Lage der Transferfunktion aufsummiert. Der Summenausgang n wird anschließend durch eine Transferfunktion $f(n)$ in den Neuronenausgang a transferiert. Der Summenausgang n und der Neuronenausgang a berechnen sich wie folgt (Endisch 2009):

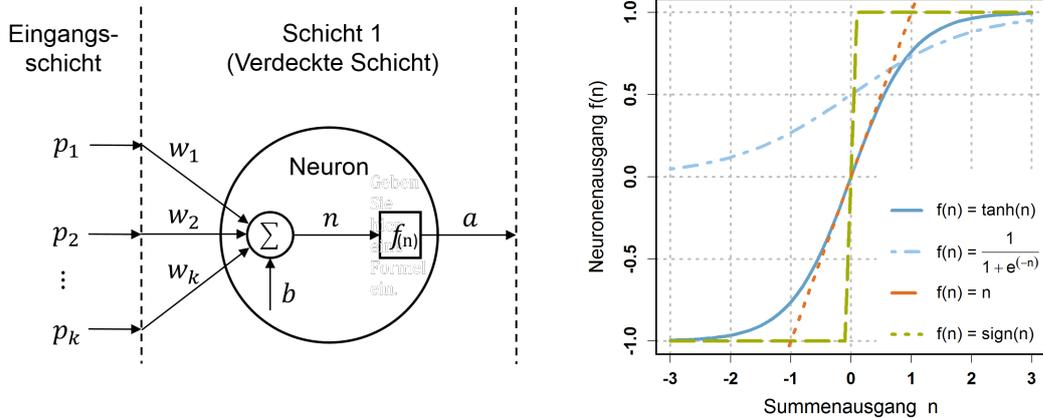
$$n = \sum_{i=1}^k w_i \cdot p_i + b \quad (8.1)$$

Der Neuronenausgang a wird anschließend mit Hilfe einer Transferfunktion $f(n)$ berechnet.

$$a = f(n) \quad (8.2)$$

In Abbildung 8.7b werden die am häufigsten verwendeten Transferfunktionen dargestellt:

- i) Tangens-Hyperbolicus-Funktion: $a = \tanh(n)$
- ii) Logistikkfunktion: $a = \left(\frac{1}{1+e^{-n}} \right)$
- iii) Lineare Funktion: $a = c \cdot n$
- iv) Signumfunktion (Schwellwertfunktion): $a = \text{sign}(n)$



(a) Aufbau eines Neurons, eigene Darstellung nach (Endisch 2009) (b) Exemplarische Transferfunktionen für die Neuronen eines MLP

Abbildung 8.7: Darstellung eines Neurons und mögliche Transferfunktionen $f(n)$

Bei einem MLP wird in der Regel die Tangens-Hyperbolicus-Funktion oder die Logistikkfunktion angewandt. Beide Funktionen besitzen die Eigenschaft einen unendlich ausgedehnten Eingangszahlenraum auf einen endlichen Ausgangsbereich abzubilden (Endisch 2009). Ein einzelnes Neuron hat nur eine beschränkte Fähigkeit eine Funktion bzw. System abzubilden. Deshalb werden in einem Neuronalen Netz mehrere Schichten miteinander verbunden, wobei jede Schicht beliebig viele Neuronen enthalten kann. Erst durch die Verbindung der einzelnen Neuronen über ein Netzwerk aus Schichten ist es möglich, auch komplexe Funktionen oder Systeme zu approximieren (Endisch 2009).

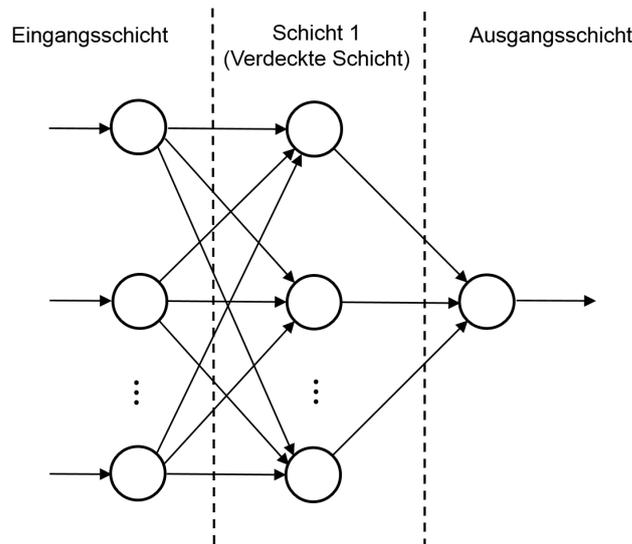


Abbildung 8.8: Schema eines MLP mit einer Eingangsschicht, einer verdeckten Schicht und einer Ausgangsschicht

In Abbildung 8.8 ist der schematische Aufbau eines MLP mit einer Eingangsschicht, einer verdeckten Schicht und einer Ausgangsschicht dargestellt. Durch die Notation in der detaillierten Darstellung des MLP in Abbildung 8.9 kann die Modellgleichung 8.3 für das Ausgangssignal \hat{y} des MLP's abgeleitet werden. In der detaillierten Notation wird eine Matrix durch einen Großbuchstaben und ein Vektor mit Hilfe eines Unterstrichs dargestellt, weitere Einzelheiten zur verwendeten Notation können aus (Hagan et al. 1996) und (Endisch 2009) entnommen werden.

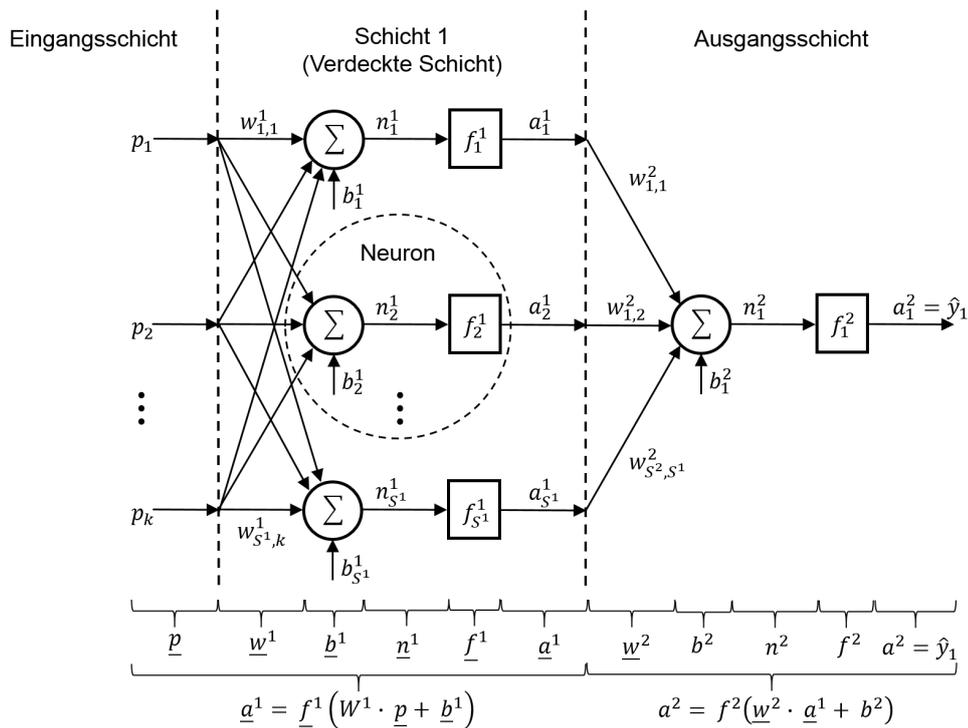


Abbildung 8.9: Detaildarstellung eines MLP mit einer Eingangsschicht, einer verdeckten Schicht und einer Ausgangsschicht, eigene Darstellung nach Hagan et al. (1996) und Endisch (2009)

$$\hat{y}_1 = f^2(\underline{w}^2 \cdot \underline{f}^1(W^1 \cdot \underline{p} + \underline{b}^1) + b^2) \quad (8.3)$$

8.4.4 Struktur- und Parameteroptimierung eines Multi Layer Perceptron

Die Modellgleichung 8.3 des MLP wird anhand der Struktur des Netzwerks ermittelt (siehe Abbildung 8.9). Die Struktur eines MLP besteht im wesentlichen aus verschiedenen Schichten - Eingangsschicht, beliebige Anzahl verdeckte Schichten und der Ausgangsschicht - sowie der Anzahl von Neuronen in der jeweiligen Schicht. Diese Struktur muss vom Anwender definiert werden, da diese immer vom abzubildenden System abhängig ist und keine allgemeingültige Netzstruktur existiert. Die Bestimmung einer optimalen Struktur kann entweder manuell oder über Algorithmen durchgeführt werden (Endisch 2009). Des Weiteren müssen die Transferfunktionen für die Neuronen vom Anwender definiert werden. In der Ein- und Ausgangsschicht wird in der Regel zwischen einer linearen oder logistischen Funktion ausgewählt. Die am häufigsten verwendeten Transferfunktionen für die verdeckten Schichten ist die Tangens-Hyperbolicus-Funktion oder die Logistikfunktion (Abbildung 8.7). Die Parameteroptimierung der Verbindungsgewichte w geschieht über eine Kostenfunktion. Dabei wird häufig die Kostenfunktion des summierten quadratischen Modellfehlers verwendet. Der Modellfehler e wird über die Abweichung des Ausgangssignals des Neuronalen Netzes \hat{y} vom Ausgangssignals des Systems y ermittelt. Gleichung 8.4 zeigt die Berechnung des Modellfehlers (Endisch 2009):

$$e(w) = y - \hat{y}(w) \quad (8.4)$$

Gleichung 8.5 zeigt die Kostenfunktion des summierten quadratischen Modellfehlers, wobei Q die Anzahl der Trainingsdaten repräsentiert:

$$E(w) = \sum_{q=1}^Q (y_q - \hat{y}_q(w))^T \cdot (y_q - \hat{y}_q(w)) \quad (8.5)$$

aus der Gleichung 8.5 kann folgendes Optimierungsproblem abgeleitet werden:

$$\min E(w); \quad w \in \mathbb{R}^N \quad (8.6)$$

Diese Optimierungsaufgabe gehört in die Kategorie der nichtlinearen Probleme ohne Nebenbedingungen (Shepherd 1997). Für die Lösung einer solchen Aufgabe existieren meist keine analytischen Verfahren (Endisch 2009). Daher kommen entweder deterministische oder stochastische Optimierungsalgorithmen zum Einsatz (Details in Teil IV). Stochastische Optimierungsverfahren weisen in der Regel einen hohen Rechenaufwand auf. Deshalb werden für die Parameteroptimierung der Verbindungsgewichte in Neuronalen Netzen meist deterministische Algorithmen eingesetzt (Endisch 2009).

Die Auswahl eines geeigneten Optimierungsalgorithmus bleibt, wie die Definition der Struktur und der Transferfunktionen, ebenfalls den Anwendern überlassen. Deshalb werden im Rahmen dieser Arbeit in den folgenden Abschnitten zwei unterschiedliche Methoden für die Optimierung der Verbindungsgewichte analysiert. Es werden dabei folgende zwei Algorithmen untersucht²:

- i) Backpropagation-Algorithmus (Spezialfall des Gradientenverfahrens).
- ii) Quasi-Newton-Verfahren nach Broyden, Fletcher, Goldfarb und Shannon (BFGS).

8.5 Support Vector Machines

Die Methode der Support Vector Machines (SVM), auch Stützvektormethode genannt, dient der Erstellung von Modellen auf Basis von Daten. Die Technik der SVM hat ihren Ursprung im Bereich des statistischen Lernens (Vapnik 1995). Die mit Hilfe einer SVM erstellten Modelle gehören deshalb zur Kategorie der Black-Box-Modelle. Bei einer SVM werden die zu untersuchenden Daten mit Hilfe des Kernel-Tricks (Smola und Schölkopf 2002) in einen mehrdimensionalen Raum transformiert. Dadurch entsteht die Möglichkeit, lineare Techniken auf nichtlineare Problemstellungen anzuwenden (Karatzoglou et al. 2006). Eine häufige Anwendung ist die Modellbildung im Bereich der nichtlinearen Regression oder Klassifizierung. Bei einer Verwendung im Bereich der Regression wird die Methode auch Support Vector Regression (SVR) genannt (Magoules und Zhao 2016). Eine Besonderheit der SVM ist, dass bei der Modellentwicklung nicht nur der Trainingsfehler, sondern auch die Modellkomplexität optimiert wird (Vapnik 1995). Aufgrund der Problemstellung im Rahmen dieser Arbeit liegt der Schwerpunkt in den folgenden Abschnitten auf der Beschreibung einer Support Vector Regression.

Ein erster Algorithmus zur Umsetzung einer SVM wurde in den 1960er Jahren in Russland entwickelt. Er stellt eine nichtlineare Verallgemeinerung des „Generalized Portrait“ Algorithmus dar (Vapnik und Lerner 1963; Vapnik und Chervonenkis 1964). Die Methode der SVM ist ein wesentlicher Bestandteil der Theorie des statistischen Lernens (Smola und Schölkopf 2004), welche seit den 1970er Jahren entwickelt wird (Vapnik und Chervonenkis 1974; Vapnik 1982; Vapnik 1995). Die SVM in ihrer jetzigen Form entstand maßgebend an den AT&T Bell Laboratories und wurde von Vapnik und seinen Mitarbeitern erarbeitet (Boser et al. 1992; Cortes und Vapnik 1995; Schölkopf et al. 1995; Vapnik, Golowich, et al. 1997).

8.5.1 Systemidentifikation mit einer Support Vector Regression

Die Systemidentifikation/Modellbildung mit einer Support Vector Regression basiert, wie bei einem Neuronalen Netz, auf der Analyse der Ein- und Ausgangssignale des detaillierten Gebäudemodells. In Abbildung 8.10 ist der schematische Ablauf der Systemidentifikation mit einer SVR dargestellt. Dabei reagiert das System auf das Eingangssignal p mit einem Ausgangssignal y . Im Rahmen dieser Arbeit werden das Ein- und Ausgangssignal mit Hilfe

² Auf eine detaillierte Beschreibung dieser beiden Verfahren wird an dieser Stelle verzichtet. Eine Beschreibung der Methoden und weitere Grundlagen zu Neuronalen Netzen können aus Endisch (2009) entnommen werden.

einer Monte-Carlo-Simulation erstellt (siehe Kapitel 8.3). Die Support Vector Regression erhält ebenfalls das Eingangssignal p und berechnet dafür, in Abhängigkeit von der definierten Struktur und der Parameteroptimierung, das Ausgangssignal \hat{y} . Ziel der Modellbildung ist es, die Struktur und die Parameteroptimierung der Support Vector Regression so abzustimmen, dass der Modellfehler $e = y - \hat{y}$ möglichst gering wird.

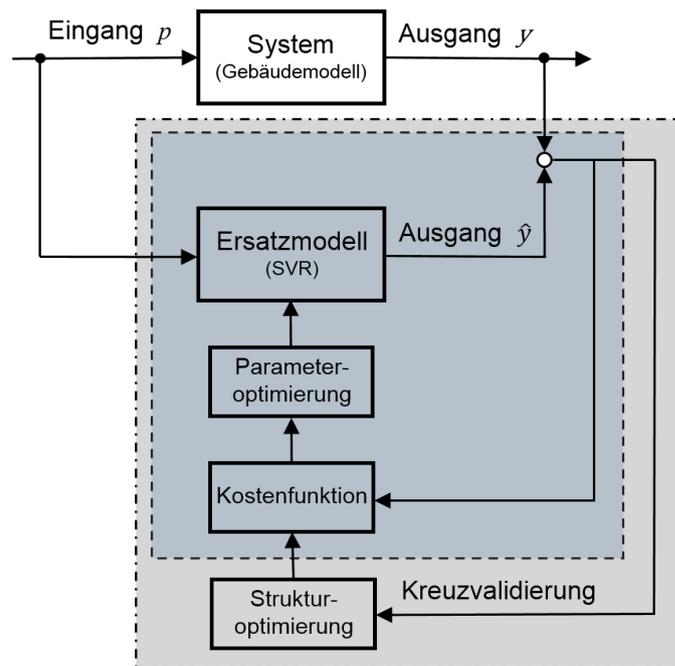


Abbildung 8.10: Schematischer Ablauf der Systemidentifikation einer Support Vector Regression

Die Systemidentifikation bei einer SVR kann, wie bei einem Neuronalen Netz, in die Phasen „Lernen“ und „Testen“ eingeteilt werden. Dabei werden die Ein- und Ausgangsdaten des abzubildenden Systems in Trainingsdaten und Validierungsdaten (Testdaten) unterteilt. In der Lernphase sind der SVR die Ein- und Ausgangssignale bekannt. In dieser Phase verändert ein Optimierungsverfahren die internen Parameter im Modell, um eine möglichst belastbare Abbildung des Ausgangssignales des Systems zu erreichen. Während der Test- bzw. Validierungsphase werden der bereits „trainierten“ SVR mit einer zweiten unabhängigen Datenmenge lediglich die Eingangsdaten des Systems zur Verfügung gestellt. Die daraus resultierenden Ausgangssignale der gelernten Support Vector Regression können anschließend mit denen des Systems verglichen (Kreuzvalidierung) und der Validierungsfehler ermittelt werden.

Auch bei der Systemidentifikation mit einer SVR wird zwischen einer internen Optimierung (Abbildung 8.10 dunkelgrauer Bereich) und einer externen Optimierung (Abbildung 8.10 hellgrauer Bereich) unterschieden. Die interne Optimierung (Parameteroptimierung) spiegelt die Anwendung eines Algorithmus wieder, welcher ohne Einfluss des Anwenders arbeitet. Die externe Optimierung (Strukturoptimierung) wird in dieser Arbeit vom Anwender durchgeführt.

8.5.2 Aufbau und Parameteroptimierung einer Support Vector Regression

Das Ziel einer Epsilon Support Vector Regression (ε -SVR) ist das Auffinden einer Funktion $\hat{y}(x)$, welche den größtmöglichen Abstand zu allen Trainingsdaten der Zielgröße y außerhalb eines ε -Bereiches aufweist (Smola und Schölkopf 2004). Die Verwendung aller Trainingsdaten zur Erstellung der Funktion führt zu einem starken Anstieg der Modellkomplexität. Deshalb werden im ε -Bereich der Funktion die Datenpunkte nicht zum Lernen des Modells verwendet (Kuhn und Johnson 2013). Diese Daten werden in Abbildung 8.11 durch Kreuze („x“) dargestellt. Alle anderen Punkte werden zur Erstellung der Funktion verwendet. Diese Punkte werden auch Stützvektoren (support vectors) genannt.

Im Fall eines linearen Zusammenhangs von Trainingsdaten $\{(x_1, y_1), \dots, (x_l, y_l)\} \subset X \times \mathbb{R}$, wobei X den Raum der Eingangssignale darstellt, hat die Funktion $\hat{y}(x)$ die Form (Smola und Schölkopf 2004):

$$\hat{y}(x) = \langle w, x \rangle + b, \quad w \in X, b \in \mathbb{R} \quad (8.7)$$

Dabei ist \hat{y} das prognostizierte Ausgangssignal des Ersatzmodells, w ein Gewichtsvektor, b ein Korrekturfaktor und $\langle \cdot, \cdot \rangle$ ein Skalarprodukt in X . Zur Maximierung des Abstandes der Funktion $\hat{y}(x)$ zu den Trainingsdaten der Zielgröße y kann w minimiert werden. Dies führt zu einem konvexen Optimierungsproblem (Smola und Schölkopf 2004):

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2; \\ \text{s.t.} \quad & y_i - \langle w, x_i \rangle - b \leq \varepsilon; \\ & \langle w, x_i \rangle + b - y_i \leq \varepsilon; \quad i = 1, 2, \dots, l \end{aligned} \quad (8.8)$$

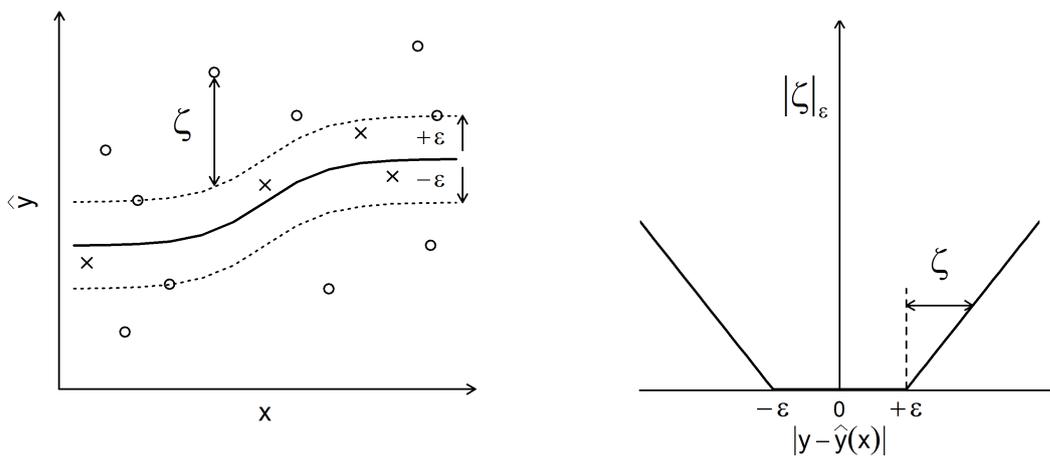
Für das in 8.8 beschriebene Optimierungsproblem können Fälle auftreten in denen die Nebenbedingungen nicht zulässig sind. Dies kann durch die Einführung von sogenannten Schlupfvariablen (ζ_i, ζ_i^*) vermieden werden. Das erweiterte Optimierungsproblem stellt die Grundform der Kostenfunktion für die interne Parameteroptimierung von $\|w\|^2$ einer ε -SVR dar (Vapnik 1995):

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\zeta_i + \zeta_i^*); \\ \text{s.t.} \quad & y_i - \langle w, x_i \rangle - b \leq \varepsilon + \zeta_i; \\ & \langle w, x_i \rangle + b - y_i \leq \varepsilon + \zeta_i^*; \\ & \zeta_i, \zeta_i^* \geq 0; \quad i = 1, 2, \dots, l \end{aligned} \quad (8.9)$$

Die Parameter C und ε regulieren den Zielkonflikt zwischen Modellkomplexität und Robustheit der Regression und müssen vom Anwender definiert werden. Die Formulierung der Zielfunktion in 8.9 beinhaltet die für eine ε -SVR typische Verlustfunktion $|\zeta|_\varepsilon$ 8.10. Diese Verlustfunktion ermittelt den Abstand bzw. die „Kosten“ (ζ) eines jeden Datenpunktes (support vectors) außerhalb des ε -Bereiches (siehe Abbildung 8.11).

$$|\zeta|_\varepsilon := \begin{cases} 0 & \text{für } |y - \hat{y}(x)| \leq \varepsilon \\ |y - \hat{y}(x)| - \varepsilon & \end{cases} \quad (8.10)$$

Abbildung 8.11a zeigt eine exemplarische Darstellung eines ε -Bereiches um eine Funktion $\hat{y}(x)$. Die Datenpunkte im ε -Bereich (Kreuze) werden nicht zur Modellbildung verwendet. Alle anderen Datenpunkte (Kreise) dienen als Stützvektoren (support vectors) für Erstellung der Funktion. Mit Hilfe der Verlustfunktion $|\zeta|_\varepsilon$ in Abbildung 8.11b werden die „Kosten“ (ζ) der einzelnen Datenpunkte zum ε -Bereich ermittelt.



(a) Abbildung eines ε -Bereiches um eine Funktion $\hat{y}(x)$

(b) Verlustfunktion $|\zeta|_\varepsilon$ einer ε -SVR

Abbildung 8.11: Grafische Darstellung der Verlustfunktion einer ε -SVR

Vapnik (1995) zeigt, dass sich das Optimierungsproblem 8.9 effizient durch die Verwendung von Lagrange-Multiplikatoren lösen lässt. Durch die Anwendung der Lagrange-Multiplikatoren kann der Gewichtsvektor w umformuliert werden und bildet dadurch die Grundlage für eine Erweiterung der ε -SVR zum Einsatz bei nichtlinearen Problemen (Details siehe Vapnik (1995) und Smola und Schölkopf (2004)):

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i \quad (8.11)$$

Daraus kann Gleichung 8.7 folgendermaßen umformuliert werden:

$$\hat{y}(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b \quad (8.12)$$

Für eine Abbildung von nichtlinearen Systemen mit Hilfe der ε -SVR werden die Trainingsdaten x_i in einen mehrdimensionalen Raum F transformiert $\Phi : X \rightarrow F$ und das Skalarprodukt $\langle \cdot, \cdot \rangle$ der Trainingsdaten mit Hilfe des Kernel-Tricks (Smola und Schölkopf 2002) durch eine sogenannte Kernelfunktion $K(x, x')$ ersetzt. Daraus folgt:

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) \Phi(x_i) \quad (8.13)$$

Die finale Modellgleichung für das Ausgangssignal \hat{y} einer nichtlinearen ε -SVR lautet:

$$\hat{y}(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (8.14)$$

8.5.3 Strukturoptimierung einer Epsilon Support Vector Regression

Die Herleitung der Modellgleichung 8.14 und der Ablauf der Parameteroptimierung einer ε -SVR wird in den vorherigen Abschnitten beschrieben. Analog zur Struktur eines Neuronalen Netzes müssen für eine ε -SVR ebenfalls Komponenten vom Anwender definiert werden. Dazu zählen die Art und Anzahl von Ein- und Ausgangssignalen sowie die Auswahl einer geeigneten Kernelfunktion. Eine der am häufigsten verwendeten Kernelfunktionen im Bereich der Gebäudesimulation ist die Gaußsche Radiale Basisfunktion (RBF) (Jain et al. 2014).

$$K(x, x') = \exp\left(-\sigma \|x - x'\|^2\right) \quad (8.15)$$

Der Parameter σ in der dargestellten RBF ist neben den Parametern C und ε aus der Kostenfunktion der ε -SVR 8.9 ebenfalls vom Anwender zu ermitteln. Die Ermittlung eines optimalen Verhältnisses dieser drei Parameter bildet den Schwerpunkt bei der Modellerstellung mit einer ε -SVR.

8.6 Kreuzvalidierung und statistische Kenngrößen

Als Grundlage für die Erstellung des Ersatzmodells durch ein Neuronales Netz oder einer Support Vector Regression werden mit Hilfe einer Monte-Carlo-Simulation und dem detaillierten Gebäudemodell Sample-Daten erzeugt. Diese Datenmenge wird auf Basis einer einfachen Kreuzvalidierung in 50% Trainingsdaten und 50% Validierungsdaten aufgeteilt. Der Zusammenhang zwischen Modellgüte und Anzahl Trainingsdaten wird durch eine Variation der gesamten Anzahl von Sample-Daten in den Schritten 1.000, 4.000 und 16.000 analysiert.

Während der Lernphase dienen die Trainingsdaten als Grundlage für die Modellerstellung. In dieser Phase sind dem Ersatzmodell die Ein- und Ausgangssignale bekannt. In der Testphase werden dem Ersatzmodell lediglich die Eingangssignale der Validierungsdaten übermittelt. Das vom Ersatzmodell prognostizierte Ausgangssignal wird anschließend mit dem Ausgangssignal des detaillierten Gebäudemodells verglichen. Durch die Abweichung kann der Validierungsfehler ermittelt werden. Die Bestimmung des Validierungsfehlers geschieht meist mit Hilfe von statistischen Kenngrößen. In dieser Arbeit werden der Root Mean Squared Error (RMSE), der Coefficient of Variation (CV) und das Bestimmtheitsmaß (R^2) verwendet.

Der RMSE sagt aus, wie groß die durchschnittliche Abweichung einer Prognose zu den Originaldaten ist. Man kann den RMSE mit einer Art Standardabweichung einer Normalverteilung vergleichen. Dieser Kennwert bietet den Vorteil, dass der Fehler in der Einheit der Originaldaten dargestellt wird (Kuhn und Johnson 2013).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8.16)$$

Im Vergleich zum RMSE ist der Coefficient of Variation ein relativer Fehler. Die Einheit des Fehlers wird in Prozent angegeben. Der Kennwert gibt die durchschnittliche prozentuale Abweichung der Modellprognose gegenüber dem Originalsystem an. Der CV kann auch als „Verallgemeinerung“ des RMSE gesehen werden (Reddy 2011). Mit Hilfe des CV kann die Modellgüte, unabhängig der Zielgröße, von unterschiedlichen Modellierungstechniken verglichen werden.

$$CV = \frac{RMSE}{\bar{y}} * 100 \quad (8.17)$$

Bei einer Kreuzvalidierung werden für die Analyse der Prognosegüte häufig das Ausgangssignal des Systems und des Modells grafisch gegenübergestellt. Dabei wird das Bestimmtheitsmaß R^2 gebildet. Das R^2 gibt an, wie viel Informationen des Systems durch das Modell abgebildet werden kann (Kuhn und Johnson 2013). Des Weiteren ist es auch ein Maß für die Korrelation der beiden Ausgangssignale.

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (8.18)$$

In den Gleichungen 8.16, 8.17, 8.18 repräsentiert y das Ausgangssignal des Systems, \hat{y} das Ausgangssignal des Ersatzmodells, \bar{y} den Mittelwert der Ausgangssignale des Systems und n die gesamte Anzahl der Signale. Für die Kennwerte RMSE und CV gilt, je kleiner der Wert, desto höher die Modellgüte. Beim Bestimmtheitsmaß gilt je größer der Wert, desto höher die Modellgüte, wobei R^2 im Bereich zwischen $[0,1]$ liegen kann.

9 | Resultate und Diskussion

9.1 Versuchsaufbau

Die folgenden Abschnitte präsentieren Resultate zu unterschiedlichen Sample-Techniken, der Strukturoptimierung und der Kreuzvalidierung der Ersatzmodelle. Als Grundlage dient der in Abbildung 9.1 dargestellte Versuchsaufbau. Auf Basis des detaillierten Gebäudemodells werden mit Hilfe einer Monte-Carlo-Simulation (MCS) die Sample-Daten zur Erstellung der Ersatzmodelle erzeugt. Anschließend werden für die Zielgrößen Heizwärmebedarf (Q_h) und Übertemperaturgradstunden (UGS) jeweils zwei Neuronale Netze und eine Support Vector Regression erstellt.

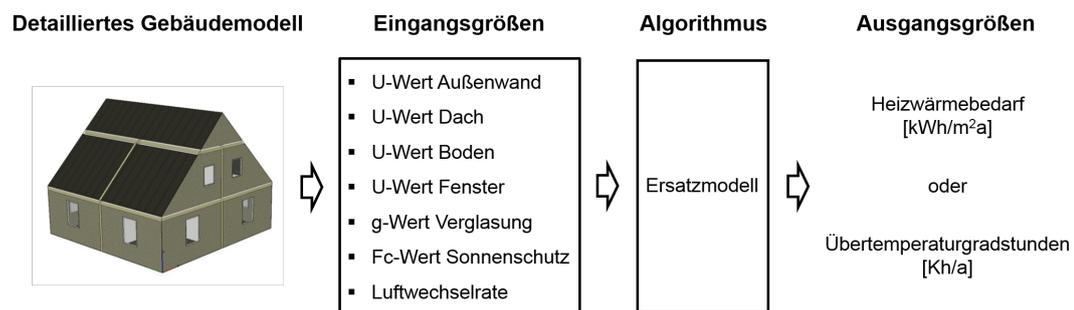


Abbildung 9.1: Schematischer Ablauf des Versuchsaufbaus

Die Eingangsgrößen für die MCS, sowie für die Ersatzmodelle werden in Tabelle 9.1 vorgestellt. Diese Gebäudeparameter repräsentieren Maßnahmen für eine energetische Gebäudesanierung. Die Auswahl dieser Parameter wird aus Gründen der Vergleichbarkeit von aktuellen Sanierungskonzepten abgeleitet¹ (Loga et al. 2011). Die einzelnen Wärmedurchgangskoeffizienten von der Bodenplatte, Dach und Außenwand repräsentiert die Maßnahme „Dämmung“ des jeweiligen Bauteils. Der Wärmedurchgangskoeffizient des Fensters und der Gesamtenergiedurchlassgrad (g-Wert) der Verglasung spiegeln einen Austausch des Fensterrahmens und der Verglasung wider. Der Parameter Fc-Wert steht für die Implementierung eines Sonnenschutzes und dessen Qualität. Der Luftwechsel wird nicht als einzelne Maßnahme behandelt, sondern bildet eine resultierende Größe aus dem Sanierungszustand des Gebäudes.

¹ Eine weitere Möglichkeit für die Auswahl von Eingangsgrößen des Ersatzmodells wäre die Durchführung einer Sensitivitätsanalyse. Details können, z.B. aus Burhenne (2013) entnommen werden.

Als Verteilung für die MCS erhalten die Gebäudeparameter eine stetige Gleichverteilung in einem Intervall von $U(a,b)$. Dabei wird zwischen zwei Wertebereichen, Erstellung und Anwendung, unterschieden. Der Wertebereich für die Erstellung der Ersatzmodelle sollte größer gewählt werden als der Anwendungsbereich des Modells. Dadurch kann die Anzahl benötigter Stichproben zum Lernen der Modelle reduziert werden (siehe Kapitel 9.4).

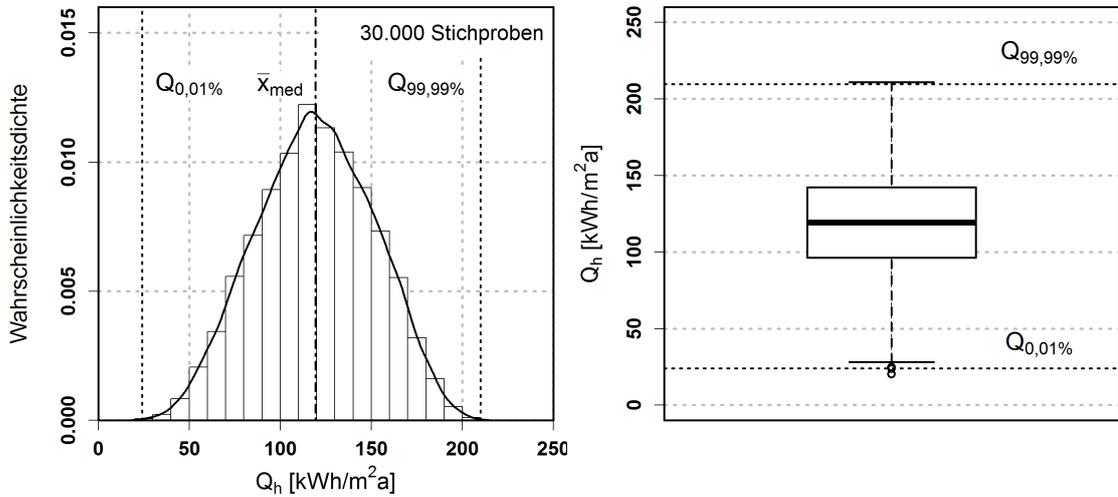
Die Grenzen des Anwendungsbereiches sind in Tabelle 9.1 unter „Anwendung“ abgebildet. Die oberen Grenzwerte des Intervalls leiten sich aus den Parametern des Bestandsgebäudes aus Teil II ab. Die unteren Grenzwerte orientieren sich an der technischen Machbarkeit aktueller Energieeinsparmaßnahmen. Auf die Bedeutung des Wertebereiches bei der Erstellung von Ersatzmodellen wird in Abschnitt 9.2 und 9.4 detaillierter eingegangen.

Tabelle 9.1: Eingangsgrößen der Ersatzmodelle mit Wertebereich für die Erstellung und die Anwendung

Eingangsgrößen	Erstellung	Anwendung	Einheit
U-Wert Außenwand	U(0,01;1,60)	U(0,10;1,40)	[W/m ² K]
U-Wert Dach	U(0,01;1,60)	U(0,10;1,10)	[W/m ² K]
U-Wert Boden	U(0,01;1,60)	U(0,10;1,10)	[W/m ² K]
U-Wert Fenster	U(0,50;3,50)	U(0,60;3,50)	[W/m ² K]
g-Wert Verglasung	U(0,20;0,80)	U(0,30;0,75)	[-]
Fc-Wert Sonnenschutz	U(0,10;1,00)	U(0,25;1,00)	[-]
Luftwechsel	U(0,40;0,80)	U(0,60;0,70)	[h ⁻¹]

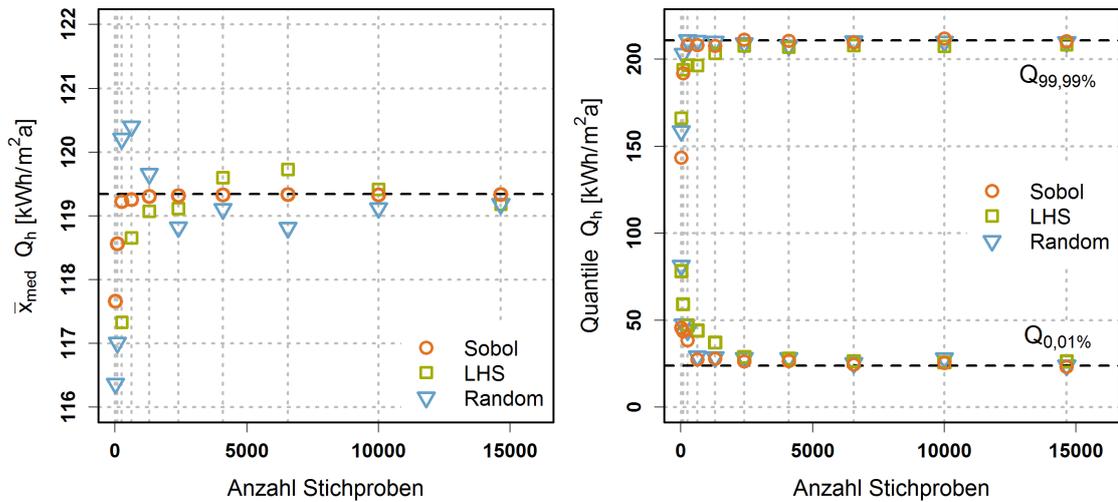
9.2 Vergleich von Sample-Techniken

Als Referenz für den Vergleich der Sample-Techniken wird eine Monte-Carlo-Simulation mit dem beschriebenen Versuchsaufbau durchgeführt. Dabei werden 30.000 Simulationen bzw. Stichproben auf Basis eines Random Samplings mit dem detaillierten Gebäudemodell berechnet. Durch die hohe Anzahl von Simulationen wird angenommen, dass die Verteilung der Zielgröße exakt wiedergeben wird. Abbildung 9.2 zeigt die resultierende Verteilung der Zielgröße bzw. des Ausgangssignals Heizwärmebedarf (Q_h). Als Kennwerte der Verteilung dienen der Median \bar{x}_{med} , das 0,01%-Quantil und das 99,99%-Quantil.



(a) Histogramm der Zielgröße Heizwärmebedarf Q_h auf Basis von 30.000 Stichproben (b) Boxplot der Zielgröße Heizwärmebedarf Q_h auf Basis von 30.000 Stichproben

Abbildung 9.2: Verteilung der Zielgröße Heizwärmebedarf Q_h



(a) Resultierender Median des Q_h in Abhängigkeit der Stichprobenanzahl und Sample-Technik (b) Das 0,01% und 99,99%-Quantil des Q_h in Abhängigkeit der Stichprobenanzahl und Sample-Technik

Abbildung 9.3: Vergleich von Sample-Techniken auf Basis des Heizwärmebedarfs Q_h

Abbildung 9.3 zeigt einen Vergleich der drei Sample-Techniken Random Sampling, Latin Hypercube Sampling (LHS) und Sobol Sequenzen. Die Qualität der Methoden wird anhand der Anzahl benötigter Stichproben zur Darstellung für die Kennwerte der Referenzberechnung in Abbildung 9.2a bewertet. Ziel ist es, ein Verfahren auszuwählen, welches mit der geringsten Anzahl von Stichproben den Referenzwert angemessen abbildet. Grafik 9.3a zeigt die Ergebnisse auf Basis des \bar{x}_{med} aus Abbildung 9.2a. Die Technik der Sobol Sequenzen erreicht bereits mit mehreren Hundert Stichproben belastbare Resultate. Die Ergebnisse aus dem Random Sampling bilden den Median selbst mit nahezu 15.000 Simulationen nicht ab. In Abbildung 9.3b dienen die Quantile der Referenzberechnung als Bewertungsgröße für den Vergleich der drei Sample-Techniken. Die Resultate der Sobol Sequenzen können auch hier bereits mit mehreren Hundert Stichproben die Kennwerte adäquat abbilden. Aber auch die Methoden LHS und Random Sampling weisen ähnlich gute Ergebnisse auf.

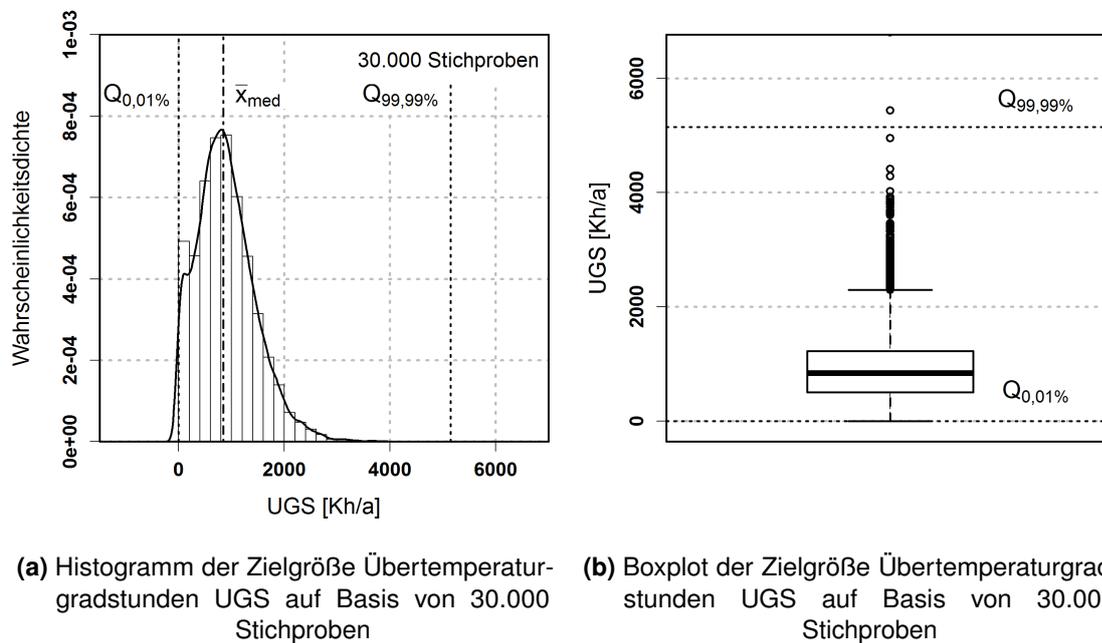
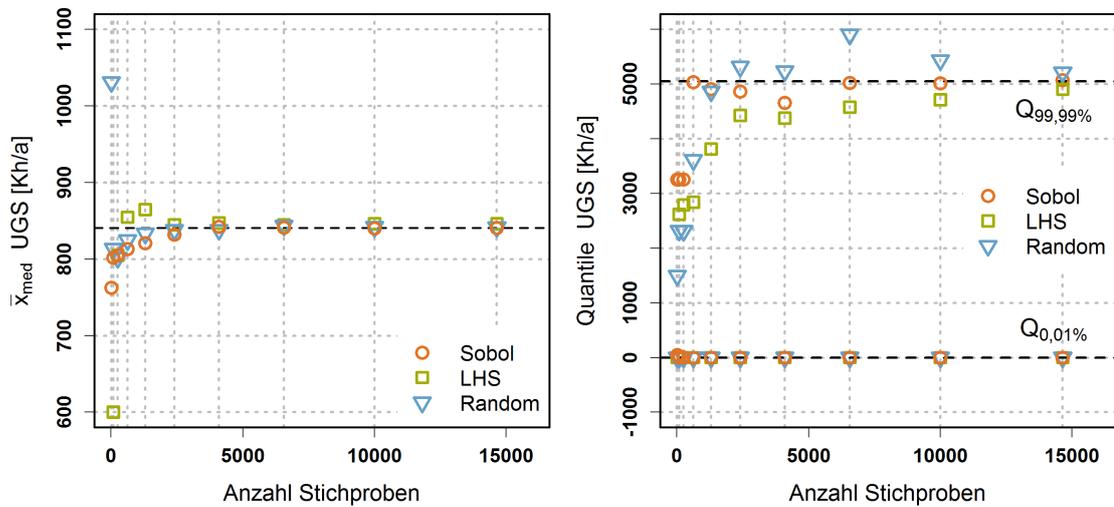


Abbildung 9.4: Verteilung der Zielgröße Übertemperaturgradstunden UGS

In Grafik 9.4 ist die Verteilung der Zielgröße UGS^2 für die kritische Zone des Fallbeispiels aus Teil II abgebildet. Auch hier werden 30.000 Simulationen bzw. Stichproben auf Basis eines Random Samplings mit dem detaillierten Gebäudemodell berechnet. Die Verteilung der UGS weist eine deutlich andere Struktur als die des Q_h auf. Während der Heizwärmebedarf Anzeichen einer Normalverteilung aufweist, zeigen die Resultate des Boxplots der Übertemperaturgradstunden in Abbildung 9.4b starke Ausreißer.

² Übertemperaturgradstunden sind ein Maß für die sommerliche Überhitzung von Gebäuden. Im Rahmen dieser Arbeit wird dieser Kennwert nach (DIN 4108-2 2013) ermittelt. Die Komfortgrenze für die kritische Zone des Gebäudes liegt bei einer Innentemperatur $> 26^\circ\text{C}$



(a) Resultierender Median der Zielgröße UGS in Abhängigkeit der Stichprobenanzahl und Sample-Technik

(b) Das 0,01% und 99,99%-Quantil der UGS in Abhängigkeit der Stichprobenanzahl und Sample-Technik

Abbildung 9.5: Vergleich unterschiedlicher Sample-Techniken auf Basis der Zielgröße Übertemperaturgradstunden UGS

Beim Vergleich auf Basis der Zielgröße UGS werden ebenfalls der Median \bar{x}_{med} , das 0,01%-Quantil und das 99,99%-Quantil als Kennwerte herangezogen. In den beiden Grafiken von Abbildung 9.5 zeigt die Technik der Sobol Sequenzen die belastbarsten Resultate. Lediglich beim 99,99%-Quantil in Abbildung 9.5b sind bis zu einer Anzahl von 5.000 Stichproben Unsicherheiten zu erkennen. Diese Schwankungen sind auf die Verteilung der Zielgröße zurückzuführen, da das 99,99%-Quantil im Bereich der Ausreißer liegt. Bei der Abbildung solcher Ausreißer weisen alle drei Sample-Techniken, im Vergleich zu den Ergebnissen bei der Verteilung des Heizwärmebedarfes, starke Unregelmäßigkeiten auf. Des Weiteren zeigen die Resultate, dass diese Unsicherheiten mit einer höheren Stichprobenanzahl reduziert werden können. Eine allgemeingültige Aussage über die benötigte Anzahl von Stichproben, die über das analysierte Fallbeispiel hinaus gehen, lässt sich dagegen nicht ableiten. Deshalb wird empfohlen, immer eine Validierung des Ersatzmodells durchzuführen, unabhängig von der Anzahl der Stichproben. Beim Vergleich der drei Sample-Techniken benötigen die Sobol Sequenzen die geringste Anzahl Stichproben, um die jeweiligen Kennwerte der Verteilung abzubilden. Deshalb werden die Sobol Sequenzen im weiteren Verlauf der Arbeit für die Erstellung der Sample-Daten verwendet.

9.3 Strukturoptimierung der Ersatzmodelle

Als Grundlage für den Vergleich von Neuronalen Netzen und der Support Vector Machine werden in den folgenden Kapiteln konkrete Modelle erstellt. Dabei wird geprüft, ob sich diese beiden Methoden als Ersatzmodell für ein detailliertes Gebäudemodell eignen. Dazu werden für die Zielgrößen Heizwärmebedarf und Übertemperaturgradstunden jeweils zwei Multi Layer Perceptrons und eine Epsilon Support Vector Regression entwickelt. Des Weiteren wird die Anzahl von Trainings- und Validierungsdaten variiert, um den Einfluss auf die Modellgüte zu analysieren.

9.3.1 Multi Layer Perceptron

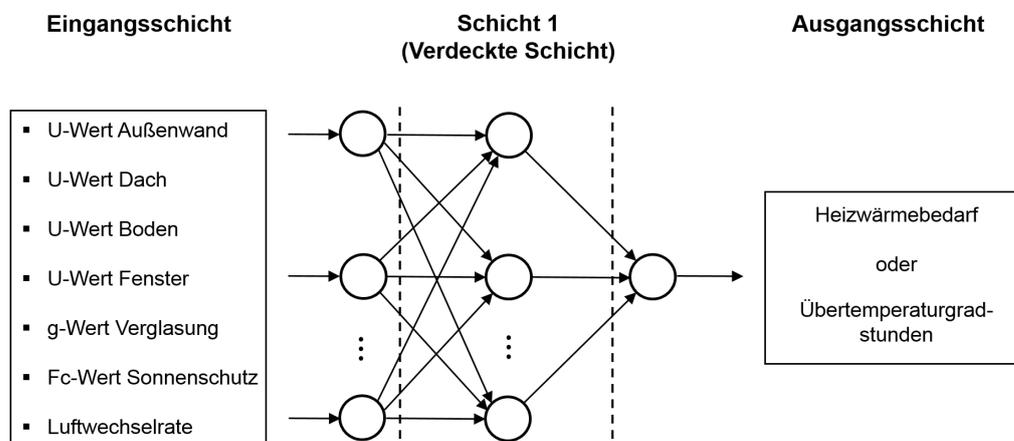


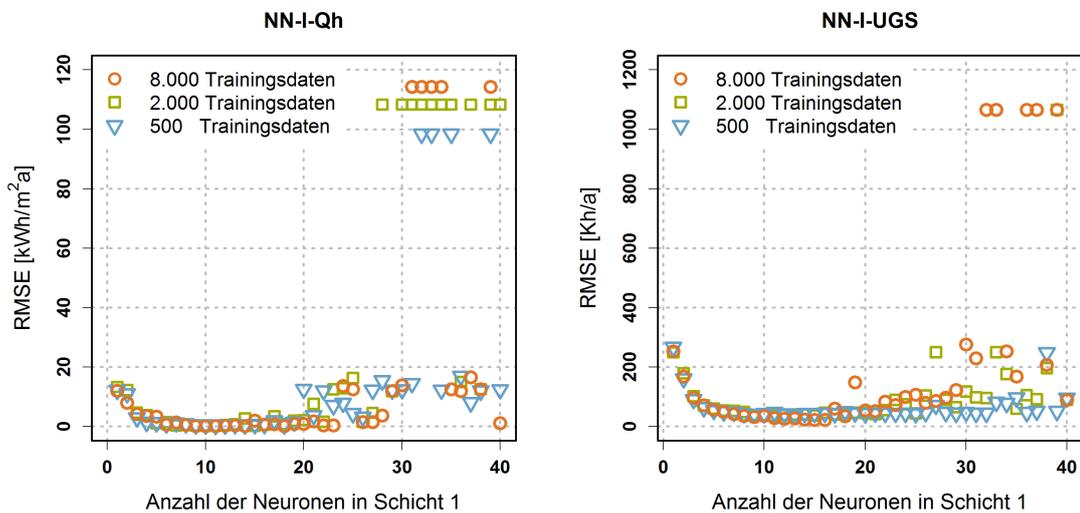
Abbildung 9.6: Ein- und Ausgangsgrößen des MLP

Abbildung 9.6 stellt die Struktur der verwendeten MLP's dar. Es werden eine Eingangsschicht, eine verdeckte Schicht und eine Ausgangsschicht definiert. Die Netze haben jeweils sieben Eingangsgrößen (Details Tabelle 9.1) und eine Ausgangsgröße. Die Transferfunktion für die Ein- und Ausgangsschicht ist linear. In der verdeckten Schicht wird eine logistische Funktion als Transferfunktion für die Neuronen definiert. Als Optimierungsverfahren für die Verbindungsgewichte werden zwei Techniken, Backpropagation und ein Quasi-Newton-Verfahren, verglichen. Tabelle 9.2 fasst die entstehenden Modellkonfigurationen zusammen.

Tabelle 9.2: Modellkonfigurationen der unterschiedlichen Multi Layer Perceptrons

MLP	Zielgröße	Optimierungsverfahren
NN-I-Qh	Heizwärmebedarf	Backpropagation
NN-I-UGS	Übertemperaturgradstunden	Backpropagation
NN-II-Qh	Heizwärmebedarf	Quasi-Newton
NN-II-UGS	Übertemperaturgradstunden	Quasi-Newton

Die Anzahl der Neuronen in der verdeckten Schicht wird in jedem MLP über eine Parameterstudie ermittelt. Abbildung 9.7 zeigt die Ergebnisse der MLP's NN-I-Qh und NN-I-UGS abhängig von der Anzahl Trainingsdaten. Auf der x-Achse ist die Anzahl der Neuronen und auf der y-Achse der RMSE der jeweiligen Zielgröße aufgetragen. Es wird deutlich, dass für beide Zielgrößen unabhängig von der Anzahl Trainingsdaten belastbare Resultate erzielt werden. Der mittlere Prognosefehler des Heizwärmebedarfes ist bei einer optimalen Anzahl von Neuronen und einer Anzahl von 500 Trainingsdaten bereits kleiner als 1 kWh/m²a (Tabelle 9.3). Bei der Zielgröße Übertemperaturgradstunden liegt der Fehler bei weniger als 40 Kh/a bei einer Anzahl von 500 Trainingsdaten (Tabelle 9.4). Als Plausibilisierung des Fehlers für die Zielgröße UGS kann der Coefficient of Variance (CV) herangezogen werden (Tabelle 9.4). Dieser weist beim NN-I-UGS mit 500 Trainingsdaten und einer optimalen Auswahl der Neuronenanzahl einen mittleren relativen Fehler der Prognose von 4,25% (RMSE 40 Kh/a) auf.



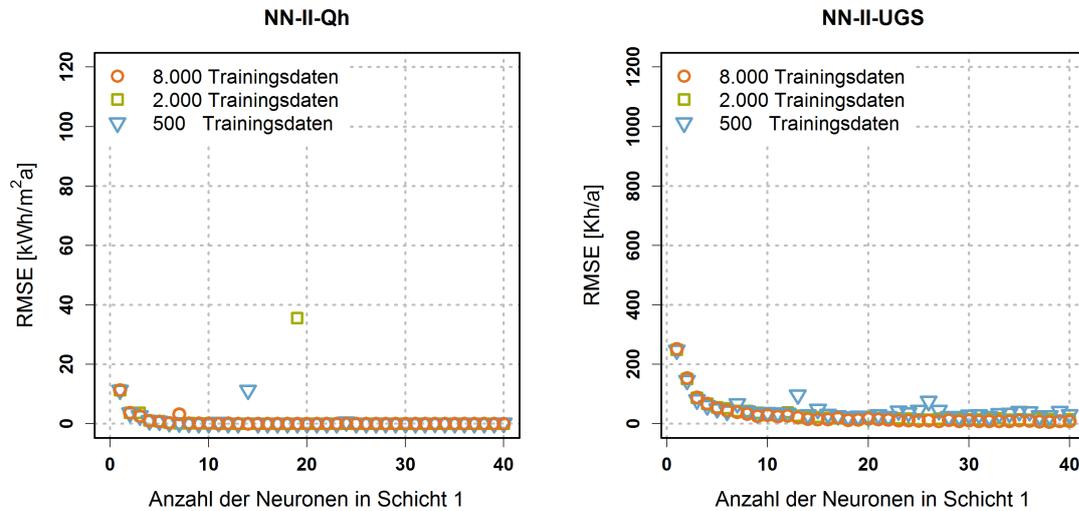
(a) Modellgüte (RMSE) der Zielgröße Q_h in Abhängigkeit von der Anzahl Trainingsdaten und Neuronen in der ersten Schicht des Neuronalen Netzes

(b) Modellgüte (RMSE) der Zielgröße UGS in Abhängigkeit von der Anzahl Trainingsdaten und Neuronen in der ersten Schicht des Neuronalen Netzes

Abbildung 9.7: Strukturoptimierung der beiden Netze NN-I-Qh und NN-I-UGS abhängig von der Anzahl Trainingsdaten

Des Weiteren ist in Abbildung 9.7 ein Optimum für die Anzahl der Neuronen ersichtlich, da sich die Punkte einem Minimum annähern (Details Tabelle 9.3 und 9.4). Aus den Ergebnissen kann auch abgeleitet werden, dass eine höhere Anzahl Neuronen keine bessere Modellgüte garantiert. Im Gegenteil, es ist ein sogenanntes Overfitting³ der Modelle erkennbar, da die Modellqualität bei einer höheren Anzahl Neuronen deutlich schlechter wird.

³ Dieses Overfitting entsteht durch das sogenannte „Bias-Varianz-Dilemma“. Details können aus Endisch (2009) entnommen werden.



(a) Modellgüte (RMSE) der Zielgröße Q_h in Abhängigkeit von der Anzahl Trainingsdaten und Neuronen in der ersten Schicht des Neuronalen Netzes

(b) Modellgüte (RMSE) der Zielgröße UGS in Abhängigkeit von der Anzahl Trainingsdaten und Neuronen in der ersten Schicht des Neuronalen Netzes

Abbildung 9.8: Strukturoptimierung der beiden Netze NN-II-Qh und NN-II-UGS abhängig von der Anzahl Trainingsdaten

Abbildung 9.8 stellt die Ergebnisse der Parameterstudie für die Netze NN-II-Qh und NN-II-UGS dar. Auch hier zeigen beide Zielgrößen unabhängig von der Anzahl Trainingsdaten verwendbare Ergebnisse. Der mittlere Prognosefehler des Heizwärmebedarfes beträgt bei einer optimalen Anzahl Neuronen und einer Anzahl von 500 Trainingsdaten ebenfalls weniger als 1 kWh/m²a (Tabelle 9.3). Der Fehler für die Übertemperaturgradstunden beträgt weniger als 25 Kh/a bei einer Anzahl von 500 Trainingsdaten (Tabelle 9.4). Im Vergleich zu den beiden Netzen mit Backpropagation-Verfahren weist die Optimierung mit dem Quasi-Newton-Algorithmus deutlich stabilere Ergebnisse auf. Eine höhere Anzahl Neuronen bewirkt auch bei diesem Verfahren keine weiteren Verbesserungen der Modellgüte.

9.3.2 Epsilon Support Vector Regression

Die Ein- und Ausgangsgrößen für die Erstellung der ε -SVR sind identisch mit denen der Neuronalen Netze. Für jede Zielgröße wird eine eigene ε -SVR, SVR-Qh und SVR-UGS, erstellt. Als Kernelfunktion wird die Gaußsche Radiale Basisfunktion definiert (siehe Abschnitt 8.5.3). Die Ermittlung von C , ε und σ wird mit Hilfe einer Parameterstudie durchgeführt. Der Parameter ε wird im Bereich von $10^{-4} \leq \varepsilon \leq 1$ analysiert. Die durchgeführten Untersuchungen weisen eine optimale Modellgüte bei einem ε von 0,001 auf. In den folgenden Abbildungen der Strukturoptimierung ist der Parameter ε mit 0,001 definiert.

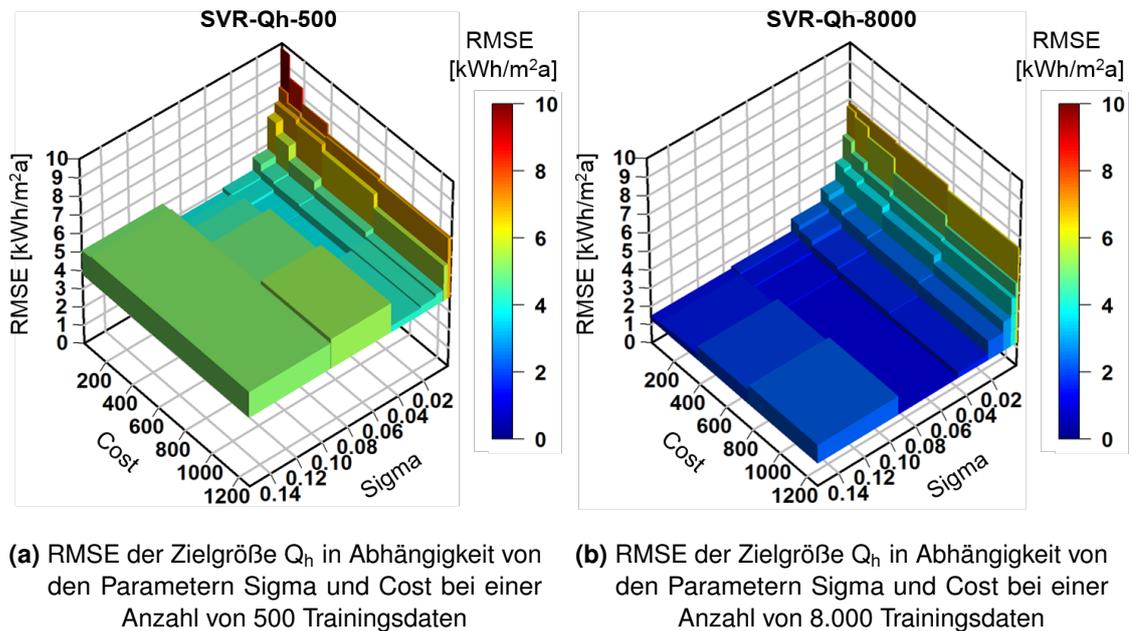
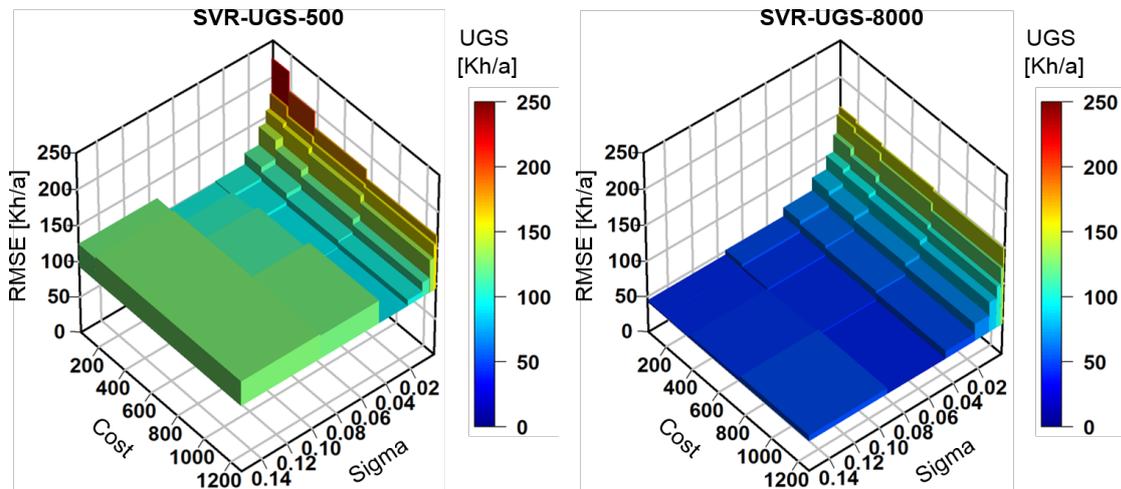


Abbildung 9.9: Strukturoptimierung zweier ε -SVR's mit der Zielgröße Q_h abhängig von der Anzahl der Trainingsdaten

Abbildung 9.9 präsentiert jeweils eine SVR mit der Zielgröße Heizwärmebedarf Q_h abhängig von der Anzahl der Trainingsdaten. Die x- und y-Achse der beiden Grafiken zeigen die Parameter Sigma σ und Cost C . Die Modellgüte (RMSE) wird auf der z-Achse abgebildet. Die farbliche Skalierung stellt ebenfalls den RMSE dar und soll eine einfachere Interpretation der Grafik ermöglichen. Beide Modelle in Abbildung 9.9 zeigen, dass sich eine ε -SVR als Ersatzmodell für die Zielgröße Q_h in diesem Anwendungsfall eignet. Der mittlere Prognosefehler bei einer Anzahl von 500 Trainingsdaten liegt mit einer optimalen Auswahl der Parameter C und σ bei weniger als 4 kWh/m²a (Tabelle 9.3). Bei einer Anzahl von 8.000 Trainingsdaten sogar unter 1,5 kWh/m²a (Tabelle 9.3). Außerdem machen die Ergebnisse deutlich, dass bei einer SVR wie beim MLP die Strukturoptimierung bzw. die Auswahl der „freien“ Parameter einen großen Einfluss auf die Modellgüte besitzen. Dies gilt auch für die Anzahl der Trainingsdaten, welche ebenfalls eine hohe Sensitivität auf den Modellfehler aufweisen.



(a) RMSE der Zielgröße UGS in Abhängigkeit von den Parametern Sigma und Cost bei einer Anzahl von 500 Trainingsdaten

(b) RMSE der Zielgröße UGS in Abhängigkeit von den Parametern Sigma und Cost bei einer Anzahl von 8.000 Trainingsdaten

Abbildung 9.10: Strukturoptimierung zweier ε -SVR's mit der Zielgröße UGS abhängig von der Anzahl Trainingsdaten

Die Resultate der Parameterstudie für die Zielgröße Übertemperaturgradstunden UGS werden in Abbildung 9.10 dargestellt. Der mittlere Prognosefehler bei einer optimalen Auswahl von C und σ und der Anzahl von 8.000 Trainingsdaten liegt bei ca. 43 Kh/a (Tabelle 9.4). Das optimale Ergebnis bei 500 Trainingsdaten liegt bei einem Fehler von ca. 93 Kh/a (Tabelle 9.4). Als Plausibilisierung der Zielgröße UGS kann wieder der Coefficient of Variation (CV) herangezogen werden (Tabelle 9.4). Der mittlere relative Prognosefehler CV ist bei einer SVR-UGS-500 ca. 10% (RMSE 93 Kh/a). Trotz des hohen Fehlers bei 500 Trainingsdaten lassen die Ergebnisse aus den beiden Modellen eine Eignung als Ersatzmodell für die Zielgröße UGS erkennen, da der Fehler bei einer Anzahl von 8.000 Trainingsdaten sich auf ca. 5% reduziert.

9.4 Kreuzvalidierung der Ersatzmodelle

Im Rahmen der oben durchgeführten Strukturoptimierung werden die Modelle bei jeder Änderung der Parameter auf Basis einer einfachen Kreuzvalidierung bewertet. Dabei werden die gesamten Sample-Daten in 50% Trainings- und 50% Validierungsdaten aufgeteilt. Der Zusammenhang zwischen Modellgüte und Anzahl Trainingsdaten wird durch eine Variation der gesamten Menge an Sample-Daten in den Schritten 1.000, 4.000 und 16.000 analysiert. In den folgenden Abschnitten sind die Ergebnisse der Strukturoptimierung und der Kreuzvalidierung der Ersatzmodelle zusammengefasst.

In Tabelle 9.3 werden unterschiedliche Ersatzmodelle, abhängig von der Anzahl der Trainingsdaten, für die Zielgröße Q_h verglichen. Als Referenzgröße werden die Resultate aus einer linearen Regression⁴ ergänzt. Neben den statistischen Kennwerten RMSE, CV und R^2 werden in Tabelle 9.3 auch die optimalen Ergebnisse der Parameter aus der Strukturoptimierung festgehalten.

Die nichtlinearen Techniken (NN und SVR) weisen generell deutlich bessere Ergebnisse auf als die lineare Regression. Es ist auch zu erkennen, dass die Neuronale Netze bei gleicher Anzahl an Trainingsdaten eine höhere Modellgüte aufweisen als die Support Vector Regression. Allgemein zeigen alle Modelle unabhängig von der Anzahl der Trainingsdaten, ausgenommen die lineare Regression, eine Eignung als Ersatzmodell für die Zielgröße Q_h . Das MLP (NN-II) mit dem Quasi-Newton-Verfahren für die Optimierung der Verbindungsgewichte demonstriert in allen Fällen die höchste Modellgüte.

Tabelle 9.3: Finale Ergebnisse aus der Kreuzvalidierung mit der Zielgröße Q_h

Modell	Training	Parameter	RMSE [kWh/m ² a]	CV [%]	R ² -
LinReg-Qh	500	-	12,19	9,23	0,88291
NN-I-Qh	500	11 Neuronen, Lernrate 1,0	0,47	0,35	0,99983
NN-II-Qh	500	10 Neuronen	0,09	0,07	0,99999
SVR-Qh	500	Cost 64, Sigma 0,0502	3,72	2,79	0,98900
LinReg-Qh	2.000	-	12,15	9,19	0,88350
NN-I-Qh	2.000	11 Neuronen, Lernrate 1,3	0,25	0,19	0,99994
NN-II-Qh	2.000	34 Neuronen	0,05	0,04	0,99999
SVR-Qh	2.000	Cost 597, Sigma 0,0450	2,54	1,92	0,99490
LinReg-Qh	8.000	-	12,15	9,18	0,88380
NN-I-Qh	8.000	16 Neuronen, Lernrate 1,0	0,15	0,11	0,99998
NN-II-Qh	8.000	31 Neuronen	0,03	0,02	0,99999
SVR-Qh	8.000	Cost 1024, Sigma 0,0540	1,26	0,95	0,99875

⁴ Die lineare Regression wurde mit der Software R (R Core Team 2008) und der Funktion `lm()` erstellt.

Tabelle 9.4 stellt die unterschiedlichen Ersatzmodelle abhängig von der Anzahl der Trainingsdaten für die Zielgröße UGS dar. Als Referenzgröße werden ebenfalls die Resultate aus einer linearen Regression ergänzt. Auch bei der Zielgröße UGS zeigt die lineare Regression größere Modellfehler als die nichtlinearen Techniken (NN und SVR). Die Neuronalen Netze weisen bei gleicher Anzahl Trainingsdaten eine höhere Modellgüte als die Support Vector Regression auf. Wie bei der Zielgröße Q_h können alle nichtlinearen Modelle als Ersatzmodell angewendet werden. Lediglich die SVR zeigt bei einer Anzahl von 500 und 2.000 Trainingsdaten einen relativen Prognosefehler (CV) von mehr als $\pm 5\%$. Das MLP (NN-II) mit dem Quasi-Newton Verfahren hat auch bei der Zielgröße UGS in allen Fällen die höchste Modellgüte.

Tabelle 9.4: Finale Ergebnisse aus der Kreuzvalidierung mit der Zielgröße UGS

Modell	Training	Parameter	RMSE [Kh/a]	CV [%]	R ² -
LinReg-UGS	500	-	273,81	30,39	0,76636
NN-I-UGS	500	13 Neuronen, Lernrate 0,7	38,36	4,25	0,99540
NN-II-UGS	500	20 Neuronen	22,81	2,53	0,99830
SVR-UGS	500	Cost 948, Sigma 0,0301	92,23	10,22	0,97360
LinReg-UGS	2.000	-	271,53	30,31	0,76521
NN-I-UGS	2.000	11 Neuronen, Lernrate 1,0	37,54	4,11	0,99570
NN-II-UGS	2.000	39 Neuronen	10,61	1,17	0,99965
SVR-UGS	2.000	Cost 1024, Sigma 0,0450	68,32	7,61	0,98000
LinReg-UGS	8.000	-	207,86	30,11	0,76379
NN-I-UGS	8.000	15 Neuronen, Lernrate 1,2	22,04	2,43	0,99848
NN-II-UGS	8.000	38 Neuronen	7,06	0,78	0,99984
SVR-UGS	8.000	Cost 512, Sigma 0,0777	42,45	4,69	0,99447

Bei der Analyse der Ergebnisse in Tabelle 9.3 und 9.4 stellt sich die Frage, welche Anzahl von Stichproben bzw. Trainingsdaten notwendig ist, um eine angemessene Modellgüte zu erreichen. Betrachtet man die Resultate des NN-II-UGS mit einer Anzahl von 500 Trainingsdaten so ist der mittlere Fehler einer Prognose $\pm 2,53\%$. Daraus könnte man ableiten, dass eine Anzahl von 500 Trainingsdaten ausreichend für die Erstellung des MLP im konkreten Anwendungsfall ist.

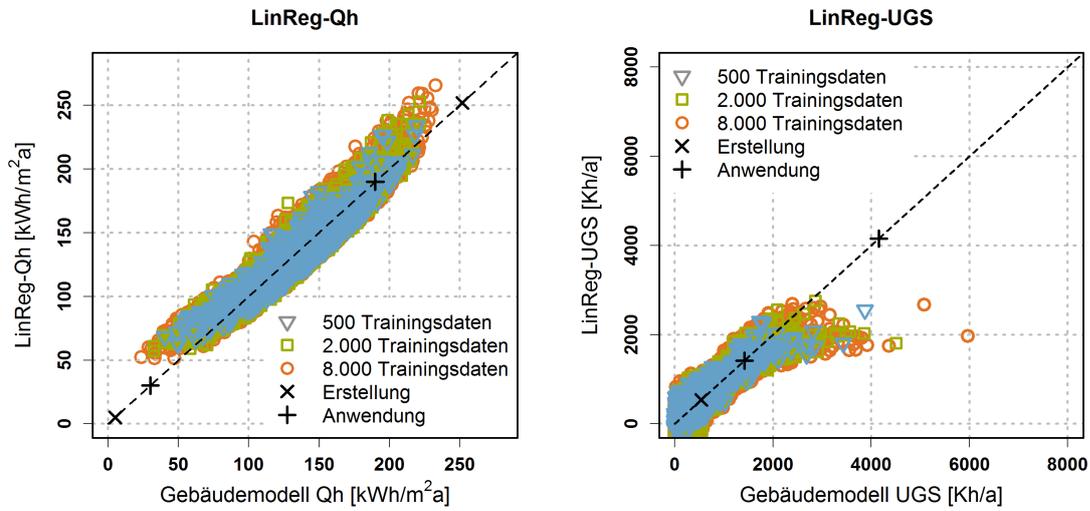
Dieser Rückschluss ist aber nur für den Wertebereich, welcher tatsächlich durch die Sample-Daten abgebildet wird, gültig. Deshalb sollte der tatsächlich abgebildete Wertebereich bei der Validierung der Modelle berücksichtigt werden. Eine effiziente Darstellung des Wertebereichs kann über sogenannte Streudiagramme erreicht werden (siehe Abbildungen 9.11 und 9.12).

Eine exakte Abbildung der Grenzen eines Wertebereiches mit Hilfe von Sample-Techniken führt zu einer erhöhten Anzahl von Stichproben. Dies zeigt bereits das Beispiel aus Kapitel 9.2. Dabei wurden die Grenzen eines Wertebereiches durch ein 0,01%-Quantil und 99,99%-Quantil dargestellt. Es zeigte sich, dass eine exakte Abbildung der Quantile bzw. des Wertebereiches eine erhöhte Anzahl von Stichproben verursacht. Deshalb ist es sinnvoll, den Wertebereich für das Trainieren der Modelle weiter zu fassen, als es für die Anwendung erforderlich ist. Die folgenden Analysen greifen diese Problematik auf und stellen die Ergebnisse anhand der erstellten Ersatzmodelle dar.

Die Diagramme in Abbildung 9.11 und 9.12 stellen auf der y-Achse die Prognose des jeweiligen Ersatzmodells und auf der x-Achse das Ausgangssignal des detaillierten Gebäudemodells dar. Des Weiteren werden die Grenzen der Wertebereiche „Erstellung (x)“ und „Anwendung (+)“ aus Tabelle 9.1 abgebildet. Die Grenzen des Wertebereichs „Erstellung“ repräsentieren jeweils die mini- und maximalen Werte einer Zielgröße, welche mit den Werten der Eingangsgrößen aus Tabelle 9.1 erreicht werden können. In den Grafiken mit der Zielgröße UGS wird aufgrund einer besseren Darstellbarkeit auf die Abbildung der oberen Grenze des Wertebereiches „Erstellung“ verzichtet. Alle Ersatzmodelle, unabhängig der Zielgröße, können selbst mit einer Anzahl von 8.000 Trainingsdaten die Grenzen des Wertebereiches „Erstellung“ nicht abbilden. Die Grenzwerte des Anwendungsbereiches können hingegen mit den Neuronalen Netzen bei einer Anzahl von 8.000 Trainingsdaten abgebildet werden. Jedoch zeigen die Ergebnisse beim oberen Grenzwert der Zielgröße UGS starke Ungenauigkeiten. Die ε -SVR kann diesen Grenzwert selbst bei 8.000 Trainingsdaten nicht mehr angemessen darstellen.

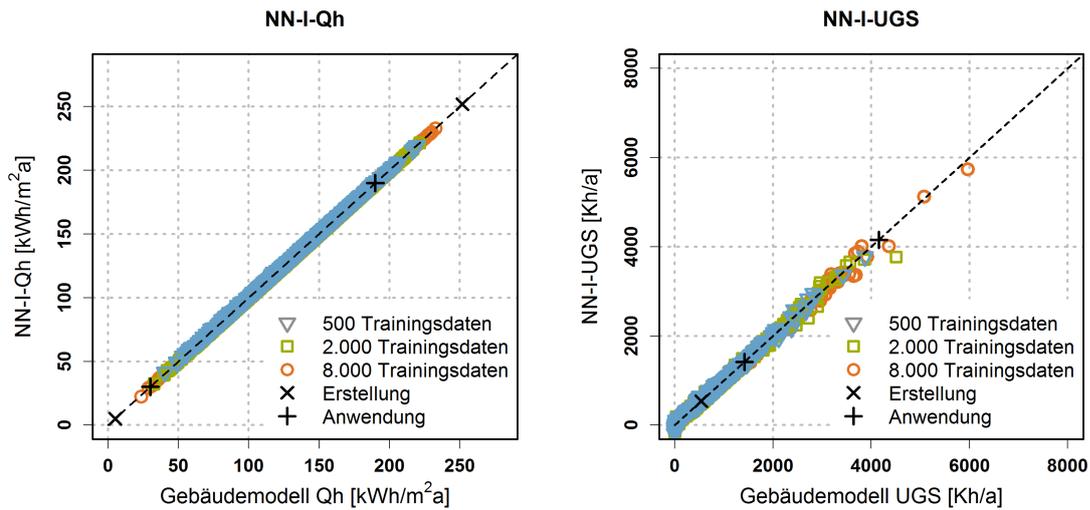
Diese Problematik hebt hervor, dass für die Validierung der Ersatzmodelle auch der Anwendungsbereich berücksichtigt werden muss. Am Beispiel des Neuronalen Netzes NN-II wird dies noch einmal verdeutlicht. Nach der Bewertung der Modellgüte auf Basis der statistischen Kennzahlen ist eine Anzahl von 500 Trainingsdaten zum Lernen des Modells ausreichend (Tabelle 9.3). Die Diagramme 9.12a und 9.12b zeigen aber, dass die Grenzwerte des Anwendungsbereiches mit einer Anzahl von 500 Trainingsdaten nicht erreicht werden. Diese Grenzwerte werden erst mit einer Anzahl von 8.000 Trainingsdaten durch das Neuronale Netz dargestellt. Daraus lässt sich für die Erstellung der Ersatzmodelle folgendes schließen:

- i) Die Auswahl einer geeigneten Sample-Technik für die Erzeugung der Trainings- und Validierungsdaten hat einen hohen Einfluss auf die Modellgüte. Besonders ist darauf zu achten, dass die gewählte Technik mit möglichst wenig Stichproben auch die Grenzen des Wertebereiches abbilden kann.
- ii) Die Erstellung qualitativer Sample-Daten stellt einen Zielkonflikt aus der Anzahl benötigter Stichproben und den Grenzen des Anwendungsbereiches für das Ersatzmodell dar.



(a) Streudiagramm der linearen Regression mit der Zielgröße Q_h in Abhängigkeit von der Anzahl Trainingsdaten

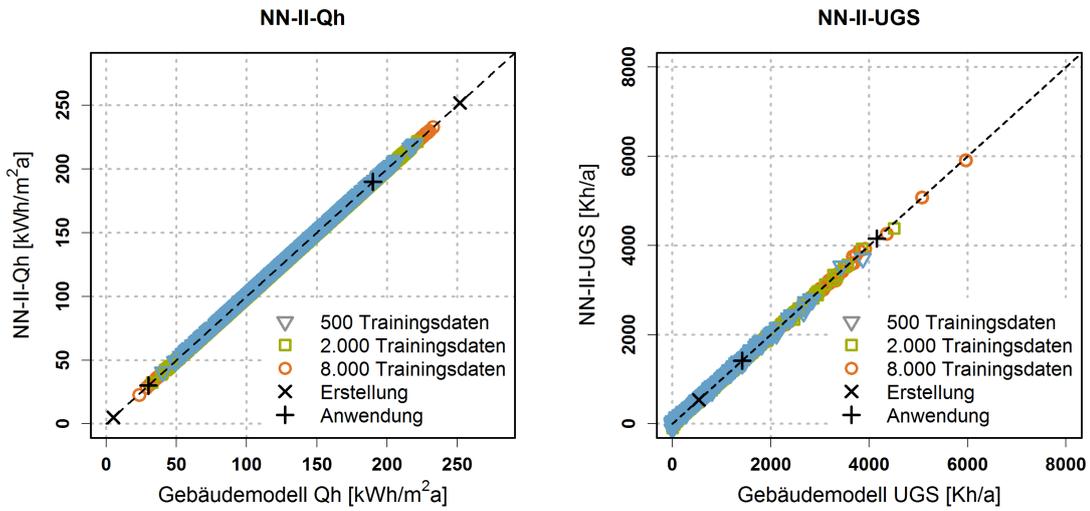
(b) Streudiagramm der linearen Regression mit der Zielgröße UGS in Abhängigkeit von der Anzahl Trainingsdaten



(c) Streudiagramm des NN-I mit der Zielgröße Q_h in Abhängigkeit von der Anzahl Trainingsdaten

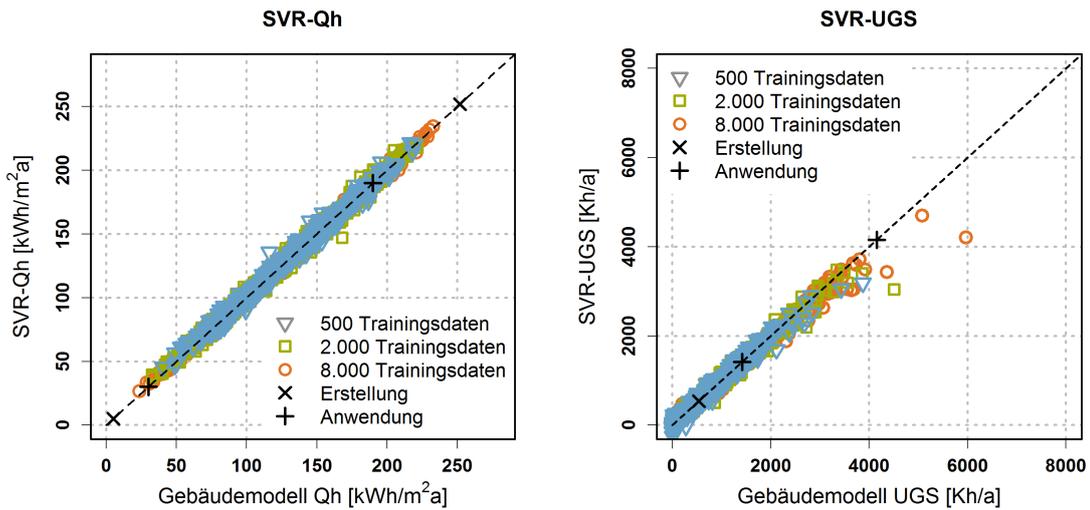
(d) Streudiagramm des NN-I mit der Zielgröße UGS in Abhängigkeit von der Anzahl Trainingsdaten

Abbildung 9.11: Streudiagramme mit den Prognosen der linearen Regression, dem Neuronalen Netz NN-I sowie des detaillierten Gebäudemodells



(a) Streudiagramm des NN-II mit der Zielgröße Q_h in Abhängigkeit von der Anzahl Trainingsdaten

(b) Streudiagramm des NN-II mit der Zielgröße UGS in Abhängigkeit von der Anzahl Trainingsdaten



(c) Streudiagramm der SVR mit der Zielgröße Q_h in Abhängigkeit von der Anzahl Trainingsdaten

(d) Streudiagramm der SVR mit der Zielgröße UGS in Abhängigkeit von der Anzahl Trainingsdaten

Abbildung 9.12: Streudiagramme mit den Prognosen der ϵ -SVR, dem Neuronalen Netz NN-II sowie des detaillierten Gebäudemodells

10 | Zusammenfassung und Modellauswahl

Die Anwendung einer robusten Optimierung bei der energetischen Gebäudesanierung erfordert ein Simulationsmodell des Gebäudes. White-Box-Modelle in Form von spezieller Gebäudesimulationssoftware (Abschnitt 7.1.1) werden bei einer mathematischen Optimierung im Gebäudebereich am häufigsten verwendet (Nguyen et al. 2014). Diese Art von Modellen kann aber aufgrund der hohen Komplexität eine erhöhte Simulationszeit aufweisen. Die Anwendung einer mathematischen Optimierung erfordert teilweise eine tausendfache Wiederholung von Simulationen, um eine vermeintlich optimale Lösung zu finden (Jacob 2012). Diese erhöhten Rechenzeiten können ein Ausschlusskriterium für die Anwendung einer mathematischen Optimierung darstellen (Eisenhower et al. 2012). Besonders gilt dies bei einer robusten Optimierung, bei der eine mathematische Optimierung durch eine Unsicherheitsanalyse erweitert wird (Nguyen et al. 2014).

Deshalb ist für die Anwendung einer robusten Optimierung ein Modell mit einem geringen Rechenaufwand in Kombination mit einer hohen Modellgüte ausschlaggebend. Eine Möglichkeit die Rechenzeit für eine robuste Optimierung zu reduzieren, ist auf Basis eines detaillierten Gebäudemodells ein Ersatzmodell für die Optimierung zu erstellen (Nguyen et al. 2014).

Ziel des Teils „Modellauswahl“ ist die Analyse und Bewertung geeigneter Modellierungsverfahren für die Entwicklung eines Ersatzmodells. Die Kategorie der Black-Box-Modelle, insbesondere die Methode der Neuronalen Netze und der Support Vector Machines, weisen gute Eigenschaften für eine Anwendung als Ersatzmodell auf (Abschnitt 7.1.2, 7.2 und 7.3). Die Erstellung von Black-Box-Modellen benötigt empirische Daten des abzubildenden Systems bzw. des detaillierten Gebäudemodells. Diese Daten werden mit Hilfe einer Monte-Carlo-Simulation (MCS) (Abschnitt 8.3) auf Basis des detaillierten Gebäudemodells, erstellt. Die Qualität der Sample-Daten und der benötigte Simulationsaufwand für die MCS ist maßgeblich von der Sample-Technik abhängig. Bei einem Vergleich von drei Sample-Techniken liefert die Methode der „Sobol Sequenzen“ die besten Resultate.

Als potenzielle Ersatzmodelle werden zwei Neuronale Netze und eine Epsilon Support Vector Regression miteinander verglichen (Abschnitt 9.4). Die beiden Neuronalen Netze unterscheiden sich lediglich beim Algorithmus für die interne Parameteroptimierung. Das Neuronale Netz mit dem Quasi-Newton-Verfahren für die Optimierung der Verbindungsgewichte zeigt bei allen

Analysen die höchste Modellgüte. Des Weiteren wird deutlich, dass bei der Validierung der Ersatzmodelle nicht nur auf statistische Kennzahlen, sondern auch auf den Wertebereich für die Gültigkeit des Modells geachtet werden muss.

Eine Validierung rein auf Basis von statistischen Kennzahlen gibt keine Information über den resultierenden Gültigkeitsbereich der Sample-Daten bzw. des Ersatzmodells. Deshalb muss bei einer Validierung der Ersatzmodelle der Anwendungsbereich berücksichtigt werden. Dies kann mit Hilfe von Streudiagrammen geschehen (Abschnitt 9.4). Des Weiteren zeigt sich, dass eine exakte Abbildung der Grenzen eines Wertebereiches eine erhöhte Anzahl von Stichproben verursacht. Deshalb ist es sinnvoll, den Wertebereich für die Erstellung der Modelle weiter zu fassen, als es für die Anwendung erforderlich ist. Daraus lässt sich ableiten, dass die Erstellung qualitativer Sample-Daten einen Zielkonflikt aus der Anzahl benötigter Stichproben und den Grenzen des Anwendungsbereiches für das Ersatzmodell darstellt.

Im weiteren Verlauf der Arbeit wird für die Erstellung der Sample-Daten die Technik der „Sobol Sequenzen“ verwendet. Als Ersatzmodell wird ein Neuronales Netz mit einem Quasi-Newton Verfahren für die interne Parameteroptimierung herangezogen.

Teil IV

Robuste Optimierung

11 | Einführung robuste Optimierung

Aufgrund der in Teil I vorgestellten Problematik gilt es aus Sicht einer belastbaren Planung Konzepte für die energetische Gebäudesanierung zu entwickeln, welche die Zielgrößen nicht nur optimieren, sondern auch ihre Unsicherheiten reduzieren. Eine Möglichkeit, dieses Ziel zu erreichen, ist die Anwendung einer robusten Optimierung. Ziel des Teils „Robuste Optimierung“ ist eine Einführung in die Methode, sowie eine erste Anwendung einer robusten Optimierung der energetischen Gebäudesanierung unter Berücksichtigung klimatischer Unsicherheiten.

11.1 Optimierung und Robustheit

Die Grundlage für eine robuste Optimierung bildet im Rahmen dieser Arbeit eine mathematische Optimierung mit dem Ersatzmodell. Unter dem Begriff der „Mathematischen Optimierung“ versteht man vereinfacht das Auffinden eines Extremwertes - Minimum oder Maximum - einer Zielfunktion (Details in Kapitel 12.2). Dabei wird in der Regel angenommen, dass alle Variablen und Parameter des Optimierungsproblems deterministisch¹ sind. Bei einer sogenannten deterministischen Optimierung werden keine Unsicherheiten der Parameter und Variablen im Optimierungsproblem berücksichtigt (Yao et al. 2011). In einer realen Anwendung treten jedoch häufig Unsicherheiten, z.B. in Form von schwankenden Eingangsgrößen des Systems bzw. des Optimierungsproblems auf. Diese Schwankungen können, je nach Struktur der Zielfunktion, einen starken Einfluss auf ein deterministisches Optimum aufweisen. Deshalb werden bei einer robusten Optimierung die Unsicherheiten beim Auffinden einer optimalen Lösung berücksichtigt. Abbildung 11.1 stellt schematisch den Unterschied zwischen einem deterministischen und einem robusten Optimum dar (nach einem Beispiel von Keane und Nair (2005) und Rhein (2014, S. 327-357)). Eine mathematische Definition der robusten Optimierung wird in den Abschnitten 12.2 und 12.3 vorgestellt.

Ziel der Optimierung in Abbildung 11.1 ist das Auffinden einer minimalen Optimallösung der Zielfunktion $f(x)$. Die y-Achse stellt das Ergebnis der Zielfunktion $y = f(x)$ und die x-Achse die Eingangsgröße x dar. Die Eingangsgröße weist eine Unsicherheit Δx auf, welche durch eine blaue Verteilung an Stelle x_0 und eine rote Verteilung an der Stelle x_1 abgebildet wird. Die Stelle x_0 repräsentiert das deterministische Minimum und die Stelle x_1 das robuste Minimum. Die Unsicherheit Δx der Eingangsgröße ist an beiden Stellen identisch. Jedoch hat die Unsicherheit, aufgrund der Struktur der Zielfunktion, unterschiedliche Auswirkungen auf das

¹ Der Begriff „Deterministisch“ bedeutet in diesem Kontext „mit Sicherheit vorhersehbar“.

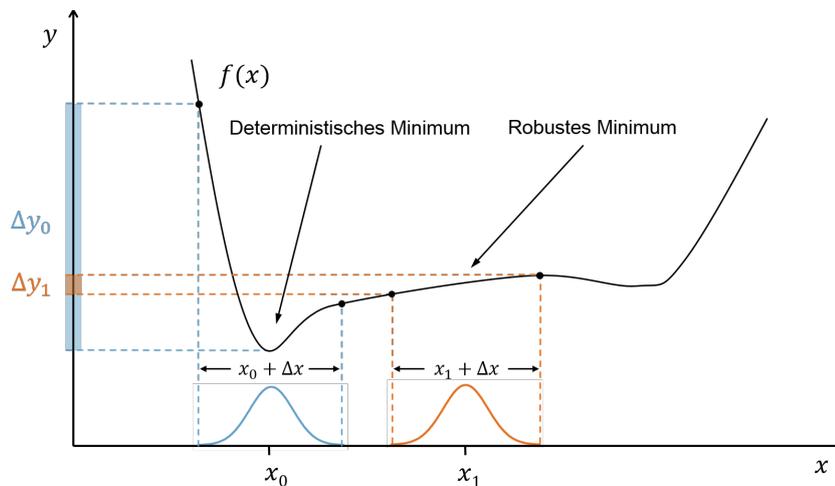


Abbildung 11.1: Unterschied zwischen einem deterministischen und einem robusten Minimum, eigene Darstellung nach Keane und Nair (2005) und Rhein (2014)

Ergebnis der Funktion. Die Schwankung der Eingangsgröße wird im Falle des deterministischen Minimums auf einen weiten Bereich des Ergebnisses der Zielfunktion Δy_0 übertragen. Beim robusten Minimum hingegen wirkt sich die Streuung der Eingangsgröße nur gering auf das Ergebnis der Zielfunktion Δy_1 aus. Dieses Verhalten kann im Allgemeinen als „Robustheit“ definiert werden (Rhein 2014).

Abbildung 11.1 macht auch den Nachteil einer robusten Optimierung deutlich. Die Lösung an der Stelle x_1 weist, im Vergleich zur Stelle x_0 , eine kleinere Unsicherheit in der Zielfunktion auf. Der Wert der Zielfunktion y ist jedoch bei x_1 höher als bei x_0 . Dies bedeutet, dass die Lösung weniger optimal ist. Die Reduktion der Unsicherheit muss also durch eine weniger optimale Lösung erkauft werden. Daraus entsteht der Zielkonflikt einer robusten Optimierung, wobei die Ziele „Reduktion der Unsicherheit“ und „Optimale Lösung der Zielfunktion“ gegeneinander abgewogen werden müssen (Rhein 2014).

Es existiert keine allgemeingültige Definition des Begriffes „Robuste Optimierung“. Eine weitgefasste Definition von Yao et al. (2011) mit Bezug auf S. H. Park (1996), G.-J. Park et al. (2006) und Beyer und Sendhoff (2007) für den Begriff der „Robusten Optimierung“ lautet: „Die robuste Optimierung ist eine Methode zur Optimierung eines Konzeptes oder Systems, mit dem Ziel das System „unempfindlich“ gegenüber unterschiedliche Arten von Schwankungen zu entwickeln“. Im Rahmen dieser Arbeit wird eine robuste Optimierung wie folgt definiert, wobei eine mathematische Definition im Abschnitt 12.3 erfolgt:

„Ziel einer robusten Optimierung ist es, ein vermeintliches Optimum der Zielfunktion zu finden, welche die definierten Restriktionen erfüllt und außerdem widerstandsfähig gegenüber den Unsicherheiten von Randbedingungen ist.“

11.2 Robustheit und Zuverlässigkeit

Generell kann die Optimierung unter Unsicherheiten in zwei Bereiche, Optimierung der Robustheit (Robust Optimization) und Optimierung der Zuverlässigkeit (Reliability Optimization), eingeteilt werden (C. Zang et al. 2005). Bei einer Optimierung der Zuverlässigkeit wird versucht, das System so zu optimieren, dass das Ausgangssignal auch bei Extremereignissen nicht den vorgeschriebenen Toleranzbereich verlässt. Der Toleranzbereich bzw. die Unsicherheit wird dabei nicht optimiert. Dies geschieht bei einer Optimierung der Robustheit. Dabei wird die Unsicherheit und gleichzeitig die Qualität des Systems verbessert.

Erste Arbeiten zur Optimierung unter Berücksichtigung von Unsicherheiten sind bereits in den 1950er Jahren erschienen (Dantzig 1955; Freund 1956). Seit dieser Zeit ist die Entwicklung in diesem Bereich stark vorangeschritten. Ein Schwerpunkt der Untersuchungen lag dabei auf der Entwicklung und Anwendung von Optimierungsalgorithmen (Sahinidis 2004; Schuëller und Jensen 2008). Hervorzuheben ist der japanische Ingenieur Genichi Taguchi, welcher als erster eine robuste Optimierung in einem Produktionsprozess anwendete. Er entwickelte die sogenannte Taguchi-Methode und gilt als „Vater“ der robusten Optimierung (Taguchi et al. 1989).

Die robuste Optimierung wird in weiten Bereichen der Ingenieurwissenschaften angewandt. Als Beispiele ist das Bauingenieurwesen (Dhillon und Belland 1986; Frangopol und Maute 2003) oder die Luft- und Raumfahrttechnik (T. Zang et al. 2002; Padula et al. 2006) zu nennen, da in diesen Bereichen strenge Vorschriften für die Zuverlässigkeit und Robustheit von Systemen existieren. Im Bereich der energetischen Gebäudesimulation ist der Einsatz einer robusten Optimierung erst am Beginn und es sind weitere Untersuchungen notwendig, um Methoden und Anwendungen zu erforschen (Nguyen et al. 2014).

11.3 Robuste Optimierung in der Gebäudesimulation

Die folgenden Abschnitte bilden eine Einführung über die bisherigen Arbeiten zur robusten Optimierung im Bereich der Gebäudesimulation. Dabei wird exemplarisch auch auf bisherige Arbeiten der Bestandteile einer robusten Optimierung, der Unsicherheitsanalyse und der Optimierung eingegangen.

11.3.1 Unsicherheitsanalyse

Als eine vereinfachte Darstellung von Unsicherheiten eines Systems bzw. Gebäudes kann die Streuung des Ausgangssignals genannt werden. In der energetischen Gebäudesanierung wären dies z.B. die jährlichen Schwankungen des Heizwärmebedarfes. Die Unsicherheiten im Bereich des energieeffizienten Bauens können verschiedene Ursachen aufweisen. Im Bereich der Gebäudesimulation können diese Unsicherheiten in folgende Kategorien eingeteilt werden (Macdonald 2002; Wit 2003; Hopfe 2009; Struck 2012; Burhenne 2013):

- i) *Szenario-Unsicherheiten* - Diese Art der Unsicherheiten entsteht durch die Veränderung von Randbedingungen, wie z.B. Wetter oder Nutzerverhalten.
- ii) *Physikalische Unsicherheiten* - Dies sind Unsicherheiten in den Eigenschaften von Komponenten, Bauteilen oder Materialien des Gebäudes, wie z.B. der Wärmedurchgangskoeffizient oder die Luftdichtigkeit. Diese können z.B. durch Unterschiede zwischen der Planung und der Ausführung entstehen.
- iii) *Entwurfs-Unsicherheiten* - Dabei handelt es sich um Unsicherheiten welche durch unterschiedliche Entwürfe des Gebäudes entstehen, z.B. Veränderung der Gebäudegeometrie oder Fensterflächen.
- iv) *Modellunsicherheiten* - Ein Modell ist immer eine Vereinfachung der Realität. Durch diese Vereinfachungen entstehen ebenfalls Unsicherheiten in den Ergebnissen.
- v) *Numerische Unsicherheiten* - Numerische Unsicherheiten entstehen bei der Lösung eines mathematischen Modells, wie z.B. bei der thermischen Gebäudesimulation. Für das Lösen der physikalischen Gleichungen an einem Rechner werden numerische Methoden verwendet, z.B. Finite Volumen, welche selbst auch eine Unsicherheit aufweisen.

Im Rahmen einer Unsicherheitsanalyse (UA) gilt es, in einem ersten Schritt die genannten Unsicherheiten zu quantifizieren. Dies kann z.B. durch die Befragung von Experten, Messungen oder der Analyse einschlägiger Literatur geschehen. Die Darstellung der Unsicherheiten geschieht beispielsweise über die Definition einer Wahrscheinlichkeitsverteilung der unsicheren Parameter. Die Durchführung einer UA kann mit verschiedenen Methoden vollzogen werden. Cox und Baybutt (1981) unterscheiden generell fünf Ansätze für eine Unsicherheitsanalyse: Analytische Methoden, Monte-Carlo-Simulation (MCS), Response Surface Methoden, Differential Sensitivity Analysis und die Bewertung von statistischen Vertrauensintervallen.

Die Monte-Carlo-Simulation (siehe Kapitel 8.3) ist im Bereich der Gebäudesimulation eine weitverbreitete Methode zur Durchführung einer UA (Burhenne 2013). Im Folgenden werden exemplarische Arbeiten mit einer MCS basierten Unsicherheitsanalyse im Bereich der Gebäudesimulation vorgestellt.

Die MCS wird bereits von (Lomas und Eppel 1992) für eine UA im Bereich der Gebäudesimulation angewandt. Dabei werden die Unsicherheiten der Zielgrößen, Energiebedarf, Leistung und Raumtemperatur mit Hilfe eines Tagesmittelwertes analysiert. Als Ursache für die Unsicherheiten werden 70 Eingangsgrößen des Gebäudemodells variiert. Macdonald (2002) vergleicht drei unterschiedliche Ansätze für die UA im Rahmen einer Gebäudesimulation. Dabei differenziert er zwischen einem internen und einem externen Vorgehen. Das interne Vorgehen setzt Anpassungen des Gebäudesimulationsmodells voraus, wohingegen das externe Vorgehen eine Kopplung zwischen Gebäudesimulation und UA repräsentiert. Die drei untersuchten UA Methoden sind Differential Analysis, Factorial Analysis und Monte-Carlo-Simulation. Der Vorteil der MCS gegenüber den anderen beiden Methoden ist die Berücksichtigung aller Interaktionen zwischen den zu untersuchenden Parametern (Macdonald 2002).

Wit (2003) verwendet ebenfalls eine MCS basierte Unsicherheitsanalyse. Als Zielgröße für die Untersuchung werden Kennzahlen des thermischen Komforts im Innenraum herangezogen. Als Sample-Technik für die Erzeugung der Stichproben wird ein „Latin Hypercube Sampling“ (siehe Kapitel 8.3) verwendet. Hopfe und Hensen (2011) nutzen ebenfalls eine MCS in Kombination mit einem Latin Hypercube Sampling. Als Fallstudie dient ein Bürogebäude. Zielgrößen der UA sind der Energiebedarf und der thermische Komfort.

Burhenne (2013) befasst sich mit der Anwendung einer MCS basierten Unsicherheits- und Sensitivitätsanalyse im Kontext der Gebäudesimulation. Dabei analysiert er unterschiedliche Methoden für die Erstellung der Sample-Daten einer MCS. Als Fallbeispiel führt er eine Kosten-Nutzen-Analyse durch, welche die Unsicherheiten von Energiepreis- und Zinsentwicklungen berücksichtigt. Burhenne (2013) kommt zu dem Schluss, dass sich die Monte-Carlo-Simulation aufgrund ihrer vielseitigen Einsetzbarkeit und der geringen Anforderungen an das zu untersuchende System besonders gut für den Einsatz in der Gebäudesimulation eignet.

Die vorgestellten Arbeiten stellen nur einen geringen Ausschnitt der bisherigen Untersuchungen zur MCS basierten Unsicherheitsanalyse im Bereich der Gebäudesimulation dar. Weitere Informationen können z.B. aus Hopfe (2009) oder Struck (2012) entnommen werden. Generell lässt sich aus der Literatur schließen, dass die MCS eine weitverbreitete und umfassend untersuchte Methode für die Anwendung einer UA im Kontext der Gebäudesimulation darstellt. Deshalb wird diese Methode auch im weiteren Verlauf der Arbeit für die Unsicherheitsanalyse angewandt.

11.3.2 Optimierung

Im Bereich der Gebäudesimulation wird unter dem Begriff Optimierung nicht immer auch eine mathematische Optimierung verstanden. In Nguyen et al. (2014) werden unterschiedliche Verwendungen des Begriffes Optimierung zusammengefasst. Dabei wird der Begriff Optimierung auch für eine Parameterstudie verwendet, in der durch manuelle Veränderungen der Gebäudeparameter im Simulationsmodell eine Verbesserung der Zielgrößen erreicht wird. Die Anwendung einer Sensitivitätsanalyse oder die Steigerung der Gebäudeperformance auf Basis von Expertenwissen wird teilweise ebenfalls unter dem Begriff Optimierung zusammengefasst. Überwiegend wird der Begriff Optimierung jedoch für die Verwendung eines Gebäudesimulationsmodells in Kombination mit einer mathematische Optimierung verwendet (Attia et al. 2013).

Die Auswahl einer geeigneten Methode zur mathematischen Optimierung eines Gebäudesimulationsmodells ist ein entscheidender Schritt. Dabei gilt es zuerst das Optimierungsproblem zu formulieren und anschließend einen passenden Optimierungsalgorithmus auszuwählen. In Tabelle 11.1 werden häufig verwendete Optimierungsverfahren in der Gebäudesimulation zusammengefasst. Details zu ausgewählten Verfahren werden in Kapitel 12.2 vorgestellt.

Tabelle 11.1: Häufig angewandte Optimierungsverfahren in der Gebäudesimulation, eigene Darstellung nach Nguyen et al. (2014)

Kategorie	Algorithmus
Allgemeine Verfahren	
Direct Search	Generalized Pattern Search, Hook-Jeeves, Mesh Adaptive Search etc.
Gradientenbasierte Techniken	Quasi-Newton-Verfahren, Levenberg-Marquardt, Discrete Armijo, Gradientenverfahren etc.
Metaheuristiken	
Populationsbasiert	Genetischer Algorithmus, Particle Swarm Optimization, Ant Colony, Bee Colony, Cuckoo Search etc.
Trajektoriebasiert	Simulated Annealing, Tabu Search, Hill Climbing, Harmony Search etc.
Hybride Verfahren	Particle Swarm Optimization + Hook-Jeeves, Genetischer Alogrithmus + Generalized Pattern Search etc.

Bei einer Gebäudesimulation ist das Ausgangssignal und dadurch die Zielfunktion der Optimierung häufig nicht stetig bzw. kontinuierlich (Wetter 2004; Wetter und Polak 2004). Diese Unstetigkeiten können bei traditionellen Optimierungsverfahren, z.B. Gradientenverfahren, Konvergenzprobleme verursachen (Wetter und J. Wright 2004). Deshalb wird empfohlen im Bereich der Gebäudesimulation sogenannte Metaheuristiken zu verwenden (Wetter 2011). Diese Art von Optimierungsverfahren garantiert zwar kein globales Optimum, erreicht aber mit einem angemessenen Rechenaufwand belastbare Lösungen (Nguyen et al. 2014). Im Folgenden werden exemplarische Arbeiten zur Verwendung von Metaheuristiken im Bereich der Gebäudesimulation vorgestellt.

Wetter und J. Wright (2004) vergleichen unterschiedliche Optimierungsverfahren für eine Anwendung in der Gebäudesimulation. Dabei werden Methoden aus den Kategorien Direct Search (Coordinate Search, Hook-Jeeves und Simplex Algorithmus), Gradientbasierte Techniken (Discrete Armijo), Metaheuristiken (Particle Swarm Optimization und Genetischer Algorithmus) und Hybride Algorithmen (Particle Swarm Optimization + Hook-Jeeves) analysiert. Als Fallbeispiele dienen ein vereinfachtes und ein detailliertes Simulationsmodell eines Bürogebäudes. Die Ergebnisse zeigen, dass die beiden Metaheuristiken Particle Swarm Optimization (PSO) und Genetischer Algorithmus (GA) in beiden Fällen belastbare Resultate mit einem angemessenen Rechenaufwand vorweisen. Die besten Resultate werden durch das Hybride Verfahren erzielt. Die Anwendung des Simplex Algorithmus und Discrete Armijo werden nicht empfohlen.

In Bichiou und Krarti (2011) werden Lebenszykluskosten, jährliche Energiekosten und der thermische Komfort im Innenraum als Zielgrößen für die Optimierung verwendet. Als Fallbeispiel dient ein Wohngebäude, welches an fünf unterschiedlichen Standorten in den USA analysiert wird. Dabei werden zwei populationsbasierte Metaheuristiken und ein gradientenbasiertes Verfahren für die Optimierung verglichen. Die beiden Heuristiken sind ein GA und eine PSO. Als gradientenbasiertes Verfahren wird die Sequential Search angewandt. Die beiden Metaheuristiken generieren mit einem geringeren Rechenaufwand bessere Lösungen als das gradientenbasierte Verfahren (Bichiou und Krarti 2011).

Hamdy et al. (2012) vergleichen drei populationsbasierte Metaheuristiken zum Auffinden einer kostenoptimalen Lösung für ein „nearly-Zero-Energy-Building (nZEB)“ (Richtlinie 2010/31/EU 2010) am Beispiel eines Einfamilienhauses. Die verwendeten Metaheuristiken sind drei unterschiedliche Genetische Algorithmen (NSGA-II, pNSGA-II und aNSGA-II (Deb et al. 2002)). Hamdy et al. (2012) zeigen mit Hilfe einer Testfunktion², dass der aNSGA-II die besten Lösungen erzeugt. Bei der Optimierung des Einfamilienhauses weisen alle drei Metaheuristiken verwendbare Lösungen mit angemessenem Rechenaufwand auf.

Die vorgestellten Arbeiten zeigen jeweils einen Vergleich unterschiedlicher Optimierungsverfahren. Dabei wird ersichtlich, dass kein allgemeingültiges Verfahren für alle Probleme existiert und die Auswahl vom Optimierungsproblem abhängig ist. Die Anwendung mathematischer Optimierungsverfahren in der Gebäudesimulation ist mittlerweile, zumindest im Bereich der Forschung, weit verbreitet. Detailliertere Informationen zur Optimierung im Kontext der Gebäudesimulation können aus (Evins 2013; Nguyen et al. 2014; Machairas et al. 2014) entnommen werden. In diesen drei Veröffentlichungen werden, teilweise redundant, mehr als 380 Artikel besprochen. Dabei zeigt sich, dass die PSO und der GA zu den am häufigsten verwendeten Verfahren zählen. Das Optimierungsproblem im Rahmen dieser Arbeit gehört zur Kategorie der nichtlinearen und kontinuierlichen Parameteroptimierung mit beschränktem Suchraum (Kapitel 12.3). Die Vorteile eines GA kommen meist bei einer diskreten Parameteroptimierung zum Vorschein, deshalb wird für die weiteren Analysen in dieser Arbeit die PSO verwendet.

² Die Ergebnisse einer Testfunktion sind bekannt und ermöglichen dadurch eine Validierung des Optimierungsverfahrens.

11.3.3 Robuste Optimierung

Im Rahmen dieser Arbeit wird unter der Methode einer robusten Optimierung die Integration einer Unsicherheitsanalyse in eine mathematische Optimierung auf Basis eines Gebäudesimulationsmodells verstanden. Generell ist die Anwendung einer robusten Optimierung im Bereich der Gebäudesimulation nicht weit verbreitet (Nguyen et al. 2014). Es existieren aber bereits Veröffentlichungen, welche sich mit der Methode nach obiger Definition auseinandersetzen.

Hopfe, Emmerich, et al. (2012) wenden eine robuste Optimierung am Fallbeispiel eines Bürogebäudes in den Niederlanden an. Dabei werden die Zielgrößen Energieverbrauch sowie der thermische Komfort im Innenraum untersucht. Die Unsicherheiten werden mit Hilfe von Wahrscheinlichkeitsverteilungen unterschiedlicher Gebäudeparameter (Infiltration, Art der Verglasung, Stärke der Außenwand etc.) dargestellt. Als Basis für die robuste Optimierung wird ein Ersatzmodell mit dem Kriging-Verfahren erstellt. Die Unsicherheitsanalyse wird mit einer Monte-Carlo-Simulation umgesetzt. Der Optimierungsalgorithmus ist eine populationsbasierte Metaheuristik (SMS EMOA). Die Ergebnisse zeigen, dass unter der Anwendung eines Ersatzmodells (Kriging) robuste Lösungen für das Gebäudedesign ermittelt werden können.

In Nix et al. (2015) wird eine robuste Optimierung zur Verbesserung des Energieverbrauches und der „Gesundheit“ am Beispiel einer typischen Wohnung in Delhi durchgeführt. Die Zielgröße „Gesundheit“ wird anhand der Feinstaubkonzentration quantifiziert. Der Nutzereinfluss, abgebildet durch die Anzahl der Bewohner und den Sollwert der Raumtemperatur, sowie die Feinstaubkonzentration im Außenraum bilden die Unsicherheiten im Modell. Eine Reduktion der Simulationszeiten der robusten Optimierung wird mit Hilfe eines Ersatzmodells erreicht. Das Ersatzmodell, ein Neuronales Netz, wird auf Basis eines detaillierten Gebäudemodells in EnergyPlus erstellt. Die Bewertung der Unsicherheiten wird mit Hilfe einer Monte-Carlo-Simulation durchgeführt. Das Optimierungsverfahren ist ein Genetischer Algorithmus. Die Resultate der Analyse lassen auf eine erfolgreiche Anwendung der vorgestellten Methode schließen. Die Reduktion der Infiltration erweist sich als wirkungsvollste Maßnahme gegenüber der Feinstaubbelastung im Innenraum.

Weitere Arbeiten führen eine robuste Optimierung ohne die Anwendung einer mathematischen Optimierung durch. Dabei werden anstelle des Optimierungsverfahrens vollständige Versuchspläne (Full Factorial Design) oder Teilfaktorpläne (Fractional Factorial Design) aller möglichen Kombinationen der definierten Maßnahmen und Szenarien des Fallbeispiels berechnet. Kotireddy et al. (2015) analysieren mit der genannten Methode robuste Lösungen für das Gleichgewicht von Energieeinsparung und Erzeugung durch erneuerbare Energien anhand eines „Net-Zero-Energy“ Reihenhauses. In van Gelder et al. (2014) wird eine Methode zum robusten Design von Gebäuden entwickelt. Dabei ersetzt ebenfalls die Simulation eines vollständigen Versuchsplans die Anwendung eines Optimierungsalgorithmus. Dieses Verfahren weist, im Vergleich zur Anwendung eines Optimierungsalgorithmus, einen deutlich höheren Rechenaufwand auf und ist deshalb nur begrenzt anwendbar.

11.4 Zusammenfassung

In diesem Kapitel wird ein exemplarischer Überblick über die bisherigen Arbeiten zum Thema Unsicherheitsanalyse und mathematischer Optimierung in der Gebäudesimulation vorgestellt. Aus dieser Literaturrecherche geht hervor, dass die Monte-Carlo-Simulation eine weitverbreitete und robuste Methode für die Anwendung einer Unsicherheitsanalyse im Kontext der Gebäudesimulation darstellt. Deshalb wird diese Methode auch im weiteren Verlauf der Arbeit angewandt. Weiterhin geht hervor, dass für die mathematische Optimierung im Bereich der Gebäudesimulation sogenannte Metaheuristiken empfohlen werden. Dabei zeigt sich, dass die beiden populationsbasierten Metaheuristiken Particle Swarm Optimization (PSO) und der Genetische Algorithmus (GA) zu den am häufigsten verwendeten Verfahren zählen, da sie ohne Einschränkungen auf eine Vielzahl von Optimierungsproblemen einsetzbar sind. Die Optimierungsprobleme im Rahmen dieser Arbeit gehören zur Kategorie der nichtlinearen und kontinuierlichen Parameteroptimierung mit beschränktem Suchraum. Die Vorteile eines GA kommen meist bei einer diskreten Parameteroptimierung zum Vorschein. Deshalb werden für die weiteren Analysen in dieser Arbeit die PSO verwendet.

Die geringe Anzahl von Arbeiten über die Anwendung einer robusten Optimierung im Bereich der Gebäudesimulation und die Literaturrecherche über die Untersuchungen im Bereich der energetischen Gebäudesanierung unter Einfluss des Klimawandels in Kapitel 2.3 weisen einen deutlichen Forschungsbedarf in beiden Bereichen auf. Deshalb wird im Rahmen dieser Arbeit eine ganzheitliche Methode zur robusten Optimierung der energetischen Gebäudesanierung unter Berücksichtigung unsicherer Randbedingungen entwickelt.

12 | Methoden der robusten Optimierung

12.1 Unsicherheitsanalyse

12.1.1 Monte-Carlo-Simulation

Aus der Einführung 11.3.1 geht hervor, dass sich die Methode der Monte-Carlo-Simulation (MCS) für eine Unsicherheitsanalyse im Kontext der Gebäudesimulation eignet. Die MCS wird im Rahmen dieser Arbeit ebenfalls zur Erzeugung von Sample-Daten für das Trainieren und Validieren von Ersatzmodellen verwendet. Die Bestandteile und die Funktionsweise einer Monte-Carlo-Simulation werden daher zum Teil in Kapitel 8.3 bereits eingeführt. Die MCS ist ein Verfahren aus der Stochastik und basiert auf der häufigen Wiederholung von gleichartigen Zufallsexperimenten. Die Quantifizierung von Unsicherheiten geschieht z.B. über die Variation von Eingangsgrößen verbunden mit einer häufigen Wiederholung von Modellsimulationen.

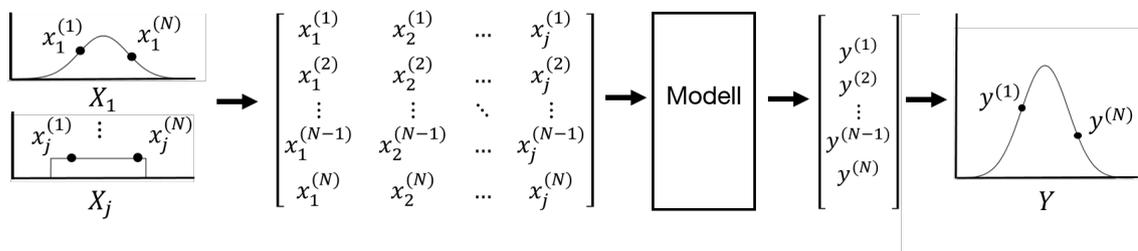


Abbildung 12.1: Schema einer Unsicherheitsanalyse auf Basis einer Monte-Carlo-Simulation

Abbildung 12.1 stellt den schematischen Ablauf einer Unsicherheitsanalyse mit Hilfe einer MCS dar. Dabei werden Wahrscheinlichkeitsverteilungen für die Eingangsgrößen $X_1 \dots X_j$ definiert und mit Hilfe von Sample-Techniken Stichproben $x_1^{(1)} \dots x_j^{(1)}$ ausgewählt und zu einer Samplematrix zusammengefasst. Anschließend wird das Modell N -fach simuliert und die Ergebnisse der Ausgangsgröße(n) $y^{(1)} \dots y^{(N)}$ erfasst. In einem nächsten Schritt können die Unsicherheiten über die Verteilung der Zielgröße Y mit Hilfe von statistischen Kennzahlen, wie z.B. Standardabweichung, Varianz oder Quantile bestimmt werden. Die Bedeutung und Funktionsweise von sogenannten Sample-Techniken werden in Kapitel 8.3 und 9.2 erläutert. Im weiteren Verlauf der Arbeit wird die Methode der Sobol Sequenzen angewandt.

12.1.2 Unsichere Randbedingungen

Die Unsicherheiten einer energetischen Gebäudesanierung werden in dieser Arbeit durch unsichere Randbedingungen, repräsentiert durch klimatische Veränderungen und Energiepreisentwicklungen, abgebildet. Diese Unsicherheiten müssen für die Anwendung bei einer robusten Optimierung im Ersatzmodell über eine Eingangsgröße berücksichtigt werden. Für die Implementierung der klimatischen Unsicherheiten in die robuste Optimierung wird deshalb die Methode ΔT_a eingeführt.

Ziel dieses Abschnittes ist es, eine Methode zu entwickeln mit der die Unsicherheiten des Klimas mit Hilfe eines Parameters im Ersatzmodell abgebildet werden können. Als Grundlage für die Analyse des Klimas dienen in dieser Arbeit die Klimaprojektionen des regionalen Klimamodells REMO (siehe Kapitel 4). Dieses Klimamodell liefert für die Jahre 2000 bis 2100 stündlich aufgelöste Prognosen von drei Klimaszenarien und für die Jahre 1950 bis 1999 Referenzdaten, welche mit gemessenen Klimadaten abgeglichen wurden. Für die weiteren Analysen wird ein exemplarisches Klimaszenario (A1B) ausgewählt. Die Projektionen dieses Szenarios werden für eine bessere Analyse des Klimawandels in vier Perioden von 30 Jahren aufgeteilt. Dabei geht Periode C20 vom Jahr 1970 bis 1999, Periode 1 vom Jahr 2000 bis 2029, Periode 2 vom Jahr 2030 bis 2059 und Periode 3 vom Jahr 2060 bis 2089. Weitere Details zu den Klimadaten und den Perioden können Kapitel 4 entnommen werden.

12.1.2.1 Verteilung der Außentemperatur

Als Grundlage für die Ermittlung der Eingangsgröße in das Ersatzmodell wird eine Analyse der Außentemperaturverteilung von einzelnen Jahresstunden durchgeführt. Abbildung 12.2a präsentiert den Außentemperaturverlauf von 30 Jahren der Periode C20 (1970-1999). In Grafik 12.2b ist die Verteilung einer exemplarischen Jahresstunde (8. Mai 15:00 Uhr) abgebildet. Die gestrichelte Box in Abbildung 12.2a entspricht der ungefähren Lage der Jahresstunde aus Grafik 12.2b. Der Außentemperaturverlauf der Jahresstunde weist die Eigenschaften einer Normalverteilung auf. Eine detaillierte Analyse des Verlaufs der einzelnen Jahresstunden geschieht mit einem Kolmogorov-Smirnov Test¹ (Durbin 1973). Mit Hilfe dieses statistischen Tests kann die Übereinstimmung von zwei Wahrscheinlichkeitsverteilungen untersucht werden. Im Rahmen der Untersuchungen wird der Verlauf der einzelnen Jahresstunden auf eine Normalverteilung getestet. In Abbildung 12.3 sind die Resultate des Tests pro Periode dargestellt. Auf der x-Achse sind jeweils die Jahresstunden aufgetragen und auf der y-Achse der P-Wert des Tests. Bei einem Kolmogorov-Smirnov Test gilt ein P-Wert größer als 0,05 (gepunktete Linie) als Indikator dafür, dass die zu untersuchenden Daten der Vergleichsverteilung entsprechen. Im konkreten Fall bedeutet ein P-Wert größer 0,05, dass die Außentemperatur der Jahresstunde normalverteilt ist.

¹ Der Kolmogorov-Smirnov Test wird mit der Software R und der Funktion `ks.test()` durchgeführt.

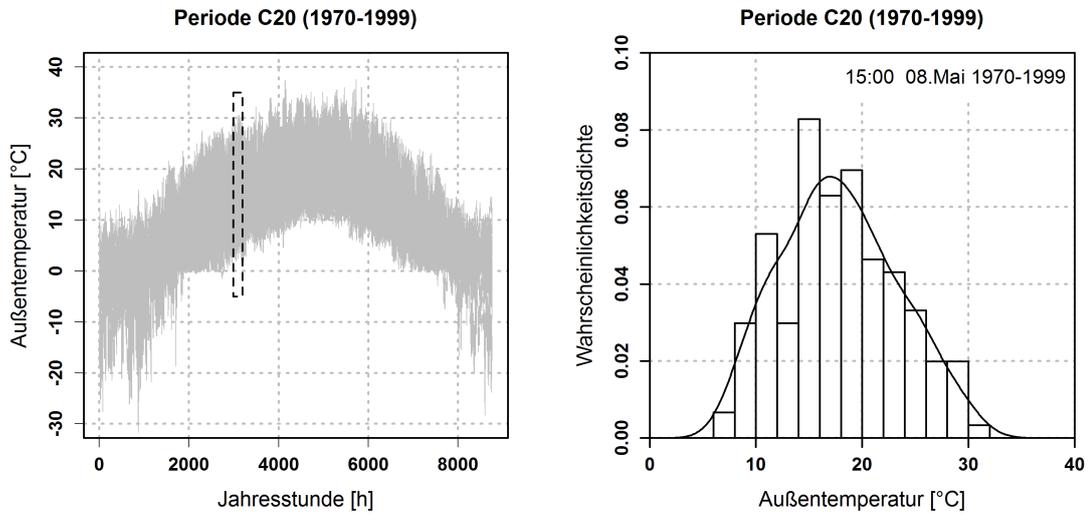
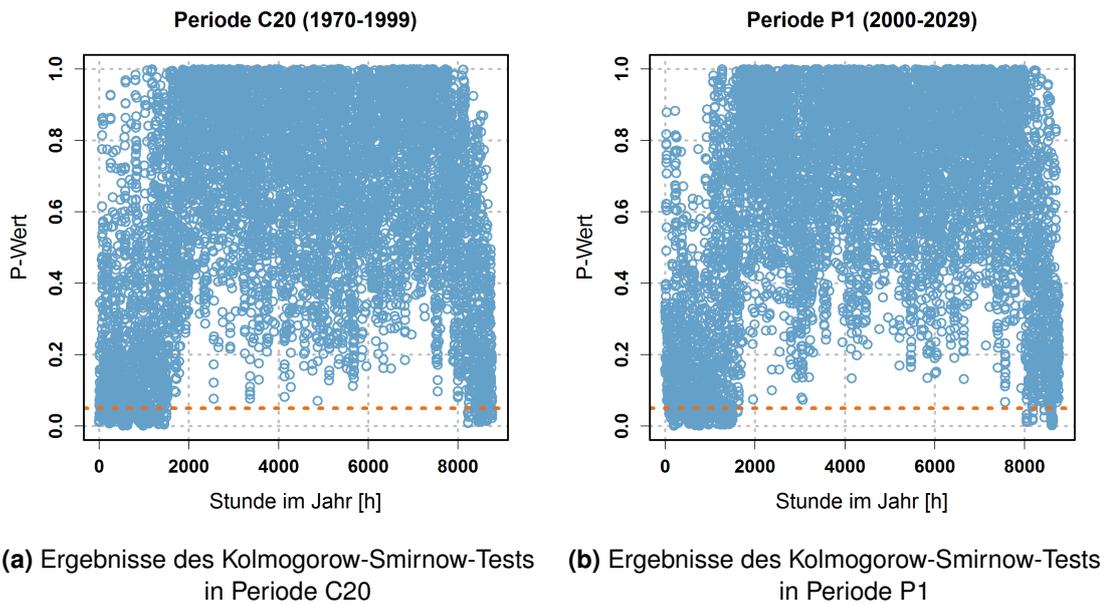
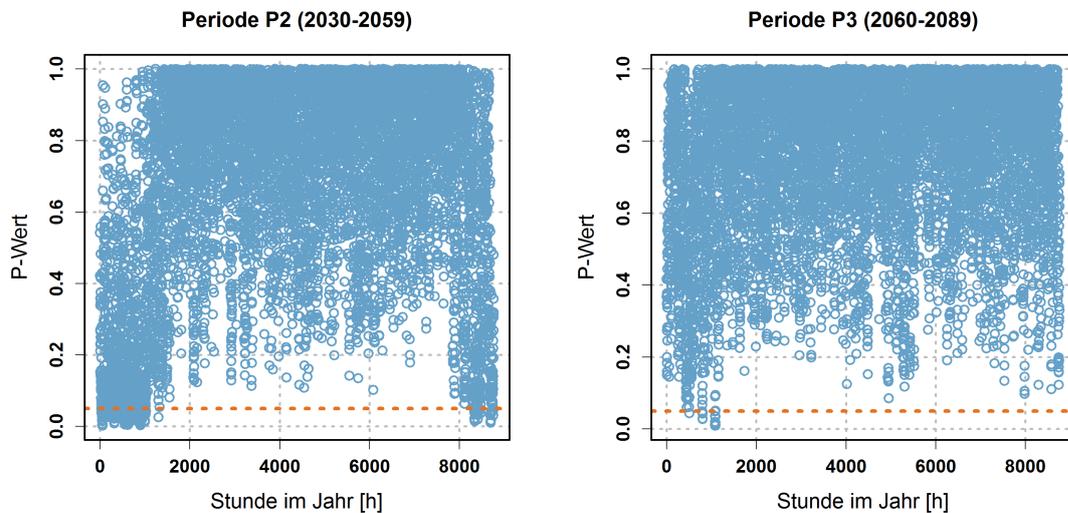


Abbildung 12.2: Verteilung der Außentemperatur





(c) Ergebnisse des Kolmogorow-Smirnow-Tests in Periode P2

(d) Ergebnisse des Kolmogorow-Smirnow-Tests in Periode P3

Abbildung 12.3: Ergebnisse des Kolmogorow-Smirnow-Tests der unterschiedlichen Perioden pro Jahresstunde. Ein P-Wert > 0.05 bedeutet eine Normalverteilung der Außentemperatur in der jeweiligen Jahresstunde.

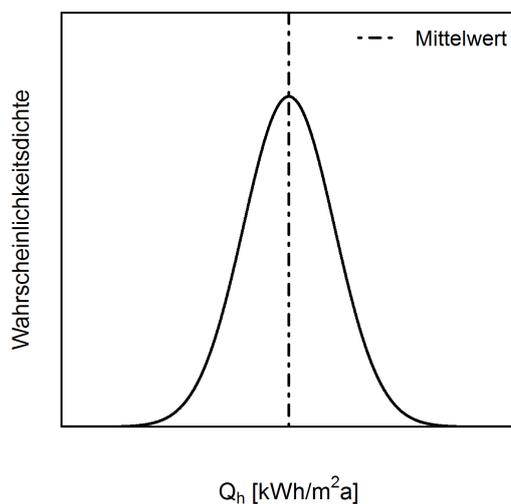
Die Ergebnisse des Tests zeigen deutlich, dass der überwiegende Anteil der Jahresstunden eine Normalverteilung aufweist. Des Weiteren ist zu erkennen, dass mit zunehmender klimatischer Erwärmung der Anteil der normalverteilten Jahresstunden ansteigt. So ist der Anteil normalverteilter Stunden in Periode 3 (Grafik 12.3d) deutlich höher als in der Referenzperiode C20 (Grafik 12.3a).

12.1.2.2 Reduktion der Unsicherheiten des Klimas auf einen Parameter

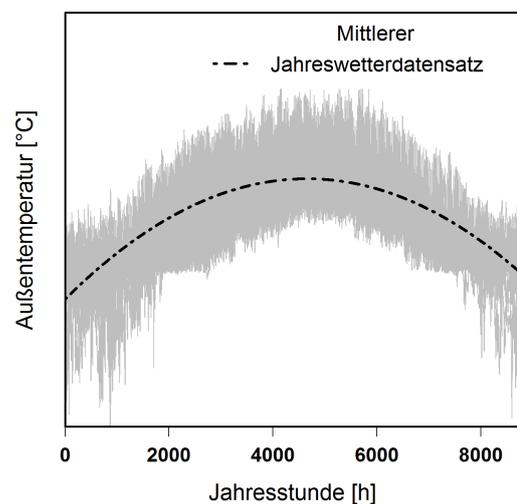
Für die Implementierung der Unsicherheiten des Klimas in die robuste Optimierung müssen diese im Ersatzmodell berücksichtigt werden. Für die Darstellung der Unsicherheiten wird deshalb eine repräsentative Eingangsgröße ermittelt. Aufgrund der oben dargestellten Untersuchungen wird für die einzelnen Jahresstunden eine Normalverteilung der Außentemperatur angenommen. Auf Grund dieser Annahme wird versucht, die klimatischen Veränderungen pro Periode und Jahr mit Hilfe eines Parameters „Delta“, welcher auf die Außentemperatur addiert oder subtrahiert wird, abzubilden. Die folgende Aufzählung sowie Abbildung 12.4 beschreibt das vom Autor entwickelte Vorgehen für die Ermittlung dieses Parameters und wird im weiteren Verlauf als Methode „ ΔT_a “ bezeichnet:

- 1.) Einteilung der Klimaprojektionen in Perioden von z.B. 30 Jahren. Daraus entstehen Gruppen von 30 Jahreswetterdatensätzen.
- 2.) Simulationen des detaillierten Gebäudemodells für die 30 Jahreswetterdatensätze einer Periode. Als Ergebnis aus diesen Simulationen resultieren Verteilungen der Zielgrößen des Gebäudemodells, wie z.B. für den Heizwärmebedarf (Grafik 12.4a).

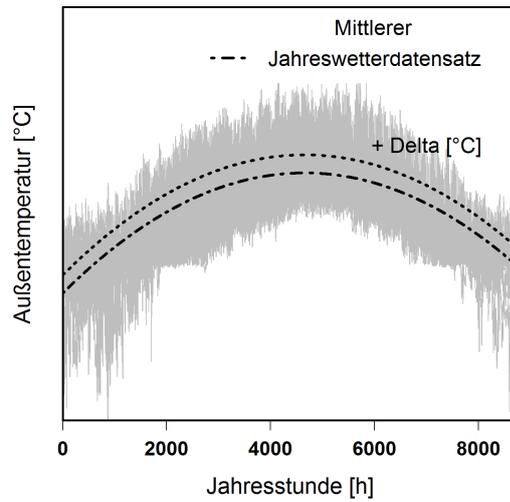
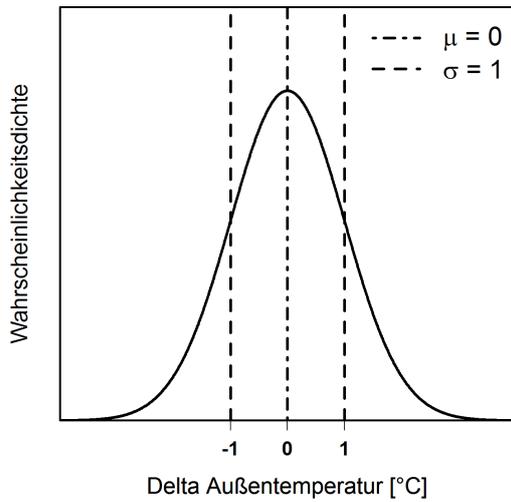
- 3.) Auswahl eines Jahreswetterdatensatzes, welcher den Mittelwert einer Zielgröße, wie z.B. den Erwartungswert der Verteilung des Heizwärmebedarfes, aus den 30 Simulationen einer Periode am besten repräsentiert (Grafik 12.4b).
- 4.) In einem nächsten Schritt wird mit Hilfe eines Deltas der Außentemperatur des mittleren Jahreswetterdatensatzes versucht, die Verteilung der Zielgröße, z.B. Heizwärmebedarf, abzubilden. Dazu werden folgende Schritte durchgeführt:
 - 4.1) Erstellung einer Normalverteilung des Parameters Delta der Außentemperatur auf Basis einer beliebigen Standardabweichung und einem Erwartungswert Null. Diese Verteilung spiegelt die Streuung der Außentemperatur wider. Dabei muss die geeignete Standardabweichung ermittelt werden (Grafik 12.4c). Dies geschieht in einem ersten Schritt durch eine Schätzung, welche in einem iterativem Verfahren sukzessive verbessert wird.
 - 4.2) Erzeugung von 30 Jahreswetterdatensätzen auf Basis des mittleren Jahreswetterdatensatzes und einem Delta aus der erstellten Normalverteilung (Grafik 12.4d).
 - 4.3) Simulationen des detaillierten Gebäudemodells auf Basis der neu erstellten Jahreswetterdatensätze.
 - 4.4) Vergleich der Simulationsergebnisse pro Zielgröße, z.B. Heizwärmebedarf, aus Schritt (2) und (4.3) (Grafik 12.4e). Bei abweichenden Ergebnissen der Zielgrößen wird die Standardabweichung aus Schritt (4.1) für die Normalverteilung des Parameters Delta so lange angepasst (Grafik 12.4f), bis die Abweichungen mit der Zielgröße aus den Simulationen der Wetterdaten angemessen reduziert werden können.



(a) Bestimmung des Mittelwertes der Zielgröße Heizwärmebedarf aus den Ergebnissen der Simulationen einer Periode

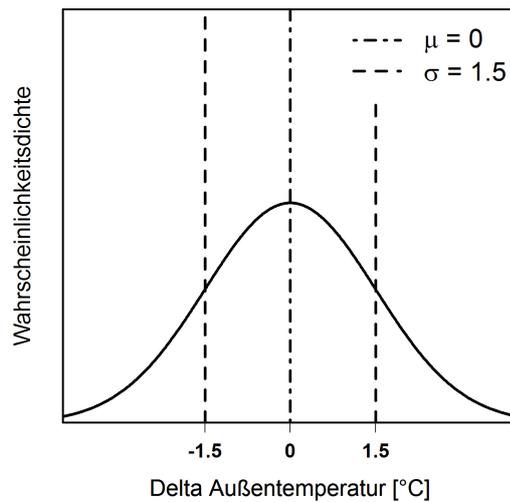
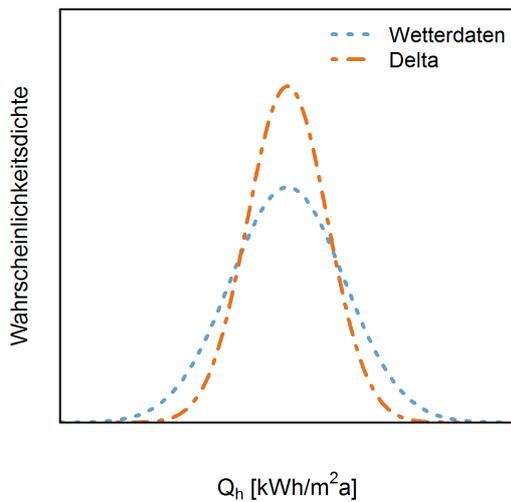


(b) Auswahl des mittleren Jahreswetterdatensatz der Periode



(c) Erstellung einer Normalverteilung des Parameters Delta für die Außentemperatur auf Basis einer beliebigen Standardabweichung und einem Erwartungswert Null

(d) Erstellung neuer Jahreswetterdatensätze auf Basis des mittleren Jahres und einem Delta der Außentemperatur



(e) Vergleich von Simulationsergebnissen des Heizwärmebedarfes auf Basis der originalen Wetterdaten und der Wetterdaten generiert durch das Delta der Außentemperatur

(f) Anpassung der Standardabweichung des Parameters Delta

Abbildung 12.4: Schematischer Ablauf der Methode ΔT_a am Beispiel der Zielgröße Heizwärmebedarf

Im weiteren Verlauf der Arbeit wird für jede Periode und Zielgröße ein Ersatzmodell erstellt. Für die Darstellung der Unsicherheiten des Klimas werden als Eingangsgröße die Werte aus der Verteilung des Parameters Delta herangezogen. Eine Anwendung der Methode ΔT_a wird in Kapitel 13.1.1 vorgestellt.

12.2 Optimierung

12.2.1 Einführung und Überblick

Die folgenden Absätze geben eine kurze Einführung in die Grundbegriffe und Definitionen der mathematischen Optimierung. Die Hauptaufgabe eines Optimierungsproblems oder Optimierungsmodells ist, auf Basis eines Entscheidungsproblems eine optimale Alternative bzw. Lösung in der Menge aller zulässigen Alternativen zu finden. Die Zulässigkeit einer Lösung wird mit Hilfe von Restriktionen bzw. Nebenbedingungen definiert. Die Optimalität einer Alternative wird auf Basis einer Zielfunktion bewertet. Dabei gilt es den Wert der Zielfunktion zu minimieren oder zu maximieren. Optimierungsmodelle beantworten die Frage „What's Best?“ und werden auch präskriptive Modelle genannt (Hillier und Lieberman 2001, S. 1-22).

Elemente eines Optimierungsproblems

Ein Optimierungsproblem besteht in der Regel aus folgenden Elementen (Hillier und Lieberman 2001, S. 1-22):

- i) Mengen - Die Mengen stellen verschiedene Typen von Objekten dar, welche im Optimierungsproblem verwendet werden z.B. $I = \{1, 2, \dots, m\}$.
- ii) Parameter - Mit den Parametern werden die konstanten Größen des zu optimierenden Systems spezifiziert. Diese können z.B. mit Hilfe von Vektoren $p = (p_1, p_2, \dots, p_r) \in \mathbb{R}^r$ abgebildet werden.
- iii) Variablen - Die veränderbaren Größen des Optimierungsproblems werden durch Variablen, auch Entscheidungsvariablen oder Optimierungsparameter genannt, abgebildet. Diese werden ebenfalls durch Vektoren $x = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ repräsentiert.
- iv) Nebenbedingungen - Die Restriktionen bzw. Nebenbedingungen der Zielfunktion werden typischerweise in Form von mathematischen Ungleichungen oder Gleichungen dargestellt. Die „linke Seite“ der Bedingung entspricht dabei den Vektoren der begrenzenden Funktionen $g_i(x, p)$, $i \in I$, und die „rechte Seite“ einem beschränkenden Wert b_i .

$$g_i(x, p) \leq b_i, \quad i \in I$$

- v) Zielfunktion - Die Zielfunktion entspricht einer Funktion aus den Variablen und Parametern des Modells $f(x, p)$, welche entweder max- oder minimiert wird.

$$\min/\max f(x, p), \quad \text{für alle } x, p \in \mathbb{R}$$

Standardform eines Optimierungsproblems

Die Standardform eines Optimierungsproblems bzw. Optimierungsmodells kann wie folgt geschrieben werden (Boyd und Vandenberghe 2011, S. 1-16):

$$\begin{aligned} \min \quad & f(x, p); & x \in \mathbb{R}^n \\ \text{s.t.} \quad & g_i(x, p) \leq 0; & i = 1, \dots, q \\ & x_j^L \leq x_j \leq x_j^U; & j = 1, \dots, m \end{aligned} \quad (12.1)$$

Der Lösungsraum ist definiert:

$$S = \{x \in \mathbb{R}^n \mid x_j^L \leq x_j \leq x_j^U\} \quad (12.2)$$

Die Komponenten des Vektors x stellen die Entscheidungsvariablen der Optimierung dar. Der Vektor p repräsentiert die konstanten Systemparameter. Die Funktion $f(\cdot)$ ist die Zielfunktion und $g_i(\cdot)$ ist der resultierende Vektor aus den Funktionen der Nebenbedingungen. Die Menge S sind die (zulässigen) Lösungen und wird als Lösungsmenge oder Lösungsraum bezeichnet. Ein $x \in S$ wird eine (zulässige) Lösung genannt.

Globale und lokale Optima

Das Optimierungsproblem 12.1 entspricht der Aufgabe unter allen zulässigen Lösungen eine Lösung zu finden, für welche die Zielfunktion minimiert wird. Es wird ein $x^* \in S$ gesucht:

$$f(x^*, p) \leq f(x, p) \quad \text{für alle } x \in S \quad (12.3)$$

Nach Neuman und Morlock (2002, S. 537-544) wird ein solches x^* auch eine Optimallösung genannt. Der Minimalwert $f(x^*, p) = \min\{f(x, p) : x \in S\}$ wird als Optimum oder Optimalwert bezeichnet. Wenn Gleichung 12.3 erfüllt ist, wird x^* auch eine globale Optimallösung genannt und das Optimum $f(x^*, p)$ als „Globales Optimum“ bezeichnet. Dies bedeutet, dass im vorhandenen Lösungsraum keine bessere Lösung für das Minimierungsproblem vorhanden ist. Für die Definition eines lokalen Optimums wird zusätzlich der Begriff der euklidischen Nachbarschaft N_ε eingeführt (Details siehe (Neuman und Morlock 2002, S. 537-544)). So ist $x^* \in S$ eine lokale Optimallösung und $f(x^*, p)$ ein „Lokales Optimum“ wenn $\varepsilon > 0$ existiert:

$$f(x^*, p) \leq f(x, p) \quad \text{für alle } x \in N_\varepsilon(x^*) \cap S \quad (12.4)$$

Abbildung 12.5 zeigt exemplarisch ein globales und ein lokales Minimum der Zielfunktion $f(x)$. Des Weiteren wird das robuste Minimum aus Abbildung 11.1 ergänzt.

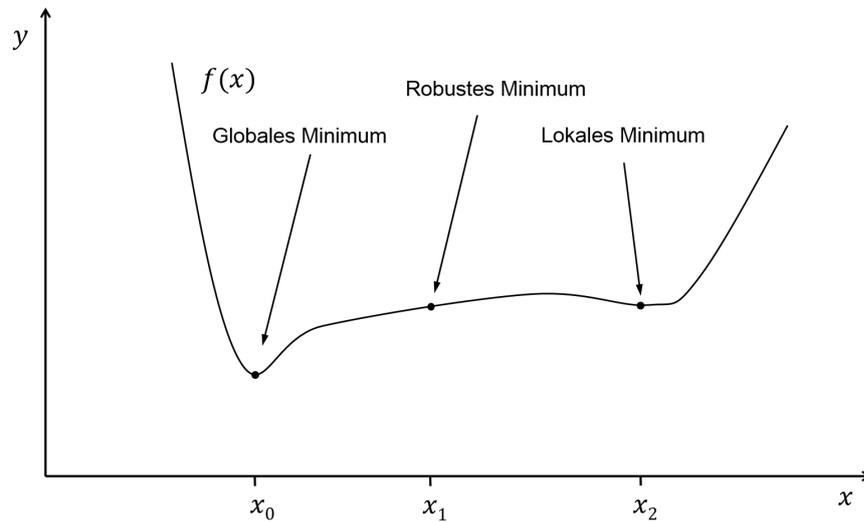


Abbildung 12.5: Exemplarische Darstellung eines globalen, lokalen und robusten Minimums der Funktion $f(x)$

Maximierungs- und Minimierungsprobleme

Optimierungsprobleme können Maximierungs- oder Minimierungsprobleme sein. Jedes Maximierungsproblem kann auf einfache Weise in ein äquivalentes Minimierungsproblem überführt werden (und umgekehrt), denn es gilt (Gritzmann 2013, S. 1-7):

$$\max\{f(x, p) : x \in S\} = -\min\{f(x, p) : x \in S\} \quad (12.5)$$

Kategorisierung von Optimierungsproblemen und Lösungsmethoden

Die methodischen Anforderungen beim Lösen mathematischer Optimierungsprobleme werden bestimmt durch die mathematische Struktur der Zielfunktion und des Lösungsraums. Je nach Struktur und Eigenschaften kommen unterschiedliche Lösungsmethoden zum Einsatz. Nachfolgend werden einige Unterscheidungskriterien zur Kategorisierung von Optimierungsproblemen aufgeführt. Des Weiteren wird ein kurzer Überblick über verschiedene Grundtypen von Optimierungsverfahren gegeben. Dabei liegt der Schwerpunkt auf der Einordnung von populationsbasierten Metaheuristiken zur Anwendung bei einer nichtlinearen und kontinuierlichen Parameteroptimierung, welche den Anwendungsfall im Rahmen dieser Arbeit widerspiegelt.

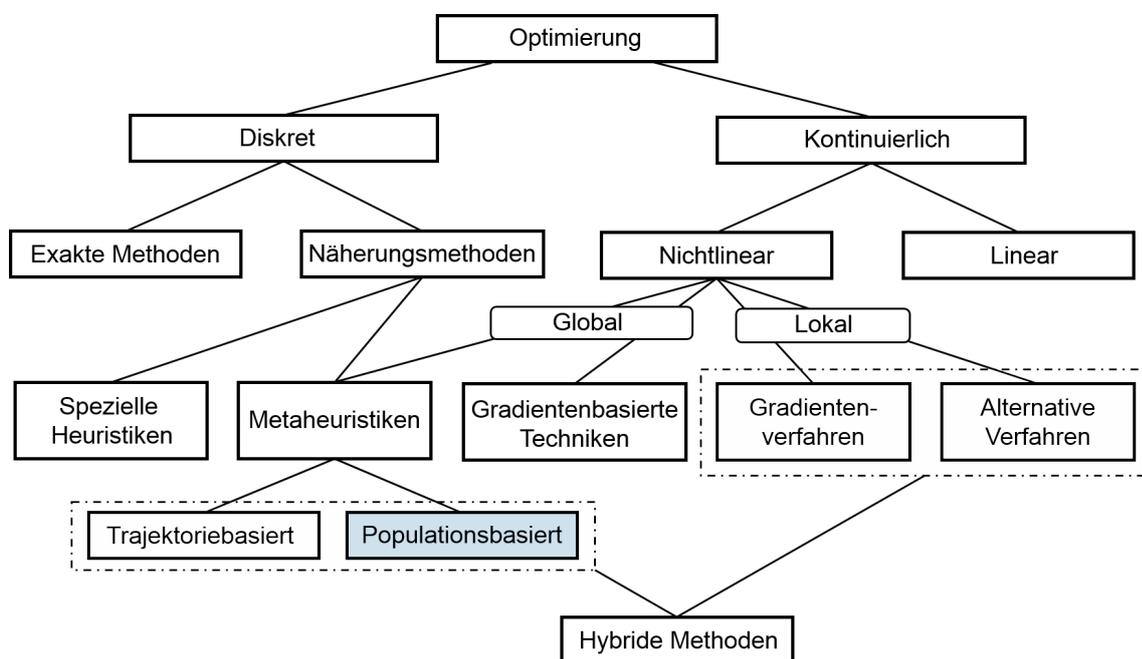


Abbildung 12.6: Exemplarische Kategorisierung unterschiedlicher Optimierungsprobleme und Lösungsmethoden, eigene Darstellung nach (Dréo 2006, S. 19) und (Collette und Siarry 2003)

Abbildung 12.6 stellt einen ausschnittswisen Überblick unterschiedlicher Optimierungsprobleme und Lösungsverfahren dar. Es werden dabei die Bereiche diskrete und kontinuierliche Optimierung unterschieden (Dréo 2006, S. 1-19). Bei einem diskreten Optimierungsproblem ist der Lösungsraum S eine diskrete Menge, d.h. S enthält eine endliche oder abzählbare Anzahl von zulässigen Lösungen. In der Regel sind bei einem diskreten Optimierungsproblem die Entscheidungsvariablen ganzzahlig d.h. $S \subseteq \mathbb{Z}^n$. Es existieren auch Optimierungsmodelle, in denen ein Teil der Entscheidungsvariablen diskret und ein anderer Teil kontinuierlich ist. Mitunter spricht man auch in diesem Fall von einer diskreten Optimierung. Ein Optimierungsproblem kann als kontinuierlich kategorisiert werden, falls keine Entscheidungsvariable auf diskrete Werte eingeschränkt ist.

Eine weitere Unterteilung kann zwischen linearen und nichtlinearen Optimierungsproblemen erfolgen. Die Begriffe linear und nichtlinear beziehen sich dabei auf das Verhalten der Zielfunktion und deren Nebenbedingungen. Es wird weiterhin zwischen einer globalen und lokalen Optimierung differenziert. Unter globaler Optimierung wird die Aufgabe verstanden, eine globale Optimallösung für ein Optimierungsproblem zu finden. Bei lokaler Optimierung begnügt man sich mit dem Auffinden einer lokal optimalen Lösung (Domschke et al. 2015, S. 1-14).

Im Bereich der diskreten Optimierung wird zwischen exakten Methoden und Näherungsmethoden unterschieden. Exakte Optimierungsmethoden liefern entweder eine optimale Lösung oder zeigen auf, dass es keine Optimallösung gibt. Im Gegensatz dazu sind heuristische Methoden oder Heuristiken² Algorithmen, die versuchen eine möglichst gute Lösung zu finden ohne deren Optimalität zu garantieren. Grundsätzlich stellt jedes Verfahren, das eine Lösung zu einem Optimierungsproblem liefert, eine Heuristik dar. Heuristiken kommen typischerweise dann zum Einsatz, wenn keine exakten Verfahren verfügbar sind oder diese nicht angewendet werden können (Burke und Kendall 2005).

Heuristiken werden oft problemspezifisch entwickelt. Sogenannte Metaheuristiken sind dagegen so aufgebaut, dass sie für verschiedene Problemstellungen verwendet werden können. Die Methoden werden auch für nichtlineare und sehr komplexe Probleme der kontinuierlichen Optimierung verwendet. Metaheuristiken basieren in der Regel auf Erfahrungen aus dem täglichen Leben oder aus Beobachtungen der Natur (Burke und Kendall 2005). Deshalb orientieren sich Metaheuristiken oft an Prinzipien der Physik, z.B. „Simulated annealing“ (Kirkpatrick et al. 1983), der Biologie, z.B. „Genetische Algorithmen“ (Schwefel 1977) und der Verhaltensforschung, z.B. „Particle Swarm Optimization“ (Eberhart und Kennedy 1995). In der Regel besitzen Metaheuristiken eine stochastische Komponente. Gegenüber anderen Methoden haben Metaheuristiken den Vorteil, dass sie mit akzeptablem Rechenaufwand gute Näherungslösungen liefern und dabei direkt auf der zu optimierenden Zielfunktion arbeiten (Dréo 2006, S. 1-19) und (Burke und Kendall 2005).

Metaheuristiken können in zwei Klassen eingeteilt werden, welche sich hinsichtlich der zugrundeliegenden Strategie unterscheiden (Dréo 2006, S. 1-19). Einige Verfahren versuchen sich einen „Weg“ (Trajektorie) zum Optimum, Schritt für Schritt, mit der Suche nach einer neuen Lösung auf Basis einer bekannten Näherungslösung zu erarbeiten. Diese Verfahren nennt man trajektoriebasierte Metaheuristiken. Andere Techniken basieren ebenfalls darauf, schrittweise ein Optimum zu finden. Jedoch werden in einem Schritt mehrere Lösungen, eine sogenannte Population, analysiert. Diese Methoden werden populationsbasierte Metaheuristiken genannt. In der aktuellen Forschung werden Metaheuristiken oft mit anderen Verfahren kombiniert. Solche hybride Methoden sind dann in der Lage, die unterschiedlichen Vorteile der verwendeten Verfahren zu nutzen und so gleichzeitig deren Schwächen zumindest teilweise zu umgehen (Dréo 2006, S. 1-19). Weitere Informationen zu Metaheuristiken und ihren Vor- und Nachteilen gegenüber „klassischen“ Methoden, wie dem Gradientenverfahren, können z.B. aus Collette und Siarry (2003), Burke und Kendall (2005) oder Dréo (2006) entnommen werden.

² Altgriechisch „heuriskein“: finden, entdecken

12.2.2 Particle Swarm Optimization

Auf Grund der in Abschnitt 11.3.2 vorgestellten Problematik wird im Bereich der Gebäudesimulation die Anwendung von Metaheuristiken empfohlen. Im Rahmen dieser Arbeit wird die populationsbasierte Metaheuristik - Particle Swarm Optimization (PSO) - verwendet. Die PSO wurde von Eberhart und Kennedy (1995) erstmals vorgestellt und in Kennedy et al. (2001) weiterentwickelt. Die Methode der PSO basiert auf der Modellierung von sozialen Interaktionen. Dabei wird das Schwarmverhalten von Fischen bei der Futtersuche oder das Verhalten von Zugvögeln imitiert. In einem Schwarm versucht jedes Individuum in seiner lokalen Umgebung eine optimale Position zu finden. Dies geschieht unter Berücksichtigung der eigenen Erfahrung sowie dem Verhalten des gesamten Schwarms.

Der Pseudocode auf der nächsten Seite stellt die im Rahmen dieser Arbeit verwendete Form der PSO für die Optimierung mit einer Zielgröße dar. Der Algorithmus generiert zu Beginn eine definierte Anzahl von Partikeln (Population) und verteilt diese zufällig im Suchraum des Optimierungsproblems (Schritt eins und zwei). Anschließend bewegen sich diese Partikel iterativ bis zum Erreichen eines Abbruchkriteriums oder der definierten Anzahl von wiederholten Iterationen (Generationen) durch den Suchraum (Schritt drei bis zehn). Die Zielfunktion wird an jeder Position eines Partikels ausgewertet. Die Bewegungsgleichung (Gl. 12.6) der Partikel wird maßgeblich von zwei Faktoren bestimmt. Jeder einzelne Partikel hat das Bestreben, zu seiner eigenen besten Position bzw. optimalen Lösung der Zielfunktion zurückzukehren (kognitiver Parameter). Der zweite Faktor ist eine Orientierung des Partikels an den besten Ergebnissen der anderen Partikel (sozialer Parameter). Der kognitive Parameter c_1 gewichtet die individuelle Erfahrung. Der soziale Parameter c_2 gewichtet die Erfahrung des Schwarms. Die Parameter z_1 und z_2 sind gleichverteilte Zufallszahlen im Intervall $[0,1]$. Da die beiden Zufallszahlen im Mittel gleich 0.5 sind, werden die beiden Parameter c_1 und c_2 häufig $c_1 = c_2 = 2$ gesetzt. Der Parameter w (inertia weight) in Gleichung 12.6 beschreibt die Trägheit der Partikel. In der Regel ist dies eine Zahl kleiner eins, welche im Laufe der Zeit abnimmt.

Die Schritte sieben und acht im Pseudo-Code sind eine Erweiterung der allgemeinen Form der PSO. Dabei wird im Schritt sieben der Suchraum auf die Ober- und Untergrenzen der Entscheidungsvariablen $\vec{x}_L \leq \vec{x} \leq \vec{x}_U$ beschränkt. Die Geschwindigkeiten der Partikel v können teilweise stark ansteigen. Dies führt zwar zu einer weiträumigen Analyse des Suchraumes, jedoch werden dabei bereits optimale Lösungen weniger stark berücksichtigt. Deshalb ist es sinnvoll, die Geschwindigkeit ebenfalls einzugrenzen (Schritt acht). Der Maximalwert der Geschwindigkeit v_{max} kann dabei aus dem Wertebereich der Entscheidungsvariablen abgeleitet werden (Gleichung 12.10). Es gibt unterschiedliche Möglichkeiten die Geschwindigkeit zu begrenzen. Die abgebildete Option basiert auf Wetter (2011) und wird mit einem λ von 0.5 angewandt. Der Pseudocode wurde in die Software R (R Core Team 2008) implementiert und ist im Detail in Anhang A.2.1 abgebildet.

Algorithm 1 Particle Swarm Optimization

- 1: Definition der Anzahl Partikel (Populationsgröße) n_{pop} und Anzahl der Iterationen (Generationen) n_{gen} sowie der kognitiven c_1 und sozialen c_2 Parameter.
- 2: Für jeden Partikel $j \in \{1, 2, 3, \dots, n_{pop}\}$ im Schwarm wird eine Startlösung $\vec{x}_j(0)$ und eine Startgeschwindigkeit $\vec{v}_j(0)$ initialisiert.

3: **for** $i \leftarrow 1$ to n_{gen} **do**

4: **for** $j \leftarrow 1$ to n_{pop} **do**

- 5: Für jedes Individuum im Schwarm wird für die aktuelle Position $\vec{x}_{j,i}$ die Fitness mit Hilfe der Zielfunktion berechnet. Ist die Fitness die bisher beste, welche das Individuum je erreicht hat, dann

$$\vec{x}_j^{(best)} = \vec{x}_{j,i}$$

Mit $\vec{x}^{(global\ best)}$ wird die beste Position bezeichnet, welche bisher im Schwarm erreicht wurde.

- 6: Für jedes Individuum $j \in \{1, 2, 3, \dots, n_{pop}\}$ wird die neue Geschwindigkeit und die neue Position mit folgenden Gleichungen berechnet:

$$\vec{v}_{j,i+1} = \underbrace{w \cdot \vec{v}_{j,i}}_{\text{Trägheit}} + \underbrace{c_1 \cdot z_1 \cdot (\vec{x}_j^{(best)} - \vec{x}_{j,i})}_{\text{Individuelle Erinnerung}} + \underbrace{c_2 \cdot z_2 \cdot (\vec{x}^{(global\ best)} - \vec{x}_{j,i})}_{\text{Soziale Erfahrung}} \quad (12.6)$$

$$\vec{x}_{j,i+1} = \vec{x}_{j,i} + \vec{v}_{j,i+1} \quad (12.7)$$

- 7: Für die Einschränkung des Suchraumes werden die Grenzen der Entscheidungsvariablen \vec{x}_{Lower} und \vec{x}_{Upper} verwendet:

$$\vec{x}_{j,i+1} = \max(\vec{x}_L; \min(\vec{x}_U; \vec{x}_{j,i+1})) \quad (12.8)$$

- 8: Für eine optimale Analyse des Suchraumes wird die Geschwindigkeit \vec{v}_j folgendermaßen begrenzt:

$$\vec{v}_{j,i+1} = \text{sign}(\vec{v}_{j,i+1}) \cdot \min(\vec{v}_{max}; |\vec{v}_{j,i+1}|) \quad (12.9)$$

$$\vec{v}_{max} = \lambda(\vec{x}_U - \vec{x}_L) \quad \lambda \in \mathbb{R} \quad (12.10)$$

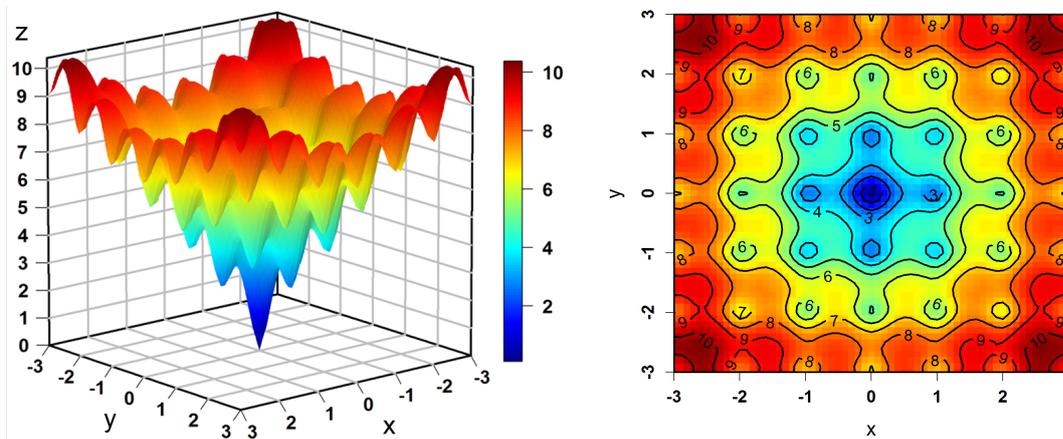
9: **end for**

10: **end for**

Funktionsweise der PSO

Als Beispiel für die Funktionsweise der PSO werden in Abbildung 12.8 unterschiedliche Ergebnisse einer Population mit einer Größe von zwanzig Partikeln, in Abhängigkeit der bereits durchgeführten Iterationen, abgebildet. Dazu wird die „Ackley“ Testfunktion als Fallbeispiel herangezogen. Mit Hilfe sogenannter Testfunktionen ist es möglich, das Suchverhalten eines Optimierungsalgorithmus zu bewerten, da die optimale Lösung bekannt ist.

Abbildung 12.7 stellt die „Ackley“ Testfunktion mit zwei Eingangsgrößen (x, y) dar. Die Gleichung 12.11 zeigt die allgemeine Form der „Ackley“ Funktion, wobei die Parameter im Fallbeispiel mit $a = 20$, $b = 0,2$ und $c = 2 * \pi$ definiert sind. Das Minimum der Funktion ist in Grafik 12.7 deutlich an der Stelle $f(0, 0) = 0$ zu erkennen.



(a) 3-Dimensionale Darstellung der „Ackley“ Testfunktion

(b) 2-Dimensionale Darstellung der „Ackley“ Testfunktion

Abbildung 12.7: „Ackley“ Testfunktion mit zwei Variablen x und y

$$f(x_0 \cdots x_n) = -a \exp \left(-b \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right) - \exp \left(\frac{1}{n} \sum_{i=1}^n \cos(cx_i) \right) + a + \exp(1) \quad (12.11)$$

Abbildung 12.8 bildet die Ergebnisse einer Suche nach dem Minimum der „Ackley“ Funktion mit Hilfe der PSO ab. Dabei werden pro Generation bzw. Iterationsschritt zwanzig Partikel (Population) bewertet. In Grafik 12.8a sind die Resultate (weiße Punkte) nach einem Durchlauf des Optimierungsalgorithmus dargestellt. Die Streuung der Partikel zeigt, dass die Suche auch die Grenzen des Lösungsraumes mit einschließt. Nach der ersten Generation hat jedoch noch kein Partikel das Minimum erreicht. Nach 25 Generationen (Grafik 12.8b) findet schon ein

Teil der 20 Partikel das globale Minimum. Des Weiteren wird deutlich, dass die vielen lokalen Minima der Testfunktion kein Problem für die PSO darstellen. Bei 50 Generationen befindet sich nur noch ein kleiner Teil der Lösungen außerhalb des Optimums und nach 100 Generationen weisen alle Partikel die optimale Lösung auf.

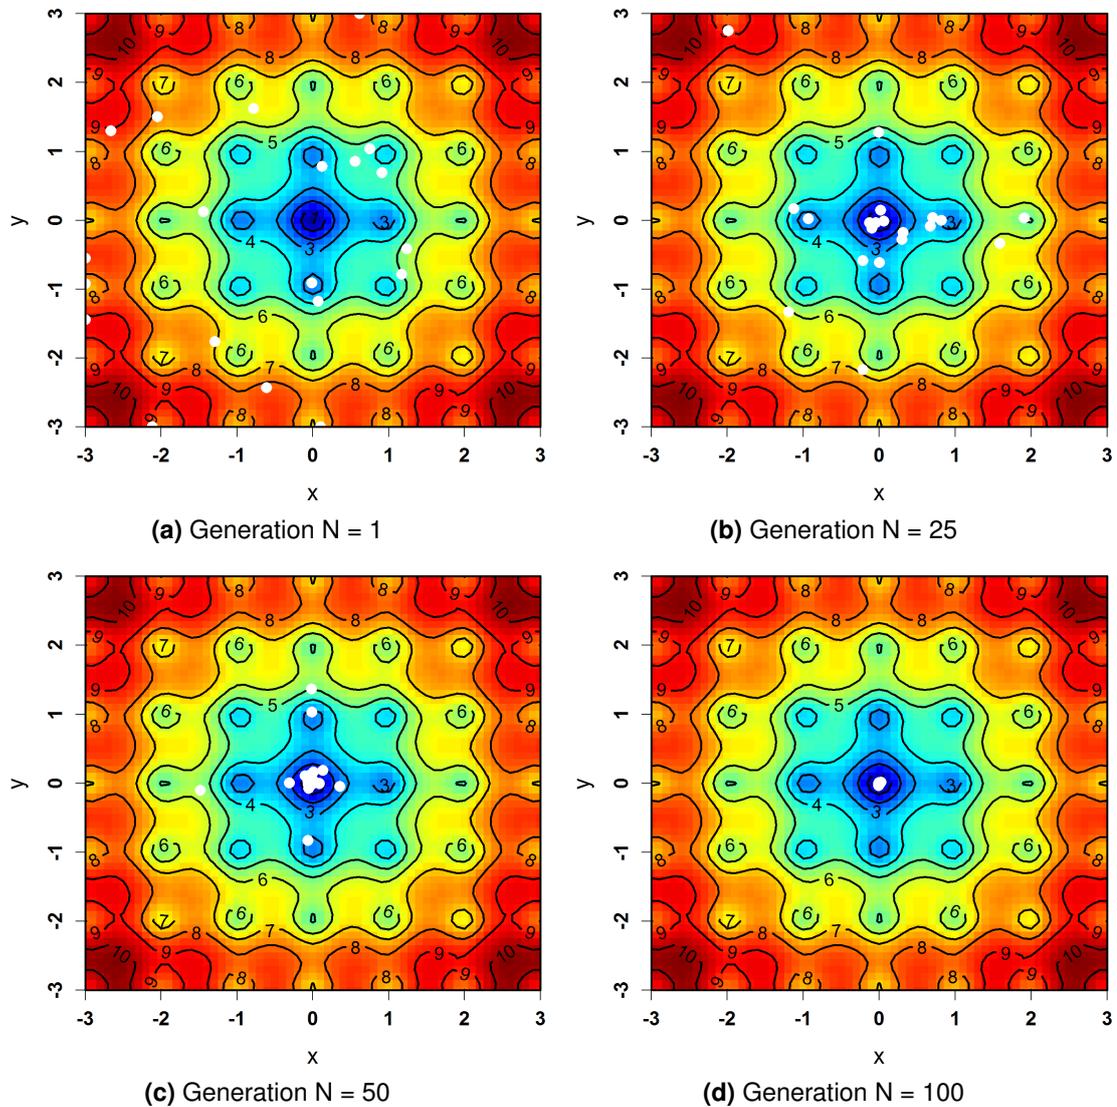


Abbildung 12.8: Ergebnisse des PSO Algorithmus nach unterschiedlicher Anzahl von Iterationen (Generationen) mit einer Populationsgröße von $N = 20$

12.2.3 Multikriterielle Optimierung

Bei einer realen Anwendung einer mathematischen Optimierung existiert oft mehr als eine Zielfunktion. Im Bereich der energetischen Gebäudesanierung stellen z.B. die Reduktion des Energiebedarfes, die Verbesserung des thermischen Komforts oder die Minimierung von Kosten unterschiedliche Zielfunktionen dar. Deshalb ist für ein optimales Planungsergebnis die Berücksichtigung von mehreren Zielgrößen sinnvoll. Eine allgemeine Formulierung eines multikriteriellen Optimierungsproblems lautet:

$$\begin{aligned}
 \min \quad & F(x, p) = (f_1(x, p), f_2(x, p), \dots, f_k(x, p))^T; \quad x \in \mathbb{R}^n \\
 \text{s.t.} \quad & g_i(x, p) \leq 0; \quad i = 1, \dots, q \\
 & x_j^L \leq x_j \leq x_j^U; \quad j = 1, \dots, m
 \end{aligned} \tag{12.12}$$

Der Unterschied zu einem einkriteriellen Optimierungsproblem, aus Gleichung 12.1, ist die Zusammensetzung der Zielfunktion aus k Zielfunktionen. Die Optimierung von mehreren Zielgrößen besitzt in der Regel keine eindeutige Lösung. Denn häufig existieren Lösungen, welche eine Zielfunktion verbessern, jedoch eine andere verschlechtern. Das finale Ergebnis muss meist über einen „Entscheider“ (Decision Maker) bestimmt werden. In der energetischen Gebäudesanierung führt z.B. die Reduktion des Heizwärmebedarfs zu höheren Kosten für qualitativ hochwertigere Fenster oder zusätzlicher Dämmung der Gebäudehülle. Der Entscheider muss gewichten, welches Ziel (Minimierung der Kosten oder Minimierung der Energie) verfolgt wird. Detailliertere Informationen zu den Grundlagen der „Multikriterielle Optimierung“ können aus Ehrgott (2005), und ein Überblick über die multikriterielle Entscheidungsfindung aus Hopfe (2009) entnommen werden.

Die Lösung von Optimierungsproblemen mit mehreren Zielgrößen kann durch unterschiedliche Methoden ermittelt werden. Im Folgenden werden verschiedene Ansätze unter Berücksichtigung eines Entscheiders vorgestellt. Die Differenzierung der Methoden hängt vom Zeitpunkt der Entscheidungsfindung bzw. Eingreifen des Entscheiders ab. Dabei wird zwischen „a priori“, „progressiven“ und „a posteriori“ Strategien unterschieden (Hwang und Masud 1979). Bei einem a priori Verfahren wird die Präferenz des Entscheiders vor dem Lösen des Optimierungsproblems definiert. Das progressive Verfahren bezieht die Prioritäten des Entscheiders schrittweise in die Optimierung mit ein. Der a posteriori Ansatz liefert zuerst die Lösungen der Optimierung, aus diesen dann der Entscheider auswählt.

A priori Ansatz

Eine häufige Umsetzung einer a-priori Strategie ist die Reduktion eines multikriteriellen Optimierungsproblems auf eine Zielfunktion. Dabei werden die einzelnen Zielfunktion gewichtet w_i und die gewichtete Summe der Zielfunktionen optimiert.

$$F_{sum}(x, p) = \sum_{i=1}^k w_i f_i(x, p) \quad (12.13)$$

Ein Problem dieser Methode ist, dass die Gewichte vorab und ohne Kenntnisse über die Ergebnisse der einzelnen Zielfunktionen definiert werden. Bei einer Veränderung der Gewichte ändert sich auch das Ergebnis der Optimierung.

Progressiver Ansatz

Ein progressives Verfahren fordert den Entscheider auf, während der Optimierung seine Präferenzen zu setzen und so den Lösungsraum einzuschränken. Der Entscheider definiert wie im a priori Verfahren Gewichte für die einzelnen Zielgrößen. Diese Strategie erzeugt in der Regel, im Vergleich zu den anderen beiden Ansätzen, einen erhöhten Rechenaufwand. Aus diesem Grund wird ein progressives Verfahren selten im Bereich der Gebäudesimulation angewandt (J. A. Wright et al. 2002).

A posteriori Ansatz

Bei einer a posteriori Strategie werden zuerst die Lösungen des Optimierungsproblems bestimmt und anschließend eine oder mehrere Lösungen vom Entscheider ausgewählt. Die Lösung einer multikriteriellen Optimierung spiegelt die Menge der „besten Kompromisse“ wider. Unter einem besten Kompromiss wird eine Lösung verstanden, in der die Verbesserung einer Zielgröße nur durch eine Verschlechterung einer anderen Zielgröße möglich ist. Die besten Kompromisse werden auch nicht-dominierte Lösungen genannt. Die Definition lautet wie folgt (Deb 2005, S. 282-283):

Eine Lösung $x^{(1)}$ dominiert eine andere Lösung $x^{(2)}$, wenn folgende Bedingungen erfüllt sind:

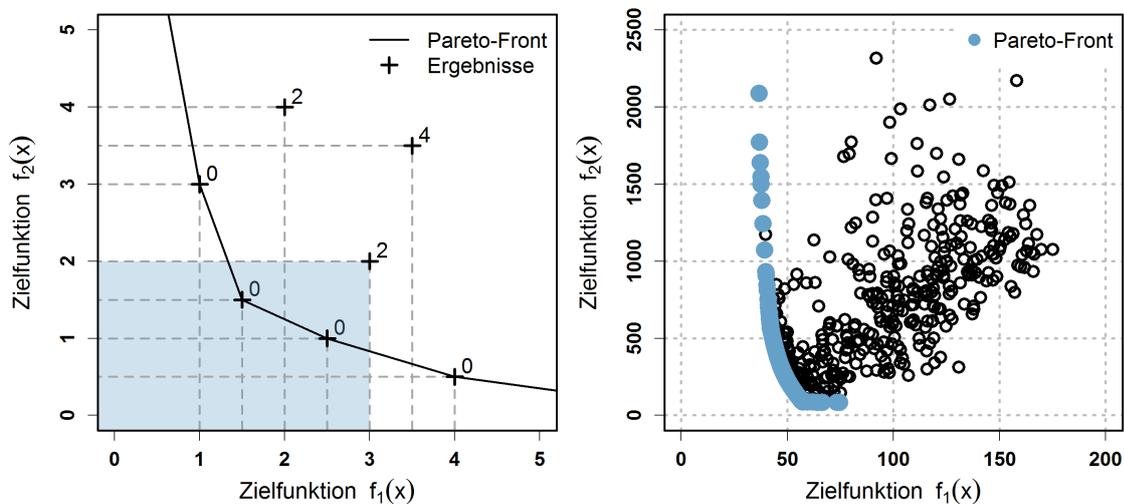
- i) Eine Lösung $x^{(1)}$ ist in allen Kriterien bzw. Zielfunktionen nicht schlechter als $x^{(2)}$

$$f_j(x^{(1)}) \leq f_j(x^{(2)}) \text{ für alle } j = 1, \dots, l$$

- ii) Eine Lösung $x^{(1)}$ ist in mindestens einem Kriterium bzw. Zielfunktion besser als $x^{(2)}$

$$f_j(x^{(1)}) < f_j(x^{(2)}) \text{ für mindestens ein } j \in \{1, \dots, l\}$$

Die nicht-dominierten Lösungen einer Menge P' können durch die dargestellte Definition aus einer Lösungsmenge P ermittelt werden. Falls P den gesamten Suchraum S des Optimierungsproblems umfasst, werden die nicht-dominierten Lösungen P' auch Pareto-Optima oder Pareto-Front genannt. Das Prinzip einer nicht-dominierten Lösung ist in Grafik 12.9a dargestellt. Dabei sind sieben Lösungen einer Optimierung von zwei Zielfunktionen abgebildet. Die nicht-dominierten Lösungen sind mit einer „0“ gekennzeichnet. Dies bedeutet, dass keine andere Lösung des Minimierungsproblems existiert, welche in beiden Zielfunktionen einen niedrigeren Wert aufweist (gestrichelter Bereich einer jeden Lösung). Andere Lösungen werden z.B. von „2“ (farbiger Bereich) oder „4“ Lösungen dominiert. Abbildung 12.9b zeigt eine exemplarische Pareto-Front einer Optimierung mit zwei Zielfunktionen.



(a) Exemplarisches Darstellung von dominierten und nicht-dominierten „0“ Lösungen einer Optimierung mit zwei Zielfunktionen

(b) Exemplarische Lösung einer multikriteriellen Optimierung mit zwei Zielfunktionen und der resultierenden Pareto-Front

Abbildung 12.9: Exemplarische Darstellungen einer Pareto-Front

Die Ermittlung einer Pareto-Front kann auf unterschiedliche Weise erfolgen (Deb 2005, S. 289-295). Eine Möglichkeit ist, wie im a priori Verfahren, die einzelnen Zielfunktionen zu gewichten und die gewichtete Summe zu optimieren. Eine Lösung der Pareto-Front spiegelt dann eine Optimallösung mit einer bestimmten Kombination von Gewichten wider. Des Weiteren eignen sich auch populationsbasierte Metaheuristiken zur effizienten Ermittlung von Pareto-Fronten, wie z.B. der Genetische Algorithmus NSGA-II (Deb et al. 2002). Dabei werden alle Lösungen einer Population auf dominiert oder nicht-dominiert bewertet und dementsprechend für die weitere Optimierung berücksichtigt (Details siehe (Deb 2005)).

Im Rahmen dieser Arbeit wird, je nach Fragestellung, eine a priori oder a posteriori Strategie angewandt. Der a priori Ansatz wird mit dem vorgestellten PSO Algorithmus in Abschnitt 12.2.2 umgesetzt. Das a posteriori Verfahren wird mit einer speziellen PSO für mehrere Zielfunktionen aus dem Paket (Naval 2013) der Software R (R Core Team 2008) durchgeführt.

12.3 Robuste Optimierung

12.3.1 Formulierung eines robusten Optimierungsproblems

Aus Sicht einer nachhaltigen Planung gilt es, Methoden zu entwickeln, welche die Zielgrößen nicht nur optimieren (Kapitel 12.2) oder deren Unsicherheit (Kapitel 12.1) abbilden, sondern beides kombinieren. Eine Möglichkeit dieses Ziel zu erreichen, ist die Integration von Unsicherheiten in das Optimierungsproblem mit Hilfe einer robusten Optimierung. Durch die Anwendung einer robusten Optimierung ist es möglich, von Zielgrößen nicht nur die Lage, sondern auch die Streuung ihrer Verteilungen zu optimieren (siehe Grafik 12.16). Durch die Berücksichtigung von Unsicherheiten ändert sich auch die Struktur des Optimierungsproblems. Bei einer allgemeineren Formulierung wird zu den Entscheidungsvariablen und Parametern in der Zielfunktion und in den Nebenbedingungen aus der Standardformulierung in Gleichung 12.1 ein „Rauschen“ $z \in \mathbb{R}$ addiert (G.-J. Park et al. 2006).

$$f(x, p) \rightarrow f(x + z_x, p + z_p) \quad (12.14)$$

$$g_i(x, p) \rightarrow g_i(x + z_x, p + z_p) \quad (12.15)$$

Dadurch bekommt das Optimierungsproblem folgende Form

$$\begin{aligned} \min \quad & F(x, p, z); \quad x \in \mathbb{R}^n \\ \text{s.t.} \quad & G_i(x, p, z) \leq 0; \quad i = 1, \dots, q \\ & x_j^L \leq x_j \leq x_j^U; \quad j = 1, \dots, m \end{aligned} \quad (12.16)$$

In den Funktionen F und G_i werden das Rauschen bzw. die Unsicherheiten z von f und g_i berücksichtigt. Zur Bewertung der Zielfunktion werden sogenannte Robustheitskriterien (Rhein 2014) benötigt. Diese werden zur Bewertung für die Lage und/oder Streuung der Verteilung der jeweiligen Zielgröße herangezogen. Dies können im Falle einer normalverteilten Zielgröße der Erwartungswert μ und die Standardabweichung σ sein. In diesem Fall kann eine weit verbreitete Formulierung eines robusten Optimierungsproblems folgendermaßen dargestellt werden (Yao et al. 2011):

$$\begin{aligned} \min \quad & \tilde{F}(x, p) = F_{\mu, \sigma}(\mu_f(x, p), \sigma_f(x, p)); \quad x \in \mathbb{R}^n \\ \text{s.t.} \quad & g_i(x, p) \leq 0; \quad i = 1, \dots, q \\ & x_j^L \leq x_j \leq x_j^U; \quad j = 1, \dots, m \end{aligned} \quad (12.17)$$

Dabei können die Entscheidungsvariablen x und/oder die Parameter des Systems p Unsicherheiten aufweisen, μ_f und σ_f sind der Erwartungswert und die Standardabweichung der originalen Zielfunktion $f(\cdot)$.

12.3.2 Robustheitskriterien und Zielfunktion

Bei einer Optimierung unter Unsicherheiten wird die Zielgröße nicht mehr durch einzelne Werte, sondern in der Regel durch eine Wahrscheinlichkeitsverteilung abgebildet. Diese Verteilung repräsentiert die Unsicherheiten. Das Ziel einer robusten Optimierung im Rahmen dieser Arbeit ist es, die Lage und gleichzeitig die Streuung dieser Verteilung zu optimieren. Abbildung 12.10 stellt schematisch eine robuste Optimierung von Verteilung (A) zu (B) dar. Dabei wird die Lage der Verteilung, z.B. repräsentiert durch den Erwartungswert, sowie die Streuung minimiert.

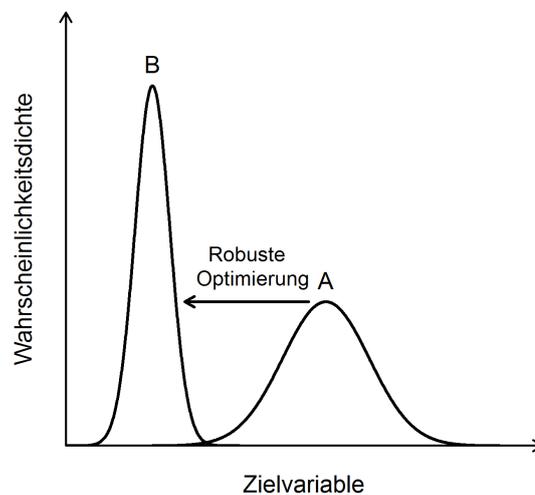


Abbildung 12.10: Schematische Darstellung einer Verteilung der Zielvariable vor (A) und nach (B) einer robusten Optimierung

Für eine robuste Optimierung werden Kriterien benötigt, nach denen die Streuung und Lage einer Verteilung der Zielgröße bewertet werden kann. Diese Kriterien werden Robustheitskriterien oder Robustheitsmaße genannt (Rhein 2014). Dabei werden der Erwartungswert und die Standardabweichung häufig als Kriterien angewandt. Jedoch setzen diese Kennwerte eine Normalverteilung der Zielgröße voraus. Eine weitere Möglichkeit zur Bewertung einer Verteilung ist der Median für die Lage und ein Quantilsabstand oder eine Quantildifferenz für die Streuung (Gleichung 12.18). Das Kriterium der Quantildifferenz überlässt dem Entscheider die Wahl der gewünschten Robustheit. Dies geschieht über die Auswahl von q in Gleichung 12.18. Durch ein höheres q können größere Teile der Verteilung berücksichtigt werden. Die Kombination aus Median und Quantildifferenz ermöglicht auch für nicht normalverteilte Zielgrößen eine angemessene Bewertung der Robustheitskriterien.

$$QD(x) = y_q(x) - y_{(1-q)}(x) \quad (12.18)$$

Abbildung 12.11 zeigt den Vorteil der Kriterien Median und Quantildifferenz. Dabei wird die Kombination aus Erwartungswert und zweifacher Standardabweichung mit dem Median und einer Quantildifferenz aus einem 2,3%-Quantil und 97,7%-Quantil der Verteilungen verglichen. Die resultierende Quantildifferenz von 95,4% entspricht dabei ca. dem Streuintervall einer zweifachen Standardabweichung (95,4499736%). Bei einer normalverteilten Zielgröße in Grafik 12.11a zeigen beide Kombinationen dieselben Ergebnisse. Ist die Verteilung jedoch nicht normalverteilt, wie in Abbildung 12.11b, liefern der Erwartungswert und vor allem die Standardabweichung keine belastbaren Resultate. Die zweifache Standardabweichung reicht in Grafik 12.11b über den Bereich der Verteilung hinaus.

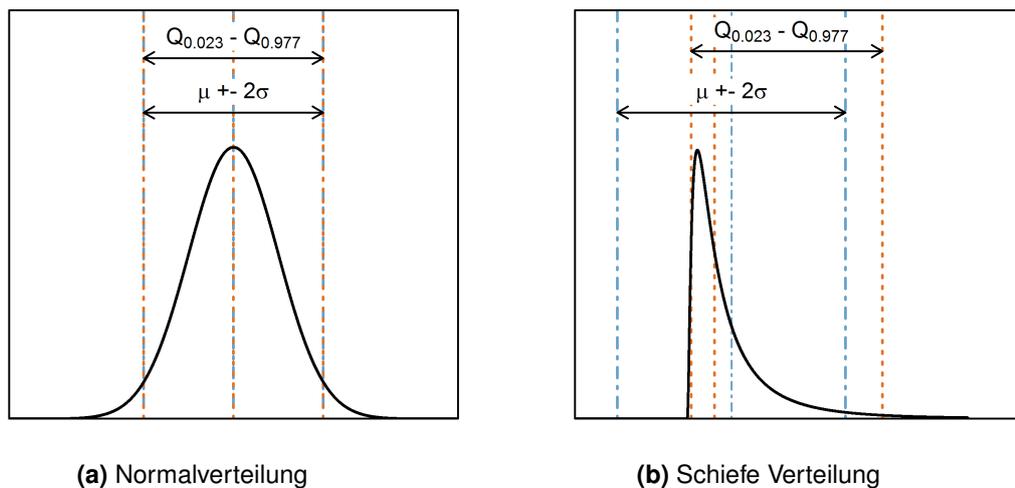


Abbildung 12.11: Vergleich der Robustheitskriterien Median und Quantildifferenz mit dem Erwartungswert und einer Standardabweichung

Die Anwendung einer Quantildifferenz in Kombination mit dem Median hat gegenüber dem Erwartungswert und der Standardabweichung weitere Vorteile (Rhein 2014):

- i) Ein Median repräsentiert die 50% Grenze einer Dichtefunktion und ist gegenüber Ausreißern unempfindlicher als der Erwartungswert. Bei schiefen Verteilungen wie in Grafik 12.11b wird durch den Median die Mitte besser abgebildet.
- ii) Durch die Wahl des Parameters p einer Quantildifferenz kann der Anwender selbst bestimmen, wie viel Prozent einer Verteilung in der Optimierung berücksichtigt werden.
- iii) Der Erwartungswert und die Standardabweichung basieren auf der Annahme einer normalverteilten Zielgröße. Diese Bedingung ist bei einer realen Anwendung häufig nicht gegeben. Im Rahmen dieser Arbeit sind z.B. die Zielgrößen Übertemperaturgradstunden und Kühlbedarf nicht normalverteilt.

Es existieren eine Vielzahl von anderen möglichen Kriterien zur Bewertung der Zielfunktion bei einer robusten Optimierung. Ein weiterführender Überblick kann aus den Arbeiten Beyer und Sendhoff (2007), Jurecka (2007) und Rhein (2014) entnommen werden. Im weiteren Verlauf der Arbeit werden als Robustheitskriterien der Median und eine Quantildifferenz von 99,98% aus einem 0,01%-Quantil und einem 99,99%-Quantil angewandt.

Zielfunktion

Eine robuste Optimierung stellt, wenn Lage und Streuung einer Verteilung berücksichtigt werden, in der Regel ein multikriterielles Optimierungsproblem dar. Die Zielfunktion 12.19 aus der allgemeinen Formulierung eines robusten Optimierungsproblems 12.17 soll dies noch einmal verdeutlichen. Dabei setzt sich die finale Zielfunktion $\tilde{F}(\cdot)$ aus den Funktionen der Zielgrößen Erwartungswert μ_f und Standardabweichung σ_f zusammen. Dadurch weist das Optimierungsproblem zwei Zielfunktionen auf.

$$\tilde{F}(x, p) = \mu_f(x, p) + \sigma_f(x, p) \quad (12.19)$$

Die Lösung eines multikriteriellen Optimierungsproblems kann durch unterschiedliche Verfahren, welche in Kapitel 12.2.3 dargestellt werden, erfolgen. Im Rahmen dieser Arbeit wird, je nach Fragestellung, eine a priori oder a posteriori Strategie angewandt. Die Zielfunktion 12.20 repräsentiert eine allgemeine Form des a priori Ansatzes, welcher in dieser Arbeit verwendet wird. Dabei wird durch eine gewichtete Summe des Medians \bar{x}_{med} und der Quantildifferenz QD das Optimierungsproblem auf eine Zielfunktion $\hat{F}(\cdot)$ reduziert. Bei einer Anwendung der a posteriori Strategie wird für jede Zielgröße, wie z.B. Energiebedarf, Treibhausgas-Emissionen oder Kosten eine Zielfunktion nach 12.20 erstellt und optimiert. Anschließend werden die Ergebnisse mit Hilfe einer Pareto-Front dargestellt.

$$\hat{F}(x, p) = w_1 \bar{x}_{med_f}(x, p) + (1 - w_1) QD_f(x, p) \quad (12.20)$$

In der Regel ist die Größenordnung der Zielgrößen Median und Quantildifferenz verschieden. Daher ist es empfehlenswert, die Größen in relative Maße umzuwandeln. Dies kann durch Division einer Referenzgröße, wie z.B. dem absoluten Minimum, geschehen. In dieser Arbeit werden als Referenzgrößen die Ergebnisse aus dem zu optimierenden Bestandsgebäude ermittelt. Dabei wird z.B. der Median und die Quantildifferenz des Heizwärmebedarfs des Bestandsgebäudes herangezogen. Dadurch wird die Funktion 12.20 um die Skalierungsfaktoren $k_{\bar{x}_{med}}$ und k_{QD} , welche auf Basis des Bestandsgebäudes ermittelt werden, folgendermaßen erweitert.

$$\hat{F}(x, p) = w_1 \left(\bar{x}_{med_f}(x, p) / k_{\bar{x}_{med}} \right) + (1 - w_1) (QD_f(x, p) / k_{QD}) \quad (12.21)$$

12.3.3 Ablauf und Bestandteile einer robusten Optimierung

Im Rahmen dieser Arbeit wird die Methode einer robusten Optimierung durch die Integration einer Unsicherheitsanalyse in eine mathematische Optimierung auf Basis eines Gebäudesimulationsmodells (Black-Box) umgesetzt. Ein allgemeiner Ablauf einer robusten Optimierung kann in vier Schritte eingeteilt werden (Keane und Nair 2005; Rhein 2014):

- i) *Identifikation und Modellierung der Unsicherheiten* - In einem ersten Schritt werden die Unsicherheiten eines Systems, wie z.B. Schwankung der Eingangsgrößen ermittelt. Dies kann durch die Befragung von Experten, Messungen oder einschlägiger Literatur geschehen. Durch eine vorgelagerte Sensitivitätsanalyse können zuerst einflussreiche Parameter ermittelt werden. Anschließend werden die Unsicherheiten mit Hilfe mathematischer Modelle oder Funktionen abgebildet, z.B. mit Hilfe von Wahrscheinlichkeitsfunktionen.
- ii) *Auswahl eines geeigneten Maßes für die Robustheit* - Bei der Auswahl eines geeigneten Maßes für die Robustheit existieren mehrere Möglichkeiten (Rhein 2014). Im Rahmen dieser Arbeit wird ein sogenanntes „Quantildifferenz-Maß“ für die Darstellung der Robustheit verwendet (Kapitel 12.3.2).
- iii) *Auswirkungen der Unsicherheiten auf die Zielfunktion* - Im dritten Schritt wird auf Basis eines Modells eine Unsicherheitsanalyse durchgeführt. Dies kann durch unterschiedlichste Methoden erfolgen wie z.B. der Monte-Carlo-Simulation (siehe Kapitel 8.3 und 12.1).
- iv) *Formulierung und Lösung des Optimierungsproblems* - Der letzte Schritt dient der Formulierung und Lösung des Optimierungsproblems. Dabei können je nach Anzahl der Zielvariablen und dem gewählten Maß für die Robustheit ein- oder multikriterielle Verfahren verwendet werden (siehe Kapitel 12.2 und 12.3).

In Abbildung 12.12 ist ein schematischer Ablauf der robusten Optimierung, welcher im Rahmen dieser Arbeit verwendet wird, dargestellt.

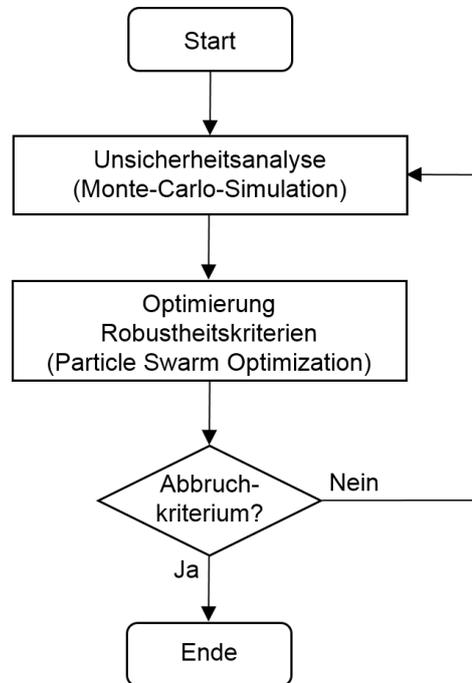


Abbildung 12.12: Schematischer Ablauf der robusten Optimierung

13 | Resultate und Diskussion

Dieses Kapitel zeigt die beispielhafte Anwendung einer robusten Optimierung für eine energetische Gebäudesanierung unter Berücksichtigung klimatischer Unsicherheiten. Dabei wird das in Teil II beschriebene Gebäude als Fallbeispiel herangezogen. In einem ersten Schritt werden die Unsicherheiten des Klimas mit Hilfe der eingeführten Methode ΔT_a quantifiziert. Weiterhin wird ein Ersatzmodell mit Hilfe eines Neuronales Netzes erstellt. Anschließend wird das Ersatzmodell, auf Basis des detaillierten Gebäudemodells, validiert. Die robuste Optimierung wird zuerst mit einer Zielfunktion aus der gewichteten Summe mehrerer Zielvariablen nach einem a priori Ansatz durchgeführt. In einem weiteren Schritt wird für die robuste Optimierung ein a posteriori Ansatz herangezogen, bei dem die Resultate durch eine Pareto-Front und ein Netzdiagramm visualisiert werden. Die beispielhaften Anwendungen des a priori und a posteriori Ansatzes dienen der Einführung und Verdeutlichung der Methode. Eine vollständige Darstellung der Methode zur robusten Optimierung für die energetische Gebäudesanierung unter Berücksichtigung unsicherer Randbedingungen wird in Teil V und eine umfassendere Anwendung mit drei konkreten Aufgabenstellungen in Teil VI dieser Arbeit vorgestellt.

13.1 Modellentwicklung

13.1.1 Quantifizierung der Unsicherheiten

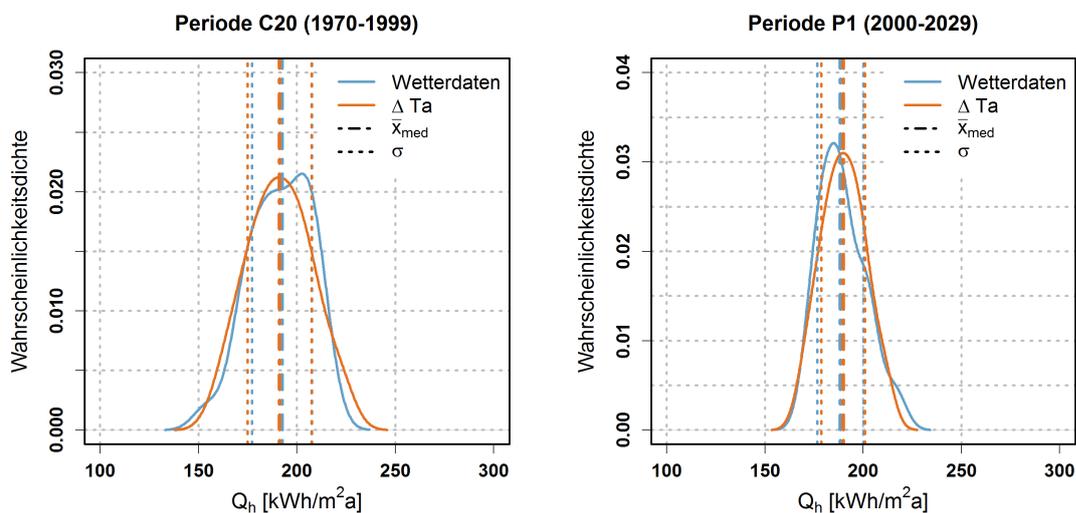
Für die Integration der Unsicherheiten des Klimas in die robuste Optimierung ist es notwendig, eine repräsentative Eingangsgröße für das Ersatzmodell zu ermitteln. In Kapitel 12.1.2 wird die Methode ΔT_a beschrieben, welche auf Basis eines durchschnittlichen Jahres einer Periode und einem Parameter Delta der Außentemperatur die Unsicherheiten des Klimas abbildet. Zur Erstellung des Ersatzmodells wird in einem ersten Schritt die Verteilung des Parameters Delta bestimmt. Dazu werden unterschiedliche Standardabweichungen für die Verteilung von Delta, abhängig von der jeweiligen Zielgröße, analysiert (siehe Kapitel 12.1.2).

In den folgenden Abschnitten wird ein Vergleich der Methode ΔT_a mit Simulationen von Wetterdaten des regionalen Klimamodells vorgestellt. Dabei wird die Zielgröße Heizwärmebedarf Q_h in den unterschiedlichen Perioden miteinander verglichen. Der Heizwärmebedarf spiegelt den Bedarf des Bestandsgebäudes aus dem in Teil II vorgestellten Fallbeispiel wider. Die durch die Methode ΔT_a ermittelten Verteilungen des Parameters Delta sind in Tabelle 13.1 zusammengefasst.

Tabelle 13.1: Verteilungen des Parameters Delta für die Zielgröße Q_h

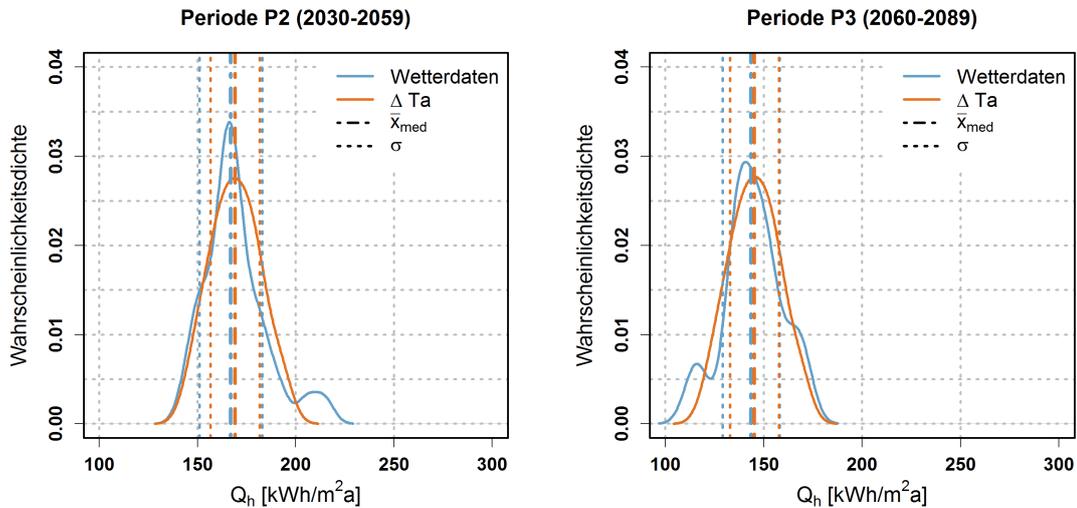
Periode	Verteilung Delta [K]
C20	$N(0;1,0)$
P1	$N(0;0,8)$
P2	$N(0;1,2)$
P3	$N(0;1,0)$

Abbildung 13.1 zeigt einen Vergleich der Methode ΔT_a mit Simulationen von Wetterdaten aus unterschiedlichen Perioden. Die Ergebnisse aus den Simulationen der Wetterdaten sind in blau und die Resultate der Methode ΔT_a in rot abgebildet. Für einen besseren Vergleich werden der Median \bar{x}_{med} und die Standardabweichung σ der jeweiligen Verteilung dargestellt. Die Resultate der Methode ΔT_a basieren auf den in Tabelle 13.1 vorgestellten Verteilungen des Parameters Delta. Generell zeigen die Resultate mit der Methode ΔT_a eine hohe Übereinstimmung mit den Simulationen der Wetterdaten. Der Median und die Standardabweichung weisen nur geringfügige Abweichungen auf.



(a) Vergleich der Methode ΔT_a mit Simulationen von Wetterdaten aus dem regionalen Klimamodell in Periode C20

(b) Vergleich der Methode ΔT_a mit Simulationen von Wetterdaten aus dem regionalen Klimamodell in Periode 1



(c) Vergleich der Methode ΔTa mit Simulationen von Wetterdaten aus dem regionalen Klimamodell in Periode P2

(d) Vergleich der Methode ΔTa mit Simulationen von Wetterdaten aus dem regionalen Klimamodell in Periode P3

Abbildung 13.1: Vergleich der Methode ΔTa mit Simulationen von Wetterdaten aus dem regionalen Klimamodell

In Tabelle 13.2 sind die Ergebnisse des Medians und der Standardabweichungen zusammengefasst. Dabei weist der Median der beiden Methoden eine maximale Abweichung von 2 kWh/m²a und die Standardabweichung von 3 kWh/m²a auf. Die geringen Abweichungen der Methode ΔTa gegenüber den Simulationen der Wetterdaten zeigen, dass die Methode ΔTa die Unsicherheiten des Klimas in angemessener Genauigkeit abbilden kann.

Tabelle 13.2: Vergleich der Methode ΔTa mit Simulationen aus dem regionalen Klimamodell

Periode	Median	Standardabweichung
	[kWh/m ² a]	[kWh/m ² a]
C20-Wetterdaten	192	15
C20- ΔTa	191	16
P1-Wetterdaten	188	12
P1- ΔTa	190	11
P2-Wetterdaten	167	16
P2- ΔTa	169	13
P3-Wetterdaten	144	15
P3- ΔTa	145	12

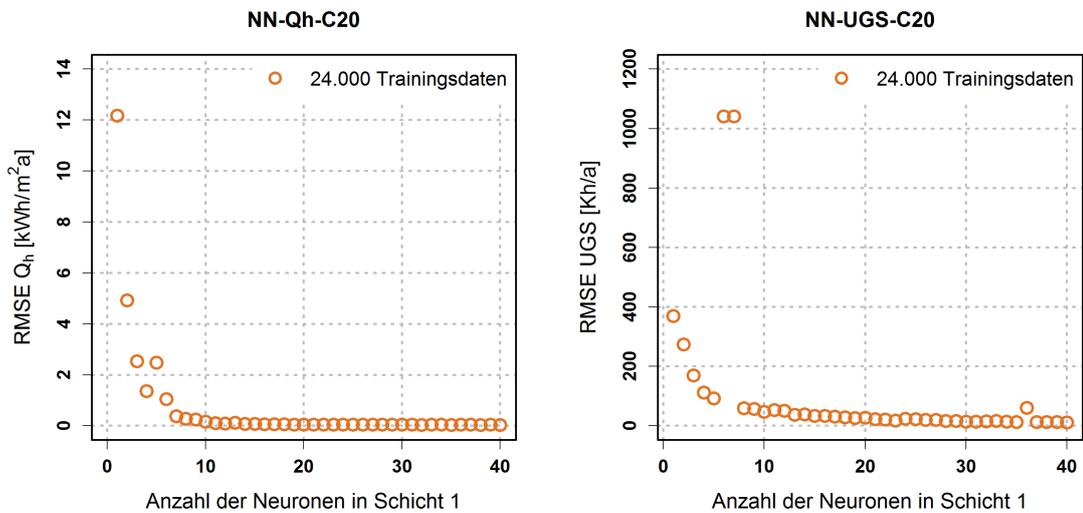
13.1.2 Erstellung Ersatzmodell

Für die Anwendung einer robusten Optimierung wird jeweils ein Ersatzmodell für die Zielgrößen Heizwärmebedarf und Übertemperaturgradstunden erstellt. Die Entwicklung der Ersatzmodelle wird nach dem in Kapitel 8.1 und 9.1 dargestellten Ablauf und auf der Datengrundlage des Fallbeispiels in Teil II durchgeführt. Jedoch werden für die Darstellung der Unsicherheiten des Klimas die Ersatzmodelle jeweils um die Eingangsgrößen ΔTa_{Qh} und ΔTa_{UGS} , welche durch die Methode ΔTa ermittelt werden, ergänzt. Die Ersatzmodelle werden für die exemplarische Anwendung der robusten Optimierung lediglich für die Periode C20 (1970-1999) entwickelt. In Tabelle 13.3 werden die Eingangsgrößen und ihre Wertebereiche für die Erstellung und die Anwendung der Ersatzmodelle zusammengefasst.

Tabelle 13.3: Eingangsgrößen der Ersatzmodelle mit Wertebereich für die Erstellung und die Anwendung in Periode C20

Eingangsgrößen	Erstellung	Anwendung	Einheit
U-Wert Außenwand	U(0,01;1,6)	U(0,1;1,4)	[W/m ² K]
U-Wert Dach	U(0,01;1,6)	U(0,1;1,1)	[W/m ² K]
U-Wert Boden	U(0,01;1,6)	U(0,1;1,1)	[W/m ² K]
U-Wert Fenster	U(0,5;3,5)	U(0,6;3,5)	[W/m ² K]
g-Wert Verglasung	U(0,2;0,8)	U(0,3;0,75)	[-]
Fc-Wert Sonnenschutz	U(0,1;1,0)	U(0,25;1,0)	[-]
Luftwechsel	U(0,4;0,8)	U(0,6;0,7)	[h ⁻¹]
ΔTa_{Qh} C20	N(0;1)	N(0;1)	[K]
ΔTa_{UGS} C20	N(0;1)	N(0;1)	[K]

Damit die Ersatzmodelle den definierten Anwendungsbereich in einer angemessenen Modellgüte wiedergeben können, sind 24.000 Trainingsdatensätze notwendig (siehe Abschnitt 13.1.3). Für die Kreuzvalidierung des Modells werden 6.000 Validierungsdaten herangezogen. Daraus resultiert eine Anzahl von 30.000 Sample-Daten für das Lernen und Testen der Ersatzmodelle. Die Ersatzmodelle werden mit Hilfe des in Teil III favorisierten Neuronalen Netzes und dessen vorgestellte Struktur erstellt. Abbildung 13.2 zeigt die Kalibrierung des Neuronalen Netzes. Dabei wird die Modellgüte (RMSE) in Abhängigkeit der Neuronenanzahl in der verdeckten Schicht analysiert. Beide Netze weisen bei einer Anzahl von 10 Neuronen bereits eine erhebliche Verbesserung des Modellfehlers auf. Des Weiteren ist zu erkennen, dass mit einer steigenden Anzahl von Neuronen die Modellgüte nicht mehr signifikant verbessert werden kann. Der Modellfehler ist beim Neuronalen Netz des Heizwärmebedarfs NN-Qh-C20 bei einer Anzahl von 36 Neuronen am geringsten. Das Netz der Übertemperaturgradstunden NN-UGS-C20 weist bei einer Anzahl von 38 Neuronen in der verdeckten Schicht den kleinsten Fehler auf.



(a) Modellgüte (RMSE) der Zielgröße Q_h in Abhängigkeit der Anzahl Neuronen in der ersten Schicht mit 24.000 Trainingsdaten

(b) Modellgüte (RMSE) der Zielgröße UGS in Abhängigkeit der Anzahl Neuronen in der ersten Schicht mit 24.000 Trainingsdaten

Abbildung 13.2: Strukturoptimierung der beiden Netze NN-Qh-C20 und NN-UGS-C20

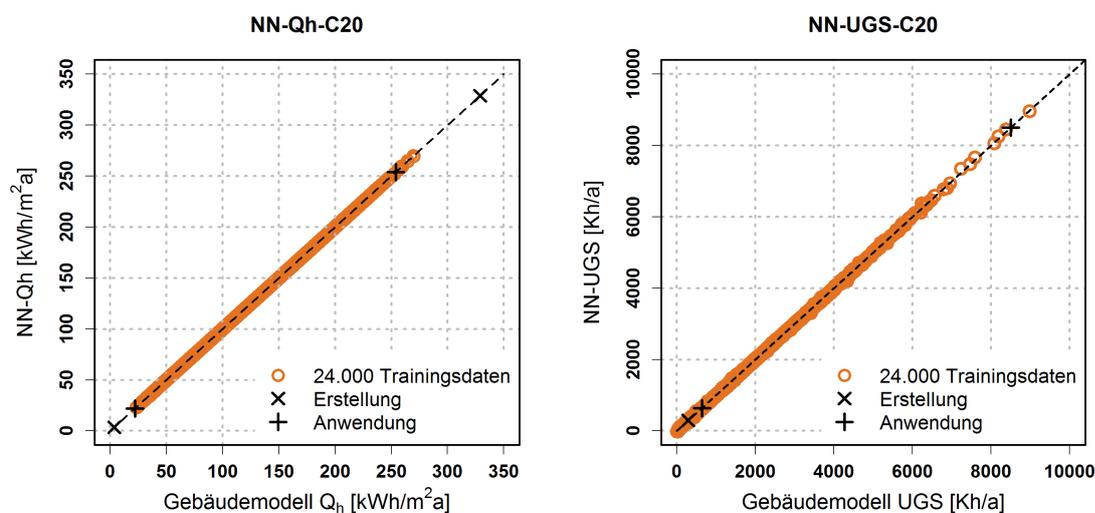
13.1.3 Validierung Ersatzmodell

Tabelle 13.4 fasst die statistischen Kennwerte der Kreuzvalidierung zusammen. Dabei weist die Prognose des Ersatzmodells für Q_h eine mittlere Abweichung (RMSE) von 0,04 kWh/m²a und für die UGS von 11,89 Kh/a auf. Dies entspricht einer durchschnittlich prozentualen Abweichung (CV) der Ersatzmodelle für Q_h von 0,03% und für UGS von 0,69%. Diese Ergebnisse lassen auf eine sehr hohe Modellgüte schließen und werfen die Frage auf, ob eine Anzahl von 24.000 Trainingsdaten notwendig ist. Jedoch muss, wie in Kapitel 9.4 beschrieben, auch der Anwendungsbereich des Ersatzmodells bei der Validierung berücksichtigt werden.

Tabelle 13.4: Ergebnisse aus der Kreuzvalidierung mit den Zielgrößen Q_h und Q_c

Modell	Training	Parameter	RMSE	CV	R ²
NN-Qh-C20	24.000	36 Neuronen	0,04 [kWh/m ² a]	0,03 [%]	0,99999
NN-UGS-C20	24.000	38 Neuronen	11,89 [Kh/a]	0,69 [%]	0,99986

Die Ergebnisse für die Validierung des Anwendungsbereiches der Ersatzmodelle sind in Abbildung 13.3 dargestellt. Die Grenzen der Wertebereiche für die Erstellung und die Anwendung der Neuronalen Netze werden mit einem Kreuz „x“ und einem Plus „+“ gekennzeichnet. Lediglich die obere Grenze des Lernbereiches für die Zielgröße UGS wird aufgrund einer besseren Visualisierung nicht abgebildet. Der Gültigkeitsbereich der beiden Ersatzmodelle wird durch die Ergebnisse (roten Punkte) in Abbildung 13.3 repräsentiert. Beide Ersatzmodelle zeigen, dass für die Darstellung des Anwendungsbereiches die Anzahl von 24.000 Trainingsdaten notwendig ist, da die Grenzen des Anwendungsbereiches sehr nahe an den Rändern des Gültigkeitsbereiches der Ersatzmodelle liegen.



(a) Streudiagramm der Zielgröße Q_h mit einer Anzahl von 24.000 Trainingsdaten (b) Streudiagramm der Zielgröße UGS mit einer Anzahl von 24.000 Trainingsdaten

Abbildung 13.3: Streudiagramme mit den Prognosen des Neuronalen Netzes und des detaillierten Gebäudemodells

13.2 Robuste Optimierung

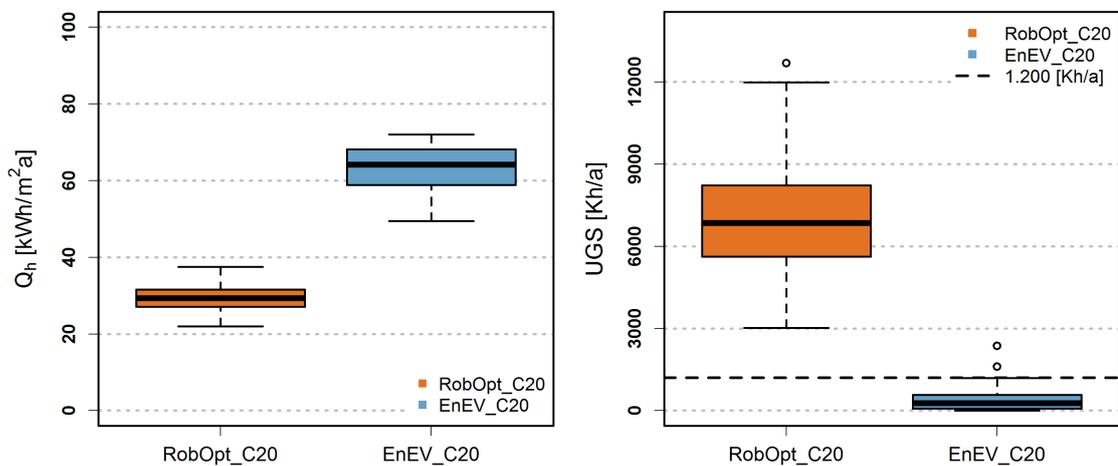
Die im Rahmen dieser Arbeit angewandte robuste Optimierung beinhaltet in der Regel mehrere Zielvariablen. Selbst wenn nur eine Zielgröße, wie z.B. der Heizwärmebedarf analysiert wird, gilt es die Robustheitskriterien der Verteilung von Q_h , Median und Quantildifferenz zu optimieren. In den folgenden Abschnitten werden zwei Anwendungen einer multikriteriellen robusten Optimierung vorgestellt. Dabei wird die robuste Optimierung einer energetischen Gebäudesanierung unter Berücksichtigung klimatischer Unsicherheiten mit einer Sanierung nach EnEV (2014) verglichen. Die Sanierung nach EnEV bezieht sich, wie die robuste Optimierung, in der folgenden Untersuchung ausschließlich auf die Gebäudehülle (siehe Kapitel 5). Als Vergleichsgröße werden der Heizwärmebedarf und die Übertemperaturgradstunden herangezogen. Für die Darstellung der Unsicherheiten des Klimas wird über die Periode C20 (1970-1999) optimiert.

13.2.1 Multikriterielle Optimierung mit einem a priori Ansatz

Die erste Anwendung einer robusten Optimierung beschäftigt sich mit der Minimierung der Zielgröße Heizwärmebedarf. Dabei wird die Zielfunktion über eine gewichtete Summe der beiden Robustheitskriterien der Zielgröße, Median und Quantildifferenz, erstellt (Funktion 13.1). Der Faktor w_1 repräsentiert die Gewichtung der beiden Robustheitskriterien. Die Skalierungsfaktoren $k_{\bar{x}_{med}}$ und k_{QD} werden auf Basis des Bestandsgebäudes ermittelt. Die Robustheitskriterien werden für die folgende Anwendung mit $w_1 = 0,5$ gewichtet. Dadurch haben beide Robustheitskriterien die gleiche Priorität.

$$F_{Q_h} = w_1 (\bar{x}_{med}(Q_h)/k_{\bar{x}_{med}}) + (1 - w_1) (QD(Q_h)/k_{QD}) \quad (13.1)$$

Abbildung 13.4 stellt die Ergebnisse einer Sanierung über die Periode C20 (1970-1999) mit einer robusten Optimierung (RobOpt) und nach EnEV dar. Grafik 13.4a zeigt die Resultate des Heizwärmebedarfs. Es wird deutlich, dass sowohl der Median als auch die Quantildifferenz von Q_h bei einer robusten Optimierung geringer sind als bei einer Sanierung nach EnEV. Jedoch hat die robuste Optimierung negative Auswirkungen auf die Übertemperaturgradstunden. In Grafik 13.4b werden die resultierenden Verteilungen der UGS abgebildet. Die gestrichelte Linie repräsentiert, als Referenz, den Grenzwert für die UGS in Wohnbauten aus der DIN 4108-2 (2013) mit 1.200 Kh/a. Die Ergebnisse aus der robusten Optimierung liegen deutlich oberhalb des Grenzwertes, während die Resultate bei einer Sanierung nach EnEV zum größten Teil den Grenzwert einhalten.



(a) Resultate der Zielgröße Q_h in Periode C20 (b) Resultate der Zielgröße UGS in Periode C20

Abbildung 13.4: Vergleich von Ergebnissen einer energetischen Sanierung nach EnEV und nach einer robusten Optimierung

Tabelle 13.5 fasst die Ergebnisse für die Kennwerte Median, 0,01%-Quantil, 99,99%-Quantil und Quantildifferenz aus Abbildung 13.4 zusammen. Der Median für Q_h kann durch die robuste Optimierung, im Vergleich zu einer Sanierung nach EnEV, um mehr als die Hälfte reduziert werden. Auch die Unsicherheiten, repräsentiert durch die Quantildifferenz, können mit der robusten Optimierung um ca. 30% reduziert werden. Durch die Verbesserung des energetischen Verhaltens der Gebäudehülle ergibt sich jedoch ein deutlicher Anstieg der UGS im Vergleich zu den Ergebnissen mit einer Sanierung nach EnEV. Die Unsicherheit der UGS bei einer robusten Optimierung ist ca. viermal höher als bei einem Vorgehen nach EnEV.

Tabelle 13.5: Zusammenfassung der Ergebnisse einer energetischen Sanierung in Periode C20

	Median [kWh/m ² a]	0,01%-Quantil [kWh/m ² a]	99,99%-Quantil [kWh/m ² a]	Quantildifferenz [kWh/m ² a]
EnEV Q_h	64	50	72	22
RobOpt Q_h	29	22	38	16
	[Kh/a]	[Kh/a]	[Kh/a]	[Kh/a]
EnEV UGS	279	0	2366	2366
RobOpt UGS	6850	3030	12678	9648

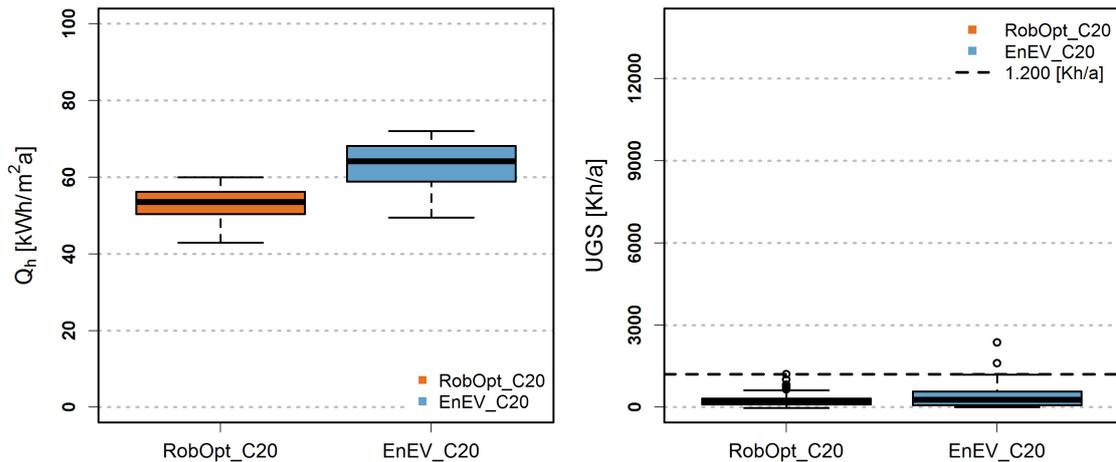
Diese Ergebnisse zeigen, dass bei der Optimierung von nur einer Zielgröße, wie z.B. dem Heizwärmebedarf, negative Veränderungen bei anderen Zielgrößen auftreten können. Deshalb ist es sinnvoll, bei einer Optimierung mehrere Zielgrößen, welche für die Problemstellung wichtig erscheinen, miteinzubeziehen und diese auch in der Visualisierung der Ergebnisse zu berücksichtigen (z.B. Pareto-Front). Dafür eignet sich z.B. ein a posteriori Ansatz (Abschnitt 13.2.2). Erfordert die Aufgabenstellung jedoch eine Fokussierung auf eine Zielgröße, können weitere Zielgrößen eventuell mit Hilfe von Grenzwerten berücksichtigt werden. Dies geschieht z.B. mit Hilfe von Straffunktionen oder Nebenbedingungen im Optimierungsproblem. Funktion 13.2 repräsentiert eine Straffunktion für die Überschreitung des Grenzwertes der UGS von 1.200 Kh/a. Mit dem Faktor St_{Fak} wird die Höhe der Strafe reguliert.

$$f_{St}(x) = \begin{cases} St_{Fak}(x - 1200) & \text{für } x > 1200 \\ 0 & \text{für } x < 1200 \end{cases} \quad (13.2)$$

Die Zielfunktion 13.1 kann so durch die Straffunktion f_{St} ergänzt werden.

$$F_{Q_h} = w_1 (\bar{x}_{med}(Q_h + f_{St})/k_{\bar{x}_{med}}) + (1 - w_1) (QD(Q_h + f_{St})/k_{QD}) \quad (13.3)$$

Abbildung 13.5 zeigt die Ergebnisse nach Integration der Straffunktion in die robuste Optimierung. Der Faktor St_{Fak} wird dabei mit 10 definiert. Der Median und die Quantildifferenz des Heizwärmebedarfes der robusten Optimierung weisen, im Vergleich zu Grafik 13.4, deutlich höhere Werte auf. Im Vergleich zur Sanierung nach EnEV sind die Resultate der robusten Optimierung jedoch immer noch deutlich geringer. Die Ergebnisse der Übertemperaturgradstunden der robusten Optimierung haben sich gegenüber den Resultaten ohne Straffunktion deutlich verbessert. Alle Werte der UGS liegen unter dem definierten Grenzwert von 1.200 Kh/a.



(a) Resultate der Zielgröße Q_h mit integrierter Straffunktion in der Periode C20

(b) Resultate der Zielgröße UGS mit integrierter Straffunktion in der Periode C20

Abbildung 13.5: Vergleich der Ergebnisse einer energetischen Sanierung nach EnEV und nach einer robusten Optimierung mit Straffunktion

In Tabelle 13.6 werden die Ergebnisse aus Abbildung 13.5 detailliert dargestellt. Der Median von Q_h kann durch eine robuste Optimierung, im Vergleich zur Sanierung nach EnEV, um 15% reduziert werden. Auch die Unsicherheit von Q_h wird durch die robuste Optimierung um 25% reduziert. Durch die Integration einer Straffunktion in die robuste Optimierung wird der Grenzwert von 1.200 Kh/a für die gesamte Verteilung der UGS eingehalten. Die resultierenden Gebäudeparameter aus der robusten Optimierung (RobOpt) sind in Tabelle 13.7 abgebildet. Als Vergleich dienen die verwendeten Parameter bei einer Sanierung nach EnEV. Des Weiteren sind die oberen (Max-Opt) und unteren Grenzen (Min-Opt) für die Optimierung der Gebäudeparameter dargestellt. Der Wärmedurchgangskoeffizient für die Außenwand (U-Wand) und für das Dach (U-Dach) liegen an der unteren Grenze des definierten Optimierungsbereiches. Der U-Wert der Bodenplatte wird jedoch nicht bis zur unteren Grenze minimiert. Die Bodenplatte des Fallbeispiels grenzt direkt an das Erdreich. Dadurch würde eine zu starke Dämmung eine Auskühlung des Innenraumes während der Sommermonate verhindern. Dies würde wiederum zu einem Anstieg der Übertemperaturgradstunden führen.

Der g-Wert der Verglasung und der Fc-Wert des Sonnenschutzes werden ebenfalls an die unteren Grenzen ihres Bereiches minimiert. Diese beiden Parameter sind maßgeblich für den solaren Eintrag in das Gebäude verantwortlich. Ein niedriger g-Wert und Fc-Wert reduzieren die solare Einstrahlung und dadurch die Übertemperaturgradstunden.

Tabelle 13.6: Zusammenfassung der Ergebnisse einer energetischen Sanierung in Periode C20 mit einer robusten Optimierung mit Straffunktion und nach EnEV

	Median [kWh/m ² a]	0,01%-Quantil [kWh/m ² a]	99,99%-Quantil [kWh/m ² a]	Quantildifferenz [kWh/m ² a]
EnEV Q _h	64	50	72	22
RobOpt Q _h	54	43	60	17
	[Kh/a]	[Kh/a]	[Kh/a]	[Kh/a]
EnEV UGS	279	0	2366	2366
RobOpt UGS	174	0	1198	1198

Tabelle 13.7: Vergleich der Gebäudeparameter der robusten Optimierung und einer Sanierung nach EnEV

	U-Wand [W/m ² K]	U-Dach [W/m ² K]	U-Boden [W/m ² K]	U-Fenster [W/m ² K]	g-Wert [-]	Fc-Wert [-]
EnEV	0,24	0,24	0,30	1,30	0,6	0,25
RobOpt	0,10	0,10	0,59	0,60	0,30	0,25
Max-Opt	1,40	1,10	1,10	3,50	0,75	1,00
Min-Opt	0,10	0,10	0,10	0,60	0,30	0,25

Die vorgestellten Ergebnisse heben bereits die Vorteile einer robusten Optimierung hervor. So ist es mit einer robusten Optimierung möglich, nicht nur die Lage, sondern auch die Streuung der Verteilung einer Zielgröße aktiv zu optimieren. Bei einer herkömmlichen energetischen Sanierung werden in der Regel keine Unsicherheiten berücksichtigt bzw. optimiert. Durch die Integration einer Straffunktion können bei dem vorgestellten a priori Ansatz Grenzwerte anderer Zielgrößen berücksichtigt werden. Dieses Verfahren bietet die Möglichkeit, auch bei der Analyse einer Zielgröße, die anderen Größen des zu optimierenden Systems miteinzubeziehen.

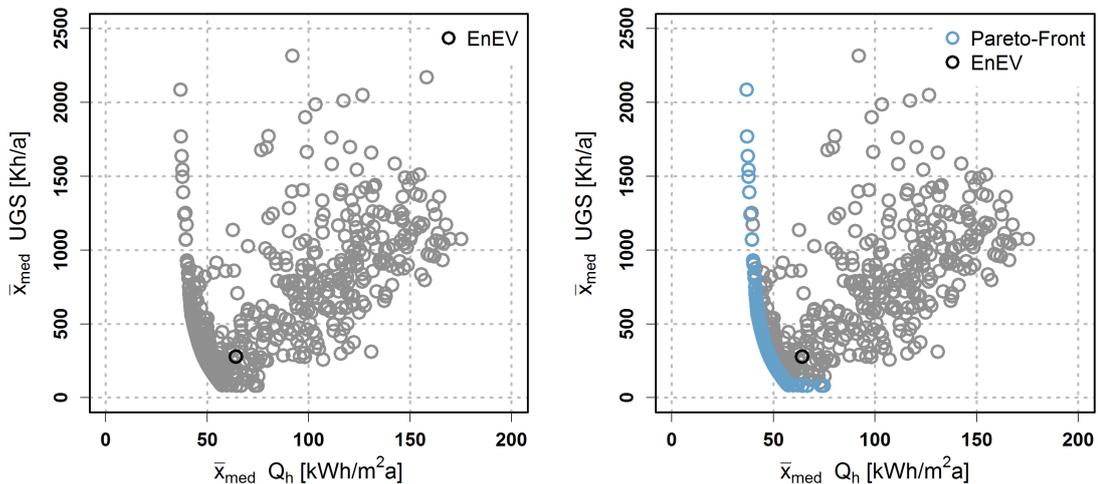
13.2.2 Multikriterielle Optimierung mit einem a posteriori Ansatz

Die zweite Anwendung einer robusten Optimierung beschreibt die Minimierung von zwei Zielgrößen, dem Heizwärmebedarf und den Übertemperaturgradstunden. Dabei wird für jede Zielgröße eine zu minimierende Zielfunktion erstellt (Funktionen 13.4 und 13.5). Die Zielfunktionen setzen sich wiederum aus den Robustheitskriterien, Median und Quantildifferenz, der Zielgrößen zusammen. Die Faktoren w_1 und w_2 regulieren die Gewichtung der beiden Robustheitskriterien und werden im Beispiel ebenfalls wieder mit 0,5 definiert, um dadurch die Kriterien gleichmäßig zu priorisieren. Die Skalierungsfaktoren $k_{\bar{x}_{med}}$ und k_{QD} werden auf Basis des Bestandsgebäudes ermittelt. Ziel der Optimierung ist das Auffinden von Pareto-optimalen Lösungen, bzw. einer Pareto-Front der beiden Zielgrößen auf Grundlage eines a posteriori Ansatzes.

$$F_{Q_h} = w_1 (\bar{x}_{med}(Q_h)/k_{\bar{x}_{med}}) + (1 - w_1) (QD(Q_h)/k_{QD}) \quad (13.4)$$

$$F_{UGS} = w_2 (\bar{x}_{med}(UGS)/k_{\bar{x}_{med}}) + (1 - w_2) (QD(UGS)/k_{QD}) \quad (13.5)$$

In Abbildung 13.6 sind die Ergebnisse der robusten Optimierung der Zielgrößen Q_h und UGS abgebildet. Hinter jedem Lösungspunkt steht jeweils eine Verteilung der beiden Zielgrößen. Für eine einfachere Darstellung werden in einem ersten Schritt die Ergebnisse mit Hilfe des Medians der jeweiligen Verteilung dargestellt. Des Weiteren werden die Resultate aus einer energetischen Sanierung nach EnEV ergänzt (schwarzer Kreis). In Grafik 13.6b wird die resultierende Pareto-Front hervorgehoben. Aus den Ergebnissen der Pareto-Front kann nun der Entscheider, je nach Priorisierung der Zielgröße, eine Pareto-optimale Lösung auswählen.

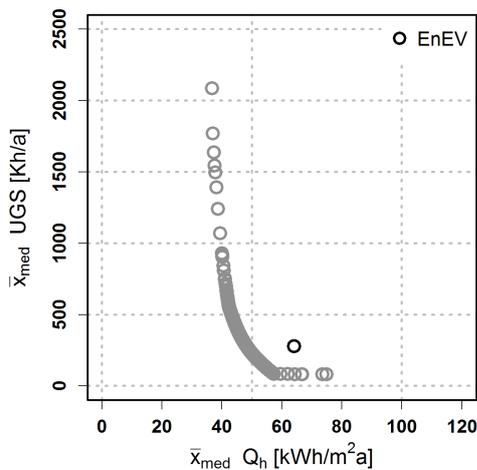


(a) Ergebnisse einer robusten Optimierung der Zielgrößen Q_h und UGS

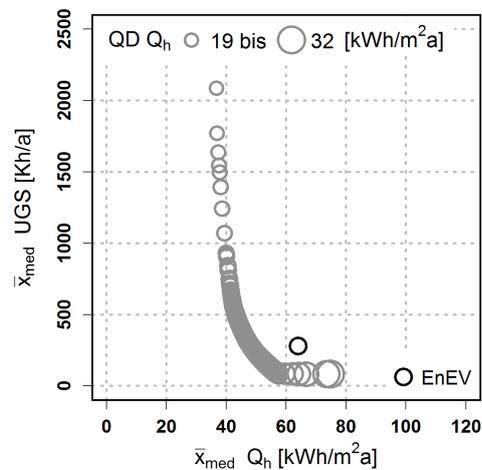
(b) Ergebnisse einer robusten Optimierung der Zielgrößen Q_h und UGS mit hervorgehobener Pareto-Front

Abbildung 13.6: Resultate der robusten Optimierung nach einem a posteriori Ansatz

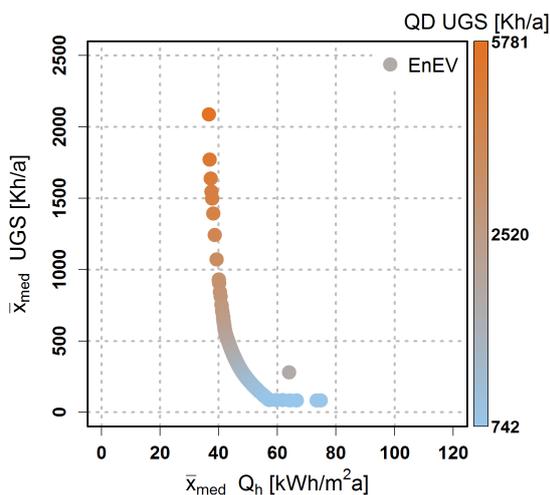
Bei einer Visualisierung der Ergebnisse mit Hilfe des Medians kann jedoch keine Aussage über die Unsicherheiten der jeweiligen Lösung getroffen werden. In Abbildung 13.7 wird deshalb die Unsicherheit über die Quantildifferenz grafisch dargestellt. Dabei wird die Unsicherheit der Zielgrößen zum einen über eine Farbskala und zum anderen über die Größe der Lösungspunkte abgebildet. Ziel dieses Vorgehens ist nicht eine exakte Darstellung der Unsicherheiten, es soll vielmehr eine erste Bewertung der Lösungen unter Berücksichtigung der Unsicherheiten ermöglichen.



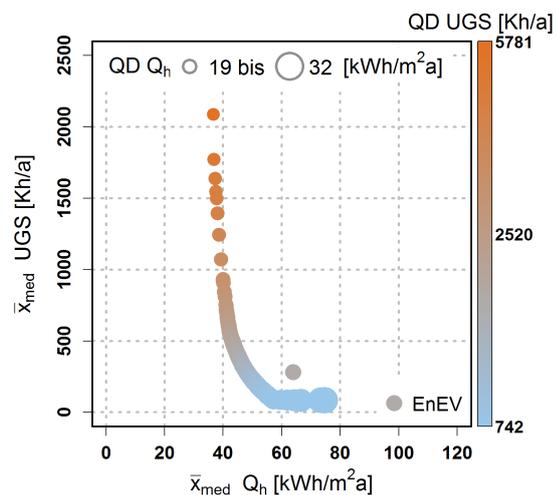
(a) Darstellung der Ergebnisse mit Hilfe einer Pareto-Front



(b) Integration der Unsicherheiten von Q_h



(c) Integration der Unsicherheiten der UGS

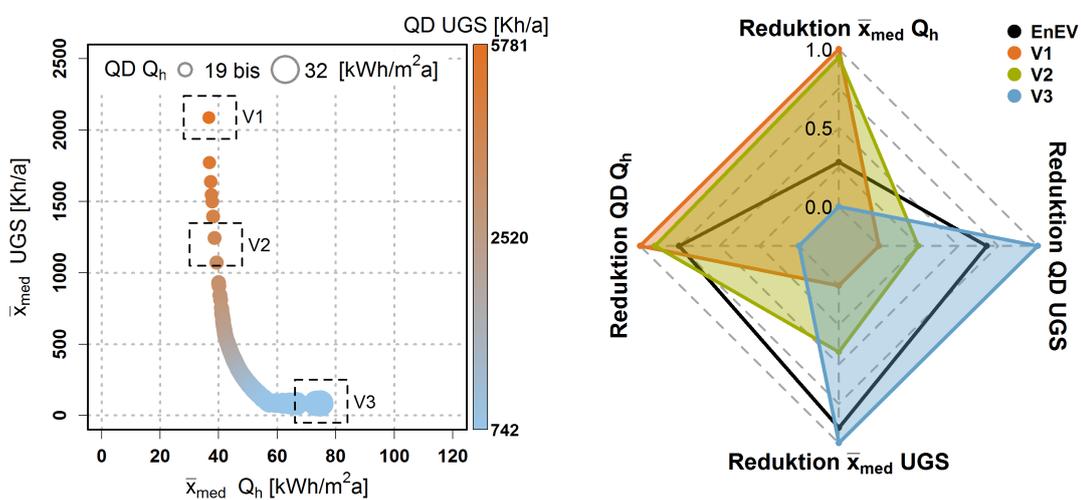


(d) Darstellung der Lage und Streuung der jeweiligen Zielgröße

Abbildung 13.7: Visualisierung der Unsicherheiten auf Basis einer Pareto-Front

Grafik 13.7a zeigt die Pareto-Front auf Basis des Medians. In Abbildung 13.7b ist die Unsicherheit der Zielgröße Q_h durch unterschiedliche Größen der Lösungspunkte dargestellt. In der Legende werden die Unsicherheiten mit Hilfe der Quantildifferenz quantifiziert. Grafik 13.7c stellt die Unsicherheiten der Zielgröße UGS dar. Dabei werden die Unsicherheiten der Lösungen farblich integriert. Die Farbskala am rechten Rand der Abbildung dient einer groben Einschätzung der jeweiligen Unsicherheiten. Abbildung 13.7d zeigt die finale Darstellung der Ergebnisse. Im Vergleich zu Grafik 13.7a kann nun eine Berücksichtigung der Unsicherheiten erfolgen. So zeigt sich, dass bei einer zunehmenden Reduzierung des Heizwärmebedarfes die Unsicherheit der Übertemperaturgradstunden ansteigt. Die selbe Entwicklung kann auch gegensätzlich beobachtet werden. Bei einer zunehmenden Reduzierung der UGS nimmt die Unsicherheit des Heizwärmebedarfes zu.

Zur Unterstützung des Entscheiders können die Lösungen der Pareto-Front in Gruppen bzw. in Varianten nach Interessen unterschiedlicher Stakeholder eingeteilt werden. Abbildung 13.8a zeigt eine exemplarische Einteilung der Pareto-Front in drei unterschiedliche Varianten der Sanierung. Dabei spiegelt V1 die Ziele des Gesetzgebers wider, welcher eine maximale Energieeinsparung verfolgt. Die Variante 2 stellt die Ziele des technischen Planers dar. Dieser möchte den Grenzwert der Übertemperaturgradstunden von 1.200 Kh/a einhalten. Der Nutzer möchte maximalen Komfort, welcher eine geringe Anzahl von UGS erfordert. Die Interessen des Nutzers sind in Variante 3 abgebildet. Diese Varianten können dann mit Hilfe eines Netzdiagramms detaillierter analysiert und verglichen werden. Als Kategorien des Netzdiagramms werden die Zielvariablen der robusten Optimierung herangezogen. Für einen Vergleich werden die Ergebnisse einer Sanierung nach EnEV ebenfalls im Netzdiagramm abgebildet.



(a) Gruppierung der Pareto-optimalen Lösungen zu Varianten (b) Netzdiagramm der ausgewählten Varianten aus der Pareto-Front

Abbildung 13.8: Interpretation der Pareto-optimalen Lösungen durch Gruppierung und Darstellung im Netzdiagramm

Das Netzdiagramm in Grafik 13.8b zeigt die beschriebenen Varianten und bewertet diese nach den Zielen der robusten Optimierung, einer Minimierung der Zielfunktion F_{Q_h} und F_{UGS} . Die Varianten V1 und V3 weisen tendenziell ein gegensätzliches Verhalten in der Reduktion der einzelnen Zielvariablen auf. Dies ist bereits aus der Pareto-Front, durch die Visualisierung der Unsicherheiten, erkennbar. Die Variante 2 zeigt trotz Einhaltung des Grenzwertes für die UGS sehr gute Ergebnisse in der Minimierung von Q_h . Diese Variante könnte als Kompromisslösung in Betracht gezogen werden, da die Grenzwerte für den Komfort eingehalten und ebenfalls gute Resultate in der Energieeinsparung erzielt werden. Tabelle 13.8 zeigt die detaillierten Ergebnisse der einzelnen Varianten. Anhand dieser Resultate können die Ergebnisse des Netzdiagramms verdeutlicht werden. Der Median von Q_h aus Variante 2 weist lediglich eine Abweichung von 2 kWh/m²a zur minimalen Lösung aus Variante 1 auf. Der Median von UGS aus Variante 2 liegt knapp unterhalb des definierten Grenzwertes von 1.200 Kh/a.

Tabelle 13.8: Zusammenstellung der Ergebnisse pro Zielgröße aus den drei Varianten

	Median [kWh/m ² a]	0,01%-Quantil [kWh/m ² a]	99,99%-Quantil [kWh/m ² a]	Quantildifferenz [kWh/m ² a]
V1 Q_h	37	28	46	19
V2 Q_h	39	29	49	20
V3 Q_h	75	59	91	32
EnEV Q_h	64	50	72	22
	[Kh/a]	[Kh/a]	[Kh/a]	[Kh/a]
V1 UGS	2088	452	6233	5781
V2 UGS	1998	207	4734	4527
V3 UGS	82	0	670	670
EnEV UGS	279	0	2366	2366

Die resultierenden Gebäudeparameter der drei Varianten sind in Tabelle 13.9 abgebildet. Generell ist in allen drei Varianten, wie beabsichtigt, der Einfluss beider Zielgrößen zu erkennen. So liegt in V1 der Wärmedurchgangskoeffizient der Bodenplatte (U-Boden) nicht an der unteren Grenze des möglichen Optimierungsbereiches (Min-Opt), wie es bei einer reinen Optimierung des Heizwärmebedarfes zu erwarten wäre. Der Fc-Wert wird minimiert um die Übertemperaturgradstunden zu reduzieren. Bei einer Optimierung, welche nur den Heizwärmebedarf berücksichtigt wäre eine Maximierung des Fc-Werts erfolgt. In V3, der Variante mit den minimalen UGS, sind ebenfalls die Einflüsse der Zielfunktion von Q_h zu erkennen. Die Gebäudeparameter des Wärmedurchgangskoeffizient der Außenwand (U-Wand) und des Daches (U-Dach) liegen an den unteren Grenzen des Optimierungsbereiches und gewährleiten so eine maximale Reduktion des Heizwärmebedarfes. Diese Resultate zeigen deutlich, wie sich die Ergebnisse einer Optimierung durch die Berücksichtigung von mehreren Zielfunktionen verändern und welche neuen Planungsmöglichkeiten durch die veränderten Gebäudeparameter entstehen können.

Tabelle 13.9: Resultierende Gebäudeparameter der drei Varianten aus der robusten Optimierung

	U-Wand [W/m ² K]	U-Dach [W/m ² K]	U-Boden [W/m ² K]	U-Fenster [W/m ² K]	g-Wert [-]	Fc-Wert [-]
V1	0,10	0,10	0,14	0,60	0,75	0,25
V2	0,10	0,10	0,10	0,60	0,52	0,25
V3	0,10	0,10	1,10	2,60	0,30	0,25
EnEV	0,24	0,24	0,30	1,30	0,6	0,25
Max-Opt	1,40	1,10	1,10	3,50	0,75	1,00
Min-Opt	0,10	0,10	0,10	0,60	0,30	0,25

Diese beispielhaften Ergebnisse einer robusten Optimierung auf Basis eines a posteriori Ansatzes verdeutlichen die Vorteile dieser Methode. Durch die Visualisierung der Unsicherheiten können bereits ohne detaillierte Analysen der gesamten Ergebnisse erste Entscheidungen über mögliche Sanierungsvarianten getroffen werden. Die Berücksichtigung von mehreren Zielfunktionen in der robusten Optimierung führt zu neuen Ergebnissen, wie z.B. alternative Kombinationen von Gebäudeparametern, welche z.B. durch eine Sanierung nach EnEV nicht identifiziert werden können.

14 | Zusammenfassung

Aufgrund der in Teil I vorgestellten Problematik gilt es aus Sicht einer belastbaren Planung Konzepte für die energetische Gebäudesanierung zu entwickeln, welche die Zielgrößen nicht nur optimieren, sondern auch ihre Unsicherheiten reduzieren. Eine Möglichkeit dieses Ziel zu erreichen ist die Anwendung einer „Robusten Optimierung“. Im Rahmen dieser Arbeit wird die Methode der robusten Optimierung durch die Integration einer Unsicherheitsanalyse in eine mathematischen Optimierung auf Basis eines Gebäudesimulationsmodells umgesetzt.

Ziel des Teils „Robuste Optimierung“ ist eine Einführung in die Methode, sowie eine erste Anwendung einer robusten Optimierung der energetischen Gebäudesanierung unter Berücksichtigung klimatischer Unsicherheiten. In einem ersten Schritt wurde ein exemplarischer Überblick über die bisherigen Arbeiten zum Thema Unsicherheitsanalyse und mathematischer Optimierung in der Gebäudesimulation vorgestellt. Auf Basis dieser Literaturrecherche wurde eine Monte-Carlo-Simulation für die Anwendung einer Unsicherheitsanalyse ausgewählt (Abschnitt 11.3.1). Weiterhin geht aus der Literatur hervor, dass für die mathematische Optimierung im Bereich der Gebäudesimulation sogenannte Metaheuristiken empfohlen werden. Dabei zeigt sich, dass die beiden populationsbasierten Metaheuristiken Particle Swarm Optimization und der Genetische Algorithmus zu den am häufigsten verwendeten Verfahren zählen. Der Vorteil dieser beiden Metaheuristiken ist, dass es lediglich geringe Restriktionen für die Anwendung gibt. Die Optimierungsprobleme im Rahmen dieser Arbeit gehören zur Kategorie der nichtlinearen und kontinuierlichen Parameteroptimierung mit beschränktem Suchraum. Die Vorteile eines GA kommen meist bei einer diskreten Parameteroptimierung zum Vorschein, weshalb in den weiteren Analysen dieser Arbeit die PSO verwendet wird (Abschnitt 11.3.2).

Die Eingangsgrößen der in Teil III entwickelten Ersatzmodelle bestehen bisher aus Parametern der Gebäudehülle. Deshalb ist es nicht möglich, unsichere Randbedingungen im Ersatzmodell direkt abzubilden. Für die Anwendung der Ersatzmodelle bei einer robusten Optimierung im Rahmen dieser Arbeit muss jedoch eine Eingangsgröße für die Berücksichtigung von unsicheren Randbedingungen entwickelt werden. Für die Implementierung der klimatischen Unsicherheiten in die robuste Optimierung wird deshalb die Methode ΔT_a eingeführt. Mit Hilfe dieser Technik ist es möglich, die Unsicherheiten des Klimas mit einem Parameter (Delta der Außentemperatur) als Eingangsgröße im Ersatzmodell zu berücksichtigen (Abschnitt 12.1.2).

Die robuste Optimierung einer energetischen Gebäudesanierung unter Berücksichtigung klimatischer Unsicherheiten wird anhand zweier Anwendungsbeispiele dargestellt. Bei einer ersten Anwendung wird ein a priori Ansatz der multikriteriellen Optimierung verwendet (Abschnitt 13.2.1). Dabei wird die Zielfunktion aus einer gewichteten Summe der Robustheitskriterien, Median und Quantildifferenz, der Zielgröße Heizwärmebedarf erstellt. Durch die Integration einer Straffunktion in die Zielfunktion können auch andere Zielfunktionen berücksichtigt werden, ohne diese direkt in der Optimierung zu behandeln.

Eine zweite Anwendung einer robusten Optimierung beschreibt die Minimierung von zwei Zielgrößen, dem Heizwärmebedarf und den Übertemperaturgradstunden (Abschnitt 13.2.2). Dabei wird für jede Zielgröße eine zu minimierende Zielfunktion erstellt. Diese Zielfunktionen setzen sich wiederum aus den Robustheitskriterien, Median und Quantildifferenz, der Zielgrößen zusammen. Ziel der Optimierung ist das Auffinden von Pareto-optimalen Lösungen bzw. einer Pareto-Front der beiden Zielgrößen auf Grundlage eines a posteriori Ansatzes. Anschließend werden die Vorteile einer Visualisierung der Unsicherheiten in Kombination mit einer Pareto-Front vorgestellt.

Der beispielhafte Vergleich zwischen den Ergebnisse einer robusten Optimierung und einer Sanierung nach EnEV verdeutlichen die Vorteile dieser Methode gegenüber einem herkömmlichen Planungsansatz. So ist es mit einer robusten Optimierung möglich, nicht nur die Lage, sondern auch die Streuung der Verteilung einer Zielgröße aktiv zu optimieren. Bei einer herkömmlichen energetischen Sanierung werden in der Regel keine Unsicherheiten berücksichtigt bzw. optimiert.

Die Visualisierung der Unsicherheiten in Kombination mit einer Pareto-Front bietet ebenfalls neue Möglichkeiten für den Planer. Mit Hilfe dieser grafischen Darstellung können bereits ohne detaillierte Analysen der gesamten Ergebnisse erste Entscheidungen über mögliche Sanierungsvarianten getroffen werden. Des Weiteren führt die Berücksichtigung von mehreren Zielfunktionen in der robusten Optimierung zu neuen Ergebnissen, wie z.B. alternative Kombinationen von Gebäudeparametern, welche z.B. mit einer Sanierung nach EnEV nicht identifiziert werden können.

Teil V

Robuste Optimierung in der Gebäudesimulation

15 | Vorgehen im Rahmen der entwickelten Methode

Ziel dieser Arbeit ist es, eine Methode zur robusten Optimierung der energetischen Gebäudesanierung unter Berücksichtigung unsicherer Randbedingungen zu entwickeln. Diese Methode soll die Erstellung von Sanierungskonzepten unterstützen, welche eine höhere Belastbarkeit gegenüber herkömmlichen Planungsansätzen aufweist. Dabei ist das Ziel dieser Methode nicht nur die Optimierung von Zielgrößen einer Sanierung, sondern auch eine Erhöhung ihrer Robustheit gegenüber unsicheren Randbedingungen. Im Rahmen dieser Arbeit werden auf Grund der vorgestellten Problematik in Kapitel 1.3 primär klimatische Veränderungen als unsichere Randbedingung für das Anwendungsbeispiel herangezogen. Die folgenden Abschnitte fassen die in den Teilen III und IV vorgestellten Techniken zusammen, um ein ganzheitliches Bild der entwickelten Methode zu präsentieren. Diese Zusammenfassung präsentiert das Vorgehen der im Rahmen dieser Arbeit entwickelten Methode zur robusten Optimierung der energetischen Gebäudesanierung unter Berücksichtigung unsicherer Randbedingungen.

Die entwickelte Methode besteht aus folgenden Schritten:

- i) Im ersten Schritt wird die Datengrundlage für die Entwicklung des Ersatzmodells erzeugt.
- ii) Im zweiten Schritt werden die unsicheren Randbedingungen quantifiziert.
- iii) Im dritten Schritt wird eine Systemidentifikation für die Erstellung des Ersatzmodells durchgeführt.
- iv) Der vierte Schritt umfasst die robuste Optimierung auf Basis des Ersatzmodells.
- v) In einem fünften Schritt werden die Ergebnisse aus der robusten Optimierung mit Hilfe eines mehrstufigen Verfahrens visualisiert.

15.1 Erstellung der Datengrundlage

Die robuste Optimierung im Rahmen dieser Arbeit wird mit einem Ersatzmodell für ein detailliertes Gebäudemodell durchgeführt. Das Ersatzmodell wird mit Hilfe eines Neuronales Netzes erstellt. Die Modellentwicklung eines Neuronales Netzes benötigt Ein- und Ausgangssignale des abzubildenden Systems als Datengrundlage für das Lernen und Testen. Detaillierte Informationen zur Erstellung des Ersatzmodells können aus Teil III entnommen werden.



Abbildung 15.1: Erstellung der Datengrundlage auf Basis des Ein- und Ausgangssignals des Gebäudemodells mit Hilfe einer Monte-Carlo-Simulation

Die sogenannten Sample-Daten werden durch eine Monte-Carlo-Simulation (MCS) mit dem detaillierten Gebäudemodell erstellt. Dabei erhalten die definierten Eingangsgrößen des Ersatzmodells eine Verteilung. Anschließend werden aus diesen Verteilungen Stichproben mit Hilfe einer Sample-Technik ausgewählt. Die Stichproben dienen als Eingangssignal für die Simulationen des detaillierten Gebäudemodells. Das Ausgangssignal des Gebäudemodells wird für die definierten Zielgrößen des Ersatzmodells erfasst. Die Qualität der Sample-Daten und die benötigte Rechenzeit für die MCS sind maßgeblich von der Sample-Technik abhängig. Bei einem Vergleich von drei Sample-Techniken liefert die Methode der „Sobol Sequenzen“ die besten Resultate. Das detaillierte Vorgehen für die Erstellung der Sample-Daten und die ausführlichen Ergebnisse des Vergleiches der Sample-Techniken ist in Teil III beschrieben.

15.2 Quantifizierung der unsicheren Randbedingungen

Die Unsicherheiten einer energetischen Gebäudesanierung werden in dieser Arbeit durch unsichere Randbedingungen, repräsentiert durch klimatische Veränderungen und der Entwicklung von Energiepreisen, abgebildet. Die Unsicherheiten des Klimas müssen für die Anwendung bei einer robusten Optimierung im Ersatzmodell über eine Eingangsgröße berücksichtigt werden. Für die Implementierung der klimatischen Unsicherheiten in das im Rahmen dieser Arbeit entwickelte Vorgehen für eine robuste Optimierung wird deshalb die Methode ΔT_a (siehe Kapitel 12.1.2) eingeführt. Die Unsicherheiten der Energiepreisentwicklung werden auf Basis des Ausgangssignals des Ersatzmodells ermittelt und benötigen deshalb keine eigene Eingangsgröße.

Diese Methode basiert auf der vereinfachten Annahme, dass die Außentemperatur einer Periode von mehreren Jahren zu jeder Stunde eine Normalverteilung aufweist. Aufgrund dieser Annahme wird versucht, die klimatischen Veränderungen einer definierten Periode ähnlich wie eine Normalverteilung abzubilden. Dabei repräsentiert das mittlere Jahr der Periode den Erwartungswert und die Verteilung wird mit Hilfe eines Parameters „Delta“ erstellt. In einem ersten Schritt wird dazu eine Verteilung des Parameters „Delta“ iterativ ermittelt. Anschließend wird diese Verteilung der Außentemperatur auf das mittlere Jahr der Periode übertragen. Auf Basis dieser angepassten Wetterdaten werden Simulationen mit dem detaillierten Gebäudemodell durchgeführt und mit Referenzergebnissen aus den Originaldaten der definierten Periode verglichen. Ziel dieses Verfahrens ist es, mit nur einem Parameter (Delta) die klimatischen Veränderungen einer Periode abzubilden und als Eingangsgröße im Ersatzmodell zu berücksichtigen.

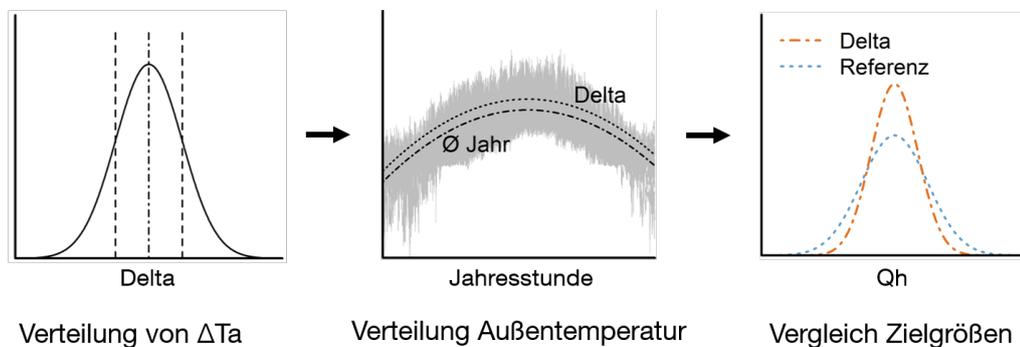


Abbildung 15.2: Schematischer Ablauf der Methode ΔT_a zur Berücksichtigung klimatischer Unsicherheiten

Es können auch andere Inputdaten als unsichere Randbedingungen in die Methode integriert werden. Bei einer Anwendung der Methode in Teil VI werden ebenfalls unsichere Randbedingungen aus der Investitionsrechnung der unterschiedlichen Energieeffizienzmaßnahmen analysiert. Die Darstellung des Gebäudenutzers wäre eine weitere Ursache für unsichere Randbedingungen einer energetischen Gebäudesanierung. Dieser könnte z.B. über ein stochastisches Modell der Anwesenheit oder Tätigkeit in die Methode integriert werden.

15.3 Systemidentifikation mit Hilfe von Ersatzmodellen

Die Systemidentifikation/Modellbildung mit einem Neuronalen Netz basiert in dieser Arbeit auf der Analyse der Ein- und Ausgangssignale des detaillierten Gebäudemodells. Die Ein- und Ausgangssignale des Gebäudemodells werden, wie in Schritt eins beschrieben, durch eine Monte-Carlo-Simulation erzeugt. Die Systemidentifikation kann in die Phasen „Lernen“ und „Testen“ eingeteilt werden. In der Lernphase sind dem Neuronalen Netz die Ein- und Ausgangssignale bekannt (Abbildung 15.3). In dieser Phase verändert ein Optimierungsalgorithmus die Parameter (Verbindungsgewichte) im Inneren des Neuronalen Netzes, um einen möglichst geringen Modellfehler zu erreichen. Des Weiteren kann über eine Veränderung der Art und

Anzahl von Eingangsgrößen oder verdeckten Schichten die Struktur des Netzes optimiert werden. Während der Testphase werden dem bereits trainierten Netzwerk mit einer zweiten, unabhängigen Datenmenge lediglich die Eingangsdaten des Systems zur Verfügung gestellt. Die daraus resultierenden Ausgangssignale des „gelernten“ Neuronalen Netzes können anschließend mit denen des detaillierten Gebäudemodells verglichen (Kreuzvalidierung) und so die Modellgüte bewertet werden.

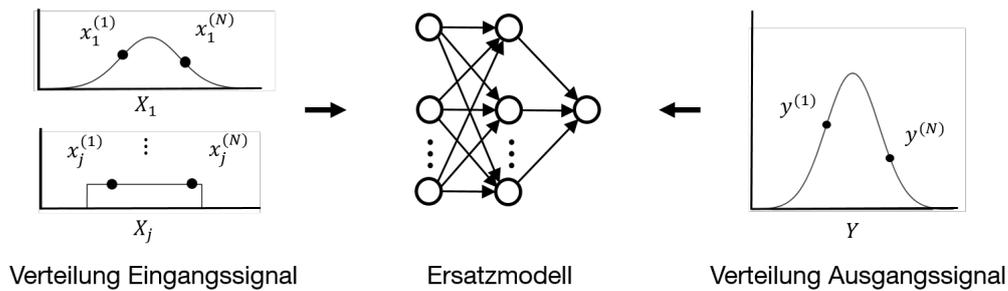


Abbildung 15.3: Erstellung des Ersatzmodells auf Basis der Ein- und Ausgangssignale des detaillierten Gebäudemodells

15.4 Robuste Optimierung auf Basis der Ersatzmodelle

Nach Erstellung des Ersatzmodells durch eine Systemidentifikation mit dem detaillierten Modell wird eine robuste Optimierung durchgeführt. In einem ersten Schritt werden die Unsicherheiten auf Basis der unsicheren Randbedingungen ermittelt. Dabei wird zuerst eine Normalverteilung der Eingangsgröße „Delta“ erzeugt. Dies geschieht mit einem Erwartungswert von Null und der durch die Methode Δ Ta ermittelten Standardabweichung. Anschließend werden mit Hilfe der Sobol Sequenzen 100 Stichproben¹ aus dieser Verteilung entnommen. Mit diesen Stichproben wird dann eine Unsicherheitsanalyse mit Hilfe einer Monte-Carlo-Simulation durchgeführt.

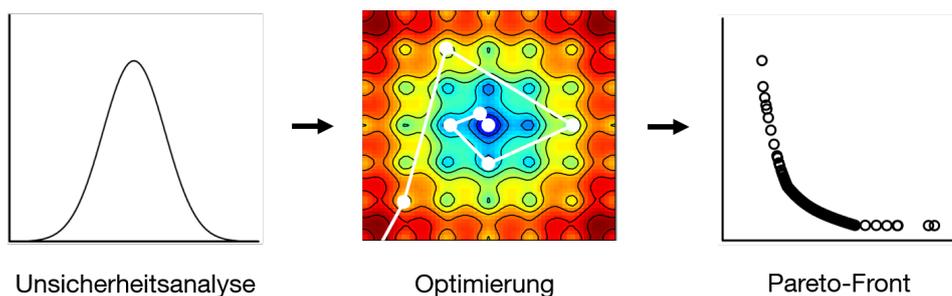


Abbildung 15.4: Robuste Optimierung basierend auf einer Unsicherheitsanalyse und einer mathematischen Optimierung

¹ Lomas und Eppel (1992) und Macdonald (2002) zeigen auf, dass für vergleichbare Aufgabenstellungen eine Anzahl von 80 bis 100 Stichproben für eine Darstellung der Unsicherheiten ausreichend ist.

Die resultierenden Verteilungen der Zielgrößen, nach Anwendung der Unsicherheitsanalyse, können durch Robustheitskriterien für die Lage und Streuung bewertet werden. Diese Robustheitskriterien bilden unter anderem die Zielfunktionen für die Optimierung. Auf Basis dieser Zielfunktionen wird, abhängig von der Fragestellung, eine multikriterielle Optimierung nach einem a priori oder a posteriori Ansatz durchgeführt. Die Optimierung geschieht mit Hilfe einer populationsbasierten Metaheuristik der Particle Swarm Optimization.

15.5 Visualisierung der Ergebnisse

Die Ergebnisse einer multikriteriellen Optimierung können z.B. durch eine Pareto-Front abgebildet werden. Bei dieser Darstellung werden aber in der Regel keine Unsicherheiten der Resultate visualisiert. Dadurch ist eine Interpretation der Robustheit von Lösungen nicht möglich. Mit einer Anpassung der Pareto-Front wird deshalb versucht, die Unsicherheiten über die Quantildifferenzen grafisch darzustellen. Dabei werden die Unsicherheiten über Farbe und Größe der Lösungspunkte in der Pareto-Front abgebildet. Ziel dieses Vorgehens ist nicht eine exakte Darstellung der Unsicherheiten, es soll vielmehr eine erste Bewertung der Lösungen unter Berücksichtigung der Unsicherheiten ermöglichen.

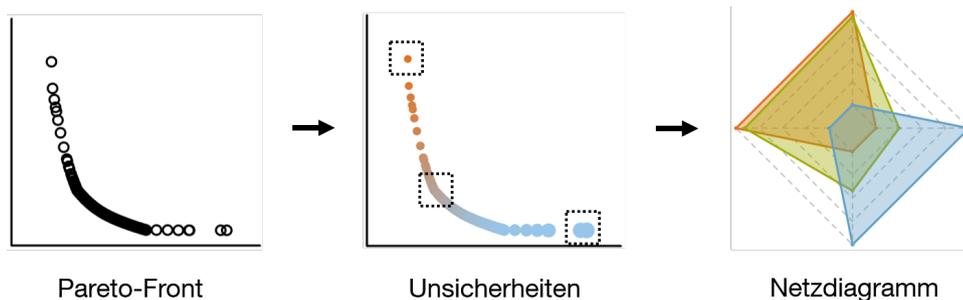


Abbildung 15.5: Visualisierung der Ergebnisse durch eine Pareto-Front mit integrierten Unsicherheiten und einem Netzdiagramm

Zur Unterstützung des Entscheiders können, auf Basis unterschiedlicher Interessen der Stakeholder, die Lösungen der Pareto-Front in Gruppen bzw. in Sanierungsvarianten eingeteilt werden. Mit Hilfe eines Netzdiagramms können diese Varianten detaillierter analysiert und verglichen werden. Dadurch wird der Entscheidungsprozess erleichtert. Die Kategorien des Netzdiagramms werden durch die Bestandteile der Zielfunktion aus der robusten Optimierung definiert.

16 | Zusammenfassung

Das Ablaufdiagramm 16.1 fasst die entwickelte Methode zur robusten Optimierung der energetischen Gebäudesanierung unter unsicheren Randbedingungen zusammen. Dabei wird der gesamte Ablauf in die Bereiche Datengrundlage, Modellentwicklung, Robuste Optimierung und Visualisierung aufgeteilt. Der Teil Datengrundlage besteht aus der Erstellung eines detaillierten Gebäudemodells sowie einer Definition und Quantifizierung der unsicheren Randbedingungen. Mit Hilfe einer Monte-Carlo-Simulation wird anschließend auf Basis des detaillierten Gebäudemodells und den unsicheren Randbedingungen die Datengrundlage (Sample-Daten) für das Erstellen des Ersatzmodells erzeugt. Im Teil Modellentwicklung wird eine Systemidentifikation mit dem Ersatzmodell, basierend auf den erstellten Sample-Daten, durchgeführt. Das Ergebnis der Systemidentifikation ist die Modellgüte des Ersatzmodells. Ist diese Modellgüte nach Abschluss der Systemidentifikation nicht ausreichend, kann sie z.B. durch eine erhöhte Anzahl von Sample-Daten verbessert werden.

Der dritte Teil des Ablaufs umfasst die robuste Optimierung. In einem ersten Schritt wird auf Basis des Ersatzmodells und den unsicheren Randbedingungen eine Unsicherheitsanalyse mit Hilfe einer Monte-Carlo-Simulation durchgeführt. Die resultierenden Verteilungen der Zielgrößen werden durch Robustheitskriterien für die Lage und Streuung bewertet. Anschließend werden diese Robustheitskriterien in Form von Zielfunktionen optimiert. Diese Schritte - Unsicherheitsanalyse, Auswertung der Robustheitskriterien und Optimierung der Robustheitskriterien - werden solange wiederholt, bis ein Abbruchkriterium erreicht wird.

Der vierte Teil beschreibt die Visualisierung der Ergebnisse. Dabei wird eine herkömmliche Präsentation der Resultate mit einer Pareto-Front durch die Darstellung von Unsicherheiten der einzelnen Lösungen und Zielgrößen erweitert. Weiterhin erfolgt eine Einteilung der Pareto-Front nach unterschiedlichen Interessen der einzelnen Stakeholder. Diese Varianten werden anschließend mit einem Netzdiagramm detailliert analysiert und verglichen.

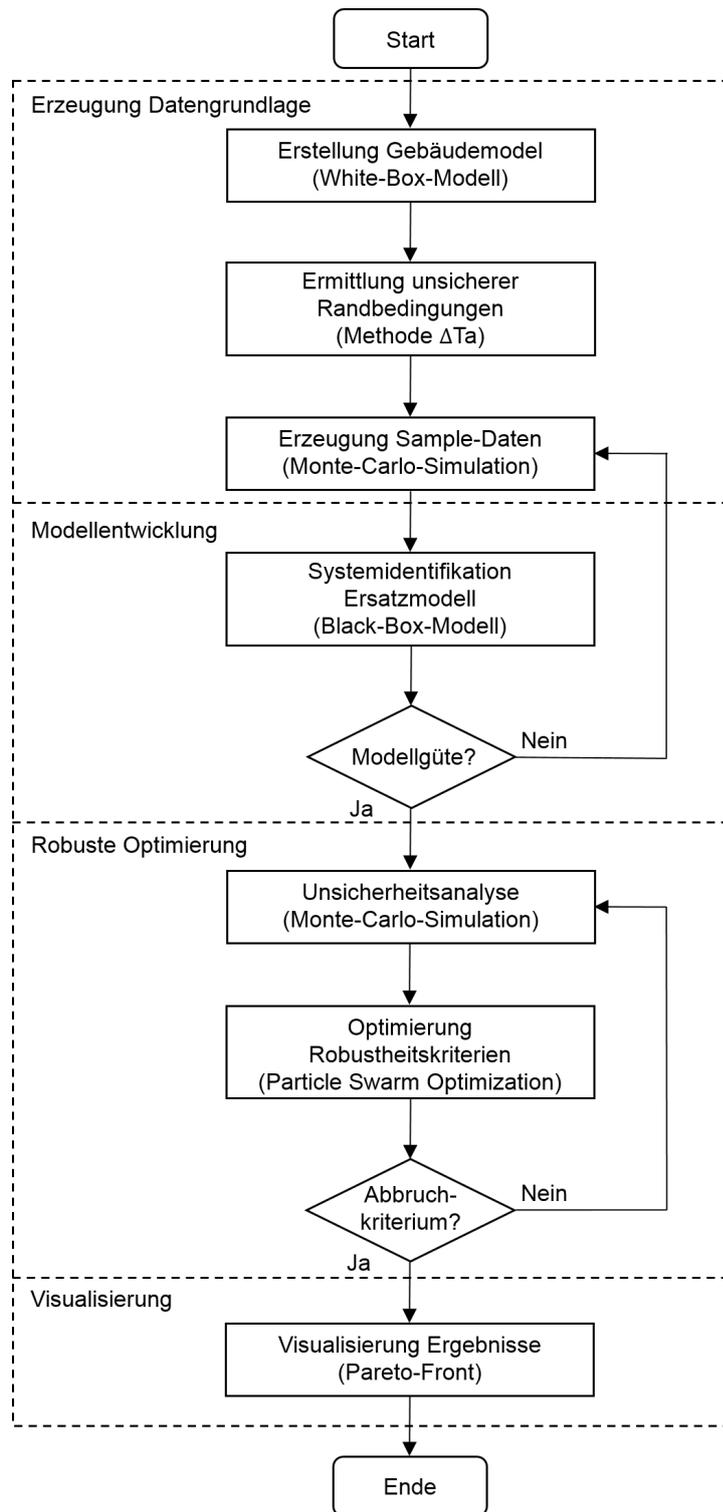


Abbildung 16.1: Ablauf der entwickelten Methode

Teil VI

Robuste Optimierung einer energetischen Gebäudesanierung

17 | Randbedingungen

Teil VI zeigt einen Vergleich der im Rahmen dieser Arbeit entwickelten Methode mit einem herkömmlichen Planungsansatz einer energetischen Sanierung nach der Energieeinsparverordnung 2014. Dieser Vergleich wird anhand einer energetischen Sanierung des in Teil II beschriebenen Einfamilienhauses durchgeführt. Als unsichere Randbedingungen werden die ebenfalls in Teil II vorgestellten Klimadaten und Energiepreisschwankungen herangezogen. Die energetische Sanierung wird mit Hilfe von Maßnahmen an der Gebäudehülle sowie der technischen Gebäudeausrüstung umgesetzt, welche in Teil II detaillierter benannt werden.

Tabelle 17.1: Zusammenfassung der analysierten Sanierungsmaßnahmen

Gebäudehülle	Gebäudetechnik
Dämmung Außenwand	Austausch Heizungsanlage
Dämmung Dach	Austausch Kühlanlage
Dämmung Bodenplatte	Anteil erneuerbarer Energien
Austausch Fenster	
Installation Sonnenschutz	

Die Maßnahmen an der Gebäudehülle werden mit Hilfe der robusten Optimierung untersucht. Die unterschiedlichen Konzepte der Anlagentechnik werden auf Basis von zwei Szenarien analysiert (Tabelle 5.5). Durch die Integration einer Kühlung in das Gebäudemodell können die Auswirkungen der klimatischen Veränderungen energetisch quantifiziert und mit dem bisherigen Energiebedarf verglichen werden. Für den Vergleich der Planungsmethoden werden lediglich die in Tabelle 17.1 vorgestellten Maßnahmen berücksichtigt. So wird z.B. keine weitere Erhöhung der Fensterlüftung durch den Nutzer berücksichtigt, da der Nutzer zwar eine wichtige unsichere Randbedingung darstellt, diese aber im Rahmen der Arbeit nicht untersucht wird.

Ziel in diesem Teil VI ist deshalb nicht die Entwicklung eines aus Sicht der realen Planung optimalen Sanierungskonzeptes, sondern eine Diskussion der Vor- und Nachteile der entwickelten Methode gegenüber einem herkömmlichen Planungsansatz. Dieser Vergleich wird anhand folgender Aufgabenstellungen durchgeführt:

- i) Minimierung der Treibhausgas-Emissionen unter Berücksichtigung des Klimawandels
- ii) Maximierung des Kapitalwertes unter Berücksichtigung des Klimawandels und unterschiedlicher Entwicklungen der Energiekosten
- iii) Gemeinsame Optimierung der beiden Zielgrößen Treibhausgas-Emissionen und Kapitalwert unter Integration der unsicheren Randbedingungen Klimawandel und Energiekosten

Die Untersuchung dieser Fragestellungen geschieht durch einen Vergleich von Ergebnissen aus drei verschiedenen Klimaperioden mit jeweils einem Zeitraum von 30 Jahren. Eine Periode repräsentiert die Länge eines Sanierungszyklus¹. Die drei Perioden stellen jeweils eine unterschiedliche Entwicklung der klimatischen Veränderungen dar. Zusätzlich werden für jede Periode zwei Konzepte der Technische Gebäudeausrüstung (TGA) analysiert. Die Details zu diesen Szenarien und den Klimaperioden können aus Teil II entnommen werden.

¹ Die Länge eines Sanierungszyklus kann zwischen 30 und 55 Jahren, in Abhängigkeit der Gebäudekomponenten, betragen (Hoier und Erhorn 2013). Im Rahmen dieser Arbeit wird ein Zyklus von 30 Jahren verwendet, da dieser auch der Länge einer definierten Klimaperiode entspricht.

18 | Resultate und Diskussion

18.1 Modellentwicklung

Das Vorgehen für die Modellentwicklung wird in Teil III dieser Arbeit detailliert beschrieben. Des Weiteren ist eine erste Anwendung der Modellentwicklung bereits in Kapitel 13 dargestellt. Deshalb wird im Folgenden lediglich auf die Eckpunkte und Kenndaten der Ersatzmodelle eingegangen. Als Grundlage der drei Anwendungsfälle wird für die Zielgrößen Heizwärmebedarf (Q_h) und Kühlbedarf (Q_c) pro Klimaperioden jeweils ein Ersatzmodell entwickelt. Daraus ergibt sich eine Anzahl von sechs Ersatzmodellen. Die Ersatzmodelle werden mit dem in Teil III favorisierten Neuronalen Netz erstellt. Abbildung 18.1 zeigt den schematischen Aufbau der erstellten Neuronalen Netze. Die Struktur besteht aus einer Eingangsschicht, einer verdeckten Schicht und einer Ausgangsschicht.

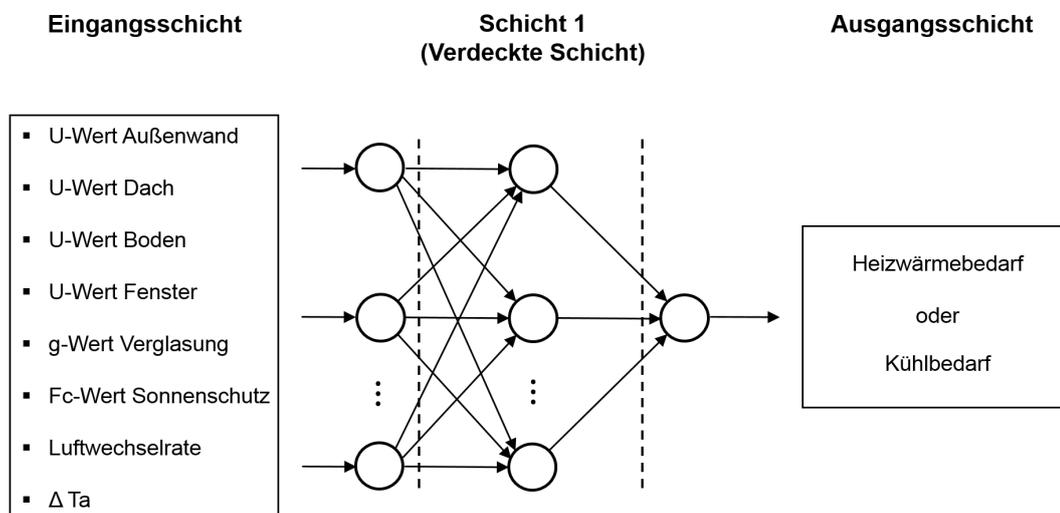


Abbildung 18.1: Ein- und Ausgangsgrößen der verwendeten Neuronalen Netze

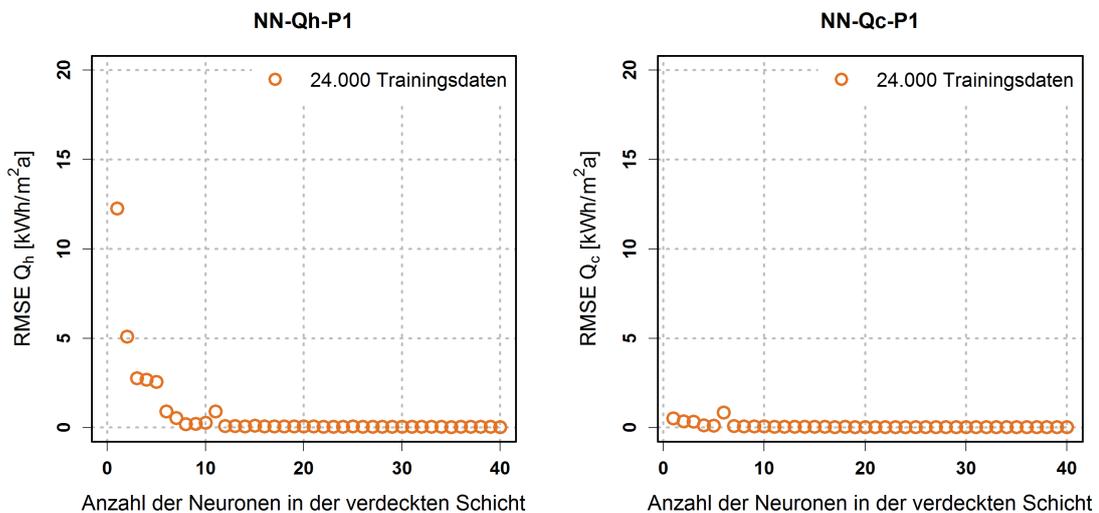
Eine detaillierte Zusammenfassung der Eingangsgrößen für die Ersatzmodelle sowie ihren Wertebereich für die „Erstellung“ und „Anwendung“ (Details, vgl. Kapitel 8 und 9) sind in Tabelle 18.1 abgebildet. Die Eingangsgrößen für das Klima, ΔTa_{Qh} und ΔTa_{Qc} , werden mit Hilfe der in Kapitel 12.1.2 vorgestellten Methode ΔTa für die jeweilige Periode ermittelt.

Tabelle 18.1: Zusammenfassung der Eingangsgrößen aller Ersatzmodelle

Eingangsgrößen Gebäude	Erstellung	Anwendung	Einheit
U-Wert Außenwand	U(0,01;1,6)	U(0,1;1,4)	[W/m ² K]
U-Wert Dach	U(0,01;1,6)	U(0,1;1,1)	[W/m ² K]
U-Wert Boden	U(0,01;1,6)	U(0,1;1,1)	[W/m ² K]
U-Wert Fenster	U(0,5;3,5)	U(0,6;3,5)	[W/m ² K]
g-Wert Verglasung	U(0,2;0,8)	U(0,3;0,75)	[-]
Fc-Wert Sonnenschutz	U(0,1;1,0)	U(0,25;1,0)	[-]
Luftwechsel	U(0,4;0,8)	U(0,6;0,7)	[h ⁻¹]
Eingangsgrößen Klima	Erstellung	Anwendung	Einheit
$\Delta T_{a_{Qh}}$ P1	N(0;1,0)	N(0;1,0)	[K]
$\Delta T_{a_{Qc}}$ P1	N(0;1,3)	N(0;1,3)	[K]
$\Delta T_{a_{Qh}}$ P2	N(0;1,2)	N(0;1,2)	[K]
$\Delta T_{a_{Qc}}$ P2	N(0;2,0)	N(0;2,0)	[K]
$\Delta T_{a_{Qh}}$ P3	N(0;1,0)	N(0;1,0)	[K]
$\Delta T_{a_{Qc}}$ P3	N(0;1,2)	N(0;1,2)	[K]

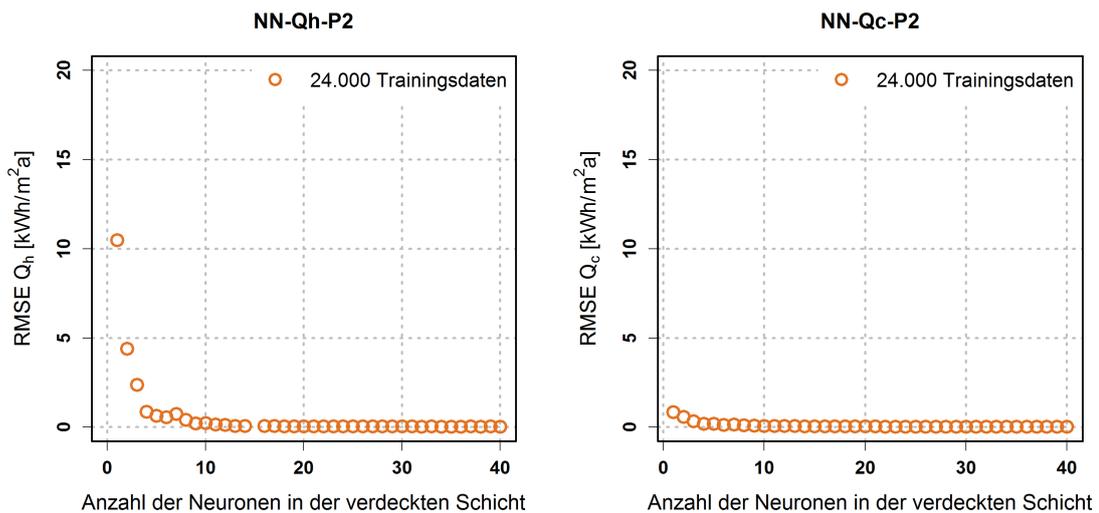
18.1.1 Kalibrierung und Validierung der Ersatzmodelle

In den folgenden Abschnitten werden die Ergebnisse aus der Kalibrierung und Validierung der sechs Ersatzmodelle dargestellt. Dabei wird für die Kalibrierung der Modelle die Anzahl der Neuronen in der verdeckten Schicht über eine Parameterstudie ermittelt (siehe Kapitel 9.3). Die Abbildung 18.2 zeigt die Ergebnisse aus der Modellkalibrierung der sechs Ersatzmodelle. Die x-Achse repräsentiert die Anzahl der Neuronen in der verdeckten Schicht und die y-Achse den durchschnittlichen Fehler der Modellprognose in Form des Root Mean Square Error (RMSE). Die Resultate zeigen, dass mit einer Anzahl von 15 oder mehr Neuronen der Prognosefehler bei allen Ersatzmodellen deutlich reduziert werden kann.



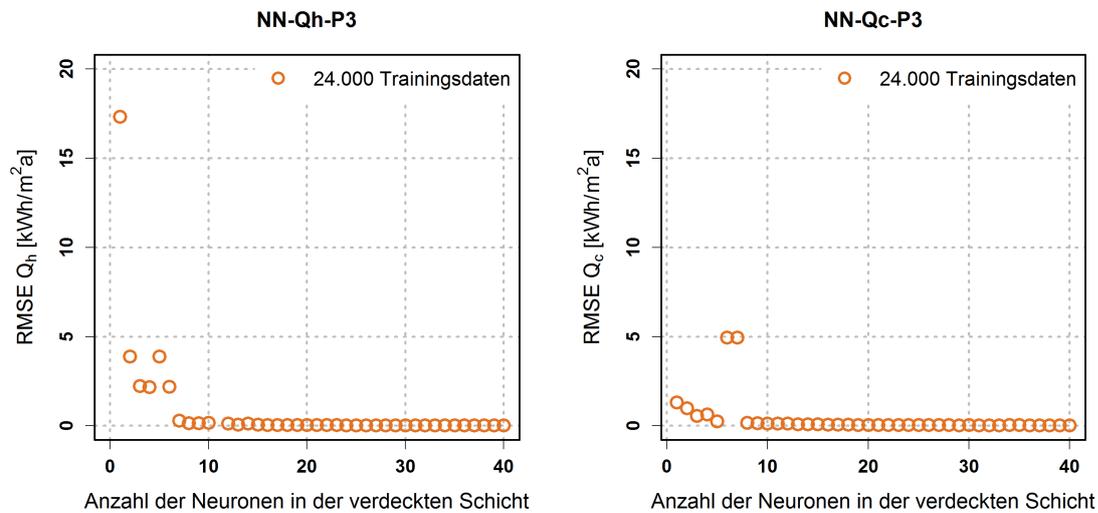
(a) Entwicklung des RMSE der Zielgröße Q_h in Periode 1

(b) Entwicklung des RMSE der Zielgröße Q_c in Periode 1



(c) Entwicklung des RMSE der Zielgröße Q_h in Periode 2

(d) Entwicklung des RMSE der Zielgröße Q_c in Periode 2



(e) Entwicklung des RMSE der Zielgröße Q_h in Periode 3 (f) Entwicklung des RMSE der Zielgröße Q_c in Periode 3

Abbildung 18.2: Strukturoptimierung der Ersatzmodelle für die beiden Zielgrößen Q_h und Q_c

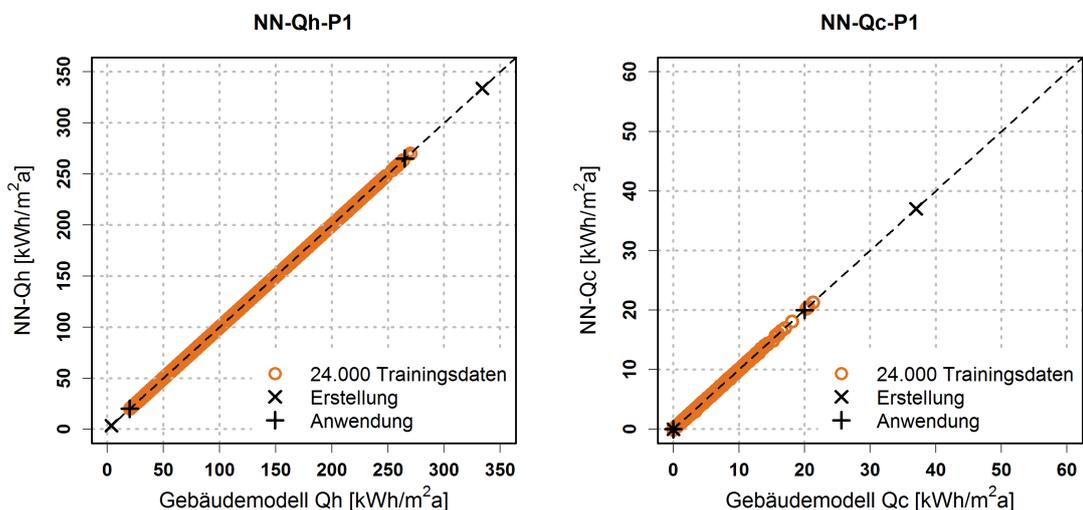
Die Anzahl der benötigten Trainingsdaten für eine angemessene Darstellung des Anwendungsbereiches liegen, wie in Teil IV, bei 24.000 (siehe Abbildung 18.3). Die Kreuzvalidierung der Modelle wird mit 6.000 Validierungsdaten durchgeführt. Dies ergibt eine Anzahl von 30.000 Sample-Daten für das Lernen und Testen der Ersatzmodelle. In Tabelle 18.2 sind die Resultate der Kreuzvalidierung dargestellt. Die Ergebnisse in Tabelle 18.3 zeigen, dass es hilfreich ist, als Bewertung für die Modellgüte sowohl den RMSE als auch den Coefficient of Variation (CV) heranzuziehen. Die Zielgröße Kühlbedarf Q_c weist in zwei Perioden einen geringeren RMSE auf, als die Zielgröße Heizwärmebedarf Q_h . Dies lässt darauf schließen, dass die Modelle für Q_c eine höhere Qualität aufweisen als für Q_h .

Tabelle 18.2: Ergebnisse aus der Kreuzvalidierung mit den Zielgrößen Q_h und Q_c

Modell	Training	Parameter	RMSE	CV	R ²
NN-Qh-P1	24.000	35 Neuronen	0,04 [kWh/m ² a]	0,03 [%]	0,99999
NN-Qc-P1	24.000	38 Neuronen	0,02 [kWh/m ² a]	0,95 [%]	0,99988
NN-Qh-P2	24.000	39 Neuronen	0,04 [kWh/m ² a]	0,03 [%]	0,99999
NN-Qc-P2	24.000	38 Neuronen	0,02 [kWh/m ² a]	0,56 [%]	0,99996
NN-Qh-P3	24.000	37 Neuronen	0,03 [kWh/m ² a]	0,03 [%]	0,99999
NN-Qc-P3	24.000	39 Neuronen	0,03 [kWh/m ² a]	0,41 [%]	0,99996

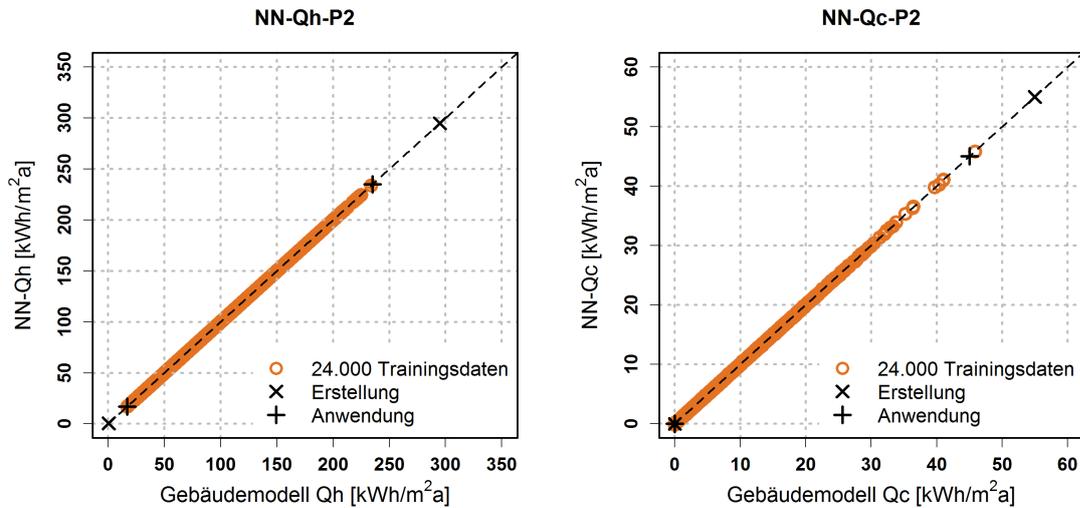
Der geringere RMSE ist jedoch auf das Größenverhältnis zwischen Heizwärme- und Kühlbedarf zurückzuführen. So liegt z.B. der maximale Heizwärmebedarf in Periode 1 bei ca. 270 kWh/m²a und der maximale Kühlbedarf bei ca. 20 kWh/m²a. Dies bedeutet, dass eine absolute Abweichung von z.B. ± 2 kWh/m²a eine relative Abweichung der Heizwärmebedarfs von $\pm 0,74\%$ bedeutet. Beim Kühlbedarf jedoch resultiert eine relative Abweichung von $\pm 10\%$. Deshalb ist trotz eines geringeren RMSE von Q_c die relative Modellgüte schlechter als von Q_h , was wiederum durch den Coefficient of Variation (CV) in Tabelle 13.4 deutlich abgebildet wird. Der CV ist ein relativer Fehler und gibt die durchschnittliche prozentuale Abweichung der Modellprognose gegenüber den Basisdaten an. Dieser Kennwert kann somit auch für den Vergleich der Modellgüte unabhängig von Größenordnung und Einheit der Zielvariablen herangezogen werden.

Prinzipiell zeigen die Kennwerte für die Modellgüte in Tabelle 13.4 sehr gute Ergebnisse. So liegt, z.B. der relative Prognosefehler (CV) bei allen Modellen unter einem Prozent. Deshalb stellt sich auch hier, wie bei den bisher vorgestellten Analysen, die Frage, ob eine Anzahl von 24.000 Trainingsdaten notwendig ist. Wie jedoch in Kapitel 9.4 beschrieben, sollte der Anwendungsbereich der Ersatzmodelle ebenfalls validiert werden. Abbildung 18.3 stellt die Ergebnisse der Validierung des Anwendungsbereiches dar. Dabei werden die Ergebnisse aus dem detaillierten Gebäudemodell und den Ersatzmodellen in Form eines Streudiagramms aufgetragen. Die Grenzwerte für den Anwendungsbereich werden mit einem Plus „+“ gekennzeichnet. Alle Grafiken zeigen, dass die Ergebnisse (orangefarbenen Punkte) nur knapp die jeweiligen Grenzen des Anwendungsbereiches abbilden. Daraus lässt sich ableiten, dass die gewählte Anzahl von 24.000 Trainingsdaten für eine angemessene Darstellung des Anwendungsbereiches notwendig ist.



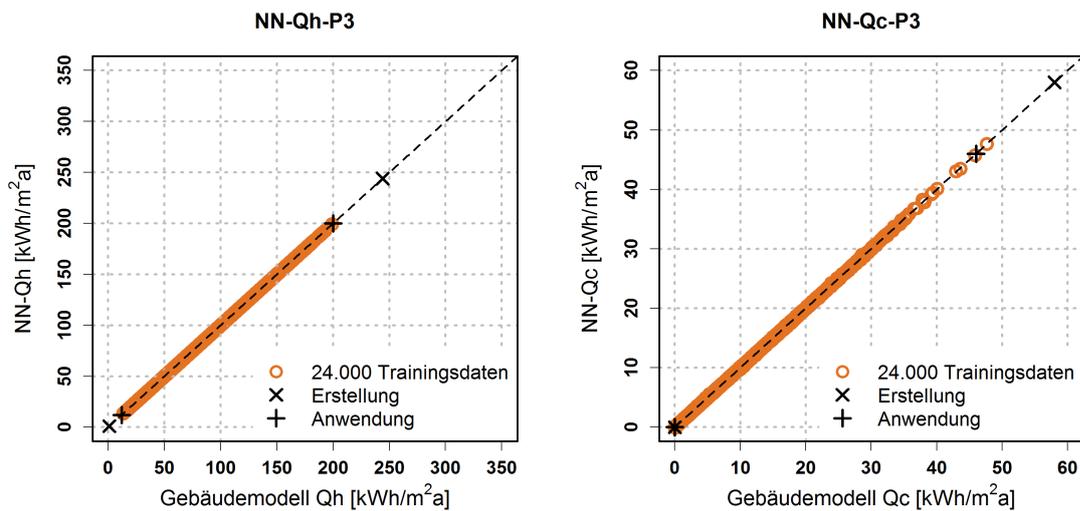
(a) Streudiagramm der Ergebnisse des Heizwärmebedarfs Q_h in der Periode 1

(b) Streudiagramm der Ergebnisse des Kühlbedarfes Q_c in der Periode 1



(c) Streudiagramm der Ergebnisse des Heizwärmebedarfes Q_h in der Periode 2

(d) Streudiagramm der Ergebnisse des Kühlbedarfes Q_c in der Periode 2



(e) Streudiagramm der Ergebnisse des Heizwärmebedarfes Q_h in der Periode 3

(f) Streudiagramm der Ergebnisse des Kühlbedarfes Q_c in der Periode 3

Abbildung 18.3: Streudiagramme mit den Prognosen der Neuronalen Netze und den Ergebnissen des detaillierten Gebäudemodells für den Heiz- und Kühlbedarf

Ein wesentlicher Grund für die Verwendung von Ersatzmodellen bei der robusten Optimierung ist die Reduktion von Rechenzeiten. Die Erstellung der Ersatzmodelle verursacht jedoch einen zusätzlichen Arbeitsaufwand. Die Erzeugung von 30.000 Sample-Daten für die Erstellung eines Ersatzmodells benötigt mit einer handelsüblichen Workstation (Intel Xeon CPU E5-2687W v3 3.10 GHz) mit 20 Kernen ca. 36 Stunden. Daraus resultiert eine Rechenzeit von ca. neun Tagen für die im Beispiel notwendigen sechs Ersatzmodelle.

Die Kalibrierung und Validierung der Ersatzmodelle benötigt weiterhin fünf Arbeitstage. Dies setzt jedoch eine ausreichende Kenntnis des Bearbeiters im Bereich des maschinellen Lernens und der Gebäudesimulation voraus. Daraus resultiert ein zusätzlicher Arbeitsaufwand, neben der Erstellung des detaillierten Modells, von zwei Wochen. Die durchschnittliche Rechenzeit einer robusten Optimierung im Rahmen dieser Arbeit beträgt ca. drei Minuten, bei einer 40.000-fachen Simulation des Ersatzmodells. Eine vergleichbare Optimierung mit einem detaillierten Gebäudemodell benötigt, ohne Parallelisierung der Simulationen¹, ca. 27 Tage. Dies bedeutet, dass bei der Durchführung einer einzigen robusten Optimierung die zusätzliche Bearbeitungszeit für alle sechs Ersatzmodelle geringer ist, als die Rechenzeit mit einem detaillierten Gebäudemodell.

18.2 Robuste Optimierung der Treibhausgas-Emissionen

Die folgenden Analysen zeigen die Ergebnisse einer energetischen Sanierung mit Hilfe einer robusten Optimierung (RobOpt) und einem herkömmlichen Planungsansatz (EnEV). Ziel der Untersuchung ist die Minimierung der Treibhausgas-Emissionen unter Berücksichtigung von klimatischen Veränderungen. Dabei werden für beide Methoden die TGA-Szenarien „Moderat“ und „Ambitioniert“ zur Berechnung der Treibhausgas-Emissionen herangezogen. Der Unterschied zwischen den beiden Methoden wird anhand der Sanierungsmaßnahmen für die Gebäudehülle ermittelt. Die Energieeffizienzmaßnahmen an der Gebäudehülle werden für den herkömmlichen Planungsansatz nach EnEV (2014) bestimmt (Tabelle 5.4).

Für die robuste Optimierung werden die Kennwerte der Sanierungsmaßnahmen durch die im Rahmen dieser Arbeit entwickelten Methode ermittelt. Die Zielfunktion der robusten Optimierung ist in den Gleichungen 18.1, 18.2 und 18.3 dargestellt. Gleichung 18.1 repräsentiert das Robustheitskriterium Median \bar{x}_{med} für die Treibhausgas-Emissionen, welche durch Heizen THG_{Q_h} und Kühlen THG_{Q_c} verursacht werden. Die Quantildifferenz wird in Gleichung 18.2 bestimmt. In Gleichung 18.3 werden die beiden Robustheitskriterien nach einem a priori Ansatz aufsummiert. Dabei wird die Gewichtung der einzelnen Gleichungen mit $w_1=0,5$ definiert, um beide Kriterien gleichmäßig zu priorisieren.

$$THG_{\bar{x}_{med}} = \bar{x}_{med}(THG_{Q_h} + THG_{Q_c})/k_{\bar{x}_{med}} \quad (18.1)$$

$$THG_{QD} = QD(THG_{Q_h} + THG_{Q_c})/k_{QD} \quad (18.2)$$

$$THG = w_1 THG_{\bar{x}_{med}} + (1 - w_1) THG_{QD} \quad (18.3)$$

Abbildung 18.4 zeigt die resultierenden Treibhausgas-Emissionen der beiden Methoden in den untersuchten Perioden mit Hilfe eines Box-Plot. In Grafik 18.4a sind die Ergebnisse aus dem TGA-Szenario „Moderat“ dargestellt. Grafik 18.4b präsentiert das TGA-Szenario „Ambitioniert“. Bei einer moderaten Sanierung der Anlagentechnik werden im Falle eines herkömmlichen

¹ Bei der Verwendung von kommerziellen Programmen in der Gebäudesimulation ist es in der Regel gar nicht oder nur durch einen sehr hohen monetären Aufwand möglich, die Simulation zu parallelisieren.

Planungsansatzes (EnEV) die negativen Auswirkungen der klimatischen Veränderungen deutlich. So ist in Grafik 18.4a ein starker Anstieg der Emissionen bei einer Sanierung nach EnEV zu erkennen. Die Ergebnisse der RobOpt weisen ebenfalls einen leichten Anstieg auf. Eine Sanierung mit dem TGA-Szenario „Ambitioniert“ kann die negativen Effekte der klimatischen Veränderungen, in beiden Methoden, fast vollständig kompensieren. Diese Ergebnisse können durch die Verwendung einer effizienten Kühlung in Kombination mit Strom aus erneuerbaren Energien, welche dem Szenario „Ambitioniert“ zugrunde liegt, erreicht werden. Daraus lässt sich ableiten, dass auch bei aktuellen Sanierungskonzepten durch die Berücksichtigung einer effizienten Kühlung, der potenzielle Anstieg von Treibhausgas-Emissionen zu großen Teilen reduziert werden kann.

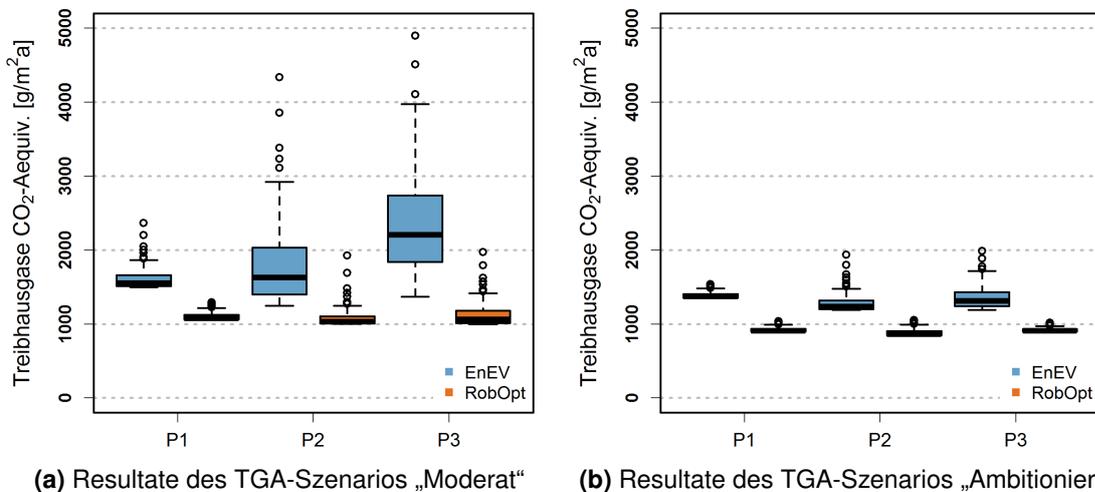


Abbildung 18.4: Vergleich von Treibhausgas-Emissionen nach einer robusten Optimierung und einer Sanierung nach EnEV

Tabelle 18.3 präsentiert einen detaillierten Vergleich der Ergebnisse beider Methoden für das Szenario „Moderat“. Dabei werden die Kennwerte Median, Quantildifferenz sowie die Grenzen der resultierenden Verteilung durch das 0,01%-Quantil und 99,99%-Quantil analysiert. Die robuste Optimierung erzielt für das Kriterium Median eine Reduzierung der Emissionen zwischen 30% und 50% gegenüber einer herkömmlichen Sanierung (EnEV). Die Robustheit der Ergebnisse, repräsentiert durch die Reduktion der Quantildifferenz, kann ebenfalls um bis zu 70% erhöht werden. In Tabelle 18.4 sind die detaillierten Ergebnisse des TGA-Szenarios „Ambitioniert“ dargestellt. Der Median der resultierenden Emissionen kann durch die robuste Optimierung zwischen 30% und 35% reduziert werden. Die Quantildifferenz bzw. die Streuung der Ergebnisse wird durch den Einsatz der entwickelten Methode (RobOpt) zwischen 25% und 85% vermindert, im Vergleich zu einer Sanierung nach EnEV. Diese ersten Ergebnisse machen deutlich, dass durch die robuste Optimierung die Treibhausgas-Emissionen nicht nur reduziert werden, sondern auch ihre Robustheit gegenüber unsicheren Randbedingungen erhöht bzw. die Streuung der Ergebnisse vermindert wird.

Tabelle 18.3: Ergebnisse der Treibhausgas-Emissionen nach einer robusten Optimierung und einer Sanierung nach EnEV für das TGA-Szenario „Moderat“

	Median [g/m ² a]	0,01%-Quantil [g/m ² a]	99,99%-Quantil [g/m ² a]	Quantildifferenz [g/m ² a]
EnEV P1	1.557	1.496	2.363	867
RobOpt P1	1.082	1.056	1.295	239
EnEV P2	1.632	1.247	4.334	3.087
RobOpt P2	1.036	1.001	1.925	924
EnEV P3	2.206	1.372	4.895	3.523
RobOpt P3	1.062	999	1.970	971

Tabelle 18.4: Ergebnisse der Treibhausgas-Emissionen nach einer robusten Optimierung und einer Sanierung nach EnEV für das TGA-Szenario „Ambitioniert“

	Median [g/m ² a]	0,01%-Quantil [g/m ² a]	99,99%-Quantil [g/m ² a]	Quantildifferenz [g/m ² a]
EnEV P1	1.375	1.351	1.539	188
RobOpt P1	913	899	1.040	141
EnEV P2	1.235	1.193	1.936	742
RobOpt P2	866	842	1.052	210
EnEV P3	1.313	1.193	1.990	797
RobOpt P3	909	897	1.018	121

Die resultierenden Kennwerte für die Sanierungsmaßnahmen an der Gebäudehülle werden in den Tabellen 18.5 und 18.6 abgebildet. Das Kürzel „EnEV“ repräsentiert die gleichbleibenden Kennwerte für eine Sanierung nach Stand der Technik. Die Grenzen des Optimierungsgebietes der Gebäudeparameter für die robuste Optimierung werden durch „Max-Opt“ und „Min-Opt“ dargestellt. Bei der Analyse der Ergebnisse aus der robusten Optimierung (RobOpt) wird der Vorteil dieser Methode nun sehr deutlich. Der Wärmedurchgangskoeffizient für die Außenwand und des Daches konvergiert, wie bei einer Sanierung mit dem Ziel einer Reduktion des Heizwärmebedarfs erwartet, gegen die definierte Untergrenze von 0,10 W/m²a. Der U-Wert der Bodenplatte jedoch nimmt Werte an, welche eine Planung nach EnEV nicht ermitteln würde. Die Energieeinsparverordnung setzt Grenzwerte für die Wärmedurchgangskoeffizienten von Bauteilen, diese Grenzwerte richten sich aber lediglich auf eine Reduktion des Heizwärmebedarfs. Der U-Wert der Bodenplatte von 1,10 W/m²a in Periode 3, welcher durch die robuste Optimierung ermittelt wird, entspricht aber dem Wert des Bestandsgebäudes. Darin liegt der Vorteil einer mathematischen Optimierung. Durch diese Methode können auch unkonventionelle Lösungen bzw. Lösungskombinationen erkannt werden. So kann die Kombination aus minimalen U-Werten für Außenwand und Dach sowie einem maximalen U-Wert für die Bodenplatte durch eine Sanierung nach EnEV nicht ermittelt werden.

Im konkreten Fallbeispiel resultieren durch die Berücksichtigung der klimatischen Veränderungen in der robusten Optimierung unterschiedliche U-Werte der Bodenplatte. Die klimatische Erwärmung erzeugt einen Anstieg des Kühlbedarfs. Das Einfamilienhaus weist keinen Keller auf und wird deshalb über den direkten Kontakt der Bodenplatte zum Erdreich während der Sommermonate passiv gekühlt. Eine erhöhte Dämmung der Bodenplatte würde diesen Effekt reduzieren und den Kühlbedarf erhöhen, was wiederum einen Anstieg der Treibhausgas-Emissionen zur Folge hätte. Die Berücksichtigung des Klimawandels in der robusten Optimierung ist auch am g-Wert der Verglasung zu erkennen. Der g-Wert im TGA-Szenario „Ambitioniert“ liegt in der ersten Periode an der oberen Grenze des Optimierungsbereiches. In der zweiten und dritten Periode jedoch ist das Ergebnis des g-Werts an der unteren Grenze des Optimierungsbereiches. Dadurch wird der Eintrag von Solarstrahlung in das Innere des Gebäudes reduziert und somit ein Anstieg des Kühlbedarfes verhindert.

Tabelle 18.5: Vergleich der Gebäudeparameter aus der robusten Optimierung und einer Sanierung nach EnEV für das TGA-Szenario „Moderat“

	U-Wand [W/m ² K]	U-Dach [W/m ² K]	U-Boden [W/m ² K]	U-Fenster [W/m ² K]	g-Wert [-]	Fc-Wert [-]
EnEV	0,24	0,24	0,30	1,30	0,60	0,25
RobOpt P1	0,10	0,10	0,47	0,60	0,30	0,25
RobOpt P2	0,10	0,10	1,10	0,60	0,30	0,25
RobOpt P3	0,10	0,10	1,10	0,60	0,30	0,25
Max-Opt	1,40	1,10	1,10	3,50	0,75	1,00
Min-Opt	0,10	0,10	0,10	0,60	0,30	0,25

Tabelle 18.6: Vergleich der Gebäudeparameter aus der robusten Optimierung und einer Sanierung nach EnEV für das TGA-Szenario „Ambitioniert“

	U-Wand [W/m ² K]	U-Dach [W/m ² K]	U-Boden [W/m ² K]	U-Fenster [W/m ² K]	g-Wert [-]	Fc-Wert [-]
EnEV	0,24	0,24	0,30	1,30	0,60	0,25
RobOpt P1	0,10	0,10	0,34	0,60	0,75	0,25
RobOpt P2	0,10	0,10	0,42	0,60	0,30	0,25
RobOpt P3	0,10	0,10	1,10	0,60	0,30	0,54
Max-Opt	1,40	1,10	1,10	3,50	0,75	1,00
Min-Opt	0,10	0,10	0,10	0,60	0,30	0,25

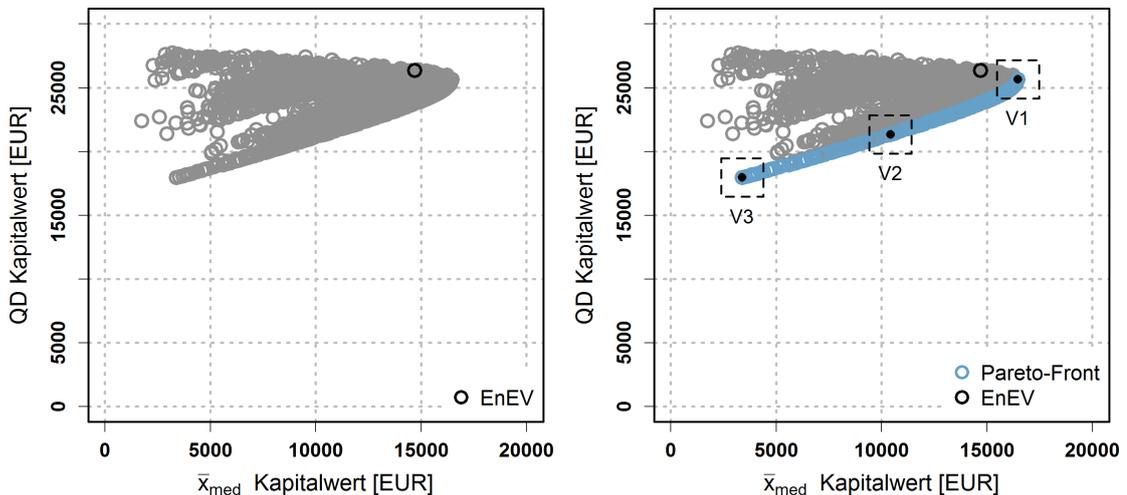
18.3 Robuste Optimierung des Kapitalwerts

Die folgenden Abschnitte zeigen die Resultate einer energetischen Sanierung mit dem Ziel der Kapitalwertmaximierung. Dabei werden die klimatischen Veränderungen und die Entwicklung der Energiekosten als unsichere Randbedingungen herangezogen. Die robuste Optimierung wird mit einem a posteriori Ansatz durchgeführt (siehe Kapitel 12). Deshalb werden zwei Zielfunktionen für die Optimierung definiert. Gleichung 18.4 repräsentiert das Robustheitskriterium Median \bar{x}_{med} und Gleichung 18.5 das Robustheitskriterium Quantildifferenz QD . Für eine Maximierung des Kapitalwertes erhält Gleichung 18.4 ein negatives Vorzeichen, da die Optimierung der beiden Zielfunktionen über ein Minimierungsproblem durchgeführt wird.

$$KW_{\bar{x}_{med}} = -\bar{x}_{med}(KW) \quad (18.4)$$

$$KW_{QD} = QD(KW) \quad (18.5)$$

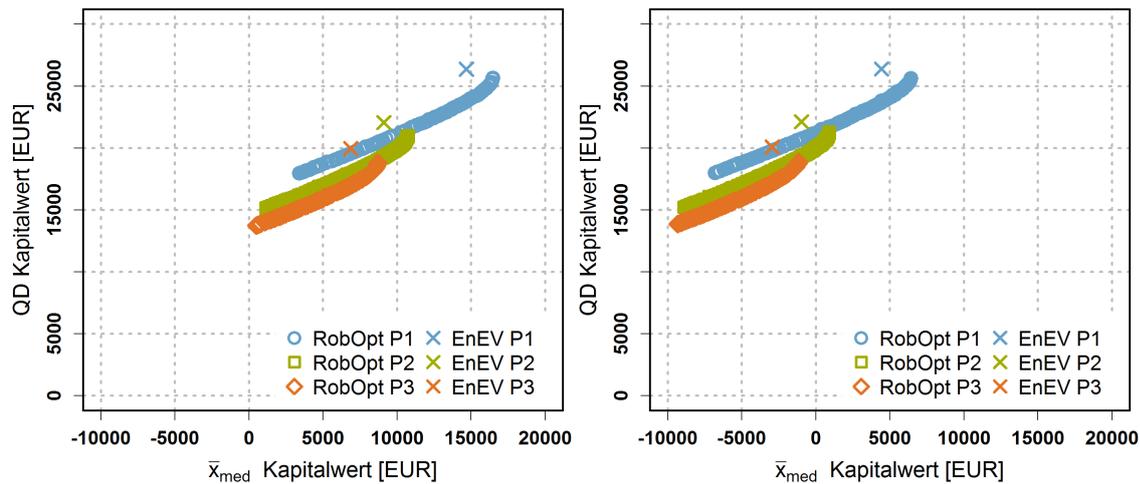
In Abbildung 18.5 wird für ein besseres Verständnis das Vorgehen für die Auswertung von Ergebnissen eines a posteriori Ansatzes dargestellt. Als Beispiel werden die Resultate aus Periode 1 und dem TGA-Szenario „Moderat“ verwendet. Grafik 18.5a zeigt alle Ergebnisse der robusten Optimierung. Jeder Lösungspunkt steht für die Parameter einer Verteilung der Zielgröße Kapitalwert. Diese Parameter werden durch die beiden Robustheitskriterien, Median und Quantildifferenz, in der Grafik repräsentiert. Die y-Achse zeigt die Quantildifferenz, welche die Robustheit der Lösungen widerspiegelt. Eine geringe Quantildifferenz bedeutet eine hohe Robustheit der Lösung. Die x-Achse stellt den Median der Zielgröße dar. Ein höherer Median bedeutet in diesem Fall einen größeren Kapitalwert und dadurch eine wirtschaftlichere Lösung.



(a) Ergebnisse der robusten Optimierung des Kapitalwerts (b) Pareto-Front des Kapitalwerts nach einer robusten Optimierung

Abbildung 18.5: Ergebnisse des Kapitalwerts für das Szenario „Moderat“ in Periode 1

Das Ergebnis der energetischen Sanierung nach EnEV ist mit einem schwarzen Kreis markiert. In Grafik 18.5b wird die resultierende Pareto-Front ergänzt. In den weiteren Analysen werden die Ergebnisse der robusten Optimierung über Pareto-Fronten abgebildet. Ein detaillierter Vergleich der Resultate geschieht über einzelne Lösungen aus der Pareto-Front. Diese Lösungen werden in Grafik 18.5b durch Boxen gekennzeichnet. Dabei ist V1 die maximale Lösung, V2 die mittlere Lösung und V3 die minimale Lösung der Pareto-Front.



(a) Ergebnisse der beiden Methoden für das TGA-Szenario „Moderat“

(b) Ergebnisse der beiden Methoden für das TGA-Szenario „Ambitioniert“

Abbildung 18.6: Ergebnisse des Kapitalwertes einer robusten Optimierung und nach EnEV

Abbildung 18.6 zeigt die Ergebnisse der beiden untersuchten Methoden für die Maximierung des Kapitalwertes. Dabei werden die Resultate der robusten Optimierung durch die Pareto-Fronten der jeweiligen Periode und die Ergebnisse einer Sanierung nach EnEV durch Kreuze „x“ dargestellt. Grafik 18.6a repräsentiert das TGA-Szenario „Moderat“ und Grafik 18.6b das TGA-Szenario „Ambitioniert“. Die Ergebnisse, welche mit einem herkömmlichen Planungsansatz (EnEV) erreicht werden, lassen in beiden TGA-Szenarien darauf schließen, dass durch die klimatischen Veränderungen der Kapitalwert bzw. die Wirtschaftlichkeit der Sanierung reduziert wird. Die Resultate des TGA-Szenarios „Ambitioniert“ machen dies besonders deutlich. In Periode 1 weist der Median des Kapitalwertes einen positiven Wert auf. Dies bedeutet, dass die energetische Sanierung wirtschaftlich ist. In Periode 2 und 3 hat der Median des Kapitalwertes jedoch negative Werte und lässt dadurch auf eine unwirtschaftliche Sanierung schließen. Diese Ergebnisse sind auf die Reduzierung des Heizwärmebedarfs, bedingt durch die klimatischen Veränderungen, zurückzuführen. Der „natürliche“ Rückgang des Heizwärmebedarfs vermindert die Wirksamkeit bzw. Rentabilität der energetischen Sanierungsmaßnahmen. Eine ähnliche Entwicklung ist ebenfalls bei den Ergebnissen der robusten Optimierung zu erkennen. In beiden TGA-Szenarien weisen die Pareto-Fronten für den Median des Kapitalwertes, mit steigender klimatischer Erwärmung, niedrigere Werte auf. Im Szenario „Ambitioniert“ wird in Periode 3 kein positiver Wert für den Median des Kapitalwertes erreicht.

Im Vergleich zu den Ergebnissen nach EnEV wird der Vorteil der multikriteriellen Optimierung offensichtlich. Die Pareto-Fronten liefern für das Optimierungsproblem mehrere Lösungen, welche abhängig von der jeweiligen Priorisierung der Robustheitskriterien eine optimale Lösung darstellen. Diese Lösungen schaffen eine Auswahlmöglichkeit für das Planungsteam, welches je nach Präferenz zwischen einer Maximierung des Kapitalwertes oder einer robusteren Lösungsvariante entscheiden kann. Die Ergebnisse nach EnEV liegen in beiden Szenarien oberhalb der Pareto-Fronten. Daraus lässt sich schließen, dass die Ergebnisse der robusten Optimierung bei einer gemeinsamen Bewertung von Robustheit (Quantildifferenz) und Maximierung des Kapitalwertes (Median) bessere Lösungen aufweisen.

Tabelle 18.7 fasst die detaillierten Ergebnisse aus dem Szenario „Moderat“ für die beiden Methoden zusammen. Die Ergebnisse werden anhand der Kennwerte Median, Quantildifferenz, 0,01%-Quantil und 99,99%-Quantil verglichen. Die Resultate aus der robusten Optimierung (RobOpt) werden durch die in Abbildung 18.5b dargestellten Lösungsvarianten aus der Pareto-Front (V1, V2 und V3) repräsentiert. Die Ergebnisse von V1 stellen dabei die optimale Maximierung des Kapitalwertes dar. Bei einem Vergleich von V1 mit den Ergebnisse nach EnEV erreicht die robuste Optimierung in jeder Periode nicht nur einen höheren Kapitalwert (Median), sondern auch eine niedrigere Quantildifferenz, also eine höhere Robustheit.

Tabelle 18.7: Ergebnisse einer Kapitalwertmaximierung auf Basis einer robusten Optimierung sowie einer Sanierung nach EnEV für das TGA-Szenario „Moderat“

	Median [EUR]	0,01%-Quantil [EUR]	99,99%-Quantil [EUR]	Quantildifferenz [EUR]
EnEV P1	14.678,00	5.382,00	31.746,00	26.364,00
RobOpt P1 V1	16.470,00	7.451,00	33.112,00	25.662,00
RobOpt P1 V2	10.417,00	3.081,00	24.434,00	21.352,00
RobOpt P1 V3	3.383,00	-2.626,00	15.340,00	17.966,00
EnEV P2	9.101,00	1.317,00	23.373,00	22.056,00
RobOpt P2 V1	10.732,00	3.369,00	24.346,00	20.977,00
RobOpt P2 V2	6.383,00	303,00	17.997,00	17.694,00
RobOpt P2 V3	1.162,00	-3.920,00	11.228,00	15.148,00
EnEV P3	6.870,00	-191,00	19.773,00	19.964,00
RobOpt P3 V1	8.706,00	2.097,00	20.890,00	18.793,00
RobOpt P3 V2	5.031,00	-453,00	15.472,00	15.925,00
RobOpt P3 V3	485,00	-4.143,00	9.603,00	13.746,00

Ein Vergleich der Lösungen aus den robusten Optimierungen untereinander führt zu folgender Schlussfolgerung: Die Resultate aus V1 repräsentieren die höchste Wirtschaftlichkeit, weisen jedoch auch die geringste Robustheit auf. Die Ergebnisse aus V3 haben die geringsten Unsicherheiten, bzw. größte Robustheit, sind aber im Vergleich zu V2 und V1 am unwirtschaftlichsten. Die Lösungen aus V2 bilden einen Mittelweg aus Wirtschaftlichkeit und Robustheit. Das Planungsteam kann nun aus diesen Varianten eine präferierte Lösung auswählen.

In Tabelle 18.8 sind die Ergebnisse aus dem TGA-Szenario „Ambitioniert“ dargestellt. Tendenziell verhalten sich die Lösungen aus der robusten Optimierung wie im Szenario „Moderat“. Der Median des Kapitalwerts weist jedoch in einigen Varianten negative Ergebnisse auf. Dies lässt auf eine unwirtschaftliche Sanierung schließen. Die Ursache liegt, wie zuvor erwähnt, in der Reduktion des Heizwärmebedarfs durch die klimatische Erwärmung. Die negativen Ergebnisse des Kapitalwertes, im Vergleich zum Szenario „Moderat“, entstehen durch die zusätzliche Investition in eine effiziente Kühlung. Daraus lässt sich für das Fallbeispiel ableiten, dass sich aus wirtschaftlicher Sicht eine effiziente Kühlung nicht lohnt. Dies beruht darauf, dass die durch den Klimawandel verursachte Reduktion der Heizkosten größer ist, als der Anstieg der Kosten für die Kühlung.

Tabelle 18.8: Ergebnisse einer Kapitalwertmaximierung auf Basis einer robusten Optimierung sowie einer Sanierung nach EnEV für das TGA-Szenario „Ambitioniert“

	Median [EUR]	0,01%-Quantil [EUR]	99,99%-Quantil [EUR]	Quantildifferenz [EUR]
EnEV P1	4.439,00	-4.869,00	21.522,00	26.391,00
RobOpt P1 V1	6.424,00	-2.582,00	23.039,00	25.621,00
RobOpt P1 V2	185,00	-7.150,00	14.199,00	21.343,00
RobOpt P1 V3	-6.827,00	-12.852,00	5.152,00	18.004,00
EnEV P2	-978,00	-8.790,00	13.329,00	22.119,00
RobOpt P2 V1	899,00	-6.581,00	14.693,00	21.274,00
RobOpt P2 V2	-3.584,00	-9.705,00	8.095,00	17.800,00
RobOpt P2 V3	-8.892,00	-14.004,00	1.216,00	15.220,00
EnEV P3	-2.942,00	-10.056,00	10.029,00	20.085,00
RobOpt P3 V1	-1.148,00	-7.792,00	11.089,00	18.881,00
RobOpt P3 V2	-4.923,00	-10.442,00	5.564,00	16.006,00
RobOpt P3 V3	-9.334,00	-14.014,00	147,00	13.866,00

Die resultierenden Gebäudeparameter aus der robusten Optimierung für das TGA-Szenario „Moderat“ sind in Tabelle 18.9 abgebildet. Die Grenzen des Optimierungsbereiches sind durch „Max-Opt“ und „Min-Opt“ gekennzeichnet. Die Gebäudeparameter einer herkömmlichen Planung sind durch „EnEV“ dargestellt. Für die Parameter g-Wert und Fc-Wert sind keine Kostenfunktionen hinterlegt. Die Installation eines Sonnenschutzes wird als obligatorisch betrachtet und eine Anpassung des g-Wertes kann über kosteneffiziente Maßnahmen wie z.B. Folien durchgeführt werden.

Die Ergebnisse der Gebäudeparameter zeigen noch deutlicher, wie bereits bei der Minimierung der Treibhausgas-Emissionen, die Vorteile der entwickelten Methode. Die Werte und Kombinationen der einzelnen Maßnahmen könnten durch ein Vorgehen nach Stand der Technik nicht ermittelt werden. Die Ergebnisse von V1 stellen eine optimale Maximierung des Kapitalwertes dar. Die Resultate der Wärmedurchgangskoeffizienten der Gebäudehülle aus V1 haben in jeder Periode höhere Werte als die nach EnEV. Daraus kann abgeleitet werden, dass eine Sanierung nach den Minimalanforderungen der aktuellen Gesetzgebung, im gewählten Fallbeispiel, kein optimales Kosten-Nutzen-Verhältnis aufweist.

Tabelle 18.9: Vergleich der Gebäudeparameter aus der robusten Optimierung und einer Sanierung nach EnEV für das TGA-Szenario „Moderat“

	U-Wand [W/m ² K]	U-Dach [W/m ² K]	U-Boden [W/m ² K]	U-Fenster [W/m ² K]	g-Wert [-]	Fc-Wert [-]
RobOpt P1 V1	0,38	0,36	0,69	1,31	0,75	1,00
RobOpt P1 V2	0,86	1,01	1,10	1,31	0,30	0,90
RobOpt P1 V3	1,40	1,10	1,10	3,50	0,30	0,25
RobOpt P2 V1	0,43	0,39	0,66	1,30	0,65	0,80
RobOpt P2 V2	0,86	1,10	1,05	1,31	0,30	0,35
RobOpt P2 V3	1,40	1,10	1,10	3,50	0,30	0,25
RobOpt P3 V1	0,42	0,41	0,75	1,30	0,48	0,25
RobOpt P3 V2	0,97	0,94	1,10	1,38	0,30	0,25
RobOpt P3 V3	1,40	1,10	1,10	3,50	0,30	0,25
EnEV	0,24	0,24	0,30	1,30	0,6	0,25
Max-Opt	1,40	1,10	1,10	3,50	0,75	1,00
Min-Opt	0,10	0,10	0,10	0,60	0,30	0,25

Die Ergebnisse aus V3 zeigen eine Kombination aus minimalen Investitionskosten und maximalen Energieverbrauch. Die Wärmedurchgangskoeffizienten der Maßnahmen sind gleich oder sogar höher als beim Bestandsgebäude, was zu einem maximalen Energiebedarf führt. Dadurch entstehen keine energiebedingten Mehrkosten für die Sanierungsmaßnahmen der Gebäudehülle, die Investitionskosten der Anlagentechnik bleiben dadurch unberührt. Die Werte für den g-Wert und den Fc-Wert weisen ebenfalls auf eine Maximierung des Energiebedarfs hin. Die Resultate aus V3 repräsentieren eine optimale Maximierung der Robustheit bzw. Minimierung der Unsicherheiten der Zielgröße Kapitalwert. Diese Reduktion der Unsicherheiten wird zum Einen über eine Minimierung der Investitionskosten und zum Anderen über geringere Einnahmen durch Energieeinsparung erreicht. Die Investitionskosten für die TGA sind fixiert, dadurch verursachen konstant geringere Einnahmen eine kleinere Schwankung des Kapitalwertes und liefern somit robustere Lösungen.

Die Ergebnisse der Gebäudeparameter für das TGA-Szenario „Ambitioniert“ sind in Tabelle 18.10 dargestellt. Im Allgemeinen weisen die Resultate ein ähnliches Verhalten wie für das Szenario „Moderat“ auf. Lediglich die Ergebnisse aus V1 in den Parametern g-Wert und Fc-Wert weisen eine andere Entwicklung auf. Im Szenario „Moderat“ ist der Einfluss des Klimawandels deutlich erkennbar. So wird in Periode 1 eine Maximierung der solaren Gewinne erzielt und in Periode 3 eine Minimierung. Im Szenario „Ambitioniert“ ist diese Entwicklung nicht ganz so deutlich, da nur der Fc-Wert angepasst wird. Dies ist auf den Einfluss der effizienten Kühlung zurückzuführen, welche einer Anpassung der Gebäudehülle entgegenwirkt.

Tabelle 18.10: Vergleich der Gebäudeparameter aus der robusten Optimierung und einer Sanierung nach EnEV für das TGA-Szenario „Ambitioniert“

	U-Wand [W/m ² K]	U-Dach [W/m ² K]	U-Boden [W/m ² K]	U-Fenster [W/m ² K]	g-Wert [-]	Fc-Wert [-]
RobOpt P1 V1	0,40	0,37	0,67	1,30	0,75	1,00
RobOpt P1 V2	0,93	1,03	1,10	1,34	0,47	0,90
RobOpt P1 V3	1,40	1,10	1,10	3,50	0,30	0,25
RobOpt P2 V1	0,40	0,40	0,62	1,30	0,75	1,00
RobOpt P2 V2	0,97	1,06	1,07	1,30	0,75	0,35
RobOpt P2 V3	1,40	1,10	1,10	3,50	0,30	0,25
RobOpt P3 V1	0,43	0,45	0,75	1,30	0,75	0,25
RobOpt P3 V2	0,97	0,95	1,10	1,37	0,30	0,30
RobOpt P3 V3	1,40	1,10	1,10	3,50	0,30	0,25
EnEV	0,24	0,24	0,30	1,30	0,6	0,25
Max-Opt	1,40	1,10	1,10	3,50	0,75	1,00
Min-Opt	0,10	0,10	0,10	0,60	0,30	0,25

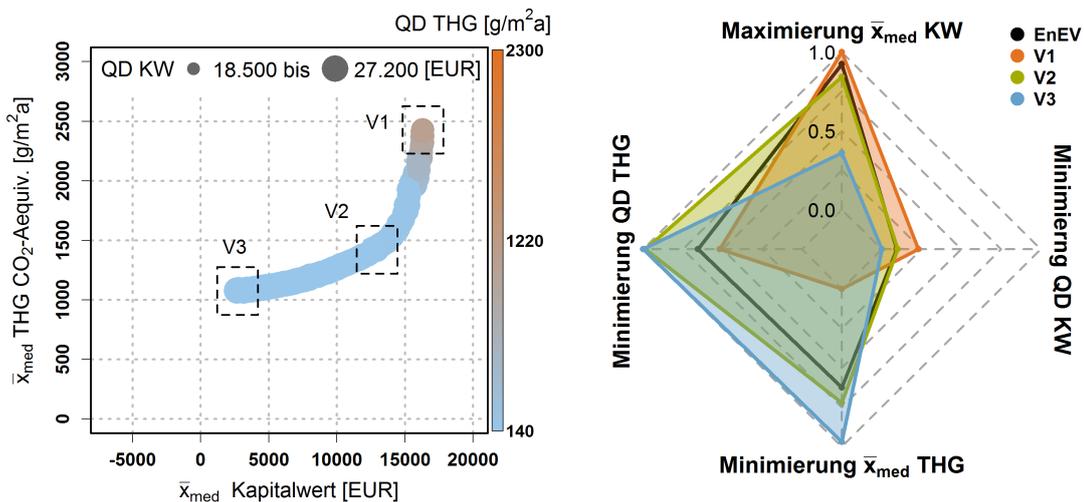
18.4 Robuste Optimierung des Kapitalwerts und der Treibhausgas-Emissionen

Die dritte Aufgabenstellung im Rahmen des Methodenvergleichs befasst sich mit einer Optimierung von mehr als zwei Zielgrößen. Dabei werden für die Optimierung des Kapitalwerts und der Treibhausgas-Emissionen jeweils zwei Robustheitskriterien herangezogen. Dadurch entstehen vier Zielfunktionen, welche in zwei Funktionen zusammengefasst werden können. Gleichung 18.6 beschreibt die Zielgröße Kapitalwert mit den Robustheitskriterien Median \bar{x}_{med} und Quantildifferenz QD . Die Zielgröße Treibhausgas-Emissionen wird mit Gleichung 18.7 dargestellt. Die Gewichte w_1 und w_2 werden mit 0,5 definiert, um eine gleichmäßige Priorisierung der Robustheitskriterien zu gewährleisten. Der Median des Kapitalwerts wird wie im vorherigen Kapitel maximiert und erhält deswegen ein negatives Vorzeichen.

$$F_{KW} = w_1(-\bar{x}_{med}(KW)) + (1 - w_1)QD(KW) \quad (18.6)$$

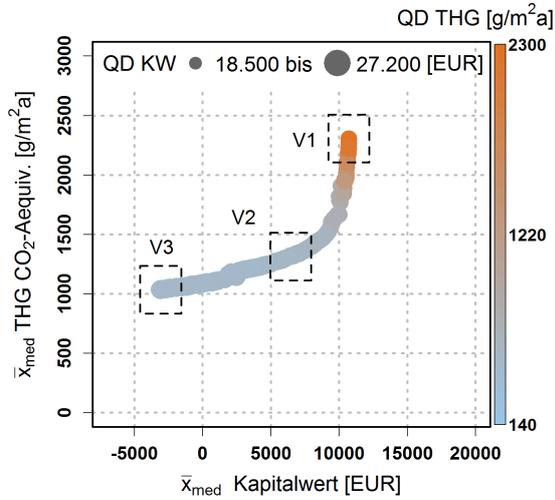
$$F_{THG} = w_2\bar{x}_{med}(THG_{Q_h, Q_c}) + (1 - w_2)QD(THG_{Q_h, Q_c}) \quad (18.7)$$

In Abbildung 18.7 sind die Ergebnisse der robusten Optimierung für den Kapitalwert und die Treibhausgas-Emissionen für das TGA-Szenario „Moderat“ dargestellt. Für eine detaillierte Einführung in die Visualisierung und Interpretation dieser Grafiken wird auf Abschnitt 13.2.2 verwiesen. Die Kombination aus Pareto-Front (a) und Netzdiagramm (b) repräsentiert die Resultate innerhalb einer Klimaperiode.

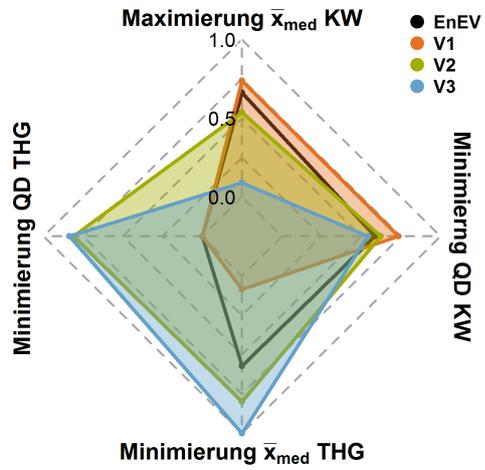


(a) Resultate der robusten Optimierung von Kapitalwert und Treibhausgas-Emissionen für das Szenario „Moderat“ in Periode 1

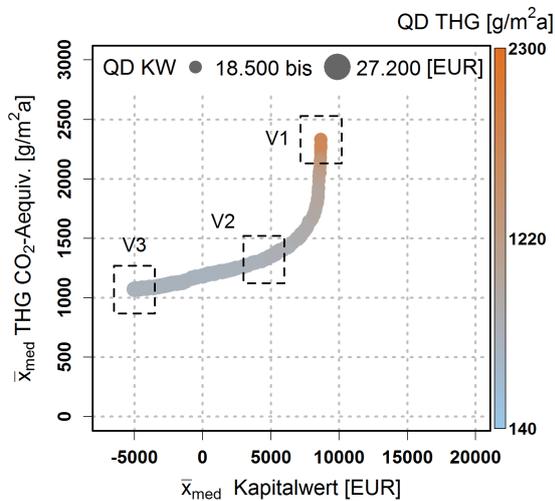
(b) Resultate aus V1, V2 und V3 im Vergleich mit den Ergebnissen nach EnEV für das Szenario „Moderat“ in Periode 1



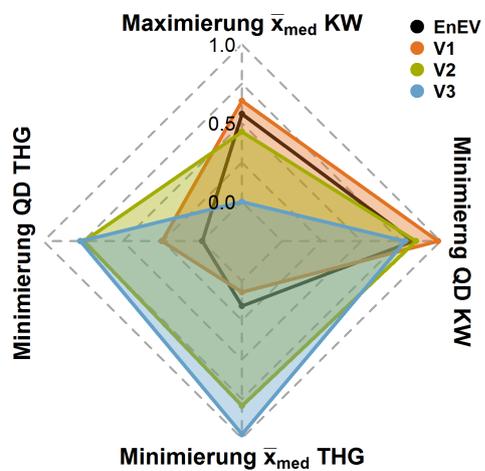
(c) Resultate der robusten Optimierung von Kapitalwert und Treibhausgas-Emissionen für das Szenario „Moderat“ in Periode 2



(d) Resultate aus V1, V2 und V3 im Vergleich mit den Ergebnissen nach EnEV für das Szenario „Moderat“ in Periode 2



(e) Resultate der robusten Optimierung von Kapitalwert und Treibhausgas-Emissionen für das Szenario „Moderat“ in Periode 3



(f) Resultate aus V1, V2 und V3 im Vergleich mit den Ergebnissen nach EnEV für das Szenario „Moderat“ in Periode 3

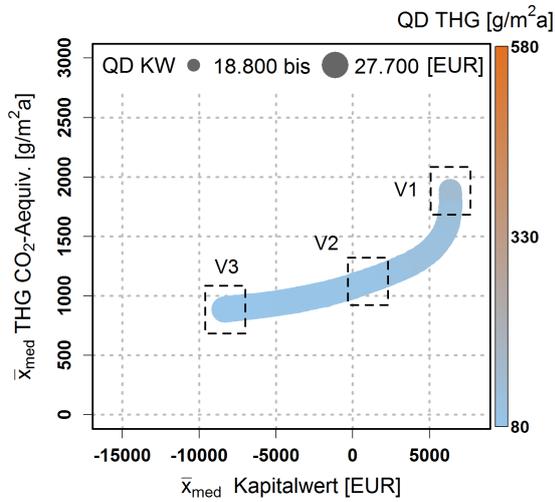
Abbildung 18.7: Resultate der robusten Optimierung von Treibhausgas-Emissionen und des Kapitalwerts für das Szenario „Moderat“

Die Grafiken der Pareto-Fronten zeigen auf der x-Achse und y-Achse den Median der Zielgrößen. Die Robustheit bzw. die Quantildifferenz für den Kapitalwert wird durch den Durchmesser der Lösungspunkte visualisiert. Die Quantildifferenz der Treibhausgas-Emissionen wird über eine Farbskalierung der Lösungen abgebildet. Für einen detaillierten Vergleich der Ergebnisse aus der robusten Optimierung mit einem herkömmlichen Planungsansatz (EnEV) werden drei Lösungsvarianten ausgewählt. Diese Lösungen werden in den Grafiken durch Boxen gekennzeichnet. Dabei repräsentiert V1 die maximale Lösung, V2 die mittlere Lösung und V3 die minimale Lösung der Pareto-Front.

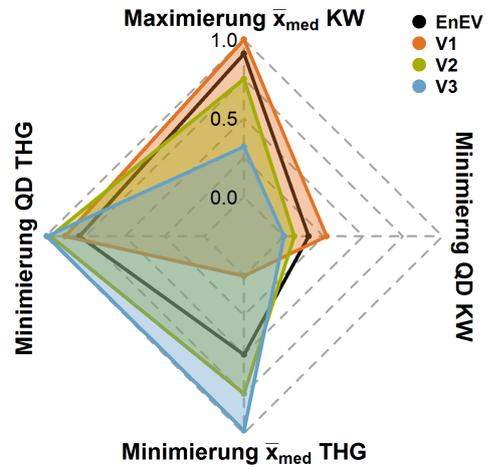
Diese Lösungen werden in einem Netzdiagramm mit den Ergebnissen nach EnEV verglichen. Die Eckpunkte des Netzdiagramms bilden die Zielgrößen der robusten Optimierung. Die Skalierung der Netzdiagramme geschieht über die Ergebnisse aus allen drei Perioden der robusten Optimierung. Dabei repräsentiert der Wert eins das beste und der Wert null das schlechteste Ergebnis aus der robusten Optimierung des jeweiligen Kriteriums. Für eine bessere Darstellbarkeit werden für die Skalierung die Resultate nach EnEV nicht berücksichtigt.

Eine exemplarische Analyse der Pareto-Fronten über die drei Perioden in Abbildung 18.7 zeigt, dass die klimatischen Veränderungen auf den Median der Zielgrößen einen unterschiedlichen Einfluss aufweisen. Betrachtet man die Entwicklung des Kapitalwerts auf der x-Achse, so ist eine deutliche Reduzierung erkennbar. Der maximale Kapitalwert in Periode 1 liegt bei ca. 16.300,00 EUR und in Periode 3 bei ca. 8.600,00 EUR. Die Ergebnisse des Medians der Treibhausgas-Emissionen zeigen hingegen keine starken Veränderungen. Die Quantildifferenz der Treibhausgas-Emissionen nimmt über die drei Perioden kontinuierlich zu. Daraus lässt sich ableiten, dass die Unsicherheit der Lösungen ansteigt. Dies kann durch den steigenden Anteil des Kühlbedarfs erklärt werden, welcher im Szenario „Moderat“ durch die ineffiziente Kühlung einen größeren Einfluss auf die Emissionen erhält.

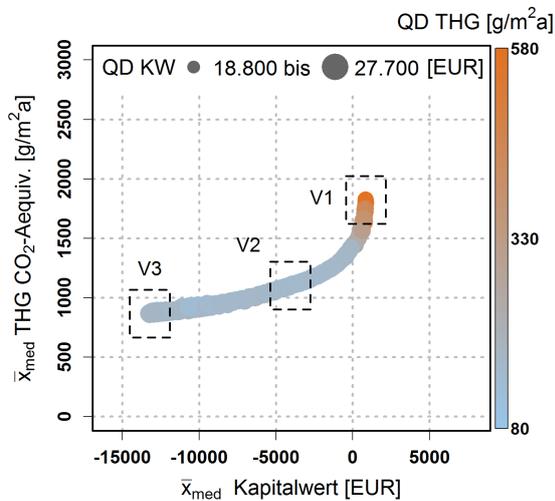
Der direkte Vergleich der robusten Optimierung mit einer Sanierung nach EnEV ist in den Netzdiagrammen abgebildet. Die Ergebnisse nach EnEV werden durch die schwarze Linie dargestellt. Als Vergleich werden die Lösungsvarianten V1, V2 und V3 aus der Pareto-Front herangezogen. Das Netzdiagramm ermöglicht einen einfachen Vergleich der vier Kriterien aus der robusten Optimierung. Daraus kann ein Planungsteam die Unterschiede der einzelnen Lösungsvarianten schnell erkennen und unterschiedliche Präferenzen von Stakeholdern diskutieren. Dies ist ein wesentlicher Vorteil der entwickelten Methode, da diese mehrere optimale Lösungen in Abhängigkeit des jeweiligen Zielkriteriums anbietet. Die exemplarische Auswertung der Ergebnisse aus Periode 1 in Grafik 18.7b zeigt drei unterschiedliche Lösungsvarianten. Dabei kann diskutiert werden, ob eine Lösung mit geringen und robusten Treibhausgas-Emissionen (V3) präferiert wird, oder die Maximierung des Kapitalwertes (V1) im Vordergrund steht. Die Lösungsvariante V2 bildet dabei einen Kompromiss aus V1 und V3. Bei einer Sanierung nach aktuellem Stand der Technik, welche sich rein an den gesetzlichen Vorgaben orientiert, ist solch eine Variation von optimalen Lösungen nicht möglich.



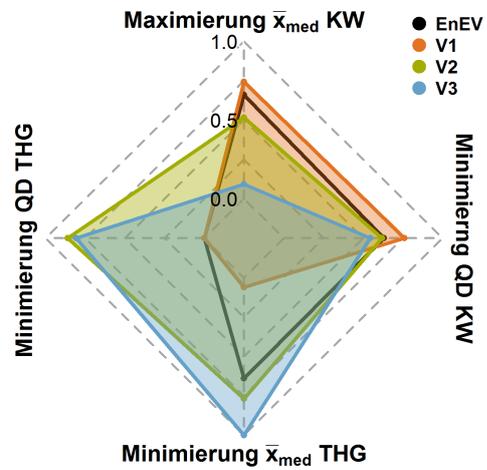
(a) Resultate der robusten Optimierung von Kapitalwert und Treibhausgas-Emissionen für das Szenario „Ambitioniert“ in Periode 1



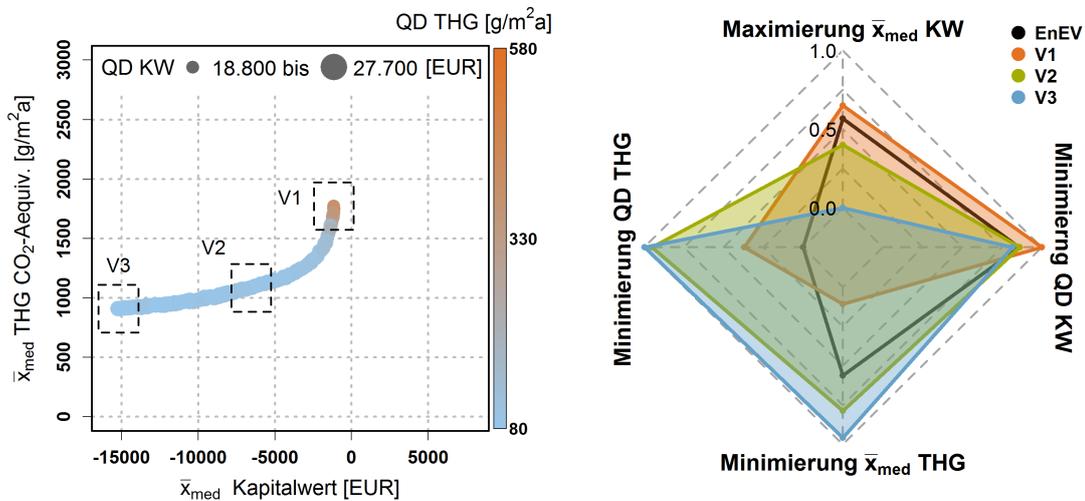
(b) Resultate aus V1, V2 und V3 im Vergleich mit den Ergebnissen nach EnEV für das Szenario „Ambitioniert“ in Periode 1



(c) Resultate der robusten Optimierung von Kapitalwert und Treibhausgas-Emissionen für das Szenario „Ambitioniert“ in Periode 2



(d) Resultate aus V1, V2 und V3 im Vergleich mit den Ergebnissen nach EnEV für das Szenario „Ambitioniert“ in Periode 2



(e) Ergebnisse der robusten Optimierung von Kapitalwert und Treibhausgas-Emissionen für das Szenario „Ambitioniert“ in Periode 3

(f) Ergebnisse aus V1, V2 und V3 im Vergleich mit den Ergebnissen nach EnEV für das Szenario „Ambitioniert“ in Periode 3

Abbildung 18.8: Resultate der robusten Optimierung von Treibhausgas-Emissionen und des Kapitalwerts für das Szenario „Ambitioniert“

Abbildung 18.8 zeigt die Ergebnisse der robusten Optimierung für das TGA-Szenario „Ambitioniert“. Bei einer exemplarischen Analyse der Pareto-Fronten wird wie in Abbildung 18.7 deutlich, dass die klimatischen Veränderungen auf die Resultate des Kapitalwertes einen stärkeren Einfluss ausüben als auf die Treibhausgas-Emissionen. Die Ergebnisse des Medians für den Kapitalwert weisen im Gegensatz zu den Treibhausgas-Emissionen eine deutliche Reduzierung über die drei Perioden auf. Der Vergleich zwischen den TGA-Szenarien macht auch deutlich, dass der Kapitalwert im Szenario „Ambitioniert“ häufiger einen negativen Median aufweist. Daraus lässt sich schließen, dass die Ergebnisse im Szenario „Ambitioniert“ unwirtschaftlicher sind als im Szenario „Moderat“.

Die Auswertung der Ergebnisse in den Netzdiagrammen zeigt ähnliche Tendenzen wie das Szenario „Moderat“. Ein exemplarischer Vergleich der Ergebnisse des Netzdiagramms aus Periode 1 in Grafik 18.8a mit den Resultaten aus dem Szenario „Moderat“ zeigt nur geringe Unterschiede. Das Resultat der Lösungsvariante V1 im Szenario „Ambitioniert“ zeigt bei der Minimierung der Quantildifferenz für die Treibhausgas-Emissionen ein deutlich besseres Verhalten als die Ergebnisse im Szenario „Moderat“. Dies ist durch die effiziente Kühlung im Szenario „Ambitioniert“ zu erklären, welche die zusätzlichen Emissionen durch den Kühlbedarf in Periode 1 fast vollständig kompensiert.

In den Tabellen 18.11 und 18.12 sind die detaillierten Ergebnisse der robusten Optimierung aus den Netzdiagrammen für beide TGA-Szenarien zusammengefasst. Diese Darstellung der Resultate macht den Vorteil der entwickelten Methode noch einmal deutlich. So kann zwischen unterschiedlichen Lösungsvarianten, abhängig von den jeweiligen Präferenzen, ausgewählt werden. Die Resultate aus Periode 1 im Szenario „Moderat“ bieten z.B. die Möglichkeit, aus einer Variante mit dem maximalen Kapitalwert (V1) oder einer Variante mit minimalen Treibhausgas-Emissionen (V3) auszuwählen. Dabei können auch die Auswirkungen auf die anderen Zielgrößen berücksichtigt werden. So sind die Emissionen in Varianten V1 mehr als doppelt so hoch als in V3. Der Median des Kapitalwerts beträgt in V3 aber nur ca. 20% von Kapitalwert aus V1. Dieser Vergleich, mit jeweils optimalen Lösungen für das jeweilige Fallbeispiel, ist mit einem herkömmlichen Planungsansatz nicht möglich.

Tabelle 18.11: Ergebnisse der Zielgrößen Kapitalwert und Treibhausgas-Emissionen für das TGA-Szenario „Moderat“

	Median [EUR]	Quantildifferenz [EUR]	Median [g/m ² a]	Quantildifferenz [g/m ² a]
EnEV P1	14.678,00	26.364,00	1.557	867
RobOpt P1 V1	16.310,00	25.164,00	2.429	1.156
RobOpt P1 V2	12.940,00	26.308,00	1.421	167
RobOpt P1 V3	2.964,00	27.171,00	1.076	138
EnEV P2	9.101,00	22.056,00	1.632	3.087
RobOpt P2 V1	10.716,00	20.778,00	2.307	2.255
RobOpt P2 V2	6.443,00	21.744,00	1.315	536
RobOpt P2 V3	-3.083,00	22.450,00	1.035	482
EnEV P3	6.870,00	19.964,00	2.206	3.523
RobOpt P3 V1	8.676,00	18.595,00	2.329	1.715
RobOpt P3 V2	4.488,00	19.797,00	1.322	677
RobOpt P3 V3	-5.006,00	20.407,00	1.070	628

Tabelle 18.12: Ergebnisse der Zielgrößen Kapitalwert und Treibhausgas-Emissionen für das TGA-Szenario „Ambitioniert“

	Median [EUR]	Quantildifferenz [EUR]	Median [g/m ² a]	Quantildifferenz [g/m ² a]
EnEV P1	4.439,00	26.391,00	1.557	867
RobOpt P1 V1	6.368,00	27.917,00	1.885	143
RobOpt P1 V2	981,00	27.186,00	1.123	98
RobOpt P1 V3	-8.315,00	27.783,00	885	86
EnEV P2	-978,00	22.119,00	1.632	3.087
RobOpt P2 V1	859,00	20.962,00	1.823	578
RobOpt P2 V2	-4.070,00	22.243,00	1.102	152
RobOpt P2 V3	-13.218,00	22.899,00	866	178
EnEV P3	-2.924,00	20.085,00	2.206	3.523
RobOpt P3 V1	-1.160,00	18.804,00	1.773	394
RobOpt P3 V2	-6.545,00	20.061,00	1.084	107
RobOpt P3 V3	-15.251,00	20.476,00	909	94

Die resultierenden Gebäudeparameter aus der robusten Optimierung und einer Sanierung nach EnEV sind in der Tabelle 18.13 für beide TGA-Szenarien abgebildet. Die Ergebnisse der robusten Optimierung heben die Vorteile der entwickelten Methode hervor. Die einzelnen Ergebnisse oder Maßnahmenkombinationen unterscheiden sich zum Teil sehr deutlich von den Gebäudeparametern einer Sanierung nach EnEV. Die Ursache dafür ist die Integration von Unsicherheiten bezüglich klimatischen Veränderungen und Energiepreisentwicklungen sowie die Berücksichtigung von mehreren Zielgrößen in der robusten Optimierung. Die robuste Optimierung liefert, im Vergleich zu einer Sanierung nach EnEV auf Basis eines Bauteilnachweises, in Abhängigkeit der Zielgrößen mehrere optimale Lösungen aus denen das Planungsteam auswählen kann.

Des Weiteren ist eine Ermittlung der Lösungen aus der robusten Optimierung auch mit der Planung auf Basis einer Variantenstudie aufgrund des hohen Arbeitsaufwands nicht durchführbar. Die Analysen einer Variantenstudie geschehen zwar in der Regel ebenfalls modellbasiert, jedoch wird die „Optimierung“ der Maßnahmen manuell durchgeführt. Die Ergebnisse der robusten Optimierung basieren im vorgestellten Fallbeispiel auf ca. 40.000 Simulationen. Dies bedeutet, ca. 40.000 Varianten an Gebäudeparameterkombinationen. Diese Anzahl an Varianten ist einem herkömmlichen Planungs- und Berechnungsansatz nicht durchführbar.

Ein Vorgehen mit einem szenariobasierten Ansatz, mit z.B. Min- Max- und Mittelwerten der Sanierungsmaßnahmen führt ebenfalls nicht zum Ziel. Dies ist deutlich an den Ergebnissen in Tabelle 18.13 zu erkennen, da in keiner Lösungskombination (V1, V2 oder V3) alle Kennwerte der Maßnahmen die Grenzen (Max-Opt oder Min-Opt) oder die Mittelwerte des Optimierungsbereiches wiedergeben. Diese Ergebnisse entstehen durch die Berücksichtigung mehrerer Zielgrößen in der robusten Optimierung, welche die Sanierungsmaßnahmen unterschiedlich beeinflussen. So wird z.B. in V3 der U-Wert von Außenwand und Dach für eine Reduktion des Heizwärmebedarfs minimiert und der g-Wert der Verglasung für ein Reduktion des Kühlbedarfes ebenfalls minimiert.

Tabelle 18.13: Vergleich der Gebäudeparameter für das TGA-Szenario „Moderat“ und „Ambitioniert“

	U-Wand [W/m ² K]	U-Dach [W/m ² K]	U-Boden [W/m ² K]	U-Fenster [W/m ² K]	g-Wert [-]	Fc-Wert [-]
TGA-Szenario „Moderat“						
RobOpt P1 V1	0,44	0,43	0,87	1,30	0,75	1,00
RobOpt P1 V2	0,21	0,17	0,36	1,30	0,34	0,25
RobOpt P1 V3	0,10	0,10	0,43	0,60	0,30	0,25
RobOpt P2 V1	0,45	0,42	0,90	1,30	0,75	0,57
RobOpt P2 V2	0,20	0,14	1,10	1,30	0,30	0,25
RobOpt P2 V3	0,10	0,10	1,10	0,60	0,30	0,25
RobOpt P3 V1	0,45	0,43	0,98	1,30	0,57	0,25
RobOpt P3 V2	0,18	0,15	1,10	1,30	0,30	0,25
RobOpt P3 V3	0,10	0,10	1,10	0,60	0,30	0,25
TGA-Szenario „Ambitioniert“						
RobOpt P1 V1	0,43	0,43	0,69	1,30	0,75	1,00
RobOpt P1 V2	0,18	0,15	0,23	0,93	0,60	0,40
RobOpt P1 V3	0,10	0,10	0,13	0,60	0,52	0,25
RobOpt P2 V1	0,45	0,44	0,80	1,30	0,75	1,00
RobOpt P2 V2	0,17	0,15	0,38	1,30	0,30	0,25
RobOpt P2 V3	0,10	0,10	0,34	0,60	0,30	0,25
RobOpt P3 V1	0,44	0,45	0,80	1,30	0,75	0,25
RobOpt P3 V2	0,16	0,16	0,78	1,11	0,30	0,25
RobOpt P3 V3	0,10	0,10	1,00	0,60	0,30	0,25
EnEV	0,24	0,24	0,30	1,30	0,6	0,25
Max-Opt	1,40	1,10	1,10	3,50	0,75	1,00
Min-Opt	0,10	0,10	0,10	0,60	0,30	0,25

Betrachtet man die Ergebnisse von V1 im Szenario „Moderat“, liegen diese weder an den Grenzen des Optimierungsbereichs noch in der Nähe der Gebäudeparameter nach EnEV. Bei einer herkömmlichen Zielsetzung wie der Minimierung der Treibhausgas-Emissionen (V3), nimmt der U-Wert von Außenwand und Dach den erwarteten Grenzwert des Optimierungsbereiches an. Der resultierende U-Wert der Bodenplatte entspricht jedoch nicht den Erwartungen einer energetischen Sanierung mit dem Ziel der Reduktion des Heizwärmebedarfs. Die Ursache für dieses Ergebnis ist der Einfluss des Klimawandels, wodurch der Anteil des Kühlbedarfs am gesamten Energiebedarf ansteigt. Deshalb wird die Kühlung des Gebäudes durch die Bodenplatte mit einer geringeren Dämmung in der robusten Optimierung fokussiert (siehe Abschnitt 18.2). Diese Entwicklung tritt im Szenario „Ambitioniert“ nicht so stark zum Vorschein. Dies kann durch den Einsatz der effizienten Kühlung begründet werden.

19 | Zusammenfassung

Ziel von Teil VI ist ein Vergleich der im Rahmen dieser Arbeit entwickelten Methode zur robusten Optimierung für die energetische Sanierung von Gebäuden mit einem Planungsansatz nach aktuellem Stand der Technik. Den aktuellen Stand der Technik stellt eine Sanierung nach Energieeinsparverordnung aus dem Jahr 2014 dar. Der Fokus der Analysen liegt nicht auf der Entwicklung eines optimalen Sanierungskonzepts, sondern vielmehr auf einem Vergleich der beiden Methoden.

Die beiden Methoden werden anhand von drei Anwendungsbeispielen bewertet. Dabei gilt es in einem ersten Schritt die Treibhausgas-Emissionen unter Berücksichtigung der klimatischen Veränderungen zu minimieren. In einem zweiten Schritt wird der Kapitalwert für die energetische Sanierung, unter Einbeziehung schwankender Energiekosten und dem Klimawandel, maximiert. In einer dritten Untersuchung werden Kapitalwert und Treibhausgas-Emissionen unter Berücksichtigung der genannten unsicheren Randbedingungen gemeinsam optimiert. Diese drei Fallbeispiele stellen jeweils die Optimierung mit einer unterschiedlichen Anzahl von Zielgrößen bzw. Zielfunktionen dar und zeigen so die unterschiedlichen Anwendungsmöglichkeiten der entwickelten Methode auf.

Bei der Minimierung von Treibhausgas-Emissionen zeigt der Vergleich, dass durch die robuste Optimierung nicht nur die Emissionen reduziert, sondern auch die Unsicherheiten der Ergebnisse, im Vergleich zu einer Sanierung nach EnEV, minimiert werden. Des Weiteren können durch den Einsatz der robusten Optimierung und ihrer Berücksichtigung von unsicheren Randbedingungen auch alternative Lösungen oder Lösungskombinationen für die Sanierungsmaßnahmen erarbeitet werden. Die Integration der klimatischen Veränderungen in den Optimierungsprozess bewirkt bei einzelnen Maßnahmen gegensätzliche Ergebnisse. In Periode drei ist zu beobachten, dass der Wärmedurchgangskoeffizient für Außenwand und Dach minimiert wird. Der Wärmedurchgangskoeffizient für die Bodenplatte wird hingegen maximiert. Dies liegt an einem Anstieg des Kühlbedarfs, verursacht durch den Klimawandel. Im konkreten Fallbeispiel grenzt die Bodenplatte an das Erdreich und schafft so eine Kühlung des Gebäudes. Durch die klimatische Erwärmung überwiegt der Vorteil der Gebäudekühlung gegenüber dem Nachteil eines erhöhten Heizwärmebedarfs. Deshalb wird der Wärmedurchgangskoeffizient der Bodenplatte nicht minimiert, sondern maximiert.

Bei der Maximierung des Kapitalwerts wird für die robuste Optimierung ein a posteriori Ansatz verwendet. Dabei werden zwei Zielfunktionen in Form der Robustheitskriterien Median und Quantildifferenz für die Optimierung gebildet. Die Optimierung der beiden Zielfunktionen liefert bei diesem Ansatz mehrere Lösungen für das Optimierungsproblem. Die Auswertung der Ergebnisse geschieht auf Basis „nicht-dominiertes“ Lösungen. Die Visualisierung der Resultate wird mit Hilfe von Pareto-Fronten durchgeführt. Anhand dieser Pareto-Fronten ist es nun möglich, ein oder mehrere optimale Lösungsvarianten, je nach Priorisierung der Zielgrößen, auszuwählen. Diese Auswahlmöglichkeit zwischen mehreren optimalen Lösungen spiegelt einen weiteren Vorteil der entwickelten Methode wider. In einer herkömmlichen Planung werden meist ein bis zwei Szenarien berechnet, welche auf Basis von Erfahrungswerten oder Normen erstellt werden und in der Regel keine optimale Lösung darstellen. Im vorgestellten Fallbeispiel kann durch die robuste Optimierung der Kriterien Median und Quantildifferenz eine Lösung zwischen maximaler Robustheit und maximalen Wert der Zielgröße Kapitalwert ausgewählt werden.

Der dritte Anwendungsfall repräsentiert eine Optimierung von vier Zielgrößen. Diese vier Größen setzen sich aus jeweils zwei Robustheitskriterien, Median und Quantildifferenz, für den Kapitalwert und die Treibhausgas-Emissionen zusammen. Durch die Integration der Robustheit in die Darstellung der Pareto-Front können anhand dieser Grafik bereits Lösungen oder Lösungsbereiche unter Berücksichtigung der vier Zielgrößen ermittelt werden. Mit Hilfe des Netzdiagramms ist eine weitere, detaillierte Analyse der Lösungsvarianten möglich. Das Netzdiagramm bietet auch die Möglichkeit, die Ergebnisse aus einer Optimierung mit mehr als vier Zielgrößen auszuwerten. Die Ergebnisse der Untersuchung machen deutlich, dass die entwickelte Methode auch für eine robuste Optimierung von mehreren Zielgrößen geeignet ist. Im Vergleich zu einer Sanierung nach aktuellem Stand der Technik zeigen die Resultate der Netzdiagramme anschaulich die Vorteile der robusten Optimierung. Während bei einer herkömmlichen Sanierung in der Regel nur ein Ziel verfolgt wird, z.B. die Reduktion von Treibhausgas-Emissionen, können durch die entwickelte Methode gleichzeitig nicht nur mehrere Zielgrößen optimiert, sondern auch deren Robustheit gegenüber unsicheren Randbedingungen erhöht werden.

Zusammenfassend werden in Teil VI drei unterschiedliche Anwendungsformen der entwickelten Methode - robuste Optimierung einer Zielfunktion, robuste Optimierung mit zwei Zielfunktionen und einer Kombination aus beiden Ansätzen mit der Optimierung von vier Zielgrößen - vorgestellt. Auf Basis dieser drei Analysen können die Vorteile der Methode umfassend dargestellt werden. Die beiden wesentlichsten Vorteile der Methode lassen sich wie folgt zusammenfassen:

- i) Gezielte Optimierung von Wert und Robustheit ein oder mehrerer Zielgrößen unter Berücksichtigung von unsicheren Randbedingungen
- ii) Visualisierung der Optimierungsergebnisse mit Hilfe einer Pareto-Front unter Berücksichtigung der Robustheit und dem Einsatz von Netzdiagrammen

Teil VII

Schlussfolgerung und Ausblick

20 | Schlussfolgerung

Die energetische Sanierung des Gebäudebestandes spielt für den Klimaschutz eine wichtige Rolle. Die Planung einer energetischen Sanierung ist teilweise sehr komplex und bringt aktuelle Planungsmethoden an ihre Grenzen. Eine belastbare Planung setzt die Integration von Unsicherheiten und das Auffinden von optimalen Lösungen unter Berücksichtigung unterschiedlichster Sanierungsziele voraus. Diese Aufgabenstellung ist mit bisherigen Planungsmethoden in der Regel nicht zu erfüllen. In der vorliegenden Arbeit wird deshalb eine Methode zur robusten Optimierung für die energetische Sanierung von Gebäuden unter Berücksichtigung unsicherer Randbedingungen entwickelt.

Ein zentraler Punkt der robusten Optimierung einer energetischen Gebäudesanierung ist die Auswahl eines geeigneten Modelltyps für die Darstellung des Gebäudes. Das Gebäudemodell hat einen wesentlichen Anteil am Rechenaufwand für die robuste Optimierung und beeinflusst deshalb auch die Anwendbarkeit der Methode. Das Ziel bei der Auswahl eines geeigneten Modelltyps ist eine optimale Kombination aus Detaillierungsgrad der Ergebnisse, Modellgüte und Rechenaufwand. In der vorliegenden Arbeit wird deshalb in einem ersten Schritt ein detailliertes Gebäudemodell auf Basis eines White-Box-Modells entwickelt. Die robuste Optimierung wird mit einem Ersatzmodell des detaillierten Gebäudemodells durchgeführt. Das Ersatzmodell wird mit Hilfe eines Black-Box-Modells erstellt. Diese Art von Modellen weist einen geringen Rechenaufwand auf und eignet sich deshalb für den Einsatz bei einer robusten Optimierung. Mit Hilfe des Ersatzmodells dauert eine Durchführung der robusten Optimierung für das in dieser Arbeit gewählte Fallbeispiel ca. drei Minuten. Bei der Verwendung eines detaillierten Gebäudemodells für die Optimierung, was aktuell den häufigsten Anwendungsfall repräsentiert, würde eine vergleichbare robuste Optimierung ca. 27 Tage dauern.

Für die Bestimmung eines geeigneten Ersatzmodells werden zwei Techniken, Neuronale Netze und Support Vector Regression, miteinander verglichen. Beide Methoden weisen eine prinzipielle Eignung für die Verwendung als Ersatzmodell auf. Für das konkrete Fallbeispiel zeigte sich, dass die Anwendung eines statischen Neuronalen Netzes, ein sogenanntes Multi Layer Perceptron (MLP), einen geringeren Prognosefehler für die analysierten Zielgrößen aufweist, als die anderen untersuchten Techniken. Dabei gilt es zu beachten, dass die Auswahl des Optimierungsverfahrens für die Parameteroptimierung des Neuronalen Netzes einen wichtigen Faktor für die Modellgüte darstellt. Für das präsentierte Fallbeispiel erzielt ein Quasi-Newton-Verfahren bessere Ergebnisse als ein Gradienten-Verfahren. Die Erstellung der Ersatzmodelle benötigt Daten aus dem detaillierten Gebäudemodell.

Diese Daten werden mit Hilfe einer Monte-Carlo-Simulation erzeugt. Die Qualität der Daten bestimmt maßgeblich die Modellgüte des Ersatzmodells. Für die Erzeugung werden sogenannte Sample-Techniken herangezogen. Bei einem Vergleich von drei Sample-Techniken zeigt die Methode der „Sobol-Sequenzen“ die besten Ergebnisse.

Eine Bewertung der entwickelten Methode wird anhand von drei Aufgabenstellungen durchgeführt. Diese Anwendungsfälle spiegeln die vielseitigen Einsatzmöglichkeiten der Methode wider. Als unsichere Randbedingungen werden zum einen die klimatischen Veränderungen und zum anderen unterschiedliche Kostenentwicklungen von Energieträgern herangezogen. Dabei wird anhand der Zielgröße Treibhausgas-Emissionen gezeigt, welche Ergebnisse die robuste Optimierung mit einer Zielfunktion ermöglicht. Die Maximierung des Kapitalwertes dient der Darstellung einer robusten Optimierung mit zwei Zielfunktionen. Die Visualisierung der Ergebnisse durch eine Pareto-Front ermöglicht eine Auswahl von ein oder mehreren Lösungsvarianten in Abhängigkeit der präferierten Zielfunktion. Eine robuste Optimierung der Treibhausgas-Emissionen und des Kapitalwertes repräsentiert eine Anwendung mit mehr als zwei Zielfunktionen. Ein Vergleich mit einem Planungsansatz nach aktuellem Stand der Technik wird mit Hilfe der drei beschriebenen Aufgabenstellungen durchgeführt. Dieser herkömmliche Planungsansatz wird durch eine Sanierung nach Energieeinsparverordnung aus dem Jahr 2014 repräsentiert. Ein Vergleich der unterschiedlichen Anwendungsfälle zeigt, dass durch die entwickelte Methode sowohl der Wert von ein oder mehreren Zielgrößen optimiert, als auch die Robustheit gegenüber unsicheren Randbedingungen erhöht werden kann. Ein weiterer Vorteil der entwickelten Methode gegenüber einer Sanierung nach EnEV ist die Auswahlmöglichkeit zwischen mehreren Pareto-optimalen Lösungen. Durch die hier vorgestellte Methode können Sanierungskonzepte erstellt werden, welche nicht nur optimale Ergebnisse unterschiedlichster Sanierungsziele aufweisen, sondern auch robuster gegenüber unsicheren Randbedingungen sind.

Diese Arbeit liefert außerdem einen wesentlichen Beitrag zur Erforschung der Anwendung von Modellen aus dem Feld des „Statistischen Lernens“ im Bereich der Gebäudesimulation. Dabei wird gezeigt, dass Neuronale Netze und Support Vector Regression in der Gebäudesimulation angewendet werden können. Des Weiteren wird dargestellt, dass entgegen gängiger Vorstellungen Black-Box-Modelle, in Form von Ersatzmodellen, durchaus für die mathematische Optimierung im Bereich der Gebäudesimulation verwendet werden können. Die Durchführung einer robusten Optimierung unter unsicheren Randbedingungen stellt für den Anwendungsfall der energetischen Gebäudesanierung im Kontext Klimawandel ebenfalls eine Neuerung dar. Die vorgestellte Methode zeigt eine erfolgreiche Anwendung der mathematischen Optimierung unter Berücksichtigung klimatischer Unsicherheiten. Eine robuste Optimierung über einen Zeitraum von 30 Jahren, unter Einbeziehung der klimatischen Entwicklung, wurde in dieser Form bisher noch nicht durchgeführt. Dabei ermöglicht die Methode eine Unterstützung von strategischen Entscheidungen zum Klimaschutz unter Berücksichtigung der klimatischen Unsicherheiten. Aus Sicht der Praxis bilden die im Rahmen dieser Arbeit entwickelten Modelle, Algorithmen und Programmabläufe eine Grundlage für die Entwicklung eines Planungstools, welches eine breitere Anwendung dieser Methode in der Baupraxis ermöglichen kann.

21 | Ausblick

In der vorliegenden Arbeit wird eine Methode zur robusten Optimierung der energetischen Sanierung von Gebäuden unter unsicheren Randbedingungen dargestellt. Eine erste Anwendung für die Sanierung eines Wohngebäudes wird diskutiert. Die folgenden Absätze beschäftigen sich mit möglichen Erweiterungen sowie künftigen Anwendungen der Methode.

Eine erste Weiterentwicklung der Methode könnte eine Anwendung auf andere Gebäudetypen, wie z.B. Mehrfamilienhäuser oder Nichtwohngebäude sein. Dies ist aufgrund des Aufbaus der Methode möglich, jedoch müssen die bestehenden Modelle und Algorithmen angepasst werden. Im Bereich der Ersatzmodelle ist zu prüfen, ob die verwendeten Techniken, Neuronale Netze und Support Vector Regression, auch bei anderen Gebäudetypen eine ähnlich hohe Modellgüte aufweisen. Des Weiteren ist zu überlegen, ob die Anzahl der Eingangsgrößen erweitert wird. Im Bezug auf eine detailliertere Analyse von klimatischen Veränderungen wäre z.B. eine Eingangsgröße für die variable Fensterlüftung im Ersatzmodell sinnvoll. Weitere Eingangsgrößen für das Ersatzmodell könnten z.B. durch eine Sensitivitätsanalyse mit dem detaillierten Gebäudemodell ermittelt werden.

Eine Ergänzung von Eingangsgrößen würde auch weitere Anwendungen der Methode für z.B. die Planung von Neubauten ermöglichen. Als Beispiel könnten Kennwerte unterschiedlicher Gebäudetechnikvarianten in das Ersatzmodell integriert und dadurch ebenfalls in der robusten Optimierung berücksichtigt werden. Prinzipiell ist auch eine Integration von geometrischen Gebäudedaten in das Ersatzmodell möglich. Dadurch kann auch in den frühen Planungsphasen eine robuste Optimierung für die Erstellung des Gebäudeentwurfs zum Einsatz kommen.

Eine Berücksichtigung von weiteren unsicheren Randbedingungen, wie z.B. den Nutzer und seine Interaktionen mit dem Gebäude, ist ebenfalls möglich. Dies kann durch den Einsatz von stochastischen Modellen, z.B. für die Anwesenheit, Benutzung von Haushaltsgeräten oder Anpassungen der Komfortbedingungen, als Eingangsgröße im Ersatzmodell realisiert werden. Des Weiteren kann mit der entwickelten Methode nicht nur die Unsicherheit von Randbedingungen, sondern auch eine Unsicherheit der Optimierungsparameter, wie z.B. dem Wärmedurchgangskoeffizienten der Außenwand, berücksichtigt werden. Dazu wird lediglich eine Wahrscheinlichkeitsverteilung für die Unsicherheit des jeweiligen Parameters definiert und in derselben Weise wie die unsicheren Randbedingungen in den Optimierungsprozess integriert.

Ein Ausbau der Methode für die robuste Optimierung einer Lebenszyklusanalyse der Sanierungsmaßnahmen ist ebenfalls möglich. Im detaillierten Gebäudemodell werden die Materialien des Gebäudes bereits zum größten Teil definiert und ermöglichen so eine effiziente Abschätzung der Massen. Für eine Durchführung der Lebenszyklusanalyse werden jedoch zusätzliche Daten über die Umweltauswirkungen der verwendeten Materialien und Gebäudetechnikkomponenten benötigt. Der Einfluss von Sanierungsmaßnahmen und die daraus resultierenden Umweltauswirkungen könnten äquivalent wie die Funktionen der „energiebedingten Mehrkosten“ in die Methode integriert werden.

Eine breite Anwendung der vorgestellten Methode wäre durch die Integration in eine bestehende Software zur Gebäudesimulation möglich. In Bereichen, wie z.B. der Strömungssimulation, existieren bereits kommerzielle Softwarelösungen, in denen automatisch ein Ersatzmodell des detaillierten Simulationsmodells erstellt und eine robuste Optimierung durchgeführt wird. Dies könnte auch im Bereich der Gebäudesimulation umgesetzt werden und die Anwendung einer robusten Optimierung im Planungsprozess erleichtern.

Abkürzungsverzeichnis

CV	Coefficient of Variation
EFH	Einfamilienhaus
EnEV	Energieeinsparverordnung
GA	Genetischer Algorithmus
g-Wert	Gesamtenergiedurchlassgrad
IPCC	Intergovernmental Panel on Climate Change
IWU	Institut Wohnen und Umwelt
JAZ	Jahresarbeitszahl
LHS	Latin Hypercube Sampling
MCS	Monte-Carlo-Simulation
MLP	Multi Layer Perceptron
NN	Neuronales Netz
PSO	Particle Swarm Optimization
Q_c	Kühlbedarf
Q_H	Heizenergiebedarf
Q_h	Heizwärmebedarf
Q_{Hver}	Heizenergieverbrauch
R²	Bestimmtheitsmaß
REMO	REgional MOdell
RMSE	Root Mean Squared Error
SVM	Support Vector Machine
SVR	Support Vector Regression
TGA	Technische Gebäudeausrüstung
UA	Unsicherheitsanalyse
UGS	Übertemperaturgradstunden
U-Wert	Wärmedurchgangskoeffizient

Abbildungsverzeichnis

1.1	Entwicklung von Energiebedarf und Treibhausgas-Emissionen eines Hochschulgebäudes unter Einfluss des Klimawandels	6
4.1	Gitterpunkte des Regionalen Klimamodells für die Region München	23
4.2	Änderungen der Jahresmitteltemperaturen in Abhängigkeit des Klimaszenarios der Region München	23
5.1	Ansichten des Beispielgebäudes	26
6.1	Funktionen für die energiebedingten Mehrkosten der unterschiedlichen Sanierungsmaßnahmen der Gebäudehülle	33
6.2	Prognosen für die jährlichen Preisentwicklungen von Heizöl, Pellets und Haushaltsstrom	35
7.1	Differenzierung unterschiedlicher Modelltypen	40
8.1	Schematischer Ablauf der Modellentwicklung	50
8.2	Simulationsumgebung von IDA Indoor Climate and Energy	51
8.3	Schematischer Ablauf der Datenerzeugung mit einer Monte-Carlo-Simulation	52
8.4	Vergleich von unterschiedlichen Sample-Techniken anhand einer Normalverteilung	53
8.5	Schematischer Ablauf der Systemidentifikation mit einem Neuronalen Netz	55
8.6	Übersicht der Modellarten im Bereich der Neuronalen Netze	56
8.7	Darstellung eines Neurons und mögliche Transferfunktionen $f(n)$	58
8.8	Schema eines MLP mit einer Eingangsschicht, einer verdeckten Schicht und einer Ausgangsschicht	58
8.9	Detailldarstellung eines MLP mit einer Eingangsschicht, einer verdeckten Schicht und einer Ausgangsschicht	59
8.10	Schematischer Ablauf der Systemidentifikation einer SVR	62
8.11	Grafische Darstellung der Verlustfunktion einer ε -SVR	64
9.1	Schematischer Ablauf des Versuchsaufbaus	69
9.2	Verteilung der Zielgröße Heizwärmebedarf Q_h	71
9.3	Vergleich von Sample-Techniken auf Basis des Heizwärmebedarfs Q_h	71
9.4	Verteilung der Zielgröße Übertemperaturgradstunden UGS	72

9.5	Vergleich unterschiedlicher Sample-Techniken auf Basis der Zielgröße Über- temperaturgradstunden UGS	73
9.6	Ein- und Ausgangsgrößen des MLP	74
9.7	Strukturoptimierung der beiden Netze NN-I-Qh und NN-I-UGS abhängig von der Anzahl Trainingsdaten	75
9.8	Strukturoptimierung der beiden Netze NN-II-Qh und NN-II-UGS abhängig von der Anzahl Trainingsdaten	76
9.9	Strukturoptimierung zweier ε -SVR's mit der Zielgröße Q_h abhängig von der Anzahl der Trainingsdaten	77
9.10	Strukturoptimierung zweier ε -SVR's mit der Zielgröße UGS abhängig von der Anzahl Trainingsdaten	78
9.11	Streudiagramme mit den Prognosen der linearen Regression, dem Neuronalen Netz NN-I sowie des detaillierten Gebäudemodells	82
9.12	Streudiagramme mit den Prognosen der ε -SVR, dem Neuronalen Netz NN-II sowie des detaillierten Gebäudemodells	83
11.1	Unterschied zwischen einem deterministischen und einem robusten Minimum.	90
12.1	Schema einer Unsicherheitsanalyse auf Basis einer Monte-Carlo-Simulation .	99
12.2	Verteilung der Außentemperatur	101
12.3	Ergebnisse des Kolmogorow-Smirnow-Tests der unterschiedlichen Perioden pro Jahresstunde	102
12.4	Schematischer Ablauf der Methode ΔT_a am Beispiel der Zielgröße Heizwär- mebedarf	104
12.5	Exemplarische Darstellung eines globalen, lokalen und robusten Minimums der Funktion $f(x)$	107
12.6	Exemplarische Kategorisierung unterschiedlicher Optimierungsprobleme und Lösungsmethoden	108
12.7	„Ackley“ Testfunktion mit zwei Variablen x und y	112
12.8	Ergebnisse des PSO Algorithmus nach unterschiedlicher Anzahl Iterationen . .	113
12.9	Exemplarische Darstellungen einer Pareto-Front	116
12.10	Schematische Darstellung einer Verteilung der Zielvariable vor (A) und nach (B) einer robusten Optimierung	118
12.11	Vergleich der Robustheitskriterien Median und Quantildifferenz mit dem Erwar- tungswert und einer Standardabweichung	119
12.12	Schematischer Ablauf der robusten Optimierung	122
13.1	Vergleich der Methode ΔT_a mit Simulationen von Wetterdaten aus dem regio- nalen Klimamodell	125
13.2	Strukturoptimierung der beiden Netze NN-Qh-C20 und NN-UGS-C20	127
13.3	Streudiagramme mit den Prognosen des Neuronalen Netzes und des detaillier- ten Gebäudemodells	128
13.4	Vergleich von Ergebnissen einer energetischen Sanierung nach EnEV und nach einer robusten Optimierung	129

13.5	Vergleich der Ergebnisse einer energetischen Sanierung nach EnEV und nach einer robusten Optimierung mit Straffunktion	131
13.6	Resultate der robusten Optimierung nach einem a posteriori Ansatz	133
13.7	Visualisierung der Unsicherheiten auf Basis einer Pareto-Front	134
13.8	Interpretation der Pareto-optimalen Lösungen durch Gruppierung und Darstellung im Netzdiagramm	135
15.1	Erstellung der Datengrundlage auf Basis des Ein- und Ausgangssignals des Gebäudemodells mit Hilfe einer Monte-Carlo-Simulation	144
15.2	Schematischer Ablauf der Methode ΔT_a zur Berücksichtigung klimatischer Unsicherheiten	145
15.3	Erstellung des Ersatzmodells auf Basis der Ein- und Ausgangssignale des detaillierten Gebäudemodells	146
15.4	Robuste Optimierung basierend auf einer Unsicherheitsanalyse und einer mathematischen Optimierung	146
15.5	Visualisierung der Ergebnisse durch eine Pareto-Front mit integrierten Unsicherheiten und einem Netzdiagramm	147
16.1	Ablauf der entwickelten Methode	150
18.1	Ein- und Ausgangsgrößen der verwendeten Neuronalen Netze	155
18.2	Strukturoptimierung der Ersatzmodelle für die beiden Zielgrößen Q_h und Q_c	158
18.3	Streudiagramme mit den Prognosen der Neuronalen Netze und den Ergebnissen des detaillierten Gebäudemodells für den Heiz- und Kühlbedarf	160
18.4	Vergleich von Treibhausgas-Emissionen nach einer robusten Optimierung und einer Sanierung nach EnEV	162
18.5	Ergebnisse des Kapitalwerts für das Szenario „Moderat“ in Periode 1	165
18.6	Ergebnisse des Kapitalwerts einer robusten Optimierung und nach EnEV	166
18.7	Resultate der robusten Optimierung von Treibhausgas-Emissionen und des Kapitalwerts für das Szenario „Moderat“	172
18.8	Resultate der robusten Optimierung von Treibhausgas-Emissionen und des Kapitalwerts für das Szenario „Ambitioniert“	175
A.1	Übersicht der Baualtersklassen des Gebäudetyps Einfamilienhaus im Quartier Neuaubing-Westkreuz	217
A.2	Blaue Markierung aller (403) Einfamilienhäuser im Schwarzplan des Quartiers Neuaubing-Westkreuz	218
A.3	Statistische Auswertung unterschiedlicher Gebäudeparameter des Einfamilienhausbestandes in Neuaubing-Westkreuz	220
A.4	Ansichten des Einfamilienhauses	221
A.5	Grundriss Erdgeschoss des Einfamilienhauses	222
A.6	Grundriss Obergeschoss des Einfamilienhauses	223
A.7	Gebäudeschnitt des Einfamilienhauses	224

Tabellenverzeichnis

4.1	Eckdaten des Regionalen Klimamodells REMO für die Klimaprojektionen im Auftrag des Umweltbundesamtes	22
5.1	Wärmedurchgangskoeffizienten Gebäudehülle	26
5.2	Ausgewählte Gebäudeparameter	27
5.3	Sanierungsmaßnahmen der Gebäudehülle	27
5.4	Kennwerte des Modells „EnEV“	28
5.5	Eckdaten der Gebäudetechnik	29
6.1	Kosten für die technische Gebäudeausrüstung	34
7.1	Vor- (+) und Nachteile (-) der verschiedenen Modellarten	42
7.2	Rechenaufwand für eine mathematischen Optimierung	44
9.1	Eingangsgrößen der Ersatzmodelle mit Wertebereich für die Erstellung und die Anwendung	70
9.2	Modellkonfigurationen der unterschiedlichen Multi Layer Perceptrons	74
11.1	Häufig angewandte Optimierungsverfahren im Bereich der Gebäudesimulation	94
13.1	Verteilungen des Parameters Delta für die Zielgröße Q_h	124
13.2	Vergleich der Methode ΔT_a mit Simulationen aus dem regionalen Klimamodell	125
13.3	Eingangsgrößen der Ersatzmodelle mit Wertebereich für die Erstellung und die Anwendung in Periode C20	126
17.1	Zusammenfassung der analysierten Sanierungsmaßnahmen	153
18.1	Zusammenfassung der Eingangsgrößen aller Ersatzmodelle	156
A.1	Aufbau Gebäudekomponenten	219

Literaturverzeichnis

- Ahmad, A. S., Hassan, M. Y., Abdullah, M. P., Rahman, H. A., Hussin, F., Abdullah, H., & Saidur, R. (2014). A review on applications of ANN and SVM for building electrical energy consumption forecasting. *Renewable and Sustainable Energy Reviews*, 33, 102–109.
- Anstett, M. & Kreider, J. F. (1993). Application of neural networking models to predict energy use. *ASHRAE Transactions*, 505–517.
- Asadi, E., Silva, M. G., Antunes, C. H., Dias, L., & Glicksman, L. (2014). Multi-objective optimization for building retrofit: A model using genetic algorithm and artificial neural network and an application. *Energy and Buildings*, 2014, 444–456.
- Attia, S., Hamdy, M., O'Brien, W., & Carlucci, S. (2013). Computational optimization zero energy building design: Interviews with twenty eight international experts. In E. Wurtz (Hrsg.), *Conference Proceedings Building Simulation 2013: 13th International Building Simulation Conference BS2013* (S. 3698–3705). National Solar Energy Institute INSE. 2013-08-25/2013-08-28. Chambéry, France.
- BayLfStad, F. (2011). *Bestand an Wohngebäuden und Wohnungen in Bayern*. Bayerisches Landesamt für Statistik und Datenverarbeitung, Statistischer Bericht F/1j 2010, München.
- Beyer, H.-G. & Sendhoff, B. (2007). Robust optimization – A comprehensive survey. *Computer Methods in Applied Mechanics and Engineering*, 196, 3190–3218.
- Bichiou, Y. & Krarti, M. (2011). Optimization of envelope and HVAC systems selection for residential buildings. *Energy and Buildings*, 43, 3373–3382.
- BMWi. (2010). *Energiekonzept: für eine umweltschonende, zuverlässige und bezahlbare Energieversorgung*. Bundesministerium für Wirtschaft und Energie (BMWi).
- BMWi. (2014). *Sanierungsbedarf im Gebäudebestand: Ein Beitrag zur Energieeffizienzstrategie Gebäude*. Bundesministerium für Wirtschaft und Energie (BMWi).
- BMWi. (2015). *Energieeffizienzstrategie Gebäude: Wege zu einem nahezu klimaneutralen Gebäudebestand*. Bundesministerium für Wirtschaft und Energie (BMWi).
- BNetzA. (2016). *Monitoringbericht 2016*. Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahnen.

- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. In D. Haussler (Hrsg.), *Proceedings of the fifth annual workshop on computational learning theory - COLT '92* (S. 144–152). The fifth annual workshop. Pittsburgh, Pennsylvania, United States.
- Boyd, S. P. & Vandenberghe, L. (2011). *Convex optimization* (9. print). Cambridge.
- Burhenne, S. (2013). *Monte Carlo Based Uncertainty and Sensitivity Analysis for Building Performance Simulation* (Dissertation, Karlsruher Institut für Technologie, Karlsruhe).
- Burke, E. & Kendall, G. (2005). Introduction in search methodologies. In E. K. Burke & G. Kendall (Hrsg.), *Search Methodologies* (S. 5–18). Boston, MA: Springer US.
- Campolongo, F., Saltelli, A., Sorensen, T., & Tarantola, S. (2000). Hitchhiker's Guide to Sensitivity Analysis. In A. Saltelli, K. Chan, & E. M. Scott (Hrsg.), *Sensitivity analysis* (S. 15–47). Wiley series in probability and statistics. Chichester: Wiley.
- Clark, J. A. (2001). *Energy Simulation in Building Design* (2. Aufl.). Oxford: Butterworth-Heinemann.
- Collette, Y. & Siarry, P. (2003). *Multiobjective optimization: Principles and case studies*. Decision engineering. Berlin: Springer.
- Collins, L., Natarajan, S., & Levermore, G. (2010). Climate change and future energy consumption in UK housing stock. *Building Services Engineering Research and Technology*, 31, 75–90.
- Cortes, C. & Vapnik, V. N. (1995). *Machine Learning*, 20, 273–297.
- Cox, D. C. & Baybutt, P. (1981). Methods for Uncertainty Analysis: A Comparative Survey. *Risk Analysis*, 1, 251–258.
- Crawley, D. B. (2008). Estimating the impacts of climate change and urbanization on building performance. *Journal of Building Performance Simulation*, 1, 91–115.
- Dantzig, G. B. (1955). Linear Programming under Uncertainty. *Management Science*, 1, 197–206.
- Deb, K. (2005). Multi-Objective Optimization. In E. K. Burke & G. Kendall (Hrsg.), *Search Methodologies* (S. 273–316). Boston, MA: Springer US.
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6, 182–197.
- DEPV. (2016). Brennstoffkostenentwicklung von Erdgas, Öl und Pellets. Zugriff 21. Juni 2016, unter <http://www.depi.de/>
- Dhillon, B. S. & Belland, J. (1986). Bibliography of literature on reliability in civil engineering. *Microelectronics Reliability*, 26, 99–121.

- Diefenbach, N. (2013). Basisdaten für Hochrechnungen mit der Deutschen Gebäudetypologie des IWU: Neufassung Oktober 2013. Zugriff 30. August 2016, unter <http://www.iwu.de/>
- DIN 4108-2. (2013). *Wärmeschutz und Energie-Einsparung in Gebäuden – Teil 2: Mindestanforderungen an den Wärmeschutz*. DIN 4108-2:2013-02.
- DIN EN 15251. (2007). *Eingangsparameter für das Raumklima zur Auslegung und Bewertung der Energieeffizienz von Gebäuden – Raumluftqualität, Temperatur, Licht und Akustik*. DIN EN 15251:2007-08.
- DIN V 18599-1. (2011). *Energetische Bewertung von Gebäuden - Berechnung des Nutz-, End- und Primärenergiebedarfs für Heizung, Kühlung, Lüftung, Trinkwarmwasser und Beleuchtung - Teil 1: Allgemeine Bilanzierungsverfahren, Begriffe, Zonierung und Bewertung der Energieträger*. DIN V 18599-1:2011-12.
- DIN V 4108-6. (2003). *Wärmeschutz und Energie-Einsparung in Gebäuden Teil 6: Berechnung des Jahresheizwärme- und des Jahresheizenergiebedarfs*. DIN V 4108-6:2003-06.
- Domschke, W., Drexl, A., Klein, R., & Scholl, A. (2015). *Einführung in Operations Research* (9., überarb. u. verb. Aufl. 2015). Berlin: Springer.
- Dréo, J. (2006). *Metaheuristics for hard optimization: Methods and case studies*. Berlin: Springer.
- Durbin, J. (1973). *Distribution Theory for Tests Based on the Sample Distribution Function*. Society for Industrial and Applied Mathematics.
- Eberhart, R. & Kennedy, J. (1995). A new optimizer using particle swarm theory. In *MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science* (S. 39–43). Nagoya, Japan. IEEE.
- Ehrgott, M. (2005). *Multicriteria optimization* (2nd ed.). Berlin: Springer.
- Eisenhower, B., O'Neill, Z., Narayanan, S., Fonoberov, V. A., & Mezić, I. (2012). A methodology for meta-model based optimization in building energy models. *Energy and Buildings*, 47, 292–301.
- Endisch, C. (2009). *Optimierungsstrategien für die Identifikation mechatronischer Systeme* (Dissertation, Technische Universität München, München).
- EnEV. (2014). Verordnung über energiesparenden Wärmeschutz und energiesparende Anlagentechnik bei Gebäuden (Energieeinsparverordnung - EnEV). *Bundesgesetzblatt, 2013 Teil I*, 3951–3990.
- EQUA. (2016). Gebäudesimulation mit IDA ICE. Zugriff 23. November 2016, unter <http://www.equa.se>
- Europäische Kommission. (2011). *Energy Efficiency Plan 2011*. Brüssel: Europäische Kommission.

- Evins, R. (2013). A review of computational optimisation methods applied to sustainable building design. *Renewable and Sustainable Energy Reviews*, 22, 230–245.
- Foltyn, M., Komischke, H., & Schmidt, I. (2014). *Vergleichende Analyse Globaler Klimamodellsimulationen für Bayern (Süddeutschland) und umliegende Gebiete*. Augsburg: Bayerisches Landesamt für Umwelt.
- Frangopol, D. M. & Maute, K. (2003). Life-cycle reliability-based optimization of civil and aerospace structures. *Computers & Structures*, 81, 397–410.
- Frank, T. (2005). Climate change impacts on building heating and cooling energy demand in Switzerland. *Energy and Buildings*, 37, 1175–1185.
- Freund, R. J. (1956). The Introduction of Risk into a Programming Model. *Econometrica*, 24, 253.
- Gaterell, M. R. & McEvoy, M. E. (2005). The impact of climate change uncertainties on the performance of energy efficiency measures applied to dwellings. *Energy and Buildings*, 37, 982–995.
- Gritzmann, P. (2013). *Grundlagen der Mathematischen Optimierung: Diskrete Strukturen, Komplexitätstheorie, Konvexitätstheorie, Lineare Optimierung, Simplex-Algorithmus, Dualität*. Wiesbaden: Springer.
- Großklos, M. (2014). Kumulierter Energieaufwand und CO₂-Emissionsfaktoren verschiedener Energieträger und -versorgungen. Zugriff 1. September 2016, unter <http://www.iwu.de>
- Hacker, J. N., De Saullés, T. P., Minson, A. J., & Holmes, M. J. (2008). Embodied and operational carbon dioxide emissions from housing: A case study on the effects of thermal mass and climate change. *Energy and Buildings*, 40, 375–384.
- Hagan, M. T., Demuth, H. B., & Beale, M. H. (1996). *Neural network design* (1st ed.). Boston: PWS Pub.
- Hamdy, M., Palonen, M., & Hasan, A. (2012). Implementation of pareto-archive NSGA-II algorithms to a nearly-zero-energy building optimisation problem. In J. Hacker & D. Mumovic (Hrsg.), *Proceedings of the 1st IBPSA-England conference building simulation and optimization (BSO2012)*, 10.–11. September 2012 (S. 181–188). Loughborough University.
- Henze, G. P. & Neumann, C. (2011). Building simulation in building automation systems. In J. Hensen & R. Lamberts (Hrsg.), *Building performance simulation for design and operation* (1. Aufl., S. 402–440). Abingdon: Spon Press.
- Hillier, F. S. & Lieberman, G. J. (2001). *Introduction to operations research* (7th ed.). McGraw-Hill series in industrial engineering and management science. Boston: McGraw-Hill.

- Hinz, E. (2006). *Gebäudetypologie Bayern - Entwicklung von 11 Hausdatenblättern zu typischen Gebäuden aus dem Wohngebäudebestand Bayerns*. Darmstadt: Institut Wohnen und Umwelt GmbH.
- Hinz, E. (2012). *Kosten energierelevanter Bau- und Anlagenteile bei der energetischen Modernisierung von Wohngebäuden*. Bundesministerium für Verkehr, Bau und Stadtentwicklung (BMVBS).
- Hinz, E. (2015). *Kosten energierelevanter Bau- und Anlagenteile bei der energetischen Modernisierung von Altbauten*. Bundesministerium für Umwelt, Naturschutz, Bau und Reaktorsicherheit.
- Hoier, A. & Erhorn, H. (2013). *Energetische Gebäudesanierung in Deutschland Studie Teil I: Entwicklung und energetische Bewertung alternativer Sanierungsfahrpläne*. Fraunhofer-Institut für Bauphysik IBP.
- Holmes, M. J. & Hacker, J. N. (2007). Climate change, thermal comfort and energy: Meeting the design challenges of the 21st century. *Comfort and Energy Use in Buildings - Getting Them Right*, 39, 802–814
- Hopfe, C. J. (2009). *Uncertainty and sensitivity analysis in building performance simulation for decision support and design optimization* (Dissertation, Technische Universität Eindhoven).
- Hopfe, C. J., Emmerich, M., Marijt, R., & Hensen, J. L. (2012). Robust multi-criteria design optimization in building design. In J. Hacker & D. Mumovic (Hrsg.), *Proceedings of the 1st IBPSA-England conference building simulation and optimization (BSO2012)*, 10.–11. September 2012 (S. 118–125). Loughborough University.
- Hopfe, C. J. & Hensen, J. L. (2011). Uncertainty analysis in building performance simulation for design support. *Energy and Buildings*, 43, 2798–2805.
- Huijbregts, Z., Kramer, R. P., Martens, M., van Schijndel, A., & Schellen, H. L. (2012). A proposed method to assess the damage risk of future climate change to museum objects in historic buildings. *Building and Environment*, 55, 43–56.
- Hwang, C. L. & Masud, A. S. M. (1979). *Multiple objective decision making, methods and applications: A state-of-the-art survey*. Lecture notes in economics and mathematical systems. Masud, Abu Syed Md., (author.) Berlin: Springer-Verlag.
- IBPSA-USA. (2016). Building Energy Software Tools. Zugriff 12. November 2016, unter <http://www.buildingenergysoftwaretools.com>
- IPCC. (2000). *IPCC Special Report: Emission Scenarios*. N. Nakicenovic und R. Swart (Hrsg.) Cambridge: Cambridge University Press.
- IPCC. (2014). *Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate*

- Change (IPCC). Core Writing Team, R.K. Pachauri und L.A. Meyer (Hrsg.). Geneva, Switzerland.*
- Jacob, D. (2001). A note to the simulation of the annual and inter-annual variability of the water budget over the Baltic Sea drainage basin. *Meteorology and Atmospheric Physics*, 77, 61–73.
- Jacob, D. (2012). *Gebäudebetrieboptimierung: Verbesserung von Optimierungsmethoden und Optimierung unter unsicheren Randbedingungen*. Stuttgart: Fraunhofer-Verlag.
- Jacob, D., Andrae, U., Elgered, G., Fortelius, C., Graham, L. P., Jackson, S. D., . . . Yang, X. (2001). A Comprehensive Model Intercomparison Study Investigating the Water Budget during the BALTEX-PIDCAP Period. *Meteorology and Atmospheric Physics*, 77, 19–43.
- Jacob, D., Barring, L., Christensen, O. B., Christensen, J. H., Hagemann, S., Hirschi, M., . . . Van den Hurk, B. (2007). An inter-comparison of regional climate models for Europe: Design of the experiments and model performance. *Climatic Change*, 81, 31–52.
- Jacob, D., Bülow, K., Kotova, L., Moseley, C., Petersen, J., & Rechid, D. (2012). *Regionale Klimaprojektionen für Europa und Deutschland. Ensemble-Simulationen für die Klimafolgenforschung, CSC Report 6*. Deutschland: Climate Service Center.
- Jacob, D., Göttel, H., Kotlarski, S., Lorenz, P., & Sieck, K. (2008). *Klimaauswirkungen und Anpassung in Deutschland – Phase 1: Erstellung regionaler Klimaszenarien für Deutschland*. Dessau-Roßlau: Umweltbundesamt.
- Jacob, D. & Podzun, R. (1997). Sensitivity studies with the regional climate model REMO. *Meteorology and Atmospheric Physics*, 63, 119–129.
- Jain, R. K., Smith, K. M., Culligan, P. J., & Taylor, J. E. (2014). Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy. *Applied Energy*, 123, 168–178.
- Jenkins, D. P., Patidar, S., Banfill, P., & Gibson, G. J. (2011). Probabilistic climate projections with dynamic building simulation: Predicting overheating in dwellings. *Energy and Buildings*, 43, 1723–1731.
- Jenkins, D. P., Peacock, A. D., & Banfill, P. (2009). Will future low-carbon schools in the UK have an overheating problem? *Building and Environment*, 44, 490–501.
- Jinhu, L., Xuemei, L., Lixing, D., & Liangzhong, J. (2010). Applying principal component analysis and weighted support vector machine in building cooling load forecasting. In *2010 International Conference on Computer and Communication Technologies in Agriculture Engineering* (S. 434–437). Chengdu, China. IEEE.

- Jones, P. D., Kilsby, C. G., Harpham, C., Gelnis, V., & Burton, A. (2009). *UK climate projections science report: Projections of future daily climate for the UK from the weather generator*. University of Newcastle.
- Juan, Y.-K., Kim, J. H., Roper, K., & Castro-Lacouture, D. (2009). GA-based decision support system for housing condition assessment and refurbishment strategies. *Automation in Construction*, 18, 394–401.
- Jungwirth, J. (2015). *Lastmanagement in Gebäuden: Entwicklung einer modellprädiktiven Regelung mit einem adaptiven Gebäudemodell zur Flexibilisierung der Wärme- und Kälteversorgung von Gebäuden* (Dissertation, Technische Universität München).
- Jurecka, F. (2007). *Robust design optimization based on metamodeling techniques*. Schriftenreihe des Lehrstuhls für Statik / TU München. Aachen: Shaker.
- Karatasou, S., Santamouris, M., & Geros, V. (2006). Modeling and predicting building's energy use with artificial neural networks: Methods and results. *Energy and Buildings*, 38, 949–958.
- Karatzoglou, A., Meyer, D., & Hornik, K. (2006). Support Vector Machines in R. *Journal of Statistical Software*, 15.
- Keane, A. J. & Nair, P. B. (2005). *Computational Approaches for Aerospace Design*. Chichester, UK: John Wiley & Sons, Ltd.
- Kennedy, J., Eberhart, R. C., & Shi, Y. (2001). *Swarm intelligence*. Morgan Kaufmann series in evolutionary computation. San Francisco: Morgan Kaufmann Publishers.
- Kershaw, T., Eames, M., & Coley, D. (2011). Assessing the risk of climate change for buildings: A comparison between multi-year and probabilistic reference year simulations. *Building and Environment*, 46, 1303–1308.
- Kirkpatrick, S., Gelatt, C. D., & Vecchi, M. P. (1983). Optimization by simulated annealing. *Science (New York, N.Y.)* 220, 671–680.
- Konstantin, P. (2013). *Praxisbuch Energiewirtschaft: Energieumwandlung, Energietransport und Energiebeschaffung im liberalisierten Markt* (3rd ed.). VDI-Buch. Dordrecht: Springer.
- Kotireddy, R., Hoes, P.-J., & Hensen, J. (2015). Optimal balance between energy demand and onsite energy generation for robust net zero energy buildings considering future scenarios. In J. Mathur & V. Garg (Hrsg.), *Conference Proceedings Building Simulation 2015*, 7.–9. Dezember 2015 (S. 1970–1977). IIIT. Hyderabad, Indien.
- Kreider, J. F., Claridge, D. E., Curtiss, P., Dodier, R., Haberl, J. S., & Krarti, M. (1995). Building Energy Use Prediction and System Identification Using Recurrent Neural Networks. *Journal of Solar Energy Engineering*, 117, 161.

- Kreider, J. F. & Haberl, J. S. (1994). Predicting hourly building energy use: the great energy predictor shootout - overview and discussion of results. *ASHRAE Transactions*, 1104–1118.
- Kreider, J. F. & Wan, X. A. (1991). Artificial neural network demonstration for automated generation of energy use predictors for commercial buildings. *ASHRAE Transactions*, 775–779.
- Kuhn, M. & Johnson, K. (2013). *Applied predictive modeling*. New York: Springer.
- Kumar, R., Aggarwal, R. K., & Sharma, J. D. (2013). Energy analysis of a building using artificial neural network: A review. *Energy and Buildings*, 65, 352–358.
- LfU. (2016). Regionale Klimamodelle. Zugriff 26. August 2016, unter <http://www.lfu.bayern.de>
- Li, Q., Meng, Q., Cai, J., Yoshino, H., & Mochida, A. (2009). Applying support vector machine to predict hourly cooling load in the building. *Applied Energy*, 86, 2249–2256.
- Li, Z., Han, Y., & Xu, P. (2014). Methods for benchmarking building energy consumption against its past or intended performance: An overview. *Applied Energy*, 124, 325–334.
- Loga, T., Diefenbach, N., & Born, R. (2011). *Deutsche Gebäudetypologie: Beispielhafte Maßnahmen zur Verbesserung der Energieeffizienz von typischen Wohngebäuden*. Darmstadt: Institut Wohnen und Umwelt.
- Lomas, K. J. & Eppel, H. (1992). Sensitivity analysis techniques for building thermal simulation programs. *Energy and Buildings*, 19, 21–44.
- Lomas, K. J. & Giridharan, R. (2012). Thermal comfort standards, measured internal temperatures and thermal resilience to climate change of free-running buildings: A case-study of hospital wards. *Building and Environment*, 55, 57–72.
- Lu, T. & Viljanen, M. (2009). Prediction of indoor temperature and relative humidity using neural network models: model comparison. *Neural Computing and Applications*, 18, 345–357.
- Macdonald, I. A. (2002). *Quantifying the Effects of Uncertainty in Building Simulation* (Dissertation, University of Strathclyde).
- Machairas, V., Tsangrassoulis, A., & Axarli, K. (2014). Algorithms for optimization of building design: A review. *Renewable and Sustainable Energy Reviews*, 31, 101–112.
- Maderspacher, J., Geyer, P., Auer, T., & Lang, W. (2015). Comparison of different meta model approaches with a detailed building model for long-term simulations. In J. Mathur & V. Garg (Hrsg.), *Conference Proceedings Building Simulation 2015*, 7.–9. Dezember 2015 (S. 106–113). IIIT. Hyderabad, Indien.
- Maderspacher, J., Geyer, P., Auer, T., & Lang, W. (2016). Energy optimization of an existing building based on a neural network and a genetic algorithm. In G. Parnis & T. Kesik (Hrsg.), *eSim 2016*, 2016 (S. 492–499). McMaster University. Hamilton, Kanada.

- Magnier, L. & Haghghat, F. (2010). Multiobjective optimization of building design using TRNSYS simulations, genetic algorithm, and Artificial Neural Network. *Building and Environment*, 45, 739–746.
- Magoules, F. & Zhao, H. X. (2016). *Data Mining and Machine Learning in Building Energy Analysis: Towards High Performance Computing*. Wiley.
- McCulloch, W. S. & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5, 115–133.
- Moore, G. E. (1965). *Cramming more components onto integrated circuits*. New York: McGraw-Hill.
- Mustafaraj, G., Lowry, G., & Chen, J. (2011). Prediction of room temperature and relative humidity by autoregressive linear and nonlinear neural network models for an open office. *Energy and Buildings*, 43, 1452–1460.
- Naval, P. (2013). MOPSOCD: Multi-objective Particle Swarm Optimization with Crowding Distance. Version 0.5.1.
- Nelles, O. (2001). *Nonlinear system identification: From classical approaches to neural networks and fuzzy models*. Berlin: Springer.
- Neuman, K. & Morlock, M. (2002). *Operations-Research* (2. Aufl.). München: Hanser.
- Nguyen, A.-T., Reiter, S., & Rigo, P. (2014). A review on simulation-based optimization methods applied to building performance analysis. *Applied Energy*, 113, 1043–1058.
- Nik, V. M. & Kalagasidis, A. (2013). Impact study of the climate change on the energy performance of the building stock in Stockholm considering four climate uncertainties. *Building and Environment*, 60, 291–304
- Nik, V. M., Mata, E., Kalagasidis, A., & Scartezzini, J.-L. (2015). A statistical method for assessing retrofitting measures of buildings and ranking their robustness against climate change. *Energy and Buildings*, 88, 262–275
- Nik, V. M., Mata, E., Kalagasidis, A., & Scartezzini, J.-L. (2016). Effective and robust energy retrofitting measures for future climatic conditions—Reduced heating demand of Swedish households. *Energy and Buildings*, 121, 176–187
- Nix, E., Das, P., Taylo, J., & Davies, M. (2015). Employing a multi-objective robust optimization method for healthy and low-energy dwellings in Delhi, India. In J. Mathur & V. Garg (Hrsg.), *Conference Proceedings Building Simulation 2015*, 7.–9. Dezember 2015 (S. 2093–2100). IIIT. Hyderabad, Indien.
- Olofsson, T. & Andersson, S. (1998). A method for predicting the annual building heating demand based on limited performance data. *Energy and Buildings*, 28, 101–108.

- Olofsson, T. & Andersson, S. (2001). Long-term energy demand predictions based on short-term measured data. *Energy and Buildings*, 33, 85–91.
- Osterhage, T., Cali, D., Streblow, R., & Müller, D. (2015). Ergebnisse einer energetischen Sanierung: Abweichung zwischen Energiebedarf und Verbrauch - ist nur der Nutzer Schuld? *Bauphysik*, 37, 100–104.
- Padula, S. L., Gumbert, C. R., & Li, W. (2006). Aerospace applications of optimization under uncertainty. *Optimization and Engineering*, 7, 317–328.
- Park, G.-J., Lee, T.-H., Lee, K. H., & Hwang, K.-H. (2006). Robust Design: An Overview. *AIAA Journal*, 44, 181–191.
- Park, S. H. (1996). *Robust design and analysis for quality engineering* (1st ed.). London: Chapman & Hall.
- Penna, P., Prada, A., Cappelletti, F., & Gasparella, A. (2015). Multi-objectives optimization of Energy Efficiency Measures in existing buildings. *Energy and Buildings*, 95, 57–69.
- Pistohl, W. (2007). *Handbuch der Gebäudetechnik: Planungsgrundlagen und Beispiele* (6. Aufl., Bde. 2). Köln: Werner Verlag.
- R Core Team. (2008). R: A language and environment for statistical computing. R Foundation for Statistical Computing. Vienna, Austria.
- Reddy, A. (2011). *Applied Data Analysis and Modeling for Energy Engineers and Scientists*. New York: Springer.
- Rhein, B. (2014). *Robuste Optimierung mit Quantilmaßen auf globalen Metamodellen* (Dissertation, Universität Köln).
- Richtlinie 2010/31/EU. (2010). Richtlinie 2010/31/EU des Europäischen Parlaments und des Rates vom 19. Mai 2010 über die Gesamtenergieeffizienz von Gebäuden. *Amtsblatt der Europäischen Union*, L 153, 13–35.
- Rumelhart, D. E. & McClelland, J. L. (1986). *Parallel distributed processing: Explorations in the microstructure of cognition*. Computational models of cognition and perception. Cambridge, Mass.: MIT Press.
- Sahinidis, N. V. (2004). Optimization under uncertainty: State-of-the-art and opportunities. *Computers & Chemical Engineering*, 28, 971–983.
- Sahlin, P. (1996). *NMF Handbook - An Introduction to the Neutral Model Format*. Stockholm.
- Sahlin, P., Eriksson, L., Grozman, P., Johnsson, H., Shapovalov, A., & Vuolle, M. (2004). Whole-building simulation with symbolic DAE equations and general purpose solvers. *Building and Environment*, 39, 949–958.

- Schölkopf, B., Burges, C., & Vapnik, V. N. (1995). Extracting support data for a given task. In U. M. Fayyad & R. Uthurusamy (Hrsg.), *First International Conference on Knowledge Discovery & Data Mining* (S. 252–257). Menlo Park, California: AAAI Press.
- Schuëller, G. I. & Jensen, H. A. (2008). Computational methods in optimization considering uncertainties – An overview. *Computer Methods in Applied Mechanics and Engineering*, 198, 2–13.
- Schwefel, H.-P. (1977). *Numerische Optimierung von Computer-Modellen mittels der Evolutionsstrategie: Mit einer vergleichenden Einführung in die Hill-Climbing- und Zufallsstrategie*. Interdisciplinary systems research. Basel: Birkhäuser.
- Shao, Y. (2015). *A systematic approach to energy efficiency retrofit solutions for existing office buildings* (Dissertation, Technische Universität München).
- Shepherd, A. J. (1997). *Second-order methods for neural networks: Fast and reliable training methods for multi-layer perceptrons*. Perspectives in neural computing. London: Springer.
- Short, C. A., Lomas, K. J., Giridharan, R., & Fair, A. J. (2012). Building resilience to overheating into 1960's UK hospital buildings within the constraint of the national carbon reduction target: Adaptive strategies. *Building and Environment*, 55, 73–95.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., van den Driessche, G., . . . Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529, 484–489.
- Smola, A. J. & Schölkopf, B. (2002). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*. Adaptive computation and machine learning. Cambridge: MIT Press.
- Smola, A. J. & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14, 199–222.
- Stieß, I., van der Land, Victoria, Birzle-Harder, B., & Deffner, J. (2010). *Handlungsmotive, -hemmnisse und Zielgruppen für eine energetische Gebäudesanierung. Ergebnisse einer standardisierten Befragung von Eigenheimsanierern*. Bundesministerium für Bildung und Forschung.
- Struck, C. (2012). *Uncertainty propagation and sensitivity analysis techniques in building performance simulation to support conceptual building and system design* (Dissertation, Technische Universität Eindhoven).
- Taguchi, G., Elsayed, E. A., & Hsiang, T. C. (1989). *Quality engineering in production systems*. McGraw-Hill series in industrial engineering and management science. New York: McGraw-Hill.

- Tian, W. & Wilde, P. d. (2011). Uncertainty and sensitivity analysis of building performance using probabilistic climate projections: A UK case study. *Automation in Construction*, 20, 1096–1109.
- UKCP09. (2016). UK climate impacts programme. Zugriff 19. August 2016, unter <http://ukclimateprojections.metoffice.gov.uk/>
- van Gelder, L., Janssen, H., & Roels, S. (2014). Probabilistic design and analysis of building performances: Methodology and application example. *Energy and Buildings*, 79, 202–211.
- Vapnik, V. N. (1982). *Estimation of Dependences Based on Empirical Data*. Berlin: Springer.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. New York: Springer.
- Vapnik, V. N. & Chervonenkis, A. (1964). A note on one class of perceptrons. *Automation and Remote Control*.
- Vapnik, V. N. & Chervonenkis, A. (1974). *Theory of Pattern Recognition*. Moskau: Nauka.
- Vapnik, V. N., Golowich, S., & Smola, A. (1997). Support vector method for function approximation, regression estimation, and signal processing. In M. C. Mozer, M. Jordan, & T. Petsche (Hrsg.), *Advances in Neural Information Processing Systems 9* (S. 281–287). Cambridge, MA: MIT Press.
- Vapnik, V. N. & Lerner, A. (1963). Pattern recognition using generalized portrait method. *Automation and Remote Control*.
- Verordnung (EU) Nr. 244/2012. (2012). Delegierte Verordnung (EU) Nr. 244/2012 der Kommission vom 16. Januar 2012 zur Ergänzung der Richtlinie 2010/31/EU des Europäischen Parlaments und des Rates über die Gesamtenergieeffizienz von Gebäuden durch die Schaffung eines Rahmens für eine Vergleichsmethode zur Berechnung kostenoptimaler Niveaus von Mindestanforderungen an die Gesamtenergieeffizienz von Gebäuden und Gebäudekomponenten. *Amtsblatt der Europäischen Union*, L 81, 18–36.
- Wan, K., Li, D., Liu, D., & Lam, J. (2011). Future trends of building heating and cooling loads and energy consumption in different climates. *Building and Environment*, 46, 223–234.
- Wang, Z. & Srinivasan, R. S. (2016). A review of artificial intelligence based building energy use prediction: Contrasting the capabilities of single and ensemble prediction models. *Renewable and Sustainable Energy Reviews*.
- Wetter, M. (2004). *Simulation-Based Building Energy Optimization* (Dissertation, Berkeley, USA).
- Wetter, M. (2011). *GenOpt Generic Optimization Program, User Manual, Version 3.1.0*. Berkeley, USA.

- Wetter, M. & Polak, E. (2004). A convergent optimization method using pattern search algorithms with adaptive precision simulation. *Building Services Engineering Research*, 25, 327–338.
- Wetter, M. & Wright, J. (2004). A comparison of deterministic and probabilistic optimization algorithms for nonsmooth simulation-based optimization. *Building and Environment*, 39, 989–999.
- Wilde, P. d. & Coley, D. (2012). The implications of a changing climate for buildings. *Building and Environment*, 55, 1–7.
- Wilde, P. d. & Tian, W. (2011). Towards probabilistic performance metrics for climate change impact studies. *Energy and Buildings*, 43, 3013–3018.
- Wilde, P. d. & Tian, W. (2012). Management of thermal performance risks in buildings subject to climate change. *Building and Environment*, 55, 167–177.
- Wit, S. d. (2003). Uncertainty in building simulation. In A. M. Malkawi & G. Augenbroe (Hrsg.), *Advanced Building Simulation* (S. 25–59). New York: Spon Press.
- Wright, J. A., Loosemore, H. A., & Farmani, R. (2002). Optimization of building thermal design and control by multi-criterion genetic algorithm. *Energy and Buildings*, 34, 959–972.
- Yao, W., Chen, X., Luo, W., van Tooren, M., & Guo, J. (2011). Review of uncertainty-based multi-disciplinary design optimization methods for aerospace vehicles. *Progress in Aerospace Sciences*, 47, 450–479.
- Zang, C., Friswell, M. I., & Mottershead, J. E. (2005). A review of robust optimal design and its application in dynamics. *Computers & Structures*, 83, 315–326.
- Zang, T., Hensch, M., Hilburger, M., Kenny, S., Luckring, J., Maghami, P., ... Stroud, J. (2002). *Needs and Opportunities for Uncertainty-Based Multidisciplinary Design Methods for Aerospace Vehicles*. Hampton: NASA Langley Research Center.
- Zhang, Y.-M. & Qi, W.-G. (2009). Interval forecasting for heating load using support vector regression and error correcting Markov chains. In *2009 International Conference on Machine Learning and Cybernetics* (S. 1106–1110). Baoding, China. IEEE.
- Zhao, H. X. & Magoulès, F. (2012). A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews*, 16, 3586–3592.

Glossar

Bestimmtheitsmaß

Das Bestimmtheitsmaß wird im Rahmen dieser Arbeit als Kennwert für die Bestimmung der Modellgüte herangezogen. Es gibt an, wie viel Information des Originalsystems durch das Modell abgebildet werden kann.

Black-Box-Modelle

Diese Art von Modellen verwendet empirische Daten von realen Systemen, um ein mathematisches Modell zu erstellen. Dazu werden die Beziehungen von Ein- und Ausgangsvariablen eines Systems mit Hilfe unterschiedlichster Techniken, z.B. aus dem statistischen Lernen, analysiert. Die Struktur des Modells stimmt mit der des abzubildenden Systems nicht überein.

Box-Plot

Diese grafische Analysemethode ermöglicht die Veranschaulichung von Lage und Streuung einer Datenmenge.

Coefficient of Variation

Der Coefficient of Variation ist ein Kennwert für die Modellgüte. Der Kennwert gibt die durchschnittliche prozentuale Abweichung der Modellprognose gegenüber dem Originalsystem an.

Deterministisch

Der Begriff deterministisch bedeutet mit Sicherheit vorhersehbar. Im Rahmen einer mathematischen Optimierung wird dabei angenommen, dass die Parameter und Variablen des Optimierungsproblems keine Unsicherheiten aufweisen.

Ersatzmodell

Vereinfachte Abbildung eines realen Systems oder detaillierten Modells.

Gebäudesimulation

Simulationsumgebung zur Berechnung von Energieflüssen und Komfortvariablen in den vom Anwender definierten Räumen bzw. Gebäuden. Dabei stehen die Räume im Kontakt zu ihrer Umgebung, angrenzenden Bauteilen sowie Personen, Geräten und Gegenständen, welche sich in der jeweiligen Zone befinden. Dadurch ist es möglich, die

dynamische Wechselwirkung zwischen Gebäude, Gebäudetechnik, Klima und Benutzer zu berechnen.

Genetischer Algorithmus

Der Genetische Algorithmus gehört zur Gruppe der Metaheuristiken. Das Optimierungsverfahren basiert auf Prinzipien der Evolution, wie z.B. Selektion, Mutation oder Rekombination.

Globales Optimum

Ein globales Optimum bedeutet, dass im vorhandenen Lösungsraum keine bessere Lösung für das Minimierungs- oder Maximierungsproblem vorhanden ist.

Grey-Box-Modelle

Diese Modelle sind eine Kategorie zwischen einem rein empirischen und einem rein strukturellen Modell. Diese Modelle setzen sich meist aus einer physikalischen und einer empirischen Komponente zusammen.

IDA-ICE

Software für die Simulation von Wärmetransport, vereinfachte Raumluftrömungen, den Einfluss von Solarstrahlung, interne Quellen wie Personen oder Geräte in Gebäuden sowie der Gebäudetechnik.

Kapitalwertmethode

Methode aus der dynamischen Investitionsrechnung, welche die Bewertung der Wirtschaftlichkeit von Investitionen ermöglicht.

Klimamodelle

Klimamodelle werden für die Prognosen von Klimaszenarien verwendet. Sie können in numerische oder statistische Modelle unterschieden werden. Numerische Modelle berechnen mit Hilfe eines dreidimensionalen Gitters der Atmosphäre die darin vorkommenden physikalischen und chemischen Prozesse. Statistische Modelle verwenden die Aufzeichnungen von vorhandenen Klimastationen und adaptieren diese für zukünftige Klimaprojektionen.

Klimaprojektionen

Eine Klimaprojektion ist eine mögliche zukünftige Entwicklung von Klimavariablen. Diese Entwicklungen werden mit Hilfe von Klimaszenarien und einem Klimamodell berechnet.

Kolmogorov-Smirnov Test

Mit Hilfe dieses statistischen Tests kann die Übereinstimmung von zwei Wahrscheinlichkeitsverteilungen untersucht werden.

Latin Hypercube Sampling

Methode zur geordneten Auswahl von Stichproben aus einer Verteilung von Daten.

Lokales Optimum

Ein lokales Optimum bedeutet, dass in der näherer Umgebung der Zielfunktion keine bessere Lösung für das Minimierungs- oder Maximierungsproblem vorhanden ist.

Mathematischen Optimierung

Eine mathematische Optimierung kann vereinfacht mit dem Auffinden eines Extremwertes - Minimum oder Maximum - einer Zielfunktion beschrieben werden.

Median

Der Median repräsentiert einen Wert der genau in der Mitte einer Datenmenge liegt. Dabei wird die Mitte von der Anzahl der Daten bestimmt. Im Vergleich zu einem arithmetischen Mittel, welches den durchschnittlichen Wert einer Datenmenge repräsentiert.

Metaheuristiken

Metaheuristiken sind Algorithmen für die mathematische Optimierung, welche näherungsweise bzw. schrittweise Lösungen erarbeiten. Dabei basieren diese Algorithmen in der Regel auf Erfahrungen aus dem täglichen Leben oder aus Beobachtungen der Natur. In der Regel besitzen Metaheuristiken eine stochastische Komponente.

Monte-Carlo-Simulation

Die Monte-Carlo-Simulation ist ein Verfahren aus der Stochastik und basiert auf der häufigen Wiederholung von gleichartigen Zufallsexperimenten. Das Verfahren basiert auf dem Gesetz der großen Zahlen.

Multi Layer Perceptron

Das Multi Layer Perceptron ist eine spezielle Form eines Neuronalen Netzes und gehört in den Bereich der statischen Modelle. Ein statisches Netz hat ausschließlich vorwärtsgerichtete Verbindungen.

Multikriterielle Optimierung

Eine multikriterielle Optimierung ist das Lösen eines Optimierungsproblems unter Berücksichtigung von mehr als einer Zielfunktion.

Neuronales Netz

Neuronale Netze gehören zur Kategorie der Black-Box-Modelle. Die Struktur eines menschlichen Gehirns dient dieser Technik als Vorlage. Eine häufige Anwendung ist die Modellbildung im Bereich der nichtlinearen Regression oder Klassifizierung.

Neuronen

Die Neuronen sind die kleinste Einheit eines Neuronalen Netzes. Zusammen bilden sie, verbunden über Layer, dessen Gesamtstruktur.

Pareto-Front

Eine Pareto-Front repräsentiert alle Lösungen eines Optimierungsproblems, bei welchen es nicht möglich ist, eine Zielgröße zu verbessern, ohne eine andere Zielgröße zu verschlechtern.

Particle Swarm Optimization

Die Particle Swarm Optimization gehört zur Gruppe der Metaheuristiken. Dieses Optimierungsverfahren basiert auf der Modellierung von sozialen Interaktionen. Dabei wird das Schwarmverhalten von Fischen bei der Futtersuche oder das Verhalten von Zugvögeln imitiert.

Quantil

Ein Quantil bestimmt einen Grenzwert für die Teilung einer Datenmenge. Durch ein Quantil wird definiert, wie viele Werte einer Verteilung über oder unterhalb des Grenzwertes liegen.

Quantildifferenz

Die Quantildifferenz definiert, wie viele Werte einer Verteilung zwischen zwei Quantilen liegen.

Regression

Statistische Methode zur Modellierung der Beziehungen zwischen verschiedenen Größen.

Robuste Optimierung

Die robuste Optimierung ist eine Methode zur Optimierung eines Konzeptes oder Systems, mit dem Ziel das System unempfindlich gegenüber unterschiedliche Arten von Schwankungen zu entwickeln.

Robustheit

Robustheit ist die Eigenschaft eines System, selbst bei Unsicherheiten von Randbedingungen oder Systemparametern keine größeren Streuungen im Ausgangssignal zu entwickeln.

Robustheitskriterien

Für die Bewertung der Ergebnisse einer robusten Optimierung werden, je nach Fragestellung, Robustheitskriterien verwendet. Diese dienen zur Bewertung für die Lage und/oder Streuung der Verteilung der resultierenden Zielgrößen.

Root Mean Squared Error

Kennwert für die Bestimmung der Modellgüte. Dieser Wert gibt die durchschnittliche Abweichung einer Modellprognose an.

Sampling

Verfahren zur Erzeugung von Stichproben aus einem Parameterraum.

Sobol Sequenzen

Quasi-Random Verfahren zur geordneten Auswahl von Stichproben aus einer Verteilung von Daten.

Stichprobe

Zufällige Auswahl eines oder mehrerer Parameter bzw. Datenpunkte aus einer definierten Verteilung oder einem Parameterraum.

Strafffunktion

Mit Hilfe einer Strafffunktion können Grenzen zusätzlicher Zielgrößen in die Zielfunktion integriert werden.

Support Vector Machine

Die Methode der Support Vector Machines, auch Stützvektormethode genannt, dient der Erstellung von Modellen auf Basis von Daten. Die Technik der SVM hat ihren Ursprung im Bereich des statistischen Lernens.

Support Vector Regression

Die Support Vector Regression ist eine spezielle Form der Support Vector Machines. Diese Technik wird im Bereich der nichtlinearen Regression angewandt.

Systemidentifikation

Eine Systemidentifizierung ist die experimentelle Ermittlung von quantitativen Zusammenhängen zwischen Ein- und Ausgangssignal eines Systems.

Testfunktion

Für die Bewertung von Optimierungsverfahren werden oft Testprobleme herangezogen. Dabei wird häufig auf Testfunktionen zurückgegriffen, welche zwar eine komplexe Struktur aufweisen, jedoch analytisch lösbar sind.

Trainingsdaten

Diese Daten dienen zur Erstellung von Modellen im Bereich des statistischen Lernens.

Unsicherheitsanalyse

Statistisches Verfahren zur Analyse von Streuung, bzw. Varianz definierter Zielgrößen eines Modells.

Validierung

Verfahren zur logischen, empirischen oder analytischen Überprüfung eines Modells auf Korrektheit und Nachvollziehbarkeit.

Validierungsdaten

Diese Daten dienen zur Validierung von Modellen im Bereich des statistischen Lernens.

White-Box-Modelle

Diese Art von Modellen wird angewandt, wenn die Struktur des abzubildenden Systems bekannt ist. Dabei wird versucht die Struktur des Systems mit Hilfe mathematischer Gleichungen, wie z.B. gewöhnlicher oder partieller Differentialgleichungen, abzubilden.

Zielfunktion

Die Zielfunktion stellt den funktionalen Zusammenhang von ein- oder mehreren Zielen eines Optimierungsproblems dar.

A | Anhang

A.1 Fallbeispiel

A.1.1 Statistische Auswertung des Einfamilienhausbestandes im Modellquartier Neubaubing-Westkreuz

Für Ermittlung von konkreten Kennwerten für das Beispielgebäude wird der Einfamilienhausbestand des Modellquartiers Neubaubing-Westkreuz statistisch ausgewertet. Anhand der Ergebnisse wird ein repräsentatives Einfamilienhaus definiert. Abbildung A.2 zeigt eine Übersicht des Quartiers. Der Gebäudebestand von Neubaubing-Westkreuz enthält ca. 403 Einfamilienhäuser in unterschiedlichen Größen und Baualtersklassen.

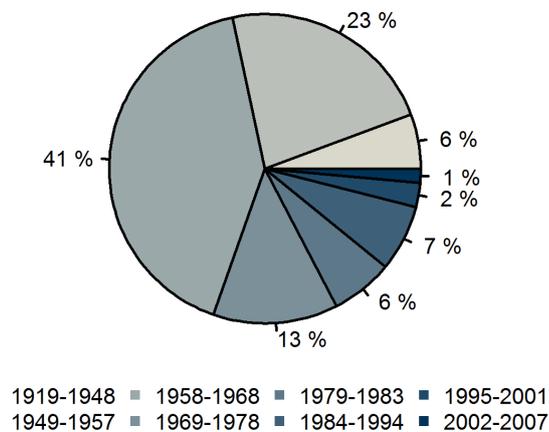


Abbildung A.1: Übersicht der Baualtersklassen des Gebäudetyps Einfamilienhaus im Quartier Neubaubing-Westkreuz

In einem ersten Schritt werden die Baualtersklassen der Einfamilienhäuser analysiert. Grafik A.1 zeigt eine Verteilung der Baualtersklassen im Quartier. Die am häufigsten vorkommende Baualtersklasse ist von 1958 bis 1968. Dabei gehören ca. 41% aller Einfamilienhäuser dieser Klasse an. Diese Baualtersklasse ist ebenfalls für den deutschen und bayerischen Einfamilienhausbestand repräsentativ. Deshalb wird diese Klasse für das Beispielgebäude für die weiteren Analysen festgelegt.



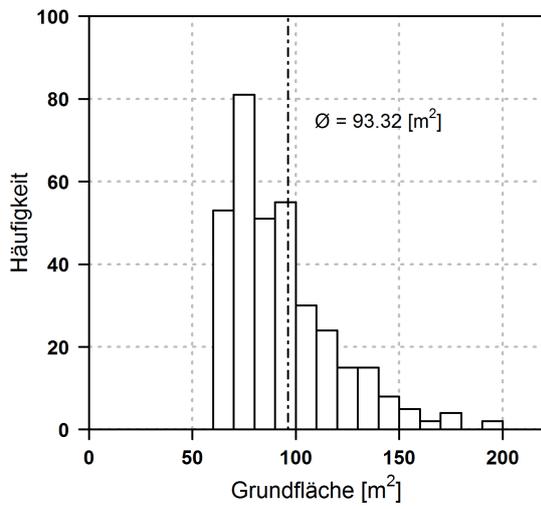
Abbildung A.2: Blaue Markierung aller (403) Einfamilienhäuser im Schwarzplan des Quartiers Neuaubing-Westkreuz

Das Institut Wohnen und Umwelt (IWU) hat eine Gebäudetypologie sowie dazugehörige Hausdatenblätter für den deutschen (Loga et al. 2011) und den bayerischen Wohngebäudebestand erstellt (Hinz 2006). Dadurch ist es möglich, über die Definition der Baualtersklasse Aufbauten von Gebäudekomponenten zu bestimmen. Die ausgewählten Aufbauten der Gebäudekomponenten und deren bauphysikalischen Eigenschaften werden in Tabelle A.1 zusammengefasst.

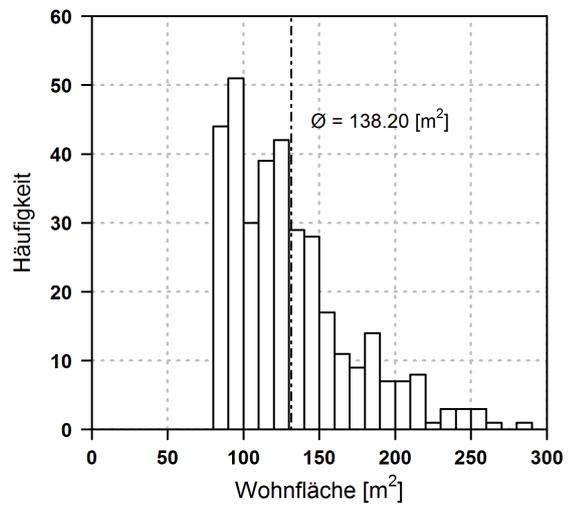
Tabelle A.1: Aufbau Gebäudekomponenten

Bauteil [-]	Aufbau [-]	Dicke [m]	Dichte [kg/m ³]	Wärmeleitfähigkeit [W/mK]	Wärmekapazität [J/kgK]
Außenwand	Putz	0,015	1100	0,35	900
	Vollziegel	0,30	1600	0,68	1000
	Putz	0,015	1100	0,58	900
Innenwand	Putz	0,015	1100	0,35	900
	Vollziegel	0,11	1600	0,68	1000
	Putz	0,015	1100	0,35	900
Bodenplatte	Estrich	0,05	2100	1,66	920
	Dämmung	0,02	70	0,035	850
	Beton	0,15	2300	1,70	880
Innendecke	Putz	0,015	1100	0,35	900
	Beton	0,15	2300	1,70	880
	Putz	0,015	1100	0,35	900
Dach	Holz	0,05	500	0,14	2300
	Luft	0,10	1,20	0,53	1000
	Dämmung	0,015	21	0,045	850
	Putz	0,015	1100	0,35	900
Fenster	U-Wert Fenster	3.50 [W/m ² K]			
	g-Wert Verglasung	0.75 [-]			

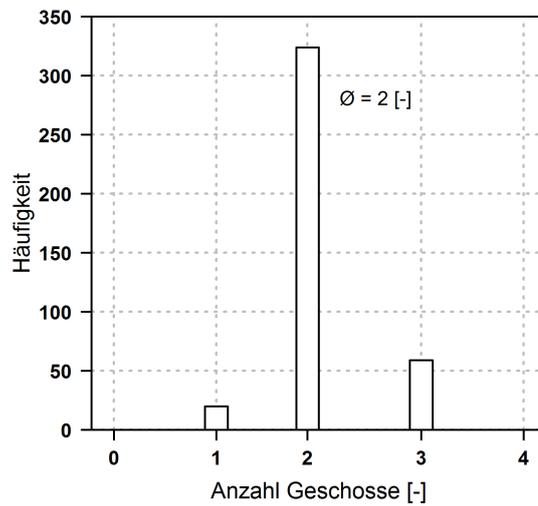
Die Gebäudegeometrie wird mit Hilfe von Mittelwerten aus der statistischen Auswertung des Bestandes bestimmt. Abbildung A.3 zeigt exemplarisch die Verteilungen der Grundfläche, Wohnfläche und Geschossanzahl. Das daraus entwickelte Einfamilienhaus ist mit den Ansichten in Abbildung A.4, den Grundrissen in Abbildung A.5 und A.6 und einem Gebäudeschnitt in Abbildung A.7 dargestellt.



(a) Histogramm der Grundfläche



(b) Histogramm der Wohnfläche



(c) Histogramm der Geschossanzahl

Abbildung A.3: Statistische Auswertung unterschiedlicher Gebäudeparameter des Einfamilienhausbestandes in Neuaubing-Westkreuz

A.1.2 Pläne des Einfamilienhauses

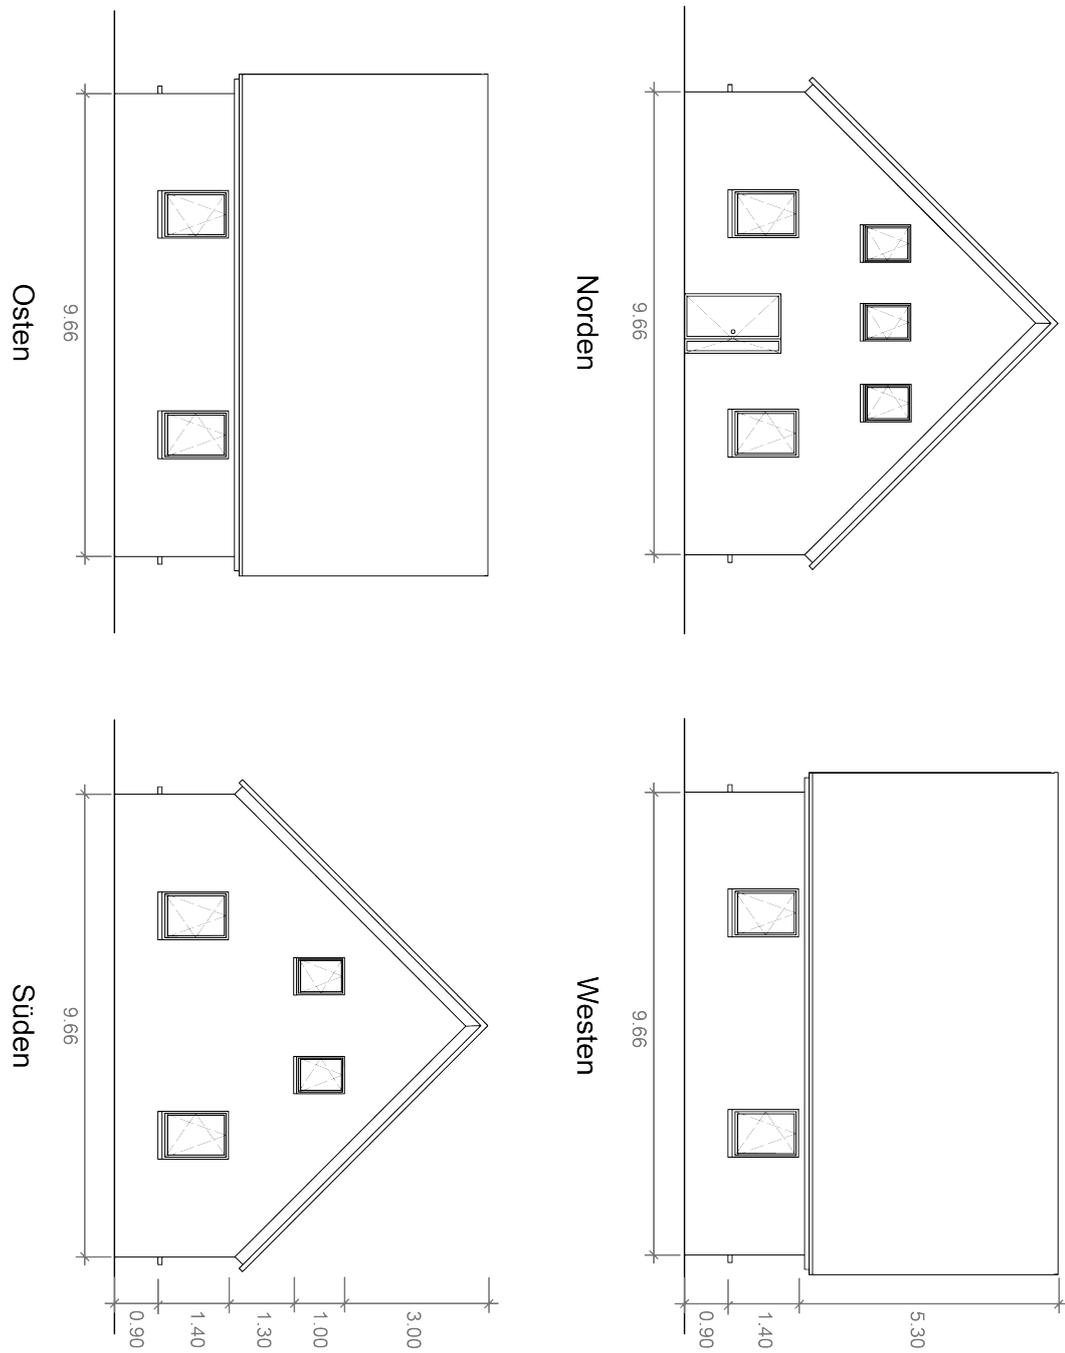


Abbildung A.4: Ansichten des Einfamilienhauses

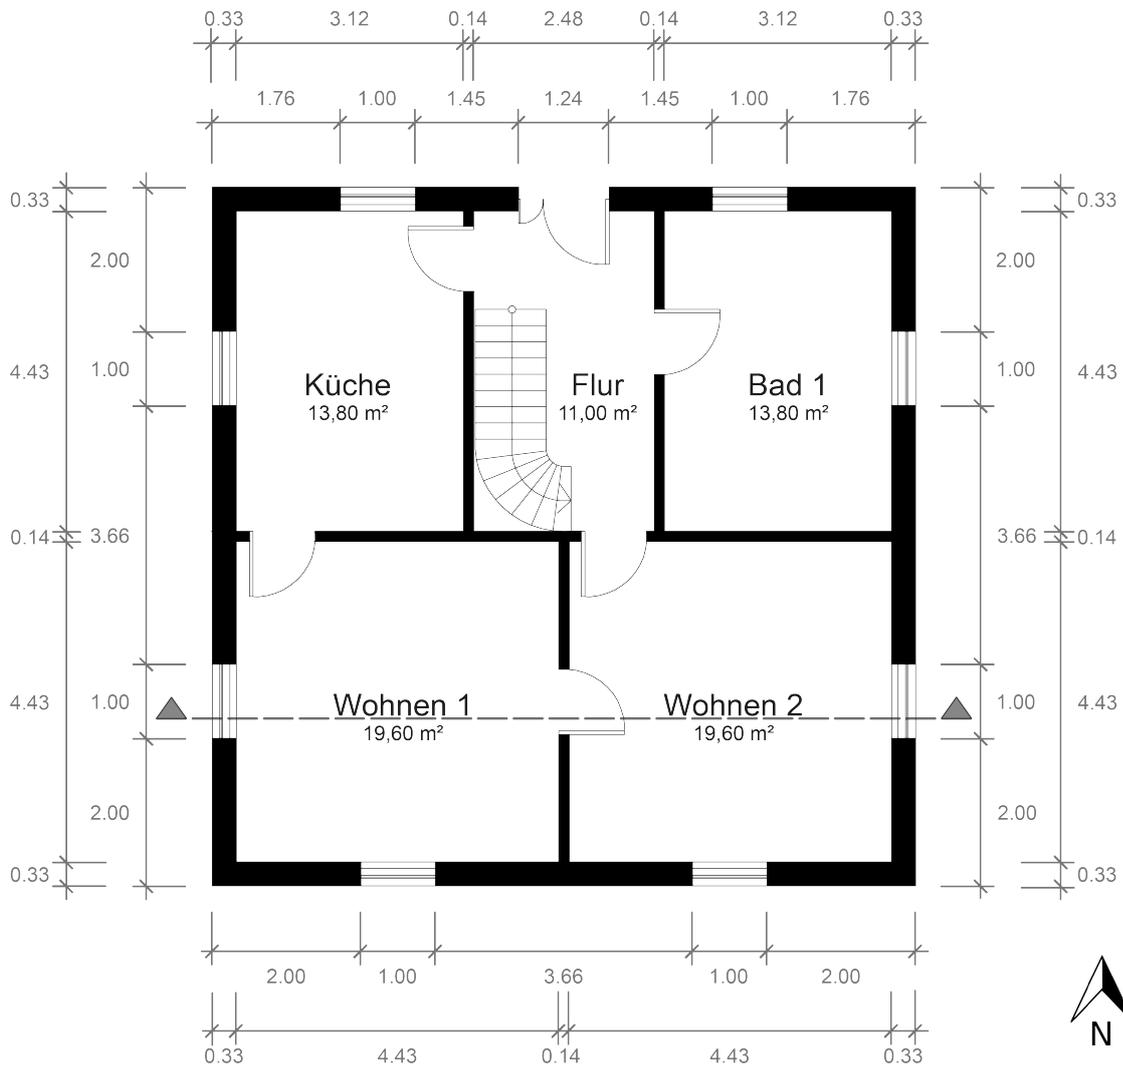


Abbildung A.5: Grundriss Erdgeschoss des Einfamilienhauses

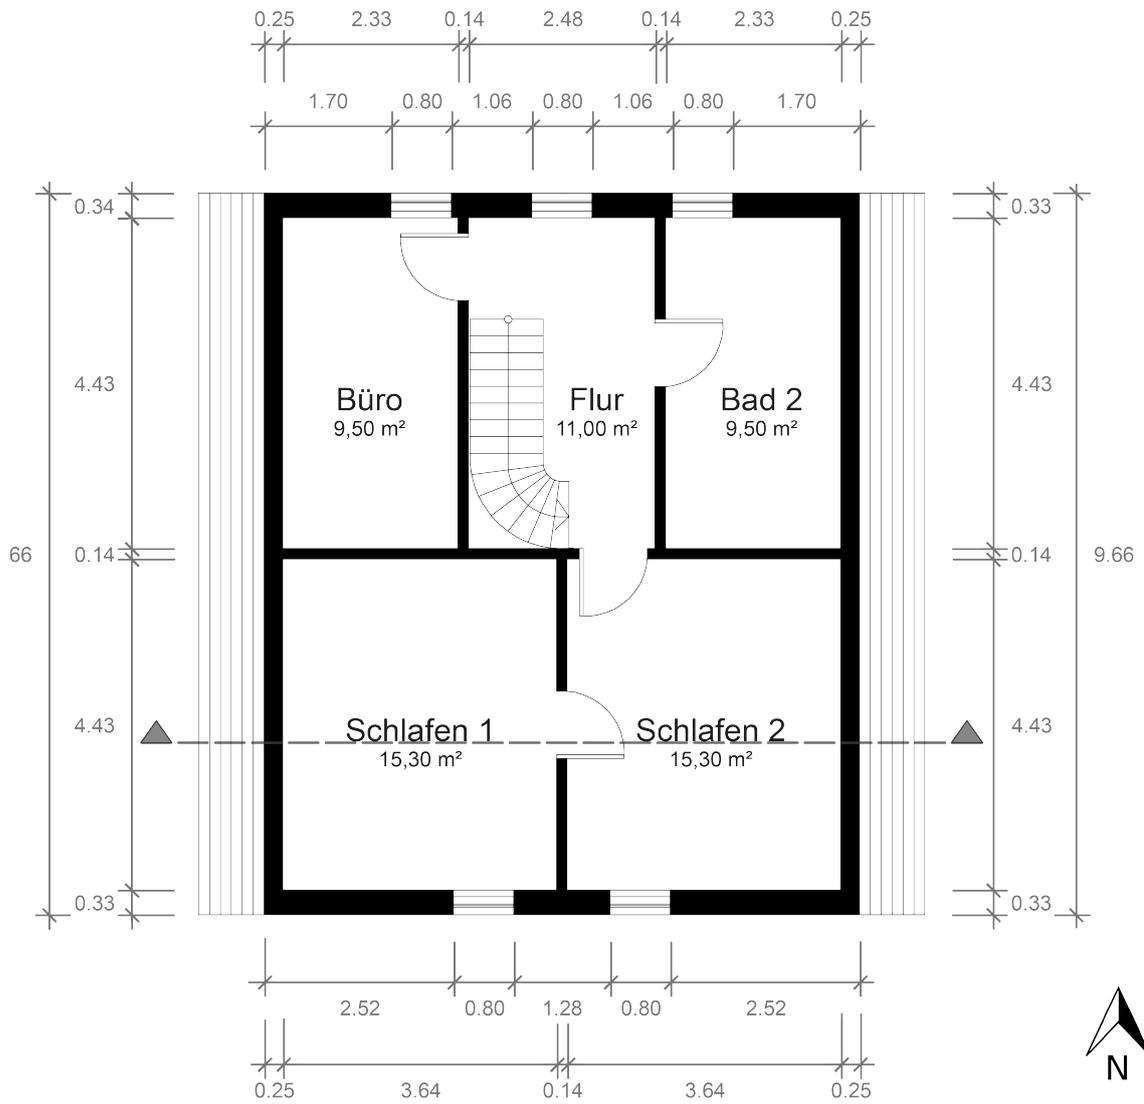


Abbildung A.6: Grundriss Obergeschoss des Einfamilienhauses

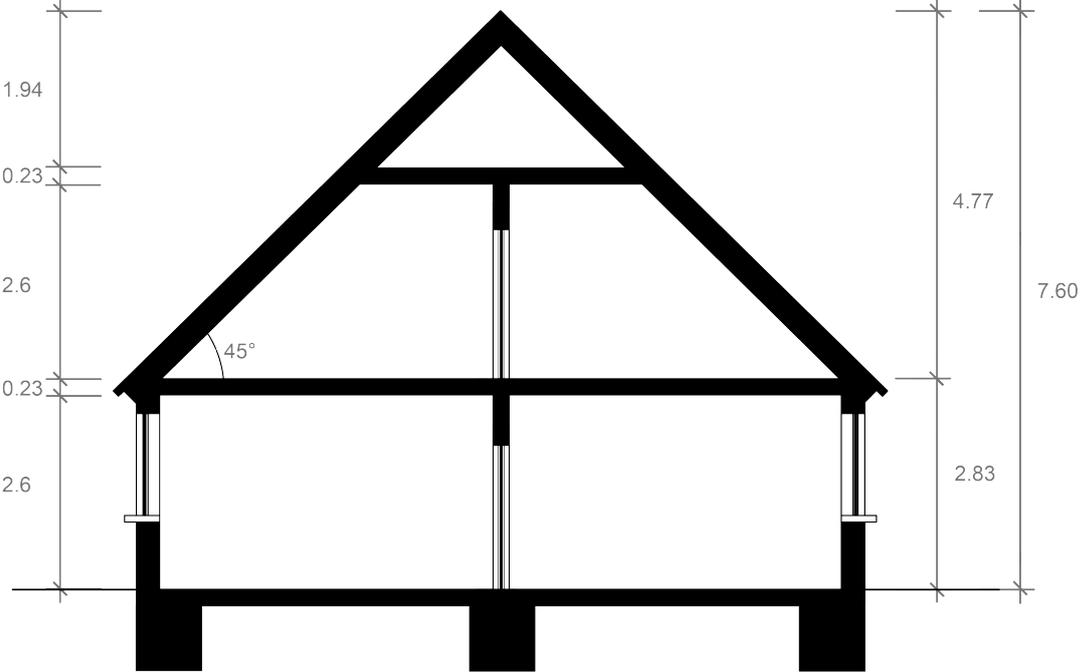


Abbildung A.7: Gebäudeschnitt des Einfamilienhauses

A.2 Optimierung

A.2.1 R-Script Particle Swarm Optimization

```

1 # Definition der Variablen und Parameter -----
2
3 n <- 2                                # Anzahl der Entscheidungsvariablen
4 ngen <- 10                             # Anzahl der Generationen
5 npop <- 40                             # Populationsgröße
6 xmin <- -5                             # Untere Grenze der Parameter
7 xmax <- 5                               # Obere Grenze der Parameter
8
9 w <- 1                                 # Internes Gewicht
10 c1 <- 2                                # Kognitive Parameter
11 c2 <- 2                                # Sozialer Parameter
12
13 # Initiiere die Vektoren und Matrixen mit Zufallszahlen -----
14
15 for ( p in 1:npop){
16   for ( m in 1:n){
17     x[p,m] <- xmin[m] + (xmax[m]-xmin[m])*runif(1)
18     v[p,m] <- (xmax[m]-xmin[m])*0.2
19     vmax[p,m] <- (xmax[m]-xmin[m])*1
20     f[p] <- 10e15
21   }
22 }
23
24 # Start PSO -----
25
26 for ( g in 1:ngen){                    # Iteration über die Generationen
27
28   for (p in 1:npop){                  # Iteration über die Population
29     fnew <- Obj(x[p,])                # Auswertung Zielfunktion
30     if ( fnew < f[p] ) {
31       f[p] <- fnew                    # Bester Wert der Zielfunktion
32       ibest[p,] <- x[p,]              # Individueller beste Position
33       if (fnew < fbest){
34         fbest <- fnew                 # Gesamt bester Wert der Zielfunktion
35         gbest <- x[p,]                # Gesamt beste Position
36       }
37     }
38
39     for (m in 1:n){
40       # Bewegungsgleichung der PSO
41       v[p,m] <- w * v[p,m] + c1*runif(1)*(ibest[p,m] - x[p,m])
42                                     + c2*runif(1)*(gbest[m] - x[p,m])
43
44       # Begrenzung der Geschwindigkeit
45       v[p,m] <- sign(v[p,m]) * min(abs(v[p,m]),vmax[p,m])
46
47       # Aktualisierung der Position
48       x[p,m] <- x[p,m] + v[p,m]
49
50       # Begrenzung des Suchraumes
51       if(x[p,m] < xmin[m]){x[p,m] <- xmin[m]}
52       if(x[p,m] > xmax[m]){x[p,m] <- xmax[m]}
53     }
54   }
55   w=w*0.99
56 }

```

